Guía del usuario

AWS Glue

Copyright © 2025 Amazon Web Services, Inc. and/or its affiliates. All rights reserved.

AWS Glue: Guía del usuario

Copyright © 2025 Amazon Web Services, Inc. and/or its affiliates. All rights reserved.

Las marcas comerciales y la imagen comercial de Amazon no se pueden utilizar en relación con ningún producto o servicio que no sea de Amazon, de ninguna manera que pueda causar confusión entre los clientes y que menosprecie o desacredite a Amazon. Todas las demás marcas registradas que no son propiedad de Amazon son propiedad de sus respectivos propietarios, que pueden o no estar afiliados, conectados o patrocinados por Amazon.

Table of Contents

¿Qué es AWS Glue? 1
Características de AWS Glue 2
Conozca las innovaciones en AWS Glue 4
Introducción a AWS Glue 4
Acceso a AWS Glue 4
Servicios relacionados 5
Cómo funciona 6
Los trabajos de ETL sin servidor se ejecutan de forma aislada 7
Conceptos 8
Terminología de AWS Glue 11
Componentes 14
Consola de AWS Glue 14
AWS Glue Data Catalog 15
Rastreadores y clasificadores de AWS Glue 16
Operaciones de ETL de AWS Glue 16
ETL de streaming en AWS Glue 17
El sistema de trabajos de AWS Glue 17
Componentes de ETL visuales 17
AWS Glue para Spark y AWS Glue para Ray 23
¿Qué es AWS Glue para Ray? 24
Conversión de esquemas semiestructurados a esquemas relacionales 25
Tipos de AWS Glue 27
Tipos de catálogos de datos de AWS Glue 27
Tipos en los scripts de AWS Glue con Spark 27
Tipos de rastreadores de AWS Glue 28
Introducción 29
Información general para el uso de AWS Glue 29
Configuración de permisos de IAM 31
Siguientes pasos 36
Configuración de AWS Glue Studio 36
Introducción a los cuaderno en AWS Glue Studio 48
Configuración de perfiles de uso 51
Administración de perfiles de uso 53
Perfiles de uso y trabajos 65

Introducción al AWS Glue Data Catalog 66
Descripción general 66
Paso 1: Crear una base de datos 66
Paso 2. Creación de una tabla 68
Pasos a seguir a continuación 69
Configuración del acceso de red a los almacenes de datos 73
Configuración de una VPC para conectarse a PyPI para AWS Glue 74
Configuración de DNS en la VPC 76
Configuración del cifrado 77
Configuración de redes para desarrollo 80
Configuración de su red para un punto de conexión de desarrollo 81
Configuración de Amazon EC2 para el servidor de blocs de notas 83
Detección y catalogación de datos 85
Cómo completar el Catálogo de datos 88
Uso de Rastreador de AWS Glue 89
Cómo definir los metadatos manualmente 181
Integración con otros servicios de AWS 201
Configuración del Catálogo de datos 202
Cómo completar y administrar las tablas transaccionales 205
Creación de tablas de Iceberg 205
Optimización de las tablas de Iceberg 209
Optimización del rendimiento de las consultas en tablas de Iceberg 250
Administración del Catálogo de datos 253
Cómo actualizar el esquema y añadir nuevas particiones 254
Cómo optimizar el rendimiento de las consultas con las estadísticas de columnas 262
Cifrado del Catálogo de datos 288
Cómo proteger su Catálogo de datos con Lake Formation 288
Trabajar con vistas AWS Glue Data Catalog 288
Cómo acceder al Catálogo de datos 293
Conexión al catálogo de datos mediante el punto de conexión de REST de AWS Glue Iceberg 294
Conexión al catálogo de datos mediante el punto de conexión de la extensión de REST de AWS Glue Iceberg 297
API de REST de AWS Glue para Apache Iceberg 298
Conexión al catálogo de datos desde una aplicación Spark independiente 318
Asignación de datos entre Amazon Redshift y Apache Iceberg 319

Consideraciones y limitaciones al utilizar las API del catálogo de REST de Iceberg AWS Glue ... 321
Prácticas recomendadas para el uso del Catálogo de datos ... 322
Supervisión de métricas de uso del Catálogo de datos en Amazon CloudWatch ... 323
Información general sobre las métricas del Catálogo de datos ... 323
Cómo agregar métricas a un panel de CloudWatch ... 323
... 325
AWS Glue Schema Registry ... 325
Schemas ... 326
Registries ... 328
Compatibilidad y control de versiones de esquemas ... 329
Bibliotecas Serde de código abierto ... 335
Cuotas del Schema Registry ... 335
Funcionamiento ... 336
Introducción ... 338
Conexión a datos ... 393
Información general del uso de conectores y conexiones ... 393
Conexiones unificadas ... 394
Tipos de autenticación compatibles ... 398
Consideraciones ... 399
Conexiones disponibles ... 399
Limitaciones ... 402
AWS GluePropiedades de las conexiones de ... 403
Propiedades de conexión requeridas ... 403
Propiedades de las conexiones JDBC ... 404
Propiedades de conexión de MongoDB y MongoDB Atlas ... 410
Propiedades de conexión de Salesforce ... 410
Conexión Snowflake ... 411
Conexión vertical ... 412
Conexión a SAP HANA ... 413
Conexión a Azure SQL ... 414
Conexión de Teradata Vantage ... 415
Conexión de OpenSearch Service ... 416
Conexión de Azure Cosmos ... 417
Propiedades de las conexiones SSL ... 417
Propiedades de las conexiones de Kafka para la autenticación de clientes ... 420

Conexión a Google BigQuery 421
Conexión vertical 412
Almacenamiento de credenciales de conexión en AWS Secrets Manager 422
Adición de una conexión de AWS Glue 422
Conexión a Adobe Analytics 425
Conexión a Adobe Marketo Engage 433
Conexión a Amazon Redshift 445
Conexión a Asana 450
Conexión a Azure Cosmos DB 459
Conexión a Azure SQL 463
Conexión a Blackbaud Raiser's Edge NXT 466
Conexión a CircleCI 476
Conexión a Datadog 489
Conexión a Docusign Monitor 496
Conexión a Domo 504
Conexión a Dynatrace 513
Conexión a Anuncios de Facebook 519
Conexión a Facebook Page Insights 527
Conexión a Freshdesk 549
Conexión a Freshsales 560
Conexión a Google Ads 566
Conexión a Google Analytics 4 595
Conexión a Google BigQuery 607
Conexión a Google Search Console 613
Conexión a Google Sheets 622
Conexión a HubSpot 629
Conexión a Anuncios de Instagram 659
Conexión a Intercom 667
Conexión a Jira Cloud 688
Conexión a Kustomer 715
Conexión a LinkedIn 743
Conexión a Mailchimp 751
Conexión con Microsoft Dynamics 365 CRM 762
Conexión a Microsoft Teams 770
Conexión a Mixpanel 781
Conexión a Monday 796

Conexión a MongoDB 805
Conexión a Oracle NetSuite 809
Conexión al servicio OpenSearch 822
Conexión a Okta 825
Conexión a PayPal 834
Conexión a Pendo 841
Conexión a Pipedrive 850
Conexión a Productboard 859
Conexión a QuickBooks 868
Conexión a Salesforce 876
Conexión a Salesforce Marketing Cloud 889
Conexión a Salesforce Commerce Cloud 916
Conexión a Salesforce Marketing Cloud Account Engagement 926
Conexión a SAP HANA 940
Conexión a SAP OData 944
Conexión a SendGrid 967
Conexión a ServiceNow 977
Conexión a Slack 989
Conexión a Smartsheet 1000
Conexión a Snapchat Ads 1012
Conectarse a Snowflake 1022
Conexión a Stripe 1026
Conexión a Teradata 1074
Conexión a Twilio 1078
Conexión a Vertica 1096
Conexión a WooCommerce 1100
Conexión a Zendesk 1128
Conexión a Zoho CRM 1157
Conexión a Zoom Meetings 1168
Agregar una conexión JDBC con sus propios controladores JDBC 1179
Uso de conectores y conexiones personalizados 1184
Creación de conectores personalizados 1186
Creación de conexiones para conectores 1190
Creación de trabajos con conectores personalizados 1199
Administración de conectores y conexiones 1207
Desarrollo de conectores personalizados 1210

Restricciones para el uso de conectores y conexiones en AWS Glue Studio 1213
Prueba de una conexión de AWS Glue 1213
Configuración de las llamadas de AWS para que pasen a través de la VPC 1214
Conexión a un almacén de datos de JDBC en una VPC 1215
Acceso a datos de VPC mediante interfaces de red elásticas 1215
Propiedades de la interfaz de red elástica 1217
Uso de una conexión MongoDB o MongoDB Atlas 1217
Rastreo de un almacén de datos de Amazon S3 mediante un punto de conexión de VPC 1218
Requisitos previos 1218
Crear la conexión a Amazon S3 1219
Prueba de la conexión a Amazon S3 1222
Creación de un rastreador para un almacén de datos de Amazon S3 1224
Creación de un rastreador para tablas del Catálogo de datos respaldadas por Amazon S3 1226
Ejecución de un rastreador 1227
Solución de problemas 1227
Uso de datos protegidos por AWS Lake Formation 1228
Acceso completo a la tabla 1228
Solución de problemas de conexión 1229
Tutorial: uso de AWS Glue Connector for Elasticsearch 1230
Requisitos previos 1231
Paso 1: (opcional) cree un secreto de AWS para la información del clúster de OpenSearch 1231
Paso 2: suscríbase al conector 1232
Paso 3: activar el conector en AWS Glue Studio y crear una conexión 1233
Paso 4: configurar un rol de IAM para el trabajo de ETL 1234
Paso 5: crear un trabajo que utilice la conexión OpenSearch 1234
Paso 6: ejecutar el trabajo 1236
Creación de trabajos de AWS Glue con sesiones interactivas 1237
Información general sobre las sesiones interactivas de AWS Glue 1237
Limitaciones 1238
Introducción a las sesiones interactivas de AWS Glue 1238
Requisitos previos para configurar las sesiones interactivas de manera local 1238
Instalación de Jupyter y kernels de Jupyter de las sesiones interactivas de AWS Glue 1238
Ejecución de Jupyter 1239
Configuración de credenciales de sesión y región 1239
Actualización desde la versión preliminar de las sesiones interactivas 1241

Uso de las sesiones interactivas con SageMaker AI Studio 1241
Uso de las sesiones interactivas con Microsoft Visual Studio Code 1242
Sesiones interactivas con IAM 1245
Configuración de las sesiones interactivas de AWS Glue para cuadernos de Jupyter y AWS Glue Studio 1254
Introducción a los comandos mágicos de Jupyter 1254
Comandos mágicos compatibles con las sesiones interactivas de AWS Glue para Jupyter 1254
Denominación de sesiones 1274
Especificación de un rol de IAM para las sesiones interactivas 1275
Configuración de sesiones con perfiles con nombre 1275
Conversión de un script o cuaderno en un trabajo de AWS Glue 1276
Uso de operaciones de streaming en sesiones interactivas de AWS Glue 1277
Cambio del tipo de sesión de streaming 1277
Muestreo de flujo de entrada para desarrollo interactivo 1277
Ejecución de aplicaciones de streaming en las sesiones interactivas 1279
Precios de las sesiones interactivas de AWS Glue 1280
Configure sus sesiones interactivas de AWS Glue 1280
Desarrollo y pruebas a nivel local 1280
Desarrollo mediante AWS Glue Studio 1281
Desarrollo mediante sesiones interactivas 1281
Desarrollo de trabajos de AWS Glue localmente con Docker 1282
Puntos de conexión de desarrollo 1292
Migración de puntos de conexión de desarrollo a sesiones interactivas 1294
Desarrollo de scripts usando puntos de conexión de desarrollo 1296
Administración de blocs de notas 1326
Creación de trabajos de ETL visual 1328
Creación de trabajos ETL visual con AWS Glue Studio 1328
Inicie sesión en la consola 1328
Siguientes pasos para crear un trabajo en AWS Glue Studio 1329
Creación de flujos de ETL visual con Amazon SageMaker 1329
Inicio de trabajos de ETL visuales en AWS Glue Studio 1329
Empezar trabajos en AWS Glue Studio 1330
Características del editor de trabajo 1332
Transformación de datos con transformaciones administradas de AWS Glue 1340
Transformación de datos con transformaciones visuales personalizadas 1417

Uso de marcos de lagos de datos con AWS Glue Studio 1436
Conexión con orígenes de datos 1448
Configuración de nodos de destino de datos 1458
Edición o carga de un script de trabajo 1464
Cambio de los nodos principales de un nodo en el diagrama de trabajo 1469
Eliminación de nodos del diagrama de trabajo 1469
Añadir parámetros de origen y destino al nodo AWS Glue del Catálogo de datos 1474
Uso de los sistemas de control de versiones de Git en AWS Glue 1476
Creación de código con cuadernos de AWS Glue Studio 1485
Limitaciones 1485
Información general sobre el uso de cuaderno 1486
Creación de un trabajo de ETL mediante cuaderno en AWS Glue Studio 1487
Componentes del editor de cuaderno 1488
Cómo guardar el cuaderno y el script de trabajo 1489
Administración de las sesiones de cuaderno 1490
Uso de Amazon Q Developer con libretas AWS Glue Studio 1492
Supervisión de ejecuciones de trabajos 1492
Acceso al panel de monitoreo de trabajos 1492
Información general del panel de monitoreo de trabajos 1492
Vista de las ejecuciones de trabajo 1493
Visualización de los registros de ejecución de trabajo 1498
Visualización de los detalles de una ejecución de trabajo 1499
Visualización de métricas de Amazon CloudWatch para una ejecución de trabajo de Spark 1502
Visualización de métricas de Amazon CloudWatch para una ejecución de trabajo de Ray . 1503
Detectar y procesar información confidencial 1505
Elegir cómo desea que se escaneen los datos 1505
Elección de las entidades de PII que se desea detectar 1507
Especificar el nivel de sensibilidad de detección 1511
Elegir qué hacer con los datos de PII identificados 1512
Agregar anulaciones de acciones detalladas 1513
Administración de trabajos 1514
Iniciar una ejecución de trabajo 1514
Programar ejecuciones de trabajo 1515
Administrar programaciones de trabajo 1516
Detener ejecuciones de trabajo 1517

Ver los trabajos 1517
Ver información sobre las ejecuciones de trabajos recientes 1518
Ver el script de trabajo 1519
Modificar las propiedades del trabajo 1520
Guardar el trabajo 1523
Clonación de un trabajo 1525
Eliminación de trabajos 1525
Trabajar con tareas 1527
AWS GlueVersiones de 1527
AWS GlueVersiones de 1527
Política de compatibilidad de versiones de AWS Glue 1549
Migración de trabajos de Spark para AWS Glue a la versión 5.0 de AWS Glue 1551
Migración de trabajos de AWS Glue para Spark a la versión 4.0 de AWS Glue 1567
Actualización del análisis con IA 1583
Trabajar con trabajos de Spark 1599
Parámetros del flujo de trabajo 1600
Trabajos de Spark y PySpark 1610
Tipos de trabajadores 1789
Trabajos ETL de streaming 1794
Coincidencia de registros con FindMatches 1809
Migrar programas Spark 1846
Trabajar con tareas de Ray 1855
Introducción a AWS Glue para Ray 1855
Entornos de tiempo de ejecución de Ray compatibles 1856
Contabilidad de los trabajadores en los trabajos de Ray 1857
Parámetros de los trabajos de Ray 1858
Métricas de trabajo de Ray 1861
Configuración de las propiedades de trabajos del intérprete de comandos de Python 1863
Limitaciones 1863
Entorno de ejecución 1864
Definición de las propiedades de trabajos de shell de Python 1864
Bibliotecas compatibles con trabajos de shell de Python 1866
Proporcionar su propia biblioteca de Python 1868
Use AWS CloudFormation con los trabajos del intérprete de comandos de Python en AWS Glue 1872

Migración del intérprete de comandos de Python 3.6 al intérprete de comandos de Python 3.9 1872
Migrar desde trabajos de shell de AWS Glue Python 1873
Monitorización 1875
AWS etiquetas 1876
Automatizar con EventBridge 1881
Monitorización de recursos de 1884
Registro con CloudTrail 1887
Transmisión de AWS Glue 1891
Casos de uso de la transmisión 1891
¿Cuáles son los beneficios de usar la transmisión de AWS Glue? 1892
¿Cuándo conviene usar la transmisión de AWS Glue? 1893
Orígenes de datos admitidos 1894
Destinos de datos admitidos 1894
Tutorial: Cree su primera carga de trabajo de transmisión con AWS Glue Studio 1895
Requisitos previos 1895
Consumir datos de transmisión desde Amazon Kinesis 1895
Tutorial: Cree su primera carga de trabajo de transmisión con los cuadernos de AWS Glue Studio 1906
Requisitos previos 1907
Consumir datos de transmisión desde Amazon Kinesis 1907
Conceptos de la transmisión 1914
Anatomía de un trabajo de transmisión de AWS Glue 1914
Conexiones de Streaming 1918
Conexiones de Kafka 1918
Conexión de Kinesis 1925
Escalado automático de la transmisión de AWS Glue 1932
Habilitar Auto Scaling en AWS Glue Studio 1932
Habilitación de Auto Scaling con AWS CLI o SDK 1933
Funcionamiento 1934
Periodos de mantenimiento 1936
Configuración de un periodo de mantenimiento 1936
Comportamiento del periodo de mantenimiento 1937
Supervisión de trabajos 1938
Gestión de la pérdida de datos 1940
Conceptos avanzados de la transmisión de AWS Glue 1941

Consideraciones de tiempo a la hora de procesar los trabajos de transmisión 1941
Creación de ventanas 1942
Manejo de datos tardíos y marcas de agua 1948
Supervisión de los trabajos de transmisión de AWS Glue 1950
Visualización de métricas de AWS Glue Streaming 1951
Uso de métricas de AWS Glue Streaming 1952
Cómo obtener el mejor rendimiento 1957
Integraciones sin ETL 1959
Capacidades sin ETL en AWS Glue 1959
Requisitos previos 1961
Configuración de los recursos de origen 1961
Configuración de los recursos de destino 1963
Creación de un almacenamiento de datos de Amazon Redshift 1968
Configuración de una VPC 1968
Configuración de una integración entre cuentas 1972
Configuración de un origen 1973
Compatibilidad con entidades SAP especiales 1973
Origen de Amazon DynamoDB 1974
Origen de Salesforce 1975
Origen de Salesforce MCAE 1976
Configuración adicional de Salesforce 1977
Origen SAP OData 1977
Origen de ServiceNow 1977
Origen de Zendesk 1978
Origen de Zoho CRM 1978
Origen de Facebook Ads 1980
Origen de Instagram Ads 1980
Campos de Salesforce no admitidos 1981
Entidades de SAP no compatibles 1984
Campos de ServiceNow no compatibles 1984
Configuración de un destino 1989
SageMaker Lakehouse con el almacenamiento de S3 1990
Destino de las tablas de S3 1990
SageMaker Lakehouse con el almacenamiento de Amazon Redshift 1995
Destino de almacén de datos de Amazon Redshift 1996
Configuración del destino de integración 1997

Desanidamiento de particiones y esquemas ... 1998
Comportamiento predeterminado de desanidamiento y partición ... 1999
Desanidamiento de esquemas ... 1999
Particiones de datos ... 2003
Limitaciones ... 2011
Tareas comunes ... 2011
Creación de una integración ... 2011
Modificación de una integración ... 2013
Eliminación de una integración ... 2014
Uso de las API ... 2014
Supervisión de una integración ... 2015
Estados de integración ... 2015
Visualización de registros ... 2015
Visualización de métricas ... 2018
Notificaciones de eventos ... 2018
Limitaciones ... 2019
Calidad de datos de AWS Glue ... 2030
Beneficios y características principales ... 2030
Funcionamiento ... 2031
Calidad de los datos para AWS Glue Data Catalog ... 2031
Calidad de los datos para los trabajos de ETL de AWS Glue ... 2032
Comparación de los puntos de entrada de Calidad de datos de AWS Glue ... 2032
Consideraciones ... 2034
Terminología ... 2034
Límites ... 2036
Notas de publicación sobre Calidad de datos de AWS Glue ... 2036
Disponibilidad general: características nuevas ... 2036
27 de noviembre de 2023 (Vista previa) ... 2037
12 de marzo de 2024 ... 2037
26 de junio de 2024 ... 2037
7 de agosto de 2024 ... 2037
22 de noviembre de 2024 ... 2037
6 de diciembre de 2024 ... 2038
7 de julio de 2025 ... 2038
21 de noviembre de 2025 ... 2038
Detección de anomalías en Calidad de los datos AWS Glue ... 2038

Funcionamiento ... 2039
Detalles del algoritmo de Detección de anomalías ... 2044
Permisos de IAM para Calidad de los datos de AWS Glue ... 2045
Permisos de IAM ... 2046
Se requiere una configuración de IAM para programar las ejecuciones de evaluación ... 2049
Ejemplos de políticas de IAM ... 2050
Introducción a Calidad de datos de AWS Glue para el Data Catalog ... 2055
Requisitos previos ... 2056
Ejemplo paso a paso ... 2056
Generar recomendaciones de reglas ... 2056
Recomendaciones de reglas de monitoreo ... 2058
Edición de los conjuntos de reglas recomendados ... 2059
Creación de un nuevo conjunto de reglas ... 2060
Ejecute un conjunto de reglas para evaluar la calidad de los datos ... 2062
Visualice la puntuación de la calidad de los datos y los resultados ... 2063
Uso de consultas de preprocesamiento ... 2064
Tipos de orígenes compatibles ... 2067
Temas relacionados ... 2068
Evaluación de la calidad de los datos con AWS Glue Studio ... 2069
Ventajas ... 2069
Evaluación de la calidad de los datos para los trabajos de ETL en AWS Glue Studio ... 2070
Generador de reglas de Calidad de datos ... 2081
Configuración de la detección de anomalías en los trabajos de ETL de AWS Glue ... 2086
Visualización de puntuaciones de calidad de datos y anomalías ... 2089
Calidad de los datos para los trabajos de ETL en los blocs de notas de AWS Glue Studio ... 2093
Requisitos previos ... 2094
Crear un trabajo de ETL en AWS Glue Studio ... 2094
Referencia del lenguaje de definición de calidad de datos (DQDL) ... 2099
Sintaxis ... 2101
Referencia de tipo de regla ... 2121
Uso de las API para medir y gestionar la calidad de los datos ... 2183
Requisitos previos ... 2183
Cómo trabajar con las recomendaciones de Calidad de datos de AWS Glue ... 2184
Trabajar con los conjuntos de reglas de Calidad de datos de AWS Glue ... 2187
Cómo trabajar con ejecuciones de Calidad de datos de AWS Glue ... 2189
Cómo trabajar con los resultados de Calidad de datos de AWS Glue ... 2194

Configuración de alertas, implementaciones y programación 2200
Configuración de alertas y notificaciones en la integración de Amazon EventBridge 2201
Configuración de alertas y notificaciones en la integración de CloudWatch 2209
Cómo consultar de resultados de calidad de datos 2211
Implementación de reglas de calidad de datos 2215
Programación de reglas de calidad de datos 2215
Cifrado de datos en reposo para Calidad de datos de AWS Glue 2215
Claves propiedad de AWS 2215
Claves administradas por el cliente 2216
Crear una clave administrada por el cliente 2219
Creación de una configuración de seguridad 2221
Contexto de cifrado de Calidad de datos de AWS Glue 2222
Monitoreo de las claves de cifrado para Calidad de datos de AWS Glue 2223
Más información 2227
Solución de problemas de calidad de datos de AWS Glue 2228
Error: falta el módulo 2229
Error: permisos insuficientes 2229
Error: los conjuntos de reglas no son únicos 2229
Error: tablas con caracteres especiales 2229
Error: desbordamiento con un conjunto de reglas grande 2229
Error: falló el estado de la regla 2230
AnalysisException: no es posible verificar la existencia de la base de datos predeterminada 2230
El mapa de teclas dado no es adecuado para determinados marcos de datos 2231
java.lang.RuntimeException: no fue posible recuperar los datos. 2231
ERROR DE INICIO: error al descargar desde S3 para bucket 2231
InvalidInputException (estado: 400): las reglas de calidad de datos no se pueden analizar 2232
Error: EventBridge no activa los trabajos de calidad de datos de Glue según la programación que configuré 2232
Errores de CustomSQL 2233
Reglas dinámicas 2233
Excepción en la Clase de usuario: org.apache.spark.sql.AnalysisException: org.apache.hadoop.hive.ql.metadata.HiveException 2235
UNCLASSIFIED_ERROR; IllegalArgumentException: Error de análisis: no se proporcionaron reglas ni analizadores, no hay una alternativa viable en la entrada 2236
Integración de datos de Amazon Q en AWS Glue 2237

¿Qué es Amazon Q? ... 2237
Integración de datos de Amazon Q en AWS Glue ... 2237
Trabajo con la integración de datos de Amazon Q ... 2238
Prácticas recomendadas ... 2240
Mejora del servicio ... 2241
Consideraciones ... 2241
Cómo configurar la integración de datos de Amazon Q ... 2241
Configuración de permisos de IAM ... 2241
Generación de código compatibles ... 2244
Interacciones de muestra ... 2245
Interacciones del chat de Amazon Q ... 2245
Interacciones del cuaderno de AWS Glue Studio ... 2246
Uso del reconocimiento del contexto ... 2250
Ejemplo: Interacciones ... 2250
Limitaciones ... 2254
Orquestación ... 2255
Inicio de trabajos y rastreadores mediante desencadenadores ... 2255
Disparadores de AWS Glue ... 2255
Agregado de desencadenadores ... 2258
Activación y desactivación de desencadenadores ... 2262
Realización de actividades de ETL complejas mediante esquemas y flujos de trabajo ... 2263
Descripción general de flujos de trabajo ... 2264
Creación y desarrollo manual de un flujo de trabajo ... 2268
Inicio de un flujo de trabajo con un evento de EventBridge ... 2273
Visualizar los eventos de EventBridge que iniciaron un flujo de trabajo ... 2280
Ejecución y monitoreo de un flujo de trabajo ... 2281
Detener una ejecución de flujo de trabajo ... 2284
Reparar y reanudar la ejecución de un flujo de trabajo ... 2285
Obtención y configuración de propiedades de ejecución de flujo de trabajo ... 2291
Consulta de flujos de trabajo mediante la AWS Glue API ... 2292
Restricciones de esquemas y flujos de trabajo ... 2297
Solución de errores de esquema ... 2298
Permisos de personas y roles para esquemas ... 2303
Desarrollo de esquemas ... 2308
Información general de los esquemas ... 2309
Desarrollo de esquemas ... 2312

Registrar un esquema ... 2338
Visualización de esquemas ... 2340
Actualizar un proyecto ... 2342
Creación de un flujo de trabajo a partir de un esquema ... 2344
Visualización de ejecuciones de esquemas ... 2346
AWS CloudFormation para AWS Glue ... 2348
Base de datos de muestra ... 2350
Base de datos, tabla y particiones de muestra ... 2351
Clasificador de Grok de muestra ... 2356
Clasificador de JSON de muestra ... 2357
Clasificador de XML de muestra ... 2358
Ejemplo de rastreador de Amazon S3 ... 2359
Conexión de muestra ... 2361
Conexión de muestra ... 2362
Conexión de muestra ... 2363
Rastreador de JDBC de muestra ... 2365
Trabajo para Amazon S3 de ejemplo a Amazon S3 ... 2368
Trabajo de ejemplo para JDBC a Amazon S3 ... 2369
Disparador bajo demanda de muestra ... 2371
Disparador programado de muestra ... 2372
Disparador condicional de muestra ... 2373
Ejemplo de transformación de machine learning ... 2375
Ejemplo de conjunto de reglas de calidad de los datos ... 2376
Ejemplo de conjunto de reglas de calidad de datos con el programador de EventBridge ... 2377
Punto de conexión de desarrollo de muestra ... 2380
Guía de programación de AWS Glue ... 2382
Suministro de sus propios scripts personalizados ... 2382
Glue para Spark AWS ... 2383
Tutorial: Escritura de un script de Spark ... 2384
ETL en PySpark ... 2398
ETL en Scala ... 2643
Características y optimizaciones ... 2730
AWS Glue para Ray ... 3013
Tutorial: Cómo escribir un script de Ray ... 3013
Uso de Ray Core y Ray Data en AWS Glue para Ray ... 3019
Proporcionar archivos y bibliotecas de Python ... 3021

Conexión a datos ... 3027
Cómo utilizar los AWS SDK ... 3029
API de AWS Glue ... 3031
Seguridad ... 3059
— tipos de datos — ... 3059
DataCatalogEncryptionSettings ... 3059
EncryptionAtRest ... 3060
ConnectionPasswordEncryption ... 3060
EncryptionConfiguration ... 3061
S3Encryption ... 3062
CloudWatchEncryption ... 3062
JobBookmarksEncryption ... 3062
SecurityConfiguration ... 3063
Política de Glue ... 3063
DataQualityEncryption ... 3064
— operaciones — ... 3064
GetDataCatalogEncryptionSettings (get_data_catalog_encryption_settings) ... 3065
PutDataCatalogEncryptionSettings (put_data_catalog_encryption_settings) ... 3065
PutResourcePolicy (put_resource_policy) ... 3066
GetResourcePolicy (get_resource_policy) ... 3068
DeleteResourcePolicy (delete_resource_policy) ... 3069
CreateSecurityConfiguration (create_security_configuration) ... 3069
DeleteSecurityConfiguration (delete_security_configuration) ... 3070
GetSecurityConfiguration (get_security_configuration) ... 3071
GetSecurityConfigurations (get_security_configurations) ... 3072
GetResourcePolicies (get_resource_policies) ... 3072
Objetos del catálogo ... 3073
Catálogos ... 3074
Bases de datos ... 3089
Tablas ... 3099
Particiones ... 3148
Connections ... 3174
Funciones definidas por el usuario ... 3219
Importación de un catálogo de Athena ... 3226
Optimizador de tablas ... 3228
— data types — ... 3228

TableOptimizer ... 3229
TableOptimizerConfiguration ... 3229
TableOptimizerVpcConfiguration ... 3230
CompactionConfiguration ... 3231
IcebergCompactionConfiguration ... 3231
TableOptimizerRun ... 3232
BatchGetTableOptimizerEntry ... 3234
BatchTableOptimizer ... 3234
BatchGetTableOptimizerError ... 3235
RetentionConfiguration ... 3235
IcebergRetentionConfiguration ... 3236
OrphanFileDeletionConfiguration ... 3236
IcebergOrphanFileDeletionConfiguration ... 3237
CompactionMetrics ... 3237
RetentionMetrics ... 3238
OrphanFileDeletionMetrics ... 3238
IcebergCompactionMetrics ... 3238
IcebergRetentionMetrics ... 3239
IcebergOrphanFileDeletionMetrics ... 3239
RunMetrics ... 3239
— operaciones — ... 3240
GetTableOptimizer (get_table_optimizer) ... 3240
BatchGetTableOptimizer (batch_get_table_optimizer) ... 3242
ListTableOptimizerRuns (list_table_optimizer_runs) ... 3242
CreateTableOptimizer (create_table_optimizer) ... 3244
DeleteTableOptimizer (delete_table_optimizer) ... 3245
UpdateTableOptimizer (update_table_optimizer) ... 3246
Rastreadores y clasificadores ... 3247
Clasificadores ... 3248
Rastreadores ... 3262
Estadísticas de las columnas ... 3291
Programador ... 3307
Generación automática de scripts de ETL ... 3310
— tipos de datos — ... 3310
CodeGenNode ... 3310
CodeGenNodeArg ... 3311

CodeGenEdge 3311
Ubicación 3312
CatalogEntry 3312
MappingEntry 3312
— operaciones — 3313
CreateScript (create_script) 3313
GetDataflowGraph (get_dataflow_graph) 3314
GetMapping (get_mapping) 3315
GetPlan (get_plan) 3316
API de Visual Job 3317
— data types — 3317
CodeGenConfigurationNode 3321
JDBCConnectorOptions 3329
StreamingDataPreviewOptions 3330
AthenaConnectorSource 3331
JDBCConnectorSource 3331
SparkConnectorSource 3332
CatalogSource 3333
MySQLCatalogSource 3334
PostgreSQLCatalogSource 3334
OracleSQLCatalogSource 3334
MicrosoftSQLServerCatalogSource 3335
CatalogKinesisSource 3335
DirectKinesisSource 3336
KinesisStreamingSourceOptions 3337
CatalogKafkaSource 3340
DirectKafkaSource 3340
KafkaStreamingSourceOptions 3341
RedshiftSource 3343
AmazonRedshiftSource 3344
AmazonRedshiftNodeData 3344
AmazonRedshiftAdvancedOption 3347
Opción 3347
S3CatalogSource 3348
S3SourceAdditionalOptions 3348
S3CsvSource 3349

DirectJDBCSource 3351
S3DirectSourceAdditionalOptions 3352
S3JsonSource 3352
S3ParquetSource 3354
S3DeltaSource 3355
S3CatalogDeltaSource 3356
CatalogDeltaSource 3357
S3HudiSource 3358
S3CatalogHudiSource 3358
S3ExcelSource 3359
CatalogHudiSource 3360
DynamoDBCatalogSource 3361
RelationalCatalogSource 3361
JDBCConnectorTarget 3362
SparkConnectorTarget 3363
BasicCatalogTarget 3364
MySQLCatalogTarget 3364
PostgreSQLCatalogTarget 3365
OracleSQLCatalogTarget 3365
MicrosoftSQLServerCatalogTarget 3366
RedshiftTarget 3366
AmazonRedshiftTarget 3367
UpsertRedshiftTargetOptions 3368
S3CatalogTarget 3368
S3GlueParquetTarget 3369
CatalogSchemaChangePolicy 3370
S3DirectTarget 3370
S3HudiCatalogTarget 3371
S3HudiDirectTarget 3372
S3DeltaCatalogTarget 3374
S3DeltaDirectTarget 3375
S3HyperDirectTarget 3376
S3IcebergDirectTarget structure 3377
DirectSchemaChangePolicy 3378
ApplyMapping 3379
Correspondencia 3379

SelectFields 3380
DropFields 3381
RenameField 3381
Spigot 3382
Join 3383
JoinColumn 3383
SplitFields 3384
SelectFromCollection 3384
FillMissingValues 3385
Filtro 3385
FilterExpression 3386
FilterValue 3386
CustomCode 3387
SparkSQL 3387
SQLAlias 3388
DropNullFields 3388
NullCheckBoxList 3389
NullValueField 3390
Tipo de datos 3390
Merge 3390
Unión 3391
PIIDetection 3391
Agregado 3393
DropDuplicates 3394
GovernedCatalogTarget 3394
GovernedCatalogSource 3395
AggregateOperation 3396
GlueSchema 3396
GlueStudioSchemaColumn 3396
GlueStudioColumn 3397
DynamicTransform 3398
TransformConfigParameter 3399
EvaluateDataQuality 3400
DQResultsPublishingOptions 3401
DQStopJobOnFailureOptions 3401
EvaluateDataQualityMultiFrame 3402

Recipe 3403
RecipeReference 3403
SnowflakeNodeData 3404
SnowflakeSource 3406
SnowflakeTarget 3406
ConnectorDataSource 3407
ConnectorDataTarget 3408
RecipeStep 3409
RecipeAction 3409
ConditionExpression 3410
S3CatalogIcebergSource 3410
CatalogIcebergSource 3411
S3IcebergCatalogTarget 3411
DynamoDBELTConnectorSource 3412
DDBELTConnectionOptions 3413
DDBELTCatalogAdditionalOptions 3414
Ruta 3414
GroupFilters 3415
AutoDataQuality 3415
Tareas 3416
Trabajos 3416
Ejecuciones de trabajo 3443
Desencadenadores 3464
API de integración 3479
— data types — 3479
Integración 3479
IntegrationConfig 3481
IntegrationPartition 3482
IntegrationError 3483
IntegrationFilter 3483
InboundIntegration 3484
SourceProcessingProperties 3485
TargetProcessingProperties 3485
SourceTableConfig 3485
TargetTableConfig 3486
— operaciones — 3487

CreateIntegration (create_integration) 3487
ModifyIntegration (modify_integration) 3490
DescribeIntegrations (describe_integrations) 3493
DeleteIntegration (delete_integration) 3495
DescribeInboundIntegrations (describe_inbound_integrations) 3497
CreateIntegrationTableProperties (create_integration_table_properties) 3498
UpdateIntegrationTableProperties (update_integration_table_properties) 3499
GetIntegrationTableProperties (get_integration_table_properties) 3501
DeleteIntegrationTableProperties (delete_integration_table_properties) 3502
CreateIntegrationResourceProperty (create_integration_resource_property) 3503
UpdateIntegrationResourceProperty (update_integration_resource_property) 3504
GetIntegrationResourceProperty (get_integration_resource_property) 3506
UntagResource (untag_resource) 3507
ListTagsForResource (list_tags_for_resource) 3507
— excepciones — 3508
ResourceNotFoundException 3508
InternalServerException 3508
IntegrationAlreadyExistsFault 3509
IntegrationConflictOperationFault 3509
IntegrationQuotaExceededFault 3509
KMSKeyNotAccessibleFault 3509
IntegrationNotFoundFault 3510
TargetResourceNotFound 3510
InvalidIntegrationStateFault 3510
Sesiones interactivas 3510
— data types — 3510
Sesión 3511
SessionCommand 3513
Instrucción 3514
StatementOutput 3514
StatementOutputData 3515
ConnectionsList 3515
— operaciones — 3515
CreateSession (create_session) 3516
StopSession (stop_session) 3520
DeleteSession (delete_session) 3520

getSession (get_session) 3521
ListSessions (list_sessions) 3522
RunStatement (run_statement) 3523
CancelStatement (cancel_statement) 3524
GetStatement (get_statement) 3525
ListStatements (list_statement) 3526
GetGlueIdentityCenterConfiguration (get_glue_identity_center_configuration) 3527
UpdateGlueIdentityCenterConfiguration (update_glue_identity_center_configuration) 3528
CreateGlueIdentityCenterConfiguration (create_glue_identity_center_configuration) 3529
DeleteGlueIdentityCenterConfiguration (delete_glue_identity_center_configuration) 3530
DevEndpoints 3530
— tipos de datos — 3531
DevEndpoint 3531
DevEndpointCustomLibraries 3535
— operaciones — 3536
CreateDevEndpoint (create_dev_endpoint) 3536
UpdateDevEndpoint (update_dev_endpoint) 3542
DeleteDevEndpoint (delete_dev_endpoint) 3543
GetDevEndpoint (get_dev_endpoint) 3544
GetDevEndpoints (get_dev_endpoints) 3545
BatchGetDevEndpoints (batch_get_dev_endpoints) 3546
ListDevEndpoints (list_dev_endpoints) 3547
Schema Registry 3548
— tipos de datos — 3548
RegistryId 3548
RegistryListItem 3549
MetadataInfo 3550
OtherMetadataValueListItem 3550
SchemalistItem 3550
SchemaVersionListItem 3551
MetadataKeyValuePair 3552
SchemaVersionErrorItem 3552
ErrorDetails 3553
SchemaVersionNumber 3553
SchemaId 3553
— operaciones — 3554

CreateRegistry (create_registry) 3555
CreateSchema (create_schema) 3556
GetSchema (get_schema) 3560
ListSchemaVersions (list_schema_versions) 3562
GetSchemaVersion (get_schema_version) 3564
GetSchemaVersionsDiff (get_schema_versions_diff) 3565
ListRegistries (list_registries) 3567
ListSchemas (list_schemas) 3568
RegisterSchemaVersion (register_schema_version) 3569
UpdateSchema (update_schema) 3570
CheckSchemaVersionValidity (check_schema_version_validity) 3572
UpdateRegistry (update_registry) 3573
GetSchemaByDefinition (get_schema_by_definition) 3574
GetRegistry (get_registry) 3575
PutSchemaVersionMetadata (put_schema_version_metadata) 3577
QuerySchemaVersionMetadata (query_schema_version_metadata) 3578
RemoveSchemaVersionMetadata (remove_schema_version_metadata) 3580
DeleteRegistry (delete_registry) 3582
DeleteSchema (delete_schema) 3583
DeleteSchemaVersions (delete_schema_versions) 3584
Flujos de trabajo 3585
— tipos de datos — 3585
JobNodeDetails 3586
CrawlerNodeDetails 3586
TriggerNodeDetails 3586
Rastreo 3586
Nodo 3587
Periferia 3588
Flujo de trabajo 3588
WorkflowGraph 3590
WorkflowRun 3590
WorkflowRunStatistics 3591
StartingEventBatchCondition 3592
Proyecto 3593
BlueprintDetails 3594
LastActiveDefinition 3594

BlueprintRun 3595
— operaciones — 3596
CreateWorkflow (create_workflow) 3597
UpdateWorkflow (update_workflow) 3599
DeleteWorkflow (delete_workflow) 3600
GetWorkflow (get_workflow) 3601
ListWorkflows (list_workflows) 3601
BatchGetWorkflows (batch_get_workflows) 3602
GetWorkflowRun (get_workflow_run) 3603
GetWorkflowRuns (get_workflow_runs) 3604
GetWorkflowRunProperties (get_workflow_run_properties) 3605
PutWorkflowRunProperties (put_workflow_run_properties) 3606
CreateBlueprint (create_blueprint) 3607
UpdateBlueprint (update_blueprint) 3608
DeleteBlueprint (delete_blueprint) 3609
ListBlueprints (list_blueprints) 3610
BatchGetBlueprints (batch_get_blueprints) 3611
StartBluePrintRun (start_blueprint_run) 3612
GetBlueprintRun (get_blueprint_run) 3613
GetBlueprintRuns (get_blueprint_runs) 3613
StartWorkflowRun (start_workflow_run) 3614
StopWorkflowRun (stop_workflow_run) 3615
ResumeWorkFlowRun (resume_workflow_run) 3616
Perfiles de uso 3617
— data types — 3617
ProfileConfiguration 3618
ConfigurationObject 3618
UsageProfileDefinition 3619
— operaciones — 3619
CreateUsageProfile (create_usage_profile) 3620
GetUsageProfile (get_usage_profile) 3621
UpdateUsageProfile (update_usage_profile) 3622
DeleteUsageProfile (delete_usage_profile) 3623
ListUsageProfiles (list_usage_profiles) 3623
Machine learning 3624
— tipos de datos — 3624

TransformParameters 3625
EvaluationMetrics 3625
MLTransform 3626
FindMatchesParameters 3629
FindMatchesMetrics 3630
ConfusionMatrix 3632
GlueTable 3632
TaskRun 3633
TransformFilterCriteria 3634
TransformSortCriteria 3636
TaskRunFilterCriteria 3636
TaskRunSortCriteria 3637
TaskRunProperties 3637
FindMatchesTaskRunProperties 3638
ImportLabelsTaskRunProperties 3638
ExportLabelsTaskRunProperties 3639
LabelingSetGenerationTaskRunProperties 3639
SchemaColumn 3639
TransformEncryption 3640
MLUserDataEncryption 3640
ColumnImportance 3641
— operaciones — 3641
CreateMLTransform (create_ml_transform) 3642
UpdateMLTransform (update_ml_transform) 3645
DeleteMLTransform (delete_ml_transform) 3648
GetMLTransform (get_ml_transform) 3649
GetMLTransforms (get_ml_transforms) 3652
ListMLTransforms (list_ml_transforms) 3653
StartMLEvaluationTaskRun (start_ml_evaluation_task_run) 3654
StartMLLabelingSetGenerationTaskRun (start_ml_labeling_set_generation_task_run) 3655
GetMLTaskRun (get_ml_task_run) 3656
GetMLTaskRuns (get_ml_task_runs) 3658
CancelMLTaskRun (cancel_ml_task_run) 3659
StartExportLabelsTaskRun (start_export_labels_task_run) 3660
StartImportLabelsTaskRun (start_import_labels_task_run) 3661
Calidad de datos 3663

— data types — 3663
DataSource 3664
DataQualityRulesetListDetails 3664
DataQualityTargetTable 3665
DataQualityRulesetEvaluationRunDescription 3666
DataQualityRulesetEvaluationRunFilter 3666
DataQualityEvaluationRunAdditionalRunOptions 3667
DataQualityRuleRecommendationRunDescription 3667
DataQualityRuleRecommendationRunFilter 3668
DataQualityResult 3668
DataQualityAnalyzerResult 3670
DataQualityObservation 3671
MetricBasedObservation 3671
DataQualityMetricValues 3672
DataQualityRuleResult 3672
DataQualityResultDescription 3673
DataQualityResultFilterCriteria 3674
DataQualityRulesetFilterCriteria 3675
DataQualityAggregatedMetrics 3675
StatisticAnnotation 3676
TimestampedInclusionAnnotation 3677
AnnotationError 3677
DatapointInclusionAnnotation 3677
StatisticSummaryList 3678
StatisticSummary 3678
RunIdentifier 3679
StatisticModelResult 3680
DataQualityGlueTable 3680
— operaciones — 3681
StartDataQualityRulesetEvaluationRun (start_data_quality_ruleset_evaluation_run) 3683
CancelDataQualityRulesetEvaluationRun (cancel_data_quality_ruleset_evaluation_run) 3684
GetDataQualityRulesetEvaluationRun (get_data_quality_ruleset_evaluation_run) 3685
ListDataQualityRulesetEvaluationRuns (list_data_quality_ruleset_evaluation_runs) 3687
StartDataQualityRuleRecommendationRun (start_data_quality_rule_recommendation_run) 3688
CancelDataQualityRuleRecommendationRun
(cancel_data_quality_rule_recommendation_run) 3690

GetDataQualityRuleRecommendationRun (get_data_quality_rule_recommendation_run) .. 3690
ListDataQualityRuleRecommendationRuns (list_data_quality_rule_recommendation_runs) 3692
GetDataQualityResult (get_data_quality_result) 3693
BatchGetDataQualityResult (batch_get_data_quality_result) 3695
ListDataQualityResults (list_data_quality_results) 3696
CreateDataQualityRuleset (create_data_quality_ruleset) 3697
DeleteDataQualityRuleset (delete_data_quality_ruleset) 3699
GetDataQualityRuleset (get_data_quality_ruleset) 3699
ListDataQualityRulesets (list_data_quality_rulesets) 3701
UpdateDataQualityRuleset (update_data_quality_ruleset) 3702
ListDataQualityStatistics (list_data_quality_statistics) 3703
TimestampFilter 3704
CreateDataQualityRulesetRequest 3704
GetDataQualityRulesetResponse 3705
GetDataQualityResultResponse 3707
StartDataQualityRuleRecommendationRunRequest 3708
GetDataQualityRuleRecommendationRunResponse 3709
BatchPutDataQualityStatisticAnnotation (batch_put_data_quality_statistic_annotation) 3711
GetDataQualityModel (get_data_quality_model) 3712
GetDataQualityModelResult (get_data_quality_model_result) 3713
ListDataQualityStatisticAnnotations (list_data_quality_statistic_annotations) 3714
PutDataQualityProfileAnnotation (put_data_quality_profile_annotation) 3715
Información confidencial 3715
— data types — 3715
CustomEntityType 3716
— operaciones — 3716
CreateCustomEntityType (create_custom_entity_type) 3716
DeleteCustomEntityType (delete_custom_entity_type) 3718
GetCustomEntityType (get_custom_entity_type) 3719
BatchGetCustomEntityTypes (batch_get_custom_entity_types) 3720
ListCustomEntityTypes (list_custom_entity_types) 3720
API de etiquetado 3721
— tipos de datos — 3721
Tag 3721
— operaciones — 3722
TagResource (tag_resource) 3722

UntagResource (untag_resource) 3723
GetTags (get_tags) 3724
Tipos de datos comunes 3724
Tag 3725
DecimalNumber 3725
ErrorDetail 3725
PropertyPredicate 3726
ResourceUri 3726
ColumnStatistics 3727
ColumnaStatisticsError 3727
ColumnError 3728
ColumnStatisticsData 3728
BooleanColumnStatisticsData 3729
DateColumnStatisticsData 3729
DecimalColumnStatisticsData 3730
DoubleColumnStatisticsData 3730
LongColumnStatisticsData 3731
StringColumnStatisticsData 3731
BinaryColumnStatisticsData 3732
Patrones de cadena 3732
Excepciones 3735
AccessDeniedException 3735
AlreadyExistsException 3735
ConcurrentModificationException 3735
ConcurrentRunsExceededException 3736
CrawlerNotRunningException 3736
CrawlerRunningException 3736
CrawlerStoppingException 3736
EntityNotFoundException 3737
FederationSourceException 3737
FederationSourceRetryableException 3737
GlueEncryptionException 3738
IdempotentParameterMismatchException 3738
IllegalWorkflowStateException 3738
InternalServiceException 3738
InvalidExecutionEngineException 3739

InvalidInputException 3739
InvalidStateException 3739
InvalidTaskStatusTransitionException 3740
JobDefinitionErrorException 3740
JobRunInTerminalStateException 3740
JobRunInvalidStateTransitionException 3740
JobRunNotInTerminalStateException 3741
LateRunnerException 3741
NoScheduleException 3741
OperationTimeoutException 3742
ResourceNotReadyException 3742
ResourceNumberLimitExceededException 3742
SchedulerNotRunningException 3742
SchedulerRunningException 3743
SchedulerTransitioningException 3743
UnrecognizedRunnerException 3743
ValidationException 3743
VersionMismatchException 3744
Ejemplos de código de la API de AWS Glue 3745
Conceptos básicos 3755
Introducción a AWS Glue 3756
Conceptos básicos 3766
Acciones 3904
Seguridad 4051
Protección de los datos 4052
Cifrado de datos en reposo 4052
Cifrado de datos en tránsito 4071
Conformidad con FIPS 4071
Administración de claves 4071
Dependencia de AWS Glue en otros servicios de AWS 4072
Puntos de conexión de desarrollo 4072
Identity and Access Management 4073
Público 4074
Autenticación con identidades 4075
Administración de acceso mediante políticas 4076
Funcionamiento de AWS Glue con IAM 4078

Configuración de permisos de IAM para AWS Glue 4085
Ejemplos de políticas de control de acceso de AWS Glue 4120
Concesión de políticas administradas de AWS 4147
Otorgamiento de políticas con un alcance dinámico 4157
Especificación de ARN del recurso de AWS Glue 4158
Concesión de acceso entre cuentas 4168
Solución de problemas 4176
Modelos de control de acceso de AWS Lake Formation 4178
Uso de AWS Glue con AWS Lake Formation para acceso completo a la tabla 4178
Lake Formation para FGAC 4191
Uso de Concesiones de acceso a Amazon S3 con AWS Glue 4204
Cómo funciona AWS Glue con Concesiones de acceso a S3 4204
Consideraciones sobre Concesiones de acceso a S3 con AWS Glue 4205
Configuración de Concesiones de acceso a S3 con AWS Glue 4206
Propagación de identidades de confianza 4208
Descripción general 4208
Características y ventajas 4209
Casos de uso 4209
Funcionamiento 4210
Integraciones 4211
Cómo empezar con la propagación de identidades de confianza en AWS Glue ETL 4212
Consideraciones y limitaciones para la integración de AWS Glue ETL Trusted Identity Propagation 4218
Sesiones de usuario en segundo plano 4219
Registro y monitoreo 4224
Validación de conformidad 4224
Resiliencia 4225
Seguridad de la infraestructura 4225
Configuración de puntos de conexión de la VPC de tipo interfaz (AWS PrivateLink) para AWS Glue 4226
Configuración de uso compartido de Amazon VPC 4229
Solución de problemas de AWS Glue 4230
Recopilación de información sobre la solución de problemas en AWS Glue 4230
Solución de errores de Spark 4231
Error: Resource unavailable (Recurso no disponible) 4232

Error: Could Not Find S3 Endpoint or NAT Gateway for subnetId in VPC (No se encontró el punto de conexión S3 o puerta de enlace NAT para subnetId en la VPC) 4233
Error: Inbound Rule in Security Group Required (La regla de entrada del grupo de seguridad es obligatoria) 4233
Error: Outbound Rule in Security Group Required (La regla de salida del grupo de seguridad es obligatoria) 4233
Error de trabajo porque el rol transferido debería tener premisos para asumir el rol para el servicio AWS Glue 4234
Error: DescribeVpcEndpoints action is unauthorized. unable to validate VPC ID vpc-id (La acción DescribeVPCEndpoints no está autorizada. No se puede validar el ID de VPC vpc-id) 4234
Error: DescribeRouteTables action is unauthorized. unable to validate subnet id: Subnet-id in VPC id: vpc-id (La acción DescribeRouteTables no está autorizada. No se puede validar el ID de subred: Subnet-id en el ID de VPC vpc-id) 4234
Error: Failed to call ec2:DescribeSubnets (Error al llamar a ec2:DescribeSubnets) 4234
Error: Failed to call ec2:DescribeSecurityGroups (Error al llamar a ec2:DescribeSecurityGroups) 4235
Error: Could Not Find Subnet for AZ (No se pudo encontrar la subred de AZ) 4235
Error: Job run exception when writing to a JDBC target (Excepción de ejecución de flujo de trabajo al escribir en un destino JDBC) 4235
Error: Amazon S3: The operation is not valid for the object's storage class 4236
Error: Amazon S3 timeout (Tiempo de espera de Amazon S3) 4236
Error: Amazon S3 access denied (Acceso denegado a Amazon S3) 4236
Error: Amazon S3 access key ID does not exist (El ID de clave de acceso de Amazon S3 no existe) 4237
Se produce un error en la ejecución de trabajo al obtener acceso a Amazon S3 con un URI de `s3a://` 4237
Error: Amazon S3 service token expired (Token de servicio de Amazon S3 caducado) 4239
Error: No private DNS for network interface found (No se encontró un DNS privado para la interfaz de red) 4239
Error: Development endpoint provisioning failed (Error en el aprovisionamiento del punto de conexión de desarrollo) 4240
Error: Notebook Server CREATE_FAILED (CREATE_FAILED el servidor del bloc de notas) 4240
Error: Local notebook fails to start (El bloc de notas local no se inicia) 4241
Error: Running crawler failed (Error de ejecución del rastreador) 4241

Error: Partitions were not updated (Las particiones no se han actualizado) 4241
Error: no se pudo actualizar el marcador de trabajo debido a que la versión no coincide ... 4242
Error: A job is reprocessing data when job bookmarks are enabled (Un trabajo está reprocesando datos cuando los marcadores de trabajo están habilitados) 4242
Error: comportamiento de conmutación por error entre VPC en AWS Glue 4243
Errores del rastreador cuando usa permisos de Lake Formation 4244
Error: la ubicación de S3: s3://examplepath no está registrada 4244
Error: el usuario o rol no está autorizado a realizar: lakeformation:GetDataAccess en el recurso 4245
Error: permisos insuficientes para la formación de lagos en (Nombre de la base de datos: exampleDatabase, Nombre de la tabla: exampleTable) 4245
Error: permisos de Lake Formation insuficientes en s3://examplepath 4245
Preguntas frecuentes sobre la configuración del rastreador con las credenciales de Lake Formation 4246
Solución de errores de Ray 4247
Inspección de los registros de trabajos de Ray 4247
Solución de errores de trabajos de Ray 4248
Excepciones de machine learning en AWS Glue 4250
CancelMLTaskRunActivity 4250
CreateMLTaskRunActivity 4250
DeleteMLTransformActivity 4252
GetMLTaskRunActivity 4252
GetMLTaskRunsActivity 4252
GetMLTransformActivity 4253
GetMLTransformsActivity 4253
GetSaveLocationForTransformArtifactActivity 4253
GetTaskRunArtifactActivity 4254
PublishMLTransformModelActivity 4254
PullLatestMLTransformModelActivity 4255
PutJobMetadataForMLTransformActivity 4255
StartExportLabelsTaskRunActivity 4256
StartImportLabelsTaskRunActivity 4256
StartMLEvaluationTaskRunActivity 4257
StartMLLabelingSetGenerationTaskRunActivity 4258
UpdateMLTransformActivity 4259
Cuotas de AWS Glue 4260

Mejora en el rendimiento de AWS Glue 4261
Ajuste de las estrategias para el tipo de trabajo 4261
Mejora del rendimiento de Spark 4261
Optimización de las lecturas con inserción 4262
Predica cómo insertar los archivos almacenados en Amazon S3 4262
Insertar al trabajar con fuentes JDBC 4264
Notas y limitaciones de cómo insertar en Glue AWS 4266
Utilizar Auto Scaling para AWS Glue 4267
Requisitos 4268
Habilitar Auto Scaling en AWS Glue Studio 1932
Habilitación de Auto Scaling con AWS CLI o SDK 1933
Habilitación del escalado automático con sesiones interactivas 4270
Sugerencias y consideraciones 4270
Monitorear Auto Scaling con las métricas de Amazon CloudWatch. 4271
Supervisión del escalado automático con Registros de Amazon CloudWatch 4272
Monitorear Auto Scaling con la IU de Spark 4273
Supervisión del uso de DPU en ejecución de trabajos de Auto Scaling 4274
Limitaciones 4274
Partición de cargas de trabajo con ejecución limitada 4274
Habilitar la partición de carga de trabajo 4275
Configuración de un desencadenador de AWS Glue para ejecutar el trabajo en forma automática 4276
Problemas conocidos 4278
Prevención del acceso a datos entre trabajos 4278
Historial de documentación 4281
Actualizaciones anteriores 4358
AWSGlosario de 4359

¿Qué es AWS Glue?

AWS Glue es un servicio de integración de datos sin servidor que facilita a los usuarios de análisis descubrir, preparar, migrar e integrar datos de varios orígenes. Puede utilizarlo para análisis, machine learning y desarrollo de aplicaciones. También incluye herramientas adicionales de productividad y operaciones de datos para la creación, la ejecución de trabajos y la implementación de flujos de trabajo empresariales.

Con AWS Glue, puede descubrir y conectarse a más de 70 orígenes de datos diversos y administrar sus datos en un catálogo de datos centralizado. Puede crear, ejecutar y supervisar visualmente canalizaciones de extracción, transformación y carga (ETL) para cargar datos en los lagos de datos. Además, puede buscar y consultar datos catalogados de forma inmediata mediante Amazon Athena, Amazon EMR y Amazon Redshift Spectrum.

AWS Glue combina las principales capacidades de integración de datos en un solo servicio. Estas capacidades incluyen el descubrimiento de datos, el ETL moderno, la limpieza, la transformación y la catalogación centralizada. Además, es un servicio sin servidor, lo que significa que no hay infraestructura para administrar. Con compatibilidad flexible para todas las cargas de trabajo como ETL, ELT y streaming en un solo servicio, AWS Glue admite usuarios en varias cargas de trabajo y varios tipos de usuarios.

Además, AWS Glue facilita la integración de datos en toda la arquitectura. Se integra con los servicios de análisis de AWS y los lagos de datos de Amazon S3. AWS Glue tiene interfaces de integración y herramientas de creación de trabajo que son fáciles de utilizar para todos los usuarios, desde desarrolladores hasta usuarios empresariales, con soluciones personalizadas para diversos conjuntos de habilidades técnicas.

Gracias a la capacidad de escalar bajo demanda, AWS Glue ayuda a centrarse en actividades de gran valor que maximizan el valor de los datos. Escala para cualquier tamaño de datos y admite todos los tipos de datos y las variaciones de esquema. Para aumentar la agilidad y optimizar los costos, AWS Glue brinda alta disponibilidad integrada y facturación de pago por uso.

Para obtener información sobre precios, consulte Precios de AWS Glue.

AWS Glue Studio

AWS Glue Studio es una interfaz gráfica que facilita la creación, la ejecución y la supervisión de trabajos de integración de datos en AWS Glue. Puede componer visualmente flujos de trabajo de

transformación de datos y ejecutarlos sin problemas en el motor de ETL sin servidor basado en Apache Spark en AWS Glue.

Con AWS Glue Studio, puede crear y administrar trabajos que recopilan, transforman y limpian datos. También puede utilizar AWS Glue Studio para solucionar problemas y editar scripts de trabajo.

Temas

- Características de AWS Glue
- Conozca las innovaciones en AWS Glue
- Introducción a AWS Glue
- Acceso a AWS Glue
- Servicios relacionados

Características de AWS Glue

Las características de AWS Glue se dividen en tres categorías principales:

- Descubrimiento y organización de datos
- Transformación, preparación y limpieza de datos para análisis
- Creación y supervisión de canalizaciones de datos

Descubrimiento y organización de datos

- Unificación y búsqueda en varios almacenes de datos: almacene, indexe y busque en varios receptores y orígenes de datos mediante la catalogación de todos los datos en AWS.
- Descubrimiento automático de datos: utilice rastreadores de AWS Glue para inferir de forma automática la información del esquema e integrarla en AWS Glue Data Catalog.
- Administración de esquemas y permisos: valide y controle el acceso a las bases de datos y las tablas.
- Conexión a una amplia variedad de orígenes de datos: acceda a varios orígenes de datos, tanto en las instalaciones como en AWS, mediante las conexiones de AWS Glue para crear su lago de datos.

Transformación, preparación y limpieza de datos para análisis

- Transformaciones visuales de datos con una interfaz de lienzo de trabajo: defina el proceso de ETL en el editor de trabajos visual, y genere de forma automática el código para extraer, transformar y cargar los datos.
- Creación de canalizaciones de ETL complejas con programación de trabajo sencilla: invoque trabajos de AWS Glue según un horario, bajo demanda o en función de un evento.
- Limpieza y transformación de datos de streaming en tránsito: habilite el consumo continuo de datos, y límpielos y transfórmelos en tránsito. Esto hace que estén disponible para analizar en cuestión de segundos en el almacén de datos de destino.
- Deduplicación y limpieza de datos con machine learning integrado: limpie y prepare los datos para analizar sin convertirse en un experto en machine learning mediante el uso de la característica `FindMatches`. Esta característica deduplica y busca registros que son coincidencias imperfectas entre sí.
- Cuadernos de trabajo integrados: los cuadernos de trabajo de AWS Glue brindan cuadernos sin servidor con una configuración mínima de AWS Glue para que pueda comenzar a trabajar rápidamente.
- Edición, depuración y prueba del código de ETL: con las sesiones interactivas de AWS Glue, puede explorar y preparar datos de forma interactiva. Puede explorar, experimentar y procesar datos de forma interactiva con el IDE o el cuaderno que elija.
- Definición, detección y corrección de datos confidenciales: la detección de datos confidenciales de AWS Glue permite definir, identificar y procesar datos confidenciales en la canalización de datos y en el lago de datos.

Creación y supervisión de canalizaciones de datos

- Escalado automático según la carga de trabajo: escale y reduzca verticalmente y de forma dinámica los recursos en función de la carga de trabajo. Esto asigna trabajo a los trabajadores solo cuando es necesario.
- Automatización de trabajos con desencadenadores basados en eventos: inicie rastreadores o trabajos de AWS Glue con desencadenadores basados en eventos, y diseñe una cadena de trabajos y rastreadores dependientes.
- Ejecute y monitoree los trabajos: ejecute los trabajos AWS Glue con el motor que elija, Spark o Ray. Monitoreelos con herramientas de monitoreo automatizadas, información sobre la ejecución de los trabajos AWS Glue y AWS CloudTrail. Mejore el monitoreo de los trabajos respaldados por Spark con la interfaz de usuario de Apache Spark.

- Definición de flujos de trabajo para ETL y actividades de integración: defina los flujos de trabajo para ETL y las actividades de integración para varios rastreadores, trabajos y desencadenadores.

Conozca las innovaciones en AWS Glue

Conozca las últimas innovaciones AWS Glue y descubra cómo los clientes utilizan AWS Glue para habilitar la preparación de datos en forma de autoservicio en toda su organización.

Descubra cómo los clientes escalan AWS Glue más allá de la configuración tradicional y cómo configuran AWS Glue para el monitoreo y el rendimiento del trabajo.

Introducción a AWS Glue

Le recomendamos que lea las siguientes secciones:

- Información general del uso de AWS Glue
- Conceptos de AWS Glue
- Configuración de permisos de IAM para AWS Glue
- Introducción a AWS Glue Data Catalog
- Creación de trabajos en AWS Glue
- Introducción a las sesiones interactivas de AWS Glue
- Orquestación en AWS Glue

Acceso a AWS Glue

Puede crear, ver y administrar los trabajos de AWS Glue con cualquiera de las siguientes interfaces:

- Consola de AWS Glue: brinda una interfaz web para que pueda crear, ver y administrar los trabajos de AWS Glue. Para obtener acceso a la consola, consulte AWS Glue.
- AWS Glue Studio: brinda una interfaz gráfica para que pueda crear y editar visualmente los trabajos de AWS Glue. Para obtener más información, consulte Creación de trabajos de ETL visual.
- Sección AWS Glue de la referencia de la AWS CLI: brinda comandos de la AWS CLI que se pueden utilizar con AWS Glue. Para obtener más información, consulte Referencia de la AWS CLI para AWS Glue.

- API de AWS Glue: brinda una referencia de API completa para los desarrolladores. Para obtener más información, consulte API de AWS Glue.

Servicios relacionados

Los usuarios de AWS Glue también utilizan lo siguiente:

- AWS Lake Formation : un servicio que es una capa de autorización que brinda un control de acceso minucioso a los recursos en AWS Glue Data Catalog.
- AWS Glue DataBrew: una herramienta de preparación de datos visuales que se puede utilizar para limpiar y normalizar los datos sin tener que escribir ningún código.

AWS Glue: Cómo funciona

AWS Glue utiliza otros servicios de AWS para organizar los trabajos de ETL (extracción, transformación y carga) con el fin de crear almacenamientos de datos y lagos de datos, y generar flujos de salida. AWS Glue invoca operaciones de la API para transformar los datos, crear registros en tiempo de ejecución, almacenar su lógica de trabajo y crear notificaciones para monitorear las ejecuciones de trabajo. La consola de AWS Glue conecta estos servicios en una aplicación administrada, para que pueda concentrarse en la creación y monitorización de los trabajos de ETL. La consola desarrolla operaciones administrativas y de desarrollo de trabajos en su nombre. Puede proporcionar credenciales y otras propiedades a AWS Glue para obtener acceso a los orígenes de datos y escribir en los destinos de datos.

AWS Glue se encarga del aprovisionamiento y la administración de los recursos necesarios para ejecutar la carga de flujo de trabajo. No es necesario crear la infraestructura para una herramienta de ETL porque AWS Glue lo hace de forma automática. Cuando se necesitan recursos para reducir el tiempo de arranque, AWS Glue utiliza una instancia de su grupo de instancias para ejecutar la carga de flujo de trabajo.

Con AWS Glue, los trabajos se crean mediante las definiciones de tabla en el Data Catalog. Los trabajos consisten en scripts que contienen las instrucciones que ejecutan las tareas de transformación de datos deseadas. Puede utilizar disparadores para iniciar trabajos en función de una programación o a través del resultado de un evento especificado. Puede determinar dónde van a residir los datos y qué datos de origen van a rellenar el destino. En función de sus entradas, AWS Glue transforma los datos del formato de origen al formato de destino. Como alternativa, también puede proporcionar scripts personalizados en la API o la consola de AWS Glue para procesar sus datos de acuerdo con sus requisitos específicos.

Orígenes y destinos de datos

AWS Glue permite leer y escribir datos de varios sistemas y bases de datos, entre los que se incluyen:

- Amazon S3
- Amazon DynamoDB
- Amazon Redshift
- Amazon Relational Database Service (Amazon RDS)
- Bases de datos accesibles a JDBC de terceros

- MongoDB y Amazon DocumentDB (compatible con MongoDB)
- Otros conectores de Marketplace y complementos de Apache Spark

Flujos de datos

AWS Glue para Spark puede transmitir datos desde los siguientes sistemas:

- Amazon Kinesis Data Streams
- Apache Kafka

AWS Glue está disponible en distintas regiones de AWS. Para obtener más información, consulte Regiones y puntos de conexión de AWS en la Referencia general de Amazon Web Services.

Temas

- Los trabajos de ETL sin servidor se ejecutan de forma aislada
- Conceptos de AWS Glue
- Componentes de AWS Glue
- AWS Glue para Spark y AWS Glue para Ray
- Conversión de esquemas semiestructurados a esquemas relacionales con AWS Glue
- Sistemas de tipos de AWS Glue

Los trabajos de ETL sin servidor se ejecutan de forma aislada

AWS Glue ejecuta los trabajos de ETL en un entorno sin servidor, con el motor elegido, Spark o Ray. AWS Glue ejecuta estos trabajos en recursos virtuales que aprovisiona y gestiona en su propia cuenta de servicio.

AWS Glue se ha diseñado para poder:

- Segregar datos de clientes.
- Proteger los datos de clientes en tránsito y en reposo.
- Obtenga acceso a los datos de clientes únicamente según se necesite para dar respuesta a las solicitudes de los clientes, mediante credenciales provisionales y con permisos reducidos o con el consentimiento del cliente para roles de IAM en su cuenta.

Durante el aprovisionamiento de un flujo de trabajo de ETL, usted proporciona los orígenes de datos de entrada y los destinos de datos de salida en la nube virtual privada (VPC). Además, debe proporcionar el rol de IAM, el ID de la VPC, el ID de la subred y el grupo de seguridad; todos ellos necesarios para obtener acceso a los orígenes y los destinos de datos. Para cada tupla (ID de cuenta de cliente, rol de IAM, ID de subred y grupo de seguridad), AWS Glue crea un nuevo entorno que está aislado, a nivel de red y administración, de todos los demás entornos de su cuenta de servicio de AWS Glue.

Usted crea y configura recursos de AWS Glue, como catálogos de datos, trabajos y rastreadores, dentro de su cuenta de AWS. A continuación, estos recursos se asocian al rol de IAM y a la configuración de red (subred y grupo de seguridad) que especifique durante el proceso de creación.

AWS Glue crea interfaces de red elástica en la subred mediante direcciones IP privadas. Los trabajos utilizan estas interfaces de red elástica para obtener acceso a los orígenes de datos y los destinos de datos. El tráfico entrante y saliente del entorno de ejecución del trabajo, así como el interno, está regido por las políticas de VPC y de red, con una única excepción: las llamadas realizadas a las bibliotecas de AWS Glue pueden utilizar un proxy para el tráfico de las operaciones de la API de AWS Glue a través de la VPC de AWS Glue. Se registran todas las llamadas al API de AWS Glue, por tanto, los propietarios de datos pueden auditar el acceso a la API mediante la habilitación de AWS CloudTrail, que entrega registros de auditoría a su cuenta.

Los entornos que administra AWS Glue y que ejecutan los trabajos de ETL están protegidos a través de las mismas prácticas de seguridad que aplican otros servicios de AWS. Para obtener información general de las prácticas y las responsabilidades de seguridad compartidas, consulte el documento técnico de Introducción a la seguridad de procesos de AWS.

Conceptos de AWS Glue

AWS Glue es un servicio de extracción, transformación, carga (ETL) completamente administrado que le permite mover datos con facilidad entre diferentes orígenes y destinos de datos. Los componentes clave son:

- Catálogo de datos: un almacén de metadatos que contiene definiciones de tablas, definiciones de trabajos y otra información de control para sus flujos de trabajo de ETL.
- Rastreadores: programas que se conectan a orígenes de datos, deducen esquemas de datos y crean definiciones de tablas de metadatos en el catálogo de datos.
- Trabajos de ETL: la lógica empresarial para extraer datos de los orígenes, transformarlos mediante scripts de Apache Spark y cargarlos en destinos.

- Desencadenadores: mecanismos para iniciar la ejecución de tareas en función de cronogramas o eventos.

El flujo de trabajo típico incluye:

1. Definir los orígenes y los destinos de datos en el catálogo de datos.
2. Utilizar los rastreadores para completar el catálogo de datos con metadatos de tablas procedentes de fuentes de datos.
3. Definir los trabajos de ETL con scripts de transformación para mover y procesar datos.
4. Ejecutar los trabajos a pedido o en función de los activadores.
5. Supervisar el desempeño laboral mediante paneles de control.

En el siguiente diagrama se muestra la arquitectura de un entorno de AWS Glue.

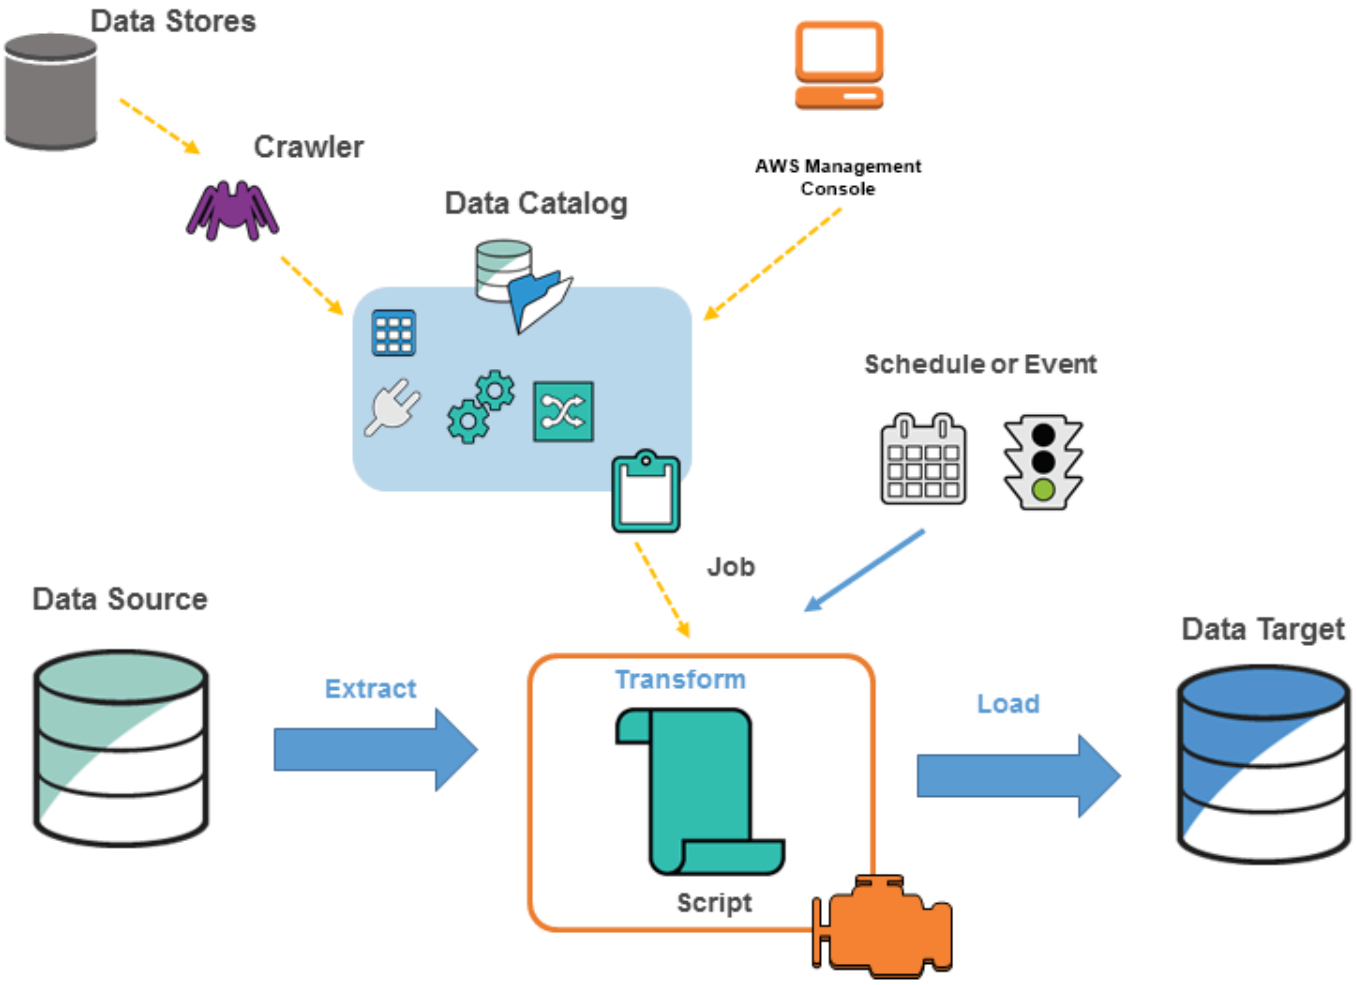

Los trabajos se definen en AWS Glue a fin de realizar el flujo de trabajo necesario para extraer, transformar y cargar datos (ETL) desde un origen de datos hasta un destino de datos. Normalmente, usted llevará a cabo las siguientes acciones:

- Para los orígenes de almacén de datos, puede definir un rastreador para rellenar su AWS Glue Data Catalog con definiciones de tabla de metadatos. Puede dirigir su rastreador a un almacén de datos y el rastreador crea definiciones de tabla en el Data Catalog. Para orígenes de streaming, se definen manualmente tablas del Data Catalog y se especifican las propiedades del flujo de datos.

  Además de las definiciones de tabla, el AWS Glue Data Catalog contiene otros metadatos necesarios para definir los trabajos de ETL. Utilizará estos metadatos al definir un flujo de trabajo para transformar sus datos.

- AWS Glue puede generar un script para transformar sus datos. O bien, puede proporcionar el script en la consola o API de AWS Glue.
- Puede ejecutar su flujo de trabajo bajo demanda o configurarlo de modo que se inicie al activarse un disparador especificado. El disparador puede corresponder a una programación basada en tiempo o a un evento.

  Al ejecutarse su flujo de trabajo, un script extrae datos de su origen de datos, transforma los datos y los carga en su destino de datos. El script se ejecuta en un entorno Apache Spark en AWS Glue.

> **Important**
>
> Las tablas y las bases de datos de AWS Glue son objetos en el AWS Glue Data Catalog. Contienen metadatos; no datos de un almacén de datos.

Los datos basados en texto, como los CSV, deben estar codificados en **`UTF-8`** para que AWS Glue los procese de forma exitosa. Para obtener más información, consulte UTF-8 en Wikipedia.

Terminología de AWS Glue

AWS Glue se basa en la interacción de varios componentes para crear y gestionar su flujo de trabajo de extracción, transformación y carga (ETL).

AWS Glue Data Catalog

El almacén de metadatos persistentes en AWS Glue. Contiene definiciones de tablas, definiciones de trabajos y otra información de control para administrar su entorno de AWS Glue. Cada cuenta de AWS tiene un AWS Glue Data Catalog por región.

Clasificador

Determina el esquema de sus datos. AWS Glue proporciona clasificadores para tipos de archivos comunes, como CSV, JSON, AVRO, XML y otros. También proporciona clasificadores para sistemas de administración de bases de datos relacionales comunes mediante una conexión de JDBC. Puede escribir su propio clasificador mediante un patrón de grok o especificando una etiqueta de fila en un documento XML.

Connection

Un objeto del Data Catalog que contiene las propiedades necesarias para conectarse a un almacén de datos determinado.

Rastreador

Un programa que se conecta a un almacén de datos (origen o destino), avanza por una lista de prioridades de clasificadores para determinar el esquema de sus datos y, a continuación, crea tablas de metadatos en el AWS Glue Data Catalog.

Base de datos

Un conjunto de definiciones de tabla del Data Catalog asociadas, organizadas en un grupo lógico.

Almacén de datos, origen de datos, destino de datos

Un almacén de datos es un repositorio para almacenar los datos de forma persistente. Entre los ejemplos se incluyen buckets de Amazon S3 y bases de datos relacionales. Un origen de datos es un almacén de datos que se utiliza como entrada para un proceso o una transformación. Un destino de datos es un almacén de datos en el que escribe un proceso o una transformación.

Punto de enlace de desarrollo

Un entorno que puede utilizar para desarrollar y probar los scripts ETL de AWS Glue.

Marco dinámico

Tabla distribuida que admite datos anidados como estructuras y matrices. Cada registro se autodescribe y está diseñado para flexibilidad de esquemas con datos semiestructurados. Cada registro contiene tanto los datos como el esquema que describe esos datos. Puede usar marcos dinámicos y Apache Spark DataFrames en sus scripts de ETL, y realizar conversiones entre ellos. Las tramas dinámicas proporcionan un conjunto de transformaciones avanzadas para la limpieza de datos y ETL.

Trabajo

La lógica empresarial que es necesaria para realizar el flujo de trabajo de ETL. Se compone de un script de transformación, orígenes de datos y destinos de datos. Las ejecuciones de trabajos pueden iniciarse a partir de disparadores programados o activados por eventos.

Panel de rendimiento del trabajo

AWS Glue proporciona un panel de ejecución integral para sus trabajos de ETL. El panel muestra información sobre las ejecuciones de trabajos desde un periodo específico.

Interfaz de cuaderno

Una experiencia de cuaderno mejorada con una configuración con un solo clic para facilitar la creación de trabajos y la exploración de datos. El bloc de notas y las conexiones se configuran automáticamente. Puede utilizar la interfaz de cuaderno basada en Jupyter Notebook para desarrollar, depurar e implementar scripts y flujos de trabajo mediante infraestructura de ETL de Apache Spark sin servidor de AWS Glue. También puede realizar consultas ad hoc, análisis de datos y visualización (por ejemplo, tablas y gráficos) en el entorno de cuaderno.

Script

Código que extrae datos de orígenes, los transforma y los carga en destinos. AWS Glue genera scripts PySpark o Scala.

Tabla

La definición de metadatos que representa sus datos. Independientemente de si sus datos están en un archivo de Amazon Simple Storage Service (Amazon S3), una tabla de Amazon Relational Database Service (Amazon RDS) u otro conjunto de datos, la tabla define el esquema de sus datos. Una tabla de AWS Glue Data Catalog está formada por los nombres de las columnas, las definiciones de tipos de datos, la información de partición y otros metadatos acerca de un conjunto de datos base. El esquema de sus datos viene representado en su definición de tabla de AWS Glue. Los datos reales permanecen en su almacén de datos original, ya sea en un archivo o en una tabla de base de datos relacional. AWS Glue cataloga sus archivos y tablas de bases de datos relacionales en el AWS Glue Data Catalog. Estos se usan como orígenes y destinos al crear un flujo de trabajo de ETL.

Transformar

La lógica de código que se usa para manipular sus datos en un formato diferente.

Desencadenador

Inicia un flujo de trabajo de ETL. Los disparadores se pueden definir según un momento programado o un evento.

Editor visual de trabajos

El editor de trabajos visuales es una interfaz gráfica que facilita la creación, ejecución y supervisión de los trabajos de extracción, transformación y carga (ETL) en AWS Glue. Puede componer visualmente flujos de trabajo de transformación de datos y ejecutarlos sin problemas en el motor de ETL sin servidor basado en Apache Spark de AWS Glue e inspeccionar el esquema y los datos resultantes en cada paso del trabajo.

Entorno de trabajo

Con AWS Glue, solo paga por el tiempo que tarda en ejecutarse su trabajo de ETL. No hay que administrar recursos ni hay costos iniciales. No se le cobra por el tiempo de inicio o cierre. Se le cobra una tarifa por hora basada en el número de unidades de procesamiento de datos (o DPU) utilizadas para ejecutar el trabajo de ETL. Una sola unidad de procesamiento de datos (DPU) también se denomina trabajador. AWS Glue cuenta con varios tipos de trabajadores para permitirle seleccionar la configuración que cumpla con sus requisitos de latencia y costo del trabajo. Los trabajadores vienen en configuraciones estándar, G.1X, G.2X, G.4X, G.8X, G.12X, G.16X, G.025X y en configuraciones optimizadas para la memoria R.1X, R.2X, R.4X, R.8X.

Componentes de AWS Glue

AWS Glue proporciona una consola y operaciones de API para configurar y administrar su carga de flujo de trabajo de extracción, transformación y carga (ETL). Puede usar las operaciones de API a través de varios SDK específicos de lenguaje y la AWS Command Line Interface (AWS CLI). Para obtener información sobre el uso de AWS CLI, consulte Referencias de comandos de AWS CLI.

AWS Glue usa el AWS Glue Data Catalog para almacenar metadatos acerca de orígenes de datos, transformaciones y destinos. El Data Catalog es un reemplazo instantáneo para el Apache Hive Metastore. AWS Glue Jobs system proporciona una infraestructura administrada para definir, programar y ejecutar operaciones de ETL en sus datos. Para obtener más información sobre la API de AWS Glue, consulte API de AWS Glue.

Consola de AWS Glue

Use la consola de AWS Glue para definir y orquestar su flujo de flujo de trabajo de ETL. La consola llama a varias operaciones API en el AWS Glue Data Catalog y AWS Glue Jobs system para realizar las siguientes tareas:

- Definir objetos de AWS Glue como trabajos, tablas, rastreadores y conexiones.

- Programar cuándo se ejecutan los rastreadores.
- Definir eventos o programaciones para los disparadores de trabajos.
- Buscar y filtrar listas de objetos de AWS Glue.
- Editar scripts de transformación.

AWS Glue Data Catalog

El AWS Glue Data Catalog es su almacén de metadatos técnicos persistente en la nube de AWS.

Cada cuenta de AWS tiene un AWS Glue Data Catalog por región de AWS. Cada catálogo de datos es una colección de tablas altamente escalable organizadas en bases de datos. Una tabla es la representación de metadatos de una colección de datos estructurados o semiestructurados almacenados en orígenes como Amazon RDS, Apache Hadoop Distributed File System, Amazon OpenSearch Service y otros. AWS Glue Data Catalog proporciona un repositorio uniforme donde sistemas dispares pueden almacenar y encontrar metadatos para hacer un seguimiento de los datos en silos de datos. A continuación, puede utilizar los metadatos para consultar y transformar esos datos de forma coherente en una amplia variedad de aplicaciones.

Utilice el catálogo de datos junto con políticas de AWS Identity and Access Management y Lake Formation para controlar el acceso a las tablas y bases de datos. Al hacer esto, permite a los diversos grupos de su empresa publicar datos de forma segura en toda la organización, al mismo tiempo que se protege la información confidencial de forma altamente granular.

El catálogo de datos, junto con CloudTrail y Lake Formation, también proporciona capacidades de auditoría y gobernanza completas, con seguimiento de cambios de esquema y controles de acceso de datos. Esto ayuda a garantizar que los datos no se modificaron incorrectamente o no se compartieron sin querer.

Para obtener información sobre cómo proteger y auditar el AWS Glue Data Catalog, consulte:

- AWS Lake Formation: para obtener más información, consulte ¿Qué es AWS Lake Formation? en la Guía para desarrolladores de AWS Lake Formation.
- CloudTrail: para obtener más información, consulte What Is CloudTrail? (¿Qué es CloudTrail?) en la Guía del usuario de AWS CloudTrail.

Los siguientes son otros servicios y proyectos de código abierto de AWS que utilizan el AWS Glue Data Catalog:

- Amazon Athena: para obtener más información, consulte Descripción de las tablas, bases de datos y el catálogo de datos en la Guía del usuario de Amazon Athena.
- Amazon Redshift Spectrum: para obtener más información, consulte Using Amazon Redshift Spectrum to Query External Data (Uso de Amazon Redshift Spectrum para consultar datos externos) en la Guía para desarrolladores de bases de datos Amazon Redshift.
- Amazon EMR: para obtener más información, consulte Resource-Based Policies for Amazon EMR Access to AWS Glue Data Catalog (Uso de políticas basadas en recursos para acceso de Amazon EMR al) en la Guía de administración de Amazon EMR.
- Cliente de AWS Glue Data Catalog para el almacén de metadatos de Apache Hive: para obtener más información sobre este proyecto de GitHub, consulte Cliente de AWS Glue Data Catalog para el almacén de metadatos de Apache Hive.

Rastreadores y clasificadores de AWS Glue

AWS Glue también le permite configurar rastreadores que pueden analizar datos en toda clase de repositorios, clasificarlos, extraer información de esquema de ellos y almacenar los metadatos de forma automática en el AWS Glue Data Catalog. El AWS Glue Data Catalog se puede usar para guiar las operaciones de ETL.

Para obtener información acerca de cómo configurar rastreadores y clasificadores, consulte Uso de rastreadores para completar el Catálogo de datos . Para obtener información acerca de cómo programar rastreadores y clasificadores mediante la API de AWS Glue, consulte API de rastreadores y clasificadores.

Operaciones de ETL de AWS Glue

Al usar los metadatos en el Data Catalog, AWS Glue puede generar automáticamente scripts de Scala o PySpark (la API de Python para Apache Spark) con extensiones de AWS Glue que puede usar y modificar para realizar diversas operaciones de ETL. Por ejemplo, puede extraer, limpiar y transformar datos sin formato y, a continuación, almacenar el resultado en un repositorio distinto, donde se puede consultar y analizar. Dicho script puede convertir un archivo CSV en un formato relacional y guardarlo en Amazon Redshift.

Para obtener más información acerca de cómo usar capacidades de ETL de AWS Glue, consulte Programación de scripts de Spark.

ETL de streaming en AWS Glue

AWS Glue le permite realizar operaciones de ETL en datos de streaming mediante trabajos en ejecución continua. ETL de streaming de AWS Glue se basa en el motor Apache Spark Structured Streaming, y puede capturar flujos de Amazon Kinesis Data Streams, Apache Kafka y Amazon Managed Streaming for Apache Kafka (Amazon MSK). ETL de streaming puede limpiar y transformar los datos de streaming y cargarlos en almacenes de datos de Amazon S3 o JDBC. Utilice ETL de streaming en AWS Glue para procesar datos de eventos como transmisiones de IoT, transmisiones de clics y registros de red.

Si conoce el esquema del origen de datos de streaming, puede especificarlo en una tabla del Data Catalog. De lo contrario, puede habilitar la detección de esquemas en el trabajo de ETL de streaming. El trabajo determinará en forma automática el esquema a partir de los datos entrantes.

El script de ETL puede usar las transformaciones incorporadas de AWS Glue y las transformaciones nativas de Apache Spark Structured Streaming. Para obtener más información, consulte Operaciones en DataFrames/conjuntos de datos de streaming en el sitio web de Apache Spark.

Para obtener más información, consulte the section called “Trabajos ETL de streaming”.

El sistema de trabajos de AWS Glue

AWS Glue Jobs system proporciona infraestructura administrada para orquestar su flujo de flujo de trabajo de ETL. Puede crear trabajos en AWS Glue que automaticen los scripts que usa para extraer, transformar y transferir datos a distintas ubicaciones. Los trabajos se pueden programar y encadenar, o bien eventos como la llegada de nuevos datos pueden activarlos.

Para obtener más información acerca del uso de AWS Glue Jobs system, consulte Supervisión de AWS Glue. Para obtener información acerca de la programación del uso de la API de AWS Glue Jobs system, consulte API de trabajos.

Componentes de ETL visuales

AWS Glue permite crear trabajos de ETL a través de un lienzo visual que pueda manipular.

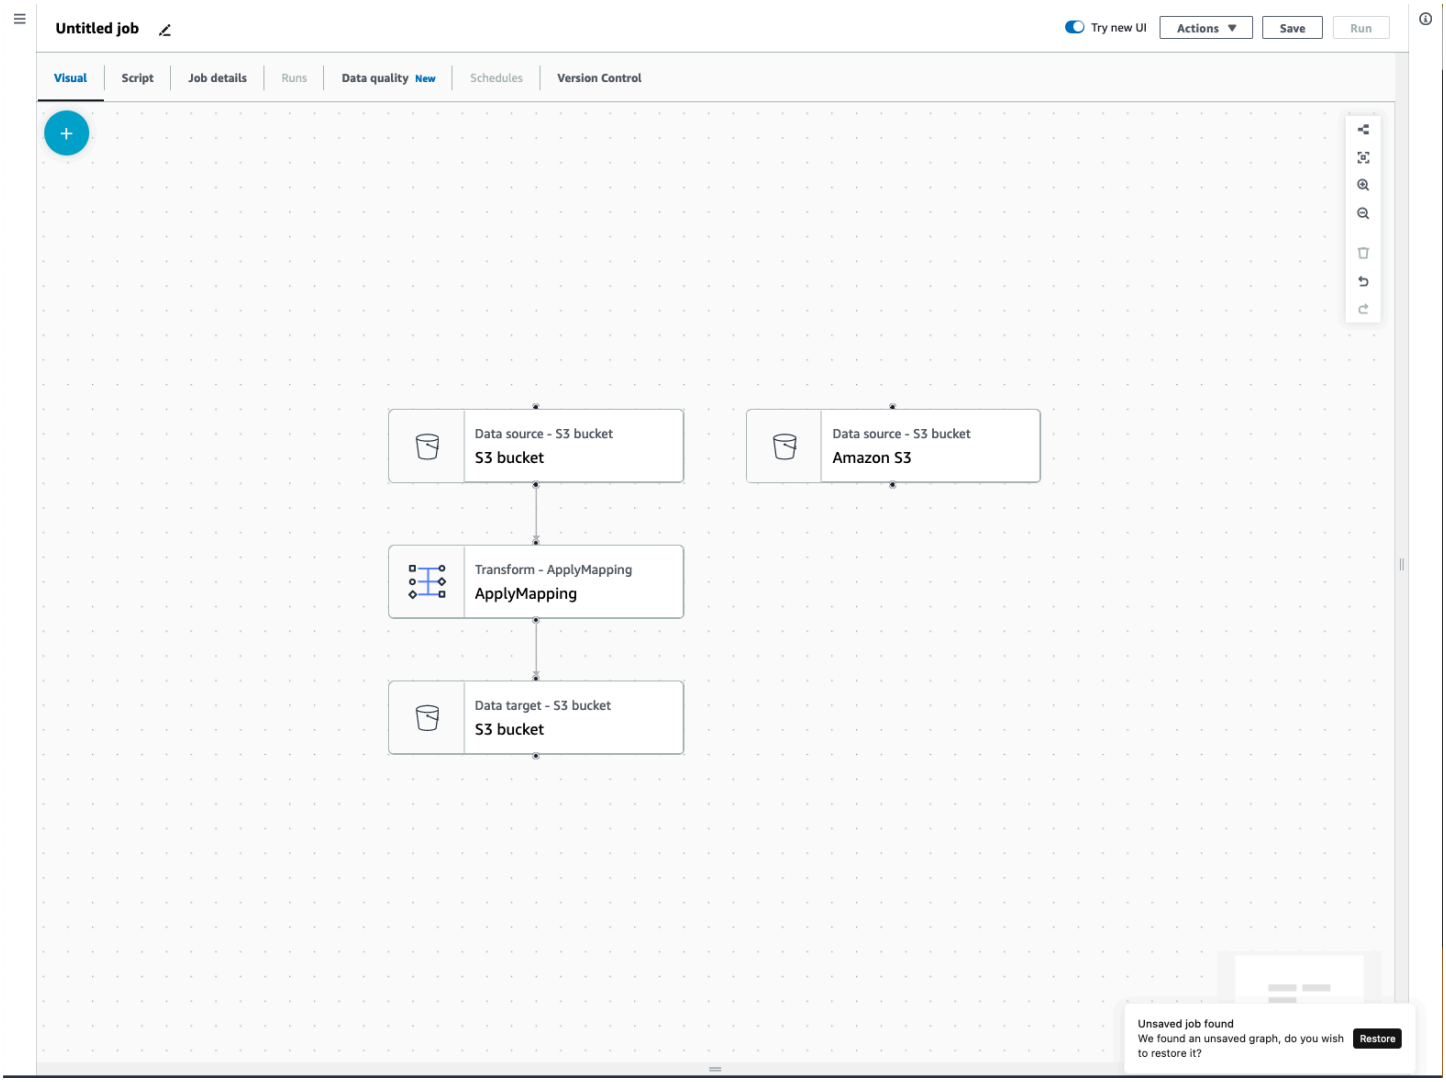

Menú de trabajos de ETL

Las opciones del menú en la parte superior del lienzo permiten acceder a las distintas vistas y detalles de configuración del trabajo.

- Visual: el lienzo del editor de trabajos de Visual. Aquí es donde puede agregar nodos para crear un trabajo.
- Script: la representación en script de su trabajo de ETL. AWS Glue genera el script en función de la representación visual de su trabajo. También puede editar el guion o descargarlo.

> **Note**
>
> Si decide editar el guion, la experiencia de creación de trabajos se convierte permanentemente en un modo de solo guion. Después ya no podrá utilizar el editor visual

para editar el trabajo. Debe agregar todos los orígenes, transformaciones y destinos del trabajo y realizar todos los cambios que necesite con el editor visual antes de decidir editar el guion.

- Detalles del trabajo: la pestaña Detalles del trabajo permite configurar el trabajo mediante la configuración de las propiedades del trabajo. Hay propiedades básicas, como el nombre y la descripción del trabajo, el rol de IAM, el tipo de trabajo, la versión de AWS Glue, el idioma, el tipo de trabajador, el número de trabajadores, el marcador del trabajo, la ejecución flexible, el número de retiros y el tiempo de espera del trabajo. También hay propiedades avanzadas, como las conexiones, las bibliotecas, los parámetros del trabajo y las etiquetas.
- Ejecuciones: después de ejecutar el trabajo, se puede acceder a esta pestaña para ver las ejecuciones anteriores.
- Calidad de datos: calidad de datos evalúa y supervisa la calidad de sus activos de datos. Puede obtener más información sobre cómo utilizar la calidad de los datos en esta pestaña y agregar una transformación de la calidad de los datos al trabajo.
- Programas: Los trabajos que ha programado aparecen en esta pestaña. Si no hay ningún programa adjunto a este trabajo, no se puede acceder a esta pestaña.
- Control de versiones: puede usar Git con el trabajo al configurarlo en un repositorio de Git.

Paneles de ETL visuales

Cuando trabaja en el lienzo, hay varios paneles disponibles para ayudarle a configurar los nodos o a obtener una vista previa de los datos y ver el esquema de salida.

- Propiedades: el panel Propiedades aparece al elegir un nodo del lienzo.
- Vista previa de datos: el panel de vista previa de datos proporciona una vista preliminar de la salida de datos para que pueda tomar decisiones antes de ejecutar el trabajo y examinar la salida.
- Esquema de salida: la pestaña Esquema de salida permite ver y editar el esquema de los nodos de transformación.

Redimensionar los paneles

Puede cambiar el tamaño del panel de Propiedades situado en el lado derecho de la pantalla y en el panel inferior, que contiene las pestañas de Vista previa de datos y Esquema de salida al hacer clic en el borde del panel y arrastrarlo hacia la izquierda y hacia la derecha o hacia arriba y hacia abajo.

- Panel de propiedades: cambie el tamaño del panel de propiedades al hacer clic y arrastrar el borde del lienzo situado en el lado derecho de la pantalla y arrastrándolo hacia la izquierda para ampliar el ancho. De forma predeterminada, el panel está contraído y, cuando se selecciona un nodo, el panel de propiedades se abre con un tamaño predeterminado.
- Panel de vista previa de datos y esquema de salida: cambie el tamaño del panel inferior al hacer clic y arrastrar el borde inferior del lienzo en la parte inferior de la pantalla. Luego arrástrelo hacia arriba para ampliar la altura. De forma predeterminada, el panel está contraído y, cuando se selecciona un nodo, el panel inferior se abre con un tamaño predeterminado.

Lienzo de trabajo

Puede agregar, eliminar y mover o reordenar nodos directamente en el lienzo de ETL visuales. Considérelo su espacio de trabajo para crear un trabajo de ETL completamente funcional que comience con un origen de datos y termine con un destino de datos.

Cuando trabaja con nodos en el lienzo, cuenta con una barra de herramientas que puede ayudarle a acercar y alejar la imagen, eliminar nodos, establecer o editar conexiones entre nodos, cambiar la orientación del flujo de trabajo y deshacer o rehacer una acción.

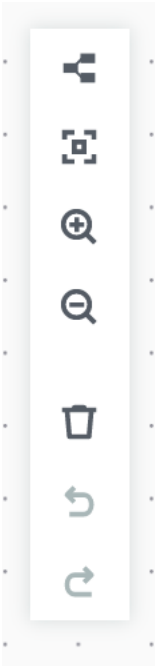

La barra de herramientas flotante está anclada al tamaño superior derecho del lienzo y contiene varias imágenes que realizan acciones:

- Icono de diseño: el primer icono de la barra de herramientas es el icono de diseño. La dirección de las tareas visuales es de arriba a abajo de forma predeterminada. Reorganiza la dirección de las tareas visuales al organizar los nodos horizontalmente de izquierda a derecha. Al volver a hacer clic en el icono de diseño, se cambia la dirección de arriba a abajo.
- Icono de recentrar: el icono de recentrar cambia la vista del lienzo al centrarlo. Puede usarlo con trabajos grandes para volver a la posición central.
- Ícono de zoom: el icono de zoom amplía el tamaño de los nodos del lienzo.
- Ícono de alejar: el icono de zoom achica el tamaño de los nodos del lienzo.
- Icono de papelera: el icono de papelera elimina un nodo del trabajo visual. Primero debe seleccionar un nodo.
- Icono de deshacer: el icono de deshacer invierte la última acción realizada en el trabajo visual.
- Icono de rehacer: el icono de rehacer repite la última acción realizada en el trabajo visual.

Uso del minimapa

Panel de recursos

El panel de recursos contiene todos los orígenes de datos, las acciones de transformación y las conexiones disponibles. Abre el panel de recursos en el lienzo mediante un clic en el icono “+”. Esto abrirá el panel de recursos.

Para cerrar el panel de recursos, haz clic en la X situada en la esquina superior derecha del panel de recursos. Esto ocultará el panel hasta que estés listo para volver a abrirlo.

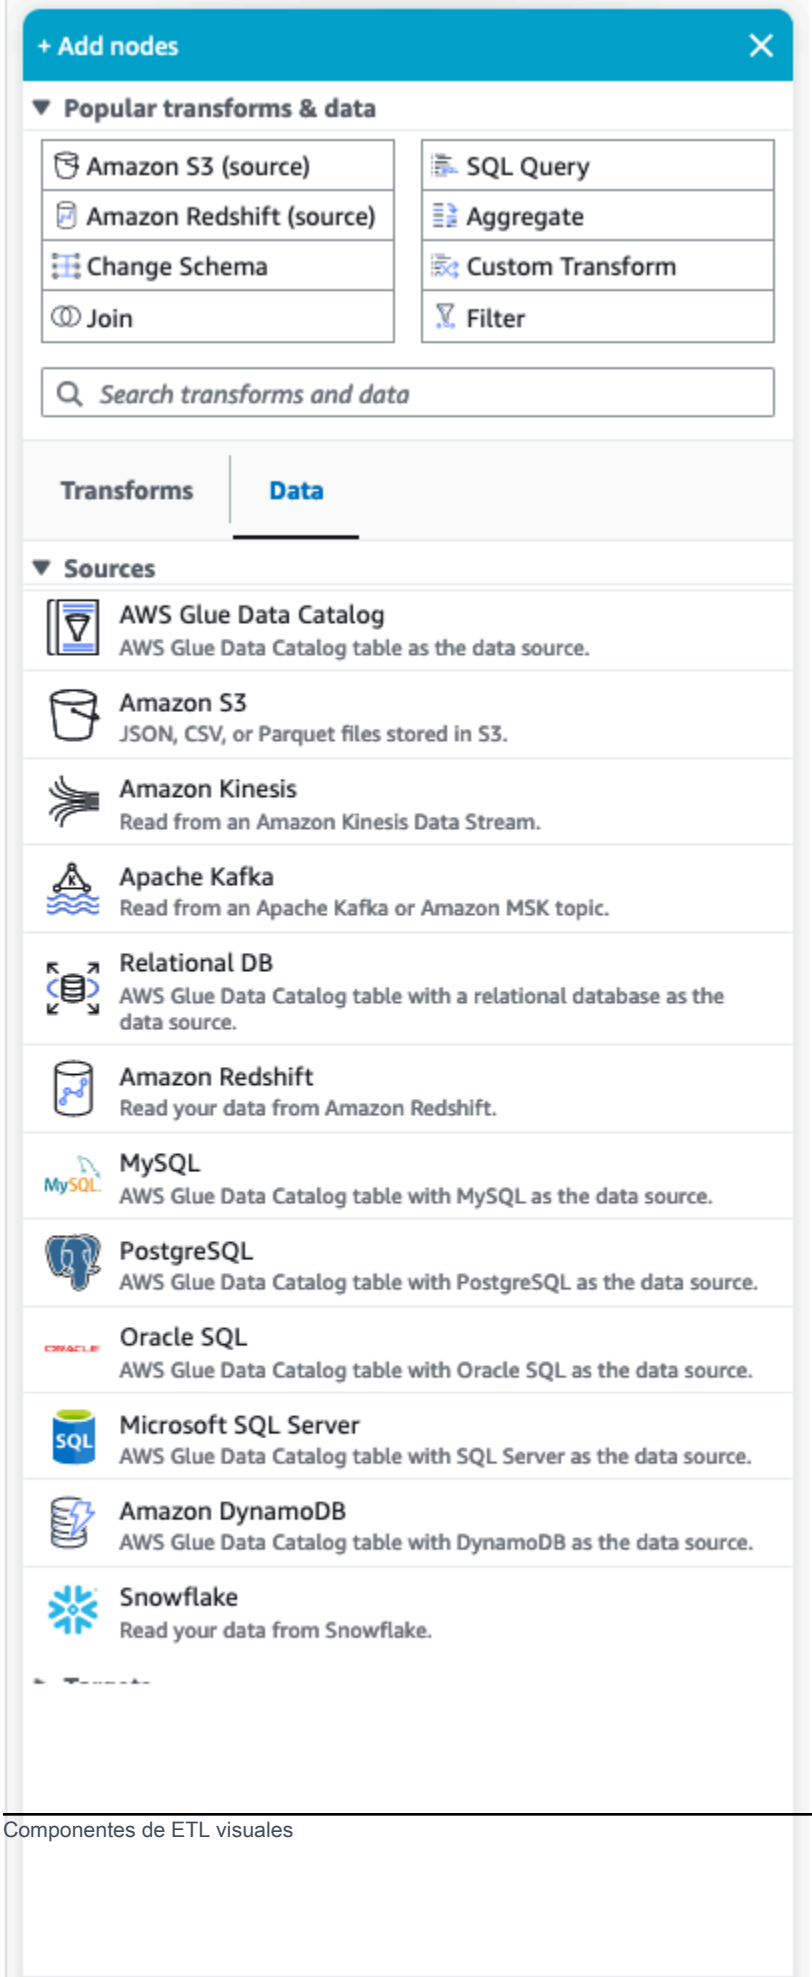
+ Add nodes
Popular transforms & data
Amazon S3 (source)
Amazon Redshift (source)
Change Schema
Join
SQL Query
Aggregate
Custom Transform
Filter
Search transforms and data
Transforms
Data
Sources
AWS Glue Data Catalog
AWS Glue Data Catalog table as the data source.
Amazon S3
JSON, CSV, or Parquet files stored in S3.
Amazon Kinesis
Read from an Amazon Kinesis Data Stream.
Apache Kafka
Read from an Apache Kafka or Amazon MSK topic.
Relational DB
AWS Glue Data Catalog table with a relational database as the data source.
Amazon Redshift
Read your data from Amazon Redshift.
MySQL
AWS Glue Data Catalog table with MySQL as the data source.
PostgreSQL
AWS Glue Data Catalog table with PostgreSQL as the data source.
Oracle SQL
AWS Glue Data Catalog table with Oracle SQL as the data source.
Microsoft SQL Server
AWS Glue Data Catalog table with SQL Server as the data source.
Amazon DynamoDB
AWS Glue Data Catalog table with DynamoDB as the data source.
Snowflake
Read your data from Snowflake.

Transformaciones populares y datos

En la parte superior del panel hay una colección de transformaciones populares y datos. Estos nodos se utilizan habitualmente en AWS Glue. Elija uno para agregarlo al lienzo. También puede ocultar las Transformaciones populares y datos al hacer clic en el triángulo situado junto al encabezado Transformaciones populares y datos.

En la sección Transformaciones populares y datos, puede buscar transformaciones y nodos de orígenes de datos. Los resultados aparecen a medida que escribe. Cuantas más letras agregue a la búsqueda, la lista de resultados se reducirá. Los resultados de la búsqueda se llenan a partir del nombre o la descripción del nodo. Elija el nodo para agregarlo al lienzo.

Transformaciones y datos

Hay dos pestañas que organizan los nodos en transformaciones y datos.

Transformaciones: al elegir la pestaña Transformaciones, se pueden seleccionar todas las transformaciones disponibles. Elija una transformación para agregarla al lienzo. También puede elegir Agregar transformación en la parte inferior de la lista de transformaciones, lo que abrirá una nueva página con la documentación para crear transformaciones visuales personalizadas. Si sigue estos pasos, podrá crear sus propias transformaciones. Sus transformaciones aparecerán en la lista de transformaciones disponibles.

Datos: la pestaña de datos contiene todos los nodos de los orígenes y los destinos. Puede ocultar los orígenes y los destinos al hacer clic en el triángulo situado junto al encabezado Orígenes o destinos. Puede mostrar los orígenes y los destinos al hacer clic de nuevo en el triángulo. Elija un nodo de origen o de destino para agregarlo al lienzo. También puede elegir Administrar conexiones para agregar una nueva conexión. Esto abrirá la página de conectores en la consola.

AWS Glue para Spark y AWS Glue para Ray

En AWS Glue en Apache Spark (ETL de AWS Glue), puede utilizar PySpark para escribir código Python para gestionar datos a escala. Spark es una solución conocida para este problema, pero a los ingenieros de datos con experiencia en Python puede parecerles poco intuitiva la transición. El modelo de DataFrame de Spark no es perfectamente como el de Python, lo que refleja el lenguaje de Scala y el entorno de ejecución de Java en el que se basa.

En AWS Glue, puede utilizar los trabajos del intérprete de comandos de Python para ejecutar integraciones de datos nativas de Python. Estos trabajos se ejecutan en una única instancia de

Amazon EC2 y se ven limitados por la capacidad de esa instancia. Esto restringe el rendimiento de los datos que puede procesar y resulta costoso mantenerlos cuando se trata de macrodatos.

AWS Glue para Ray permite escalar verticalmente las cargas de trabajo de Python sin una inversión sustancial en el aprendizaje de Spark. Puede aprovechar ciertos escenarios en los que Ray tiene un mejor rendimiento. Al ofrecerle una opción, puede utilizar los puntos fuertes de Spark y Ray.

ETL de AWS Glue y AWS Glue para Ray son diferentes en el fondo, por lo que admiten diferentes características. Consulte la documentación para ver las características admitidas.

¿Qué es AWS Glue para Ray?

Ray es un marco de computación distribuida de código abierto que se puede utilizar para escalar verticalmente las cargas de trabajo, con un enfoque en Python. Para obtener información sobre Ray, consulte el sitio web de Ray. AWS Glue Los trabajos y las sesiones interactivas de Ray le permiten utilizar Ray en AWS Glue.

Puede usar AWS Glue para Ray para escribir scripts de Python para cálculos que se ejecutarán en paralelo en varias máquinas. En los trabajos y sesiones interactivas de Ray, puede utilizar bibliotecas de Python conocidas, como pandas, para facilitar la escritura y la ejecución de los flujos de trabajo. Para obtener más información sobre los conjuntos de datos de Ray, consulte Conjuntos de datos de Ray en la documentación de Ray. Para más información acerca de Pandas, consulte el sitio web de Pandas.

Cuando utiliza AWS Glue para Ray, puede ejecutar los flujos de trabajo de pandas con macrodatos a escala empresarial, con solo algunas líneas de código. Puede crear un informe desde la consola de AWS Glue o AWS SDK. También puede abrir una sesión interactiva de AWS Glue para ejecutar el código en un entorno de Ray sin servidor. Aún no se admiten los trabajos visuales en AWS Glue Studio.

Los trabajos de AWS Glue para Ray permiten ejecutar un script según un cronograma o en respuesta a un evento de Amazon EventBridge. Los trabajos almacenan información de registro y estadísticas de supervisión en CloudWatch que permiten comprender el estado y la fiabilidad del script. Para más información sobre el sistema de trabajos de AWS Glue, consulte the section called “Trabajar con tareas de Ray”.

Ray automatiza el trabajo de escalar el código de Python mediante la distribución del procesamiento en un clúster de equipos que vuelve a configurar en tiempo real en función de la carga. Esto puede mejorar el rendimiento por dólar de determinadas cargas de trabajo. Con los trabajos de Ray, hemos

incorporado el escalado automático de forma nativa en el modelo de trabajo de AWS Glue, para poder aprovechar al máximo esta característica. Los trabajos de Ray se ejecutan en AWS Graviton, lo que lleva a una mayor rentabilidad general de los precios.

Además de ahorrar costos, puede utilizar el escalado automático nativo para ejecutar cargas de trabajo de Ray sin invertir tiempo en el mantenimiento, el ajuste y la administración del clúster. Puede utilizar bibliotecas conocidas de código abierto listas para su uso, como pandas y AWS SDK para Pandas. Estas mejoran la velocidad de iteración mientras desarrolla en AWS Glue para Ray. Cuando utilice AWS Glue para Ray, podrá desarrollar y ejecutar rápidamente cargas de trabajo rentables de integración de datos.

Conversión de esquemas semiestructurados a esquemas relacionales con AWS Glue

Es habitual querer convertir los datos semiestructurados en tablas relacionales. Conceptualmente, usted aplana un esquema jerárquico a un esquema relacional. AWS Glue puede realizar esta conversión automáticamente sobre la marcha.

Los datos semiestructurados suelen contar con margen para identificar las entidades dentro de los datos. Puede tener estructuras de datos anidadas sin esquema fijo. Para obtener más información acerca de los datos semiestructurados, consulte Datos semiestructurados en Wikipedia.

Los datos relacionales vienen representados por tablas que constan de filas y columnas. Las relaciones entre las tablas se pueden representar mediante una relación de clave principal a clave externa. Para obtener más información, consulte Base de datos relacional en Wikipedia.

AWS Glue usa los rastreadores para inferir esquemas para los datos semiestructurados. A continuación, transforma los datos en un esquema relacional mediante un flujo de trabajo de ETL (extracción, transformación y carga). Por ejemplo, es posible que desee diseccionar datos JSON desde archivos de origen de Amazon Simple Storage Service (Amazon S3) hacia tablas de Amazon Relational Database Service (Amazon RDS). Saber cómo controla AWS Glue las diferencias entre los esquemas puede ayudarle a entender el proceso de transformación.

En este diagrama se muestra cómo transforma AWS Glue un esquema semiestructurado en un esquema relacional.

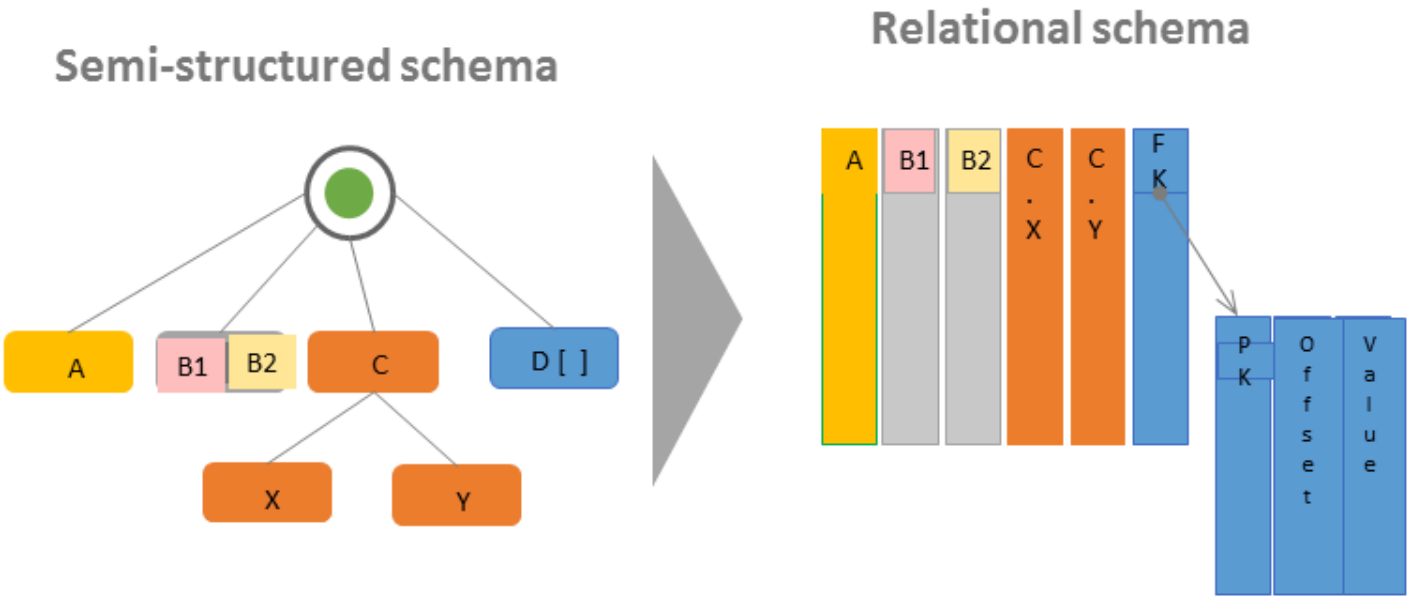

En el siguiente diagrama se ilustra lo siguiente:

- El valor único `A` se convierte directamente en una columna relacional.
- El par de valores `B1` y `B2` se convierten en dos columnas relacionales.
- La estructura `C`, con los elementos secundarios `X` e `Y`, se convierte en dos columnas relacionales.
- La matriz `D[]` se convierte en una columna relacional con una clave externa que apunta a otra tabla relacional. Junto con una clave principal, la segunda tabla relacional tiene columnas que contienen el desplazamiento y el valor de los elementos en la matriz.

Sistemas de tipos de AWS Glue

AWS Glue utiliza sistemas de tipos múltiples para proporcionar una interfaz versátil sobre sistemas de datos que almacenan datos de formas muy diferentes. Este documento desambigua los sistemas de tipos de AWS Glue y los estándares de datos.

Tipos de catálogos de datos de AWS Glue

El catálogo de datos es un registro de tablas y campos almacenados en diferentes sistemas de datos, un metaalmacén. Cuando los componentes de AWS Glue, como los rastreadores de AWS Glue y los trabajos de AWS Glue con Spark, escriben en el catálogo de datos, lo hacen con un sistema de tipos interno para rastrear los tipos de campos. Estos valores se muestran en la columna Tipo de datos del esquema de tablas de la consola de AWS Glue. Este sistema de tipos se basa en el sistema de tipos de Apache Hive. Para obtener más información sobre el sistema de tipos de Apache Hive, consulte Tipos en la wiki de Apache Hive. Para obtener más información sobre los tipos específicos y la compatibilidad, se proporcionan ejemplos en la consola de AWS Glue como parte del generador de esquemas.

Validación, compatibilidad y otros usos

El catálogo de datos no valida los tipos escritos en campos de tipos. Cuando los componentes de AWS Glue lean y escriban en el catálogo de datos, serán compatibles entre sí. Los componentes de AWS Glue también tienen como objetivo preservar un alto grado de compatibilidad con los tipos de Hive. Sin embargo, los componentes de AWS Glue no garantizan la compatibilidad con todos los tipos de Hive. Esto permite la interoperabilidad con herramientas como Athena DDL cuando se trabaja con tablas del catálogo de datos.

Dado que el catálogo de datos no valida los tipos, otros servicios pueden usarlo para rastrear los tipos mediante sistemas que se ajusten estrictamente al sistema de tipos de Hive o a cualquier otro sistema.

Tipos en los scripts de AWS Glue con Spark

Cuando un script de AWS Glue con Spark interpreta o transforma un conjunto de datos, proporcionamos `DynamicFrame`, una representación en memoria del conjunto de datos tal como se usa en el script. El objetivo de un `DynamicFrame` es similar al del Spark `DataFrame`: modela tu conjunto de datos para que Spark pueda programar y ejecutar transformaciones en los datos. Garantizamos que la representación de tipos de `DynamicFrame` es intercompatible con `DataFrame` y proporciona los métodos `toDF` y `fromDF`.

Si la información de tipos se puede inferir o proporcionar a un `DataFrame`, se puede inferir o proporcionar a un `DynamicFrame`, a menos que se documente lo contrario. Cuando proporcionamos lectores o escritores optimizados para formatos de datos específicos, si Spark puede leer o escribir sus datos, los lectores y escritores que proporcionemos podrán hacerlo, con sujeción a las limitaciones documentadas. Para obtener más información acerca de los lectores y los escritores, consulte the section called “Opciones de formato de datos”.

El tipo Choice

Los `DynamicFrames` proporcionan un mecanismo para modelar los campos de un conjunto de datos cuyo valor puede tener tipos inconsistentes en el disco en todas las filas. Por ejemplo, un campo puede contener un número almacenado como cadena en determinadas filas y un entero en otras. Este mecanismo es de un tipo en memoria denominado `Choice`. Proporcionamos transformaciones, como el método `ResolveChoice`, para resolver las columnas Choice en un tipo concreto. El proceso de ETL de AWS Glue no escribirá el tipo Choice en el catálogo de datos durante su funcionamiento normal; los tipos Choice solo existen en el contexto de los modelos de memoria de los conjuntos de datos de DynamicFrame. Para ver un ejemplo del uso del tipo Choice, consulte the section called “Muestra de preparación de datos”.

Tipos de rastreadores de AWS Glue

El objetivo de los rastreadores es crear un esquema coherente y utilizable para el conjunto de datos y, a continuación, almacenarlo en el catálogo de datos para usarlo en otros componentes de AWS Glue y Athena. Los rastreadores se encargan de los tipos, como se describe en la sección anterior sobre el catálogo de datos, the section called “Tipos de catálogos de datos de AWS Glue”. Para generar un tipo utilizable en los escenarios de tipo “Choice”, en los que una columna contiene valores de dos o más tipos, los rastreadores crearán un tipo `struct` que modele los tipos potenciales.

Introducción a AWS Glue

En las siguientes secciones, se ofrece información acerca de la configuración de AWS Glue. No todas las secciones de configuración son necesarias para empezar a utilizar AWS Glue. Puede utilizar las instrucciones según sea necesario para configurar los permisos de IAM, el cifrado y el DNS (si utiliza una VPC, un entorno para acceder a los almacenes de datos o si utiliza sesiones interactivas).

Temas

- Información general para el uso de AWS Glue
- Configuración de permisos de IAM para AWS Glue
- Configuración de perfiles de uso de AWS Glue
- Introducción al AWS Glue Data Catalog
- Configuración del acceso de red a los almacenes de datos
- Configuración del cifrado en AWS Glue
- Configuración de redes para el desarrollo de AWS Glue

Información general para el uso de AWS Glue

Con AWS Glue se almacenan metadatos en el AWS Glue Data Catalog. Estos metadatos se utilizan para organizar los trabajos de ETL que transforman los orígenes de datos y cargan su almacenamiento de datos o lago de datos. A continuación se describe el flujo de flujo de trabajo general y algunas de las elecciones que se realizan cuando se trabaja con AWS Glue.

> **Note**
>
> Puede seguir los pasos que se indican a continuación o puede crear un flujo de trabajo que realice automáticamente los pasos 1 a 3. Para obtener más información, consulte the section called “Realización de actividades de ETL complejas mediante esquemas y flujos de trabajo”.

1. Rellene AWS Glue Data Catalog con definiciones de tabla.

   En la consola, para almacenes de datos persistentes, puede agregar un rastreador para rellenar AWS Glue Data Catalog. Puede iniciar el asistente para Add crawler (Añadir rastreador) desde la

lista de tablas o la lista de rastreadores. Debe elegir uno o varios almacenes de datos a los que el rastreador tendrá acceso. También puede crear un programa para establecer la frecuencia de ejecución de su rastreador. Para transmisiones de datos, puede crear manualmente la definición de tabla y definir las propiedades de transmisión.

Opcionalmente, puede proporcionar un clasificador personalizado que deduce el esquema de los datos. Puede crear clasificadores personalizados utilizando un patrón de grok de . Por otra parte, AWS Glue proporciona clasificadores integrados que los rastreadores utilizan automáticamente si un clasificador personalizado no reconoce los datos. Cuando define un rastreador, no tiene que seleccionar un clasificador. Para obtener más información sobre los clasificadores de AWS Glue, consulte Definición y administración de clasificadores.

Para rastrear algunos tipos de almacenes de datos se necesita una conexión que proporcione información de autenticación y de ubicación. Si es necesario, puede crear una conexión que proporcione esta información en la consola de AWS Glue.

El rastreador lee el almacén de datos y crea definiciones de datos y tablas con nombre en AWS Glue Data Catalog. Estas tablas se organizan en una base de datos de su elección. También puede rellenar el Data Catalog con tablas creadas en forma manual. Con este método proporciona el esquema y otros metadatos para crear definiciones de tabla en Data Catalog. Dado que este método puede ser un poco tedioso y dar lugar a errores, a menudo es mejor que un rastreador cree las definiciones de tabla.

Para obtener más información acerca de cómo rellenar AWS Glue Data Catalog con definiciones de tabla, consulte Creación de tablas.

2. Defina un flujo de trabajo que describa la transformación de los datos de origen a destino.

   Por lo general, para crear un flujo de trabajo, tiene que realizar las tareas siguientes:

   - Elegir una tabla de AWS Glue Data Catalog para que sea el origen del trabajo. Su flujo de trabajo utilizará esta definición de tabla para obtener acceso a su origen de datos e interpretar el formato de los datos.
   - Elegir una tabla o ubicación de AWS Glue Data Catalog para que sea el destino del flujo de trabajo. Su flujo de trabajo utilizará esta información para obtener acceso a su almacén de datos.
   - Indicar a AWS Glue para que genere un script para transformar el origen en destino. AWS Glue genera el código para llamar a las transformaciones integradas para que conviertan datos de su esquema de origen en formato de esquema de destino. Estas transformaciones llevan a cabo

operaciones como copiar datos, cambiar el nombre de columnas y filtrar datos para transformar los datos según sea necesario. Puede modificar este script en la consola de AWS Glue.

Para obtener más información acerca de cómo definir trabajos en AWS Glue, consulte Creación de trabajos de ETL visual.

3. Ejecute su flujo de trabajo para transformar los datos.

   Puede ejecutar su flujo de trabajo bajo demanda o comenzarlo basándose en uno de los tipos de disparador siguientes:

   - Un disparador basado en un programa cron.
   - Un disparador basado en eventos; por ejemplo, la finalización correcta de otro flujo de trabajo puede iniciar otro flujo de trabajo de AWS Glue.
   - Un disparador que inicie un flujo de trabajo bajo demanda.

   Para obtener más información sobre de los disparadores de AWS Glue, consulte Inicio de trabajos y rastreadores mediante desencadenadores.

4. Monitoree su rastreadores programados y los trabajos activados.

   Use la consola de AWS Glue para ver los elementos siguientes:

   - Detalles y errores de la ejecución del flujo de trabajo.
   - Detalles y errores de la ejecución del rastreador.
   - Todas las notificaciones sobre las actividades de AWS Glue.

   Para obtener más información sobre la monitorización de los rastreadores y los trabajos en AWS Glue, consulte Supervisión de AWS Glue.

Configuración de permisos de IAM para AWS Glue

Las instrucciones de este tema ayudan a configurar rápidamente los permisos AWS Identity and Access Management (IAM) para AWS Glue. Deberá completar las tareas siguientes:

- Conceda a sus identidades de IAM acceso a los recursos AWS Glue.
- Cree un rol de servicio para ejecutar trabajos, acceder a los datos y ejecutar tareas de calidad de datos AWS Glue.

Para obtener instrucciones detalladas que puede utilizar para personalizar los permisos de IAM para AWS Glue, consulte Configuración de permisos de IAM para AWS Glue.

Para configurar los permisos de IAM para AWS Glue en la Consola de administración de AWS

1. Inicie sesión en la Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. Elija Empezar.
3. En Preparar su cuenta para AWS Glue, seleccione Configurar permisos de IAM.
4. Elige las identidades de IAM (roles o usuarios) a las que quieres conceder permisos AWS Glue. AWS Glue adjunta la política gestionada de `AWSGlueConsoleFullAccess` a estas identidades. Puede omitir este paso si desea configurar estos permisos de forma manual o solo desea establecer un rol de servicio predeterminado.
5. Elija Siguiente.
6. Elija el nivel de acceso a Amazon S3 que necesitan sus roles y usuarios. Las opciones que elija en este paso se aplican a todas las identidades que haya seleccionado.

   a. En Elegir ubicaciones de S3, elija las ubicaciones de Amazon S3 a las que quiere conceder acceso.

   b. A continuación, seleccione si sus identidades deben tener acceso de Solo lectura (recomendado) o acceso de lectura y escritura a las ubicaciones que seleccionó anteriormente. AWS Glue agrega políticas de permisos a sus identidades en función de la combinación de ubicaciones y los permisos de lectura o escritura que seleccione.

   En la siguiente tabla se muestran los permisos que AWS Glue adjunta al acceso a Amazon S3.

Si elige...	AWS Glue adjunta...
Sin cambios	Sin permisos. AWS Glue no realizará ningún cambio en los permisos de su identidad.
Conceder acceso a ubicaciones específicas de Amazon S3 (solo lectura)	La política administrada por el cliente, `AWSGlueConsole-S3-read-only-policy` , otorga acceso a ubicaciones

Si elige...	AWS Glue adjunta...
	específicas de Amazon S3 con permisos de solo lectura. JSON `{ "Version":"2012-10-17", "Statement": [{ "Effect": "Allow", "Action": ["s3:GetObject"], "Resource": ["arn:aws:s3:::amzn-s3-demo-bucket1/*", "arn:aws:s3:::amzn-s3-demo-bucket2/*", "arn:aws:s3:::amzn-s3-demo-bucket3", "arn:aws:s3:::amzn-s3-demo-bucket"], "Condition": { "StringEquals": { "aws:ResourceAccount": "000000000000" } } }] }`

Si elige...	AWS Glue adjunta...
Conceder acceso a ubicaciones específicas de Amazon S3 (lectura y escritura)	La `AWSGlueConsole-S3-read-and-write-policy` concede acceso a ubicaciones específicas de Amazon S3 con permisos de lectura y escritura. JSON **{** **"Version":"2012-10-17",** **"Statement": [** **{** **"Effect": "Allow",** **"Action": [** **"s3:GetObject",** **"s3:PutObject"** **],** **"Resource": [** **"arn:aws:s3:::aes-siem-00000000000-log/*",** **"arn:aws:s3:::aes-siem-00000000000-snapshot/*",** **"arn:aws:s3:::aes-siem-00000000000-log",** **"arn:aws:s3:::aes-siem-00000000000-snapshot"** **],** **"Condition": {** **"StringEquals": {** **"aws:ResourceAccount": "000000000000"** **}** **}** **}** **]** **}**

7. Elija Siguiente.
8. Elija un rol de servicio predeterminado de AWS Glue para su cuenta. Un rol de servicio es un rol de IAM que AWS Glue utiliza para acceder a los recursos de otros servicios de AWS en su nombre. Para obtener más información, consulte Roles de servicio para AWS Glue.

   - Al elegir la función de rol de servicio de AWS Glue, AWS Glue crea un nuevo rol de IAM en su Cuenta de AWS llamado `AWSGlueServiceRole` con las siguientes políticas gestionadas adjuntas. Si su cuenta ya tiene un rol de IAM denominado `AWSGlueServiceRole`, AWS Glue adjunta estas políticas al rol existente.
     - AWSGlueServiceRole: esta política administrada es necesaria para que AWS Glue pueda acceder a los recursos y administrarlos en su nombre. Permite a AWS Glue crear, actualizar y eliminar varios recursos, como trabajos de AWS Glue, rastreadores y conexiones. Esta política también otorga permisos para que AWS Glue acceda a los registros de Amazon CloudWatch con fines de registro. Para empezar, le recomendamos que utilice esta política para aprender a usar AWS Glue. A medida que se vaya sintiendo más cómodo con AWS Glue, podrá crear políticas que le permitan afinar el acceso a los recursos según sea necesario.
     - AWSGlueConsoleFullAccess: esta política administrada otorga acceso total al servicio AWS Glue a través de Consola de administración de AWS. Esta política otorga permisos para realizar cualquier operación dentro de AWS Glue, lo que le permite crear, modificar y eliminar cualquier recurso AWS Glue según sea necesario. Sin embargo, es importante tener en cuenta que esta política no otorga permisos para acceder a los almacenes de datos subyacentes ni a otros servicios AWS que puedan estar involucrados en el proceso de ETL. Debido a la amplia gama de permisos que concede la política `AWSGlueConsoleFullAccess`, se debe asignar con cautela y siguiendo el principio del privilegio mínimo. En general, se recomienda crear y utilizar políticas más detalladas adaptadas a casos de uso y requisitos específicos siempre que sea posible.
     - AWSGlueConsole-S3-read-only-policy: esta política permite a AWS Glue leer datos de buckets específicos de Amazon S3, pero no otorga permisos para escribir o modificar datos en Amazon S3 o

       AWSGlueConsole-S3-read-and-write: esta política permite a AWS Glue leer y escribir datos en buckets específicos de Amazon S3 como parte del proceso de ETL.
   - Al elegir un rol de IAM existente, AWS Glue lo establece como predeterminado, pero no agrega permisos para `AWSGlueServiceRole`. Asegúrese de haber configurado el rol para usarlo como rol de servicio para AWS Glue. Para obtener más información, consulte Paso 1:

Crear una política de IAM para el servicio AWS Glue y Paso 2: creación de un rol de IAM para AWS Glue.

9. Elija Siguiente.
10. Por último, revise los permisos que ha seleccionado y, a continuación, seleccione Aplicar cambios. Al aplicar los cambios, AWS Glue agregue permisos de IAM a las identidades que seleccionó. Puede ver o modificar los nuevos permisos en la consola de IAM en https://console.aws.amazon.com/iam/.

Ya ha completado la configuración mínima de permisos de IAM para AWS Glue. En un entorno de producción, recomendamos que se familiarice con la Seguridad en AWS Glue y Administración de identidades y accesos para AWS Glue para ayudarlo a proteger los recursos de AWS para su caso de uso.

Siguientes pasos

Ahora que ha configurado los permisos de IAM, puede explorar los siguientes temas para empezar a utilizar AWS Glue:

- Primeros pasos con AWS Glue Skill Builder de AWS
- Introducción al AWS Glue Data Catalog

Configuración de AWS Glue Studio

Complete las tareas de esta sección cuando utilice AWS Glue para operaciones de ETL visuales por primera vez:

Temas

- Revisar los permisos de IAM necesarios para el usuario de AWS Glue Studio
- Revisar los permisos de IAM necesarios para trabajos de ETL.
- Definición de permisos de IAM para AWS Glue Studio
- Configurar una VPC para su trabajo de ETL

Revisar los permisos de IAM necesarios para el usuario de AWS Glue Studio

Para utilizar AWS Glue Studio, el usuario debe tener acceso a diversos recursos de AWS. El usuario debe poder ver y seleccionar buckets de Amazon S3, políticas y roles de IAM, y objetos de AWS Glue Data Catalog.

Permisos de servicios de AWS Glue

AWS Glue Studio utiliza las acciones y recursos del servicio de AWS Glue. Su usuario necesita permisos sobre estas acciones y recursos para utilizar AWS Glue Studio de manera eficaz. Puede conceder al usuario de AWS Glue Studio la política administrada de `AWSGlueConsoleFullAccess` o crear una política personalizada con un conjunto de permisos más pequeño.

> **Important**
>
> Según las mejores prácticas de seguridad, se recomienda restringir el acceso mediante políticas más estrictas para limitar aún más el acceso al bucket de Amazon S3 y grupos de registros de Amazon CloudWatch. Para ver un ejemplo de política de Amazon S3, consulte Cómo escribir políticas de IAM: cómo conceder acceso a un bucket de Amazon S3.

Creación de políticas de IAM personalizadas para AWS Glue Studio

Puede crear una política personalizada con un conjunto de permisos más pequeño para AWS Glue Studio. La política puede conceder permisos para un subconjunto de objetos o acciones. Utilice la siguiente información al crear una política personalizada.

Para utilizar las API de AWS Glue Studio, incluye `glue:UseGlueStudio` en la política de acción de los permisos de IAM. Utilizar `glue:UseGlueStudio` le permitirá acceder a todas las acciones de AWS Glue Studio, incluso a las que se vayan agregando a la API a lo largo del tiempo.

Para obtener más información acerca de las acciones definidas por AWS Glue, consulte Acciones definidas por AWS Glue.

Acciones de preparación y creación de datos

- SendRecipeAction
- GetRecipeAction

Acciones de gráficos acíclicos dirigidos (DAG)

- CreateDag
- UpdateDag
- GetDag
- DeleteDag

Acciones de trabajo

- SaveJob
- GetJob
- CreateJob
- DeleteJob
- GetJobs
- UpdateJob

Acciones de ejecución de trabajo

- StartJobRun
- GetJobRuns
- BatchStopJobRun
- GetJobRun
- QueryJobRuns
- QueryJobs
- QueryJobRunsAggregated

Acciones de esquemas

- GetSchema
- GetInferredSchema

Acciones de la base de datos

- GetDatabases

Acciones del plan

- GetPlan

Acciones de la tabla

- SearchTables
- GetTables
- GetTable

Acciones de conexión

- CreateConnection
- DeleteConnection
- UpdateConnection
- GetConnections
- GetConnection

Acciones de asignación

- GetMapping

Acciones de proxy de S3

- ListBuckets
- ListObjectsV2
- GetBucketLocation

Acciones de configuración de seguridad

- GetSecurityConfigurations

Acción de script

- CreateScript (diferente de la API del mismo nombre en AWS Glue)

Acceso a API de AWS Glue Studio

Para acceder a AWS Glue Studio, agregue `glue:UseGlueStudio` a la lista de políticas de acciones de los permisos de IAM.

En el siguiente ejemplo, se ha incluido `glue:UseGlueStudio` en la política de acción, pero las API de AWS Glue Studio no están identificadas individualmente. Esto se debe a que cuando se incluye `glue:UseGlueStudio` se concede automáticamente acceso a las API internas sin tener que especificar las API de AWS Glue Studio individuales en los permisos de IAM.

En el ejemplo, las políticas de acción adicionales que aparecen (por ejemplo, `glue:SearchTables`) no son API de AWS Glue Studio, de modo que se deberán incluir en los permisos de IAM según sea necesario. También se pueden incluir acciones de proxy de Amazon S3 para especificar el nivel de acceso de Amazon S3 que se desea conceder. La siguiente política de ejemplo proporciona acceso para abrir AWS Glue Studio, crear un trabajo visual y guardarlo o ejecutarlo si el rol de IAM seleccionado tiene suficiente acceso.

Permisos de vista previa de datos y cuaderno

Las vistas previas de datos y los cuaderno le permiten ver una muestra de los datos en cualquier etapa del trabajo (lectura, transformación, escritura), sin tener que ejecutar el trabajo. Se especifica un rol de AWS Identity and Access Management (IAM) para que utilice AWS Glue Studio al acceder a los datos. Los roles de IAM están destinados a ser asumibles y no tienen asociadas credenciales estándar a largo plazo, como una contraseña o clave de acceso. En lugar de esto, cuando AWS Glue Studio asume el rol, IAM le proporciona credenciales de seguridad temporales.

Para garantizar que las vistas previas de datos y los comandos de cuaderno funcionen correctamente, utilice un rol que tenga un nombre que empiece por la cadena `AWSGlueServiceRole`. Si decide utilizar otro nombre para el rol, debe agregar el permiso `iam:passrole` y configurar una política para el rol en IAM. Para obtener más información, consulte Crear una política de IAM para roles no denominados “AWSGlueServiceRole*”.

> **Warning**
>
> Si un rol concede el permiso `iam:passrole` a un cuaderno e implementa el encadenamiento de roles, un usuario podría obtener acceso involuntariamente al cuaderno. Actualmente no se ha implementado ninguna auditoría que le permita monitorear a qué usuarios se les ha concedido acceso al cuaderno.

Si desea denegar a una identidad de IAM la capacidad de crear sesiones de vista previa de datos, consulte el siguiente ejemplo the section called “Cómo denegar a una identidad la capacidad de crear sesiones de vista previa de datos”.

Permisos de Amazon CloudWatch

Puede monitorear sus trabajos de AWS Glue Studio mediante Amazon CloudWatch, que recopila y procesa los datos sin procesar de AWS Glue en métricas legibles y casi en tiempo real. De forma predeterminada, los datos de las métricas de AWS Glue se envían a CloudWatch en forma automática. Para obtener más información, consulte ¿Qué es Amazon CloudWatch? en la Guía del usuario de Amazon CloudWatch, y Métricas de AWS Glue en la Guía para desarrolladores de AWS Glue.

Para acceder a los paneles de CloudWatch, el usuario que accede a AWS Glue Studio necesita alguna de las siguientes:

- La política `AdministratorAccess`
- La política `CloudWatchFullAccess`
- Una política personalizada que incluya uno o varios de estos permisos específicos:
  - `cloudwatch:GetDashboard` y `cloudwatch:ListDashboards` para ver paneles
  - `cloudwatch:PutDashboard` para poder crear o modificar paneles
  - `cloudwatch:DeleteDashboards` para eliminar paneles

Para obtener más información sobre cómo cambiar los permisos de un usuario de IAM mediante políticas, consulte Cambio de los permisos de un usuario de IAM en la Guía del usuario de IAM.

Revisar los permisos de IAM necesarios para trabajos de ETL.

Cuando crea un trabajo con AWS Glue Studio, el trabajo asume los permisos del rol de IAM que se especifica al crear el trabajo. Este rol de IAM debe tener permiso para extraer datos de su origen de datos, escribir en su destino y acceder a recursos de AWS Glue.

El nombre del rol que cree para el trabajo debe comenzar con la cadena `AWSGlueServiceRole` para que AWS Glue Studio lo utilice correctamente. Por ejemplo, podría asignar el siguiente nombre a su rol: `AWSGlueServiceRole-FlightDataJob`.

Permisos de origen de datos y destino de datos

Un trabajo de AWS Glue Studio debe tener acceso a Amazon S3 para todos los orígenes, destinos, scripts y directorios temporales que utilice en su trabajo. Puede crear una política para proporcionar un acceso detallado a determinados recursos de Amazon S3.

- Los orígenes de datos requieren permisos `s3:ListBucket` y `s3:GetObject`.
- Los destinos de datos requieren permisos `s3:ListBucket`, `s3:PutObject` y `s3:DeleteObject`.

> **Note**
>
> Su política de IAM debe permitir `s3:GetObject` para los buckets específicos que se utilizan para alojar las transformaciones AWS Glue.
> Los siguientes buckets pertenecen a la cuenta de servicio de AWS y se pueden leer en todo el mundo. Estos buckets sirven como depósito del código fuente correspondiente a un subconjunto de transformaciones al que se puede acceder mediante el editor visual AWS Glue Studio. Los permisos del bucket están configurados para denegar cualquier otra acción de la API en este. Los scripts que proporcionamos para las transformaciones pueden ser leídos por cualquier persona, pero nadie ajeno a nuestro equipo de servicio puede “poner” nada en ellos. Cuando se ejecuta el trabajo de AWS Glue, ese archivo se extrae como importación local y, por lo tanto, se descarga en el contenedor local. Después de eso, no hay más comunicación con esa cuenta.

Región: nombre del bucket

- af-south-1: aws-glue-studio-transforms-762339736633-prod-af-south-1
- ap-east-1: aws-glue-studio-transforms-125979764932-prod-ap-east-1
- ap-northeast-2: aws-glue-studio-transforms-673535381443-prod-ap-northeast-2
- ap-northeast-3: aws-glue-studio-transforms-149976050262-prod-ap-northeast-3
- ap-south-1: aws-glue-studio-transforms-584702181950-prod-ap-south-1
- ap-south-2: aws-glue-studio-transforms-380279651983-prod-ap-south-2
- ap-southeast-1: aws-glue-studio-transforms-737106620487-prod-ap-southeast-1
- ap-southeast-2: aws-glue-studio-transforms-234881715811-prod-ap-southeast-2

- ap-southeast-3: aws-glue-studio-transforms-151265630221-prod-ap-southeast-3
- ap-southeast-4: aws-glue-studio-transforms-052235663858-prod-ap-southeast-4
- ca-central-1: aws-glue-studio-transforms-622716468547-prod-ca-central-1
- ca-west-1: aws-glue-studio-transforms-915795495192-prod-ca-west-1
- eu-central-1: aws-glue-studio-transforms-560373232017-prod-eu-central-1
- eu-central-2: aws-glue-studio-transforms-907358657121-prod-eu-central-2
- eu-north-1: aws-glue-studio-transforms-312557305497-prod-eu-north-1
- eu-south-1: aws-glue-studio-transforms-939684186351-prod-eu-south-1
- eu-south-2: aws-glue-studio-transforms-239737454084-prod-eu-south-2
- eu-west-1: aws-glue-studio-transforms-244479516193-prod-eu-west-1
- eu-west-2: aws-glue-studio-transforms-804222392271-prod-eu-west-2
- eu-west-3: aws-glue-studio-transforms-371299348807-prod-eu-west-3
- il-central-1: aws-glue-studio-transforms-806964611811-prod-il-central-1
- me-central-1: aws-glue-studio-transforms-733304270342-prod-me-central-1
- me-south-1: aws-glue-studio-transforms-112120182341-prod-me-south-1
- sa-east-1: aws-glue-studio-transforms-881619130292-prod-sa-east-1
- us-east-1: aws-glue-studio-transforms-510798373988-prod-us-east-1
- us-east-2: aws-glue-studio-transforms-251189692203-prod-us-east-2
- us-west-1: aws-glue-studio-transforms-593230150239-prod-us-west-1
- us-west-2: aws-glue-studio-transforms-818035625594-prod-us-west-2
- ap-northeast-1: aws-glue-studio-transforms-200493242866-prod-ap-northeast-1
- cn-north-1: aws-glue-studio-transforms-071033555442-prod-cn-north-1
- cn-northwest-1: aws-glue-studio-transforms-070947029561-prod-cn-northwest-1
- us-gov-west-1: aws-glue-studio-transforms-227493901923-prod-us-gov-west-1-2604

Si elige Amazon Redshift como origen de datos, puede proporcionar un rol para los permisos de clúster. Los trabajos que se ejecutan respecto de un clúster de Amazon Redshift envían comandos que acceden a Amazon S3 para el almacenamiento temporal mediante credenciales temporales. Si el trabajo se ejecuta durante más de una hora, estas credenciales caducarán, y provocarán un error

en el trabajo. Para evitar este problema, puede asignar un rol al clúster de Amazon Redshift que conceda los permisos necesarios a los trabajos que utilizan credenciales temporales. Para obtener más información, consulte Movimiento de datos desde y hacia Amazon Redshift en la Guía para desarrolladores de AWS Glue.

Si el trabajo utiliza orígenes o destinos de datos distintos de Amazon S3, debe asociar los permisos necesarios al rol de IAM utilizado por el trabajo para acceder a estos orígenes y destinos de datos. Para obtener más información, consulte Configuración del entorno para obtener acceso a almacenes de datos en la Guía para desarrolladores de AWS Glue.

Si utiliza conectores y conexiones para el almacén de datos, necesita permisos adicionales, como se describe en the section called “Permisos necesarios para utilizar conectores”.

Permisos necesarios para eliminar trabajos

En AWS Glue Studio, puede seleccionar múltiples trabajos para eliminar en la consola. Para realizar esta acción, debe tener el permiso `glue:BatchDeleteJob`. Esto es diferente de la consola de AWS Glue, que requiere el permiso `glue:DeleteJob` para eliminar trabajos.

Permisos de AWS Key Management Service

Si tiene previsto acceder a orígenes y destinos de Amazon S3 que utilizan cifrado del lado del servidor con AWS Key Management Service (AWS KMS), adjunte una política al rol de AWS Glue Studio utilizado por el trabajo que permita al trabajo descifrar los datos. El rol del trabajo necesita los permisos `kms:ReEncrypt`, `kms:GenerateDataKey` y `kms:DescribeKey`. Además, el rol del trabajo necesita el permiso `kms:Decrypt` para cargar o descargar un objeto de Amazon S3 cifrado con una clave maestra del cliente (CMK) AWS KMS.

La utilización de CMK de AWS KMS conlleva cargos adicionales. Para obtener más información, consulte Conceptos de AWS Key Management Service: claves maestras del cliente (CMK) y Precios de AWS Key Management Service en la Guía para desarrolladores de AWS Key Management Service.

Permisos necesarios para utilizar conectores

Si utiliza un conector personalizado y conexión de AWS Glue para acceder a un almacén de datos, el rol utilizado para ejecutar el trabajo de ETL de AWS Glue necesita permisos adicionales asociados:

- La política administrada de AWS `AmazonEC2ContainerRegistryReadOnly` para acceder a los conectores adquiridos en AWS Marketplace.

- Los permisos `glue:GetJob` y `glue:GetJobs`.
- Los permisos de AWS Secrets Manager para acceder a los secretos que se utilizan con las conexiones. Consulte Ejemplo: Permiso para recuperar valores de secretos para ver ejemplos de políticas de IAM.

Si sus trabajos de ETL de AWS Glue se ejecutan en una VPC que ejecuta Amazon VPC, la VPC debe configurarse como se describe en the section called “Configurar una VPC para su trabajo de ETL”.

Definición de permisos de IAM para AWS Glue Studio

Puede crear los roles y asignar políticas a usuarios y roles de trabajo mediante el usuario administrado de AWS.

Puede utilizar la política administrada de AWS AWSGlueConsoleFullAccess para proporcionar los permisos necesarios para utilizar la consola de AWS Glue Studio.

Para crear su propia política, siga los pasos documentados en Crear una política de IAM para el servicio AWS Glue en la Guía para desarrolladores de AWS Glue. Incluya los permisos de IAM descritos anteriormente en Revisar los permisos de IAM necesarios para el usuario de AWS Glue Studio.

Temas

- Adjuntar políticas al usuario de AWS Glue Studio
- Crear una política de IAM para roles no denominados “AWSGlueServiceRole*”

Adjuntar políticas al usuario de AWS Glue Studio

Todo usuario de AWS que inicie sesión en la consola de AWS Glue Studio debe tener permisos para acceder a recursos específicos. Estos permisos los concede mediante la asignación de políticas de IAM al usuario.

Para adjuntar la política administrada AWSGlueConsoleFullAccess a un usuario

1. Inicie sesión en la Consola de administración de AWS y abra la consola de IAM en https://console.aws.amazon.com/iam/.
2. En el panel de navegación, seleccione Políticas.

3. En la lista de políticas, seleccione la casilla de verificación situada junto a AWSGlueConsoleFullAccess. Puede utilizar el menú Filtro y el cuadro de búsqueda para filtrar la lista de políticas.
4. Seleccione Policy actions (Acciones de la política) y, a continuación, Attach (Adjuntar).
5. Seleccione el usuario al que asociará la política. Puede utilizar el menú Filtro y el cuadro de búsqueda para filtrar la lista entidades principales. Después de seleccionar el usuario al que asociará la política, seleccione Attach policy (Asociar política).
6. Repita los pasos anteriores para adjuntar políticas adicionales al usuario según sea necesario.

Crear una política de IAM para roles no denominados “AWSGlueServiceRole*”

Para configurar una política de IAM para los roles utilizados por AWS Glue Studio

1. Inicie sesión en Consola de administración de AWS y abra la consola IAM en https://console.aws.amazon.com/iam/.
2. Agregue una nueva política de IAM. Puede agregar a una política existente o crear una nueva política insertada de IAM. Para crear una política de IAM:
    1. Elija Policies y después, Create Policy. Si aparece el botón Get Started (Empezar), elíjalo y, a continuación, elija Create Policy (Crear política).
    2. Junto a Create Your Own Policy, seleccione Select.
    3. En Policy Name (Nombre de política), escriba cualquier valor que sea fácil de consultar más tarde. Si lo desea, escriba un texto descriptivo en Description (Descripción).
    4. En Policy Document (Documento de política), escriba una instrucción de política con el formato siguiente y, a continuación, elija Create Policy (Crear política):
3. Copie y pegue los siguientes bloques en la política en la matriz “Declaración” y sustituya *my-interactive-session-role-prefix* con el prefijo para que todos los roles comunes se asocien con permisos para AWS Glue.

```
{
    "Action": [
        "iam:PassRole"
    ],
    "Effect": "Allow",
    "Resource": "arn:aws:iam::*:role/my-interactive-session-role-prefix*",
    "Condition": {
        "StringLike": {
```

```
            "iam:PassedToService": [
                "glue.amazonaws.com "
            ]
        }
    }
}
```

Este es el ejemplo completo con las matrices Version (Versión) y Statement (Declaración) incluidas en la política

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Action": [
        "iam:PassRole"
      ],
      "Effect": "Allow",
      "Resource": "arn:aws:iam::*:role/my-interactive-session-role-prefix*",
      "Condition": {
        "StringLike": {
          "iam:PassedToService": [
            "glue.amazonaws.com "
          ]
        }
      }
    }
  ]
}
```

4. Para habilitar la política para un usuario, elija Users (Usuarios).
5. Elija el usuario de a quien desea asociar la política.

Configurar una VPC para su trabajo de ETL

Puede utilizar Amazon Virtual Private Cloud (Amazon VPC) para definir una red virtual en su propia área aislada lógicamente dentro de la Nube de AWS, conocida como una nube privada virtual (VPC). Puede lanzar recursos de AWS, como, por ejemplo, instancias, en su VPC. Una VPC es

prácticamente idéntica a una red tradicional que usted puede operar en su propio centro de datos, con los beneficios que supone utilizar la infraestructura escalable de AWS. Puede configurar la VPC, seleccionar su rango de direcciones IP, crear subredes y configurar tablas de enrutamiento, puerta de enlace de red y ajustes de seguridad. Ahora puede conectar sus instancias de la VPC a Internet. Puede conectar la VPC a su propio centro de datos corporativo, lo que convierte la Nube de AWS en una ampliación del centro de datos. Para proteger los recursos de cada subred, puede utilizar varias capas de seguridad, incluidos grupos de seguridad y listas de control de acceso a la red. Para obtener más información, consulte la Guía del usuario de Amazon VPC.

Puede configurar sus trabajo de ETL de AWS Glue para que se ejecuten dentro de una VPC cuando se utilicen conectores. Debe configurar la VPC para lo siguiente, según sea necesario:

- Acceso a la red pública de almacenes de datos externos a AWS. Todos los almacenes de datos a los que obtiene acceso el trabajo deben estar disponibles a partir de la subred de la VPC.
- Si su trabajo necesita obtener acceso a los recursos de la VPC y a la red pública de Internet, la VPC debe tener una gateway de NAT (traducción de direcciones de red) dentro de la VPC.

  Para obtener más información, consulte Configuración del entorno para obtener acceso a almacenes de datos en la Guía para desarrolladores de AWS Glue.

Introducción a los cuaderno en AWS Glue Studio

Al iniciar un cuaderno a través de AWS Glue Studio, todos los pasos de configuración se hacen por usted para que, después de unos segundos, pueda explorar los datos y comenzar a desarrollar el script de trabajo.

Las siguientes secciones describen cómo crear un rol y otorgar los permisos adecuados para utilizar cuadernos en AWS Glue Studio para trabajos de ETL.

Para obtener más información sobre las acciones definidas por AWS Glue, consulte Acciones definidas por AWS Glue.

Temas

- Concesión de permisos para el rol de IAM

Concesión de permisos para el rol de IAM

Configurar AWS Glue Studio es un requisito previo para utilizar cuadernos.

Para utilizar cuadernos en AWS Glue, la función requiere lo siguiente:

- Una relación de confianza con AWS Glue para la acción `sts:AssumeRole` y, si desea etiquetar, `sts:TagSession`.
- Una política de IAM que contenga todos los permisos para cuadernos, AWS Glue y sesiones interactivas.
- Una política de IAM para un rol de pase, ya que el rol debe poder pasarse a sí mismo desde el cuaderno a sesiones interactivas.

Por ejemplo, cuando crea un nuevo rol, puede agregar una política administrada de AWS estándar como `AWSGlueConsoleFullAccessRole` al rol y luego agregar una nueva política para las operaciones del cuaderno y otra para la política IAM PassRole.

Acciones necesarias para una relación de confianza con AWS Glue

Al iniciar una sesión de cuaderno, se debe agregar `sts:AssumeRole` a la relación de confianza del rol que se pase al cuaderno. Si la sesión incluye etiquetas, también se debe pasar la acción `sts:TagSession`. Sin estas acciones, la sesión del cuaderno no puede iniciarse.

Por ejemplo:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Principal": {
        "Service": "glue.amazonaws.com"
      },
      "Action": "sts:AssumeRole"
    }
  ]
}
```

Políticas que contienen permisos de IAM para cuadernos

La siguiente política de ejemplo describe los permisos de AWS IAM requeridos para cuadernos. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:StartNotebook",
        "glue:TerminateNotebook",
        "glue:GlueNotebookRefreshCredentials",
        "glue:DeregisterDataPreview",
        "glue:GetNotebookInstanceStatus",
        "glue:GlueNotebookAuthorize"
      ],
      "Resource": "*"
    }
  ]
}
```

Puede utilizar las siguientes políticas de IAM para permitir el acceso a recursos específicos:

- AwsGlueSessionUserRestrictedNotebookServiceRole: proporciona acceso completo a todos los recursos de AWS Glue, excepto las sesiones. Permite a los usuarios crear y utilizar solo las sesiones de cuadernos que estén asociadas a esos usuarios. Esta política también incluye otros permisos que AWS Glue necesita para administrar recursos de AWS Glue en otros servicios de AWS.
- AwsGlueSessionUserRestrictedNotebookPolicy: proporciona permisos que permiten a los usuarios crear y utilizar solo las sesiones de cuadernos que estén asociadas a esos usuarios. Esta política también incluye permisos para que los usuarios puedan pasar expresamente un rol de sesión de AWS Glue restringida.

Política de IAM para pasar un rol

Cuando se crea un cuaderno con un rol, ese rol se pasa a las sesiones interactivas para que se pueda utilizar el mismo rol en ambos lugares. Como tal, el permiso `iam:PassRole` debe formar parte de la política del rol.

Cree una nueva política para el rol mediante el siguiente ejemplo. Reemplace el número de cuenta por el suyo y por el nombre del rol.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": "iam:PassRole",
      "Resource": "arn:aws:iam::111122223333:role/<role_name>"
    }
  ]
}
```

Configuración de perfiles de uso de AWS Glue

Una de las principales ventajas de utilizar una plataforma en la nube es su flexibilidad. Sin embargo, esta facilidad a la hora de crear recursos de computación conlleva el riesgo de que los costos de la nube aumenten vertiginosamente si no se gestionan ni tienen barreras de protección. Como resultado, los administradores deben encontrar el equilibrio entre evitar los altos costos de infraestructura y, al mismo tiempo, permitir que los usuarios trabajen sin fricciones innecesarias.

Con los perfiles de uso de AWS Glue, los administradores pueden crear diferentes perfiles para las distintas clases de usuarios de la cuenta, como desarrolladores, evaluadores y equipos de productos. Cada perfil es un conjunto único de parámetros que se pueden asignar a distintos tipos de usuarios. Por ejemplo, los desarrolladores pueden necesitar más trabajadores y tener un número máximo de trabajadores más alto, mientras que los equipos de productos pueden necesitar menos trabajadores y un valor de tiempo de espera o inactividad más bajo.

Ejemplo de comportamiento de trabajos y ejecuciones de trabajos

Supongamos que un trabajo lo crea el usuario A con el perfil A. El trabajo se guarda con determinados valores de parámetros. El usuario B con el perfil B intentará ejecutar el trabajo.

Cuando el usuario A creó el trabajo, si no estableció un número específico de trabajadores, se aplicó el conjunto predeterminado en el perfil del usuario A y se guardó con las definiciones del trabajo.

Cuando el usuario B ejecuta el trabajo, lo hace con los valores que se hayan guardado para él. Si el propio perfil del usuario B es más restrictivo y no se le permite ejecutarse con tantos trabajadores, la ejecución de la tarea fallará.

Uso del perfil como recurso

Un perfil de uso de AWS Glue es un recurso identificado por un nombre de recurso de Amazon (ARN). Se aplican todos los controles de IAM (Identity and Access Management) predeterminados, incluida la autorización basada en acciones y en recursos. Los administradores deben actualizar la política de IAM de los usuarios que crean recursos de AWS Glue, lo que les concede acceso para usar los perfiles.

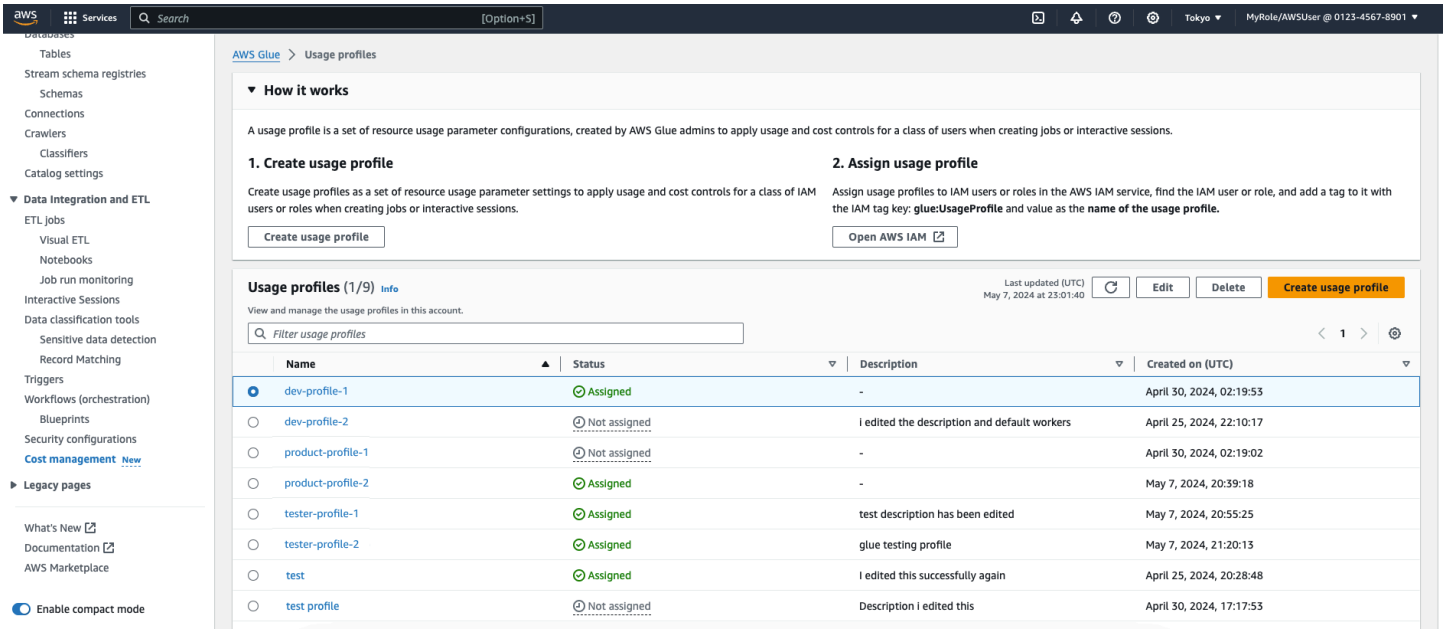

Temas

- Creación y administración de perfiles de uso
- Perfiles de uso y trabajos

Creación y administración de perfiles de uso

Creación de un perfil de uso de AWS Glue

Los administradores deben crear perfiles de uso y, luego, asignarlos a los distintos usuarios. Durante la creación de un perfil de uso, debe especificar los valores predeterminados, así como un rango de valores permitidos para varios parámetros de trabajo y sesión. Debe configurar al menos un parámetro para trabajos o sesiones interactivas. Puede personalizar el valor predeterminado que se utilizará cuando no se proporcione un valor de parámetro para el trabajo o configurar un límite de rango o un conjunto de valores permitidos para la validación si un usuario proporciona un valor de parámetro al usar este perfil.

Los valores predeterminados son una práctica recomendada que el administrador establece para ayudar a los autores de los trabajos. Cuando un usuario cree un nuevo trabajo y no establezca un valor de tiempo de espera, se aplicará el tiempo de espera predeterminado del perfil de uso. Si el autor no tiene un perfil, se aplicarán los valores predeterminados del servicio de AWS Glue y se guardarán en la definición del trabajo. En el tiempo de ejecución, AWS Glue impone los límites establecidos en el perfil (mínimo, máximo, trabajadores permitidos).

Una vez configurado un parámetro, todos los demás parámetros son opcionales. Los parámetros que se pueden personalizar para los trabajos o las sesiones interactivas son los siguientes:

- Número de trabajadores: restrinja el número de trabajadores para evitar el uso excesivo de los recursos informáticos. Puede establecer un valor predeterminado, mínimo y máximo. El mínimo es 1.
- Tipo de trabajador: restrinja los tipos de trabajadores relevantes para sus cargas de trabajo. Puede establecer un tipo predeterminado y permitir tipos de trabajadores para un perfil de usuario.
- Tiempo de espera: defina el tiempo máximo que un trabajo o una sesión interactiva puede ejecutarse y consumir recursos antes de que finalice. Configure valores de tiempo de espera para evitar trabajos de larga duración.

  Puede establecer un valor predeterminado, mínimo y máximo en minutos. El mínimo es 1 (minuto). Si bien el tiempo de espera predeterminado de AWS Glue es de 2880 minutos, puede establecer cualquier valor predeterminado en el perfil de uso.

  Se recomienda establecer un valor para “predeterminado”. Este valor se utilizará para la creación del trabajo o la sesión si el usuario no estableció ningún valor.

- Tiempo de espera de inactividad: defina el número de minutos que una sesión interactiva permanece inactiva antes de que se agote el tiempo de espera una vez ejecutada una celda. Defina el tiempo de espera de inactividad para que las sesiones interactivas finalicen una vez terminado el trabajo. El rango de tiempo de espera de inactividad debe estar dentro del límite de tiempo de espera.

  Puede establecer un valor predeterminado, mínimo y máximo en minutos. El mínimo es 1 (minuto). Si bien el tiempo de espera predeterminado de AWS Glue es de 2880 minutos, puede establecer cualquier valor predeterminado en el perfil de uso.

  Se recomienda establecer un valor para “predeterminado”. Este valor se utilizará para la creación de la sesión si el usuario no estableció ningún valor.

Para crear un perfil de uso de AWS Glue como administrador (consola)

1. En el menú de navegación izquierdo, elija Administración de costos.
2. Elija Crear perfil de uso.
3. Ingrese el Nombre del perfil de uso para el perfil de uso.
4. Ingrese una descripción opcional que ayude a otras personas a reconocer el propósito del perfil de uso.
5. Defina al menos un parámetro en el perfil. Cualquier campo del formulario es un parámetro. Por ejemplo, el valor mínimo de tiempo de espera de inactividad de la sesión.
6. Defina cualquier etiqueta opcional que se aplique al perfil de uso.
7. Seleccione Save.

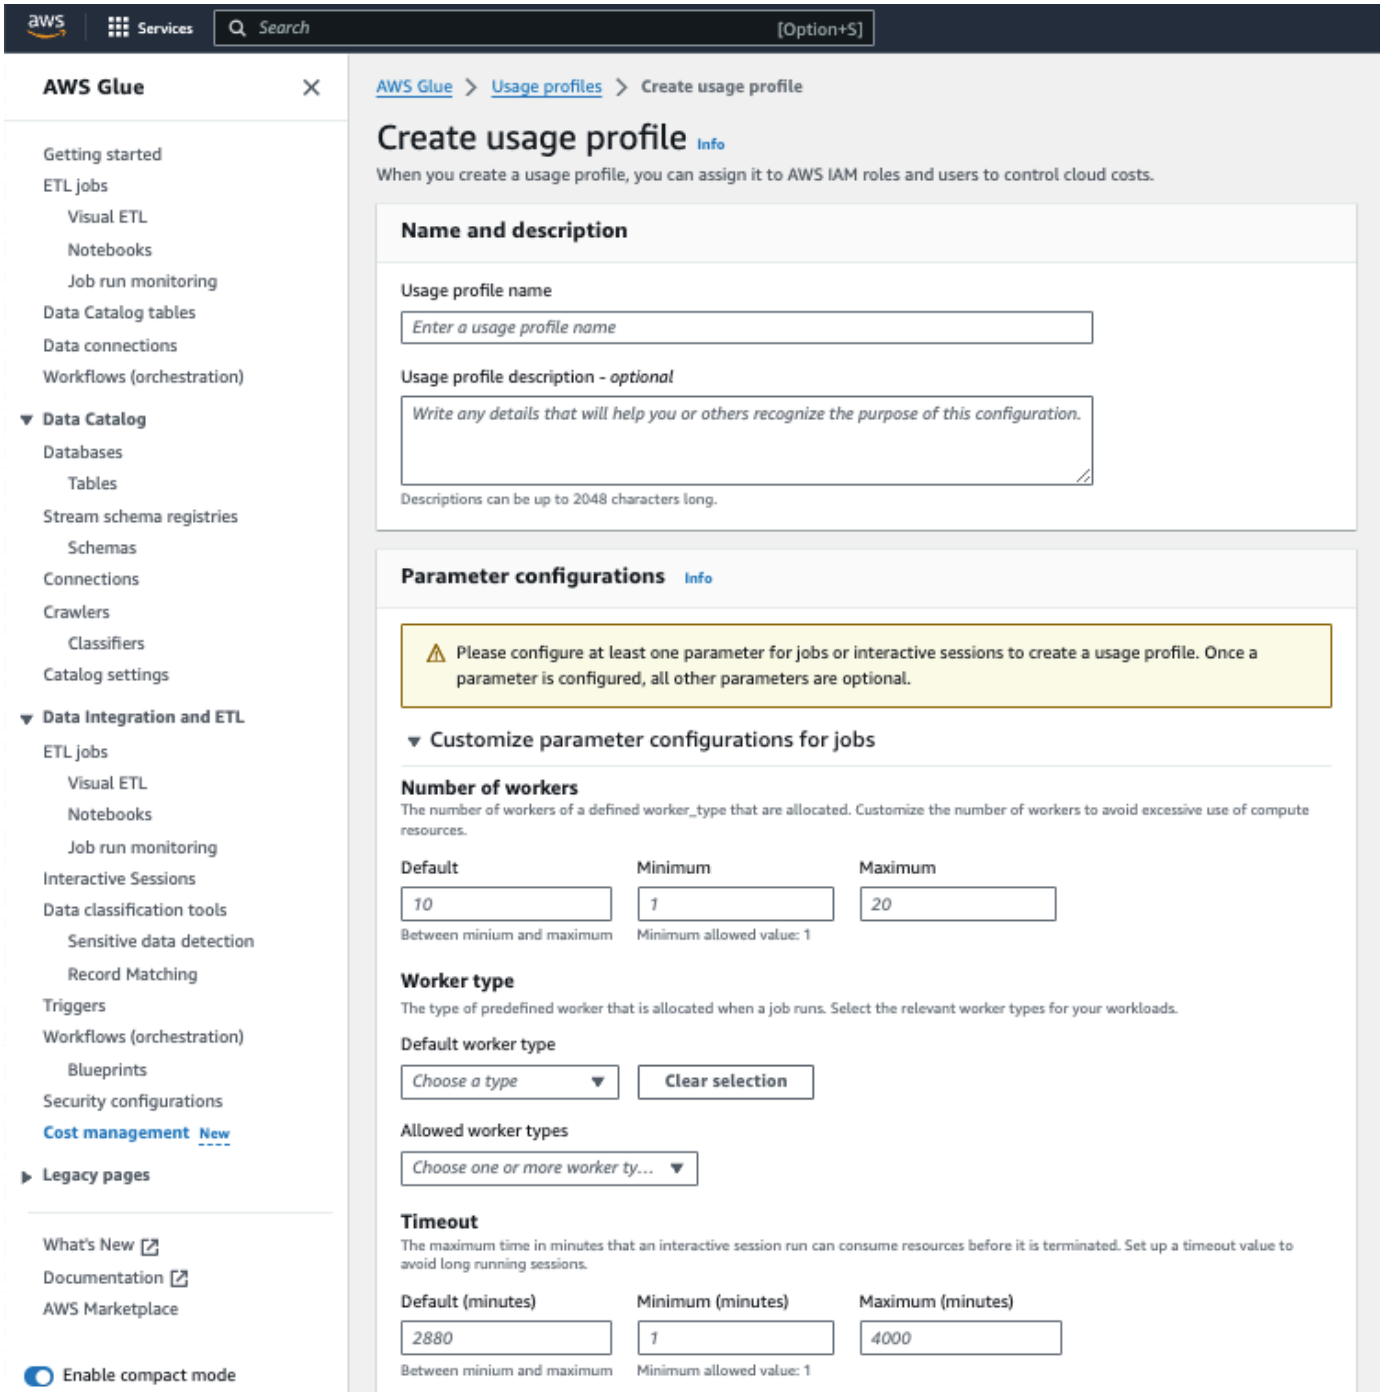

Para crear un perfil de usuario (AWS CLI)

1. Escriba el siguiente comando.

```
aws glue create-usage-profile --name profile-name --configuration file://
config.json --tags list-of-tags
```

donde config.json puede definir valores de parámetros para sesiones interactivas (`SessionConfiguration`) y trabajos (`JobConfiguration`):

```
//config.json (There is a separate blob for session/job configuration
{
    "SessionConfiguration": {
        "timeout": {
            "DefaultValue": "2880",
            "MinValue": "100",
            "MaxValue": "4000"
        },
        "idleTimeout": {
            "DefaultValue": "30",
            "MinValue": "10",
            "MaxValue": "4000"
        },
        "workerType": {
            "DefaultValue": "G.2X",
            "AllowedValues": [
                "G.1X",
                "G.2X",
                "G.4X",
                "G.8X",
                "G.12X",
                "G.16X",
                "R.1X",
                "R.2X",
                "R.4X",
                "R.8X"
            ]
        },
        "numberOfWorkers": {
            "DefaultValue": "10",
            "MinValue": "1",
            "MaxValue": "10"
        }
    },
    "JobConfiguration": {
        "timeout": {
            "DefaultValue": "2880",
            "MinValue": "100",
            "MaxValue": "4000"
```

```
        },
        "workerType": {
            "DefaultValue": "G.2X",
            "AllowedValues": [
                "G.1X",
                "G.2X",
                "G.4X",
                "G.8X",
                "G.12X",
                "G.16X",
                "R.1X",
                "R.2X",
                "R.4X",
                "R.8X"
            ]
        },
        "numberOfWorkers": {
            "DefaultValue": "10",
            "MinValue": "1",
            "MaxValue": "10"
        }
    }
}
```

2. Ingrese el siguiente comando para ver el perfil de uso creado:

```
aws glue get-usage-profile --name profile-name
```

La respuesta:

```
{
    "ProfileName": "foo",
    "Configuration": {
        "SessionConfiguration": {
            "numberOfWorkers": {
                "DefaultValue": "10",
                "MinValue": "1",
                "MaxValue": "10"
            },
            "workerType": {
                "DefaultValue": "G.2X",
                "AllowedValues": [
                    "G.1X",
```

```
                    "G.2X",
                    "G.4X",
                    "G.8X",
                    "G.12X",
                    "G.16X",
                    "R.1X",
                    "R.2X",
                    "R.4X",
                    "R.8X"
                ]
            },
            "timeout": {
                "DefaultValue": "2880",
                "MinValue": "100",
                "MaxValue": "4000"
            },
            "idleTimeout": {
                "DefaultValue": "30",
                "MinValue": "10",
                "MaxValue": "4000"
            }
        },
        "JobConfiguration": {
            "numberOfWorkers": {
                "DefaultValue": "10",
                "MinValue": "1",
                "MaxValue": "10"
            },
            "workerType": {
                "DefaultValue": "G.2X",
                "AllowedValues": [
                    "G.1X",
                    "G.2X",
                    "G.4X",
                    "G.8X",
                    "G.12X",
                    "G.16X",
                    "R.1X",
                    "R.2X",
                    "R.4X",
                    "R.8X"
                ]
            },
            "timeout": {
```

```
                "DefaultValue": "2880",
                "MinValue": "100",
                "MaxValue": "4000"
            }
        }
    },
    "CreatedOn": "2024-01-19T23:15:24.542000+00:00"
}
```

Comandos de CLI adicionales que se utilizan para administrar los perfiles de uso:

- aws glue list-usage-profiles
- aws glue update-usage-profile --name *profile-name* --configuration *file://config.json*
- aws glue delete-usage-profile --name *profile-name*

Edición de un perfil de uso

Los administradores pueden editar los perfiles de uso que hayan creado para cambiar los valores de los parámetros del perfil para los trabajos y las sesiones interactivas.

Para editar un perfil de uso:

Para editar un perfil de uso de AWS Glue como administrador (consola)

1. En el menú de navegación izquierdo, elija Administración de costos.
2. Elija un perfil de uso para el que tenga permisos de edición y seleccione Editar.
3. Realice los cambios necesarios en el perfil. De forma predeterminada, los parámetros que ya tienen valores se expanden.
4. Seleccione Guardar ediciones.

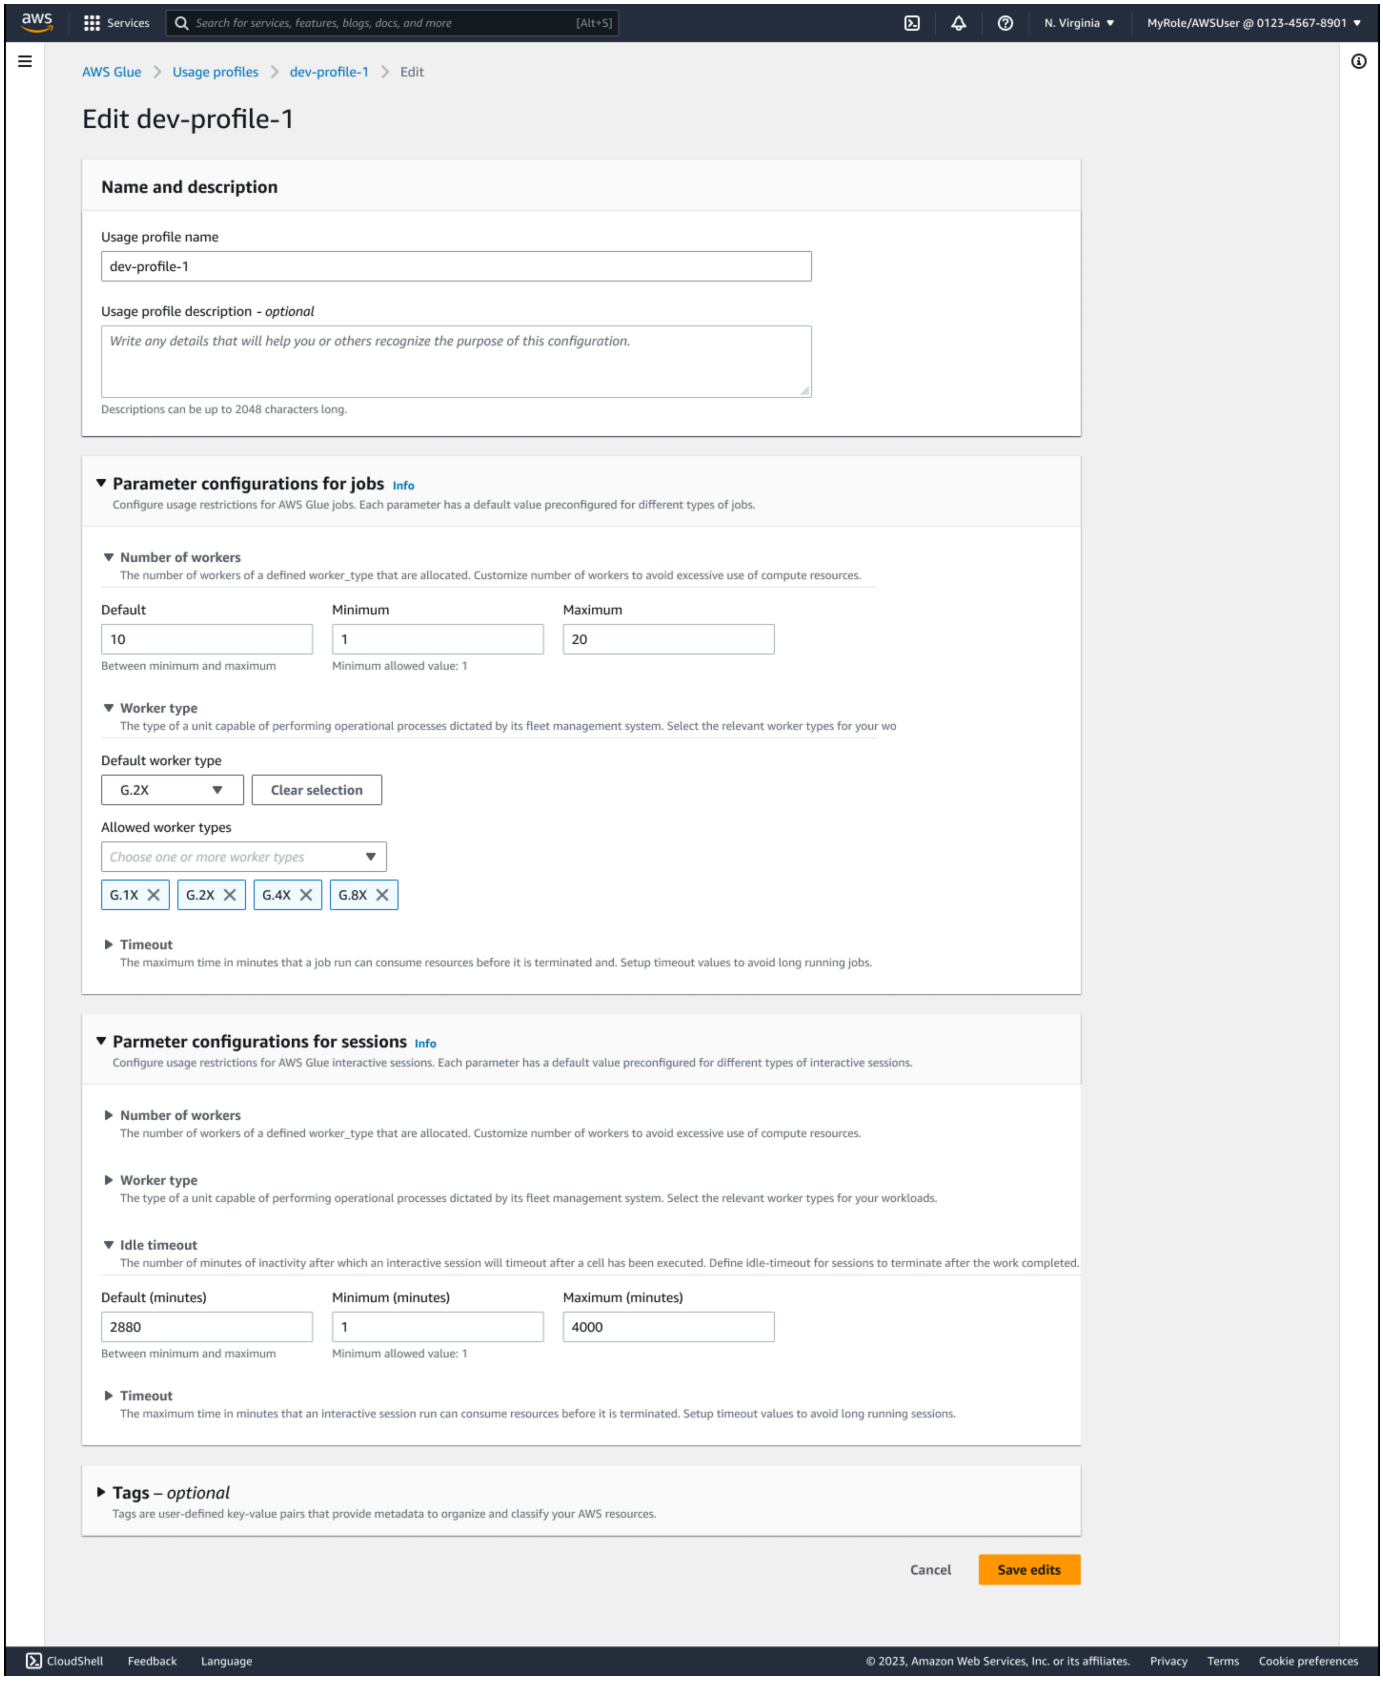
Services
Search for services, features, blogs, docs, and more [Alt+S]
N. Virginia
MyRole/AWSUser @ 0123-4567-8901
AWS Glue > Usage profiles > dev-profile-1 > Edit
Edit dev-profile-1
Name and description
Usage profile name
dev-profile-1
Usage profile description - optional
Write any details that will help you or others recognize the purpose of this configuration.
Descriptions can be up to 2048 characters long.
Parameter configurations for jobs Info
Configure usage restrictions for AWS Glue jobs. Each parameter has a default value preconfigured for different types of jobs.
Number of workers
The number of workers of a defined worker_type that are allocated. Customize number of workers to avoid excessive use of compute resources.
Default
10
Between minimum and maximum
Minimum
1
Minimum allowed value: 1
Maximum
20
Worker type
The type of a unit capable of performing operational processes dictated by its fleet management system. Select the relevant worker types for your wo
Default worker type
G.2X
Clear selection
Allowed worker types
Choose one or more worker types
G.1X
G.2X
G.4X
G.8X
Timeout
The maximum time in minutes that a job run can consume resources before it is terminated and. Setup timeout values to avoid long running jobs.
Parmeter configurations for sessions Info
Configure usage restrictions for AWS Glue interactive sessions. Each parameter has a default value preconfigured for different types of interactive sessions.
Number of workers
The number of workers of a defined worker_type that are allocated. Customize number of workers to avoid excessive use of compute resources.
Worker type
The type of a unit capable of performing operational processes dictated by its fleet management system. Select the relevant worker types for your workloads.
Idle timeout
The number of minutes of inactivity after which an interactive session will timeout after a cell has been executed. Define idle-timeout for sessions to terminate after the work completed.
Default (minutes)
2880
Between minimum and maximum
Minimum (minutes)
1
Minimum allowed value: 1
Maximum (minutes)
4000
Timeout
The maximum time in minutes that an interactive session run can consume resources before it is terminated. Setup timeout values to avoid long running sessions.
Tags – optional
Tags are user-defined key-value pairs that provide metadata to organize and classify your AWS resources.
Cancel
Save edits
CloudShell
Feedback
Language
© 2023, Amazon Web Services, Inc. or its affiliates.
Privacy
Terms
Cookie preferences

Para editar un perfil de uso (AWS CLI)

- Escriba el siguiente comando. Se utiliza la misma sintaxis de archivos de `--configuration` que se muestra arriba en el comando create.

```
aws glue update-usage-profile --name profile-name --configuration file://
config.json
```

  donde config.json define los valores de parámetros para las sesiones interactivas (`SessionConfiguration`) y los trabajos (`JobConfiguration`):

Asignación de un perfil de uso

La columna Estado de uso de la página Perfiles de uso muestra si hay un perfil de uso asignado a los usuarios. Al pasar el ratón sobre el estado, se muestran las entidades de IAM asignadas.

El administrador puede asignar un perfil de uso de AWS Glue a los usuarios o roles que crean recursos de AWS Glue. La asignación de un perfil es una combinación de dos acciones:

- Actualizar la etiqueta de rol o usuario de IAM con la clave de `glue:UsageProfile`.
- Actualizar la política de IAM del rol o usuario.

En el caso de los usuarios que utilizan AWS Glue Studio para crear trabajos o sesiones interactivas, el administrador etiqueta los siguientes roles:

- Para restringir los trabajos, el administrador etiqueta el rol de consola en el que se inició sesión
- Para restringir las sesiones interactivas, el administrador etiqueta el rol que el usuario proporciona cuando crea el bloc de notas

La siguiente es una política de ejemplo que el administrador debe actualizar sobre los roles o usuarios de IAM que crean recursos de AWS Glue:

```
{
    "Effect": "Allow",
    "Action": [
        "glue:GetUsageProfile"
    ],
    "Resource": [
```

```
        "arn:aws:glue:us-east-1:123456789012:usageProfile/foo"
    ]
}
```

AWS Glue valida las solicitudes de trabajo, ejecución y sesión en función de los valores especificados en el perfil de uso de AWS Glue, y genera una excepción si no se permite la solicitud. En el caso de las API sincrónicas, se mostrará un error al usuario. En el caso de las rutas asíncronas, se crea una ejecución de trabajo fallida con el mensaje de error que indica que el parámetro de entrada está fuera del rango permitido para el perfil asignado del usuario o rol.

Para asignar un perfil de uso a un usuario o rol:

1. Abra la consola de IAM (Identity and Access Management).
2. En el panel de navegación izquierdo, elija Usuarios o Roles.
3. Elija un usuario o un rol.
4. Elija la pestaña Etiquetas.
5. Elija Añadir nueva etiqueta
6. Agregue una etiqueta con la clave de `glue:UsageProfile` y el valor del nombre de su perfil de uso.
7. Elija Guardar cambios.

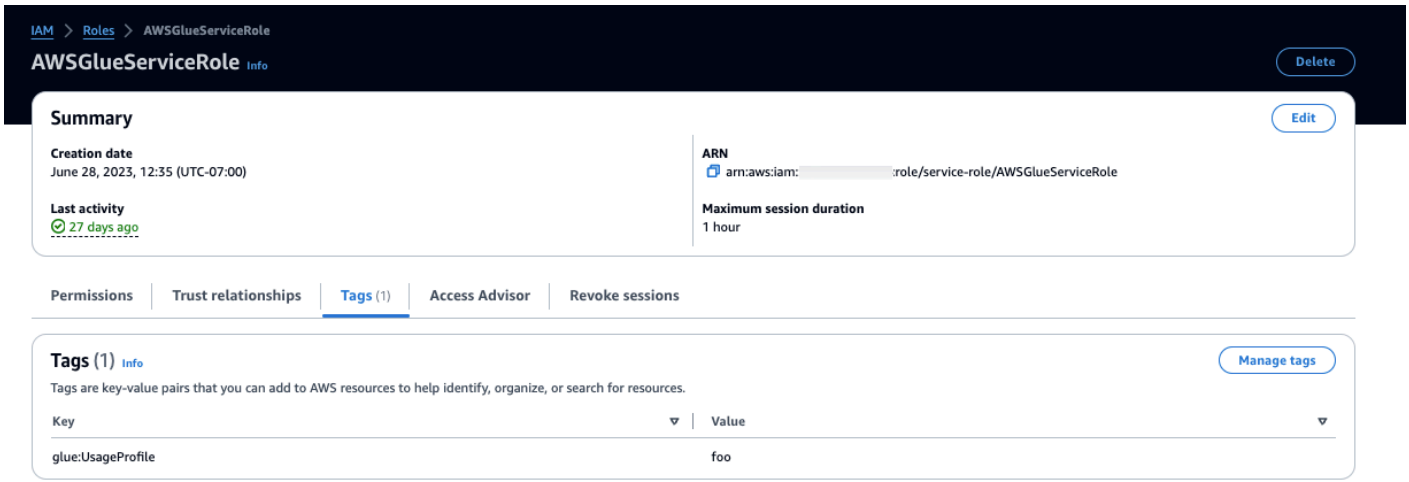

Visualización del perfil de uso asignado

Los usuarios pueden ver sus perfiles de uso asignados y usarlos al realizar llamadas a la API para crear recursos de trabajo y sesión de AWS Glue, o al iniciar un trabajo.

Los permisos de perfil se proporcionan en las políticas de IAM. Siempre que la política de intermediarios tenga el permiso `glue:UsageProfile`, el usuario puede ver el perfil. De lo contrario, aparecerá el error de acceso denegado.

Para ver un perfil de uso asignado:

1. En el menú de navegación izquierdo, elija Administración de costos.
2. Elija un perfil de uso para el que tenga permisos de visualización.

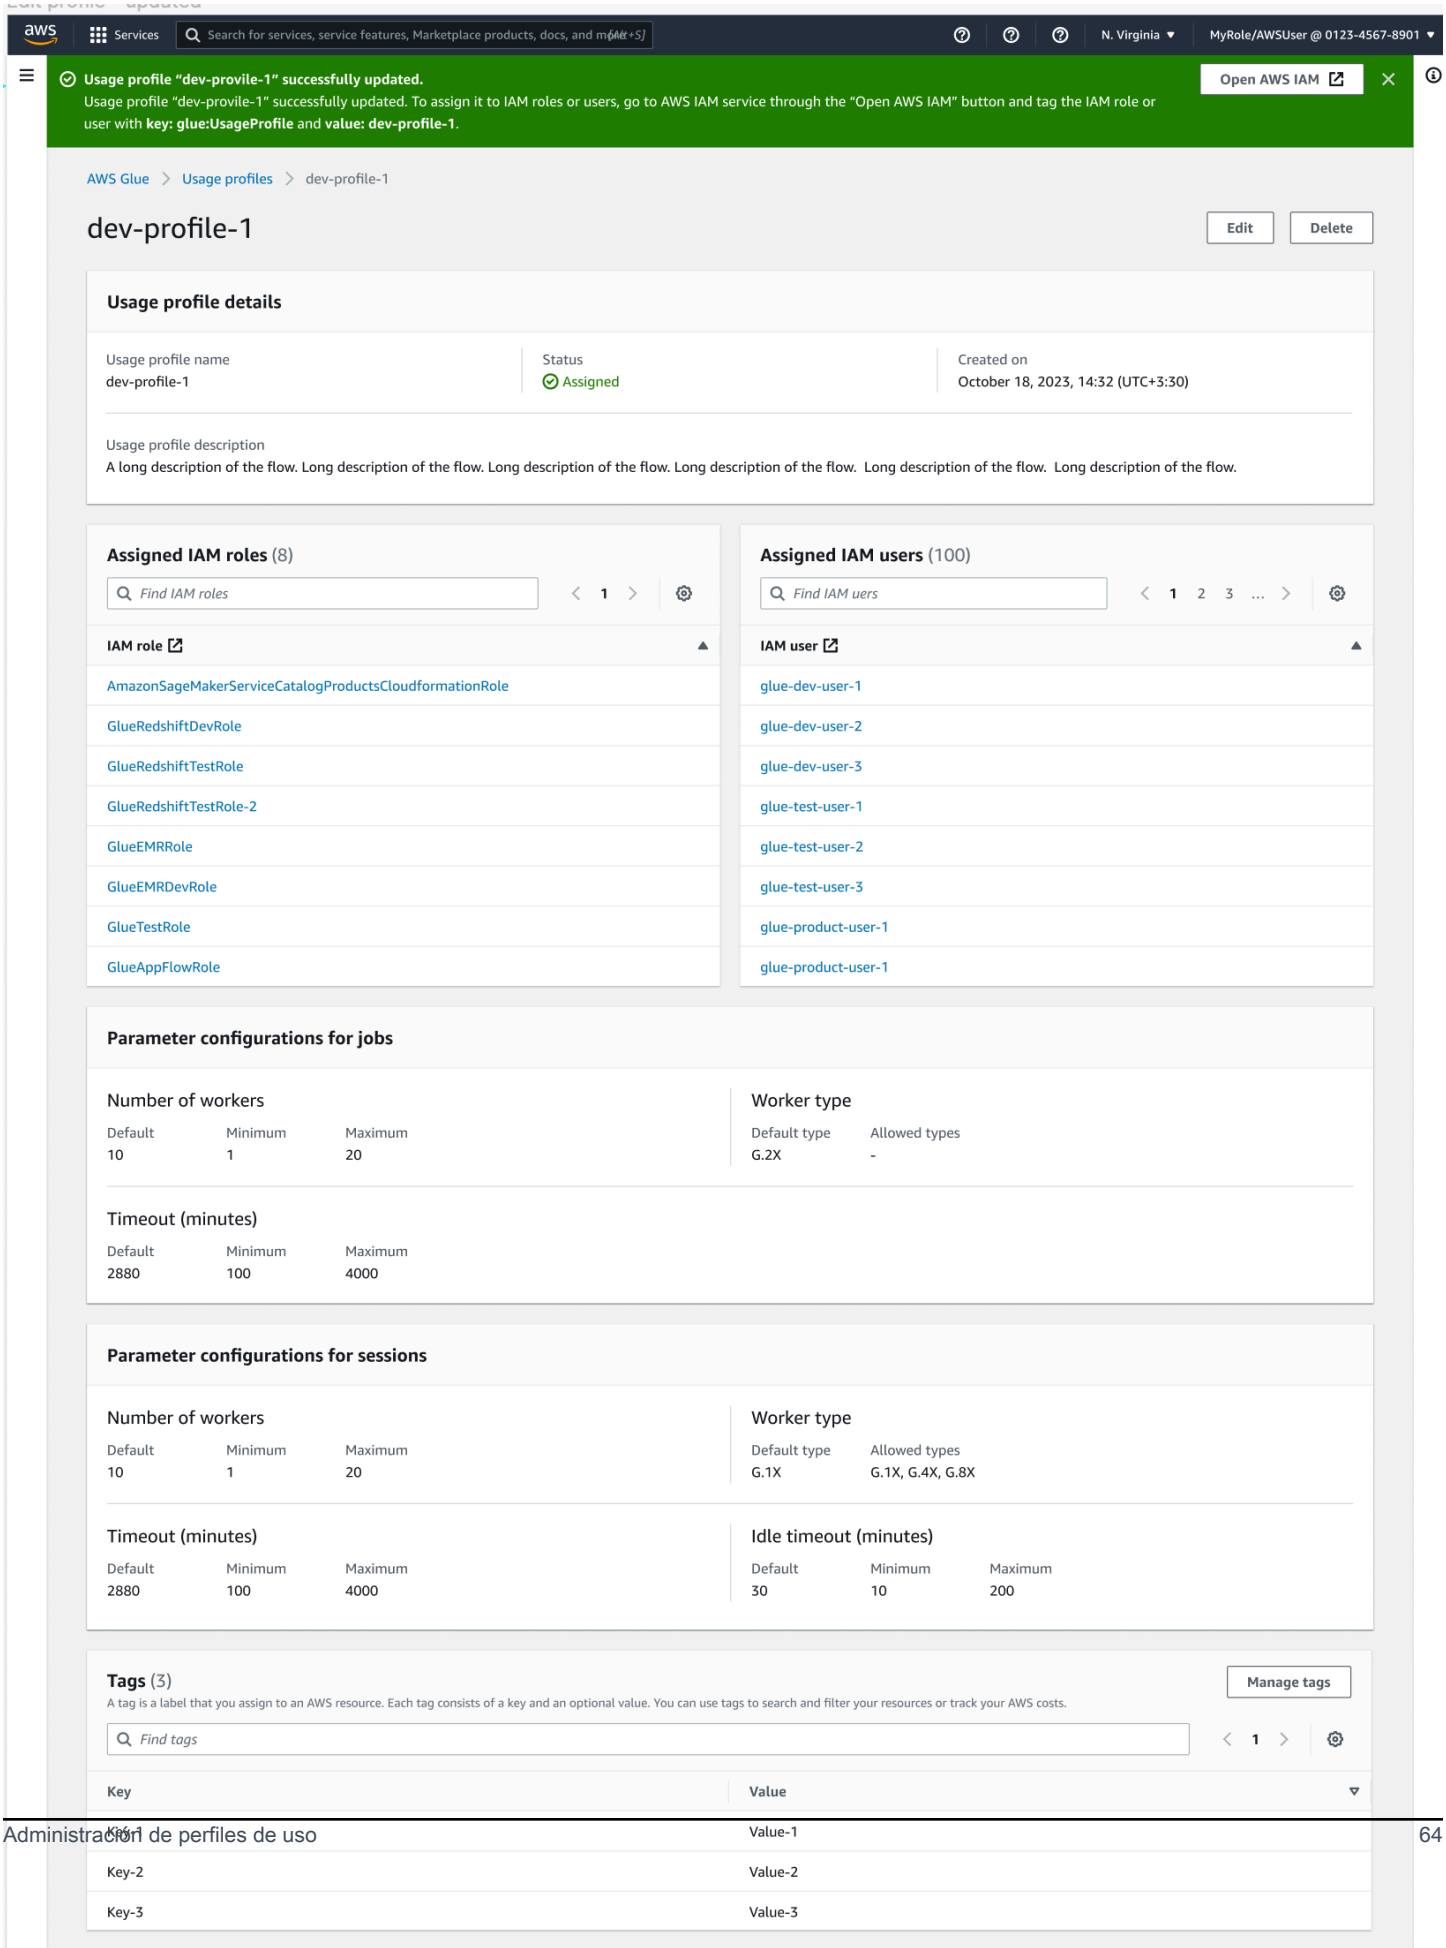
Services
Search for services, service features, Marketplace products, docs, and more [Alt+S]
N. Virginia
MyRole/AWSUser @ 0123-4567-8901
Usage profile "dev-provile-1" successfully updated.
Usage profile "dev-provile-1" successfully updated. To assign it to IAM roles or users, go to AWS IAM service through the "Open AWS IAM" button and tag the IAM role or user with key: glue:UsageProfile and value: dev-profile-1.
Open AWS IAM
AWS Glue > Usage profiles > dev-profile-1
dev-profile-1
Edit
Delete
Usage profile details
Usage profile name
dev-profile-1
Status
Assigned
Created on
October 18, 2023, 14:32 (UTC+3:30)
Usage profile description
A long description of the flow. Long description of the flow. Long description of the flow. Long description of the flow. Long description of the flow. Long description of the flow.
Assigned IAM roles (8)
Find IAM roles
IAM role
AmazonSageMakerServiceCatalogProductsCloudformationRole
GlueRedshiftDevRole
GlueRedshiftTestRole
GlueRedshiftTestRole-2
GlueEMRRole
GlueEMRDevRole
GlueTestRole
GlueAppFlowRole
Assigned IAM users (100)
Find IAM uers
IAM user
glue-dev-user-1
glue-dev-user-2
glue-dev-user-3
glue-test-user-1
glue-test-user-2
glue-test-user-3
glue-product-user-1
glue-product-user-1
Parameter configurations for jobs
Number of workers
Default 10
Minimum 1
Maximum 20
Worker type
Default type G.2X
Allowed types -
Timeout (minutes)
Default 2880
Minimum 100
Maximum 4000
Parameter configurations for sessions
Number of workers
Default 10
Minimum 1
Maximum 20
Worker type
Default type G.1X
Allowed types G.1X, G.4X, G.8X
Timeout (minutes)
Default 2880
Minimum 100
Maximum 4000
Idle timeout (minutes)
Default 30
Minimum 10
Maximum 200
Tags (3)
A tag is a label that you assign to an AWS resource. Each tag consists of a key and an optional value. You can use tags to search and filter your resources or track your AWS costs.
Manage tags
Find tags
Key
Value
Key-1
Value-1
Key-2
Value-2
Key-3
Value-3

Perfiles de uso y trabajos

Creación de trabajos con perfiles de uso

Durante la creación de trabajos, se aplicarán los límites y los valores predeterminados establecidos en su perfil de uso. Su perfil se asignará al trabajo al guardarlo.

Ejecutar trabajos con perfiles de uso

Cuando empieza a ejecutar un trabajo, AWS Glue aplica los límites establecidos en el perfil del intermediario. Si no hay un intermediario directo, Glue aplicará los límites del perfil que el autor asignó al trabajo.

> **Note**
>
> Cuando un trabajo se ejecute de forma programada (mediante flujos de trabajo AWS Glue o desencadenadores AWS Glue), se aplicará el perfil que el autor asignó al trabajo.
> Cuando un servicio externo (Step Functions, MWAA) o una API `StartJobRun` ejecute un trabajo, se aplicará el límite del perfil del intermediario.

En el caso de los flujos de trabajo AWS Glue o desencadenantesAWS Glue: los trabajos preexistentes deben actualizarse para guardar el nombre del nuevo perfil, de modo que los límites del perfil (mínimo, máximo y trabajadores permitidos) se apliquen durante el tiempo de ejecución para las ejecuciones programadas.

Visualización de un perfil de uso asignado a los trabajos

Para ver el perfil asignado a sus trabajos (que se utilizará en tiempo de ejecución con flujos de trabajo AWS Glue o desencadenadores AWS Glue programados), consulte la pestaña Detalles del trabajo. También puede consultar el perfil utilizado en las ejecuciones anteriores en la pestaña de detalles de las ejecuciones de tareas.

Actualización o eliminación de un perfil de uso adjunto a un trabajo

El perfil asignado a un trabajo se modifica al actualizarse. Si al autor no se le asigna un perfil de uso, se eliminará cualquier perfil que se haya adjuntado previamente al trabajo.

Introducción al AWS Glue Data Catalog

El AWS Glue Data Catalog es su almacén de metadatos técnicos persistentes. Se trata de un servicio administrado que puede usar para almacenar, comentar y compartir metadatos en la nube de AWS. Para obtener más información, consulte AWS Glue Data Catalog.

La consola de AWS Glue, junto con algunas interfaces de usuario, se actualizaron recientemente.

Descripción general

Puede usar este tutorial para crear el primer Catálogo de datos de AWS Glue, que utiliza un bucket de Simple Storage Service (Amazon S3) como origen de datos.

En este tutorial, utilizará la consola de AWS Glue para hacer lo siguiente:

1. Crear una base de datos
2. Creación de una tabla
3. Utilizar un bucket de Amazon S3 como origen de datos

Tras completar estos pasos, habrá utilizado correctamente un bucket de Simple Storage Service (Amazon S3) como origen de datos para rellenar el Catálogo de datos de AWS Glue.

Paso 1: Crear una base de datos

Para comenzar, inicie sesión en la Consola de administración de AWS y abra la consola de AWS Glue.

Para crear una base de datos mediante la consola de AWS Glue:

1. En la consola de AWS Glue, elija Databases (Bases de datos) en Data catalog (Catálogo de datos) en el menú de la izquierda.
2. Elija Agregar una base de datos.
3. En la página Crear base de datos, ingrese el nombre de la base de datos. En la sección Ubicación: opcional, establezca la ubicación de la URI para que la usen los clientes del catálogo de datos. Si no sabe esto, puede continuar con la creación de la base de datos.
4. (Opcional). Ingrese la descripción de la base de datos.

5. Elija Creación de base de datos.

Enhorabuena, acaba de configurar su primera base de datos con la consola de AWS Glue. La nueva base de datos aparecerá en la lista de bases de datos disponibles. Puede editar la base de datos eligiendo su nombre en el panel Databases (Bases de datos).

Pasos siguientes

Otras formas de crear una base de datos:

Acaba de crear una base de datos con la consola de AWS Glue, pero hay otras formas de crear una base de datos:

- Puede utilizar rastreadores para crear una base de datos y tablas automáticamente. Para configurar una base de datos mediante rastreadores, consulte Trabajo con rastreadores en la consola de AWS Glue.
- Puede usar plantillas de CloudFormation. Consulte Crear recursos de AWS Glue con plantillas de AWS Glue Data Catalog.
- También puede crear una base de datos mediante las operaciones de la API de base de datos de AWS Glue.

  Para crear una base de datos mediante la operación `create`, se debe estructurar la solicitud mediante la inclusión de los parámetros (obligatorios) de `DatabaseInput`.

  Por ejemplo:

  A continuación, se muestran ejemplos de cómo puede utilizar CLI, Boto3 o DDL para definir una tabla basada en el mismo archivo flights_data.csv del bucket de S3 que utilizó en el tutorial.

  CLI

  ```
  aws glue create-database --database-input "{\"Name\":\"clidb\"}"
  ```

  Boto3

  ```
  glueClient = boto3.client('glue')

  response = glueClient.create_database(
  ```

```
    DatabaseInput={
        'Name': 'boto3db'
    }
)
```

Para obtener más información sobre los tipos de datos, la estructura y las operaciones de la API de la base de datos, consulte API de la base de datos.

Pasos siguientes

En la siguiente sección, creará una tabla y la agregará a la base de datos.

También puede explorar la configuración y los permisos de su Catálogo de datos. Consulte Trabajo con la configuración del Catálogo de datos en la consola de AWS Glue.

Paso 2. Creación de una tabla

En este paso, utilice la consola de AWS Glue para crear una tabla.

1. En la consola de AWS Glue, elija Tables (Tablas) en el menú de la izquierda.
2. Elija Add table (Añadir tabla).
3. Configure las propiedades de la tabla ingresando un nombre para ella en Table details (Detalles de la tabla).
4. En la sección Databases (Bases de datos), elija en el menú desplegable la base de datos que creó en el paso 1.
5. En la sección Add a data store (Agregar un almacén de datos), S3 estará seleccionado de manera predeterminada como tipo de origen.
6. En la sección Data is located in (Los datos se encuentran en), elija Specified path in another account (Ruta especificada en otra cuenta).
7. Copie y pegue la ruta del campo de entrada Include path (Incluir ruta):

   ```
   s3://crawler-public-us-west-2/flight/2016/csv/
   ```
8. En la sección Data format (Formato de datos), para Classification (Clasificación), elija CSV, y para Delimiter (Delimitador), comma (,) (coma [,]). Elija Siguiente.
9. Tendrá que definir un esquema. Un esquema define la estructura y el formato de un registro de datos. Elija Add column (Agregar columna). (Para obtener más información, consulte Schema registries [Registros de esquemas]).

10. Especifique las propiedades de columna:

    a. Ingrese un nombre de columna.

    b. Para Column type (Tipo de columna), 'cadena' ya está seleccionada de forma predeterminada.

    c. Para Column number (Número de columna), '1' ya está seleccionado de forma predeterminada.

    d. Elija Agregar.

11. Tendrá que agregar índices de partición. Es opcional. Para omitir este paso, elija Next (Siguiente).

12. Se muestra un resumen de las propiedades de la tabla. Si todo está correcto, seleccione Crear. En caso contrario, elija Back (Volver) y edite según sea necesario.

Enhorabuena, ha creado correctamente una tabla de forma manual y la ha asociado a una base de datos. La tabla recién creada aparecerá en el panel de tablas. En el panel, puede administrar y modificar todas sus tablas.

Para obtener más información, consulte Trabajo con tablas en la consola de AWS Glue.

Pasos a seguir a continuación

Pasos siguientes

Ahora que hemos rellenado el Catálogo de datos, puede comenzar a crear trabajos en AWS Glue. Consulte Creación de trabajos visuales de ETL con AWS Glue Studio.

Además de utilizar la consola, hay otras formas de definir tablas en el Catálogo de datos, entre ellas:

- Creating and running a crawler (Creación y puesta en marcha de un rastreador)
- Adición de clasificadores a un rastreador en AWS Glue
- Uso de la API de tabla de AWS Glue
- Uso de la plantilla de AWS Glue Data Catalog
- Migrating an Apache Hive metastore (Migración de un meta-almacén de Apache Hive)
- Uso de AWS CLI, Boto3 o lenguaje de definición de datos (DDL)

  A continuación, se muestran ejemplos de cómo puede utilizar CLI, Boto3 o DDL para definir una tabla basada en el mismo archivo flights_data.csv del bucket de S3 que utilizó en el tutorial.

Consulte la documentación sobre cómo estructurar un comando AWS CLI. El ejemplo de CLI contiene la sintaxis JSON para el valor “aws glue create-table --table-input”.

CLI

```
{
        "Name": "flights_data_cli",
        "StorageDescriptor": {
            "Columns": [
                {
                    "Name": "year",
                    "Type": "bigint"
                },
                {
                    "Name": "quarter",
                    "Type": "bigint"
                }
            ],
            "Location": "s3://crawler-public-us-west-2/flight/2016/csv",
            "InputFormat": "org.apache.hadoop.mapred.TextInputFormat",
            "OutputFormat":
 "org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat",
            "Compressed": false,
            "NumberOfBuckets": -1,
            "SerdeInfo": {
                "SerializationLibrary":
 "org.apache.hadoop.hive.serde2.lazy.LazySimpleSerDe",
                "Parameters": {
                    "field.delim": ",",
                    "serialization.format": ","
                }
            }
        },
        "PartitionKeys": [
            {
                "Name": "mon",
                "Type": "string"
            }
        ],
        "TableType": "EXTERNAL_TABLE",
        "Parameters": {
            "EXTERNAL": "TRUE",
            "classification": "csv",
```

```
            "columnsOrdered": "true",
            "compressionType": "none",
            "delimiter": ",",
            "skip.header.line.count": "1",
            "typeOfData": "file"
        }
    }
```

Boto3

```
import boto3

glue_client = boto3.client("glue")

response = glue_client.create_table(
    DatabaseName='sampledb',
    TableInput={
        'Name': 'flights_data_manual',
    'StorageDescriptor': {
      'Columns': [{
        'Name': 'year',
        'Type': 'bigint'
      }, {
        'Name': 'quarter',
        'Type': 'bigint'
      }],
      'Location': 's3://crawler-public-us-west-2/flight/2016/csv',
      'InputFormat': 'org.apache.hadoop.mapred.TextInputFormat',
      'OutputFormat':
 'org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat',
      'Compressed': False,
      'NumberOfBuckets': -1,
      'SerdeInfo': {
        'SerializationLibrary':
 'org.apache.hadoop.hive.serde2.lazy.LazySimpleSerDe',
        'Parameters': {
          'field.delim': ',',
          'serialization.format': ','
        }
      },
    },
    'PartitionKeys': [{
```

```
      'Name': 'mon',
      'Type': 'string'
    }],
    'TableType': 'EXTERNAL_TABLE',
    'Parameters': {
      'EXTERNAL': 'TRUE',
      'classification': 'csv',
      'columnsOrdered': 'true',
      'compressionType': 'none',
      'delimiter': ',',
      'skip.header.line.count': '1',
      'typeOfData': 'file'
    }
    }
)
```

DDL

```
CREATE EXTERNAL TABLE `sampledb`.`flights_data` (
  `year` bigint,
  `quarter` bigint)
PARTITIONED BY (
  `mon` string)
ROW FORMAT DELIMITED
  FIELDS TERMINATED BY ','
STORED AS INPUTFORMAT
  'org.apache.hadoop.mapred.TextInputFormat'
OUTPUTFORMAT
  'org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat'
LOCATION
  's3://crawler-public-us-west-2/flight/2016/csv/'
TBLPROPERTIES (
  'classification'='csv',
  'columnsOrdered'='true',
  'compressionType'='none',
  'delimiter'=',',
  'skip.header.line.count'='1',
  'typeOfData'='file')
```

Configuración del acceso de red a los almacenes de datos

Para ejecutar sus trabajos de extracción, transformación y carga (ETL), AWS Glue debe tener la posibilidad de obtener acceso a los almacenes de datos. Si un trabajo no necesita ejecutarse en la subred de la nube privada virtual (VPC); por ejemplo, transformar datos de Amazon S3 a Amazon S3, no se necesita una configuración adicional.

Si un trabajo debe ejecutarse en la subred de VPC, por ejemplo, deben transformarse datos de un almacén de datos de JDBC en una subred privada, AWS Glue configura interfaces de red elásticas que permiten que sus trabajos se conecten de forma segura con otros recursos dentro de la VPC. A cada interfaz de red elástica se le asigna una dirección IP privada del intervalo de direcciones IP de la subred especificada. No se asignan direcciones IP públicas. Los grupos de seguridad especificados en la conexión AWS Glue se aplican en cada una de las interfaces de red elásticas. Para obtener más información, consulte Configuración de Amazon VPC para conexiones JDBC a los almacenes de datos de Amazon RDS de AWS Glue.

Todos los almacenes de datos JDBC a los obtiene acceso el flujo de trabajo deben estar disponibles a partir de la subred VPC. Para obtener acceso a Amazon S3 desde su VPC, se requiere un punto de enlace de la VPC. Si su trabajo necesita obtener acceso a los recursos de la VPC y a la red pública de Internet, la VPC debe tener una gateway de NAT (traducción de direcciones de red) dentro de la VPC.

Un flujo de trabajo o punto de enlace de desarrollo solo puede obtener acceso a una VPC (y subred) a la vez. Si necesita obtener acceso a almacenes de datos en diferentes VPC, dispone de las siguientes opciones:

- Utilice las interconexiones de la VPC para obtener acceso a los almacenes de datos. Para obtener más información acerca de las interconexiones de VPC, consulte Conceptos básicos de las interconexiones de VPC
- Utilice un bucket de Amazon S3 como ubicación de almacenamiento intermediaria. Divida el flujo de trabajo en dos trabajos, con la salida de Amazon S3 del trabajo 1 como entrada del trabajo 2.

Para obtener más información sobre cómo conectarse a un almacén de datos de Amazon Redshift a través de Amazon VPC, consulte the section called “Configurar Redshift”.

Para obtener más información sobre cómo conectarse a los almacenes de datos de Amazon RDS a través de Amazon VPC, consulte the section called “Configuración de Amazon VPC para conectarse a los almacenes de datos de Amazon RDS”.

Una vez establecidas las reglas necesarias en Amazon VPC, debe crear una conexión en AWS Glue con las propiedades necesarias para conectarse a sus almacenes de datos. Para obtener más información sobre la conexión, consulte Conexión a datos.

> **Note**
>
> Asegúrese de que configure su entorno de DNS para AWS Glue. Para obtener más información, consulte Configuración de DNS en la VPC.

Temas

- Configuración de una VPC para conectarse a PyPI para AWS Glue
- Configuración de DNS en la VPC

Configuración de una VPC para conectarse a PyPI para AWS Glue

El Python Package Index (PyPI) es un repositorio de software para el lenguaje de programación Python. En este tema se abordan los detalles necesarios para admitir el uso de paquetes instalados por pip (según lo especificado por el creador de la sesión mediante la marca `--additional-python-modules`).

El uso de sesiones AWS Glue interactivas con un conector implica el uso de la red de VPC a través de la subred especificada para el conector. Por lo tanto, los servicios de AWS y otros destinos de red no están disponibles a menos que se establezca una configuración especial.

Las soluciones a este problema incluyen:

- Uso de una puerta de enlace de Internet a la que pueda acceder su sesión.
- Configuración y uso de un bucket de S3 con un repositorio PyPI/Simple que contiene el cierre transitivo de las dependencias de un conjunto de paquetes.
- Uso de un repositorio CodeArtifact que refleje PyPI y esté conectado a su VPC.

Configuración de una puerta de enlace de Internet

Los aspectos técnicos se detallan en los Casos de uso de la puerta de enlace NAT, pero tenga en cuenta estos requisitos al utilizar `--additional-python-modules`. En concreto, `--`

`additional-python-modules` requiere acceso a pypi.org, que viene determinado por la configuración de su VPC. Tenga en cuenta los siguientes requisitos:

1. El requisito de instalar módulos de Python adicionales mediante pip install para la sesión de un usuario. Si la sesión usa un conector, su configuración puede verse afectada.
2. Cuando se utiliza un conector con `--additional-python-modules`, al iniciar la sesión, la subred asociada al `PhysicalConnectionRequirements` del conector debe proporcionar una ruta de red para llegar a pypi.org.
3. Debe determinar si su configuración es correcta o no.

Configuración de un bucket de Amazon S3 para alojar un repositorio de PyPI/Simple de destino

En este ejemplo, se configura una réplica de PyPI en Amazon S3 para un conjunto de paquetes y sus dependencias.

Para configurar la réplica PyPI para un conjunto de paquetes:

```
# pip download all the dependencies
pip download -d s3pypi --only-binary :all: plotly gglplot
pip download -d s3pypi --platform manylinux_2_17_x86_64 --only-binary :all: psycopg2-
binary
# create and upload the pypi/simple index and wheel files to the s3 bucket
s3pypi -b test-domain-name --put-root-index -v s3pypi/*
```

Si ya tienes un repositorio de artefactos existente, tendrá una URL de índice para que pip la use y que podrás proporcionar en lugar de la URL de ejemplo para el bucket de Amazon S3, como se indica anteriormente.

Para usar la URL de índice personalizada, con algunos paquetes de ejemplo:

```
%%configure
{
    "--additional-python-modules": "psycopg2_binary==2.9.5",
    "python-modules-installer-option": "--no-cache-dir --verbose --index-url https://
test-domain-name.s3.amazonaws.com/ --trusted-host test-domain-name.s3.amazonaws.com"
}
```

Configuración de una réplica CodeArtifact de pypi conectada a su VPC

Para configurar un espejo:

1. Cree un repositorio en la misma región que la subred utilizada por el conector.

   Seleccione `Public upstream repositories` y elija `pypi-store`.
2. Proporcione acceso al repositorio desde la VPC de la subred.
3. Especifique la correcta `--index-url` mediante `python-modules-installer-option`.

```
%%configure
{
    "--additional-python-modules": "psycopg2_binary==2.9.5",
    "python-modules-installer-option": "--no-cache-dir --verbose --index-url https://
test-domain-name.s3.amazonaws.com/ --trusted-host test-domain-name.s3.amazonaws.com"
}
```

Para obtener más información, consulte Usar CodeArtifact desde una VPC.

Configuración de DNS en la VPC

El sistema de nombres de dominio (DNS) es un estándar mediante el cual los nombres utilizados en Internet se resuelven a sus direcciones IP correspondientes. Un nombre de host de DNS designa a un equipo de forma exclusiva y se compone de un nombre de host y un nombre de dominio. Los servidores DNS resuelven los nombres de host DNS a sus direcciones IP correspondientes.

Para configurar DNS en la VPC, asegúrese de que tanto los nombres de host de DNS, como la resolución de DNS están habilitados en la VPC. Los atributos de red de VPC `enableDnsHostnames` y `enableDnsSupport` deben establecerse en `true`. Para ver y modificar estos atributos, vaya a la consola de la VPC en https://console.aws.amazon.com/vpc/.

Para obtener más información, consulte Utilización de DNS con su VPC. Además, puede utilizar AWS CLI y llamar al comando modify-vpc-attribute para configurar los atributos de red de VPC.

> **Note**
>
> Si utiliza Route 53, confirme que la configuración no sustituye los atributos de red de DNS.

Configuración del cifrado en AWS Glue

En el siguiente flujo de trabajo de ejemplo se resaltan las opciones que se deben configurar al utilizar el cifrado con AWS Glue. El ejemplo ilustra el uso de claves de AWS Key Management Service (AWS KMS) específicas, pero puede elegir otras configuraciones en función de sus necesidades particulares. Este flujo de trabajo destaca solo las opciones que atañen al cifrado a la hora de configurar AWS Glue.

1. Si el usuario de la consola de AWS Glue no utiliza una política de permisos que permita todas las operaciones de la API de AWS Glue (por ejemplo, `"glue:*"`), confirme que las siguientes acciones están permitidas:
   - `"glue:GetDataCatalogEncryptionSettings"`
   - `"glue:PutDataCatalogEncryptionSettings"`
   - `"glue:CreateSecurityConfiguration"`
   - `"glue:GetSecurityConfiguration"`
   - `"glue:GetSecurityConfigurations"`
   - `"glue:DeleteSecurityConfiguration"`
2. Cualquier cliente que obtenga acceso a un catálogo de cifrado o escriba en él, es decir, cualquier usuario de la consola, rastreador, trabajo o punto de enlace de desarrollo, necesitará los siguientes permisos.
3. Cualquier usuario o rol que obtenga acceso a una contraseña de conexión cifrada necesitará los siguientes permisos:
4. El rol de cualquier trabajo de extracción, transformación y carga (ETL) que escriba datos cifrados en Amazon S3 necesitará los siguientes permisos.

   JSON

```
{
  "Version":"2012-10-17",
  "Statement": {
    "Effect": "Allow",
    "Action": [
      "kms:Decrypt",
      "kms:Encrypt",
      "kms:GenerateDataKey"
    ],
    "Resource": "arn:aws:kms:us-east-1:111122223333:key/key-id"
```

```
    }
}
```

5. Cualquier rastreador o trabajo de ETL que escriba Registros de Amazon CloudWatch cifrados necesitará los siguientes permisos en la política de claves y las políticas de IAM.

   En la política de claves (no en la política de IAM):

```
{
  "Effect": "Allow",
  "Principal": {
   "Service": "logs.region.amazonaws.com"
  },
  "Action": [
   "kms:Encrypt*",
   "kms:Decrypt*",
   "kms:ReEncrypt*",
   "kms:GenerateDataKey*",
   "kms:Describe*"
  ],
  "Resource": "<arn of key used for ETL/crawler cloudwatch encryption>"
 }
```

   Para obtener más información acerca de las políticas de claves, consulte Uso de las políticas de claves en AWS KMS en la Guía para desarrolladores de AWS Key Management Service.

   En la política de IAM, adjunte el permiso de `logs:AssociateKmsKey`:

```
{
  "Effect": "Allow",
  "Principal": {
   "Service": "logs.region.amazonaws.com"
  },
  "Action": [
   "logs:AssociateKmsKey"
  ],
  "Resource": "<arn of key used for ETL/crawler cloudwatch encryption>"
 }
```

6. Cualquier flujo de trabajo de ETL que utilice un marcador de trabajo cifrado necesitará los siguientes permisos:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": {
    "Effect": "Allow",
    "Action": [
      "kms:Decrypt",
      "kms:Encrypt"
    ],
    "Resource": "arn:aws:kms:us-east-1:111122223333:key/*"
  }
}
```

7. En la consola de AWS Glue, elija Settings (Configuración) en el panel de navegación.
   a. En la página Data catalog settings (Configuración del Data Catalog), cifre su Data Catalog al seleccionar Metadata encryption (Cifrado de metadatos). Esta opción cifra todos los objetos del Data Catalog con la clave AWS KMS que usted elija.
   b. Para AWS KMS key (Clave KMS), elija aws/glue. También puede elegir una clave AWS KMS que haya creado.

> **Important**
>
> AWS Glue solo soporta claves maestras de cliente (CMK) simétricas. La lista de AWS KMS key (Clave KMS) muestra únicamente claves simétricas. Sin embargo, si selecciona Choose a AWS KMS key ARN (Elegir un ARN de clave KMS), la consola le permite introducir un ARN para cualquier tipo de clave. Asegúrese de introducir sólo ARN para claves simétricas.

   Cuando el cifrado está habilitado, el cliente que accede a Data Catalog debe tener permisos de AWS KMS.

8. En el panel de navegación, seleccione Security configurations (Configuraciones de seguridad). Una configuración de seguridad es un conjunto de propiedades de seguridad que se pueden usar para configurar procesos de AWS Glue. A continuación, elija Add security configuration (Agregar configuración de seguridad). En la configuración, elija cualquiera de las siguientes opciones:
   a. Seleccione S3 encryption (Cifrado de S3). Para Encryption mode (Modo de cifrado), seleccione SSE-KMS. Para la AWS KMS key (Clave de), elija aws/s3 (asegúrese de que el usuario tiene

permiso para usar esta clave). Esto permite a los datos escritos por el trabajo en Amazon S3, utilizar la clave AWS KMS de AWS Glue administrada por AWS.

b. Seleccione CloudWatch logs encryption (Cifrado de registros de Cloudwatch) y una CMK. (Asegúrese de que el usuario tenga permiso para usar esta clave). Para obtener más información, consulte Cifrar datos de registro en CloudWatch Logs mediante AWS KMS en la Guía para desarrolladores de AWS Key Management Service.

> **Important**
>
> AWS Glue solo soporta claves maestras de cliente (CMK) simétricas. La lista de AWS KMS key (Clave KMS) muestra únicamente claves simétricas. Sin embargo, si selecciona Choose a AWS KMS key ARN (Elegir un ARN de clave KMS), la consola le permite introducir un ARN para cualquier tipo de clave. Asegúrese de introducir sólo ARN para claves simétricas.

c. Seleccione Advanced properties (Propiedades avanzadas) y Job bookmark encryption (Cifrado de marcador de trabajos). Para la AWS KMS key (Clave de), elija aws/glue (asegúrese de que el usuario tiene permiso para usar esta clave). Esto permite el cifrado de marcadores de trabajo escritos en Amazon S3 con la clave AWS KMS de AWS Glue.

9. En el panel de navegación, elija Connections (Conexiones).
   a. Seleccione Add connection (Agregar conexión) para crear una conexión al almacén de datos de Java Database Connectivity (JDBC) que es el destino de su flujo de trabajo de ETL.
   b. Para forzar el uso del cifrado de Capa de conexión segura (SSL), seleccione Require SSL connection (Exigir conexión SSL) y pruebe la conexión.
10. En el panel de navegación, seleccione Trabajos.
    a. Seleccione Add job (Añadir trabajo) para crear una flujo de trabajo que transforma los datos.
    b. En la definición de trabajo, elija la configuración de seguridad que ha creado.
11. En la consola de AWS Glue, ejecute el flujo de trabajo bajo demanda. Compruebe que todos los datos de Amazon S3 escritos por el trabajo, los CloudWatch Logs escritos por el trabajo y los marcadores de trabajo están cifrados.

Configuración de redes para el desarrollo de AWS Glue

Para ejecutar sus scripts del servicio ETL (extracción, transformación y carga) con AWS Glue, puede desarrollar y probar sus scripts mediante un punto de conexión de desarrollo. Los trabajos de

la versión 2.0 de AWS Glue no soportan el uso de puntos de enlace desarrollo. Para las versiones 2.0 y posteriores, el método de desarrollo preferido es utilizar el bloc de notas de Jupyter con uno de los kernel de AWS Glue. Para obtener más información, consulte the section called “Introducción a las sesiones interactivas de AWS Glue”.

Configuración de su red para un punto de conexión de desarrollo

Cuando configura un punto de enlace de desarrollo, debe especificar una nube virtual privada (VPC), una subred y los grupos de seguridad.

> **Note**
>
> Asegúrese de que configure su entorno de DNS para AWS Glue. Para obtener más información, consulte Configuración de DNS en la VPC.

Para que AWS Glue pueda obtener acceso a los recursos necesarios, agregue una fila a su tabla de ruta de la subred para asociar una lista de prefijos para Amazon S3 al punto de enlace de la VPC. Se necesita un ID de lista de prefijo para crear una regla de grupo de seguridad saliente que permita al tráfico de una VPC obtener acceso a un servicio de AWS a través de un punto de conexión de la VPC. Para facilitar la conexión a un servidor de blocs de notas que esté asociado a este punto de enlace de desarrollo, en el equipo local agregue una fila a la tabla de ruta para incorporar un ID de gateway de Internet. Para obtener más información, consulte Puntos de conexión de la VPC. Actualice las rutas de subred para que sean similares a la siguiente tabla:

Destino	Objetivo		
10.0.0.0/16	local		
pl-id para Amazon S3	vpce-id		
0.0.0.0/0	igw-xxxx		

Para que AWS Glue pueda comunicarse entre sus componentes, especifique un grupo de seguridad con una regla de entrada con autorreferencia para todos los puertos TCP. Si crea una regla de entrada con autorreferencia, puede restringir el origen al mismo grupo de seguridad de la VPC y no está abierto a todas las redes. Puede que el grupo de seguridad predeterminado de la VPC ya tenga una regla de entrada con autorreferencia para ALL Traffic.

Para configurar un grupo de seguridad

1. Inicie sesión en la Consola de administración de AWS y abra la consola de Amazon EC2 en https://console.aws.amazon.com/ec2/.
2. En el panel de navegación izquierdo, elija Security Groups.
3. Elija un grupo de seguridad ya existente en la lista o seleccione Create Security Group (Crear grupo de seguridad) para usarlo con el punto de enlace de desarrollo.
4. En el panel del grupo de seguridad, vaya a la pestaña Inbound (Entrante).
5. Añada una regla con autorreferencia para que los componentes de AWS Glue puedan comunicarse. En concreto, añada o confirme que hay una regla con Type (Tipo) `All TCP`, Protocol (Protocolo) `TCP`, Port Range (Intervalo de puertos) con todos los puertos y el Source (Origen) con el mismo nombre de grupo de seguridad que Group ID (ID de grupo).

   La regla de entrada tiene un aspecto similar al siguiente:

Tipo	Protocolo	Intervalo de puertos	Origen
Todos los TCP	TCP	0–65535	*security-group*

   A continuación se muestra un ejemplo de una regla de entrada con autorreferencia:

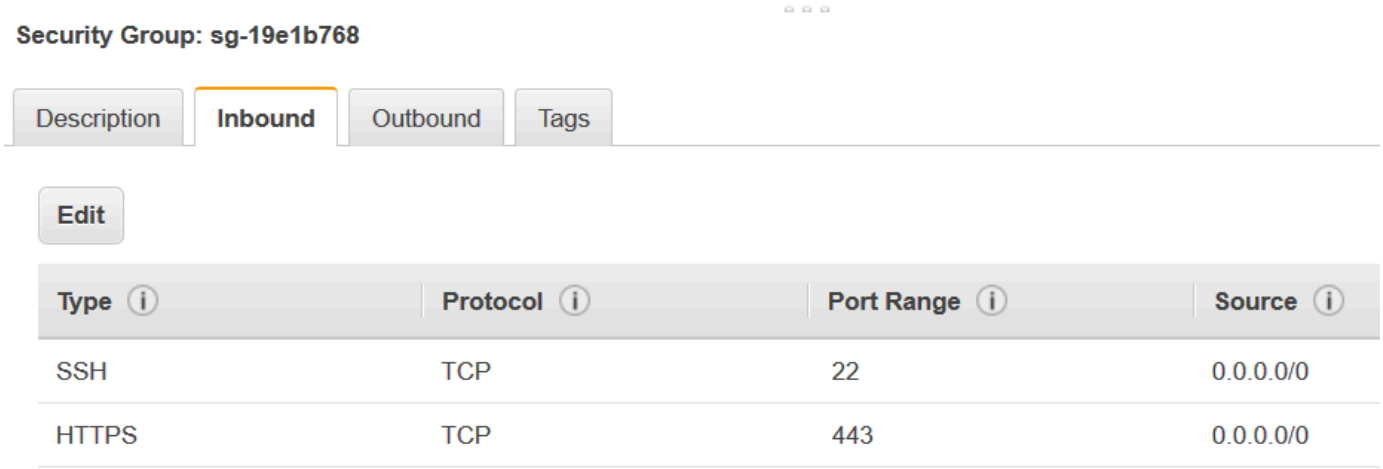

6. Añada también una regla para el tráfico saliente. Abra el tráfico saliente a todos los puertos o cree una regla con autorreferencia de Type (Tipo) `All TCP`, Protocol (Protocolo) `TCP`, Port Range (Intervalo de puertos) con todos los puertos y el Source (Origen) con el mismo nombre de grupo de seguridad que Group ID (ID de grupo).

La regla de salida será similar a una de estas reglas:

Tipo	Protocolo	Rango de puerto	Destino
Todos los TCP	TCP	0–65535	*security-group*
All Traffic	ALL	ALL	0.0.0.0/0

Configuración de Amazon EC2 para el servidor de blocs de notas

Con un punto de conexión de desarrollo, puede crear un servidor de blocs de notas para probar sus scripts de ETL con cuaderno de Jupyter. Para habilitar la comunicación con su bloc de notas, especifique un grupo de seguridad con reglas de entrada tanto para HTTPS (puerto 443) como para SSH (puerto 22). Asegúrese de que el origen de la regla sea 0.0.0.0/0 o la dirección IP del equipo que se va a conectar al bloc de notas.

Para configurar un grupo de seguridad

1. Inicie sesión en la Consola de administración de AWS y abra la consola de Amazon EC2 en https://console.aws.amazon.com/ec2/.
2. En el panel de navegación izquierdo, elija Security Groups.
3. Elija un grupo de seguridad ya existente en la lista o seleccione Create Security Group (Crear grupo de seguridad) para usarlo con su servidor de blocs de notas. El grupo de seguridad asociado con su punto de enlace de desarrollo también se utiliza para crear su servidor de blocs de notas.
4. En el panel del grupo de seguridad, vaya a la pestaña Inbound (Entrante).
5. Añada reglas de entrada similares a la siguiente:

Tipo	Protocolo	Intervalo de puertos	Origen
SSH	TCP	22	0.0.0.0/0
HTTPS	TCP	443	0.0.0.0/0

A continuación se muestra un ejemplo de las reglas de entrada del grupo de seguridad:

Detección y catalogación de datos en AWS Glue

El AWS Glue Data Catalog es un repositorio centralizado que almacena metadatos sobre los conjuntos de datos de su organización. Actúa como un índice para las métricas de tiempo de ejecución, esquema y ubicación de sus orígenes de datos. Los metadatos se almacenan en tablas de metadatos, en las que cada tabla representa un único almacén de datos.

Para completar el Catálogo de datos, puede usar un rastreador, que escanea automáticamente los orígenes de datos y extrae los metadatos. Los rastreadores pueden conectarse a orígenes de datos internos (basados en AWS) y externos a AWS.

Para obtener más información sobre los orígenes de datos compatibles, consulte Orígenes de datos admitidos para el rastreo.

También puede crear tablas en el Catálogo de datos manualmente, para lo cual debe definir la estructura de la tabla, el esquema y la estructura de particiones de acuerdo con sus requisitos específicos.

Para obtener más información sobre la creación manual de tablas de metadatos, consulte Cómo definir los metadatos manualmente.

Puede usar la información del Catálogo de datos para crear y supervisar sus trabajos de ETL. El Catálogo de datos se integra con otros servicios de análisis de AWS y proporciona una vista unificada de los orígenes de datos, lo que facilita la administración y el análisis de los datos.

- Amazon Athena: Almacene y consulte los metadatos de las tablas en el Catálogo de datos para los datos de Amazon S3 con SQL.
- AWS Lake Formation: Defina y administre las políticas de acceso a los datos detalladas y audite el acceso a los datos de forma centralizada.
- Amazon EMR: Acceda a los orígenes de datos definidos en el Catálogo de datos para el procesamiento de macrodatos.
- Amazon SageMaker AI: Cree, entrene e implemente modelos de machine learning de forma rápida y segura.

Características clave del Catálogo de datos

A continuación se detallan los aspectos clave del Catálogo de datos.

Repositorio de metadatos

El Catálogo de datos actúa como un repositorio central de metadatos y almacena información sobre la ubicación, el esquema y las propiedades de los orígenes de datos. Estos metadatos se organizan en bases de datos y tablas, de forma similar a un catálogo de una base de datos relacional tradicional.

Detección automática de datos

Los Rastreador de AWS Glue pueden detectar y catalogar los orígenes de datos nuevos o actualizados automáticamente, lo que reduce la sobrecarga de la administración manual de los metadatos y garantiza que su Catálogo de datos permanezca actualizado. Al catalogar sus orígenes de datos, el Catálogo de datos facilita a los usuarios y las aplicaciones la detección y la comprensión de los activos de datos disponibles en su organización, lo que promueve la reutilización de los datos y la colaboración.

El Catálogo de datos es compatible con una amplia gama de orígenes de datos, incluidos Amazon S3, Amazon RDS, Amazon Redshift y Apache Hive, entre otros. Puede inferir y almacenar metadatos de estos orígenes automáticamente mediante el uso de Rastreador de AWS Glue.

Para obtener más información, consulte Uso de rastreadores para completar el Catálogo de datos .

Administración de esquemas

El Catálogo de datos captura y administra automáticamente el esquema de sus orígenes de datos, incluida la inferencia, la evolución y el control de versiones del esquema. Para actualizar el esquema y las particiones del Catálogo de datos, puede usar los trabajos de ETL de AWS Glue.

Optimización de tablas

Para mejorar el rendimiento de lectura de los servicios de análisis de AWS, como Amazon Athena, Amazon EMR, y los trabajos de ETL de AWS Glue, el Catálogo de datos ofrece una compactación administrada (un proceso que compacta objetos pequeños de Amazon S3 para convertirlos en objetos más grandes) para procesar las tablas de Iceberg del Catálogo de datos. Puede usar la consola de AWS Glue, la consola de AWS Lake Formation, la AWS CLI o la API de AWS para activar o desactivar la compactación de las tablas de Iceberg individuales que están en el Catálogo de datos.

Para obtener más información, consulte Optimización de las tablas de Iceberg.

Estadísticas de las columnas

Puede calcular las estadísticas a nivel de columna para las tablas del Catálogo de datos en formatos de datos como Parquet, ORC, JSON, ION, CSV y XML sin necesidad de configurar canalizaciones de datos adicionales. Las estadísticas de columnas le ayudan a entender los perfiles de datos al obtener información sobre los valores de una columna. El Catálogo de datos permite generar estadísticas para los valores de las columnas, como los valores mínimo y máximo, los valores nulos totales y distintos totales, la longitud media de los valores y el total de apariciones de valores verdaderos.

Para obtener más información, consulte Cómo optimizar el rendimiento de las consultas con las estadísticas de columnas.

Linaje de datos

El Catálogo de datos mantiene un registro de las transformaciones y operaciones realizadas con los datos, y proporciona información sobre el linaje de los datos. Esta información sobre el linaje es valiosa para la auditoría, el cumplimiento y la comprensión de la procedencia de los datos.

Integración con otros servicios de AWS

El Catálogo de datos se integra perfectamente con otros servicios de AWS, como AWS Lake Formation, Amazon Athena, Amazon Redshift Spectrum y Amazon EMR. Esta integración le permite consultar y analizar los datos de varios almacenes de datos mediante el uso de una única capa de metadatos coherente.

Seguridad y control de acceso

AWS Glue se integra con AWS Lake Formation para promover un control minucioso del acceso a los recursos del Catálogo de datos, lo que le permite administrar los permisos y proteger el acceso a sus activos de datos en función de las políticas y los requisitos de su organización. AWS Glue se integra con AWS Key Management Service (AWS KMS) para cifrar los metadatos almacenados en el Catálogo de datos.

Vistas materializadas

El catálogo de datos admite vistas materializadas de Apache Iceberg, que son tablas administradas que almacenan resultados precomputados de consultas SQL y se actualizan automáticamente a medida que cambian los datos de origen subyacentes. Las vistas materializadas simplifican las canalizaciones de transformación de datos y aceleran el rendimiento de las consultas al eliminar cálculos redundantes.

Puede crear vistas materializadas mediante Apache Spark SQL en la versión 5.1 de AWS Glue o posteriores, en la versión 7.12.0 de Amazon EMR o posteriores y en Amazon Athena. El catálogo de datos supervisa automáticamente las tablas de Apache Iceberg de origen y actualiza las vistas materializadas mediante infraestructura de cómputo administrada. Los motores de Spark en AWS Glue, Amazon EMR y Amazon Athena pueden reescribir automáticamente las consultas para usar vistas materializadas cuando estas ofrecen mejor rendimiento.

Las vistas materializadas se almacenan como tablas de Apache Iceberg en buckets de tablas de Amazon S3 o en buckets de uso general de Amazon S3 dentro de su cuenta, lo que las hace accesibles desde múltiples motores de consulta. El catálogo de datos administra todos los aspectos del ciclo de vida de las vistas materializadas, incluida la programación automática de actualizaciones, las actualizaciones incrementales y la administración de metadatos.

Para obtener más información, consulte Uso de vistas materializadas con AWS Glue y Uso de vistas materializadas con Amazon EMR.

Temas

- Cómo completar el Catálogo de datos de AWS Glue
- Cómo completar y administrar las tablas transaccionales
- Administración del Catálogo de datos
- Cómo acceder al Catálogo de datos
- Prácticas recomendadas para el uso del Catálogo de datos de AWS Glue
- Supervisión de métricas de uso del Catálogo de datos en Amazon CloudWatch
- AWS Glue Schema Registry

Cómo completar el Catálogo de datos de AWS Glue

Puede completar el AWS Glue Data Catalog mediante los siguientes métodos:

- Rastreador de AWS Glue: El Rastreador de AWS Glue puede detectar y catalogar automáticamente orígenes de datos, como bases de datos, lagos de datos y datos de streaming. Los rastreadores son el método más común y recomendado para completar el Catálogo de datos, ya que pueden detectar e inferir automáticamente los metadatos de una amplia variedad de orígenes de datos.

- Adición manual de metadatos: Puede definir manualmente las bases de datos, las tablas y los detalles de conexión, y agregarlos al Catálogo de datos con la consola de AWS Glue, la consola de Lake Formation, la AWS CLI o las API de AWS Glue. El ingreso manual resulta útil cuando quiere catalogar los orígenes de datos que no se pueden rastrear.
- Integración con otros servicios de AWS: Puede completar el Catálogo de datos con metadatos de servicios como AWS Lake Formation y Amazon Athena. Estos servicios pueden detectar y registrar los orígenes de datos en el Catálogo de datos.
- Adición desde un repositorio de metadatos existente: Si tiene un almacén de metadatos existente, como Apache Hive Metastore, puede usar AWS Glue para importar esos metadatos al Catálogo de datos. Para obtener más información, consulte Migración entre un metaalmacén de Hive y AWS Glue Data Catalog en GitHub.

Temas

- Uso de rastreadores para completar el Catálogo de datos
- Cómo definir los metadatos manualmente
- Integración con otros servicios de AWS
- Configuración del Catálogo de datos

Uso de rastreadores para completar el Catálogo de datos

Puede usar un Rastreador de AWS Glue para completar el AWS Glue Data Catalog con bases de datos y tablas. Este es el método principal usado por la mayoría de los usuarios de AWS Glue. Un rastreador puede rastrear varios almacenes de datos en una única ejecución. Cuando finaliza, el rastreador crea o actualiza una o varias tablas del Catálogo de datos. Los trabajos de extracción, transformación y carga (ETL) que define en AWS Glue usan estas tablas del Catálogo de datos como orígenes y destinos. El trabajo de ETL lee y escribe en los almacenes de datos que se especifican en las tablas de origen y destino del Catálogo de datos.

Flujo de trabajo

En el siguiente diagrama de flujo de flujo de trabajo se muestra cómo los rastreadores de AWS Glue interactúan con almacenes de datos y otros elementos para rellenar el Catálogo de datos.

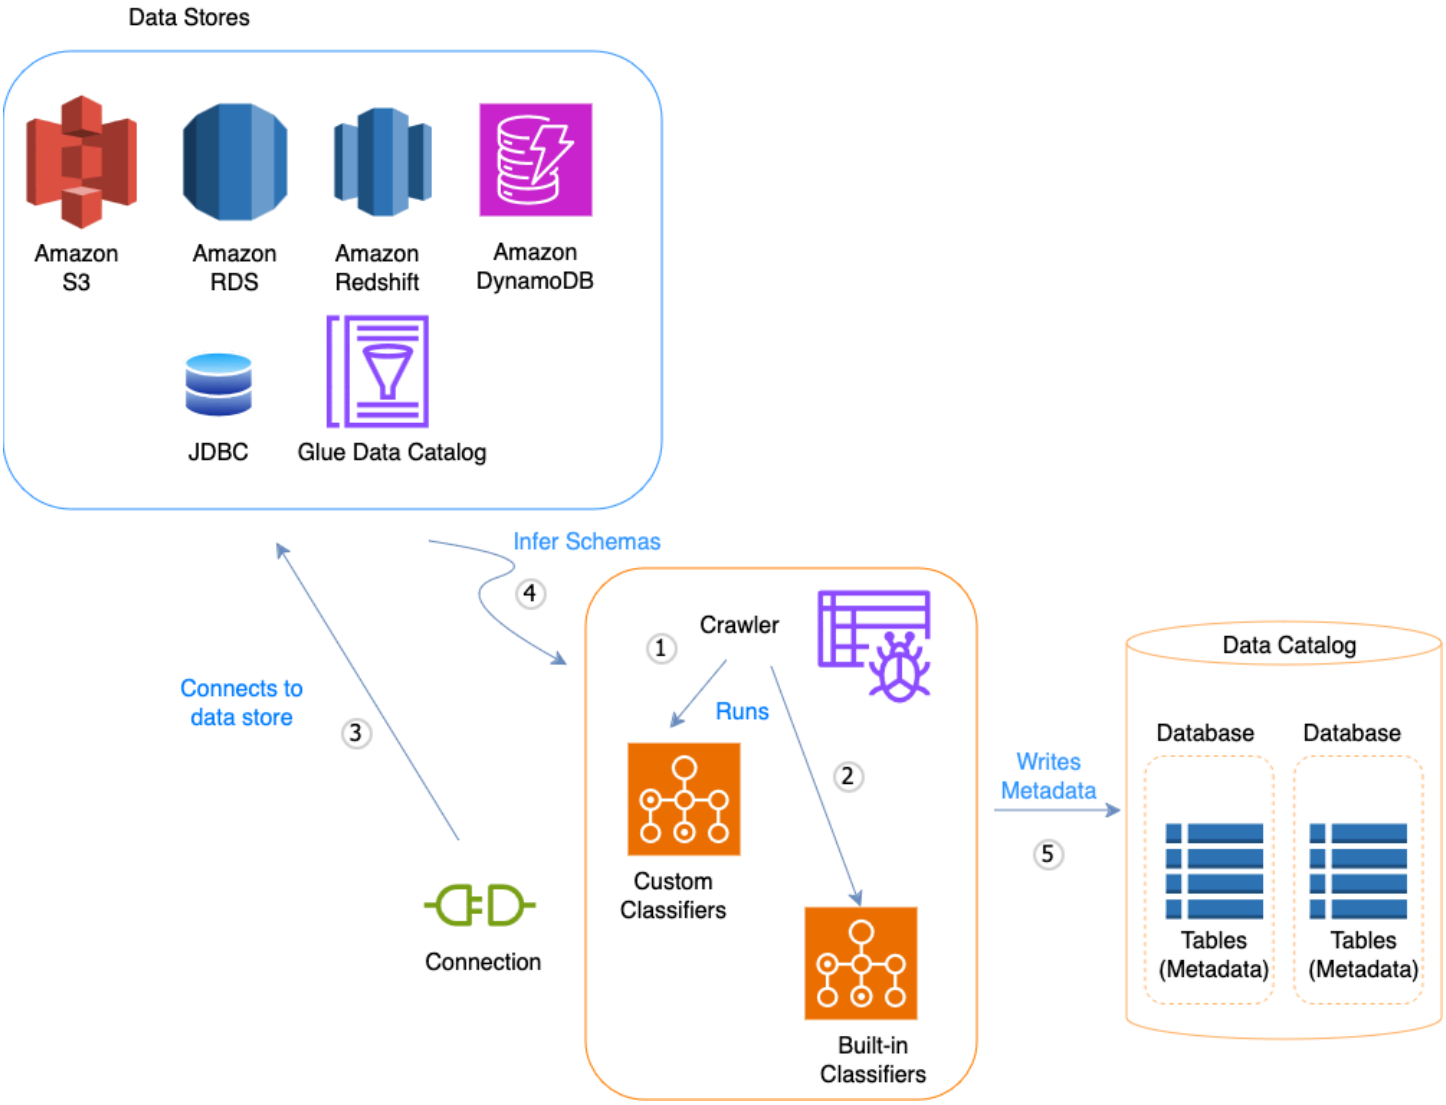

Este es el flujo de flujo de trabajo general de rellenado de AWS Glue Data Catalog por parte de un rastreador:

1. Un rastreador ejecuta cualquier clasificador personalizado que elija para inferir el formato y el esquema de sus datos. Debe proporcionar el código para clasificadores personalizados, que se ejecutan en el orden especificado.

   El primer clasificador personalizado en reconocer correctamente la estructura de sus datos se usa para crear un esquema. Los clasificadores personalizados que aparecen más abajo en la lista se omiten.

2. Si no coincide ningún clasificador con el esquema de sus datos, los clasificadores integrados intentarán reconocer el esquema de sus datos. Un ejemplo de un clasificador integrado es uno que reconoce JSON.

3. El rastreador se conecta al almacén de datos. Algunos almacenes de datos requieren propiedades de conexión para el acceso del rastreador.
4. El esquema inferido se crea para sus datos.
5. El rastreador escribe los metadatos en el Catálogo de datos. Una definición de tabla contiene metadatos acerca de los datos de su almacén de datos. La tabla se escribe en una base de datos, que es un contenedor de tablas en el Catálogo de datos. Entre los atributos de una tabla se incluye la clasificación, que es una etiqueta creada por el clasificador que determinó el esquema de tabla.

Temas

- Funcionamiento de los rastreadores
- ¿Cómo determina un rastreador cuándo crear particiones?
- Orígenes de datos admitidos para el rastreo
- Requisitos previos del rastreador
- Definición y administración de clasificadores
- Configuración de rastreadores
- Programación de un rastreador
- Ver los resultados y detalles del rastreador
- Personalización del comportamiento del rastreador
- Tutorial: agregar un rastreador de AWS Glue

Funcionamiento de los rastreadores

Cuando se ejecuta un rastreador, realiza las siguientes acciones para interrogar a un almacén de datos:

- Clasifica los datos para determinar el formato, el esquema y las propiedades asociadas de los datos sin procesar: puede configurar los resultados de clasificación mediante la creación de un clasificador personalizado.
- Agrupa los datos en tablas o particiones: los datos se agrupan en función de la heurística de rastreador.
- Escribe los metadatos en el Catálogo de datos: puede configurar cómo el rastreador agrega, actualiza y elimina tablas y particiones.

Al definir un rastreador, puede elegir uno o varios clasificadores que evalúen el formato de sus datos para inferir un esquema. Al ejecutarse el rastreador, el primer clasificador de su lista en reconocer correctamente su almacén de datos se usa para crear un esquema para su tabla. Puede usar clasificadores integrados o definir los suyos propios. Puede definir sus clasificadores personalizados en una operación independiente, antes de definir los rastreadores. AWS Glue proporciona clasificadores integrados para inferir esquemas a partir de archivos comunes con formatos entre los que se incluyen JSON, CSV y Apache Avro. Para ver la lista actual de clasificadores integrados en AWS Glue, consulte Clasificadores integrados.

Las tablas de metadatos que crea un rastreador se incluyen en una base de datos al definir un rastreador. Si su rastreador no especifica una base de datos, sus tablas se colocan en la base de datos predeterminada. Además, cada tabla tiene una columna de clasificación que rellena el clasificador que reconoció correctamente el almacén de datos en primer lugar.

Si se comprime el archivo que se rastrea, el rastreador debe descargarlo para procesarlo. Cuando un rastreador se ejecuta, interroga los archivos para determinar su formato y tipo de compresión, y escribe estas propiedades en el Catálogo de datos. Algunos formatos de archivo (por ejemplo, Apache Parquet) le permiten comprimir partes del archivo a medida que se escribe. Para estos archivos, los datos comprimidos son un componente interno del archivo y AWS Glue no rellena la propiedad `compressionType` cuando escribe tablas en el Catálogo de datos. Por el contrario, si un archivo completo se comprime mediante un algoritmo de compresión (por ejemplo, gzip), la propiedad `compressionType` se rellena cuando las tablas se escriben en el Catálogo de datos.

El rastreador genera los nombres para las tablas que crea. Los nombres de las tablas que se almacenan en el AWS Glue Data Catalog siguen estas reglas:

- Solo se permiten caracteres alfanuméricos y guiones bajos (_).
- Ningún prefijo personalizado puede tener más de 64 caracteres.
- La longitud máxima del nombre no puede ser superior a 128 caracteres. El rastreador trunca nombres generados para que quepan en el límite.
- Si se encuentran nombres de tabla duplicados, el rastreador añade un sufijo de cadena hash al nombre.

Si su rastreador se ejecuta más de una vez, quizás en una programación, busca archivos o tablas nuevos o cambiados en su almacén de datos. La salida del rastreador incluye nuevas tablas y particiones encontradas desde una ejecución anterior.

¿Cómo determina un rastreador cuándo crear particiones?

Cuando un rastreador de AWS Glue escanea el almacén de datos de Amazon S3 y detecta varias carpetas en un bucket, determina la raíz de una tabla en la estructura de carpetas y qué carpetas son particiones de una tabla. El nombre de la tabla se basa en el prefijo de Amazon S3 o el nombre de carpeta. Proporcione una ruta de inclusión que apunte al nivel de carpeta que se rastreará. Cuando la mayoría de los esquemas en el nivel de carpeta son similares, el rastreador crea particiones de una tabla en vez de tablas independientes. Para influir en el rastreador con el fin de que cree tablas independientes, agregue la carpeta raíz de cada tabla como un almacén de datos independiente al definir el rastreador.

Por ejemplo, considere la siguiente estructura de carpetas de Amazon S3.

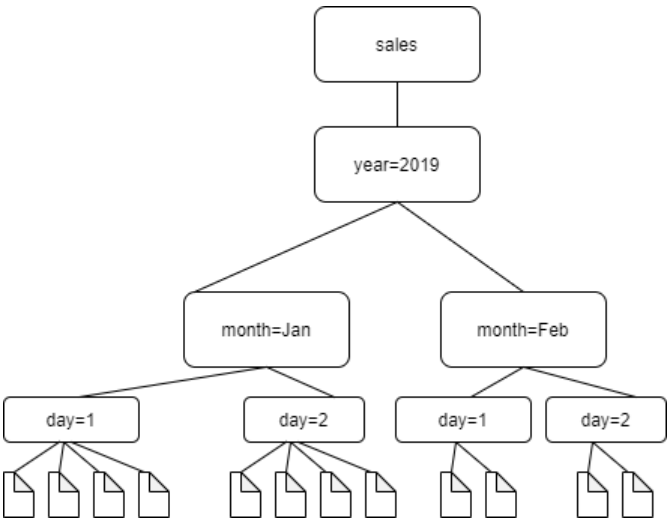

Las rutas de acceso a las cuatro carpetas de nivel inferior son las siguientes:

```
S3://sales/year=2019/month=Jan/day=1
S3://sales/year=2019/month=Jan/day=2
S3://sales/year=2019/month=Feb/day=1
S3://sales/year=2019/month=Feb/day=2
```

Supongamos que el destino del rastreador está establecido en `Sales` y que todos los archivos en la carpeta `day=`*n* tienen el mismo formato (por ejemplo, JSON, no cifrado) y tienen los mismos esquemas o muy similares. El rastreador creará una sola tabla con cuatro particiones, con claves de partición `year`, `month` y `day`.

Por ejemplo, considere la siguiente estructura de Amazon S3:

```
s3://bucket01/folder1/table1/partition1/file.txt
s3://bucket01/folder1/table1/partition2/file.txt
s3://bucket01/folder1/table1/partition3/file.txt
s3://bucket01/folder1/table2/partition4/file.txt
s3://bucket01/folder1/table2/partition5/file.txt
```

Si los esquemas para los archivos en `table1` y `table2` son similares, y se define un almacén de datos individual en el rastreador con Include path (Ruta de inclusión) `s3://bucket01/folder1/`, el rastreador crea una sola tabla con dos columnas de claves de partición. La primera columna de clave de partición contiene `table1` y `table2`, y la segunda columna de clave de partición contiene `partition1` a `partition3` para la partición de la `table1`, y `partition4` y `partition5` para la partición de la `table2`. Para crear dos tablas independientes, defina el rastreador con dos almacenes de datos. En este ejemplo, defina la primera ruta de inclusión como `s3://bucket01/folder1/table1/` y la segunda como `s3://bucket01/folder1/table2`.

> **Note**
>
> En Amazon Athena, cada tabla corresponde a un prefijo de Amazon S3 con todos los objetos que contiene. Si los objetos tienen diferentes esquemas, Athena no reconoce objetos distintos en el mismo prefijo como tablas independientes. Esto puede suceder si un rastreador crea varias tablas a partir del mismo prefijo de Amazon S3. Esto podría dar lugar a consultas en Athena que no devuelvan resultados. Para que Athena reconozca y consulte las tablas correctamente, cree el rastreador con una Include path (Ruta de inclusión)diferente para cada esquema de tabla en la estructura de carpetas de Amazon S3. Para obtener más información, consulte las Mejores prácticas de uso de Athena con AWS Glue y este artículo del Centro de conocimientos de AWS.

Orígenes de datos admitidos para el rastreo

Los rastreadores pueden rastrear los siguientes almacenes de datos basados en archivos y almacenes de datos basados en tablas.

Tipo de acceso que utiliza el rastreador	Almacenes de datos
Cliente nativo	• Amazon Simple Storage Service (Amazon S3) • Amazon DynamoDB

Tipo de acceso que utiliza el rastreador	Almacenes de datos
	• Delta Lake 2.0.x • Apache Iceberg 1.5 • Apache Hudi 0.14
JDBC	Amazon Redshift Snowflake Dentro de Amazon Relational Database Service (Amazon RDS) o externo a Amazon RDS: • Amazon Aurora • MariaDB • Microsoft SQL Server • MySQL • Oracle • PostgreSQL
Cliente de MongoDB	• MongoDB • MongoDB Atlas • Amazon DocumentDB (con compatibilidad con MongoDB)

> **Note**
>
> Actualmente, AWS Glue no admite rastreadores para transmisiones de datos.

Para los almacenes de datos JDBC, MongoDB, MongoDB Atlas y Amazon DocumentDB (con compatibilidad con MongoDB), debe especificar una conexión de AWS Glue que el rastreador pueda usar para conectarse al almacén de datos. Para Amazon S3, puede especificar opcionalmente una conexión de tipo Red. Una conexión es un objeto del Catálogo de datos que almacena información de conexión, como credenciales, URL, información de Amazon Virtual Private Cloud, etc. Para obtener más información, consulte Conexión a datos.

A continuación se enumeran las versiones de controladores compatibles con el rastreador:

Producto	Controlador compatible con el rastreador
PostgreSQL	42.2.1
Amazon Aurora	Igual que los controladores de rastreadores nativos
MariaDB	8.0.13
Microsoft SQL Server	6.1.0
MySQL	8.0.13
Oracle	11.2.2
Amazon Redshift	4.1
Snowflake	3.13.20
MongoDB	4.7.2
MongoDB Atlas	4.7.2

A continuación, se muestran notas sobre los distintos almacenes de datos.

Amazon S3

Puede elegir rastrear una ruta en su cuenta o en otra cuenta. Si todos los archivos de Amazon S3 de una carpeta tienen el mismo esquema, el rastreador crea una tabla. Además, si el objeto de Amazon S3 está particionado, solo se crea una tabla de metadatos y se agrega información de particiones al Catálogo de datos de esa tabla.

Amazon S3 y Amazon DynamoDB

Los rastreadores utilizan un rol de AWS Identity and Access Management (IAM) para obtener permiso y acceder a sus almacenes de datos. El rol que se transfiere al rastreador debe tener permiso para obtener acceso a las rutas de Amazon S3 y a las tablas de Amazon DynamoDB que se rastrean.

Amazon DynamoDB

Al definir un rastreador mediante la consola de AWS Glue, especifica una tabla de DynamoDB. Si usa la API de AWS Glue, especifica una lista de tablas. Puede elegir rastrear sólo una pequeña muestra de los datos para reducir los tiempos de ejecución del rastreador.

Delta Lake

En cada almacén de datos de Delta Lake, debe especificar cómo crear tablas de Delta:

- Crear tablas nativas: se permite la integración a los motores de consulta que permiten consultar el registro de transacciones de Delta directamente. Para obtener más información, consulte Consultar las tablas de Delta Lake.
- Crear tablas de enlaces simbólicos: se crea una carpeta de `_symlink_manifest` con los archivos de manifiesto particionados mediante las claves de partición en función de los parámetros de configuración especificados.

Iceberg

Para cada almacén de datos de Iceberg, debe especificar una ruta de Amazon S3 que contenga los metadatos de las tablas de Iceberg. Si el rastreador descubre metadatos de tablas de Iceberg, los registra en el Data Catalog. Puede establecer una programación para que el rastreador mantenga las tablas actualizadas.

Puede definir estos parámetros para el almacén de datos:

- Exclusiones: permite omitir determinadas carpetas.
- Profundidad máxima de recorrido: establece el límite de profundidad que el rastreador puede rastrear en su bucket de Amazon S3. La profundidad de recorrido máxima predeterminada es 10 y la profundidad máxima que puede establecer es 20.

Hudi

Para cada almacén de datos de Hudi, debe especificar una ruta de Amazon S3 que contenga los metadatos de las tablas de Hudi. Si el rastreador descubre metadatos de la tabla de Hudi, los registra en el Data Catalog. Puede establecer una programación para que el rastreador mantenga las tablas actualizadas.

Puede definir estos parámetros para el almacén de datos:

- Exclusiones: permite omitir determinadas carpetas.

- Profundidad máxima de recorrido: establece el límite de profundidad que el rastreador puede rastrear en su bucket de Amazon S3. La profundidad de recorrido máxima predeterminada es 10 y la profundidad máxima que puede establecer es 20.

> **Note**
>
> Las columnas de marcas temporales con tipos lógicos `millis` se interpretarán como `bigint` debido a una incompatibilidad con Hudi 0.13.1 y los tipos de marcas temporales. Es posible que se proporcione una solución en la próxima versión de Hudi.

Las tablas Hudi se clasifican de la siguiente manera, con implicaciones específicas para cada una de ellas:

- Copiar al escribir (CoW): los datos se almacenan en un formato de columnas (Parquet) y cada actualización crea una nueva versión de los archivos durante una escritura.
- Fusionar al leer (MoR): los datos se almacenan mediante la utilización de un formato que combina columnas (Parquet) y filas (Avro). Las actualizaciones se registran en archivos delta basados en filas y se compactan según sea necesario para crear nuevas versiones de los archivos en columnas.

Con los datasets de tipo CoW, cada vez que se produce una actualización de un registro, el archivo que contiene el registro se vuelve a escribir con los valores actualizados. Con un conjunto de datos de tipo MoR, cada vez que hay una actualización, Hudi escribe solo la fila correspondiente al registro modificado. MoR es más adecuado para cargas de trabajo con gran cantidad de escrituras o cambios y menos lecturas. CoW es más adecuado para cargas de trabajo con gran cantidad de lecturas con datos que cambian con menos frecuencia.

Hudi ofrece tres tipos de consulta para acceder a los datos:

- Consultas de instantáneas: consultas que ven la última instantánea de la tabla a partir de una acción de confirmación o compactación determinada. Para las tablas MoR, las consultas de instantáneas exponen el estado más reciente de la tabla mediante la combinación de los archivos base y delta del segmento de archivos más reciente en el momento de la consulta.
- Consultas progresivas: consultas que solo ven los nuevos datos escritos en la tabla, desde una confirmación o compactación determinada. Esto proporciona flujos de cambio de manera efectiva para habilitar canalizaciones de datos incrementales.
- Consultas optimizadas para lectura: para las tablas de MoR, las consultas ven compactados los datos más recientes. Para las tablas CoW, las consultas ven los últimos datos confirmados.

En el caso de las tablas Copiar al escribir, los rastreadores crean una sola tabla en el Data Catalog con el serde ReadOptimized `org.apache.hudi.hadoop.HoodieParquetInputFormat`.

En el caso de las tablas Fusionar al leer, el rastreador crea dos tablas en el Data Catalog para la misma ubicación de la tabla:

- Tabla con un sufijo `_ro` que utiliza el serde ReadOptimized `org.apache.hudi.hadoop.HoodieParquetInputFormat`.
- Una tabla con un sufijo `_rt` que utiliza el serde RealTime para realizar consultas instantáneas: `org.apache.hudi.hadoop.realtime.HoodieParquetRealtimeInputFormat`.

MongoDB y Amazon DocumentDB (compatible con MongoDB)

Las versiones 3.2 y posteriores de MongoDB son compatibles. Puede elegir rastrear sólo una pequeña muestra de los datos para reducir los tiempos de ejecución del rastreador.

Base de datos relacional

La autenticación se realiza con un nombre de usuario y una contraseña de base de datos. En función del tipo de motor de base de datos, puede elegir qué objetos se rastrean, como bases de datos, esquemas y tablas.

Snowflake

El rastreador de JDBC de Snowflake permite rastrear la tabla, la tabla externa, la vista y la vista materializada. La definición de vista materializada no se rellenará.

En el caso de las tablas externas de Snowflake, el rastreador solo llevará a cabo el rastreo si apunta a una ubicación de Amazon S3. Además del esquema de la tabla, el rastreador también rastreará la ubicación de Amazon S3, el formato de archivo y la salida como parámetros de tabla en la tabla del Catálogo de datos. Tenga en cuenta que la información de particiones de la tabla externa particionada no se rellena.

Actualmente, el proceso de ETL no es compatible con las tablas del Catálogo de datos creadas con el rastreador de Snowflake.

Requisitos previos del rastreador

El rastreador asume los permisos del rol de AWS Identity and Access Management (IAM) que se especifican al definirlo. Este rol de IAM debe tener permisos para extraer datos de su almacén de datos y escribir al Catálogo de datos. En la consola de AWS Glue solo se listan roles de IAM que

tienen asociada una política de confianza para el servicio principal de AWS Glue. En la consola, también puede crear un rol de IAM con una política de IAM para obtener acceso a almacenes de datos de Amazon S3 a los que obtiene acceso el rastreador. Para obtener más información acerca de cómo proporcionar roles para AWS Glue, consulte Políticas basadas en identidades de AWS Glue.

> **Note**
>
> Al rastrear un almacén de datos de Delta Lake, debe tener permisos de lectura y escritura en la ubicación de Simple Storage Service (Amazon S3).

Puede crear un rol para su rastreador y asociar las siguientes políticas:

- La política `AWSGlueServiceRole` administrada por AWS, que concede los permisos necesarios en el Catálogo de datos
- Política en línea que concede permisos en el origen de datos.
- Política en línea que concede permisos de `iam:PassRole` al rol.

Un enfoque más rápido es dejar que el asistente de rastreadores de la consola de AWS Glue cree un rol para usted. El rol que crea es específicamente para el rastreador e incluye la política `AWSGlueServiceRole` administrada por AWS, más la política en línea necesaria para el origen de datos especificado.

Si especifica un rol existente para un rastreador, asegúrese de que incluya la política `AWSGlueServiceRole` o equivalente (o una versión reducida de esta política), además de las políticas en línea requeridas. Por ejemplo, para un almacén de datos de Amazon S3, la política en línea sería, como mínimo, la siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "s3:GetObject"
```

```
      ],
      "Resource": [
        "arn:aws:s3:::bucket/object*"
      ]
    }
  ]
}
```

Para un almacén de datos de Amazon DynamoDB, la política sería, como mínimo, la siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "dynamodb:DescribeTable",
        "dynamodb:Scan"
      ],
      "Resource": [
        "arn:aws:dynamodb:us-east-1:111122223333:table/table-name*"
      ]
    }
  ]
}
```

Si el rastreador lee datos de Amazon S3 cifrados por AWS Key Management Service (AWS KMS), entonces el rol de IAM debe tener permiso para descifrar la clave AWS KMS. Para obtener más información, consulte Paso 2: creación de un rol de IAM para AWS Glue.

Definición y administración de clasificadores

Un clasificador lee los datos en un almacén de datos. Si reconoce el formato de los datos, genera un esquema. El clasificador también devuelve un número de certeza para indicar el grado de certeza del reconocimiento del formato.

AWS Glue proporciona un conjunto de clasificadores integrados, pero también puede crear clasificadores personalizados. AWS Glue invoca clasificadores personalizados en primer lugar, en

el orden especificado en su definición del rastreador. Según los resultados devueltos a partir de los clasificadores personalizados, AWS Glue también podría invocar clasificadores integrados. Si un clasificador devuelve `certainty=1.0` durante el procesamiento, indica que puede crear el esquema correcto con una seguridad del 100 por ciento. A continuación, AWS Glue usa la salida de ese clasificador.

Si ningún clasificador devuelve `certainty=1.0`, AWS Glue usará la salida del clasificador con la mayor certeza. Si ningún clasificador devuelve una certeza mayor que `0.0`, AWS Glue devolverá la cadena de clasificación predeterminada de `UNKNOWN`.

¿Cuándo uso un clasificador?

Se usan clasificadores al rastrear un almacén de datos para definir tablas de metadatos en el AWS Glue Data Catalog. Puede configurar su rastreador con un conjunto ordenado de clasificadores. Cuando el rastreador invoca un clasificador, el clasificador determina si se reconocen los datos. Si el clasificador no puede reconocer los datos o no es 100 % seguro, el rastreador invoca el siguiente clasificador de la lista para determinar si puede reconocer los datos.

Para obtener información adicional acerca de cómo crear un clasificador mediante la consola de AWS Glue, consulte Creación de clasificadores mediante la consola de AWS Glue.

Clasificadores personalizados

La salida de un clasificador incluye una cadena que indica la clasificación o el formato del archivo (por ejemplo, `json`) y el esquema del archivo. En el caso de los clasificadores personalizados, defina la lógica para crear el esquema en función del tipo de clasificador. Los tipos de clasificador incluyen la definición de esquemas en función de patrones de grok, etiquetas XML y rutas JSON.

Si cambia una definición de clasificador, no se vuelven a clasificar los datos que se rastrearon anteriormente con el clasificador. Un rastreador realiza un seguimiento de datos rastreados anteriormente. Los datos nuevos se clasifican con el clasificador actualizado, lo que podría dar lugar a un esquema actualizado. Si el esquema de sus datos ha evolucionado, actualice el clasificador para tener en cuenta los cambios de esquema cuando se ejecute el rastreador. Para volver a clasificar los datos con el fin de corregir un clasificador incorrecto, cree un nuevo rastreador con el clasificador actualizado.

Para obtener más información acerca de la creación de clasificadores personalizados en AWS Glue, consulte Redacción de clasificadores personalizados para diversos formatos de datos.

> **Note**
>
> Si uno de los clasificadores integrados reconoce el formato de sus datos, no es necesario que cree un clasificador personalizado.

Clasificadores integrados

AWS Glue proporciona clasificadores integrados para diversos formatos, incluidos JSON, CSV, registros web y muchos sistemas de bases de datos.

Si AWS Glue no encuentra un clasificador personalizado que se adapte mejor al formato de datos de entrada con una seguridad del 100 por ciento, invoca los clasificadores integrados en el orden mostrado en la siguiente tabla. Los clasificadores integrados devuelven un resultado para indicar si el formato coincide (`certainty=1.0`) o no coincide (`certainty=0.0`). El primer clasificador con `certainty=1.0` proporciona la cadena de clasificación y el esquema para una tabla de metadatos en su Data Catalog.

Tipo de clasificador	Cadena de clasificación	Notas
Apache Avro	`avro`	Lee el esquema al principio del archivo para determinar el formato.
Apache ORC	`orc`	Lee los metadatos de archivo para determinar el formato.
Apache Parquet	`parquet`	Lee el esquema al final del archivo para determinar el formato.
JSON	`json`	Lee el principio del archivo para determinar el formato.
JSON binario	`bson`	Lee el principio del archivo para determinar el formato.
XML	`xml`	Lee el principio del archivo para determinar el formato. AWS Glue determina el esquema de la tabla basado en etiquetas XML del documento.

Tipo de clasificador	Cadena de clasificación	Notas
		Para obtener información acerca de la creación de un clasificador XML personalizado para especificar filas en el documento, consulte Escritura de clasificadores personalizados XML.
Amazon Ion	`ion`	Lee el principio del archivo para determinar el formato.
Registro Apache combinado	`combined_apache`	Determina los formatos de log a través de un patrón de grok.
Registro Apache	`apache`	Determina los formatos de log a través de un patrón de grok.
Registro de kernel de Linux	`linux_kernel`	Determina los formatos de log a través de un patrón de grok.
Registro de Microsoft	`microsoft_log`	Determina los formatos de log a través de un patrón de grok.
Registro de Ruby	`ruby_logger`	Lee el principio del archivo para determinar el formato.
Registro de Squid 3.x	`squid`	Lee el principio del archivo para determinar el formato.
Registro de monitorización de Redis	`redismonlog`	Lee el principio del archivo para determinar el formato.
Registro de Redis	`redislog`	Lee el principio del archivo para determinar el formato.

Tipo de clasificador	Cadena de clasificación	Notas
CSV	`csv`	Comprueba los siguientes delimitadores: coma (,), barra vertical (|), tabulación (\t), punto y coma (;) y Ctrl-A (\u0001). Ctrl-A es el carácter de control Unicode para `Start Of Heading`.
Amazon Redshift	`redshift`	Usa la conexión de JDBC para importar metadatos.
MySQL	`mysql`	Usa la conexión de JDBC para importar metadatos.
PostgreSQL	`postgresql`	Usa la conexión de JDBC para importar metadatos.
Base de datos de Oracle	`oracle`	Usa la conexión de JDBC para importar metadatos.
Microsoft SQL Server	`sqlserver`	Usa la conexión de JDBC para importar metadatos.
Amazon DynamoDB	`dynamodb`	Lee datos de la tabla de DynamoDB.

Los archivos en los siguientes formatos comprimidos se pueden clasificar:

- ZIP (compatible con archivos que solo contengan un único archivo). Tenga en cuenta que Zip no es totalmente compatible en otros servicios (por el archivo).
- BZIP
- GZIP
- LZ4
- Snappy (compatible con los formatos Snappy estándar y nativo de Hadoop)

Clasificador de CSV integrado

El clasificador de CSV integrado analiza el contenido del archivo CSV para determinar el esquema de una tabla de AWS Glue. Este clasificador comprueba los siguientes delimitadores:

- Coma (,)

- Barra vertical (|)
- Tabulador (\t)
- Punto y coma (;)
- Ctrl-A (\u0001)

  Ctrl-A es el carácter de control Unicode para `Start Of Heading`.

Para clasificarse como CSV, el esquema de tabla debe tener al menos dos columnas y dos filas de datos. El clasificador de CSV utiliza una serie de funciones heurísticas para determinar si un encabezado está en un determinado archivo. Si el clasificador no puede determinar un encabezado a partir de la primera fila de datos, los encabezados de columna se muestran como `col1`, `col2`, `col3`, etc. El clasificador de CSV determina si debe deducir un encabezado mediante la evaluación de las siguientes características del archivo:

- Cada columna en un posible encabezado se analiza como un tipo de datos STRING.
- Excepto en la última, cada columna en un posible encabezado incluye contenido de menos de 150 caracteres. Para permitir un delimitador final, la última columna puede estar vacía en el archivo.
- Cada columna de un encabezado potencial debe cumplir los requisitos `regex` de AWS Glue correspondientes a un nombre de columna.
- La fila de encabezado debe estar suficientemente diferenciada de las filas de datos. Para determinarlo, una o varias de las filas deben analizarse como un tipo distinto de STRING. Si todas las columnas son de tipo STRING, la primera fila de datos que no esté suficientemente diferenciada de las filas posteriores se usará como el encabezado.

> **Note**
>
> Si el clasificador de CSV integrado no crea la tabla de AWS Glue como desea, es posible que deba usar una de las siguientes alternativas:
>
> - Cambie los nombres de columnas en el Data Catalog, establezca `SchemaChangePolicy` en LOG y defina la configuración de salida de partición en `InheritFromTable` para las futuras ejecuciones de rastreador.
> - Cree un clasificador de grok para analizar los datos y asignar las columnas que desee.
> - El clasificador de CSV crea tablas haciendo referencia a `LazySimpleSerDe` como la biblioteca de serialización, lo que es una buena opción para la inferencia de tipo. Sin

embargo, si los datos CSV contienen cadenas entre comillas, edite la definición de tabla y cambie la biblioteca SerDe a `OpenCSVSerDe`. Ajuste los tipos inferidos a STRING, establezca `SchemaChangePolicy` en LOG y defina la configuración de salida de partición en `InheritFromTable` para las futuras ejecuciones de rastreador. Para obtener más información acerca de las bibliotecas SerDe, consulte Referencia de SerDe en la Guía del usuario de Amazon Athena.

Redacción de clasificadores personalizados para diversos formatos de datos

Puede proporcionar un clasificador personalizado para clasificar los datos de AWS Glue. Puede crear un clasificador personalizado con un patrón grok, con una etiqueta XML, con la notación de objetos JavaScript (JSON) o con valores separados por comas (CSV). Un rastreador de AWS Glue llama a un clasificador personalizado. Si el clasificador reconoce los datos, devuelve la clasificación y el esquema de los datos al rastreador. Puede que tenga que definir un clasificador personalizado si sus datos no coinciden con ningún clasificador integrado o si desea personalizar las tablas creadas por el rastreador.

Para obtener información adicional acerca de cómo crear un clasificador mediante la consola de AWS Glue, consulte Creación de clasificadores mediante la consola de AWS Glue.

AWS Glue ejecuta los clasificadores personalizados antes que los integrados, en el orden especificado. Cuando un rastreador encuentra un clasificador que coincide con los datos, la cadena de clasificación y el esquema se usan en la definición de las tablas escritas en su AWS Glue Data Catalog.

Temas

- Escritura de clasificadores personalizados de Grok
- Escritura de clasificadores personalizados XML
- Escritura de clasificadores personalizados JSON
- Escritura de clasificadores personalizados CSV

Escritura de clasificadores personalizados de Grok

Grok es una herramienta que se usa para analizar datos textuales con un patrón coincidente. Un patrón de grok es un conjunto designado de expresiones regulares (regex) que se usan para que los datos coincidan con una línea a la vez. AWS Glue usa patrones de grok para inferir el esquema

de sus datos. Cuando un patrón de grok coincide con sus datos, AWS Glue usa el patrón para determinar la estructura de sus datos y mapearlos en campos.

AWS Glue proporciona muchos patrones integrados o usted puede definir los suyos propios. Puede crear un patrón de grok mediante patrones integrados y personalizados en su definición personalizada del clasificador. Puede adaptar un patrón de grok para clasificar formatos de archivos de texto personalizados.

> **Note**
>
> Los clasificadores personalizados de grok de AWS Glue usan la biblioteca de serialización `GrokSerDe` para las tablas creadas en AWS Glue Data Catalog. Si usa AWS Glue Data Catalog con Amazon Athena, Amazon EMR o Redshift Spectrum, consulte la documentación acerca de esos servicios para obtener información acerca del soporte de `GrokSerDe`. Actualmente, podría tener problemas al consultar las tablas creadas con `GrokSerDe` desde Amazon EMR y Redshift Spectrum.

Esta es la sintaxis básica para los componentes de un patrón de grok:

```
%{PATTERN:field-name}
```

Los datos que coinciden con el elemento `PATTERN` designado se mapean a la columna `field-name` del esquema, con un tipo de datos predeterminado de `string`. Si lo prefiere, el tipo de datos para el campo se puede convertir en `byte`, `boolean`, `double`, `short`, `int`, `long` o `float` en el esquema resultante.

```
%{PATTERN:field-name:data-type}
```

Por ejemplo, para convertir un campo `num` en un tipo de datos `int`, puede usar este patrón:

```
%{NUMBER:num:int}
```

Los patrones se pueden componer de otros patrones. Por ejemplo, puede tener un patrón para una marca temporal `SYSLOG` definida utilizando patrones para el mes, el día del mes y la hora (por ejemplo, `Feb 1 06:25:43`). Para estos datos, puede definir el siguiente patrón:

```
SYSLOGTIMESTAMP %{MONTH} +%{MONTHDAY} %{TIME}
```

> **Note**
>
> Los patrones de grok pueden procesar una única línea a la vez. No se admiten los patrones de varias líneas. Asimismo, no se admiten los saltos de línea dentro de un patrón.

Valores personalizados para el clasificador grok

Al definir un clasificador grok, se proporcionan los siguientes valores para crear el clasificador personalizado.

Nombre

Nombre del clasificador.

Clasificación

La cadena de texto que se escribe para describir el formato de los datos que se clasifican; por ejemplo, `special-logs`.

Patrón de Grok

El conjunto de patrones que se aplican al almacén de datos para determinar si existe una coincidencia. Estos patrones proceden de AWS Gluepatrones integrados de y cualquier patrón personalizado que defina.

A continuación se muestra un ejemplo de un patrón de grok:

```
%{TIMESTAMP_ISO8601:timestamp} \[%{MESSAGEPREFIX:message_prefix}\]
 %{CRAWLERLOGLEVEL:loglevel} : %{GREEDYDATA:message}
```

Cuando los datos coinciden con `TIMESTAMP_ISO8601`, se crea una columna de esquema `timestamp`. El comportamiento es similar para los otros patrones designados del ejemplo.

Patrones personalizados

Patrones personalizados opcionales definidos por usted. El patrón de grok que clasifica sus datos hace referencia a estos patrones. Puede hacer referencia a estos patrones personalizados en el patrón de grok aplicado a sus datos. Cada patrón de componente personalizado debe estar en una línea independiente. La sintaxis Expresión regular (regex) se usa para definir el patrón.

A continuación se muestra un ejemplo del uso de patrones personalizados:

```
CRAWLERLOGLEVEL (BENCHMARK|ERROR|WARN|INFO|TRACE)
MESSAGEPREFIX .*-.*-.*-.*-.*
```

El primer patrón designado personalizado, `CRAWLERLOGLEVEL`, es una coincidencia si los datos coinciden con una de las cadenas enumeradas. El segundo patrón personalizado, `MESSAGEPREFIX`, intenta coincidir con una cadena prefijo del mensaje.

AWS Glue realiza un seguimiento de la hora de creación, la hora de la última actualización y la versión de su clasificador.

Patrones integrados

AWS Glue proporciona muchos patrones comunes que puede usar para crear un clasificador personalizado. Puede añadir un patrón designado a `grok pattern` en una definición del clasificador.

La siguiente lista consta de una línea para cada patrón. En cada línea, al nombre del patrón le sigue su definición. Para definir el patrón, se utiliza la sintaxis de las expresiones regulares (regex).

```
#<noloc>&GLU;</noloc> Built-in patterns
 USERNAME [a-zA-Z0-9._-]+
 USER %{USERNAME:UNWANTED}
 INT (?:[+-]?(?:[0-9]+))
 BASE10NUM (?<![0-9.+-])(?>[+-]?(?:(?:[0-9]+(?:\.[0-9]+)?)|(?:\.[0-9]+)))
 NUMBER (?:%{BASE10NUM:UNWANTED})
 BASE16NUM (?<![0-9A-Fa-f])(?:[+-]?(?:0x)?(?:[0-9A-Fa-f]+))
 BASE16FLOAT \b(?<![0-9A-Fa-f.])(?:[+-]?(?:0x)?(?:(?:[0-9A-Fa-f]+(?:\.[0-9A-Fa-f]*)?)|
(?:\.[0-9A-Fa-f]+)))\b
 BOOLEAN (?i)(true|false)

 POSINT \b(?:[1-9][0-9]*)\b
 NONNEGINT \b(?:[0-9]+)\b
 WORD \b\w+\b
 NOTSPACE \S+
 SPACE \s*
 DATA .*?
 GREEDYDATA .*
 #QUOTEDSTRING (?:(?<!\\)(?:"(?:\\.|[^\\"])*"|(?:'(?:\\.|[^\\'])*')|(?:`(?:\\.|[^\
\`])*`)))
```

```
 QUOTEDSTRING (?>(?<!\\)(?>"(?>\\.|[^\\"]+)+"|""|(?>'(?>\\.|[^\\']+)+')|''|(?>`(?>\\.|
[^\\`]+)+`)|``))
 UUID [A-Fa-f0-9]{8}-(?:[A-Fa-f0-9]{4}-){3}[A-Fa-f0-9]{12}

 # Networking
 MAC (?:%{CISCOMAC:UNWANTED}|%{WINDOWSMAC:UNWANTED}|%{COMMONMAC:UNWANTED})
 CISCOMAC (?:(?:[A-Fa-f0-9]{4}\.){2}[A-Fa-f0-9]{4})
 WINDOWSMAC (?:(?:[A-Fa-f0-9]{2}-){5}[A-Fa-f0-9]{2})
 COMMONMAC (?:(?:[A-Fa-f0-9]{2}:){5}[A-Fa-f0-9]{2})
 IPV6 ((([0-9A-Fa-f]{1,4}:){7}([0-9A-Fa-f]{1,4}|:))|(([0-9A-Fa-f]{1,4}:){6}(:[0-9A-
Fa-f]{1,4}|((25[0-5]|2[0-4]\d|1\d\d|[1-9]?\d)(\.(25[0-5]|2[0-4]\d|1\d\d|[1-9]?\d))
{3})|:))|(([0-9A-Fa-f]{1,4}:){5}(((:[0-9A-Fa-f]{1,4}){1,2})|:((25[0-5]|2[0-4]\d|1\d
\d|[1-9]?\d)(\.(25[0-5]|2[0-4]\d|1\d\d|[1-9]?\d)){3})|:))|(([0-9A-Fa-f]{1,4}:){4}(((:
[0-9A-Fa-f]{1,4}){1,3})|((:[0-9A-Fa-f]{1,4})?:((25[0-5]|2[0-4]\d|1\d\d|[1-9]?\d)(\.
(25[0-5]|2[0-4]\d|1\d\d|[1-9]?\d)){3}))|:))|(([0-9A-Fa-f]{1,4}:){3}(((:[0-9A-Fa-f]
{1,4}){1,4})|((:[0-9A-Fa-f]{1,4}){0,2}:((25[0-5]|2[0-4]\d|1\d\d|[1-9]?\d)(\.(25[0-5]|
2[0-4]\d|1\d\d|[1-9]?\d)){3}))|:))|(([0-9A-Fa-f]{1,4}:){2}(((:[0-9A-Fa-f]{1,4}){1,5})|
((:[0-9A-Fa-f]{1,4}){0,3}:((25[0-5]|2[0-4]\d|1\d\d|[1-9]?\d)(\.(25[0-5]|2[0-4]\d|1\d
\d|[1-9]?\d)){3}))|:))|(([0-9A-Fa-f]{1,4}:){1}(((:[0-9A-Fa-f]{1,4}){1,6})|((:[0-9A-Fa-
f]{1,4}){0,4}:((25[0-5]|2[0-4]\d|1\d\d|[1-9]?\d)(\.(25[0-5]|2[0-4]\d|1\d\d|[1-9]?\d))
{3}))|:))|(:(((:[0-9A-Fa-f]{1,4}){1,7})|((:[0-9A-Fa-f]{1,4}){0,5}:((25[0-5]|2[0-4]\d|
1\d\d|[1-9]?\d)(\.(25[0-5]|2[0-4]\d|1\d\d|[1-9]?\d)){3}))|:))(%.+)?
 IPV4 (?<![0-9])(?:(?:25[0-5]|2[0-4][0-9]|[0-1]?[0-9]{1,2})[.](?:25[0-5]|2[0-4][0-9]|
[0-1]?[0-9]{1,2})[.](?:25[0-5]|2[0-4][0-9]|[0-1]?[0-9]{1,2})[.](?:25[0-5]|2[0-4][0-9]|
[0-1]?[0-9]{1,2}))(?![0-9])
 IP (?:%{IPV6:UNWANTED}|%{IPV4:UNWANTED})
 HOSTNAME \b(?:[0-9A-Za-z][0-9A-Za-z-_]{0,62})(?:\.(?:[0-9A-Za-z][0-9A-Za-z-_]
{0,62}))*(\.?|\b)
 HOST %{HOSTNAME:UNWANTED}
 IPORHOST (?:%{HOSTNAME:UNWANTED}|%{IP:UNWANTED})
 HOSTPORT (?:%{IPORHOST}:%{POSINT:PORT})

 # paths
 PATH (?:%{UNIXPATH}|%{WINPATH})
 UNIXPATH (?>/(?>[\w_%!$@:.,~-]+|\\.)*)+
 #UNIXPATH (?<![\w\/])(?:/[^\/\s?*]*)+
 TTY (?:/dev/(pts|tty([pq])?)(\w+)?/?(?:[0-9]+))
 WINPATH (?>[A-Za-z]+:|\\)(?:\\[^\\?*]*)+
 URIPROTO [A-Za-z]+(\+[A-Za-z+]+)?
 URIHOST %{IPORHOST}(?::%{POSINT:port})?
 # uripath comes loosely from RFC1738, but mostly from what Firefox
 # doesn't turn into %XX
 URIPATH (?:/[A-Za-z0-9$.+!*'(){},~:;=@#%_\-]*)+
 #URIPARAM \?(?:[A-Za-z0-9]+(?:=(?:[^&]*))?(?:&(?:[A-Za-z0-9]+(?:=(?:[^&]*))?)?)*)?
```

```
 URIPARAM \?[A-Za-z0-9$.+!*'|(){},~@#%&/=:;_?\-\[\]]*
 URIPATHPARAM %{URIPATH}(?:%{URIPARAM})?
 URI %{URIPROTO}://(?:%{USER}(?::[^@]*)?@)?(?:%{URIHOST})?(?:%{URIPATHPARAM})?

 # Months: January, Feb, 3, 03, 12, December
 MONTH \b(?:Jan(?:uary)?|Feb(?:ruary)?|Mar(?:ch)?|Apr(?:il)?|May|Jun(?:e)?|Jul(?:y)?|
Aug(?:ust)?|Sep(?:tember)?|Oct(?:ober)?|Nov(?:ember)?|Dec(?:ember)?)\b
 MONTHNUM (?:0?[1-9]|1[0-2])
 MONTHNUM2 (?:0[1-9]|1[0-2])
 MONTHDAY (?:(?:0[1-9])|(?:[12][0-9])|(?:3[01])|[1-9])

 # Days: Monday, Tue, Thu, etc...
 DAY (?:Mon(?:day)?|Tue(?:sday)?|Wed(?:nesday)?|Thu(?:rsday)?|Fri(?:day)?|
Sat(?:urday)?|Sun(?:day)?)

 # Years?
 YEAR (?>\d\d){1,2}
 # Time: HH:MM:SS
 #TIME \d{2}:\d{2}(?::\d{2}(?:\.\d+)?)?
 # TIME %{POSINT<24}:%{POSINT<60}(?::%{POSINT<60}(?:\.%{POSINT})?)?
 HOUR (?:2[0123]|[01]?[0-9])
 MINUTE (?:[0-5][0-9])
 # '60' is a leap second in most time standards and thus is valid.
 SECOND (?:(?:[0-5]?[0-9]|60)(?:[:.,][0-9]+)?)
 TIME (?!<[0-9])%{HOUR}:%{MINUTE}(?::%{SECOND})(?![0-9])
 # datestamp is YYYY/MM/DD-HH:MM:SS.UUUU (or something like it)
 DATE_US %{MONTHNUM}[/-]%{MONTHDAY}[/-]%{YEAR}
 DATE_EU %{MONTHDAY}[./-]%{MONTHNUM}[./-]%{YEAR}
 DATESTAMP_US %{DATE_US}[- ]%{TIME}
 DATESTAMP_EU %{DATE_EU}[- ]%{TIME}
 ISO8601_TIMEZONE (?:Z|[+-]%{HOUR}(?::?%{MINUTE}))
 ISO8601_SECOND (?:%{SECOND}|60)
 TIMESTAMP_ISO8601 %{YEAR}-%{MONTHNUM}-%{MONTHDAY}[T ]%{HOUR}:?%{MINUTE}(?::?
%{SECOND})?%{ISO8601_TIMEZONE}?
 TZ (?:[PMCE][SD]T|UTC)
 DATESTAMP_RFC822 %{DAY} %{MONTH} %{MONTHDAY} %{YEAR} %{TIME} %{TZ}
 DATESTAMP_RFC2822 %{DAY}, %{MONTHDAY} %{MONTH} %{YEAR} %{TIME} %{ISO8601_TIMEZONE}
 DATESTAMP_OTHER %{DAY} %{MONTH} %{MONTHDAY} %{TIME} %{TZ} %{YEAR}
 DATESTAMP_EVENTLOG %{YEAR}%{MONTHNUM2}%{MONTHDAY}%{HOUR}%{MINUTE}%{SECOND}
 CISCOTIMESTAMP %{MONTH} %{MONTHDAY} %{TIME}

 # Syslog Dates: Month Day HH:MM:SS
 SYSLOGTIMESTAMP %{MONTH} +%{MONTHDAY} %{TIME}
 PROG (?:[\w._/%-]+)
```

```
 SYSLOGPROG %{PROG:program}(?:\[%{POSINT:pid}\])?
 SYSLOGHOST %{IPORHOST}
 SYSLOGFACILITY <%{NONNEGINT:facility}.%{NONNEGINT:priority}>
 HTTPDATE %{MONTHDAY}/%{MONTH}/%{YEAR}:%{TIME} %{INT}

 # Shortcuts
 QS %{QUOTEDSTRING:UNWANTED}

 # Log formats
 SYSLOGBASE %{SYSLOGTIMESTAMP:timestamp} (?:%{SYSLOGFACILITY} )?%{SYSLOGHOST:logsource}
 %{SYSLOGPROG}:

 MESSAGESLOG %{SYSLOGBASE} %{DATA}

 COMMONAPACHELOG %{IPORHOST:clientip} %{USER:ident} %{USER:auth}
 \[%{HTTPDATE:timestamp}\] "(?:%{WORD:verb} %{NOTSPACE:request}(?: HTTP/
%{NUMBER:httpversion})?|%{DATA:rawrequest})" %{NUMBER:response} (?:%{Bytes:bytes=
%{NUMBER}|-})
 COMBINEDAPACHELOG %{COMMONAPACHELOG} %{QS:referrer} %{QS:agent}
 COMMONAPACHELOG_DATATYPED %{IPORHOST:clientip} %{USER:ident;boolean} %{USER:auth}
 \[%{HTTPDATE:timestamp;date;dd/MMM/yyyy:HH:mm:ss Z}\] "(?:%{WORD:verb;string}
 %{NOTSPACE:request}(?: HTTP/%{NUMBER:httpversion;float})?|%{DATA:rawrequest})"
 %{NUMBER:response;int} (?:%{NUMBER:bytes;long}|-)


 # Log Levels
 LOGLEVEL ([A|a]lert|ALERT|[T|t]race|TRACE|[D|d]ebug|DEBUG|[N|n]otice|NOTICE|[I|i]nfo|
INFO|[W|w]arn?(?:ing)?|WARN?(?:ING)?|[E|e]rr?(?:or)?|ERR?(?:OR)?|[C|c]rit?(?:ical)?|
CRIT?(?:ICAL)?|[F|f]atal|FATAL|[S|s]evere|SEVERE|EMERG(?:ENCY)?|[Ee]merg(?:ency)?)
```

Escritura de clasificadores personalizados XML

XML define la estructura de un documento utilizando etiquetas en el archivo. Con un clasificador personalizado XML, puede especificar el nombre de etiqueta usado para definir una fila.

Valores de clasificador personalizados para un clasificador XML

Al definir un clasificador XML, proporciona los siguientes valores a AWS Glue para crear el clasificador. El campo de clasificación de este clasificador se establece en `xml`.

Nombre

Nombre del clasificador.

Etiqueta de fila

El nombre de etiqueta XML que define una fila de tabla en el documento XML, sin paréntesis < >. El nombre debe cumplir las reglas de XML para una etiqueta.

> **Note**
>
> El elemento que contiene los datos de fila no puede ser un elemento vacío de autocierre. Por ejemplo, noAWS Glue analiza este elemento vacío:
>
> ```
> <row att1=”xx” att2=”yy” />
> ```
>
> Los elementos vacíos se pueden escribir de la siguiente manera:
>
> ```
> <row att1=”xx” att2=”yy”> </row>
> ```

AWS Glue realiza un seguimiento de la hora de creación, la hora de la última actualización y la versión de su clasificador.

Por ejemplo, suponga que tiene el archivo XML siguiente. Para crear una tabla de AWS Glue que solo contiene columnas para autor y título, cree un clasificador en la consola de AWS Glue con Row tag (Etiqueta de fila) como `AnyCompany`. A continuación, añada y ejecute un rastreador que use este clasificador personalizado.

```
<?xml version="1.0"?>
<catalog>
   <book id="bk101">
     <AnyCompany>
       <author>Rivera, Martha</author>
       <title>AnyCompany Developer Guide</title>
     </AnyCompany>
   </book>
   <book id="bk102">
     <AnyCompany>
```

```
        <author>Stiles, John</author>
        <title>Style Guide for AnyCompany</title>
      </AnyCompany>
    </book>
</catalog>
```

Escritura de clasificadores personalizados JSON

JSON es un formato de intercambio de datos. Define estructuras de datos con pares nombre-valor o una lista ordenada de valores. Con un clasificador personalizado JSON, puede especificar la ruta de JSON a una estructura de datos que se usa para definir el esquema para su tabla.

Valores personalizados del clasificador en AWS Glue

Al definir un clasificador JSON, proporciona los siguientes valores a AWS Glue para crear el clasificador. El campo de clasificación de este clasificador se establece en `json`.

Nombre

Nombre del clasificador.

JSON path (Ruta JSON)

Ruta de JSON que apunta a un objeto que se usa para definir un esquema de tabla. La ruta de JSON se puede escribir en la notación de puntos o la notación de corchete. Se admiten los siguientes operadores:

Descripción
Elemento raíz de un objeto JSON. Esto inicia todas las expresiones de ruta
Carácter comodín. Disponible allí donde se requiera un nombre o un valor numérico en la ruta de JSON.
Elemento secundario con notación de puntos. Especifica un campo secundario en un objeto JSON.
Elemento secundario con notación de corchete. Especifica el campo secundario en un objeto JSON. Solo se puede especificar un único campo secundario.
Índice de matriz. Especifica el valor de una matriz por índice.

AWS Glue realiza un seguimiento de la hora de creación, la hora de la última actualización y la versión de su clasificador.

Example Uso de un clasificador JSON para extraer registros de una matriz

Supongamos que sus datos JSON son una matriz de registros. Por ejemplo, las primeras líneas de su archivo podrían tener el siguiente aspecto:

```
[
  {
    "type": "constituency",
    "id": "ocd-division\/country:us\/state:ak",
    "name": "Alaska"
  },
  {
    "type": "constituency",
    "id": "ocd-division\/country:us\/state:al\/cd:1",
    "name": "Alabama's 1st congressional district"
  },
  {
    "type": "constituency",
    "id": "ocd-division\/country:us\/state:al\/cd:2",
    "name": "Alabama's 2nd congressional district"
  },
  {
    "type": "constituency",
    "id": "ocd-division\/country:us\/state:al\/cd:3",
    "name": "Alabama's 3rd congressional district"
  },
  {
    "type": "constituency",
    "id": "ocd-division\/country:us\/state:al\/cd:4",
    "name": "Alabama's 4th congressional district"
  },
  {
    "type": "constituency",
    "id": "ocd-division\/country:us\/state:al\/cd:5",
    "name": "Alabama's 5th congressional district"
  },
  {
    "type": "constituency",
    "id": "ocd-division\/country:us\/state:al\/cd:6",
```

```
    "name": "Alabama's 6th congressional district"
  },
  {
    "type": "constituency",
    "id": "ocd-division\/country:us\/state:al\/cd:7",
    "name": "Alabama's 7th congressional district"
  },
  {
    "type": "constituency",
    "id": "ocd-division\/country:us\/state:ar\/cd:1",
    "name": "Arkansas's 1st congressional district"
  },
  {
    "type": "constituency",
    "id": "ocd-division\/country:us\/state:ar\/cd:2",
    "name": "Arkansas's 2nd congressional district"
  },
  {
    "type": "constituency",
    "id": "ocd-division\/country:us\/state:ar\/cd:3",
    "name": "Arkansas's 3rd congressional district"
  },
  {
    "type": "constituency",
    "id": "ocd-division\/country:us\/state:ar\/cd:4",
    "name": "Arkansas's 4th congressional district"
  }
]
```

Al ejecutar un rastreador mediante el clasificador JSON integrado, todo el archivo se usará para definir el esquema. Como no especifica una ruta de JSON, el rastreador tratará los datos como un objeto, es decir, solo una matriz. Por ejemplo, el esquema podría tener el siguiente aspecto:

```
root
|-- record: array
```

Sin embargo, para crear un esquema que se basa en cada registro de la matriz JSON, cree un clasificador JSON personalizado y especifique la ruta de JSON como `$[*]`. Al especificar esta ruta de JSON, el clasificador interroga a los 12 registros de la matriz para determinar el esquema. El esquema resultante contiene campos independientes para cada objeto, similares al siguiente ejemplo:

```
root
|-- type: string
|-- id: string
|-- name: string
```

Example Uso de un clasificador JSON para examinar solo las partes de un archivo

Supongamos que sus datos JSON siguen el patrón del archivo JSON de ejemplo `s3://awsglue-datasets/examples/us-legislators/all/areas.json` procedente de http://everypolitician.org/. Los objetos de ejemplo del archivo JSON tienen un aspecto similar al siguiente:

```
{
  "type": "constituency",
  "id": "ocd-division\/country:us\/state:ak",
  "name": "Alaska"
}
{
  "type": "constituency",
  "identifiers": [
    {
      "scheme": "dmoz",
      "identifier": "Regional\/North_America\/United_States\/Alaska\/"
    },
    {
      "scheme": "freebase",
      "identifier": "\/m\/0hjy"
    },
    {
      "scheme": "fips",
      "identifier": "US02"
    },
    {
      "scheme": "quora",
      "identifier": "Alaska-state"
    },
    {
      "scheme": "britannica",
      "identifier": "place\/Alaska"
    },
    {
      "scheme": "wikidata",
```

```
      "identifier": "Q797"
    }
  ],
  "other_names": [
    {
      "lang": "en",
      "note": "multilingual",
      "name": "Alaska"
    },
    {
      "lang": "fr",
      "note": "multilingual",
      "name": "Alaska"
    },
    {
      "lang": "nov",
      "note": "multilingual",
      "name": "Alaska"
    }
  ],
  "id": "ocd-division\/country:us\/state:ak",
  "name": "Alaska"
}
```

Al ejecutar un rastreador mediante el clasificador JSON integrado, todo el archivo se usará para crear el esquema. Es posible que termine contando con un esquema similar a este:

```
root
|-- type: string
|-- id: string
|-- name: string
|-- identifiers: array
|    |-- element: struct
|    |    |-- scheme: string
|    |    |-- identifier: string
|-- other_names: array
|    |-- element: struct
|    |    |-- lang: string
|    |    |-- note: string
|    |    |-- name: string
```

Sin embargo, para crear un esquema con solo el objeto “`id`”, cree un clasificador JSON personalizado y especifique la ruta de JSON como `$.id`. A continuación, el esquema se basa solo en el campo “`id`”:

```
root
|-- record: string
```

Las primeras líneas de datos extraídas con este esquema tienen el siguiente aspecto:

```
{"record": "ocd-division/country:us/state:ak"}
{"record": "ocd-division/country:us/state:al/cd:1"}
{"record": "ocd-division/country:us/state:al/cd:2"}
{"record": "ocd-division/country:us/state:al/cd:3"}
{"record": "ocd-division/country:us/state:al/cd:4"}
{"record": "ocd-division/country:us/state:al/cd:5"}
{"record": "ocd-division/country:us/state:al/cd:6"}
{"record": "ocd-division/country:us/state:al/cd:7"}
{"record": "ocd-division/country:us/state:ar/cd:1"}
{"record": "ocd-division/country:us/state:ar/cd:2"}
{"record": "ocd-division/country:us/state:ar/cd:3"}
{"record": "ocd-division/country:us/state:ar/cd:4"}
{"record": "ocd-division/country:us/state:as"}
{"record": "ocd-division/country:us/state:az/cd:1"}
{"record": "ocd-division/country:us/state:az/cd:2"}
{"record": "ocd-division/country:us/state:az/cd:3"}
{"record": "ocd-division/country:us/state:az/cd:4"}
{"record": "ocd-division/country:us/state:az/cd:5"}
{"record": "ocd-division/country:us/state:az/cd:6"}
{"record": "ocd-division/country:us/state:az/cd:7"}
```

Para crear un esquema basado en un objeto profundamente anidado, como “`identifier`”, en el archivo JSON, puede crear un clasificador JSON personalizado y especificar la ruta de JSON como `$.identifiers[*].identifier`. Aunque el esquema es similar al ejemplo anterior, se basa en un objeto diferente del archivo JSON.

El esquema sería similar al siguiente:

```
root
```

```
|-- record: string
```

Al mostrar las primeras líneas de datos de la tabla, se muestra a su vez que el esquema se basa en los datos del objeto “`identifier`”:

```
{"record": "Regional/North_America/United_States/Alaska/"}
{"record": "/m/0hjy"}
{"record": "US02"}
{"record": "5879092"}
{"record": "4001016-8"}
{"record": "destination/alaska"}
{"record": "1116270"}
{"record": "139487266"}
{"record": "n79018447"}
{"record": "01490999-8dec-4129-8254-eef6e80fadc3"}
{"record": "Alaska-state"}
{"record": "place/Alaska"}
{"record": "Q797"}
{"record": "Regional/North_America/United_States/Alabama/"}
{"record": "/m/0gyh"}
{"record": "US01"}
{"record": "4829764"}
{"record": "4084839-5"}
{"record": "161950"}
{"record": "131885589"}
```

Para crear una tabla basada en otro objeto profundamente anidado, como el campo “`name`” de la matriz “`other_names`” del archivo JSON, puede crear un clasificador JSON personalizado y especificar la ruta de JSON como `$.other_names[*].name`. Aunque el esquema es similar al ejemplo anterior, se basa en un objeto diferente del archivo JSON. El esquema sería similar al siguiente:

```
root
|-- record: string
```

Al mostrar las primeras líneas de datos de la tabla, se muestra a su vez que se basa en los datos del objeto “`name`” de la matriz “`other_names`”:

```
{"record": "Alaska"}
{"record": "Alaska"}
{"record": "Аляска"}
{"record": "Alaska"}
{"record": "Alaska"}
{"record": "Alaska"}
{"record": "Alaska"}
{"record": "Alaska"}
{"record": "Alaska"}
{"record": "######"}
{"record": "######"}
{"record": "######"}
{"record": "Alaska"}
{"record": "Alyaska"}
{"record": "Alaska"}
{"record": "Alaska"}
{"record": "Штат Аляска"}
{"record": "Аляска"}
{"record": "Alaska"}
{"record": "#######"}
```

Escritura de clasificadores personalizados CSV

Los clasificadores CSV personalizados permiten especificar los tipos de datos para cada columna en el campo del clasificador CSV personalizado. Se puede especificar el tipo de datos separados por una coma. Al especificar los tipos de datos, se pueden anular los tipos de datos inferidos por los rastreadores y garantizar que los datos se clasifiquen correctamente.

Puede configurar el SerDe para procesar CSV en el clasificador, lo que se aplicará en el Data Catalog.

Al crear un clasificador personalizado, también se puede volver a utilizarlo para diferentes rastreadores.

- Para los archivos CSV con solo encabezados (sin datos), estos archivos se clasificarán como DESCONOCIDOS ya que no se proporciona suficiente información. Si especifica que el CSV “tiene encabezados” en la opción Encabezados de columna y proporciona los tipos de datos, se pueden clasificar estos archivos correctamente.

Puede utilizar un clasificador CSV personalizado para deducir el esquema de distintos tipos de datos CSV. Entre los atributos personalizados que puede proporcionar para el clasificador, se incluyen los

delimitadores, una opción de SerDe de CSV, las opciones sobre el encabezado y si se van a realizar o no ciertas validaciones de los datos.

Valores personalizados del clasificador en AWS Glue

Cuando defina un clasificador CSV, debe proporcionar los siguientes valores a AWS Glue para que pueda crear el clasificador. El campo de clasificación de este clasificador se establece en `csv`.

Classifier name (Nombre de clasificador)

Nombre del clasificador.

Serde de CSV

Establece el SerDe para procesar CSV en el clasificador, que se aplicará en el catálogo de datos. Las opciones son Open CSV SerDe, Lazy Simple SerDe y None. Puede especificar el valor Ninguno cuando desee que el rastreador realice la detección.

Delimitador de columnas

Símbolo personalizado que indica qué elemento va a separar cada entrada de columna en la fila. Proporcione un carácter Unicode. Si no puede escribir el delimitador, puede copiarlo y pegarlo. Esto funciona con los caracteres imprimibles, incluidos con los que el sistema no es compatible (normalmente se muestran como □).

Símbolo de comillas

Símbolo personalizado que indica qué elemento va a combinar contenido en un valor de columna único. Debe ser diferente al delimitador de columnas. Proporcione un carácter Unicode. Si no puede escribir el delimitador, puede copiarlo y pegarlo. Esto funciona con los caracteres imprimibles, incluidos con los que el sistema no es compatible (normalmente se muestran como □).

Encabezados de columna

Indica cómo deben detectarse los encabezados de columna en el archivo CSV. Si el archivo CSV personalizado tiene encabezados de columna, escriba una lista delimitada por comas con los encabezados de columna.

Opciones de procesamiento: permitir archivos con una sola columna

Permite procesar los archivos que contienen una sola columna.

Opciones de procesamiento: quitar un espacio en blanco antes de identificar los valores de columna

Indica si los valores se van a recortar antes de identificar el tipo de valores de columna.

Tipos de datos personalizados: opcional

Ingrese el tipo de datos personalizado separados por una coma. Especifica los tipos de datos personalizados del archivo CSV. El tipo de datos personalizado debe ser un tipo de datos compatible. Los tipos de datos admitidos son: “BINARIO”, “BOOLEANO”, “FECHA”, “DECIMAL”, “DOUBLE”, “FLOAT”, “INT”, “LONG”, “SHORT”, “STRING”, “TIMESTAMP”. Los tipos de datos no compatibles mostrarán un error.

Creación de clasificadores mediante la consola de AWS Glue

Un clasificador determina el esquema de sus datos. Puede escribir un clasificador personalizado y apuntar a él desde AWS Glue.

Creación de clasificadores

Para añadir un clasificador en la consola de AWS Glue, seleccione Add classifier (Añadir clasificador). Cuando define un clasificador, suministra valores para los elementos siguientes:

- Nombre del clasificador: facilita un nombre único para el clasificador.
- Tipo de clasificador: tipo de clasificación de las tablas que este clasificador deduce.
- Última actualización: última actualización de este clasificador.

Classifier name (Nombre de clasificador)

Facilite un nombre único para el clasificador.

Tipo de clasificador

Elija el tipo de clasificador que debe crearse.

Dependiendo del tipo de clasificador que elija, configure las siguientes propiedades para el clasificador:

Grok

- Clasificación

  Describa el formato o el tipo de datos que se clasifica o proporcione una etiqueta personalizada.

- Patrón de Grok

  Este valor se utiliza para analizar los datos en un esquema estructurado. El patrón de grok se compone de patrones con nombre que describen el formato de su almacén de datos. Debe escribir este patrón de grok con los patrones integrados con nombre que AWS Glue proporciona y los patrones personalizados que escribe e incluye en el campo Custom patterns (Patrones personalizados). Aunque puede que los resultados del depurador de grok no coincidan exactamente con los resultados de AWS Glue, le sugerimos que pruebe su patrón utilizando algunos datos de muestra con un depurador de grok. Puede encontrar depuradores de grok en la web. Los patrones integrados con nombre que AWS Glue proporciona suelen ser compatibles con los patrones de grok que están disponibles en la web.

  Cree su patrón de grok añadiendo iterativamente patrones con nombre y compruebe sus resultados en un depurador. Esta actividad le ofrece la confianza de que cuando el rastreador de AWS Glue ejecute el patrón de grok, sus datos se podrán analizar.

- Patrones personalizados

  Para los clasificadores de grok, son componentes básicos opcionales del Grok pattern (Patrón de grok) que escribe. Cuando los patrones integrados no pueden analizar sus datos, es posible que tenga que escribir un patrón personalizado. Estos patrones personalizados se definen en este campo y se hace referencia a ellos en el campo Grok pattern (Patrón de Grok). Cada patrón personalizado se define en una línea independiente. Al igual que los patrones integrados, se compone de una definición de patrón con nombre que utiliza la sintaxis expresión regular (regex).

  En el ejemplo siguiente se ve el nombre `MESSAGEPREFIX` seguido de una definición de expresión regular para aplicarla a sus datos a fin de establecer si siguen el patrón o no.

```
MESSAGEPREFIX .*-.*-.*-.*-.*
```

XML

- Etiqueta de fila

  Para los clasificadores de XML, nombre de la etiqueta XML que define una fila de una tabla en el documento XML. Escriba el nombre sin corchetes angulares < >. El nombre debe cumplir las reglas de XML para una etiqueta.

Para obtener más información, consulte Escritura de clasificadores personalizados XML.

JSON

- JSON path (Ruta JSON)

  Para los clasificadores de JSON, ruta de JSON al objeto, la matriz o el valor que define una fila de la tabla que se está creando. Escriba el nombre con sintaxis JSON de punto o corchete y utilizando los operadores compatibles de AWS Glue.

  Para obtener más información, consulte la lista de operadores en Escritura de clasificadores personalizados JSON.

CSV

- Delimitador de columnas

  Único caracter o símbolo personalizado que indica qué elemento va a separar cada entrada de columna en la fila. Elija el delimitador en la lista o elija `Other` para introducir un delimitador personalizado.

- Símbolo de comillas

  Único caracter o símbolo personalizado que indica qué elemento va a combinar contenido en un valor de columna único. Debe ser diferente al delimitador de columnas. Elija el símbolo de comillas de la lista o elija `Other` para introducir un carácter de comilla personalizado.

- Encabezados de columna

  Indica cómo deben detectarse los encabezados de columna en el archivo CSV. Puede elegir `Has headings`, `No headings`, o `Detect headings`. Si el archivo CSV personalizado tiene encabezados de columna, escriba una lista delimitada por comas con los encabezados de columna.

- Permita archivos con una sola columna

  Para clasificarse como CSV, los datos deben tener al menos dos columnas y dos filas de datos. Utilice esta opción para permitir procesar los archivos que contienen una sola columna.

- Quite los espacios en blanco antes de identificar los valores de columna

Esta opción indica si los valores se van a recortar antes de identificar el tipo de valores de columna.

- Tipo de datos personalizado

  (Opcional): ingrese los tipos de datos personalizados en una lista delimitada por comas. Los tipos de datos admitidos son: “BINARIO”, “BOOLEANO”, “FECHA”, “DECIMAL”, “DOUBLE”, “FLOAT”, “INT”, “LONG”, “SHORT”, “STRING”, “TIMESTAMP”.

- Serde de CSV

  (Opcional): un SerDe para procesar CSV en el clasificador, lo que se aplicará en el catálogo de datos. Elija entre `Open CSV SerDe`, `Lazy Simple SerDe` o `None`. Puede especificar el valor `None` cuando desee que el rastreador realice la detección.

Para obtener más información, consulte Redacción de clasificadores personalizados para diversos formatos de datos.

Visualización de clasificadores

Para ver una lista de todos los clasificadores que ha creado, abra la consola de AWS Glue en https://console.aws.amazon.com/glue/ y elija la pestaña Classifiers (Clasificadores).

La lista muestra las siguientes propiedades sobre cada clasificador:

- Clasificadores: nombre del clasificador. Cuando crea un clasificador, debe proporcionarle un nombre.
- Clasificación: tipo de clasificación de las tablas que este clasificador deduce.
- Última actualización: última actualización de este clasificador.

Administración de clasificadores

En la lista Classifiers (Clasificadores) de la consola de AWS Glue, puede añadir, editar y eliminar clasificadores. Para consultar más detalles sobre un clasificador, seleccione el nombre del clasificador en la lista. Los detalles incluirán la información que definió al crear el clasificador.

Configuración de rastreadores

Un rastreador obtiene acceso al almacén de datos, identifica metadatos y crea definiciones de tablas en AWS Glue Data Catalog. El panel Crawlers (Rastreadores) de la consola de AWS Glue lista todos

los rastreadores que crea. La lista muestra el estado y las métricas desde la última ejecución de su rastreador.

Este tema contiene el proceso paso a paso de configuración de un rastreador y abarca aspectos clave como la configuración de parámetros del rastreador, la definición de los orígenes de datos que se van a rastrear, la configuración de la seguridad y la administración de los datos rastreados.

Temas

- Paso 1: configurar las propiedades del rastreador
- Paso 2: elegir orígenes de datos y clasificadores
- Paso 3: Establecer configuración de seguridad
- Paso 4: establecer salida y programación
- Paso 5: Revisar y crear

Paso 1: configurar las propiedades del rastreador

Cómo configurar un rastreador

1. Inicie sesión en la Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/. Elija Crawlers (Rastreadores) en el panel de navegación.
2. Elija Crear rastreador y siga las instrucciones en el asistente Crear rastreador. El asistente le explicará los pasos necesarios para crear un rastreador. Si desea añadir clasificadores personalizados para definir el esquema, consulte Definición y administración de clasificadores.
3. Ingrese un nombre y una descripción para su rastreador (opcional). Si lo desea, puede etiquetar el rastreador con una clave de etiqueta y un valor de etiqueta opcional. Una vez creadas, las claves de etiqueta son de solo lectura. Utilice etiquetas en algunos recursos para que le resulte más fácil organizarlos e identificarlos. Para obtener más información, consulte las etiquetas de AWS en AWS Glue.

   Nombre

   El nombre puede contener letras (A-Z), números (0-9), guiones (-) o guiones bajos (_) y puede tener un máximo de 255 caracteres.

   Descripción

   La descripción puede tener una longitud máxima de 2048 caracteres.

Etiquetas

Utilice etiquetas para organizar e identificar los recursos. Para obtener más información, consulte los siguientes temas:

- Etiquetas de AWS en AWS Glue

Paso 2: elegir orígenes de datos y clasificadores

A continuación, configure los orígenes de datos y los clasificadores del rastreador.

Para obtener más información sobre orígenes de datos compatibles, consulte Orígenes de datos admitidos para el rastreo.

Configuración del origen de datos

Seleccione la opción que corresponda para responder la pregunta ¿Sus datos ya están asignados a tablas de AWS Glue?: elija «Aún no» o «Sí». De manera predeterminada, está seleccionado 'Aún no'.

El rastreador puede acceder a los almacenes de datos directamente como origen de rastreo o puede utilizar tablas existentes del Catálogo de datos como origen. Si el rastreador utiliza tablas de catálogos existentes, este rastrea los almacenes de datos especificados por dichas tablas de catálogos.

- Not yet (Aún no): seleccione uno o varios orígenes de datos para rastrearlos. Un rastreador puede rastrear varios almacenes de datos de diferentes tipos (Amazon S3, JDBC, etc.).

  Solo puede configurar un almacén de datos por vez. Después de proporcionar la información de conexión e incluir rutas de acceso y patrones de exclusión, tendrá la opción de agregar otro almacén de datos.
- Yes (Sí): seleccione las tablas existentes de su Catálogo de datos de AWS Glue. Las tablas de catálogos especifican los almacenes de datos que se van a rastrear. El rastreador puede rastrear solo tablas de catálogos en una única ejecución; no puede combinar otros tipos de fuentes.

  Una razón habitual para especificar una tabla de catálogo como origen es que creó la tabla de forma manual (dado que ya conocía la estructura del almacén de datos) y quiere un rastreador para mantener la tabla actualizada, incluido el agregado de nuevas particiones. Para obtener información de otras razones, consulte Actualización de tablas del Catálogo de datos creadas de forma manual mediante rastreadores.

Cuando especifique las tablas existentes como el tipo de origen de rastreador, se aplicarán las siguientes condiciones:

- El nombre de la base de datos es opcional.
- Solo se permiten las tablas de catálogos que especifiquen los almacenes de datos de Amazon S3, Amazon DynamoDB o Delta Lake.
- No se crean nuevas tablas de catálogos cuando el rastreador se ejecuta. Las tablas existentes se actualizan según sea necesario, lo que incluye la adición de nuevas particiones.
- Los objetos eliminados encontrados en los almacenes de datos se ignoran; no se eliminan tablas de catálogos. En su lugar, el rastreador escribe un mensaje de registro. (`SchemaChangePolicy.DeleteBehavior=LOG`)
- La opción de la configuración del rastreador para crear un único esquema para cada ruta de Amazon S3 está activada de forma predeterminada y no se puede desactivar. (`TableGroupingPolicy=CombineCompatibleSchemas`) Para obtener más información, consulte Creación de un único esquema para cada ruta de inclusión de Amazon S3.
- No se pueden combinar las tablas de catálogos como origen con cualquier otro tipo de origen (por ejemplo, Amazon S3 o Amazon DynamoDB).

Para usar tablas Delta, primero cree una tabla Delta con el DDL de Athena o la API de AWS Glue.

Mediante Athena, establezca la ubicación en su carpeta Amazon S3 y el tipo de tabla en “DELTA”.

```
CREATE EXTERNAL TABLE database_name.table_name
LOCATION 's3://bucket/folder/'
TBLPROPERTIES ('table_type' = 'DELTA')
```

Con la API de AWS Glue, especifique el tipo de tabla en el mapa de parámetros de la tabla. Los parámetros de la tabla deben incluir el siguiente par clave/valor. Para obtener más información sobre cómo crear una tabla, consulte la documentación de Boto3 sobre create_table.

```
{
    "table_type":"delta"
}
```

Origen de datos

Seleccione o agregue la lista de orígenes de datos que el rastreador va a analizar.

(Opcional) Si elige JDBC como origen de datos, puede usar sus propios controladores JDBC al especificar el acceso a la conexión en el que se almacena la información del controlador.

Incluir ruta

Al evaluar lo que se va a incluir o excluir en un rastreo, un rastreador comienza por evaluar la ruta de inclusión necesaria. Para almacenes de datos relacionales, Amazon S3, MongoDB, MongoDB Atlas y Amazon DocumentDB (con compatibilidad con MongoDB), debe especificar una ruta de inclusión.

Para un almacén de datos de Amazon S3

Elija si desea especificar una ruta de esta cuenta o de una cuenta diferente y busque una ruta de Amazon S3.

Para los almacenes de datos de Amazon S3, la sintaxis de ruta de inclusión es `bucket-name/folder-name/file-name.ext`. Para rastrear todos los objetos de un bucket, debe especificar solo el nombre de bucket en la ruta de inclusión. EL patrón de exclusión es relativo a la ruta de inclusión

Para un almacén de datos de Delta Lake:

Especifique una o más rutas de Simple Storage Service (Amazon S3) a las tablas Delta como s3://*bucket*/*prefijo*/*objeto*.

Para un almacén de datos de Iceberg o Hudi

Especifique una o más rutas de Amazon S3 que contengan carpetas con metadatos de tablas de Iceberg o Hudi como s3://bucket/prefijo.

En el caso de los almacenes de datos de Iceberg y Hudi, la carpeta de Iceberg/Hudi puede estar ubicada en una carpeta secundaria de la carpeta raíz. El rastreador escaneará todas las carpetas situadas debajo de una ruta para una carpeta Hudi.

En un almacén de datos JDBC

Ingrese *<database>*/*<schema>*/*<table>* o *<database>*/*<table>*, en función del producto de base de datos. Oracle Database y MySQL no permiten utilizar un esquema en la ruta. Puede sustituir *<esquema>* o *<tabla>* por el carácter de porcentaje (%). Por ejemplo, en una base de datos Oracle con el identificador del sistema (SID) `orcl`, escriba `orcl/%` para importar todas las tablas a las que el usuario especificado en la conexión tiene acceso.

> **Important**
>
> Este campo distingue entre mayúsculas y minúsculas.

> **Note**
>
> Si decide incorporar sus versiones de controladores JDBC, los rastreadores AWS Glue consumirán recursos en trabajos AWS Glue y en los buckets de Amazon S3 para garantizar que los controladores proporcionados se ejecuten en su entorno. El uso adicional de los recursos se reflejará en su cuenta. Los controladores están limitados a las propiedades descritas en Agregar una conexión AWS Glue.

Para un almacén de datos MongoDB, MongoDB Atlas o Amazon DocumentDB

Para MongoDB, MongoDB Atlas y Amazon DocumentDB (con compatibilidad con MongoDB), la sintaxis es `database/collection`.

Para los almacenes de datos de JDBC, la sintaxis es `database-name/schema-name/table-name` o `database-name/table-name`. La sintaxis depende de si el motor de base de datos admite esquemas en una base de datos. Por ejemplo, en el caso de motores de base de datos como MySQL u Oracle, no especifique `schema-name` en la ruta de inclusión. Puede sustituir el signo de porcentaje (`%`) de un esquema o una tabla en la ruta de inclusión para representar todos los esquemas o todas las tablas de una base de datos. No se puede sustituir el signo de porcentaje (`%`) de base de datos en la ruta de inclusión.

Profundidad transversal máxima (solo para los almacenes de datos de Iceberg o Hudi)

Define la profundidad máxima de la ruta de Amazon S3 que el rastreador puede recorrer para descubrir la carpeta de metadatos de Iceberg o Hudi en la ruta de Amazon S3. El objetivo de este parámetro es limitar el tiempo de ejecución del rastreador. El valor predeterminado es 10 y el valor máximo es 20.

Patrones de exclusión

Estos le permiten excluir determinados archivos o tablas desde del rastreo. Una ruta de exclusión es relativa a la ruta de inclusión. Por ejemplo, para excluir una tabla en su almacén de datos de JDBC, escriba el nombre de la tabla en la ruta de exclusión.

Un rastreador se conecta a un almacén de datos de JDBC mediante una conexión de AWS Glue que contiene una cadena de conexión de URI de JDBC. El rastreador solo tiene acceso a los objetos en el motor de base de datos mediante el nombre de usuario y la contraseña de JDBC de la conexión de AWS Glue. El rastreador solo puede crear tablas a las que puede obtener acceso a través de la conexión de JDBC. Una vez que el rastreador obtiene acceso al motor de base de datos con el URI de JDBC, la ruta de inclusión se utiliza para determinar qué tablas de datos del motor de base de datos se crean en el Catálogo de datos. Por ejemplo, con MySQL, si especifica una ruta de inclusión de `MyDatabase/%`, todas las tablas en `MyDatabase` se crean en el Catálogo de datos. Al obtener acceso a Amazon Redshift, si especifica una ruta de inclusión de `MyDatabase/%`, todas las tablas en todos los esquemas de la base de datos `MyDatabase` se crean en el Catálogo de datos. Si especifica una ruta de inclusión de todas `MyDatabase/MySchema/%`, se crean todas las tablas de la base de datos `MyDatabase` y el esquema `MySchema`.

Después de especificar una ruta de inclusión, puede excluir objetos del rastreo que, de otro modo, su ruta de inclusión incluiría especificando uno o varios patrones de exclusión `glob` tipo Unix. Estos patrones se aplican a la ruta de inclusión para determinar qué objetos están excluidos. Estos patrones también se almacenan como una propiedad de las tablas creadas por el rastreador. AWS Glue Las extensiones PySpark, como `create_dynamic_frame.from_catalog`, leen las propiedades de la tabla y excluyen los objetos definidos por el patrón de exclusión.

AWS Glue admite los siguientes patrones `glob` en el patrón de exclusión.

Patrón de exclusión	Descripción
`*.csv`	Coincide con una ruta de Amazon S3 que representa un nombre de objeto de la carpeta actual que termina en `.csv`
`*.*`	Coincide con todos los nombres de objeto que contienen un punto
`*.{csv,avro}`	Coincide con los nombres de objeto que terminan con `.csv` o `.avro`

Patrón de exclusión	Descripción
`foo.?`	Coincide con los nombres de objeto que comienzan por `foo.` a los que sigue una extensión de un solo carácter
`myfolder/*`	Coincide con los objetos en un nivel de subcarpeta desde `myfolder`, como `/myfolder/mysource`
`myfolder/*/*`	Coincide con los objetos en dos niveles de subcarpetas desde `myfolder`, como `/myfolder/mysource/data`
`myfolder/**`	Coincide con los objetos en todas las subcarpetas de `myfolder`, como `/myfolder/mysource/mydata` y `/myfolder/mysource/data`
`myfolder**`	Coincide con la subcarpeta `myfolder` así como con los archivos debajo de `myfolder`, como `/myfolder` y `/myfolder/mydata.txt`
`Market*`	Coincide con las tablas en una base de datos de JDBC con nombres que comienzan por `Market`, como `Market_us` y `Market_fr`

AWS Glue interpreta los patrones de exclusión `glob` de la siguiente manera:

- El carácter de barra inclinada (`/`) es el delimitador para separar claves de Amazon S3 en una jerarquía de carpetas.
- El carácter asterisco (`*`) coincide con cero o varios caracteres de un componente de nombre sin superar límites de carpeta.
- Dos asteriscos (`**`) coinciden con cero o varios caracteres que superan límites de carpeta o esquema.

- El signo de interrogación (`?`) coincide exactamente con un carácter de un componente de nombre.
- El carácter de barra inversa (`\`) se usa para escapar caracteres que de otro modo se pueden interpretar como caracteres especiales. La expresión `\\` coincide con una sola barra inversa y `\{` coincide con una llave de apertura.
- Los corchetes `[ ]` crean una expresión de corchetes que coincide con un solo carácter de un componente de nombre fuera de un conjunto de caracteres. Por ejemplo, `[abc]` coincide con `a`, `b` o `c`. El guion (`-`) se puede usar para especificar un rango, por lo que `[a-z]` especifica un rango que coincide de la `a` a la `z` (inclusive). Estas formas se pueden mezclar, por lo que `[abce-g]` coincide con `a`, `b`, `c`, `e`, `f` o `g`. Si el carácter después del corchete (`[`) es un signo de exclamación (`!`), la expresión de corchetes se niega. Por ejemplo, `[!a-c]` coincide con cualquier carácter salvo con `a`, `b` o `c`.

  Dentro de una expresión de corchete, los caracteres `*`, `?` y `\` coinciden con ellos mismos. El guion (`-`) coincide consigo mismo si es el primer carácter dentro de los corchetes o si es el primer carácter después de `!` durante la negación.
- Las llaves (`{ }`) incluyen un grupo de subpatrones, donde el grupo coincide si cualquier subpatrón del grupo coincide. Una coma (`,`) se usa para separar los subpatrones. Los grupos no pueden estar anidados.
- Los puntos al inicio de los nombres de archivo se tratan como caracteres normales en las operaciones de coincidencia. Por ejemplo, el patrón de exclusión `*` coincide con el nombre de archivo `.hidden`.

Example Amazon S3 excluye patrones

Cada patrón de exclusión se evalúa con respecto a la ruta de inclusión. Por ejemplo, suponga que tiene la estructura de directorios de Amazon S3 siguiente:

```
/mybucket/myfolder/
   departments/
      finance.json
      market-us.json
      market-emea.json
      market-ap.json
   employees/
      hr.json
      john.csv
      jane.csv
```

```
    juan.txt
```

Dada la ruta de inclusión `s3://mybucket/myfolder/`, estos son algunos resultados de ejemplo para los patrones de exclusión:

Patrón de exclusión	Resultados
`departments/**`	Excluye todas las carpetas y archivos situados debajo de `departments` e incluye la carpeta `employees` y sus archivos
`departments/market*`	Excluye `market-us.json` , `market-emea.json` y `market-ap.json`
`**.csv`	Excluye todos los objetos situados debajo de `myfolder` con un nombre terminado con `.csv`
`employees/*.csv`	Excluye todos los archivos `.csv` de la carpeta `employees`

Example Excluir un subconjunto de particiones de Amazon S3

Supongamos que sus datos se particionan por día de modo que cada uno de los días de un año esté en una partición de Amazon S3 independiente. En enero de 2015, hay 31 particiones. Ahora, para rastrear datos durante solo la primera semana de enero, debe excluir todas las particiones excepto del día 1 al 7:

```
2015/01/{[!0],0[8-9]}**, 2015/0[2-9]/**, 2015/1[0-2]/**
```

Veamos las partes de este patrón de glob. La primera parte, `2015/01/{[!0],0[8-9]}**`, excluye todos los días que no comienzan por "0", además de los días 08 y 09 del mes 01 del año 2015. Tenga en cuenta que "**" se usa como sufijo del patrón de número de día y supera límites de carpeta hasta alcanzar carpetas de nivel más bajo. Si "*" se usa, los niveles de carpeta más bajos no se excluyen.

La segunda parte, `2015/0[2-9]/**`, excluye días de los meses comprendidos entre el 02 y el 09 del año 2015.

La tercera parte, `2015/1[0-2]/**`, excluye días de los meses 10, 11 y 12 del año 2015.

Example Patrones de exclusión de JDBC

Supongamos que rastrea una base de datos de JDBC con la siguiente estructura de esquema:

```
MyDatabase/MySchema/
   HR_us
   HR_fr
   Employees_Table
   Finance
   Market_US_Table
   Market_EMEA_Table
   Market_AP_Table
```

Dada la ruta de inclusión `MyDatabase/MySchema/%`, estos son algunos resultados de ejemplo para los patrones de exclusión:

Patrón de exclusión	Resultados
`HR*`	Excluye las tablas con nombres que comienzan por `HR`
`Market_*`	Excluye las tablas con nombres que comienzan por `Market_`
`**_Table`	Excluye todas las tablas con nombres que finalizan con `_Table`

Parámetros adicionales de origen de rastreadores

Cada tipo de origen requiere un conjunto diferente de parámetros adicionales.

Connection

Seleccione o agregue una conexión de AWS Glue. Para obtener más información acerca de las conexiones, consulte Conexión a datos.

Metadatos adicionales: opcionales (para almacenes de datos de JDBC)

Seleccione propiedades de metadatos adicionales para que el rastreador las rastree.

- Comments (Comentarios): se rastrean los comentarios asociados de tabla y columna.
- Raw types (Tipos sin procesar): se mantienen los tipos de datos sin procesar de las columnas de la tabla en metadatos adicionales. Como comportamiento predeterminado, el rastreador traduce los tipos de datos sin procesar a tipos compatibles con Hive.

Nombre de clase de controlador JDBC: opcional (para almacenes de datos JDBC)

Escriba un nombre de clase de controlador JDBC personalizado para que el rastreador se conecte al origen de datos:

- Postgres: org.postgresql.Driver
- MySQL: com.mysql.jdbc.Driver, com.mysql.cj.jdbc.Driver
- Redshift: com.amazon.redshift.jdbc.Driver, com.amazon.redshift.jdbc42.Driver
- Oracle: oracle.jdbc.driver.OracleDriver
- SQL Server: com.microsoft.sqlserver.jdbc.SQLServerDriver

Ruta S3 del controlador JDBC: opcional (para almacenes de datos JDBC)

Elija una ruta de Amazon S3 existente para un archivo `.jar`. Aquí es donde se almacenará el archivo `.jar` cuando se utilice un controlador JDBC personalizado para que el rastreador se conecte al origen de datos.

Habilitación del muestreo de datos (solo en almacenes de datos Amazon DynamoDB, MongoDB, MongoDB Atlas y Amazon DocumentDB)

Seleccione si desea rastrear solo una muestra de datos. Si no lo selecciona, se rastreará toda la tabla. Escanear todos los registros puede tardar mucho tiempo cuando la tabla no es una tabla de alto rendimiento.

Crear tablas para consultar (solo para almacenes de datos de Delta Lake)

Seleccione cómo desea crear las tablas de Delta Lake:

- Crear tablas nativas: se permite la integración con los motores de consulta que permiten consultar directamente el registro de transacciones de Delta.
- Create Symlink tables (Crear tablas de enlaces simbólicos): se crea una carpeta de manifiesto de enlaces simbólicos con los archivos de manifiesto particionados mediante las claves de partición en función de los parámetros de configuración especificados.

Scanning rate (Velocidad de análisis): opcional (solo en almacenes de datos de DynamoDB)

Especifique el porcentaje de las unidades de capacidad de lectura de tablas de DynamoDB que utilizará el rastreador. Unidades de capacidad de lectura es un término definido por DynamoDB y es un valor numérico que actúa como limitador de velocidad del número de lecturas que se pueden realizar en esa tabla por segundo. Introduzca un valor comprendido entre 0,1 y 1,5. Si no se especifica, el valor predeterminado es de 0,5 para las tablas aprovisionadas y 1/4 de la capacidad máxima configurada para las tablas bajo demanda. Tenga en cuenta que solo se debe utilizar el modo de capacidad aprovisionada con rastreadores de AWS Glue.

> **Note**
>
> Para los almacenes de datos de DynamoDB, establezca el modo de capacidad aprovisionada para procesar las lecturas y escrituras en las tablas. El rastreador de AWS Glue no debe utilizarse con el modo de capacidad bajo demanda.

Conexión de red: opcional (para almacenes de datos de destino de Amazon S3, Delta, Iceberg, Hudi y Catalog)

Si lo desea, incluya una conexión de red para utilizarla con este destino de Amazon S3. Tenga en cuenta que cada rastreador se limita a una conexión de red, por lo que cualquier otro destino de Amazon S3 también utilizará la misma conexión (o ninguna, si se deja en blanco).

Para obtener más información acerca de las conexiones, consulte Conexión a datos.

Muestrear solo un subconjunto de archivos y tamaño de la muestra (solo para almacenes de datos de Amazon S3)

Establece el número de archivos de cada carpeta que se van a rastrear al rastrear archivos de ejemplo en un conjunto de datos. Cuando esta característica está activada, en lugar de rastrear todos los archivos de este conjunto de datos, el rastreador selecciona aleatoriamente algunos archivos en cada carpeta para rastrear.

El rastreador de muestreo es el más adecuado para clientes que tienen conocimientos previos sobre sus formatos de datos y saben que los esquemas de sus carpetas no cambian. Activar esta característica reducirá significativamente el tiempo de ejecución del rastreador.

Un valor válido es un entero entre 1 y 249. Si no se especifica, se rastrean todos los archivos.

Ejecuciones posteriores del rastreador

Este campo es un campo global que afecta a todos los orígenes de datos de Amazon S3.

- Crawl all sub-folders (Rastrear todas las subcarpetas): se vuelven a rastrear todas las carpetas con cada rastreo posterior.
- Crawl new sub-folders only (Rastrear solo las subcarpetas nuevas): solo se rastrearán las carpetas de Amazon S3 que se hayan agregado desde el último rastreo. Si los esquemas son compatibles, se agregarán nuevas particiones a las tablas existentes. Para obtener más información, consulte the section called “Programación de rastreos progresivos”.
- Crawl based on events (Rastreo basado en eventos): confíe en los eventos de Amazon S3 para controlar qué carpetas rastrear. Para obtener más información, consulte Aceleración de los rastreadores mediante las notificaciones de eventos de Amazon S3.

Custom classifiers (Clasificadores personalizados): opcionales

Defina los clasificadores personalizados antes de definir los rastreadores. Un clasificador comprueba si un determinado archivo está en un formato que puede el rastreador administrar. En caso afirmativo, el clasificador crea un esquema en forma de un objeto `StructType` que coincida con formato de datos.

Para obtener más información, consulte Definición y administración de clasificadores.

Paso 3: Establecer configuración de seguridad

rol de IAM

El rastreador asume este rol. Debe tener permisos a la política `AWSGlueServiceRole` administrada por AWS. En el caso de los orígenes de Amazon S3 y DynamoDB, también debe tener permisos para acceder al almacén de datos. Si el rastreador lee datos de Amazon S3 cifrados por AWS Key Management Service (AWS KMS), entonces el rol debe tener permiso para descifrar la clave AWS KMS.

Para un almacén de datos de Amazon S3, los permisos adicionales asociados al rol serían similares a los siguientes:

JSON

```
{
```

```
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "s3:GetObject",
        "s3:PutObject"
      ],
      "Resource": [
        "arn:aws:s3:::bucket/object*"
      ]
    }
  ]
}
```

Para un almacén de datos de Amazon DynamoDB, los permisos adicionales asociados al rol serían similares a los siguientes:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "dynamodb:DescribeTable",
        "dynamodb:Scan"
      ],
      "Resource": [
        "arn:aws:dynamodb:*:111122223333:table/table-name*"
      ]
    }
  ]
}
```

Para agregar su propio controlador JDBC, es necesario agregar permisos adicionales.

- Conceda permisos para las siguientes acciones de trabajos: `CreateJob`, `DeleteJob`, `GetJob`, `GetJobRun`, `StartJobRun`.
- Conceda permisos para todas las acciones de Amazon S3: `s3:DeleteObjects`, `s3:GetObject`, `s3:ListBucket`, `s3:PutObject`.

> **Note**
>
> `s3:ListBucket` no es necesaria si la política de bucket de Amazon S3 está deshabilitada.

- Conceda el acceso principal del servicio al bucket o la carpeta en la política de Amazon S3.

Ejemplo de política de Amazon S3:

JSON

```
{
    "Version":"2012-10-17",
    "Statement": [
        {
            "Sid": "VisualEditor0",
            "Effect": "Allow",
            "Action": [
                "s3:PutObject",
                "s3:GetObject",
                "s3:ListBucket",
                "s3:DeleteObject"
            ],
            "Resource": [
                "arn:aws:s3:::amzn-s3-demo-bucket/driver-parent-folder/
driver.jar",
                "arn:aws:s3:::amzn-s3-demo-bucket"
            ]
        }
    ]
}
```

AWS Glue crea las siguientes carpetas (`_crawler` y `_glue_job_crawler` al mismo nivel que el controlador JDBC en su bucket de Amazon S3). Por ejemplo, si la ruta del controlador es `<s3-path/driver_folder/driver.jar>`, entonces se crearán las siguientes carpetas si aún no existen:

- <s3-path/driver_folder/_crawler>
- <s3-path/driver_folder/_glue_job_crawler>

De forma opcional, puede agregar una configuración de seguridad a un rastreador para especificar opciones de cifrado en reposo.

Para obtener más información, consulte Paso 2: creación de un rol de IAM para AWS Glue y Administración de identidades y accesos para AWS Glue.

Lake Formation configuration (Configuración de Lake Formation): opcional

Permita que el rastreador utilice credenciales de Lake Formation para rastrear el origen de datos.

Al marcar Use Lake Formation credentials for crawling S3 data source (Utilizar credenciales de Lake Formation para rastrear un origen de datos S3), el rastreador podrá usar las credenciales de Lake Formation para rastrear el origen de datos. Si el origen de datos pertenece a otra cuenta, debe proporcionar el ID de la cuenta registrada. De lo contrario, el rastreador solo rastreará los orígenes de datos asociados a la cuenta. Solo se aplica a los orígenes de datos del Catálogo de datos y Amazon S3.

Security configuration (Configuración de seguridad): opcional

La configuración incluye ajustes de seguridad. Para obtener más información, consulte los siguientes temas:

- Cifrado de datos escritos por AWS Glue

> **Note**
>
> Una vez que se establezca una configuración de seguridad en un rastreador, puede modificarla, pero no eliminarla. Para reducir el nivel de seguridad de una rastreador, establezca de manera explícita la característica de seguridad en `DISABLED` dentro de la configuración o cree un nuevo rastreador.

Paso 4: establecer salida y programación

Configuración de la salida

Las opciones incluyen la forma en la que el rastreador debe gestionar los cambios detectados en un esquema, los objetos eliminados en el almacén de datos y mucho más. Para obtener más información, consulte Personalización del comportamiento del rastreador

Propiedad Schedule de rastreador

Puede ejecutar un rastreador bajo demanda o definir programaciones basadas en tiempo para los rastreadores y los trabajos de AWS Glue. La definición de estas programaciones utiliza sintaxis cron del tipo Unix. Para obtener más información, consulte Programación de un rastreador.

Paso 5: Revisar y crear

Revise la configuración del rastreador que estableció y cree el rastreador.

Programación de un rastreador

Puede ejecutar un rastreador de AWS Glue bajo demanda o según una programación periódica. Al crear un rastreador con base en una programación, puede especificar ciertas restricciones, como la frecuencia de las ejecuciones del rastreador, los días de la semana y la hora en que este se ejecuta. Puede crear estas programaciones personalizadas en formato cron. Para obtener más información, consulte Cron en Wikipedia.

Al configurar una programación de rastreador, debe tener en cuenta las características y limitaciones de Cron. Por ejemplo, si decide ejecutar su rastreador el día 31 de cada mes, tenga en cuenta que algunos meses no tienen 31 días.

Temas

- Creación de una programación de rastreadores
- Creación de una programación para un rastreador existente

Creación de una programación de rastreadores

Puede crear una programación para un rastreador con la consola de AWS Glue o la AWS CLI.

Consola de administración de AWS

1. Luego, inicie sesión en la Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. Elija Crawlers (Rastreadores) en el panel de navegación.
3. Siga los pasos 1-3 en la sección Configuración de rastreadores.

4. En Paso 4: establecer salida y programación, elija una Programación del rastreador para establecer la frecuencia de la ejecución. Puede elegir el rastreador para que funcione cada hora, día, semana o mes o definir un horario personalizado mediante expresiones cron.

   Una expresión cron es una cadena que representa un patrón de programación y consta de 6 campos separados por espacios: * * * * * <minuto> <hora> <día del mes> <mes> <día de la semana> <año>

   Por ejemplo, para ejecutar una tarea todos los días a medianoche, la expresión cron es: 0 0 * *? *

   Para obtener más información, consulte Expresiones Cron.

5. Revise la configuración del rastreador que estableció y cree el rastreador para ejecutar una programación.

AWS CLI

```
aws glue create-crawler
 --name myCrawler \
 --role AWSGlueServiceRole-myCrawler  \
 --targets '{"S3Targets":[{Path="s3://amzn-s3-demo-bucket/"}]}' \
 --schedule cron(15 12 * * ? *)
```

Para obtener más información acerca cómo utilizar Cron para programar trabajos y rastreadores, consulte Programaciones basadas en tiempo para trabajos y rastreadores.

Creación de una programación para un rastreador existente

Siga estos pasos para configurar una programación periódica para un rastreador existente.

Consola de administración de AWS

1. Inicie sesión en la Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. Elija Crawlers (Rastreadores) en el panel de navegación.
3. Elija el rastreador que desea programar de la lista disponible.
4. En el Menú de acciones, elija Editar.

5. Desplácese hacia abajo hasta el Paso 4: configurar la salida y la programación y seleccione Editar.
6. Actualice su programación de rastreadores en Programación de rastreadores.
7. Elija Actualizar.

AWS CLI

Utilice el siguiente comando de la CLI para actualizar una configuración del rastreador existente:

```
aws glue update-crawler-schedule
   --crawler-name myCrawler
   --schedule cron(15 12 * * ? *)
```

Ver los resultados y detalles del rastreador

Una vez que el rastreador se ejecuta correctamente, crea definiciones de tabla en el Catálogo de datos. Elija Tables (Tablas) en el panel de navegación para ver las tablas que creó su rastreador en la base de datos especificada.

Puede ver la información relacionada con el rastreador en sí de la siguiente manera:

- La página Crawlers (Rastreadores) en la consola de AWS Glue muestra las siguientes propiedades de un rastreador:

Propiedad	Descripción
Nombre	Cuando se crea un rastreador, se le debe asignar un nombre único.
Estado	Un rastreador puede tener los siguientes estados: ready, starting, stopping, scheduled o schedule paused. Un rastreador en ejecución progresa de starting a stopping. Puede reanudar o pausar una programación asociada a un rastreador.

Propiedad	Descripción
Programación	Puede elegir ejecutar su rastreador bajo demanda o elegir una frecuencia con una programación. Para obtener más información acerca de la programación de un rastreador, consulte Programación de un rastreador.
Last run (Última ejecución)	Fecha y hora en que se ejecutó el rastreador por última vez.
Log (Registro)	Enlaces a cualquier registro disponible de la última ejecución del rastreador.
Tables changes from last run (Cambios en las tablas desde la última ejecución)	El número de tablas en el AWS Glue Data Catalog que actualizó la última ejecución del rastreador.

- Para el historial de un rastreador, elija Crawlers (Rastreadores) en el panel de navegación con el fin de ver los rastreadores que haya creado. Elija un rastreador de la lista de rastreadores disponibles. Puede ver las propiedades y el historial del rastreador en la pestaña Crawler runs (Ejecuciones del rastreador).

  La pestaña Crawler runs (Ejecuciones del rastreador) muestra información sobre cada una de las veces que se ha ejecutado el rastreador, incluyendo Start time (UTC) (Hora de inicio [UTC]), End time (UTC) (Hora de finalización [UTC]), Duration (Duración), Status (Estado), DPU hours (Horas de DPU) y Table changes (Cambios en las tablas).

  La pestaña del ejecutor del rastreador muestra solo los rastreos que se han producido desde la fecha de lanzamiento de la función de historial del rastreador y solo conserva hasta 12 meses de rastreo. No se devolverán los rastreos más antiguos.
- Para ver información adicional, elija una pestaña en la página de detalles del rastreador. En cada pestaña se mostrará información relacionada con el rastreador.
  - Schedule (Programación): aquí aparecerán los programas creados para el rastreador.
  - Data sources (Orígenes de datos): aquí aparecerán todos los orígenes de datos analizados por el rastreador.
  - Classifiers (Clasificadores): aquí aparecerán todos los clasificadores asignados al rastreador.

- Tags (Etiquetas): aquí aparecerán las etiquetas creadas y asignadas a un recurso de AWS.

Parámetros establecidos en las tablas del catálogo de datos por el rastreador

Los rastreadores de AWS Glue establecen estas propiedades de la tabla. Esperamos que los usuarios consuman las propiedades `classification` y `compressionType`. Para los cálculos internos se utilizan otras propiedades, incluidas las estimaciones del tamaño de las tablas, y no se garantizan su precisión ni aplicabilidad a los casos de uso de los clientes. Cambiar estos parámetros puede alterar el comportamiento del rastreador y no admitimos este flujo de trabajo.

Clave de la propiedad	Valor de la propiedad
`UPDATED_BY_CRAWLER`	Nombre del rastreador que realiza la actualización.
`connectionName`	El nombre de la conexión del Catálogo de datos para el rastreador que se utiliza para la conexión al almacén de datos.
`recordCount`	Calcule el recuento de registros de la tabla, según el tamaño de los archivos y los encabezados.
`skip.header.line.count`	Filas omitidas para omitir el encabezado. Se establece en tablas clasificadas como CSV.
`CrawlerSchemaSerializerVersion`	Para uso interno
`classification`	Formato de los datos, deducido por el rastreador. Para obtener más información sobre los formatos de datos que admiten los rastreadores de AWS Glue, consulte the section called “Clasificadores integrados”.
`CrawlerSchemaDeserializerVersion`	Para uso interno
`sizeKey`	Tamaño combinado de los archivos de la tabla rastreada.

Clave de la propiedad	Valor de la propiedad
`averageRecordSize`	Tamaño promedio de una fila en la tabla, en bytes.
`compressionType`	Tipo de compresión utilizado en los datos de la tabla. Para obtener más información sobre los tipos de compresión que admiten los rastreadores de AWS Glue, consulte the section called “Clasificadores integrados”.
`typeOfData`	`file`, `table` o bien `view`.
`objectCount`	Número de objetos en la ruta de Amazon S3 para la tabla.

Los rastreadores de AWS Glue establecen estas propiedades de tabla adicionales para almacenes de datos de Snowflake.

Clave de la propiedad	Valor de la propiedad
`aws:RawTableLastAltered`	Registra la última marca temporal modificada de la tabla de Snowflake.
`ViewOriginalText`	Vea la instrucción SQL.
`ViewExpandedText`	Vea la instrucción SQL codificada en formato Base64.
`ExternalTable:S3Location`	Ubicación de Amazon S3 de la tabla externa de Snowflake.
`ExternalTable:FileFormat`	Formato de archivo de Amazon S3 de la tabla externa de Snowflake.

Los rastreadores de AWS Glue establecen estas propiedades de tabla adicionales para almacenes de datos de tipo JDBC, como Amazon Redshift, Microsoft SQL Server, MySQL, PostgreSQL y Oracle.

Clave de la propiedad	Valor de la propiedad
`aws:RawType`	Cuando un rastreador almacena los datos en el Catálogo de datos, traduce los tipos de datos a tipos compatibles con Hive, lo que muchas veces hace que se pierda la información del tipo de datos nativo. El rastreador genera el parámetro `aws:RawType` para proporcionar el tipo de datos de nivel nativo.
`aws:RawColumnComment`	Si un comentario está asociado a una columna de la base de datos, el rastreador genera el comentario correspondiente en la tabla del catálogo. La cadena de comentario se trunca en 255 bytes. Microsoft SQL Server no admite los comentarios.
`aws:RawTableComment`	Si un comentario está asociado a una tabla de la base de datos, el rastreador genera el comentario correspondiente en la tabla del catálogo. La cadena de comentario se trunca en 255 bytes. Microsoft SQL Server no admite los comentarios.

Personalización del comportamiento del rastreador

Al configurar un Rastreador de AWS Glue, dispone de varias opciones para definir el comportamiento de su rastreador.

- Rastreos progresivos: puede configurar un rastreador para ejecutar rastreos progresivos y agregar solo particiones nuevas al esquema de la tabla.
- Índices de particiones: un rastreador crea, de manera predeterminada, índices de particiones para los destinos de Amazon S3 y Delta Lake para ofrecer una búsqueda eficiente de particiones específicas.
- Mejora del tiempo de rastreo mediante eventos de Amazon S3: puede configurar un rastreador para usar eventos de Amazon S3 para identificar los cambios entre dos rastreos al enumerar todos

los archivos de la subcarpeta que activó el evento en lugar de publicar el destino completo de Amazon S3 o el Catálogo de datos.

- Gestión de los cambios de esquema: puede impedir que un rastreador realice cambios de esquema en el esquema existente. Puede utilizar la Consola de administración de AWS o la API de AWS Glue para configurar la manera en que su rastreador procesa determinados tipos de cambios.
- Un solo esquema para varias rutas de Amazon S3: puede configurar un rastreador para crear un solo esquema para cada ruta de S3, si los datos son compatibles.
- Ubicación de la tabla y niveles de partición: la opción de rastreador de nivel de tabla proporciona la flexibilidad para indicar al rastreador dónde se encuentran las tablas y cómo desea crear las particiones.
- Umbral de tabla: puede especificar el número máximo de tablas que el rastreador tiene permitido crear mediante un umbral de tabla.
- Credenciales de AWS Lake Formation: puede configurar un rastreador para que utilice credenciales de Lake Formation para acceder a un almacén de datos de Amazon S3 o a una tabla del Catálogo de datos con una ubicación de Amazon S3 subyacente en la misma Cuenta de AWS o en otra Cuenta de AWS.

Para obtener más información acerca de cómo usar la consola de AWS Glue para añadir un rastreador, consulte Configuración de rastreadores.

Temas

- Programación de rastreos progresivos para agregar nuevas particiones
- Generación de índices de particiones
- Cómo evitar que un rastreador cambie un esquema existente
- Creación de un único esquema para cada ruta de inclusión de Amazon S3
- Cómo especificar la ubicación de la tabla y el nivel de partición
- Cómo especificar el número máximo de tablas que el rastreador tiene permitido crear
- Configuración de un rastreador para que utilice credenciales de Lake Formation
- Aceleración de los rastreadores mediante las notificaciones de eventos de Amazon S3

Programación de rastreos progresivos para agregar nuevas particiones

Puede configurar rastreos progresivos de ejecuciones de Rastreador de AWS Glue para agregar solo particiones nuevas al esquema de la tabla. Cuando el rastreador se ejecuta por primera vez, realiza un rastreo completo para procesar todo el origen de datos y registrar el esquema completo y todas las particiones existentes en AWS Glue Data Catalog.

Los rastreos posteriores al rastreo completo inicial serán progresivos, en los que el rastreador identificará y agregará solo las particiones nuevas que se hayan introducido desde el rastreo anterior. Este enfoque se traduce en tiempos de rastreo más rápidos, ya que el rastreador ya no necesita procesar todo el origen de datos para cada ejecución, sino que se centra únicamente en las nuevas particiones.

> **Note**
>
> Los rastreos progresivos no detectan las modificaciones o eliminaciones de las particiones existentes. Esta configuración es la más adecuada para orígenes de datos con un esquema estable. Si se produce un cambio importante en el esquema una sola vez, se recomienda configurar temporalmente el rastreador para que realice un rastreo completo a fin de capturar el nuevo esquema con precisión y, a continuación, volver al modo de rastreo progresivo.

En el siguiente diagrama se muestra que, con la configuración de rastreo gradual habilitada, el rastreador solo detectará y agregará al catálogo la carpeta recién agregada, month=March.

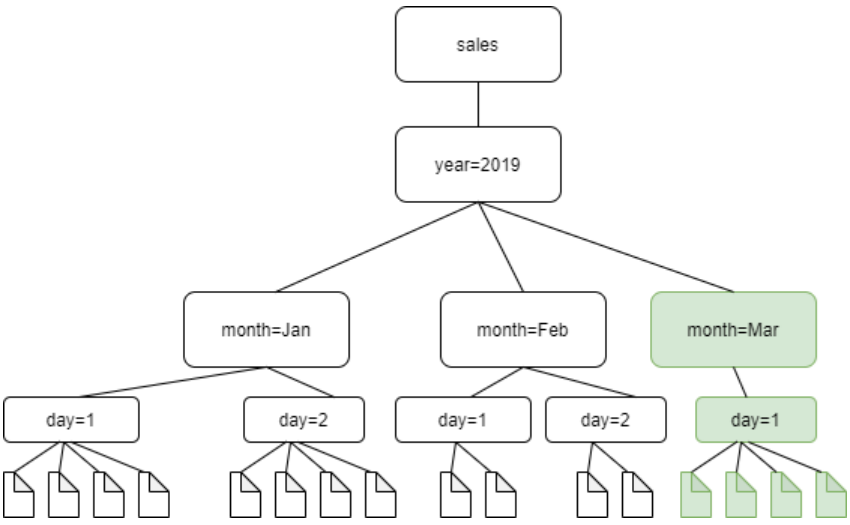

Siga estos pasos para actualizar su rastreador y realizar rastreos graduales:

Consola de administración de AWS

1. Inicie sesión en la Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. Elija Rastreadores en el Catálogo de datos.
3. Elija el rastreador que desea configurar para rastrear progresivamente.
4. Seleccione Editar.
5. Elija Paso 2. Elija orígenes de datos y clasificadores.
6. Elija el origen de datos que desea rastrear progresivamente.
7. Seleccione Editar.
8. Seleccione Rastrear subcarpetas nuevas únicamente en las Siguientes ejecuciones del rastreador.
9. Elija Actualizar.

Para crear una programación para un rastreador, consulte the section called “Programación de un rastreador”.

AWS CLI

```
aws glue update-crawler \
 --name myCrawler \
 --recrawl-policy RecrawlBehavior=CRAWL_NEW_FOLDERS_ONLY \
 --schema-change-policy UpdateBehavior=LOG,DeleteBehavior=LOG
```

Notas y restricciones

Cuando esta opción está activada, no puede cambiar los almacenes de datos de destino de Amazon S3 al editar el rastreador. Esta opción afecta a determinados valores de configuración del rastreador. Cuando está activada, fuerza el comportamiento de actualización y el comportamiento de eliminación del rastreador a `LOG`. Esto significa que:

- Si descubre objetos en los que los esquemas no son compatibles, el rastreador no agregará los objetos en el Catálogo de datos y agregará este detalle como un registro en CloudWatch Logs.
- No actualizará los objetos eliminados en el Catálogo de datos.

Generación de índices de particiones

El Catálogo de datos es compatible con la creación de índices de particiones para ofrecer una búsqueda eficiente de particiones específicas. Para obtener más información, consulte Creación de índices de partición. El rastreador de AWS Glue crea, de manera predeterminada, índices de particiones para los destinos de Amazon S3 y Delta Lake.

Consola de administración de AWS

1. Inicie sesión en la Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. Elija Rastreadores en el Catálogo de datos.
3. Cuando se define un rastreador, la opción para Crear índices de partición de manera automática se habilita de manera predeterminada en la sección Opciones avanzadas en la página Establecer salida y programación.

   Para desactivar esta opción, puede anular la selección de la casilla Crear índices de particiones de manera automática en la consola.
4. Complete la configuración del rastreador y elija Crear rastreador.

AWS CLI

También puede desactivarla mediante la AWS CLI, establezca `CreatePartitionIndex` en el parámetro `configuration`. El valor predeterminado es true.

```
aws glue update-crawler \
    --name myCrawler \
    --configuration '{"Version": 1.0, "CreatePartitionIndex": false }'
```

Notas de uso de índices de particiones

- Las tablas creadas por el rastreador no tienen la variable de forma `partition_filtering.enabled` predeterminada. Para obtener más información, consulte Índices de partición y filtros de AWS Glue.
- La creación de índices de partición para particiones cifradas no es compatible.

Cómo evitar que un rastreador cambie un esquema existente

Puede impedir que Rastreador de AWS Glue realice cambios de esquema en el Catálogo de datos durante su ejecución. De forma predeterminada, los rastreadores actualizan el esquema del Catálogo de datos para que coincida con el origen de datos que se está rastreando. Sin embargo, en algunos casos, puede impedir que el rastreador modifique el esquema existente, en especial si ha transformado o limpiado los datos y no quiere que el esquema original sobrescriba los cambios.

Siga estos pasos para configurar el rastreador de forma que no sobrescriba el esquema existente en una definición de tabla.

Consola de administración de AWS

1. Inicie sesión en la Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. Elija Rastreadores en el Catálogo de datos.
3. Elija un rastreador de la lista y, luego, Editar.
4. Elija Paso 4: establecer la salida y la programación.
5. En Opciones avanzadas, seleccione Agregar solo columnas nuevas o Ignorar el cambio y no actualizar la tabla en el Catálogo de datos.
6. También puede establecer una opción de configuración para Actualizar todas las particiones nuevas y existentes con metadatos de la tabla. Esto establece los esquemas de particiones para que se hereden de la tabla.
7. Elija Actualizar.

AWS CLI

En el siguiente ejemplo, se muestra cómo configurar un rastreador para que no cambie el esquema existente y solo agregue columnas nuevas:

```
aws glue update-crawler \
  --name myCrawler \
  --configuration '{"Version": 1.0, "CrawlerOutput": {"Tables":
 {"AddOrUpdateBehavior": "MergeNewColumns"}}}'
```

En el siguiente ejemplo, se muestra cómo configurar un rastreador para que no cambie el esquema existente y no agregue columnas nuevas:

```
aws glue update-crawler \
  --name myCrawler \
  --schema-change-policy UpdateBehavior=LOG \
  --configuration '{"Version": 1.0, "CrawlerOutput": {"Partitions":
 { "AddOrUpdateBehavior": "InheritFromTable" }}}'
```

API

Si no desea que un esquema de tabla cambie en absoluto cuando se ejecuta un rastreador, establezca la política de cambio de esquema en `LOG`.

Al configurar el rastreador mediante la API, establezca los siguientes parámetros:

- Configure el campo `UpdateBehavior` de la estructura `SchemaChangePolicy` en `LOG`.
- Establezca el campo `Configuration` con una representación de cadena del siguiente objeto JSON en la API del rastreador; por ejemplo:

```
{
   "Version": 1.0,
   "CrawlerOutput": {
      "Partitions": { "AddOrUpdateBehavior": "InheritFromTable" }
   }
}
```

Creación de un único esquema para cada ruta de inclusión de Amazon S3

De forma predeterminada, cuando un rastreador define tablas para los datos almacenados en Amazon S3, tiene en cuenta la compatibilidad y el esquema de los datos por igual. Entre los factores de compatibilidad de datos que se tienen en cuenta se incluye si los datos poseen el mismo formato (por ejemplo, JSON), el mismo tipo de compresión (por ejemplo, GZIP), la estructura de la ruta de Amazon S3 y otros atributos de datos. La similitud de los esquemas es una medida de qué tan similares son los esquemas de objetos de Amazon S3 independientes.

Para ayudar a ilustrar esta opción, supongamos que define un rastreador con una ruta de inclusión `s3://amzn-s3-demo-bucket/table1/`. Al ejecutarse el rastreador, encuentra dos archivos JSON con las siguientes características:

- Archivo 1 `S3://amzn-s3-demo-bucket/table1/year=2017/data1.json`

- Contenido del archivo: `{“A”: 1, “B”: 2}`
- Esquema: `A:int, B:int`

- Archivo 2 `S3://amzn-s3-demo-bucket/table1/year=2018/data2.json`
- Contenido del archivo: `{“C”: 3, “D”: 4}`
- Esquema: `C: int, D: int`

De forma predeterminada, el rastreador crea dos tablas, llamadas `year_2017` y `year_2018`, ya que los esquemas no son lo suficientemente similares. Sin embargo, si la opción Crear un solo esquema para cada ruta de S3 está seleccionada y los datos son compatibles, el rastreador crea una tabla. La tabla tiene el esquema `A:int,B:int,C:int,D:int` y `partitionKey year:string`.

Consola de administración de AWS

1. Inicie sesión en la Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. Elija Rastreadores en el Catálogo de datos.
3. Al configurar un rastreador nuevo, en Salida y programación, seleccione la opción Crear un solo esquema para cada ruta de S3 en Opciones avanzadas.

AWS CLI

Puede configurar un rastreador en `CombineCompatibleSchemas` en una definición de tabla común cuando sea posible. Con esta opción, el rastreador sigue teniendo en cuenta la compatibilidad de los datos, pero pasa por alto la similitud de los esquemas específicos al evaluar objetos de Amazon S3 en la ruta de inclusión especificada.

Al configurar el rastreador mediante la AWS CLI, establezca la siguiente opción de configuración:

```
aws glue update-crawler \
   --name myCrawler \
   --configuration '{"Version": 1.0, "Grouping": {"TableGroupingPolicy":
 "CombineCompatibleSchemas" }}'
```

API

Al configurar el rastreador mediante la API, establezca la siguiente opción de configuración:

Establezca el campo `Configuration` con una representación de cadena del siguiente objeto JSON en la API del rastreador; por ejemplo:

```
{
   "Version": 1.0,
   "Grouping": {
      "TableGroupingPolicy": "CombineCompatibleSchemas" }
}
```

Cómo especificar la ubicación de la tabla y el nivel de partición

De forma predeterminada, cuando un rastreador define tablas para los datos almacenados en Amazon S3, el rastreador intenta combinar esquemas y crear tablas de nivel superior (`year=2019`). En algunos casos, es posible que espere que el rastreador cree una tabla para la carpeta `month=Jan`, pero en su lugar el rastreador crea una partición ya que una carpeta "hermana" (`month=Mar`) se fusionó en la misma tabla.

La opción de rastreador de nivel de tabla proporciona la flexibilidad para indicar al rastreador dónde se encuentran las tablas y cómo desea crear las particiones. Cuando se especifica un Nivel de tabla, la tabla se crea en ese nivel absoluto a partir del bucket de Amazon S3.

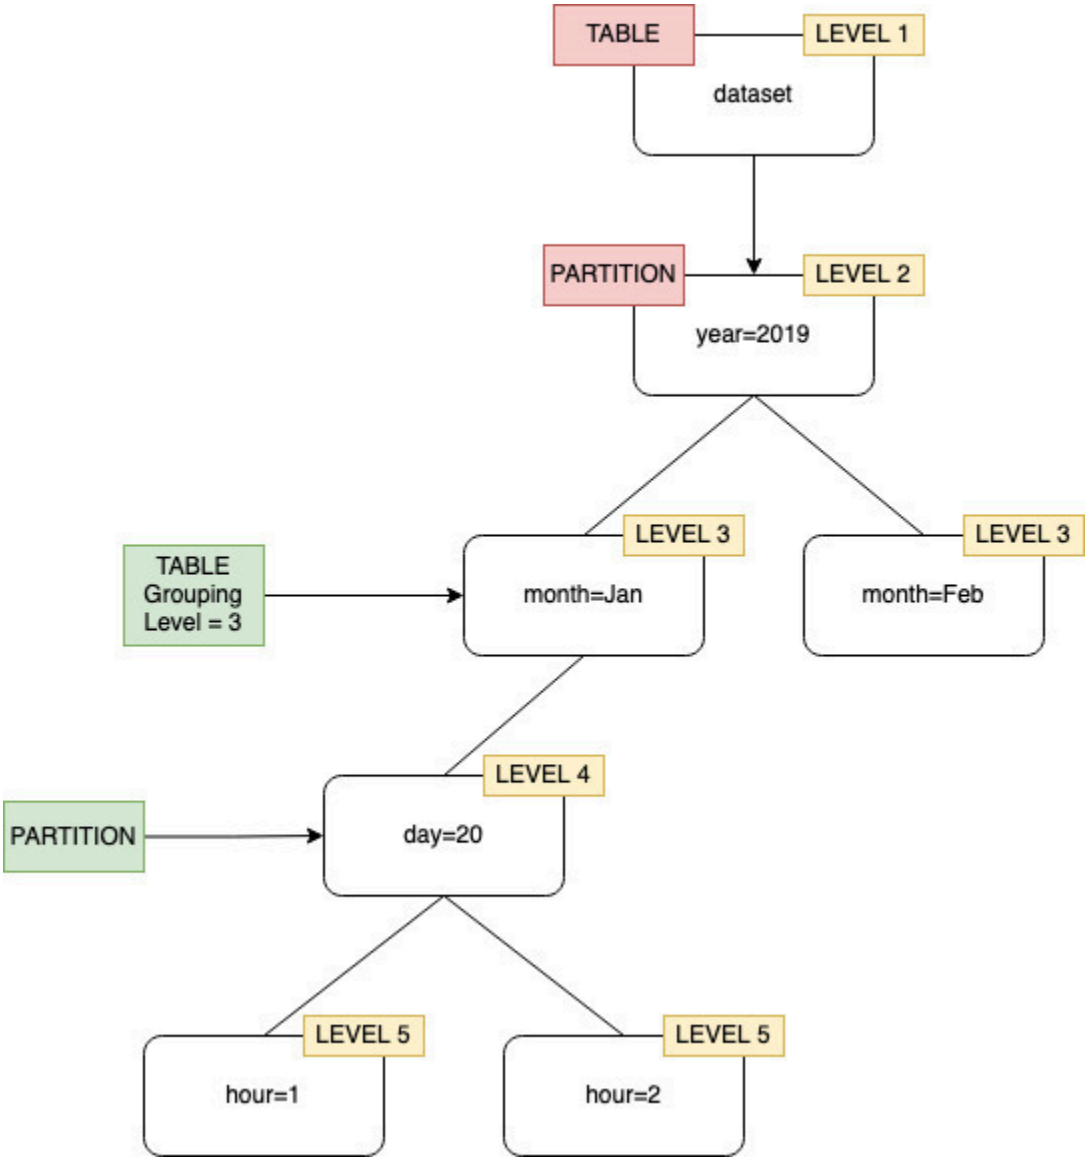

Al configurar el rastreador en la consola, puede especificar un valor para la opción del rastreador Nivel de tabla. El valor debe ser un entero positivo que indique la ubicación de la tabla (el nivel absoluto del conjunto de datos). El nivel de la carpeta de nivel superior es 1. Por ejemplo, para la ruta `mydataset/year/month/day/hour`, si el nivel se establece en 3, la tabla se crea en la ubicación `mydataset/year/month`.

Consola de administración de AWS

1. Inicie sesión en la Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. Elija Rastreadores en el Catálogo de datos.

3. Al configurar un rastreador, en Salida y programación, elija Nivel de tabla en Opciones avanzadas.

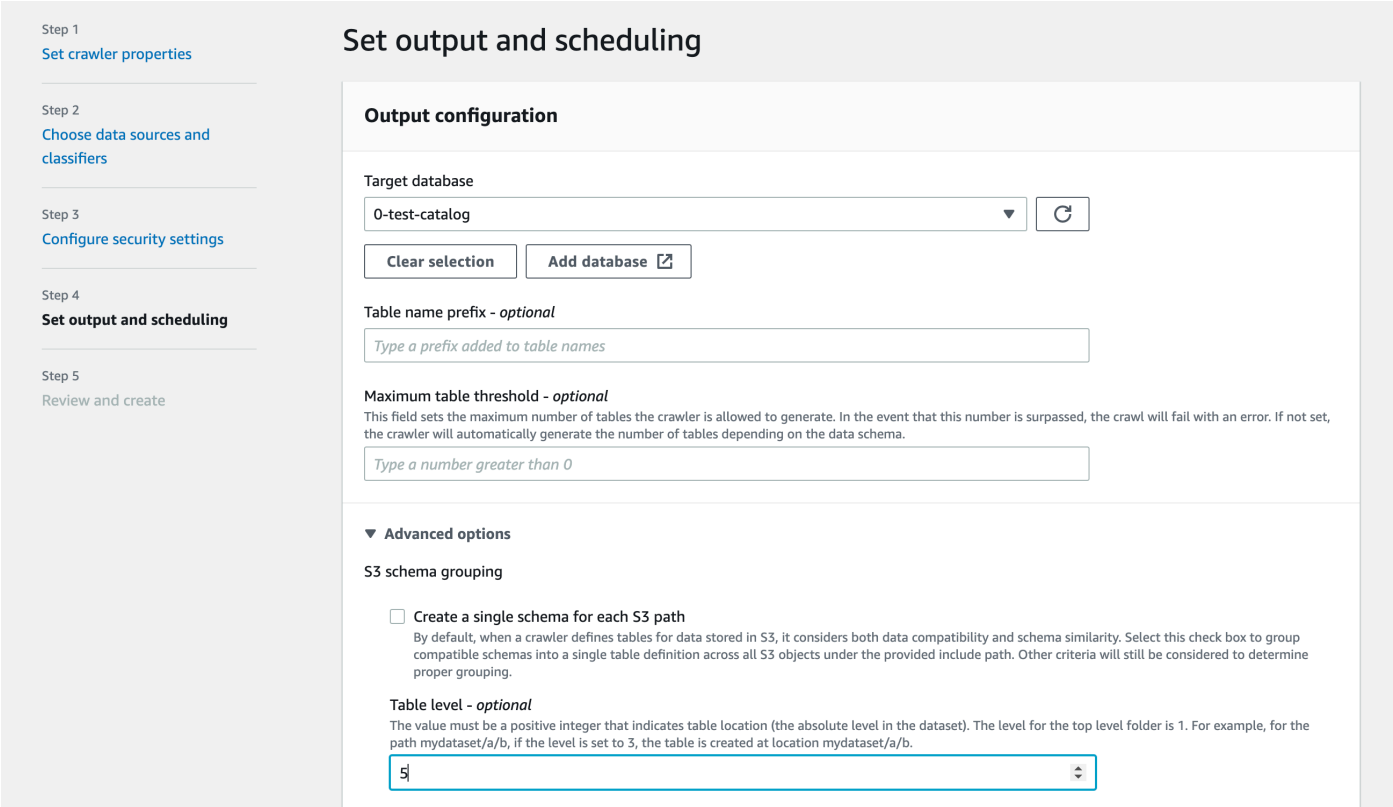

AWS CLI

Al configurar el rastreador mediante la AWS CLI, defina el parámetro `configuration` tal y como se muestra en el código de ejemplo:

```
aws glue update-crawler \
  --name myCrawler \
  --configuration '{"Version": 1.0, "Grouping": { "TableLevelConfiguration": 2 }}'
```

API

Cuando configure el rastreador mediante la API, establezca el campo `Configuration` con una representación de cadena del siguiente objeto JSON; por ejemplo:

```
configuration = jsonencode(
{
   "Version": 1.0,
   "Grouping": {
```

```
            TableLevelConfiguration = 2
        }
})
```

CloudFormation

En este ejemplo, establezca la opción Nivel de la tabla como disponible en la consola de la plantilla de CloudFormation:

```
"Configuration": "{
    \"Version\":1.0,
    \"Grouping\":{\"TableLevelConfiguration\":2}
}"
```

Cómo especificar el número máximo de tablas que el rastreador tiene permitido crear

Opcionalmente, puede especificar el número máximo de tablas que el rastreador tiene permitido crear especificando un valor de `TableThreshold` mediante la consola de AWS Glue o la AWS CLI. Si las tablas detectadas por el rastreador durante el rastreo superan este valor de entrada, se produce un error en el rastreo y no se escribe ningún dato en el Catálogo de datos.

Este parámetro es útil cuando las tablas que detectaría y crearía el rastreador son muchas más de las esperadas. Las razones para que ocurra esto pueden ser varias; por ejemplo:

- Cuando se utiliza un trabajo de AWS Glue para rellenar las ubicaciones de Amazon S3, es posible que acabe habiendo archivos vacíos en el mismo nivel que el de una carpeta. En esos casos, cuando se ejecuta un rastreador en esta ubicación de Amazon S3, el rastreador crea varias tablas debido a la presencia de archivos y carpetas en el mismo nivel.
- Si no configura `"TableGroupingPolicy": "CombineCompatibleSchemas"`, es posible que acabe habiendo más tablas de las esperadas.

Se debe especificar un valor entero mayor que 0 para `TableThreshold`. Este valor se configura para cada rastreador. Es decir, se tiene en cuenta este valor para cada rastreo. Por ejemplo, un rastreador tiene el valor `TableThreshold` establecido en 5. En cada rastreo, AWS Glue compara el número de tablas detectadas con este valor de umbral de tablas (5) y, si el número de tablas detectadas es inferior a 5, AWS Glue escribe las tablas en el Catálogo de datos; en caso contrario, se produce un error en el rastreo y no se escribe nada en el Catálogo de datos.

Consola de administración de AWS

Para configurar **`TableThreshold`** mediante la Consola de administración de AWS:

1. Inicie sesión en la Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. Al configurar un rastreador, en Salida y programación, defina el Umbral máximo de tabla en el número de tablas que el rastreador puede generar.

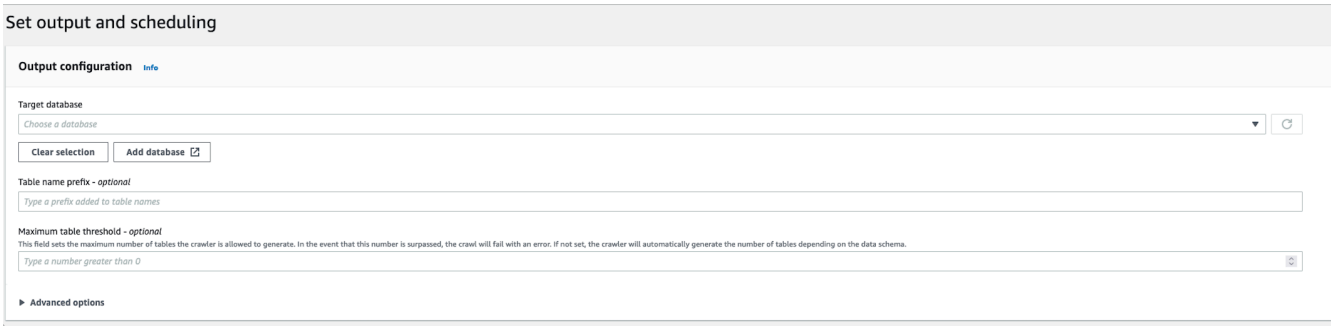

AWS CLI

Para configurar `TableThreshold` mediante la AWS CLI:

```
aws glue update-crawler \
    --name myCrawler \
    --configuration '{"Version": 1.0, "CrawlerOutput": {"Tables":
 { "TableThreshold": 5 }}}'
```

API

Para configurar `TableThreshold` mediante la API:

```
"{"Version":1.0,
"CrawlerOutput":
{"Tables":{"AddOrUpdateBehavior":"MergeNewColumns",
"TableThreshold":5}}}";
```

Se registran mensajes de error para ayudarle a identificar las rutas de las tablas y a limpiar los datos. Ejemplo de registro en la cuenta si el rastreador falla porque el número de tablas es mayor que el valor umbral de tablas proporcionado:

```
Table Threshold value = 28, Tables detected - 29
```

En CloudWatch, se registran todas las ubicaciones de las tablas detectadas en forma de mensaje INFO. Se registra un error como motivo del fallo.

```
ERROR com.amazonaws.services.glue.customerLogs.CustomerLogService - CustomerLogService
 received CustomerFacingException with message
The number of tables detected by crawler: 29 is greater than the table threshold value
 provided: 28. Failing crawler without writing to Data Catalog.
com.amazonaws.services.glue.exceptions.CustomerFacingInternalException: The number of
 tables detected by crawler: 29 is greater than the table threshold value provided:
 28.
Failing crawler without writing to Data Catalog.
```

Configuración de un rastreador para que utilice credenciales de Lake Formation

Puede configurar un rastreador para que utilice credenciales de AWS Lake Formation para acceder a un almacén de datos de Amazon S3 o a una tabla del Catálogo de datos con una ubicación de Amazon S3 subyacente en la misma Cuenta de AWS o en otra Cuenta de AWS. Puede configurar una tabla existente del Catálogo de datos como destino de un rastreador, si el rastreador y la tabla del Catálogo de datos residen en la misma cuenta. Actualmente, solo se permite un único destino de catálogo con una sola tabla de catálogo cuando se utiliza una tabla del Catálogo de datos como destino de un rastreador.

> **Note**
>
> Cuando vaya a definir una tabla del Catálogo de datos como destino de un rastreador, asegúrese de que la ubicación subyacente de la tabla del Catálogo de datos sea una ubicación de Amazon S3. Los rastreadores que utilizan credenciales de Lake Formation solo admiten destinos del Catálogo de datos con ubicaciones de Amazon S3 subyacentes.

Configuración requerida cuando el rastreador y la ubicación de Amazon S3 o la tabla del Catálogo de datos registradas residen en la misma cuenta (rastreo en cuenta)

Para permitir que el rastreador acceda a un almacén de datos o a una tabla del Catálogo de datos con credenciales de Lake Formation, se debe registrar la ubicación de los datos en Lake Formation. Además, el rol de IAM del rastreador debe tener permisos para leer los datos del destino en el que esté registrado el bucket de Amazon S3.

Puede completar los siguientes pasos de configuración mediante la Consola de administración de AWS o la AWS Command Line Interface (AWS CLI).

Consola de administración de AWS

1. Antes de configurar un rastreador para que acceda al origen del rastreador, registre la ubicación de los datos del almacén de datos o el Catálogo de datos en Lake Formation. En la consola de Lake Formation (https://console.aws.amazon.com/lakeformation/), registre una ubicación de Amazon S3 como ubicación raíz del lago de datos en la Cuenta de AWS donde esté definido el rastreador. Para obtener más información, consulte Registering an Amazon S3 location (Registro de una ubicación de Amazon S3).
2. Conceda permisos de Ubicación de datos al rol de IAM que se utiliza para la ejecución del rastreador, de modo que el rastreador pueda leer los datos del destino en Lake Formation. Para obtener más información, consulte Concesión de permisos de ubicación de datos (misma cuenta).
3. Otorgue al rol del rastreador permisos de acceso (`Create`) a la base de datos, que se especifica como base de datos de salida. Para obtener más información, consulte Concesión de permisos de base de datos mediante la consola de Lake Formation y el método de recurso con nombre.
4. En la consola de IAM (https://console.aws.amazon.com/iam/), cree un rol de IAM para el rastreador. Agregue la política `lakeformation:GetDataAccess` al rol.
5. En la consola de AWS Glue (https://console.aws.amazon.com/glue/), al configurar el rastreador, seleccione la opción Utilizar credenciales de Lake Formation para rastrear un origen de datos de Amazon S3.

> **Note**
>
> El campo accountId es opcional para el rastreo en cuenta.

AWS CLI

```
aws glue --profile demo create-crawler --debug --cli-input-json '{
    "Name": "prod-test-crawler",
    "Role": "arn:aws:iam::111122223333:role/service-role/AWSGlueServiceRole-prod-
test-run-role",
    "DatabaseName": "prod-run-db",
    "Description": "",
```

```
    "Targets": {
    "S3Targets":[
                {
                 "Path": "s3://amzn-s3-demo-bucket"
                }
                ]
                },
   "SchemaChangePolicy": {
      "UpdateBehavior": "LOG",
      "DeleteBehavior": "LOG"
  },
  "RecrawlPolicy": {
    "RecrawlBehavior": "CRAWL_EVERYTHING"
  },
  "LineageConfiguration": {
    "CrawlerLineageSettings": "DISABLE"
  },
  "LakeFormationConfiguration": {
    "UseLakeFormationCredentials": true,
    "AccountId": "111122223333"
  },
  "Configuration": {
           "Version": 1.0,
           "CrawlerOutput": {
             "Partitions": { "AddOrUpdateBehavior": "InheritFromTable" },
             "Tables": {"AddOrUpdateBehavior": "MergeNewColumns" }
           },
           "Grouping": { "TableGroupingPolicy": "CombineCompatibleSchemas" }
         },
  "CrawlerSecurityConfiguration": "",
  "Tags": {
    "KeyName": ""
  }
}'
```

Configuración requerida cuando el rastreador y la ubicación de Amazon S3 registrada residen en cuentas diferentes (rastreo entre cuentas)

Para permitir que el rastreador acceda a un almacén de datos de una cuenta diferente con credenciales de Lake Formation, primero debe registrar la ubicación de los datos de Amazon S3 en Lake Formation. Después, debe conceder permisos de ubicación de datos a la cuenta del rastreador siguiendo estos pasos.

Puede completar los siguientes pasos mediante la Consola de administración de AWS o la AWS CLI.

Consola de administración de AWS

1. En la cuenta en la que esté registrada la ubicación de Amazon S3 (cuenta B):
   a. Registre una ruta de Amazon S3 en Lake Formation. Para obtener más información, consulte Registro de una ubicación de Amazon S3.
   b. Conceda permisos de Ubicación de datos a la cuenta (cuenta A) en la que se vaya a ejecutar el rastreador. Para obtener más información, consulte Concesión de permisos de ubicación de datos.
   c. Cree una base de datos vacía en Lake Formation con la ubicación subyacente como ubicación de Amazon S3 de destino. Para obtener más información, consulte Creación de una base de datos.
   d. Conceda a la cuenta A (la cuenta en la que se vaya a ejecutar el rastreador) acceso a la base de datos que ha creado en el paso anterior. Para obtener más información, consulte Concesión de permisos de base de datos.
2. En la cuenta donde se ha creado y se va a ejecutar el rastreador (cuenta A):
   a. Mediante la consola de AWS RAM, acepte la base de datos que se haya compartido desde la cuenta externa (cuenta B). Para obtener más información, consulte Aceptación de una invitación para compartir un recurso de AWS Resource Access Manager.
   b. Cree un rol de IAM para el rastreador. Agregue la política `lakeformation:GetDataAccess` al rol.
   c. En la consola de Lake Formation (https://console.aws.amazon.com/lakeformation/), conceda permisos de Ubicación de datos sobre la ubicación de Amazon S3 de destino al rol de IAM utilizado para la ejecución del rastreador, de modo que el rastreador pueda leer los datos del destino en Lake Formation. Para obtener más información, consulte Concesión de permisos de ubicación de datos.
   d. Cree un enlace de recurso en la base de datos compartida. Para obtener más información, consulte Creación de un enlace de recurso.
   e. Otorgue al rol del rastreador permisos de acceso (`Create`) en la base de datos compartida y (`Describe`) en el enlace de recurso. El enlace de recurso se especifica en la salida del rastreador.
   f. En la consola de AWS Glue (https://console.aws.amazon.com/glue/), al configurar el rastreador, seleccione la opción Use Lake Formation credentials for crawling Amazon S3

data source (Utilizar credenciales de Lake Formation para rastrear un origen de datos de Amazon S3).

Para el rastreo entre cuentas, especifique el ID de la Cuenta de AWS donde esté registrada la ubicación de Amazon S3 de destino en Lake Formation. Para el rastreo en cuenta, el campo accountId es opcional.

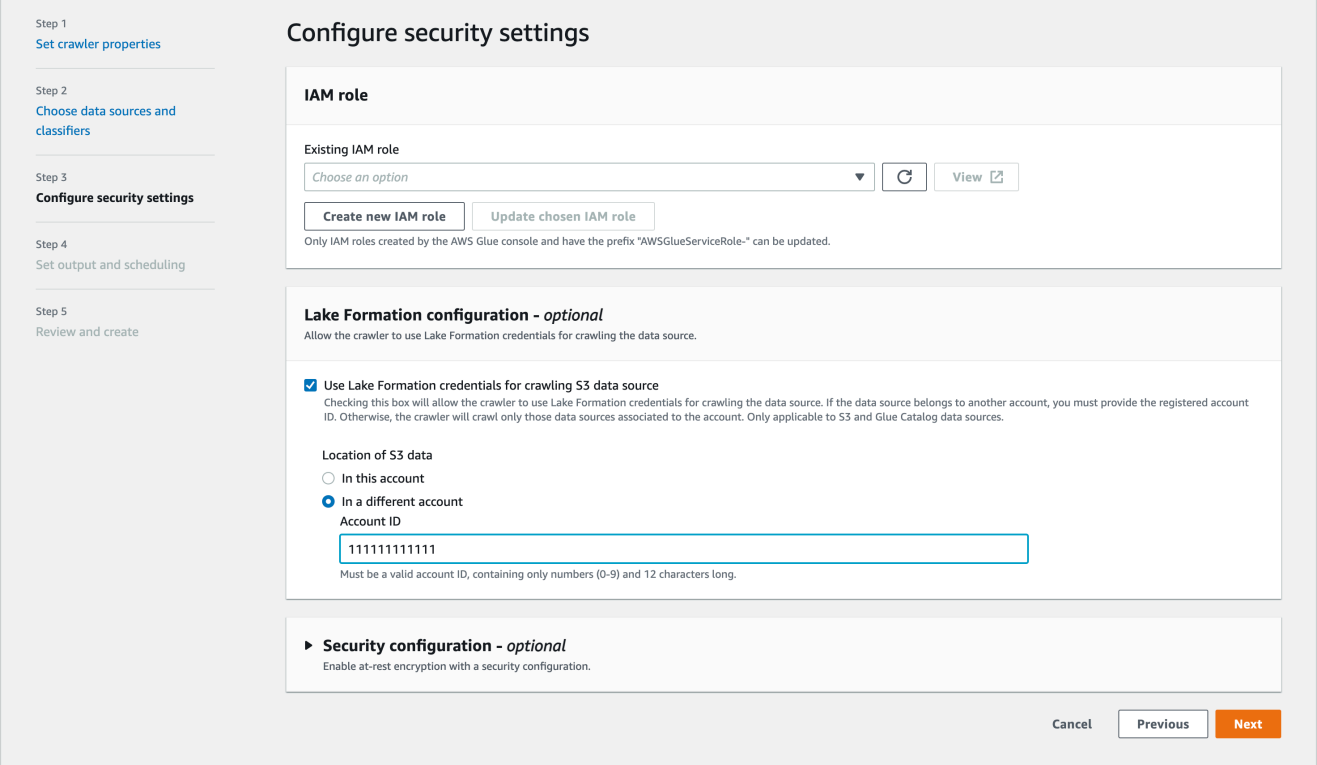

AWS CLI

```
aws glue --profile demo create-crawler --debug --cli-input-json '{
    "Name": "prod-test-crawler",
    "Role": "arn:aws:iam::111122223333:role/service-role/AWSGlueServiceRole-prod-
test-run-role",
    "DatabaseName": "prod-run-db",
    "Description": "",
    "Targets": {
    "S3Targets":[
                {
                 "Path": "s3://amzn-s3-demo-bucket"
                }
                ]
                },
```

```
   "SchemaChangePolicy": {
      "UpdateBehavior": "LOG",
      "DeleteBehavior": "LOG"
  },
  "RecrawlPolicy": {
    "RecrawlBehavior": "CRAWL_EVERYTHING"
  },
  "LineageConfiguration": {
    "CrawlerLineageSettings": "DISABLE"
  },
  "LakeFormationConfiguration": {
    "UseLakeFormationCredentials": true,
    "AccountId": "111111111111"
  },
  "Configuration": {
           "Version": 1.0,
           "CrawlerOutput": {
             "Partitions": { "AddOrUpdateBehavior": "InheritFromTable" },
             "Tables": {"AddOrUpdateBehavior": "MergeNewColumns" }
           },
           "Grouping": { "TableGroupingPolicy": "CombineCompatibleSchemas" }
         },
  "CrawlerSecurityConfiguration": "",
  "Tags": {
    "KeyName": ""
  }
}'
```

> **Note**
>
> - Un rastreador que utilice credenciales de Lake Formation solo puede rastrear destinos de Amazon S3 y el Catálogo de datos.
> - En el caso de destinos que utilicen el suministro de credenciales de Lake Formation, las ubicaciones de Amazon S3 subyacentes deben pertenecer al mismo bucket. Por ejemplo, los clientes pueden utilizar varios destinos (s3://amzn-s3-demo-bucket1/folder1, s3://amzn-s3-demo-bucket1/folder2) siempre que todas las ubicaciones de destino estén en el mismo bucket (amzn-s3-demo-bucket1). No se permite especificar buckets diferentes (s3://amzn-s3-demo-bucket1/folder1, s3://amzn-s3-demo-bucket2/folder2).

- Actualmente, para los rastreadores de destinos del Catálogo de datos, solo se permite un único destino de catálogo con una sola tabla de catálogo.

Aceleración de los rastreadores mediante las notificaciones de eventos de Amazon S3

En lugar de publicar los objetos de un destino de Amazon S3 o del Catálogo de datos, puede configurar el rastreador para que utilice eventos de Amazon S3 para buscar cualquier cambio. Esta característica mejora el tiempo de rastreo mediante el uso de eventos de Amazon S3 o del Catálogo de datos para identificar los cambios entre dos rastreos al enumerar todos los archivos de la subcarpeta que activó el evento en lugar de publicar el destino completo de Amazon S3 o el Catálogo de datos.

En el primer rastreo se enumeran todos los objetos de Amazon S3 del destino. Después del primer rastreo exitoso, puede optar por volver a rastrear manualmente o según un calendario establecido. El rastreador enumerará solo los objetos de esos eventos en lugar de enumerar todos los objetos.

Cuando el destino es una tabla del Catálogo de datos, el rastreador actualiza las tablas existentes en el Catálogo de datos con los cambios (por ejemplo, particiones adicionales en una tabla).

Las ventajas de pasar a un rastreador basado en eventos de Amazon S3 son:

- Un nuevo rastreo más rápido, ya que la lista de todos los objetos del destino no es necesaria, sino que la lista de carpetas específicas se realiza cuando se agregan o eliminan objetos.
- Reducción del costo global de rastreo a medida que la lista de carpetas específicas se realiza en las que se agregan o eliminan objetos.

El rastreo de eventos de Amazon S3 se ejecuta al consumir eventos de Amazon S3 desde la cola de SQS según la programación del rastreador. No habrá ningún costo si no hay eventos en la cola. Los eventos de Amazon S3 se pueden configurar para que vayan directamente a la cola de SQS o en los casos en que varios consumidores necesitan el mismo evento, una combinación de SNS y SQS. Para obtener más información, consulte the section called “Cómo configurar la cuenta para las notificaciones de eventos de Amazon S3”.

Después de crear y configurar el rastreador en modo evento, el primer rastreo se ejecuta en modo listado y enumera un listado completo del destino de Amazon S3 o del Catálogo de datos. A través del siguiente registro se confirma el funcionamiento del rastreo mediante el uso de eventos de

Amazon S3 tras el primer rastreo correcto: “El rastreo se ejecuta mediante el uso de eventos de Amazon S3”.

Después de crear el rastreo de eventos de Amazon S3 y actualizar las propiedades del rastreador que pueden afectar al rastreo, el rastreo funciona en modo lista y se agrega el siguiente registro: “El rastreo no se ejecuta en modo de evento de S3”.

> **Note**
>
> El número máximo de mensajes que se pueden consumir es de 100 000 mensajes por rastreo.

Consideraciones y limitaciones

Las siguientes consideraciones y limitaciones se aplican al configurar un rastreador para usar notificaciones de eventos de Amazon S3 para detectar cualquier cambio.

- Comportamiento importante con particiones eliminadas

  Cuando se utilizan rastreadores de eventos de Amazon S3 con tablas del Catálogo de datos:

  - Si elimina una partición mediante la llamada a la API `DeletePartition`, también debe eliminar todos los objetos de S3 de esa partición y seleccionar Todos los eventos de eliminación de objetos al configurar las notificaciones de eventos de S3. Si los eventos de eliminación no están configurados, el rastreador volverá a crear la partición eliminada durante su próxima ejecución.
- El rastreador admite un solo destino, ya sean destinos para Amazon S3 o para el Catálogo de datos.
- No es posible utilizar SQS en una VPC privada.
- No se admite el muestreo de Amazon S3.
- El destino del rastreador debe ser una carpeta para un destino de Amazon S3 o una o más tablas del Catálogo de datos de AWS Glue para un destino del Catálogo de datos.
- No se admite el comodín de la ruta “todo”: s3://%
- Para un destino de Catálogo de datos, todas las tablas del Catálogo deben apuntar al mismo bucket de Amazon S3 para el modo de eventos de Amazon S3.
- Para un destino de Catálogo de datos, una tabla de catálogo no debe apuntar a una ubicación de Amazon S3 en formato Delta Lake (que contenga carpetas _symlink o consulte las tablas del catálogo `InputFormat`).

Temas

- Cómo configurar la cuenta para las notificaciones de eventos de Amazon S3
- Configuración de un rastreador para las notificaciones de eventos de Amazon S3 para un destino de Amazon S3
- Configuración de un rastreador para notificaciones de eventos de Amazon S3 para una tabla del Catálogo de datos

Cómo configurar la cuenta para las notificaciones de eventos de Amazon S3

Realice los siguientes pasos de configuración. Tenga en cuenta que los valores entre paréntesis hacen referencia a los valores configurables del script.

1. Debe configurar las notificaciones de eventos para su bucket de Amazon S3.

   Para obtener más información, consulte Notificaciones de eventos de Amazon S3.

2. Para utilizar el rastreador basado en eventos de Amazon S3, debe habilitar la notificación de eventos en el bucket de Amazon S3 con eventos filtrados del prefijo, que es el mismo que el destino de S3 y el almacenamiento en SQS. Puede configurar SQS y la notificación de eventos a través de la consola siguiendo los pasos del Tutorial: configuración de un bucket para notificaciones.

3. Agregue la siguiente política de SQS al rol utilizado por el rastreador.

   JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Sid": "VisualEditor0",
      "Effect": "Allow",
      "Action": [
        "sqs:DeleteMessage",
        "sqs:GetQueueUrl",
        "sqs:ListDeadLetterSourceQueues",
        "sqs:ReceiveMessage",
        "sqs:GetQueueAttributes",
        "sqs:ListQueueTags",
        "sqs:SetQueueAttributes",
        "sqs:PurgeQueue"
```

```
      ],
      "Resource": "arn:aws:sqs:us-east-1:111122223333:cfn-sqs-queue"
    }
  ]
}
```

Configuración de un rastreador para las notificaciones de eventos de Amazon S3 para un destino de Amazon S3

Siga estos pasos para configurar un rastreador para las notificaciones de eventos de Amazon S3 para un destino de Amazon S3 mediante la Consola de administración de AWS o AWS CLI.

Consola de administración de AWS

1. Inicie sesión en la Consola de administración de AWS y abra la consola de GuardDuty en https://console.aws.amazon.com/guardduty/.
2. Configure las propiedades del rastreador. Para obtener más información, consulte Opciones de configuración de rastreadores en la consola de AWS Glue.
3. En la sección Configuración de origen de datos, se preguntará ¿Los datos ya están asignados a tablas de AWS Glue?

   De manera predeterminada, está seleccionado Not yet (Aún no). Déjelo así si está utilizando un origen de datos de Amazon S3 y los datos aún no están asignados a tablas de AWS Glue.
4. En la sección Data sources (Origen de datos), elija Add a data source (Agregar un origen de datos).

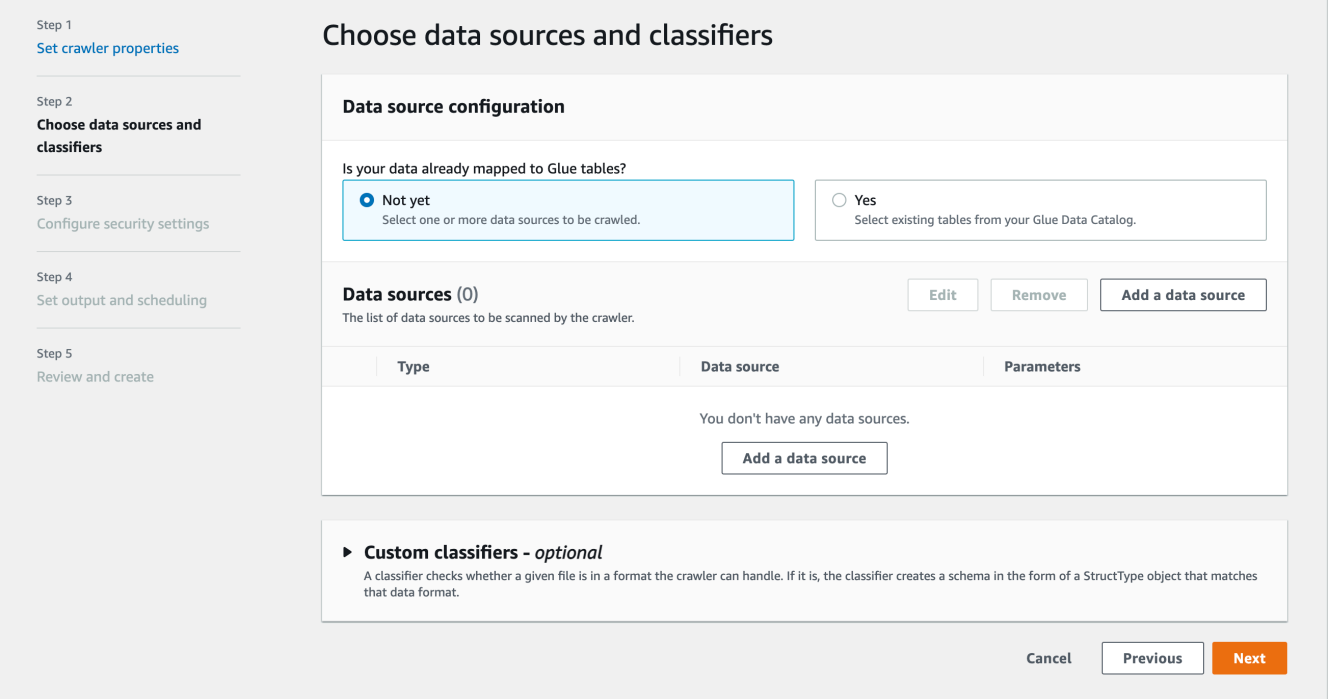

5. En el modal Add data source (Agregar origen de datos), configure el origen de datos de Amazon S3:

   - Data source (Origen de datos): de manera predeterminada, está seleccionado Amazon S3.
   - Network connection (Conexión de red) (opcional): elija Add new connection (Agregar nueva conexión).
   - Location of Amazon S3 data (Ubicación de datos de Amazon S3): de manera predeterminada, está seleccionado In this account (En esta cuenta).
   - Amazon S3 path (Ruta de Amazon S3): especifique la ruta de Amazon S3 en la que se rastrean carpetas y archivos.
   - Subsequent crawler runs (Ejecuciones posteriores del rastreador): elija Crawl based on events (Rastreo basado en eventos) para utilizar las notificaciones de eventos de Amazon S3 para el rastreador.
   - Include SQS ARN (Incluir ARN de SQS): especifique los parámetros del almacén de datos, incluido un ARN SQS válido. (Por ejemplo, `arn:aws:sqs:region:account:sqs`).
   - Include dead-letter SQS ARN (Incluir un SQS ARN de mensajes fallidos) (Optional): especifique un ARN de SQS con mensajes erróneos de Amazon válido. (Por ejemplo, `arn:aws:sqs:region:account:deadLetterQueue`).
   - Elija Add an Amazon S3 data source (Agregar un origen de datos de Amazon S3).

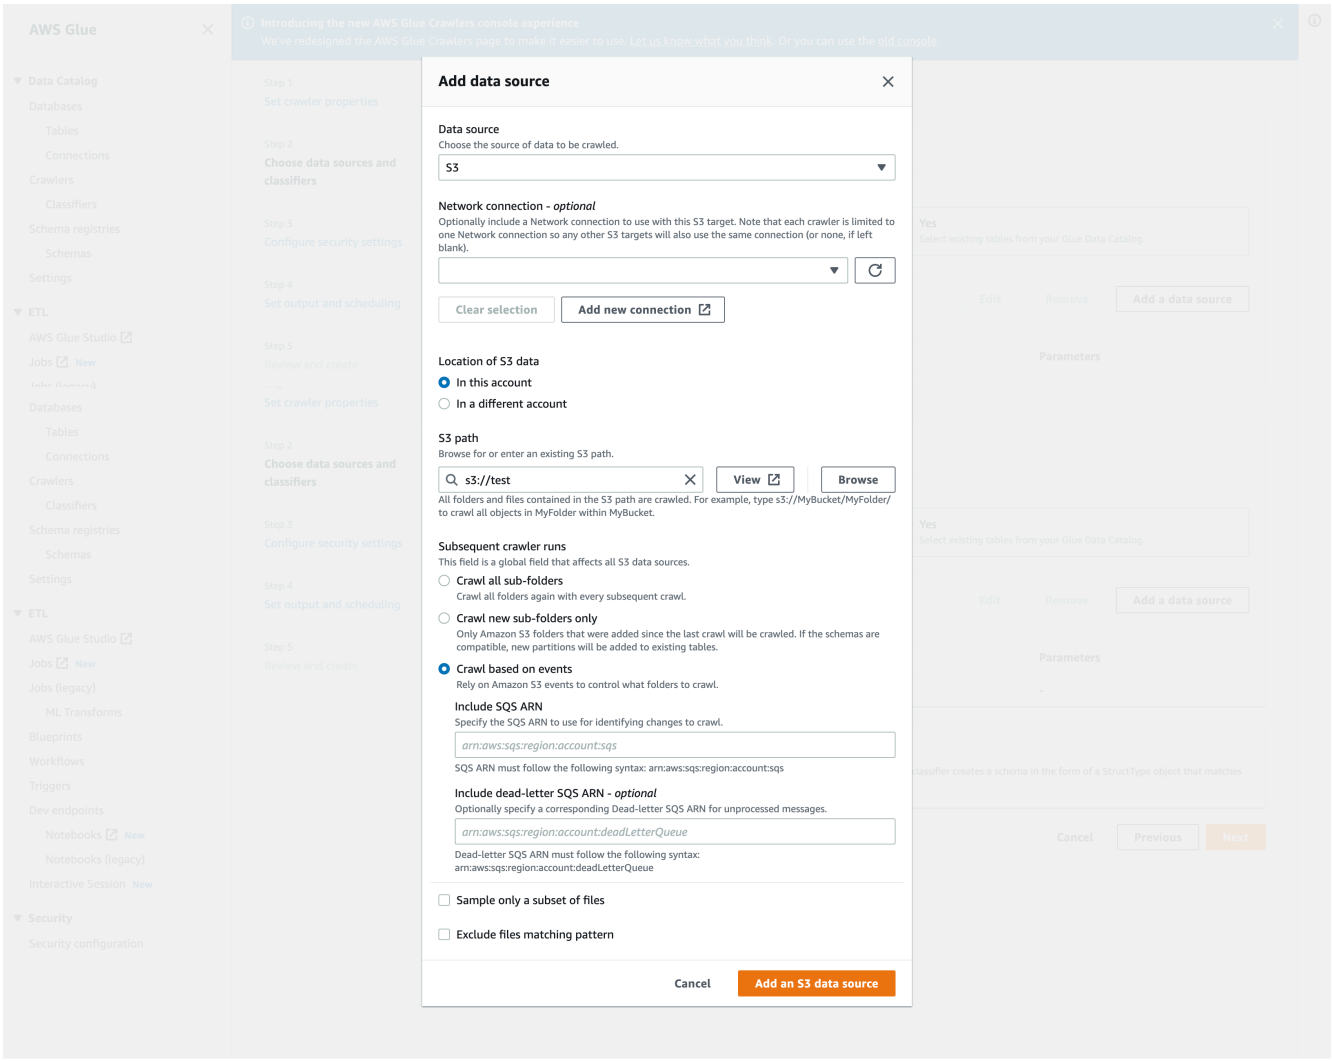

AWS CLI

El siguiente es un ejemplo de llamada a la AWS CLI de Amazon S3 para configurar un rastreador para usar notificaciones de eventos a fin de rastrear un bucket de destino de Amazon S3.

```
Create Crawler:
aws glue update-crawler \
    --name myCrawler \
    --recrawl-policy RecrawlBehavior=CRAWL_EVENT_MODE \
    --schema-change-policy UpdateBehavior=UPDATE_IN_DATABASE,DeleteBehavior=LOG
    --targets '{"S3Targets":[{"Path":"s3://amzn-s3-demo-bucket/", "EventQueueArn":
 "arn:aws:sqs:us-east-1:012345678910:MyQueue"}]}'
```

Configuración de un rastreador para notificaciones de eventos de Amazon S3 para una tabla del Catálogo de datos

Cuando el destino sea una tabla del Catálogo de datos, configure un rastreador para las notificaciones de eventos de Amazon S3 mediante la consola de AWS Glue:

1. Configure las propiedades del rastreador. Para obtener más información, consulte Opciones de configuración de rastreadores en la consola de AWS Glue.
2. En la sección Configuración de origen de datos, se preguntará ¿Los datos ya están asignados a tablas de AWS Glue?

   Seleccione Yes (Sí) para seleccionar las tablas existentes de su Catálogo de datos como origen de datos.
3. En la sección Glue tables (Tablas de Glue), seleccione Add tables (Agregar tablas).

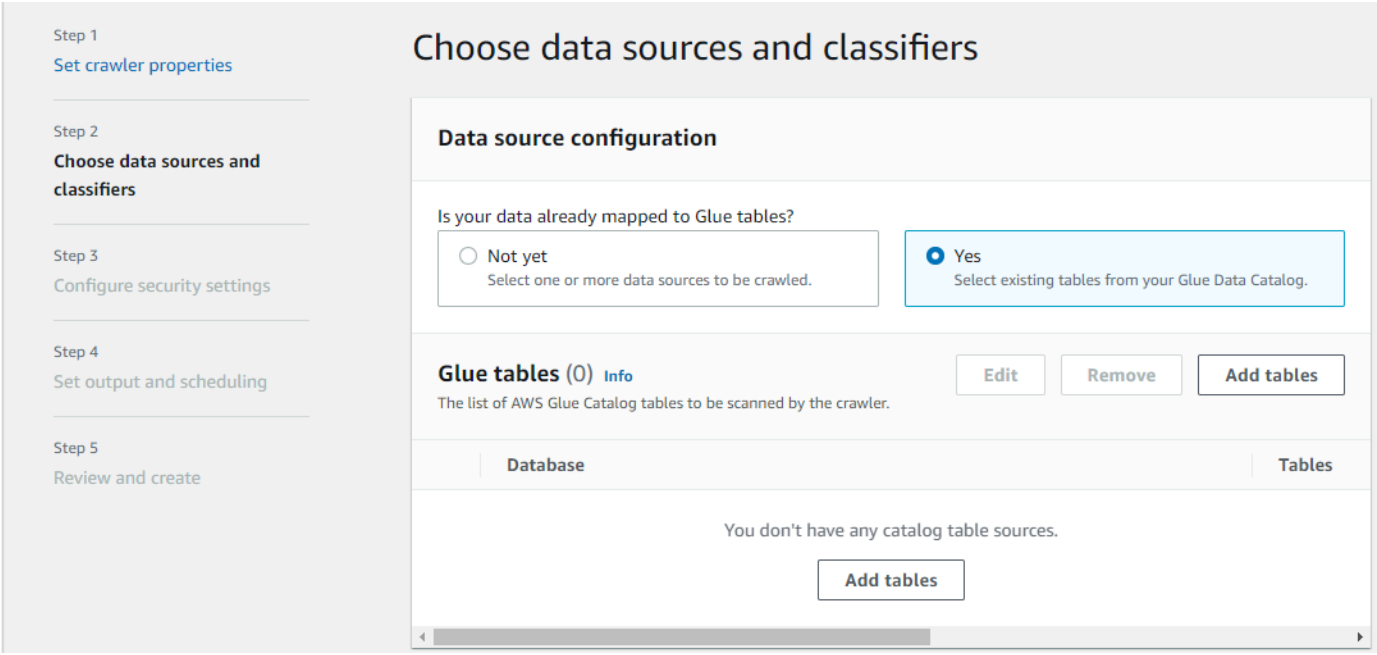

4. En el modal Add table (Agregar tabla), configure la base de datos y las tablas:

   - Network connection (Conexión de red) (opcional): elija Add new connection (Agregar nueva conexión).
   - Base de datos: seleccione una base de datos en el Catálogo de datos.

- Tablas: seleccione una o más tablas de esa base de datos en el Catálogo de datos.
- Subsequent crawler runs (Ejecuciones posteriores del rastreador): elija Crawl based on events (Rastreo basado en eventos) para utilizar las notificaciones de eventos de Amazon S3 para el rastreador.
- Include SQS ARN (Incluir ARN de SQS): especifique los parámetros del almacén de datos, incluido un ARN SQS válido. (Por ejemplo, `arn:aws:sqs:region:account:sqs`).
- Include dead-letter SQS ARN (Incluir un SQS ARN de mensajes fallidos) (Optional): especifique un ARN de SQS con mensajes erróneos de Amazon válido. (Por ejemplo, `arn:aws:sqs:region:account:deadLetterQueue`).
- Elija Confirmar.

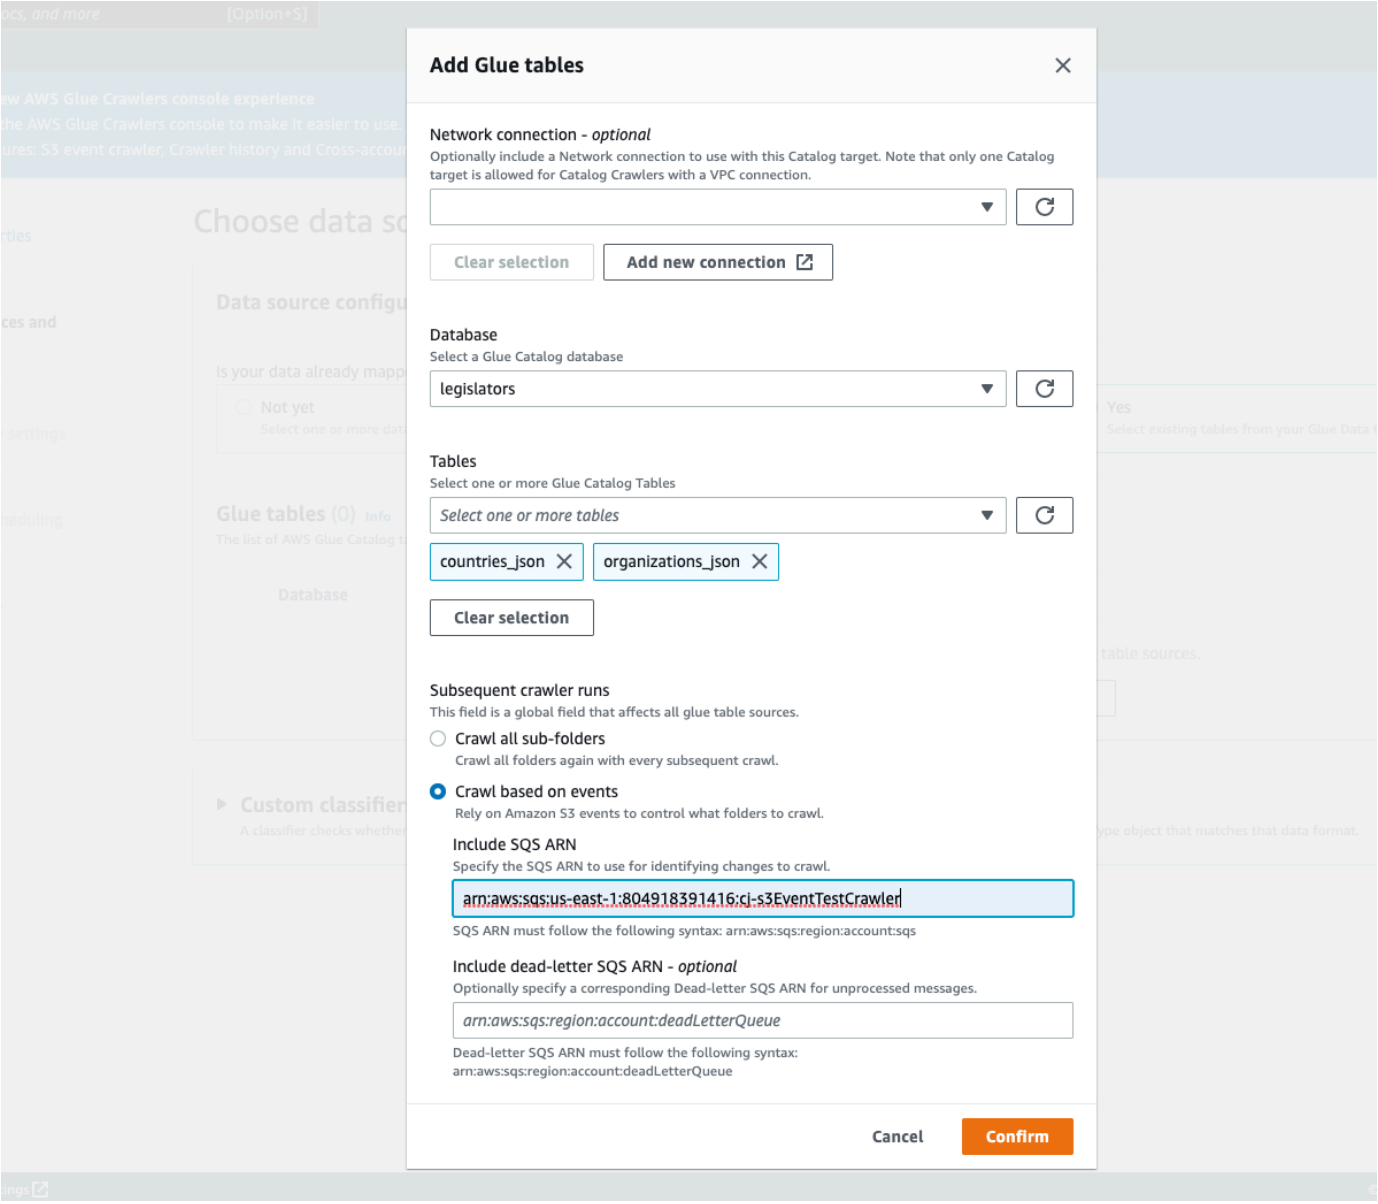

Tutorial: agregar un rastreador de AWS Glue

Para este escenario de AWS Glue, se le pedirá que analice los datos de llegada de las principales compañías aéreas para calcular la popularidad de los aeropuertos de salida mes a mes. Tiene datos de vuelos para el año 2016 en formato CSV almacenado en Amazon S3. Antes de transformar y analizar los datos, catalogue sus metadatos en AWS Glue Data Catalog.

En este tutorial, agregaremos un rastreador que deduce metadatos de estos registros de vuelo en Amazon S3 y crea una tabla en el Data Catalog.

Temas

- Requisitos previos
- Paso 1: agregar un rastreador
- Paso 2: ejecutar el rastreador
- Paso 3: ver objetos del AWS Glue Data Catalog

Requisitos previos

En este tutorial se supone que usted tiene una cuenta de AWS y acceso a AWS Glue.

Paso 1: agregar un rastreador

Siga estos pasos para configurar y ejecutar un rastreador que extraiga los metadatos de un archivo CSV almacenado en Amazon S3.

Para crear un rastreador que lea archivos almacenados en Amazon S3

1. En la consola del servicio AWS Glue, en el menú de la izquierda, elija Crawlers (Rastreadores).
2. En la página Rastreadores, elija Agregar rastreador. Esto inicia una serie de páginas que le solicitan los detalles del rastreador.

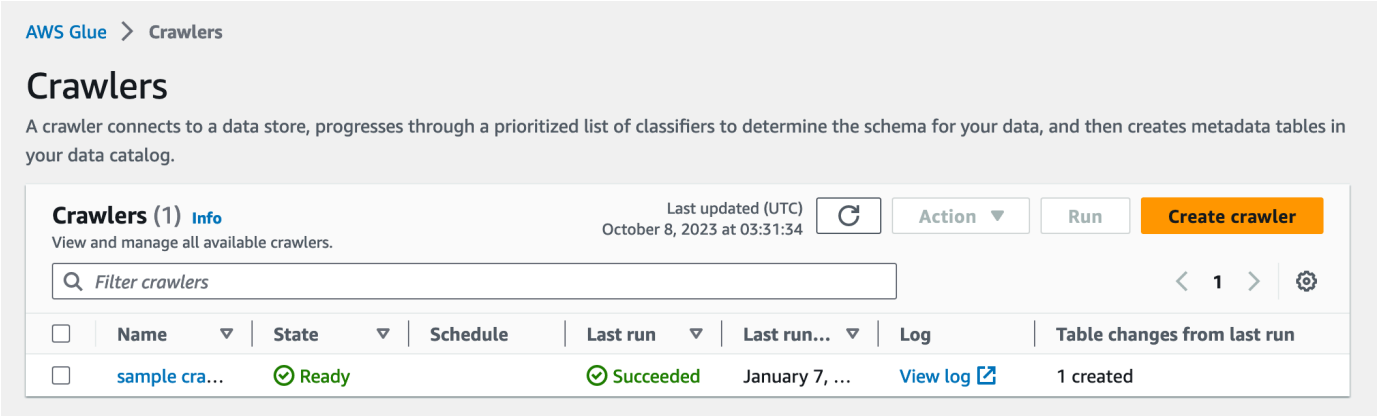

3. En el campo Crawler name (Nombre del rastreador), ingrese **`Flights Data Crawler`** y, a continuación, elija Next (Siguiente).

   Los rastreadores invocan clasificadores para inferir el esquema de sus datos. En este tutorial se utiliza el clasificador integrado para CSV de forma predeterminada.
4. Para el tipo de origen de rastreador, elija Data stores (Almacenes de datos) y luego elija Next (Siguiente).

5. Ahora apuntaremos el rastreador a sus datos. En la página Add a data store (Agregar un almacén de datos), elija el almacén de datos de Amazon S3. Este tutorial no utiliza una conexión, así que deje el campo Connection (Conexión) en blanco si está visible.

   Para la opción Crawl data in (Rastrear los datos en), elija Specified path in another account (Ruta especificada en otra cuenta). Luego, para Include path (Incluir ruta), ingrese la ruta donde el rastreador puede encontrar los datos de vuelos, que es **`s3://crawler-public-us-east-1/flight/2016/csv`**. Después de introducir la ruta, el título de este campo cambia a Include path (Incluir ruta). Elija Siguiente.
6. Puede rastrear varios almacenes de datos con un único rastreador. Sin embargo, en este tutorial, estamos usando solo un único almacén de datos, así que elija No, y luego Next (Siguiente).
7. El rastreador necesita permisos para acceder al almacén de datos y crear objetos en el AWS Glue Data Catalog. Para configurar estos permisos, elija Create an IAM role (Crear un rol de IAM). El nombre del rol de IAM comienza con `AWSGlueServiceRole-` y, en el campo, ingrese la última parte del nombre del rol. Ingrese **`CrawlerTutorial`** y, a continuación, elija Next (Siguiente).

   > **Note**
   >
   > Para crear un rol de IAM, el usuario de AWS debe tener permisos `CreateRole`, `CreatePolicy` y `AttachRolePolicy`.

   El asistente crea un rol de IAM denominado `AWSGlueServiceRole-CrawlerTutorial`, asocia la política administrada de AWS, `AWSGlueServiceRole`, a este rol y agrega una política en línea que permite el acceso de lectura a la ubicación `s3://crawler-public-us-east-1/flight/2016/csv` de Amazon S3.
8. Cree una programación para el rastreador. Para Frequency (Frecuencia), elija Run on demand (Ejecutar bajo demanda), y luego elija Next (Siguiente).
9. Los rastreadores crean tablas en su Data Catalog. Una base de datos de en una base de datos del Data Catalog. Primero, elija Add database (Agregar base de datos) para crear una base de datos. En la ventana emergente, ingrese **`test-flights-db`** para el nombre de la base de datos y, a continuación, elija Create (Crear).

   Luego, ingrese **`flights`** para Prefix added to tables (Prefijo agregado a las tablas). Utilice los valores predeterminados para el resto de las opciones y elija Next (Siguiente).

10. Compruebe las opciones elegidas en el asistente Add crawler (Agregar rastreador). Si detecta algún error, puede elegir Back (Atrás) para volver a las páginas anteriores y realizar cambios.

    Después de haber revisado la información, elija Finish (Finalizar) para crear el rastreador.

Paso 2: ejecutar el rastreador

Después de crear un rastreador, el asistente lo envía a la página Crawlers view (Visualización de rastreadores). Dado que creó un rastreador con una programación bajo demanda, se le ofrece la opción de ejecutar el rastreador.

Para ejecutar un rastreador

1. El banner situado cerca de la parte superior de esta página le permite saber que se creó el rastreador y le pregunta si desea ejecutarlo ahora. Elija Run it now (Ejecutarlo ahora) para ejecutar el rastreador.

   El banner cambia para mostrar los mensajes “Attempting to run (Intento de ejecución)” and “Running (Ejecución)” para el rastreador. Una vez que el rastreador comienza a ejecutarse, el banner desaparece y la visualización del rastreador se actualiza para mostrar un estado Starting (Inicio) para el rastreador. Después de un minuto, puede hacer clic en el ícono Refresh (Actualizar) para actualizar el estado del rastreador que se muestra en la tabla.
2. Cuando se completa el rastreador, aparece un nuevo banner que describe los cambios realizados por el rastreador. Puede elegir el enlace test-flights-db (probar base de datos de vuelos) para ver los objetos del Data Catalog.

Paso 3: ver objetos del AWS Glue Data Catalog

El rastreador lee los datos en la ubicación de origen y crea tablas en el Data Catalog. Una tabla es una definición de metadatos que representa sus datos e incluye el esquema de datos. Las tablas del Data Catalog no contienen datos. En su lugar, se utilizan estas tablas como origen o destino en una definición de trabajo.

Para ver los objetos del Data Catalog creados por el rastreador

1. En el panel de navegación de la izquierda, en Data Catalog, elija Databases (Bases de datos). Aquí puede ver la base de datos de `flights-db` que crea el rastreador.

2. En el panel de navegación de la izquierda, Data catalog y luego en Databases (Bases de datos), elija Tables (Tablas). Aquí puede ver la tabla de `flightscsv` que crea el rastreador. Si elige el nombre de la tabla, puede ver la configuración, los parámetros y las propiedades de la tabla. Si se desplaza hacia abajo en esta vista, puede ver el esquema, que es información sobre las columnas y los tipos de datos de la tabla.
3. Si elige View partitions (Ver particiones) en la página de vista de tabla, puede ver las particiones creadas para los datos. La primera columna es la clave de partición.

Cómo definir los metadatos manualmente

El Catálogo de datos de AWS Glue es un repositorio central que almacena los metadatos sobre los orígenes y conjuntos de datos. Si bien un rastreador puede rastrear y completar metadatos automáticamente para los orígenes de datos compatibles, hay determinadas situaciones en las que es posible que deba definir los metadatos manualmente en el Catálogo de datos:

- Formatos de datos no compatibles: Si tiene orígenes de datos que no son compatibles con el rastreador, deberá definir los metadatos correspondientes a esos orígenes de datos en el catálogo de forma manual.
- Requisitos de metadatos personalizados: El Rastreador de AWS Glue infiere los metadatos en función de reglas y convenciones predefinidas. Si tiene requisitos de metadatos específicos que no están cubiertos por los metadatos deducidos mediante el Rastreador de AWS Glue, puede definir los metadatos manualmente para adaptarlos a sus necesidades.
- Gobernanza y estandarización de los datos: En algunos casos, es posible que quiera tener un mayor control sobre las definiciones de los metadatos por motivos de gobernanza, cumplimiento o seguridad de los datos. Al definir los metadatos manualmente, se asegura de que estos cumplan con las normas y políticas de su organización.
- Marcador de posición para la futura ingesta de datos: Si tiene orígenes de datos que no están disponibles o accesibles de forma inmediata, puede crear tablas de esquemas vacías a modo de marcadores de posición. Una vez que los orígenes de datos estén disponibles, podrá completar las tablas con los datos reales y, al mismo tiempo, mantener la estructura predefinida.

Para definir los metadatos manualmente, puede usar la consola de AWS Glue, la consola de Lake Formation, la API de AWS Glue o la AWS Command Line Interface (AWS CLI). Puede crear bases de datos, tablas y particiones, y especificar las propiedades de los metadatos, como los nombres de las columnas, los tipos de datos, las descripciones y otros atributos.

Creación de bases de datos

Las bases de datos se utilizan para organizar tablas de metadatos en el AWS Glue. Al definir una tabla en el AWS Glue Data Catalog, puede añadirla a una base de datos. Una tabla puede estar en solo una base de datos.

Su base de datos puede contener tablas que definan datos de muchos almacenes de datos diferentes. Estos datos pueden incluir objetos de Amazon Simple Storage Service (Amazon S3) y tablas relacionales de Amazon Relational Database Service.

> **Note**
>
> Al eliminar una base de datos del Catálogo de datos de AWS Glue, también se eliminan todas las tablas de la base de datos.

Para ver la lista de bases de datos, inicie sesión en Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/. Seleccione Databases (Bases de datos) y, a continuación, seleccione un nombre de base de datos en la lista para ver los detalles.

En la pestaña Databases (Bases de datos) de la consola de AWS Glue, se pueden añadir, editar y eliminar bases de datos:

- Para crear una nueva base de datos, seleccione Add database (Añadir base de datos) e indique un nombre y una descripción. Para ofrecer compatibilidad con otros almacenes de metadatos, como Apache Hive, el nombre se incorpora en minúsculas.

  > **Note**
  >
  > Si tiene previsto obtener acceso a la base de datos desde Amazon Athena, proporcione un nombre únicamente con caracteres alfanuméricos y guiones bajos. Para obtener más información, consulte Nombres de Athena.

- Para editar la descripción de una base de datos, marque la casilla situada junto al nombre de la base de datos y seleccione Edit database (Editar base de datos).
- Para eliminar una base de datos, seleccione la casilla situada junto al nombre de la base de datos y elija Remove (Eliminar).
- Para ver la lista de tablas que contiene la base de datos, elija el nombre de la base de datos; todas las tablas aparecerán enumeradas en las propiedades de la base de datos.

Para cambiar la base de datos de escritura de un rastreador, tendrá que modificar la definición del rastreador. Para obtener más información, consulte Uso de rastreadores para completar el Catálogo de datos .

Enlaces de recursos a base de datos

> La consola de AWS Glue se ha actualizado recientemente. La versión actual de la consola no admite enlaces de recursos a base de datos.

El Catálogo de datos también puede contener enlaces de recursos a bases de datos. Un enlace de recursos a bases de datos es un enlace a una base de datos local o compartida. En la actualidad, puede crear enlaces de recursos solo en AWS Lake Formation. Después de crear un enlace de recurso a una base de datos, puede utilizar el nombre del enlace de recursos donde quiera que utilice el nombre de la base de datos. Junto con las bases de datos que posee o que se comparten con usted, los enlaces de recursos a base de datos son devueltos por `glue:GetDatabases()` y aparecerán como entradas en la página Databases (Bases de datos) de la consola de AWS Glue.

El Catálogo de datos también puede contener enlaces de recursos a tablas.

Para obtener más información acerca de los enlaces de recursos, consulte Creación de enlaces de recursos en la Guía para desarrolladores de AWS Lake Formation.

Creación de tablas

Aunque ejecutar un rastreador es el método recomendado para hacer un inventario de los datos incluidos en sus almacenes de datos, puede añadir tablas de metadatos al AWS Glue Data Catalog manualmente. Este enfoque le permite tener más control sobre las definiciones de los metadatos y personalizarlas de acuerdo con sus requisitos específicos.

También puede agregar tablas al Catálogo de datos manualmente de las siguientes formas:

- Utilice la consola de AWS Glue para crear de forma manual una tabla en el AWS Glue Data Catalog. Para obtener más información, consulte Creación de tablas mediante la consola.
- Use la operación `CreateTable` en API de AWS Glue para crear una tabla en AWS Glue Data Catalog. Para obtener más información, consulte Acción CreateTable (Python: create_table).
- Utilice plantillas de CloudFormation. Para obtener más información, consulte AWS CloudFormation para AWS Glue.

Al definir una tabla de forma manual mediante la consola o una API, especifica el esquema de tabla y el valor de un campo de clasificación que indica el tipo y el formato de los datos de la fuente de datos. Si un rastreador crea la tabla, el formato de los datos y el esquema se determinan por un clasificador personalizado o un clasificador integrado. Para obtener información adicional acerca de cómo crear una tabla mediante la consola de AWS Glue, consulte Creación de tablas mediante la consola.

Temas

- Particiones de la tabla
- Enlaces de recursos a tabla
- Creación de tablas mediante la consola
- Creación de índices de particiones
- Actualización de tablas del Catálogo de datos creadas de forma manual mediante rastreadores
- Propiedades de la tabla del catálogo de datos

Particiones de la tabla

Una definición de tabla de AWS Glue de una carpeta de Amazon Simple Storage Service (Amazon S3) puede describir una tabla con particiones. Por ejemplo, para mejorar el desempeño de las consultas, una tabla con particiones podría separar datos mensuales en diferentes archivos con el nombre del mes como clave. En AWS Glue, las definiciones de tabla incluyen la clave de partición de una tabla. Cuando AWS Glue evalúa los datos de carpetas de Amazon S3 para catalogar una tabla, determina si se agrega una tabla individual o con particiones.

Puede crear índices de partición en una tabla para obtener un subconjunto de las particiones en lugar de cargar todas las particiones de la tabla. Para obtener más información sobre cómo trabajar con índices de partición, consulte Creación de índices de particiones .

Todas las condiciones siguientes deben cumplirse para que AWS Glue cree una tabla con particiones para una carpeta de Amazon S3:

- Los esquemas de los archivos son similares, según determine AWS Glue.
- El formato de datos de los archivos es el mismo.
- El formato compresión de los archivos es el mismo.

Por ejemplo, es posible que posea un bucket de Amazon S3 denominado `my-app-bucket`, en el que almacene datos de aplicaciones de ventas de iOS y Android. Los datos se distribuyen en particiones por año, mes y día. Los archivos de datos para ventas iOS y Android tienen el mismo esquema, formato de datos y formato de compresión. En AWS Glue Data Catalog el rastreador de AWS Glue crea una definición de tabla con claves de partición para año, mes y día.

En la siguiente lista de Amazon S3 para `my-app-bucket` se muestran algunas de las particiones. El símbolo = se utiliza para asignar valores de clave de partición.

```
my-app-bucket/Sales/year=2010/month=feb/day=1/iOS.csv
my-app-bucket/Sales/year=2010/month=feb/day=1/Android.csv
my-app-bucket/Sales/year=2010/month=feb/day=2/iOS.csv
my-app-bucket/Sales/year=2010/month=feb/day=2/Android.csv
...
my-app-bucket/Sales/year=2017/month=feb/day=4/iOS.csv
my-app-bucket/Sales/year=2017/month=feb/day=4/Android.csv
```

Enlaces de recursos a tabla

> La consola de AWS Glue se ha actualizado recientemente. La versión actual de la consola no admite enlaces de recursos a tabla.

El Catálogo de datos también puede contener enlaces de recursos a tablas. Un enlace de recursos a tablas es un enlace a una tabla local o compartida. En la actualidad, puede crear enlaces de recursos solo en AWS Lake Formation. Después de crear un enlace de recurso a una tabla, puede utilizar el nombre del enlace de recursos donde quiera que utilice el nombre de la tabla. Junto con las tablas que posee o que se comparten con usted, los enlaces de recursos a tablas son devueltos por `glue:GetTables()` y aparecerán como entradas en la página Tables (Tablas) de la consola de AWS Glue.

El Catálogo de datos también puede contener enlaces de recursos a tablas.

Para obtener más información acerca de los enlaces de recursos, consulte Creación de enlaces de recursos en la Guía para desarrolladores de AWS Lake Formation.

Creación de tablas mediante la consola

Una tabla en el AWS Glue Data Catalog es la definición de metadatos que representa los datos en un almacén de datos. Puede crear tablas al ejecutar un rastreador, o bien puede crear una tabla manualmente en la consola de AWS Glue. En la lista Tablas en la consola de AWS Glue se muestran los valores de los metadatos de su tabla. Puede usar definiciones de tabla para especificar orígenes y destinos al crear trabajos de ETL (extracción, transformación y carga).

> **Note**
>
> Con los cambios recientes en la consola de administración de AWS, es posible que tenga que modificar sus roles de IAM existentes para obtener permiso de `SearchTables`. Para la creación de nuevos roles, se agregó de forma predeterminada el permiso de la API de `SearchTables`.

Para comenzar, inicie sesión en Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/. Elija la pestaña Tablas y use el botón Agregar tablas para crear tablas con un rastreador o escribiendo atributos manualmente.

Adición de tablas en la consola

A fin de usar un rastreador para agregar tablas, elija Agregar tablas y Agregar tablas mediante un rastreador. A continuación, siga las instrucciones en el asistente Adición de rastreadores. Cuando se ejecuta el rastreador, se agregan las tablas al AWS Glue Data Catalog. Para obtener más información, consulte Uso de rastreadores para completar el Catálogo de datos .

Si conoce los atributos necesarios para crear una definición de tabla de Amazon Simple Storage Service (Amazon S3) en su Data Catalog puede crearla con el asistente de tabla. Elija Agregar tablas, Agregar tabla manualmente y siga las instrucciones en el asistente Agregar tabla.

Al agregar una tabla manualmente a través de la consola, tenga en cuenta lo siguiente:

- Si tiene previsto obtener acceso a la tabla desde Amazon Athena, proporcione un nombre únicamente con caracteres alfanuméricos y guiones bajos. Para obtener más información, consulte Nombres de Athena.
- La ubicación de sus datos de origen debe ser una ruta de Amazon S3.

- El formato de datos de los datos debe coincidir con uno de los formatos que aparecen en el asistente. La clasificación correspondiente, SerDe, y otras propiedades de tabla se rellenan automáticamente según el formato elegido. Puede definir tablas con los siguientes formatos:

  Avro

  Formato binario JSON Apache Avro.

  CSV

  Valores separados por caracteres. También puede especificar el delimitador de coma, barra vertical, punto y coma, tabulador o Ctrl-A.

  JSON

  JavaScript Object Notation, notación de objetos de JavaScript.

  XML

  Formato de lenguaje de marcado extensible. Especifique la etiqueta XML que define una fila en los datos. Las columnas se definen dentro de etiquetas de fila.

  Parquet

  Almacenamiento en columnas de Apache Parquet.

  ORC

  Formato archivo Optimized Row Columnar (ORC). Formato diseñado para almacenar de forma eficiente los datos de Hive.

- Puede definir una clave de partición para la tabla.
- Actualmente, las tablas con particiones que crea con la consola no se pueden usar en los trabajos de ETL.

Atributos de tabla

A continuación se muestran algunos atributos importantes de su tabla:

Nombre

El nombre se determina al crearse la tabla y no puede cambiarlo. Puede hacer referencia a un nombre de tabla en muchas operaciones de AWS Glue.

Base de datos

El objeto contenedor donde reside su tabla. Este objeto contiene una organización de sus tablas que existe en el AWS Glue Data Catalog y puede diferir de una organización en su almacén de datos. Al eliminar una tabla, todas las tablas incluidas en la base de datos también se eliminan del Data Catalog.

Descripción

Descripción de la tabla. Puede escribir una descripción para ayudarle a entender el contenido de la tabla.

Formato de tabla

Especifique la creación de una tabla estándar de AWS Glue o de una tabla en formato Apache Iceberg.

El Catálogo de datos proporciona las siguientes opciones de optimización de tablas para administrar el almacenamiento de las tablas y mejorar el rendimiento de las consultas para las tablas de Iceberg.

- Compactación: los archivos de datos se combinan y se reescriben para eliminar los datos obsoletos y consolidar los datos fragmentados en archivos más grandes y eficientes.
- Retención de instantáneas: las instantáneas son versiones con fecha y hora de una tabla de Iceberg. Las configuraciones de retención de instantáneas permiten a los clientes determinar cuánto tiempo se deben retener las instantáneas y cuántas instantáneas retener. La configuración de un optimizador de retención de instantáneas puede ayudar a administrar la sobrecarga de almacenamiento mediante la eliminación de las instantáneas antiguas e innecesarias y sus correspondientes archivos subyacentes.
- Eliminación de archivos huérfanos: los archivos huérfanos son archivos a los que los metadatos de la tabla de Iceberg ya no hacen referencia. Con el tiempo, estos archivos se pueden acumular, sobre todo después de operaciones como la eliminación de tablas o los errores en los trabajos de ETL. Habilitar la eliminación de archivos huérfanos permite a AWS Glue identificar y eliminar periódicamente estos archivos innecesarios y así liberar espacio de almacenamiento.

Para obtener más información, consulte Optimización de las tablas de Iceberg.

Configuración de optimización

Puede utilizar la configuración predeterminada o personalizar la configuración para activar los optimizadores de tablas.

rol de IAM

Para ejecutar los optimizadores de tablas, el servicio asume un rol de IAM en su nombre. Puede elegir un rol de IAM mediante el menú desplegable. Asegúrese de que el rol tenga los permisos necesarios para habilitar la compactación.

Para obtener más información sobre los permisos necesarios para este rol de IAM, consulte Requisitos previos para la optimización de tablas .

Ubicación

El señalizador a la ubicación de los datos en un almacén de datos que representa esta definición de tabla.

Clasificación

Un valor de categorización proporcionado cuando se creó la tabla. Normalmente, este se escribe al ejecutarse un rastreador y especifica el formato de los datos de origen.

Última actualización

La hora y la fecha (UTC) en que se actualizó esta tabla en el Data Catalog.

Fecha agregada

La hora y la fecha (UTC) en que se agregó esta tabla al Data Catalog.

Obsoleto

Si AWS Glue descubre que una tabla en el Data Catalog ya no existe en su almacén de datos original, marca la tabla como obsoleta en el catálogo de datos. Si ejecuta un flujo de trabajo que hace referencia a una tabla obsoleta, podría producirse un error en el flujo de trabajo. Edite trabajos que hagan referencia a tablas obsoletas para quitarlas como orígenes y destinos. Recomendamos que elimine las tablas obsoletas cuando ya no sean necesarias.

Connection

Si AWS Glue requiere una conexión a su almacén de datos, el nombre de la conexión se asocia a la tabla.

Visualización y administración de los detalles de la tabla

Para ver los detalles de una tabla existente, elija el nombre de tabla de la lista y, a continuación, elija Acción, Ver detalles.

Entre los detalles de la tabla se incluyen propiedades de su tabla y su esquema. Esta vista muestra el esquema de la tabla, incluidos los nombres de columna en el orden definido para la tabla, los tipos de datos y las columnas con clave para las particiones. Si una columna es un tipo complejo, puede elegir Ver propiedades para mostrar detalles de la estructura de ese campo, como se muestra en el siguiente ejemplo:


```
{
"StorageDescriptor":
    {
      "cols": {
         "FieldSchema": [
           {
             "name": "primary-1",
             "type": "CHAR",
             "comment": ""
           },
           {
             "name": "second ",
             "type": "STRING",
             "comment": ""
           }
        ]
      },
      "location": "s3://aws-logs-111122223333-us-east-1",
      "inputFormat": "",
      "outputFormat": "org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat",
      "compressed": "false",
      "numBuckets": "0",
      "SerDeInfo": {
          "name": "",
          "serializationLib": "org.apache.hadoop.hive.serde2.OpenCSVSerde",
          "parameters": {
              "separatorChar": "|"
           }
      },
      "bucketCols": [],
      "sortCols": [],
      "parameters": {},
      "SkewedInfo": {},
      "storedAsSubDirectories": "false"
    },
    "parameters": {
       "classification": "csv"
```

```
    }
}
```

Para obtener más información acerca de las propiedades de una tabla, como `StorageDescriptor`, consulte Estructura StorageDescriptor.

Para cambiar el esquema de una tabla, elija Editar esquema para agregar y quitar columnas, cambiar nombres de columna y cambiar tipos de datos.

Para comparar diferentes versiones de una tabla, incluido su esquema, elija Comparar versiones para ver una comparación paralela de dos versiones del esquema para una tabla. Para obtener más información, consulte Comparación de las versiones del esquema de la tabla .

Para mostrar los archivos que componen una partición de Amazon S3, elija Ver partición. Para las tablas de Amazon S3, la columna Clave muestra las claves de partición que se usan para particionar la tabla en el almacén de datos de origen. La creación de particiones es una forma de dividir una tabla en partes relacionadas según los valores de una columna de clave, tales como fecha, ubicación o departamento. Para obtener más información acerca de las particiones, busque en Internet información acerca de la “creación de particiones Hive”.

> **Note**
>
> Para obtener instrucciones paso a paso para ver los detalles de una tabla, consulte el tutorial Explorar tabla en la consola.

Comparación de las versiones del esquema de la tabla

Cuando compara dos versiones de esquemas de tablas, puede comparar los cambios en las filas anidadas al expandir y contraer las filas anidadas, puede comparar los esquemas de dos versiones y ver las propiedades de las tablas lado a lado.

Comparación de versiones

1. En la consola de AWS Glue, seleccione Tablas, Acciones y, a continuación, elija Comparar versiones.

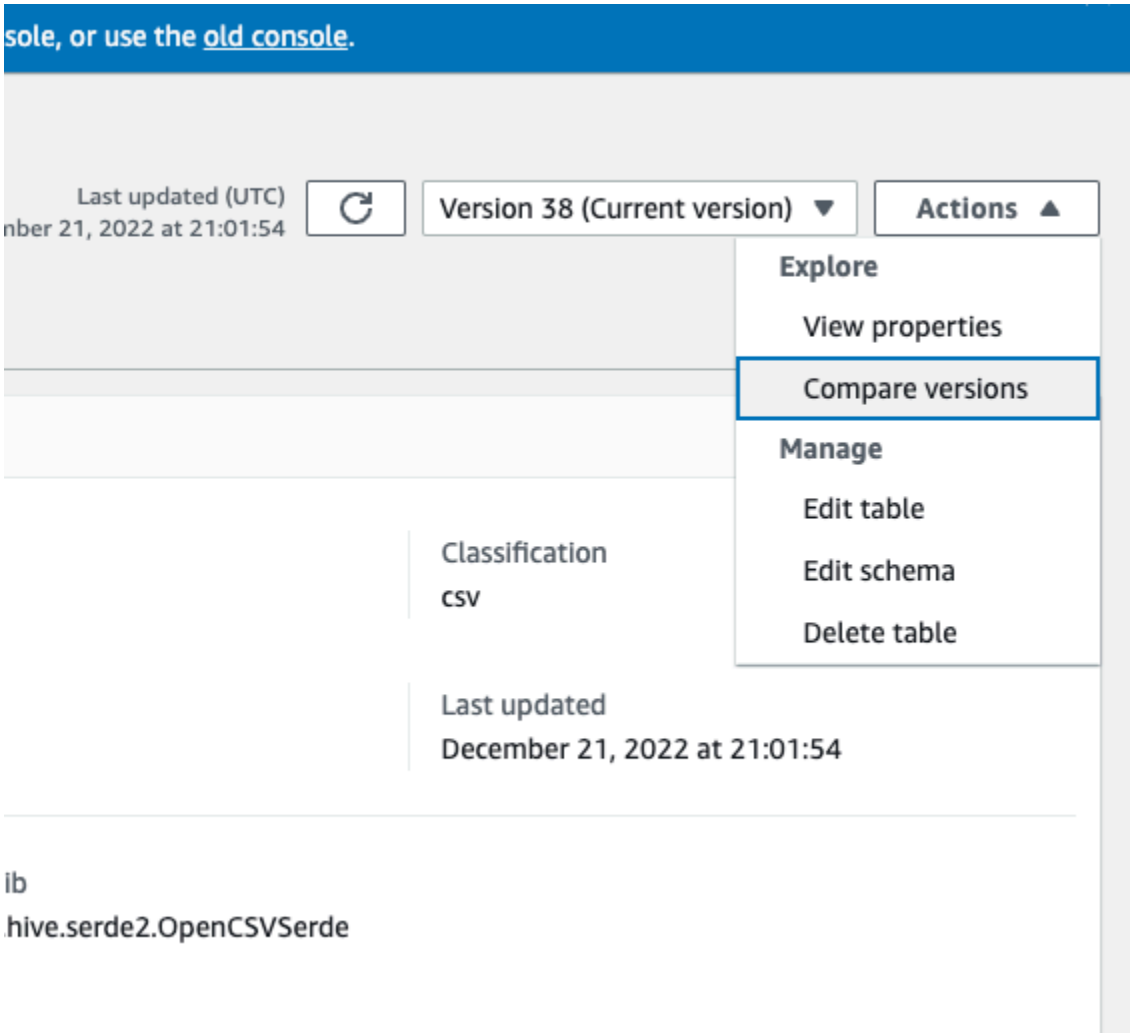

2. Elija una versión para comparar mediante el menú desplegable de versiones. Cuando compare esquemas, la pestaña Esquema aparece resaltada en naranja.
3. Cuando compare tablas entre dos versiones, los esquemas de las tablas se muestran en la parte izquierda y derecha de la pantalla. Esto le permite visualizar los cambios al comparar los campos de Nombre de columna, tipo de datos, clave y comentario uno al lado del otro. Cuando se produce un cambio, aparece un icono de color que muestra el tipo de cambio realizado.

   - Eliminada: se muestra un icono rojo que indica dónde se quitó la columna de una versión anterior del esquema de la tabla.
   - Editada o movida: se muestra un icono azul que indica dónde se modificó o movió la columna en una versión más reciente del esquema de la tabla.
   - Agregado: se muestra un icono verde que indica dónde se agregó una columna a una versión más reciente del esquema de la tabla.

- Cambios anidados: se muestra un icono amarillo que indica dónde contiene cambios la columna anidada. Elija la columna para expandirla y ver las columnas que se eliminaron, editaron, movieron o agregaron.

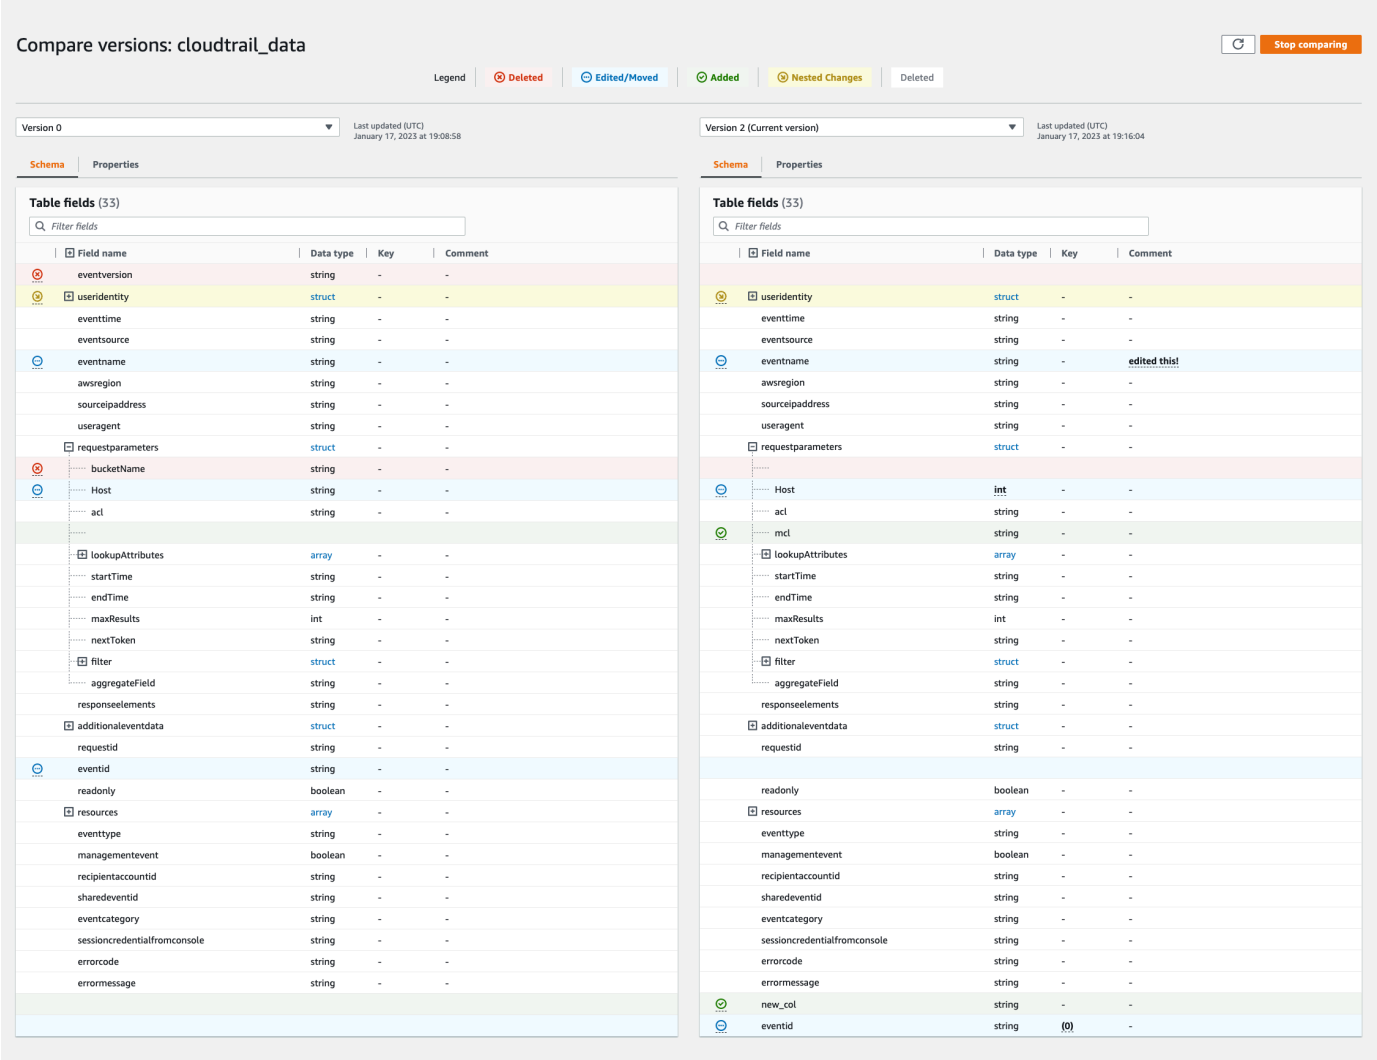

4. Utilice la barra de búsqueda de campos filtrados para mostrar los campos en función de los caracteres que introduzca aquí. Si introduce un nombre de columna en cualquier versión de la tabla, los campos filtrados se muestran en ambas versiones de la tabla para mostrarle dónde se produjeron los cambios.
5. Para comparar propiedades, elija la pestaña de Propiedades.
6. Para detener la comparación de versiones, elija Detener comparación para volver a la lista de tablas.

Creación de índices de particiones

Con el tiempo, cientos de miles de particiones se agregan a una tabla. La API GetPartitions se utiliza para buscar las particiones en la tabla. La API devuelve las particiones que coinciden con la expresión proporcionada en la solicitud.

Utilicemos, a modo de ejemplo, una tabla sales_data (datos de servicio), la cual está dividida en las secciones Country (País), Category (Categoría), Year (Año), Month (Mes) y creationDate (Fecha de creación). Para obtener los datos de ventas de todos los objetos que se vendieron en la categoría Books (Libros) durante el 2020, después del 2020-08-15, tiene que crear una solicitud de `GetPartitions` con la expresión “Category = ‘Books’ and creationDate > ‘2020-08-15’” en el catálogo de datos.

Si no hay índices de partición presentes en la tabla, AWS Glue carga todas las particiones de la tabla y, a continuación, filtra las particiones cargadas con la expresión de consulta proporcionada por el usuario en la solicitud `GetPartitions`. La consulta tarda más tiempo en ejecutarse a medida que aumenta el número de particiones en una tabla sin índices. Con un índice, la consulta `GetPartitions` intentará obtener un subconjunto de las particiones en lugar de cargar todas las particiones en la tabla.

Temas

- Acerca de los índices de partición
- Creación de una tabla con índices de partición
- Agregado de un índice de partición a una tabla existente
- Descripción de índices de partición en una tabla
- Limitaciones al uso de índices de partición
- Uso de índices para una llamada GetPartitions optimizada
- Integración con motores

Acerca de los índices de partición

Cuando crea un índice de partición, especifica una lista de claves de partición que ya existen en una tabla determinada. El índice de partición es una sublista de claves de partición definidas en la tabla. Se puede crear un índice de partición en cualquier permutación de claves de partición definidas en la tabla. Para la tabla sales_data anterior, los índices posibles son (país, categoría, fecha de creación), (país, categoría, año), (país, categoría), (país), (categoría, país, año, mes), etc.

El Data Catalog concatenará los valores de partición en el orden proporcionado en el momento de la creación del índice. El índice se genera de forma continua a medida que se agregan particiones a la tabla. Los índices pueden crearse para los tipos de columna Cadena (string, char y varchar), Numérico (int, biging, long, tinyint y smallint) y Fecha (aaaa-mm-dd).

Tipos de datos compatibles

- Fecha: una fecha en el formato ISO, como `YYYY-MM-DD`. Por ejemplo, la fecha `2020-08-15`. El formato utiliza guiones (-) para separar el año, el mes y el día. El rango de fechas admitido para los lapsos de indexación es de `0000-01-01` a `9999-12-31`.
- Cadena: un literal de cadena entre comillas simples o dobles.
- Char: datos de caracteres de longitud fija, con una longitud especificada comprendida entre 1 y 255 como, por ejemplo, char(10).
- Varchar: datos de caracteres de longitud variable, con una longitud especificada comprendida entre 1 y 65 535 como, por ejemplo, varchar(10).
- Numérico: int, bigint, long, tinyint y smallint

Los índices para los tipos de datos Numérico, Cadena y Fecha admiten el uso de los símbolos **=**, **>**, **>=**, **<** y **<=** entre los operadores. La solución de indexación actualmente solo admite el operador lógico `AND`. Las subexpresiones con los operadores “LIKE (COMO)”, “IN (EN)”, “OR (O)” y “NOT (NO)” se ignoran en la expresión para el filtrado mediante índice. El filtrado de la subexpresión ignorada se realiza en las particiones obtenidas después de aplicar el filtrado de índices.

Para cada partición agregada a una tabla, se crea elemento de índice correspondiente. Para una tabla con particiones “n”, un índice de partición dará como resultado elementos de índice de partición “n”. El índice de partición “m” en la misma tabla dará como resultado elementos de índice de partición “m*n”. Cada elemento del índice de partición se cargará de acuerdo con la política de precios actual de AWS Glue para el almacenamiento del catálogo de datos. Para obtener detalles sobre el precio de los objetos de almacenamiento, consulte Precios de AWS Glue.

Creación de una tabla con índices de partición

Puede crear un índice de partición durante la creación de la tabla. La solicitud `CreateTable` toma una lista de objetos de `PartitionIndex` como entrada. Se puede crear un máximo de 3 índices de partición en una tabla determinada. Cada índice de partición requiere un nombre y una lista de `partitionKeys` definida para la tabla. Los índices creados en una tabla se pueden recuperar con la API `GetPartitionIndexes`

Agregado de un índice de partición a una tabla existente

Para agregar un índice de partición a una tabla existente, se usa la operación `CreatePartitionIndex`. Puede crear un `PartitionIndex` por cada operación `CreatePartitionIndex`. Agregar un índice no afecta la disponibilidad de una tabla, ya que la tabla sigue estando disponible mientras se crean los índices.

El estado del índice para una partición agregada se establece en CREATING (CREACIÓN) y se inicia la creación de los datos del índice. Si el proceso de creación de los índices se realiza correctamente, el estado del índice se actualiza a ACTIVE (ACTIVO) y, en caso de que el proceso no se realice correctamente, el estado del índice se actualiza a FAILED (ERROR). La creación del índice puede presentar errores por varias razones, y puede usar la función `GetPartitionIndexes` para recuperar los detalles del error. Los posibles errores son:

- ENCRYPTED_PARTITITION_ERROR (ERROR DE PARTICICÓN CIFRADA): no se admite la creación de índices en una tabla con particiones cifradas.
- INVALID_PARTITITION_TYPE_DATA_ERROR (ERROR DE DATOS DE TIPO DE PARTICIÓN INVÁLIDOS): se observa cuando el valor `partitionKey` no es un valor válido para el tipo de datos `partitionKey` correspondiente. Por ejemplo: una `partitionKey` con el tipo de datos “int” tiene un valor “foo”.
- MISSING_PARTITITION_VALUE_ERROR (ERROR DE VALOR DE PARTICIÓN FALTANTE): se observa cuando el `partitionValue` para una `indexedKey` no está presente. Esto puede suceder cuando una tabla no se particiona de manera uniforme.
- UNSUPPORTED_PARTITITION_CARACTER_ERROR (ERROR DE CARÁCTER DE PARTICIÓN NO SOPORTADO): se observa cuando el valor de una clave de partición indexada contiene los caracteres \u0000, \u0001 o \u0002
- INTERNAL_ERROR (ERROR INTERNO): se produjo un error interno mientras se creaban los índices.

Descripción de índices de partición en una tabla

Para obtener los índices de partición creados en una tabla, utilice la operación `GetPartitionIndexes`. La respuesta enumera todos los índices de la tabla, junto con el estado actual de cada uno de ellos (el `IndexStatus`).

El `IndexStatus` para un índice de partición será uno de los siguientes:

- `CREATING`: el índice está en proceso de creación y aún no está disponible para usarlo.

- `ACTIVE`: ya se puede utilizar el índice. Las solicitudes pueden utilizar el índice para realizar una consulta optimizada.
- `DELETING`: el índice se está eliminando y ya no se puede utilizar. Un índice en el estado activo se puede eliminar mediante la solicitud `DeletePartitionIndex`, que mueve el estado de ACTIVE (ACTIVO) a DELETING (ELIMINACIÓN).
- `FAILED`: error en la creación del índice en una tabla existente. Cada tabla almacena los últimos 10 índices que presentaron errores.

Las transiciones de estado posibles para los índices creados en una tabla existente son:

- CREACIÓN → ACTIVO → ELIMINACIÓN
- CREACIÓN → ERROR

Limitaciones al uso de índices de partición

Una vez que haya creado un índice de partición, tenga en cuenta estos cambios en la funcionalidad de la tabla y la partición:

Creación de una nueva partición (después del agregado de índices)

Después de crear un índice de partición en una tabla, se validarán las comprobaciones de tipos de datos de claves indexadas de todas las particiones nuevas agregadas a la tabla. Se validará el formato de tipo de datos del valor de partición de las claves indexadas. Si se produce un error en la comprobación del tipo de datos, la operación de creación de partición fallará. Para la tabla sales_data (datos de venta), si se crea un índice para claves (categoría, año) donde la categoría es de tipo `string` y año del tipo `int`, la creación de la nueva partición con un valor de YEAR (AÑO) de “foo” presentará errores.

Una vez habilitados los índices, el agregado de particiones con valores clave indexados que tengan los caracteres U+0000, U+00001 y U+0002 comenzará a fallar.

Actualizaciones de tablas

Una vez creado un índice de partición en una tabla, no puede modificar los nombres de las claves de partición para las claves de partición existentes y no puede cambiar el tipo o el orden de las claves que están registradas con el índice.

Uso de índices para una llamada GetPartitions optimizada

Cuando llame `GetPartitions` en una tabla con un índice, puede incluir una expresión y, si corresponde, el Data Catalog utilizará un índice si es posible. La primera clave del índice debe ser transferida a la expresión para los índices que se van a utilizar en el filtrado. La optimización de índices en el filtrado se aplica en la medida de lo posible. El Data Catalog intenta utilizar la optimización del índice tanto como sea posible, pero en caso de que falte un índice o en caso de un operador no soportado, vuelve a la implementación existente de cargar todas las particiones.

Para la tabla sales_data (datos de venta) anterior, agregaremos el índice [Country (País), Category (Categoría), Year (Año)]. Si “País” no se transfiere en la expresión, el índice registrado no podrá filtrar particiones utilizando índices. Puede agregar hasta 3 índices para soportar varios patrones de consulta.

Tomemos algunas expresiones de ejemplo y veamos cómo funcionan los índices en ellas:

Expressions	Cómo se utilizará el índice
Country = 'US' (País = “EE.UU.”)	El índice se utilizará para filtrar particiones.
Country = 'US' (País = “EE.UU.”) y Category = 'Shoes' (Categoría = ”Zapatos”)	El índice se utilizará para filtrar particiones.
Category = 'Shoes' (Categoría = “Zapatos”)	Los índices no se utilizarán ya que no se proporciona “país” en la expresión. Todas las particiones se cargarán para devolver una respuesta.
Country = 'US' (País = “EE.UU.”) y Category = 'Shoes' (Categoría = ”Zapatos”) y Year > '2018' (Año > “2018”)	El índice se utilizará para filtrar particiones.
Country = 'US' (País = “EE.UU.”) y Category = 'Shoes' (Categoría = ”Zapatos”) y Year > '2018' (Año > “2018”) y month = 2 (mes = 2)	El índice se utilizará para buscar todas las particiones con país = “EE.UU.” y categoría = “zapatos” y año > 2018. A continuación, se realizará el filtrado en la expresión del mes.
País = “EE.UU.” Y Categoría = ”Zapatos” O Año > “2018”	Los índices no se usarán ya que se incluye un operador `OR` en la expresión.

Expressions	Cómo se utilizará el índice
País = “EE.UU.” Y Categoría = “Zapatos” Y (Año = 2017 O Año = “2018”)	El índice se utilizará para buscar todas las particiones con país = “EE.UU.” y categoría = “zapatos”, y luego se realizará el filtrado en la expresión del año.
País en (“EE.UU.”, “UK”) Y Categoría = “Zapatos”	Los índices no se usarán para filtrar ya que el operador `IN` no se soporta actualmente.
País = “EE.UU.”, Y Categoría en (“Zapatos”, “Libros”)	El índice se utilizará para buscar todas las particiones con país = “EE.UU.” y luego se realizará el filtrado en la expresión de la categoría.
País = ‘EE. UU.’ Y Categoría en (‘Zapatos’, ’Libros’) Y (Fecha de creación > ‘2023-9-01’	El índice se utilizará para buscar todas las particiones con País = ‘EE. UU.’ y Fecha de creación > ‘2023-9-01’ y luego se realizará el filtrado en la expresión de la Categoría.

Integración con motores

Redshift Spectrum, Amazon EMR y AWS Glue ETL Spark DataFrames pueden utilizar índices para obtener particiones después de que los índices estén en estado ACTIVE en AWS Glue. Athena y los AWS Glue marcos dinámicos de ETL requieren que siga pasos adicionales si desea utilizar índices para mejorar las consultas.

Habilitación del filtrado de particiones

Para habilitar el filtrado de particiones, se necesita actualizar las propiedades de la tabla tal como se muestra a continuación:

1. En la consola de AWS Glue, en la sección Catálogo de datos, seleccione Tablas.
2. Elija una tabla.
3. En Acciones, seleccione Editar tabla.
4. En Propiedades de la tabla, agregue lo siguiente:
   - Clave: `partition_filtering.enabled`

- Valor: `true`

5. Seleccione Aplicar.

Como alternativa, puede establecer este parámetro al ejecutar la consulta ALTER TABLE SET PROPERTIES (Alterar las propiedades establecidas de la tabla) en Athena.

```
ALTER TABLE partition_index.table_with_index
SET TBLPROPERTIES ('partition_filtering.enabled' = 'true')
```

Actualización de tablas del Catálogo de datos creadas de forma manual mediante rastreadores

Es posible que desee crear tablas de AWS Glue Data Catalog de forma manual y, a continuación, mantenerlas actualizadas con rastreadores de AWS Glue. Los rastreadores que se ejecutan en una programación pueden añadir nuevas particiones y actualizar las tablas con cualquier cambio de esquema. Esto también se aplica a tablas migradas desde un metaalmacén de Apache Hive.

Para ello, cuando defina un rastreador, en lugar de especificar un almacén de datos o más como origen de un rastreador, especifique una o más tablas existentes del Catálogo de datos. El rastreador rastrea los almacenes de datos especificados por las tablas del catálogo. En este caso, no se crean tablas nuevas. En su lugar, las tablas que usted crea de forma manual se actualizan.

A continuación se muestran otros motivos por los que podría desear crear tablas de catálogos de forma manual y especificar tablas de catálogos como la fuente del rastreador:

- Desea elegir el nombre de la tabla de catálogo y no confía en el algoritmo de denominación de tablas de catálogos.
- Desea evitar que se creen tablas nuevas en caso de que los archivos que tengan un formato que podría interrumpir la detección de particiones se guarden de forma errónea en la ruta de la fuente de datos.

Para obtener más información, consulte Paso 2: elegir orígenes de datos y clasificadores.

Propiedades de la tabla del catálogo de datos

Las propiedades o los parámetros de la tabla, tal como se les conoce en la AWS CLI, son cadenas de valores y claves no validadas. Puede establecer sus propias propiedades en la tabla para permitir

usos del catálogo de datos fuera de AWS Glue. Otros servicios que utilizan el Catálogo de datos también pueden hacerlo. AWS Glue establece algunas propiedades de la tabla al ejecutar trabajos o rastreadores. A menos que se describa lo contrario, estas propiedades son para uso interno, no se admite que sigan existiendo en su forma actual ni el comportamiento del producto si estas propiedades se cambian manualmente.

Para obtener más información sobre las propiedades de tabla establecidas por los rastreadores de AWS Glue, consulte the section called “Parámetros establecidos en las tablas del catálogo de datos por el rastreador”.

Integración con otros servicios de AWS

Si bien puede usar los Rastreador de AWS Glue para completar el AWS Glue Data Catalog, hay varios servicios de AWS que pueden integrarse con el catálogo y completarlo automáticamente. En las siguientes secciones se proporciona más información sobre los casos de uso específicos compatibles con los servicios de AWS que pueden completar el Catálogo de datos.

Temas

- AWS Lake Formation
- Amazon Athena

AWS Lake Formation

AWS Lake Formation es un servicio que facilita la configuración de un lago de datos seguro en AWS. Lake Formation se basa en AWS Glue, y ambos comparten el mismo AWS Glue Data Catalog. Puede registrar la ubicación de sus datos de Amazon S3 con Lake Formation y usar la consola de Lake Formation para crear bases de datos y tablas en el Catálogo de datos de AWS Glue, definir políticas de acceso a los datos y auditar el acceso a estos en todo su lago de datos desde un solo lugar. Puede utilizar el control de acceso detallado de Lake Formation para gestionar los recursos del Catálogo de datos existentes y las ubicaciones de datos de Amazon S3.

Si registra los datos con Lake Formation, puede compartir de forma segura los recursos del Catálogo de datos entre las entidades principales de IAM, cuentas de AWS, organizaciones de AWS y unidades organizativas.

Para obtener más información sobre cómo crear recursos en el Catálogo de datos con Lake Formation, consulte Creación de tablas y bases de datos del Catálogo de datos en la Guía para desarrolladores de AWS Lake Formation.

Amazon Athena

Amazon Athena usa el Catálogo de datos para almacenar y recuperar metadatos de tablas para los datos de Amazon S3 en su cuenta de AWS. Los metadatos de la tabla permiten al motor de consultas de Athena saber cómo buscar, leer y procesar los datos que desea consultar.

Para completar el AWS Glue Data Catalog, puede usar directamente las instrucciones de Athena para `CREATE TABLE`. Puede definir y completar manualmente los metadatos del esquema y la partición en el Catálogo de datos sin necesidad de ejecutar un rastreador.

1. En la consola de Athena, cree una base de datos que almacene los metadatos de la tabla en el Catálogo de datos.
2. Use la instrucción `CREATE EXTERNAL TABLE` para definir el esquema del origen de datos.
3. Use la cláusula `PARTITIONED BY` para definir las claves de partición si sus datos están particionados.
4. Use la cláusula `LOCATION` para especificar la ruta de Amazon S3 en la que se almacenan sus archivos de datos reales.
5. Ejecute la instrucción `CREATE TABLE`.

   Esta consulta crea los metadatos de la tabla en el Catálogo de datos en función del esquema y las particiones definidos sin rastrear realmente los datos.

Puede consultar la tabla en Athena, que utilizará los metadatos del Catálogo de datos para acceder a sus archivos de datos en Amazon S3 y consultarlos.

Para obtener más información, consulte Creación de bases de datos y tablas en la Guía del usuario de Amazon Athena.

Configuración del Catálogo de datos

La configuración del Catálogo de datos contiene opciones para establecer las opciones de encriptación y permisos para este en su cuenta.

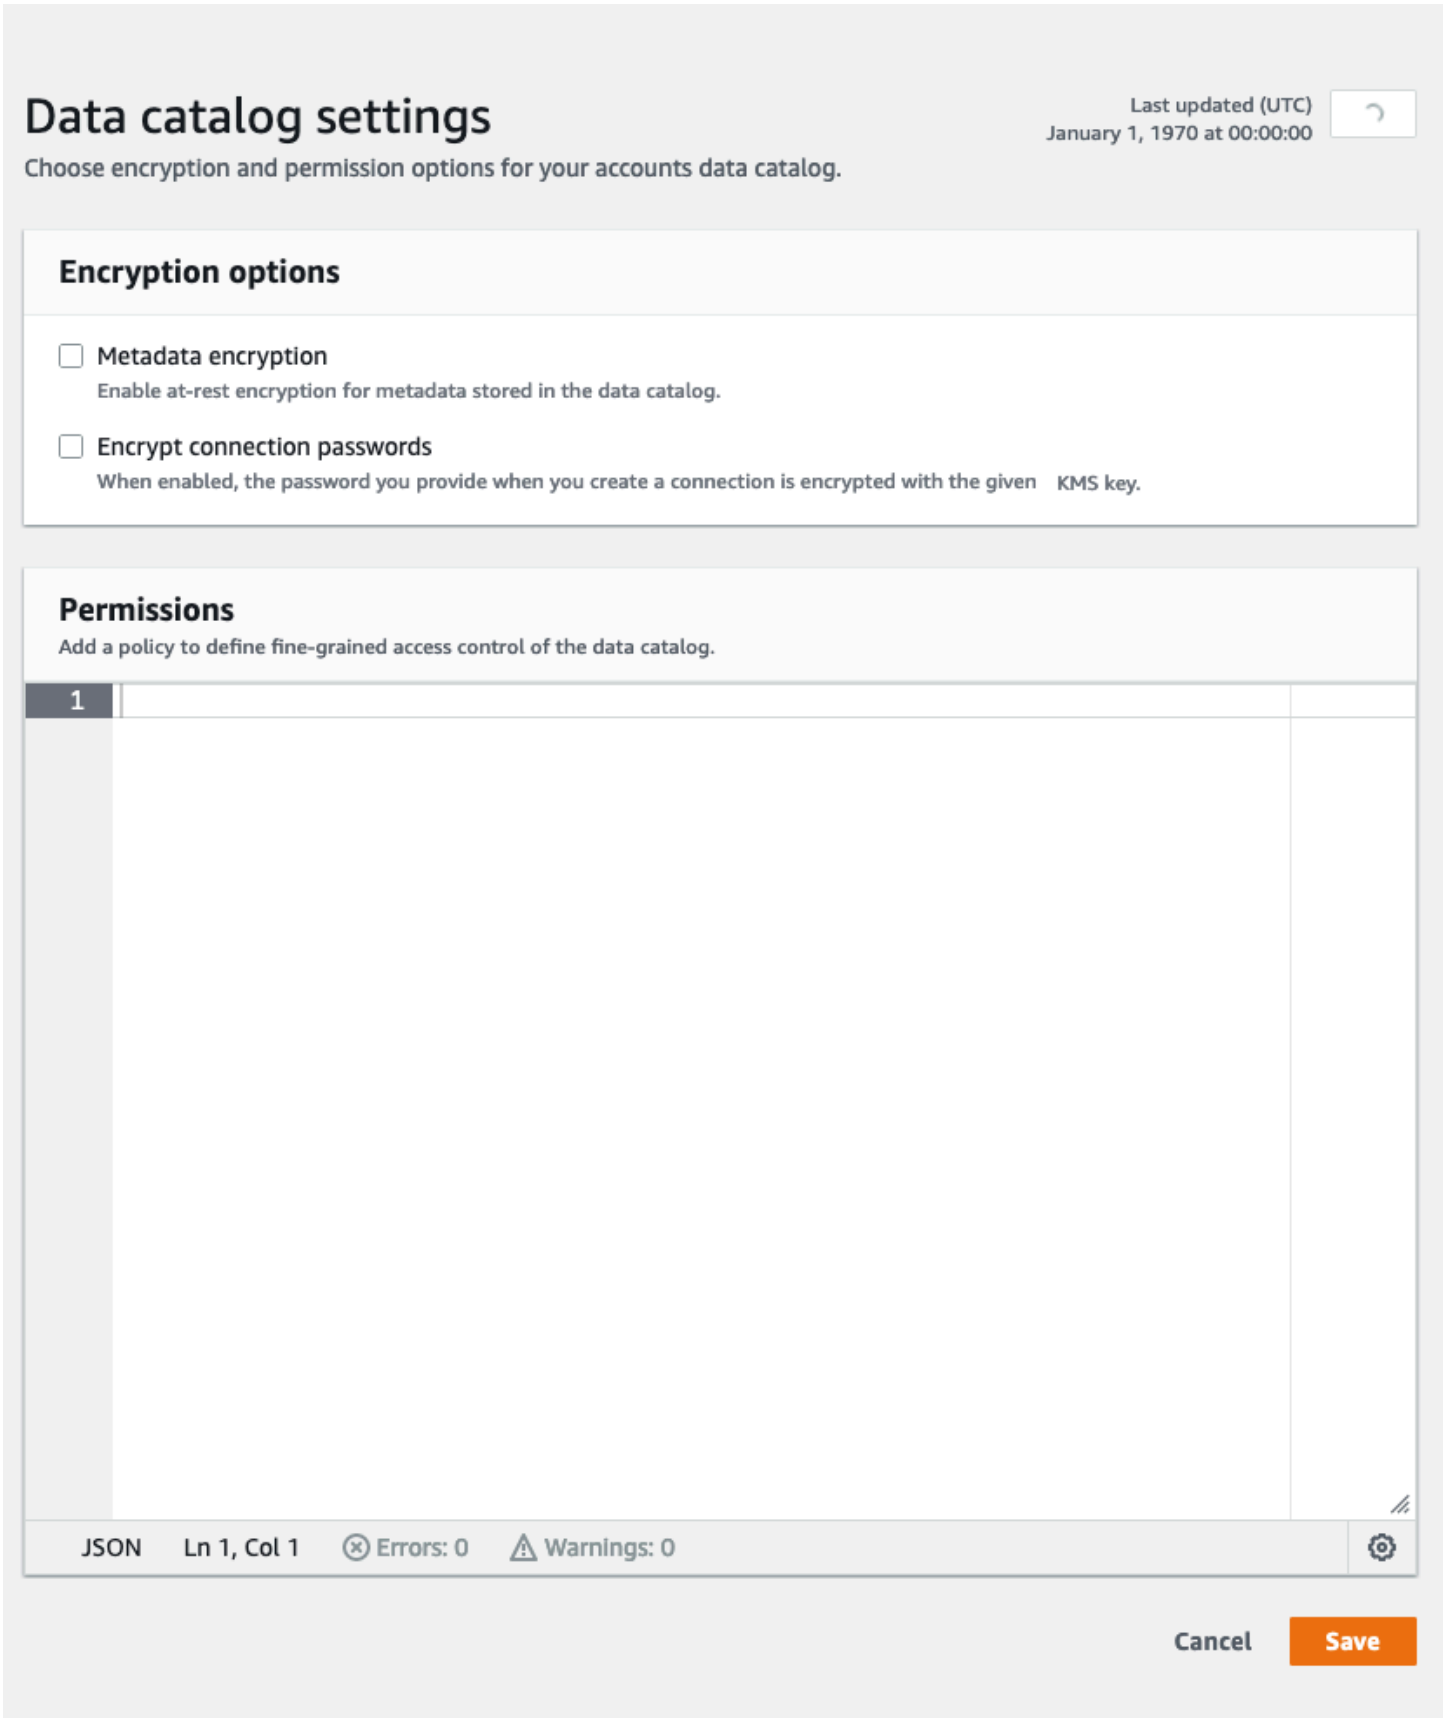
Data catalog settings
Choose encryption and permission options for your accounts data catalog.
Last updated (UTC)
January 1, 1970 at 00:00:00
Encryption options
Metadata encryption
Enable at-rest encryption for metadata stored in the data catalog.
Encrypt connection passwords
When enabled, the password you provide when you create a connection is encrypted with the given KMS key.
Permissions
Add a policy to define fine-grained access control of the data catalog.
1
JSON
Ln 1, Col 1
Errors: 0
Warnings: 0
Cancel
Save

Para cambiar el control de acceso detallado del Catálogo de datos

1. Inicie sesión en la Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. Elija una opción de cifrado.

   - Cifrado de metadatos: seleccione esta casilla para cifrar los metadatos en el Catálogo de datos. Los metadatos se cifrarán en reposo con la clave AWS Key Management Service (AWS KMS) que especifique. Para obtener más información, consulte Cifrado del Catálogo de datos.
   - Cifrado de contraseñas de conexión: active esta casilla para cifrar las contraseñas en el objeto de conexión de AWS Glue cuando se cree o se actualice la conexión. Las contraseñas se cifran utilizando la clave de AWS KMS que especifique. Cuando se devuelven las contraseñas, se cifran. Esta opción es una configuración global para todas las conexiones de AWS Glue en el Catálogo de datos. Si desactiva esta casilla, las contraseñas cifradas anteriormente permanecen cifradas utilizando la clave que se usó al crearlas o actualizarlas. Para obtener más información acerca de las conexiones de AWS Glue, consulte Conexión a datos.

     Al habilitar esta opción, elija una clave de AWS KMS o elija Enter a key ARN (Escribir un ARN de clave) y proporcione el nombre de recurso de Amazon (ARN) de la clave. Escriba el ARN con la forma `arn:aws:kms:region:account-id:key/key-id`. También puede proporcionar el ARN como un alias de clave, como `arn:aws:kms:region:account-id:alias/alias-name`.

     > **Important**
     >
     > Si se selecciona esta opción, cualquier usuario o rol que cree o actualice una conexión debe tener permiso de `kms:Encrypt` en la clave KMS especificada.

     Para obtener más información, consulte Cifrado de las contraseñas de conexión.
3. Elija Settings (Configuración), y luego en el editor de Permissions (Permisos), agregue la instrucción de política para cambiar el control de acceso detallado del Catálogo de datos para su cuenta. Solo se puede asociar una política al Catálogo de datos a la vez. Puede pegar una política de recursos JSON en este control. Para obtener más información, consulte Políticas basadas en recursos de AWS Glue.
4. Elija Save (Guardar) para actualizar el Catálogo de datos con los cambios que haya realizado.

También puede utilizar operaciones de la API de AWS Glue para colocar, obtener y eliminar políticas de recursos. Para obtener más información, consulte API de seguridad en AWS Glue.

Cómo completar y administrar las tablas transaccionales

Apache Iceberg, Apache Hudi y Linux Foundation Delta Lake son formatos de tablas de código abierto diseñados para gestionar cargas de trabajo de análisis de datos y lagos de datos a gran escala en Apache Spark.

Puede completar las tablas de Iceberg, Hudi y Delta Lake en el AWS Glue Data Catalog mediante los siguientes métodos:

- Rastreador de AWS Glue: Los Rastreador de AWS Glue pueden detectar y completar automáticamente los metadatos de las tablas de Iceberg, Hudi y Delta Lake en el Catálogo de datos. Para obtener más información, consulte Uso de rastreadores para completar el Catálogo de datos .
- Trabajos de ETL de AWS Glue: Puede crear trabajos de ETL para escribir datos en las tablas de Iceberg, Hudi y Delta Lake, y completar sus metadatos en el Catálogo de datos. Para obtener más información, consulte Uso de marcos de lagos de datos con trabajos de ETL de AWS Glue.
- Consola de AWS Glue, consola de AWS Lake Formation, AWS CLI o API: Puede usar la consola de AWS Glue, la consola de Lake Formation o API para crear y administrar las definiciones de las tablas de Iceberg en el Catálogo de datos.

Temas

- Creación de tablas de Apache Iceberg
- Optimización de las tablas de Iceberg
- Optimización del rendimiento de las consultas en tablas de Iceberg

Creación de tablas de Apache Iceberg

Puede crear tablas de Apache Iceberg que utilicen el formato de datos de Apache Parquet en el AWS Glue Data Catalog con datos que residan en Amazon S3. Una tabla en el Catálogo de datos es la definición de metadatos que representa los datos en un almacén de datos. AWS Glue crea tablas de Iceberg v2 de forma predeterminada. Para ver la diferencia entre las tablas v1 y v2, consulte Cambios de versión de formato en la documentación de Apache Iceberg.

Apache Iceberg es un formato de tabla abierto para conjuntos de datos analíticos muy grandes. Iceberg permite modificar fácilmente su esquema, o evolución del esquema, de manera que los usuarios pueden añadir, renombrar o eliminar columnas de una tabla de datos sin alterar los datos subyacentes. Iceberg también ofrece compatibilidad con el control de versiones de datos, que permite a los usuarios hacer un seguimiento de los cambios en los datos a lo largo del tiempo. Esto habilita la característica de viaje en el tiempo, con la que los usuarios pueden acceder a versiones históricas de los datos y consultarlas, así como analizar los cambios en los datos entre actualizaciones y eliminaciones.

Puede usar la consola de AWS Glue o de Lake Formation, o bien la operación `CreateTable` en la API de AWS Glue, para crear una tabla de Iceberg en el Catálogo de datos. Para obtener más información, consulte la acción CreateTable (Python: create_table).

Cuando cree una tabla de Iceberg en el Catálogo de datos, deberá especificar el formato de la tabla y la ruta del archivo de metadatos en Amazon S3 para poder hacer lecturas y escrituras.

Puede utilizar Lake Formation para asegurar su tabla de Iceberg utilizando permisos de control de acceso específicos cuando registre la ubicación de datos de Amazon S3 con AWS Lake Formation. Para los datos de origen en Amazon S3 y los metadatos que no están registrados en Lake Formation, el acceso se determina mediante las políticas de permisos de IAM para Amazon S3 y acciones de AWS Glue. Para obtener más información, consulte Administración de permisos.

> **Note**
>
> El Catálogo de datos no admite la creación de particiones ni la adición de propiedades de tablas de iceberg.

Requisitos previos

Para crear tablas de Iceberg en el Catálogo de datos y configurar los permisos de acceso a los datos de Lake Formation, debe cumplir los siguientes requisitos:

1. Se requieren permisos para crear tablas de Iceberg sin datos registrados en Lake Formation.

   Además de los permisos necesarios para crear una tabla en el Catálogo de datos, el creador de la tabla requiere los siguientes permisos:

   - `s3:PutObject` en el recurso arn:aws:s3:::{bucketName}
   - `s3:GetObject` en el recurso arn:aws:s3:::{bucketName}

- `s3:DeleteObject` en el recurso arn:aws:s3:::{bucketName}

2. Se requieren permisos para crear tablas de Iceberg con datos registrados en Lake Formation:

   Para utilizar Lake Formation para administrar y asegurar los datos de su lago de datos, registre su ubicación de Amazon S3 que tiene los datos de las tablas con Lake Formation. De este modo, Lake Formation puede expedir credenciales a servicios analíticos de AWS como Athena, Redshift Spectrum y Amazon EMR para acceder a los datos. Para obtener más información sobre el registro de una ubicación de Amazon S3, consulte Cómo añadir una ubicación de Amazon S3 a su lago de datos.

   Una entidad principal que lee y escribe los datos subyacentes que están registrados en Lake Formation requiere los siguientes permisos:

   - `lakeformation:GetDataAccess`
   - `DATA_LOCATION_ACCESS`

     Una entidad principal que tiene permisos de localización de datos en una localización también tiene permisos de localización en todas las ubicaciones secundarias.

     Para obtener más información sobre los permisos de ubicación de datos, consulte Control de acceso a los datos subyacentes.

Para habilitar la compactación, el servicio debe asumir un rol de IAM que tenga permisos para actualizar las tablas del Catálogo de datos. Para obtener más información, consulte Requisitos previos para la optimización de tablas

Creación de tablas de Iceberg

Puede crear tablas de Iceberg v1 y v2 con la consola de AWS Glue o de Lake Formation, o bien con la AWS Command Line Interface, tal como se documenta en esta página. También puede crear tablas de Iceberg con el Rastreador de AWS Glue. Para más información, consulte Catálogo de datos y rastreadores en la Guía para desarrolladores de AWS Glue.

Creación de una tabla de Iceberg

Console

1. Inicie sesión en la Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.

2. En Catálogo de datos, seleccione Tablas y utilice el botón Crear tabla para especificar los siguientes atributos:
   - Nombre de la tabla: Ingrese el nombre de la tabla. Si utiliza Athena para acceder a las tablas, utilice los consejos para nombres recogidos en la Guía del usuario de Amazon Athena.
   - Base de datos: Seleccione una base de datos existente o cree una nueva.
   - Descripción: Descripción de la tabla. Puede escribir una descripción para ayudarle a entender el contenido de la tabla.
   - Formato de la tabla: En Formato de la tabla, seleccione Apache Iceberg.
   - Activar la compactación: Seleccione Activar la compactación para compactar los objetos pequeños de Amazon S3 de la tabla de modo que formen objetos más grandes.
   - Rol de IAM: para ejecutar la compactación, el servicio asume un rol de IAM en su nombre. Puede elegir un rol de IAM mediante el menú desplegable. Asegúrese de que el rol tenga los permisos necesarios para habilitar la compactación.

     Para obtener más información sobre los permisos necesarios, consulte Requisitos previos para la optimización de tablas .
   - Ubicación: Especifique la ruta a la carpeta en Amazon S3 que almacena la tabla de metadatos. Iceberg necesita un archivo de metadatos y una ubicación en el Catálogo de datos para poder hacer lecturas y escrituras.
   - Esquema: Seleccione Agregar columnas para añadir columnas y los tipos de datos de las columnas. Tiene la opción de crear una tabla vacía y actualizar el esquema más adelante. El Catálogo de datos admite los tipos de datos de Hive. Para obtener más información, consulte Tipos de datos de Hive.

     Con Iceberg podrá desarrollar el esquema y la partición después de crear la tabla. Puede utilizar consultas de Athena para actualizar el esquema de la tabla y consultas de Spark para actualizar las particiones.

AWS CLI

```
aws glue create-table \
    --database-name iceberg-db \
    --region us-west-2 \
    --open-table-format-input '{
      "IcebergInput": {
```

```
          "MetadataOperation": "CREATE",
          "Version": "2"
       }
    }' \
--table-input '{"Name":"test-iceberg-input-demo",
          "TableType": "EXTERNAL_TABLE",
          "StorageDescriptor":{
             "Columns":[
                 {"Name":"col1", "Type":"int"},
                 {"Name":"col2", "Type":"int"},
                 {"Name":"col3", "Type":"string"}
              ],
             "Location":"s3://DOC_EXAMPLE_BUCKET_ICEBERG/"
          }
       }'
```

Optimización de las tablas de Iceberg

AWS Glue admite varias opciones de optimización de tablas que mejoran la administración y el rendimiento de las tablas de Apache Iceberg utilizadas por los motores analíticos de AWS y los trabajos de ETL. Estos optimizadores ofrecen un uso eficiente del almacenamiento, un rendimiento mejorado de las consultas y la administración efectiva de los datos. Existen tres tipos de optimizadores de tablas disponibles en AWS Glue:

- Compactación: la compactación de datos compacta archivos de datos pequeños para reducir el uso del almacenamiento y mejorar el rendimiento de lectura. Los archivos de datos se combinan y se reescriben para eliminar los datos obsoletos y consolidar los datos fragmentados en archivos más grandes y eficientes. Puede configurar la compactación para que se ejecute de forma automática.

  Binpack es la estrategia de compactación predeterminada que utiliza Apache Iceberg. Combina archivos de datos más pequeños en otros de mayor tamaño para mejorar el rendimiento. La compactación también admite las estrategias de ordenación y orden Z, que agrupan datos similares. La ordenación organiza los datos según columnas especificadas y mejora el rendimiento de las consultas en operaciones que aplican filtros. El orden Z crea conjuntos de datos ordenados que mejoran el rendimiento de las consultas cuando se consultan varias columnas al mismo tiempo. Las tres estrategias de compactación (binpack, ordenación y orden Z) reducen la cantidad

de datos que escanean los motores de consultas, lo que a su vez disminuye los costos de procesamiento de las consultas.

- Retención de instantáneas: las instantáneas son versiones con fecha y hora de una tabla de Iceberg. Las configuraciones de retención de instantáneas permiten a los clientes determinar cuánto tiempo se deben retener las instantáneas y cuántas instantáneas retener. La configuración de un optimizador de retención de instantáneas puede ayudar a administrar la sobrecarga de almacenamiento mediante la eliminación de las instantáneas antiguas e innecesarias y sus correspondientes archivos subyacentes.
- Eliminación de archivos huérfanos: los archivos huérfanos son archivos a los que los metadatos de la tabla de Iceberg ya no hacen referencia. Con el tiempo, estos archivos se pueden acumular, sobre todo después de operaciones como la eliminación de tablas o los errores en los trabajos de ETL. Habilitar la eliminación de archivos huérfanos permite a AWS Glue identificar y eliminar periódicamente estos archivos innecesarios y así liberar espacio de almacenamiento.

La configuración de la optimización a nivel de catálogo está disponible a través de la consola de Lake Formation y mediante el uso de la operación de la API `UpdateCatalog` de AWS Glue. Puede activar o desactivar la compactación, la retención de instantáneas y la eliminación de archivos huérfanos para tablas de Iceberg individuales en el Catálogo de datos mediante la consola de AWS Glue, la AWS CLI o las operaciones de la API de AWS Glue.

Temas

- Requisitos previos para la optimización de tablas
- Optimizadores de tablas a nivel de catálogo
- Optimización de la compactación
- Optimización de retención de instantáneas
- Eliminación de archivos huérfanos
- Visualización de los detalles de la optimización
- Visualización de métricas de Amazon CloudWatch
- Eliminar un optimizador
- Consideraciones y limitaciones
- Regiones compatibles con los optimizadores de tablas

Requisitos previos para la optimización de tablas

El optimizador de tablas asume los permisos del rol de AWS Identity and Access Management (IAM) que especifica al habilitar las opciones de optimización (compactación, retención de instantáneas y eliminación de archivos huérfanos) de una tabla. Puede crear un único rol para todos los optimizadores o crear roles separados para cada optimizador.

> **Note**
>
> El optimizador de eliminación de archivos huérfanos no requiere los permisos `glue:updateTable` o `s3:putObject`. Los optimizadores de compactación y caducidad de las instantáneas requieren el mismo conjunto de permisos.

El rol de IAM debe tener los permisos para leer los datos y actualizar los metadatos en el catálogo de datos. Cree un rol de IAM y adjunte las siguientes políticas integradas:

- Agregue la siguiente política insertada que conceda a Amazon S3 permisos de lectura y escritura en la ubicación para los datos en los que no estén registrados con AWS Lake Formation. Esta política también incluye permisos para actualizar la tabla en el catálogo de datos y permitir que AWS Glue agregue registros en los registros Amazon CloudWatch y publicar métricas. Para los datos de origen en Amazon S3 que no estén registrados en Lake Formation, el acceso se determina mediante las políticas de permisos de IAM para Amazon S3 y acciones de AWS Glue.

  En las siguientes políticas en línea, sustituya `bucket-name` por el nombre de su bucket de Amazon S3, `aws-account-id` y `region` por un número de cuenta y región del catálogo de datos de AWS válidos, `database_name` por el nombre de su base de datos y `table_name` por el nombre de la tabla.

  JSON

```
{
    "Version":"2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "s3:PutObject",
                "s3:GetObject",
                "s3:DeleteObject"
```

```
            ],
            "Resource": [
                "arn:aws:s3:::amzn-s3-demo-bucket/*"
            ]
        },
        {
            "Effect": "Allow",
            "Action": [
                "s3:ListBucket"
            ],
            "Resource": [
                "arn:aws:s3:::amzn-s3-demo-bucket"
            ]
        },
        {
            "Effect": "Allow",
            "Action": [
                "glue:UpdateTable",
                "glue:GetTable"
            ],
            "Resource": [
                "arn:aws:glue:us-east-1:111122223333:table/<database-
name>/<table-name>",
                "arn:aws:glue:us-east-1:111122223333:database/<database-name>",
                "arn:aws:glue:us-east-1:111122223333:catalog"
            ]
        },
        {
            "Effect": "Allow",
            "Action": [
                "logs:CreateLogGroup",
                "logs:CreateLogStream",
                "logs:PutLogEvents"
            ],
            "Resource": [
                "arn:aws:logs:us-east-1:111122223333:log-group:/aws-glue/
iceberg-compaction/logs:*",
                "arn:aws:logs:us-east-1:111122223333:log-group:/aws-glue/
iceberg-retention/logs:*",
                "arn:aws:logs:us-east-1:111122223333:log-group:/aws-glue/
iceberg-orphan-file-deletion/logs:*"
            ]
        }
    ]
```

```
}
```

- Utilice la siguiente política para habilitar la compactación de los datos registrados en Lake Formation.

  Si el rol de optimización no tiene permisos de grupo `IAM_ALLOWED_PRINCIPALS` otorgados en la tabla, el rol requiere los permisos de Lake Formation `ALTER`, `DESCRIBE`, `INSERT` y `DELETE` de la tabla.

  Para obtener más información sobre cómo registrar un bucket de Amazon S3 con Lake Formation, consulte Cómo añadir una ubicación de Amazon S3 a su lago de datos.

  JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "lakeformation:GetDataAccess"
      ],
      "Resource": "*"
    },
    {
      "Effect": "Allow",
      "Action": [
        "glue:UpdateTable",
        "glue:GetTable"
      ],
      "Resource": [
        "arn:aws:glue:us-east-1:111122223333:table/databaseName/tableName",
        "arn:aws:glue:us-east-1:111122223333:database/databaseName",
        "arn:aws:glue:us-east-1:111122223333:catalog"
      ]
    },
    {
      "Effect": "Allow",
      "Action": [
        "logs:CreateLogGroup",
        "logs:CreateLogStream",
        "logs:PutLogEvents"
      ],
```

```
      "Resource": [
        "arn:aws:logs:us-east-1:111122223333:log-group:/aws-glue/iceberg-
compaction/logs:*",
        "arn:aws:logs:us-east-1:111122223333:log-group:/aws-glue/iceberg-
retention/logs:*",
        "arn:aws:logs:us-east-1:111122223333:log-group:/aws-glue/iceberg-
orphan-file-deletion/logs:*"
      ]
    }
  ]
}
```

- (Opcional) Para optimizar tablas de Iceberg con datos de buckets de Amazon S3 cifrados mediante cifrado del servidor, el rol de compactación requiere permisos para descifrar los objetos de Amazon S3 y generar una nueva clave de datos para escribir los objetos en los buckets cifrados. Agregue la siguiente política a la clave de AWS KMS deseada. Solo admitimos el cifrado a nivel de bucket.

```
{
    "Effect": "Allow",
    "Principal": {
        "AWS": "arn:aws:iam::<aws-account-id>:role/<optimizer-role-name>"
    },
    "Action": [
        "kms:Decrypt",
        "kms:GenerateDataKey"
    ],
    "Resource": "*"
}
```

- (Opcional) Para la ubicación de datos registrada en Lake Formation, el rol utilizado para registrar la ubicación requiere permisos para descifrar los objetos de Amazon S3 y generar una nueva clave de datos para escribir los objetos en los buckets cifrados. Para obtener más información, consulte Registro de una ubicación de Amazon S3.
- (Opcional) Si la clave AWS KMS está almacenada en una cuenta AWS diferente, debe incluir los siguientes permisos para el rol de compactación.

  JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
```

```
    {
      "Effect": "Allow",
      "Action": [
        "kms:Decrypt",
        "kms:GenerateDataKey"
      ],
      "Resource": [
        "arn:aws:kms:us-east-1:111122223333:key/key-id"
      ]
    }
  ]
}
```

- El rol que utilice para ejecutar la compactación debe tener el permiso `iam:PassRole` correspondiente al rol.

  JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "iam:PassRole"
      ],
      "Resource": [
        "arn:aws:iam::111122223333:role/<optimizer-role-name>"
      ]
    }
  ]
}
```

- Agregue la siguiente política de confianza al rol para que el servicio AWS Glue asuma el rol de IAM para ejecutar el proceso de compactación.

  JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Sid": "",
      "Effect": "Allow",
```

```
      "Principal": {
        "Service": "glue.amazonaws.com"
      },
      "Action": "sts:AssumeRole"
    }
  ]
}
```

- (Opcional) Para actualizar la configuración del Catálogo de datos y así poder habilitar las optimizaciones a nivel de catálogo, el rol de IAM que se utiliza debe tener el permiso `glue:UpdateCatalog` o el permiso `ALTER CATALOG` de AWS Lake Formation en el catálogo raíz. Puede utilizar la API `GetCatalog` para verificar las propiedades del catálogo.

Optimizadores de tablas a nivel de catálogo

Con una configuración de catálogo única, puede configurar optimizadores automáticos como la compactación, la retención de instantáneas y la eliminación de archivos huérfanos para todas las tablas de Apache Iceberg nuevas y actualizadas en el AWS Glue Data Catalog. Las configuraciones de los optimizadores a nivel de catálogo le permiten aplicar la misma configuración de optimización en todas las tablas de un catálogo, lo que elimina la necesidad de configurar los optimizadores individualmente para cada tabla.

Para configurar los optimizadores de tablas, los administradores de lagos de datos pueden seleccionar el catálogo predeterminado en la consola de Lake Formation y habilitar los optimizadores mediante la opción `Table optimization`. Al crear tablas nuevas o actualizar las tablas existentes en el Catálogo de datos, el Catálogo de datos ejecuta automáticamente las optimizaciones de las tablas para reducir la carga operativa.

Si configuró la optimización a nivel de la tabla o si eliminó previamente la configuración de optimización de una tabla, esa configuración específica de cada tabla tendrá prioridad sobre la configuración predeterminada del catálogo para la optimización de tablas. Si un parámetro de configuración no está definido ni a nivel de tabla ni de catálogo, se aplicará el valor de la propiedad de la tabla de Iceberg. Esta configuración se aplica al optimizador de retención de instantáneas y eliminación de archivos huérfanos.

Cuando habilite los optimizadores a nivel del catálogo, tenga en cuenta lo siguiente:

- Si configura los ajustes de optimización cuando crea el catálogo y, posteriormente, deshabilita las optimizaciones mediante una solicitud de actualización del catálogo, la operación se extenderá en cascada a todas las tablas del catálogo.
- Si ya ha configurado optimizadores para una tabla determinada, la operación de deshabilitación a nivel de catálogo no afectará esta tabla.
- Si deshabilita los optimizadores a nivel de catálogo, las tablas con configuraciones de optimización existentes mantendrán sus ajustes específicos y no se verán afectadas por el cambio a nivel de catálogo. Sin embargo, las tablas que no tengan sus propias configuraciones de optimización heredarán el estado deshabilitado del nivel de catálogo.
- Como los optimizadores para la retención de instantáneas y la eliminación de archivos huérfanos pueden basarse en una programación, las actualizaciones introducirán un retraso al azar en el inicio de su programación. Esto hará que cada optimizador se inicie en momentos ligeramente diferentes, lo que distribuirá la carga y reducirá la probabilidad de superar los límites de servicio.

Temas

- Habilitación de la optimización automática de tablas a nivel de catálogo
- Visualización de optimizaciones a nivel de catálogo
- Cómo deshabilitar la optimización de tablas a nivel de catálogo

Habilitación de la optimización automática de tablas a nivel de catálogo

Puede habilitar la optimización automática de tablas para todas las tablas nuevas de Apache Iceberg en el Catálogo de datos. Tras crear la tabla, también puede actualizar de forma explícita y manual la configuración de la optimización de las tablas.

Para actualizar la configuración del Catálogo de datos y así poder habilitar las optimizaciones a nivel de catálogo, el rol de IAM que utiliza debe tener el permiso `glue:UpdateCatalog` en el catálogo raíz. Puede utilizar la API `GetCatalog` para verificar las propiedades del catálogo.

En el caso de las tablas gestionadas por Lake Formation, el rol de IAM seleccionado durante la configuración de la optimización del catálogo requiere los permisos `ALTER`, `DESCRIBE`, `INSERT`, y `DELETE` de Lake Formation para cualquier tabla nueva o actualizada.

Para habilitar los optimizadores a nivel de catálogo (consola)

1. Abra la consola de Lake Formation en https://console.aws.amazon.com/lakeformation/.

2. En el panel de navegación, seleccione Catálogo de datos.
3. Seleccione la pestaña Catálogos.
4. Elija el catálogo a nivel de la cuenta.
5. Seleccione Optimizaciones de tablas y Editar en la pestaña Optimizaciones de tablas. También puede seleccionar Editar optimizaciones en Acciones.

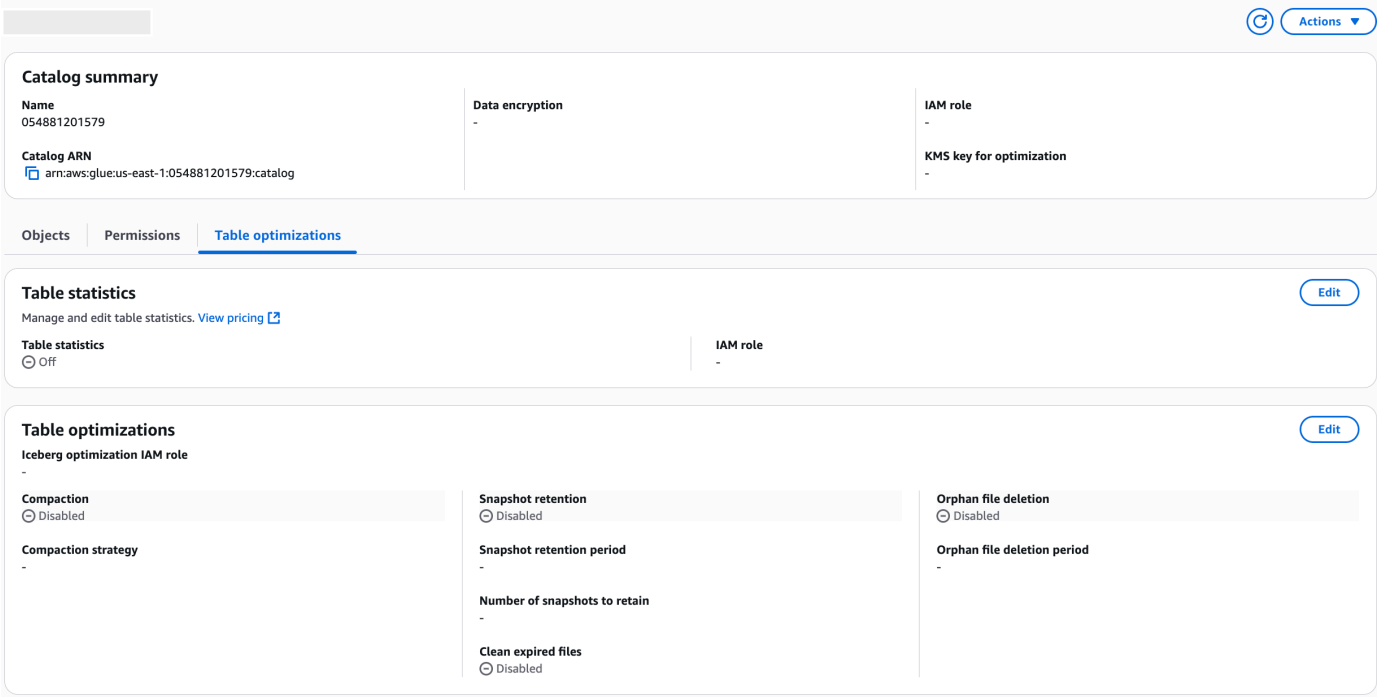

6. En la página Optimizaciones de tablas, configure las siguientes opciones:

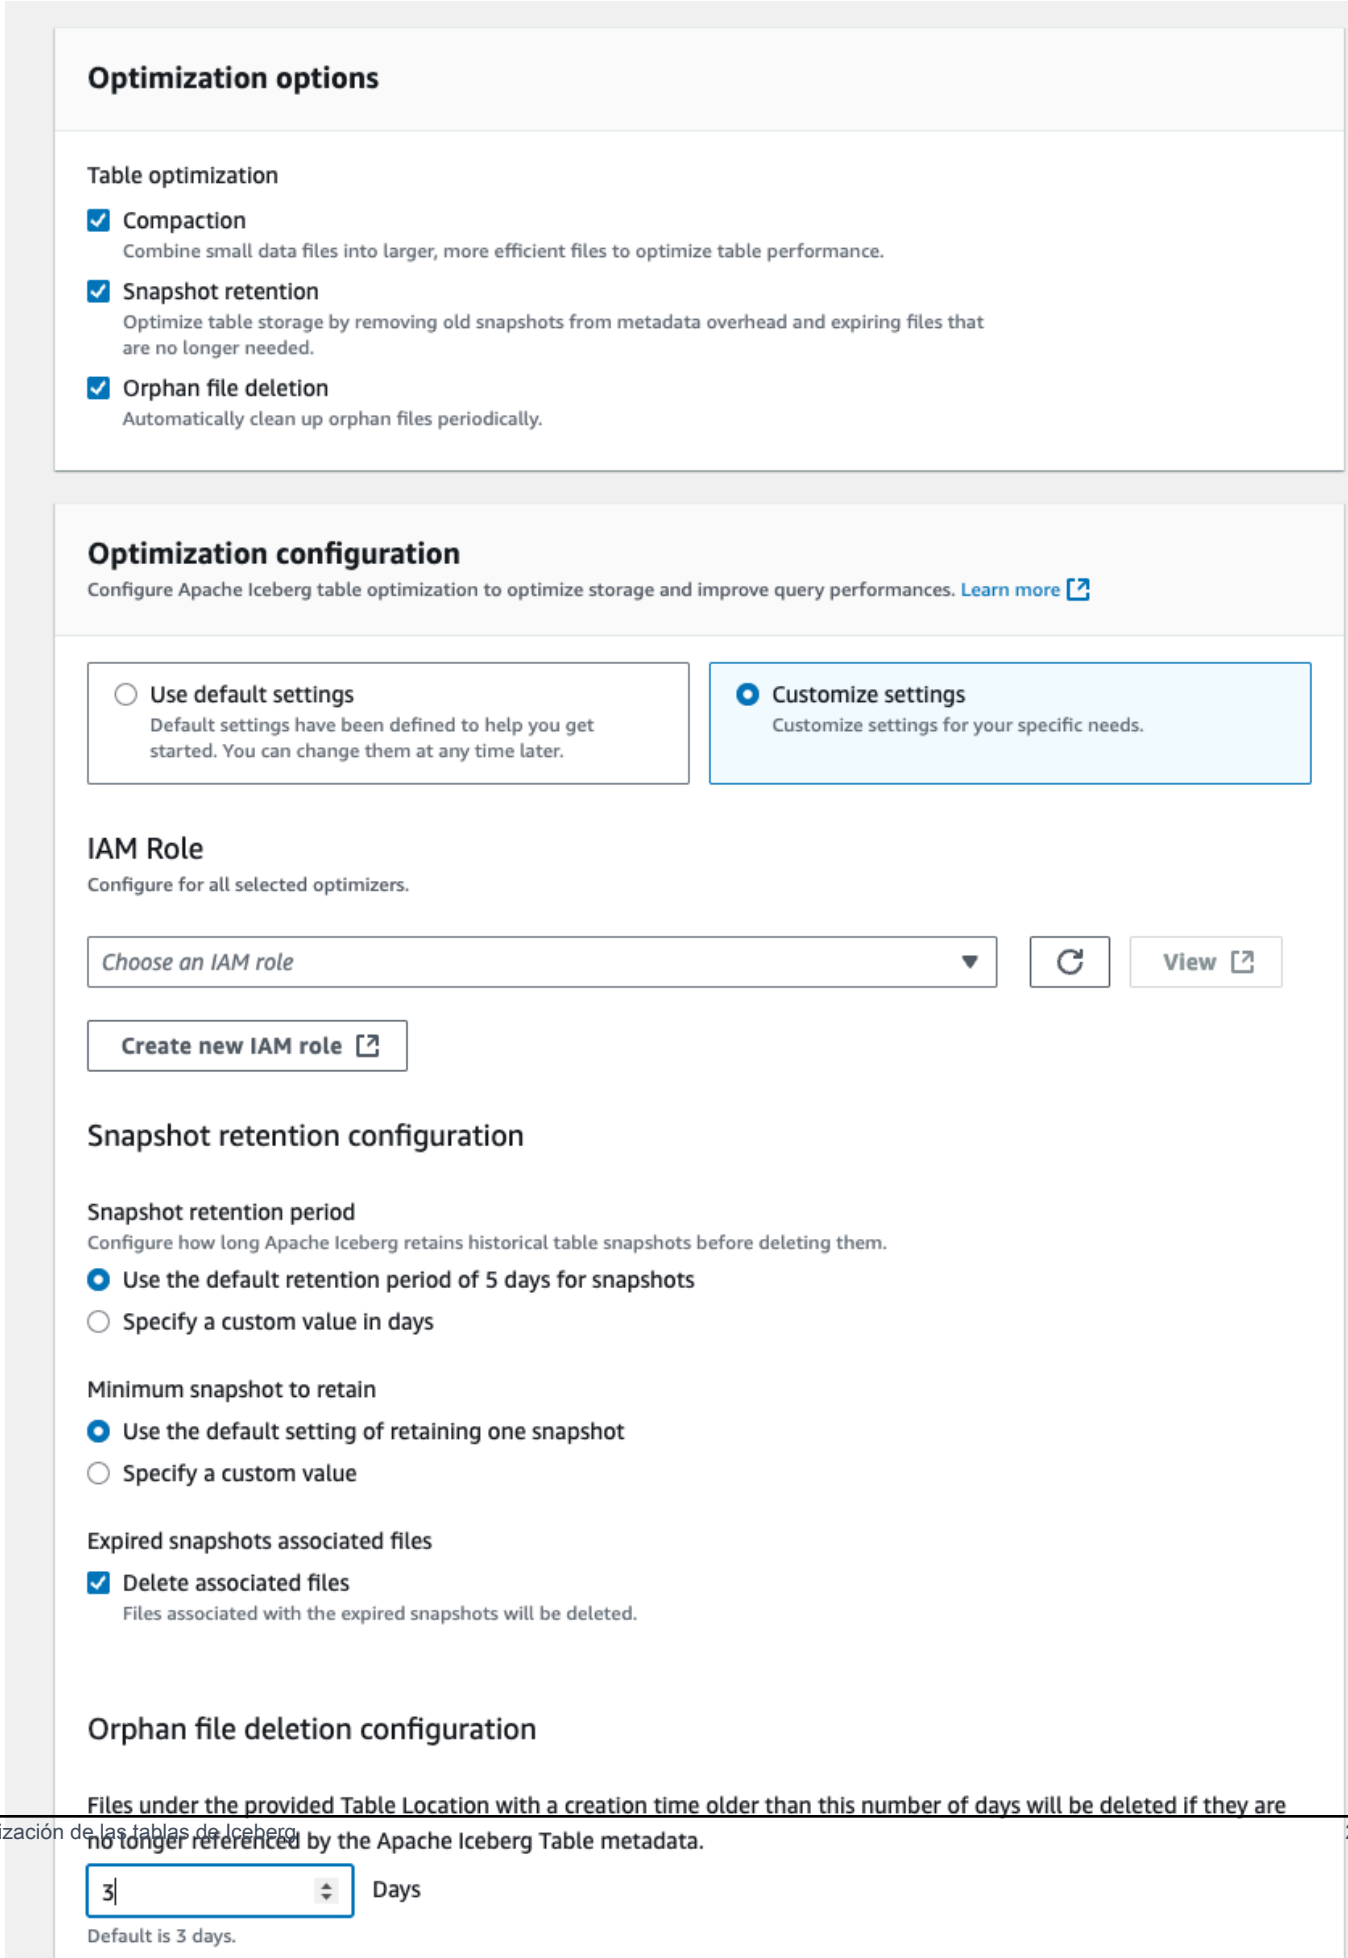
Optimization options
Table optimization
Compaction
Combine small data files into larger, more efficient files to optimize table performance.
Snapshot retention
Optimize table storage by removing old snapshots from metadata overhead and expiring files that are no longer needed.
Orphan file deletion
Automatically clean up orphan files periodically.
Optimization configuration
Configure Apache Iceberg table optimization to optimize storage and improve query performances. Learn more
Use default settings
Default settings have been defined to help you get started. You can change them at any time later.
Customize settings
Customize settings for your specific needs.
IAM Role
Configure for all selected optimizers.
Choose an IAM role
View
Create new IAM role
Snapshot retention configuration
Snapshot retention period
Configure how long Apache Iceberg retains historical table snapshots before deleting them.
Use the default retention period of 5 days for snapshots
Specify a custom value in days
Minimum snapshot to retain
Use the default setting of retaining one snapshot
Specify a custom value
Expired snapshots associated files
Delete associated files
Files associated with the expired snapshots will be deleted.
Orphan file deletion configuration
Files under the provided Table Location with a creation time older than this number of days will be deleted if they are no longer referenced by the Apache Iceberg Table metadata.
3
Days
Default is 3 days.

a. Configure los ajustes de Compactación:

- Habilite/deshabilite la compactación.
- Elija el rol de IAM que tenga los permisos necesarios para ejecutar los optimizadores.

  Para obtener más información sobre los permisos necesarios para el rol de IAM, consulte Requisitos previos para la optimización de tablas .

b. Configure los ajustes de Retención de instantáneas:

- Habilite/deshabilite la retención.
- Establezca el período de retención de instantáneas en días; el valor predeterminado es de 5 días.
- Establezca el número de instantáneas que se deben retener; el valor predeterminado es de 1 instantánea.
- Habilite/deshabilite la limpieza de archivos caducados.

c. Configure los ajustes de Eliminación de archivos huérfanos:

- Habilite/deshabilite la eliminación de archivos huérfanos.
- Establezca el período de retención de archivos huérfanos en días; el valor predeterminado es de 3 días.

7. Seleccione Save.

Cómo habilitar los optimizadores a nivel de catálogo mediante AWS CLI

Utilice el siguiente comando de la CLI para actualizar un catálogo existente con ajustes del optimizador:

Example Actualice el catálogo con la configuración del optimizador

```
aws glue update-catalog \
   --name catalog-id \
  --catalog-input \
  '{
    "CatalogId": "111122223333",
    "CatalogInput": {
        "CatalogProperties": {
            "CustomProperties": {
                "ColumnStatistics.Enabled": "false",
```

```
                "ColumnStatistics.RoleArn": "arn:aws:iam::111122223333:role/service-
role/stats-role-name"
            },
            "IcebergOptimizationProperties": {
                "RoleArn": "arn:aws:iam::111122223333:role/optimizer-role-name",
                "Compaction": {
                    "enabled": "true"
                },
                "Retention": {
                    "enabled": "true",
                    "snapshotRetentionPeriodInDays": "10",
                    "numberOfSnapshotsToRetain": "5",
                    "cleanExpiredFiles": "true"
                },
                "OrphanFileDeletion": {
                    "enabled": "true",
                    "orphanFileRetentionPeriodInDays": "3"
                }
            }
        }
    }
}'
```

Si tiene problemas con los optimizadores a nivel de catálogo, verifique lo siguiente:

- Asegúrese de que el rol de IAM tenga los permisos correctos, tal como se describe en la sección Requisitos previos.
- Revise los registros de CloudWatch para ver si hay algún mensaje de error relacionado con las operaciones del optimizador.

  Para obtener más información, consulte Ver métricas disponibles en la Guía del usuario de Amazon CloudWatch.
- Compruebe que la configuración del catálogo se haya aplicado correctamente; para ello, verifique la configuración del catálogo.
- En el caso de errores de acceso a las tablas, consulte los registros de CloudWatch y las notificaciones de EventBridge para obtener información detallada sobre los errores.

Visualización de optimizaciones a nivel de catálogo

Cuando se habilita la optimización de tablas a nivel de catálogo, cada vez que se crea o actualiza una tabla de Apache Iceberg mediante las API `CreateTable` o `UpdateTable` a través de la Consola de administración de AWS, un SDK o la Rastreador de AWS Glue, se crea una configuración a nivel de tabla equivalente para esa tabla.

Después de crear o actualizar una tabla, puede verificar los detalles de esta para confirmar la optimización de tablas. `Table optimization` muestra el conjunto de propiedades `Configuration source` como `Catalog`.

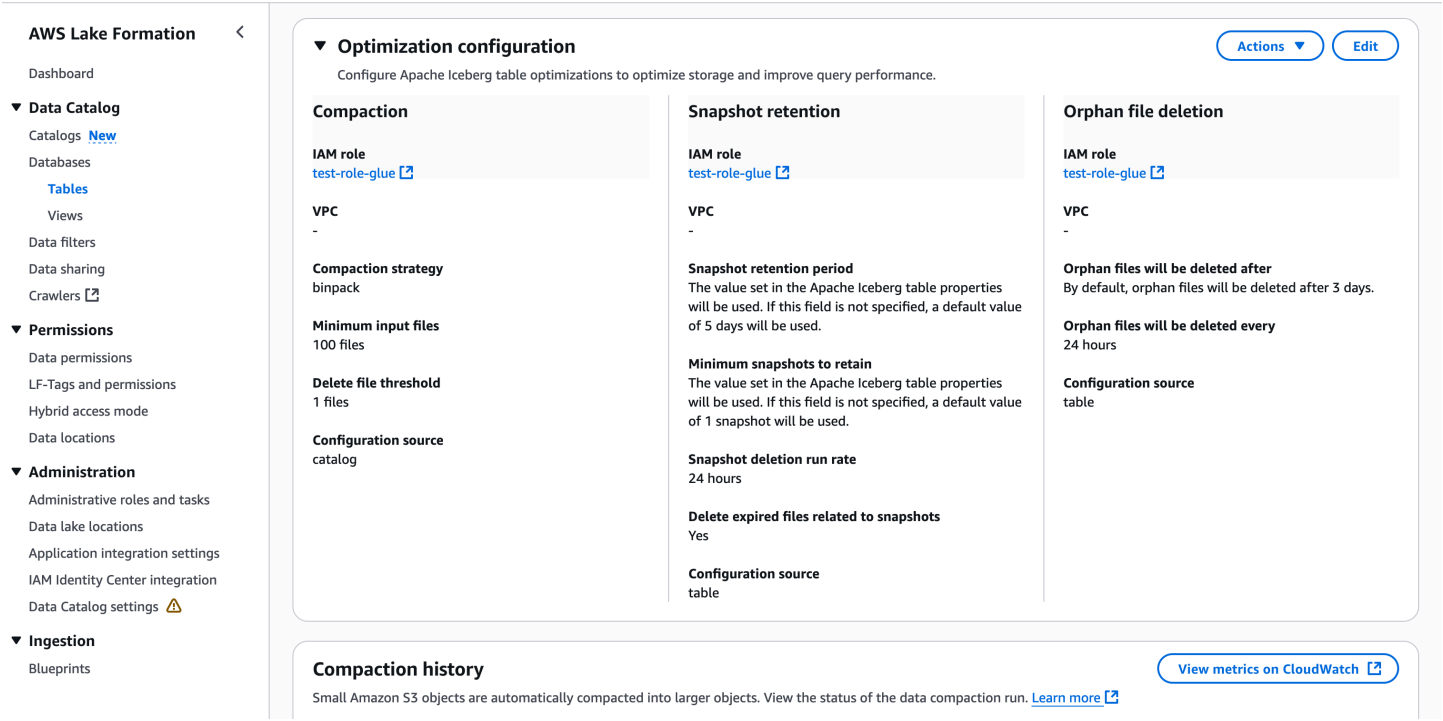

Cómo deshabilitar la optimización de tablas a nivel de catálogo

Puede deshabilitar la optimización de tablas para tablas nuevas mediante la consola de AWS Lake Formation, la API `glue:UpdateCatalog`.

Para deshabilitar las optimizaciones de las tablas a nivel de catálogo

1. Abra la consola de Lake Formation en https://console.aws.amazon.com/lakeformation/.
2. En la barra de navegación izquierda, elija Claves.
3. En la página Resumen del catálogo, seleccione Editar en Optimizaciones de tablas.
4. En la página Editar optimización, anule la selección de Opciones de optimización.

5. Seleccione Save.

Optimización de la compactación

Los lagos de datos de Amazon S3 que utilizan formatos de tablas abiertos, como Apache Iceberg, almacenan los datos como objetos de S3. Tener miles de objetos pequeños de Amazon S3 en una tabla de lago de datos aumenta la sobrecarga de metadatos y afecta al rendimiento de lectura. AWS Glue Data Catalog proporciona una compactación administrada para tablas de Iceberg, que compacta objetos pequeños en otros más grandes para lograr un mejor rendimiento de lectura mediante servicios de análisis de AWS como Amazon Athena y Amazon EMR, así como trabajos de ETL de AWS Glue. El Catálogo de datos efectúa la compactación sin interferir en las consultas simultáneas y solo admite la compactación en tablas con formato Parquet.

El optimizador de tablas supervisa continuamente las particiones de las tablas e inicia el proceso de compactación cuando se supera el límite de cantidad y tamaño de los archivos.

En el catálogo de datos, el proceso de compactación comienza cuando una tabla o cualquiera de sus particiones tiene más de 100 archivos. Cada archivo debe tener un tamaño inferior al 75 % del tamaño del archivo de destino. El tamaño del archivo de destino se define mediante la propiedad de tabla `write.target-file-size-bytes`, que por defecto es de 512 MB si no se establece explícitamente.

Para conocer las limitaciones, consulte Formatos compatibles y limitaciones de la compactación de datos administrada .

Temas

- Activación del optimizador de compactación
- Desactivación del optimizador de compactación

Activación del optimizador de compactación

Puede usar la consola de AWS Glue, la AWS CLI o la API de AWS para activar la compactación de sus tablas de Apache Iceberg en el Catálogo de datos de AWS Glue. Para las tablas nuevas, puede elegir Apache Iceberg como formato de tabla y habilitar la compactación al crear la tabla. La compactación está deshabilitada de forma predeterminada para las tablas nuevas.

Console

Habilitación de la compactación

1. Abra la consola de AWS Glue en https://console.aws.amazon.com/glue/ e inicie sesión como administrador del lago de datos, creador de la tabla o usuario al que se le hayan concedido los permisos `glue:UpdateTable` y `lakeformation:GetDataAccess` de la tabla.
2. En el panel de navegación, en Catálogo de datos, elija Tablas.
3. En la página Tablas, elija una tabla en formato de tabla abierta para la que desee activar la compactación y, a continuación, en el menú Acciones, elija Optimización y, por último, Activar.

   Para activar la compactación, también puede seleccionar la pestaña Optimización de la tabla en la página Detalles de la tabla. Seleccione la pestaña Optimización de tablas en la sección inferior de la página y elija Habilitar la compactación.

   La opción Activar optimización también está disponible al crear una nueva tabla de Iceberg en el Catálogo de datos.
4. En la página Activar optimización, seleccione Compactación en Opciones de optimización.

Optimization configuration

Configure Apache Iceberg table optimization to optimize storage and improve query performances. Learn more

- Use default settings
  Default settings have been defined to help you get started. You can change them at any time later.
- Customize settings
  Customize settings for your specific needs.

IAM Role

Configure for all selected optimizers.

- [x] Apply the selected IAM role to all selected optimizers. Update individual roles later as needed.
  Create a single role with necessary permissions to configure all table optimizers. Learn more

IAM role

Choose an IAM role | View

Create new IAM role

Virtual private cloud (VPC) - *optional*

Choose a network connection to access a data store in your VPC.

Choose a Glue connection | Create Glue network connection

Compaction configuration

Compaction strategy

Choose a compaction strategy Learn more

- Binpack
  Combines small files into larger files, typically targeting sizes over 100MB, while applying any pending deletes. This is the default and recommended compaction strategy for most use cases.
- Sort
  Organizes data based on specified columns which are sorted hierarchically during compaction, improving query performance for filtered operations. This strategy is recommended when your queries frequently filter on specific columns. To use this strategy, you must first define a sort order in your Iceberg table properties using the 'sort_order' table property.
- Z-Order
  Optimizes data organization by blending multiple attributes into a single scalar value that can be used for sorting, allowing efficient querying across multiple dimensions. This strategy is recommended when you need to query data across multiple dimensions simultaneously. To use this strategy, you must first define a sort order in your Apache Iceberg table properties using the 'sort_order' table property.

Minimum input files

Minimum number of data-files to be present in a partition before compaction will actually compact files.

100 files

Default is 100 files.

Delete file threshold

Minimum number of deletes in a data-file to be eligible for compaction.

1 deletes

Default is 1 delete.

5. A continuación, seleccione un rol de IAM en el menú desplegable con los permisos que se muestran en la sección Requisitos previos para la optimización de tablas .

   También puede elegir la opción Crear un nuevo rol de IAM para crear un rol personalizado con los permisos necesarios para ejecutar la compactación.

   Siga los pasos que se indican a continuación para actualizar un rol de IAM existente:

   a. Para actualizar la política de permisos del rol de IAM, en la consola de IAM, vaya al rol de IAM que se está utilizando para ejecutar la compactación.

   b. En la sección Agregar permisos, seleccione Crear política. En la ventana del navegador que se acaba de abrir, cree una nueva política para utilizarla con su rol.

   c. En la página Crear política, elija la pestaña `JSON`. Copie el código JSON que se muestra en la sección Requisitos previos en el campo del editor de políticas.

6. Si tiene configuraciones de políticas de seguridad en las que el optimizador de tablas de Iceberg necesita acceder a los buckets de Amazon S3 desde una nube privada virtual (VPC) específica, cree una conexión de red de AWS Glue o utilice una existente.

   Si aún no tiene configurada una conexión de VPC de AWS Glue, cree una nueva según los pasos de la sección Creating connections for connectors mediante la consola de AWS Glue, la AWS CLI o los SDK.

7. Elija una estrategia de compactación. Las opciones disponibles son:

   - Binpack: Binpack es la estrategia de compactación predeterminada en Apache Iceberg. Combina archivos de datos más pequeños en otros de mayor tamaño para mejorar el rendimiento.
   - Ordenar: ordenar en Apache Iceberg es una técnica de organización de datos que agrupa en clústeres la información dentro de los archivos según columnas específicas, lo que mejora significativamente el rendimiento de las consultas al reducir la cantidad de archivos que se deben procesar. El orden de clasificación en los metadatos de Iceberg se establece mediante el campo de ordenación. Cuando se definen varias columnas, los datos se organizan según la secuencia en que estas aparecen, lo que permite almacenar juntos los registros con valores similares dentro de los archivos. La estrategia de compactación por ordenación lleva la optimización un paso más allá, ya que ordena los datos en todos los archivos dentro de una misma partición.
   - Orden Z: el orden Z es una técnica de organización de datos útil cuando se requiere ordenarlos según varias columnas con igual importancia. A diferencia de la ordenación tradicional, que da prioridad a una columna sobre las demás, el orden Z asigna una

ponderación equilibrada a cada columna, lo que permite al motor de consultas reducir la cantidad de archivos que debe leer al buscar datos.

La técnica funciona al entrelazar los dígitos binarios de los valores de distintas columnas. Por ejemplo, si tiene los números 3 y 4 de dos columnas, el orden Z primero los convierte a binario (3 se convierte en 011 y 4 en 100) y luego entrelaza estos dígitos para generar un nuevo valor: 011010. Este entrelazado genera un patrón que mantiene los datos relacionados físicamente próximos entre sí.

El orden Z resulta especialmente eficaz para consultas multidimensionales. Por ejemplo, una tabla de clientes ordenada en Z por ingresos, Estado y código postal puede ofrecer un rendimiento superior al de una ordenación jerárquica al ejecutar consultas en múltiples dimensiones. Esta organización permite que las consultas orientadas a combinaciones específicas de ingresos y ubicación geográfica localicen los datos relevantes con rapidez y, al mismo tiempo, reduzcan al mínimo los escaneos innecesarios de archivos.

8. Archivos de entrada mínimos: el número de archivos de datos necesarios en una partición para que se active la compactación.
9. Límite de eliminación de archivos: la cantidad mínima de operaciones de eliminación que debe contener un archivo de datos para que sea elegible para la compactación.
10. Seleccione Habilitar la optimización.

AWS CLI

En el ejemplo siguiente se muestra cómo habilitar la compactación. Sustituya el ID de cuenta por un ID de cuenta de AWS válido. Sustituya el nombre de la base de datos y el nombre de la tabla por el nombre real de la tabla de Iceberg y el nombre de la base de datos. Sustituya el `roleArn` por el nombre de recurso de AWS (ARN) del rol de IAM y el nombre del rol de IAM que tiene los permisos necesarios para ejecutar la compactación. Puede reemplazar la estrategia de compactación de `sort` con otras estrategias compatibles, como `z-order` o `binpack`.

"orden" según sus requisitos.

```
aws glue create-table-optimizer \
  --catalog-id 123456789012 \
  --database-name iceberg_db \
  --table-name iceberg_table \
  --table-optimizer-configuration '{
    "roleArn": "arn:aws:iam::123456789012:role/optimizer_role",
```

```
    "enabled": true,
    "vpcConfiguration": {"glueConnectionName": "glue_connection_name"},
    "compactionConfiguration": {
      "icebergConfiguration": {"strategy": "sort"}
    }
  }'\
--type compaction
```

AWS API

Llame a la operación CreateTableOptimizer para habilitar la compactación de una tabla.

Después de activar la compactación, la pestaña Optimización de la tabla muestra los siguientes detalles de compactación una vez finalizada la ejecución:

Hora de inicio

Hora a la que se inició el proceso de compactación en el Catálogo de datos. El valor es una marca en la hora UTC.

Hora de finalización

Hora a la que terminó el proceso de compactación en el Catálogo de datos. El valor es una marca en la hora UTC.

Estado

Estado del ciclo de compactación. Los valores indican éxito o fracaso.

Archivos compactados

Número de archivos compactados.

Bytes compactados

Número de bytes compactados.

Desactivación del optimizador de compactación

Puede deshabilitar la compactación automática de una tabla Apache Iceberg concreta mediante la consola AWS Glue o AWS CLI.

Console

1. Inicie sesión en la Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. En el panel de navegación izquierdo, en Catálogo de datos, elija Tablas.
3. En la lista de tablas, elija la tabla de Iceberg en la que quiera deshabilitar la compactación.
4. Seleccione la pestaña Optimización de la tabla en la sección inferior de la página Detalles de tablas.
5. En Acciones, seleccione Desactivar y, a continuación, seleccione Compactación.
6. Selecciona Desactivar la compactación en el mensaje de confirmación. Puede volver a habilitar la compactación más adelante.

   Tras la confirmación, la compactación se desactiva y el estado de compactación de la tabla vuelve a ser el siguiente `Disabled`.

AWS CLI

En el siguiente ejemplo, reemplace el ID de cuenta con un ID de AWS válido. Sustituya el nombre de la base de datos y el nombre de la tabla por el nombre real de la tabla de Iceberg y el nombre de la base de datos. Sustituya el `roleArn` por el nombre de recurso de AWS (ARN) del rol de IAM y el nombre real del rol de IAM que tiene los permisos necesarios para ejecutar la compactación.

```
aws glue update-table-optimizer \
  --catalog-id 123456789012 \
  --database-name iceberg_db \
  --table-name iceberg_table \
  --table-optimizer-configuration
 '{"roleArn":"arn:aws:iam::123456789012:role/optimizer_role", "enabled":'false',
 "vpcConfiguration":{"glueConnectionName":"glue_connection_name"}}'\
  --type compaction
```

AWS API

Llame a la operación UpdateTableOptimizer para deshabilitar la compactación de una tabla específica.

Optimización de retención de instantáneas

La característica de retención de instantáneas de Apache Iceberg permite a los usuarios consultar datos históricos en momentos específicos y revertir las modificaciones no deseadas en sus tablas. En el Catálogo de datos de AWS Glue, la configuración de retención de instantáneas controla cuánto tiempo se conservan estas instantáneas (versiones de los datos de la tabla) antes de que caduquen y se eliminen. Esto ayuda a administrar los costos de almacenamiento y la sobrecarga de metadatos al eliminar automáticamente las instantáneas antiguas en función de un periodo de retención configurado o del número máximo de instantáneas que se deben conservar.

Puede configurar el periodo de retención en días y el número máximo de instantáneas que se deben retener para una tabla. AWS Glue elimina las instantáneas anteriores al periodo de retención especificado de los metadatos de la tabla y, al mismo tiempo, mantiene las instantáneas más recientes dentro del límite configurado. Tras eliminar las instantáneas antiguas de los metadatos, AWS Glue elimina los archivos de datos y metadatos correspondientes a los que ya no se hace referencia y que son exclusivos de las instantáneas caducadas. Esto permite realizar consultas en el tiempo solo hasta las instantáneas restantes que se han conservado y, al mismo tiempo, recuperar el espacio de almacenamiento utilizado por los datos de las instantáneas caducadas.

Temas

- Habilitación del optimizador de retención de instantáneas
- Actualización del optimizador de retención de instantáneas
- Deshabilitación del optimizador de retención de instantáneas

Habilitación del optimizador de retención de instantáneas

Puede usar la consola de AWS Glue, la AWS CLI o la API de AWS para habilitar los optimizadores de retención de instantáneas de las tablas Apache Iceberg en el Catálogo de datos. Para las tablas nuevas, puede elegir Apache Iceberg como formato de tabla y habilitar el optimizador de retención de instantáneas al crear la tabla. La retención de instantáneas está deshabilitada de forma predeterminada para las tablas nuevas.

Console

Habilitación del optimizador de retención de instantáneas

1. Abra la consola de AWS Glue en https://console.aws.amazon.com/glue/ e inicie sesión como administrador del lago de datos, creador de la tabla o usuario al que se le hayan concedido los permisos `glue:UpdateTable` y `lakeformation:GetDataAccess` de la tabla.
2. En el panel de navegación, en Catálogo de datos, elija Tablas.
3. En la página Tablas, elija una tabla de Iceberg para la que desee habilitar el optimizador de retención de instantáneas y, a continuación, en el menú Acciones, seleccione Habilitar en Optimización.

   Para habilitar la optimización, también puede seleccionar la tabla y abrir la página Detalles de la tabla. Seleccione la pestaña Optimización de tablas en la sección inferior de la página y elija Habilitar la retención de instantáneas.
4. En la página Habilitar la optimización, en Configuración de optimización, tiene dos opciones: Usar la configuración predeterminada o Personalizar la configuración. Si elige usar la configuración predeterminada, AWS Glue utiliza las propiedades definidas en la configuración de la tabla de Iceberg para determinar el periodo de retención de las instantáneas y el número de instantáneas que se deben retener. En ausencia de esta configuración, AWS Glue retiene una instantánea durante cinco días y elimina los archivos asociados a las instantáneas caducadas.
5. A continuación, elija un rol de IAM que AWS Glue pueda asumir en su nombre para ejecutar el optimizador. Para obtener más información sobre los permisos necesarios para el rol de IAM, consulte la sección Requisitos previos para la optimización de tablas .

   Siga los pasos que se indican a continuación para actualizar un rol de IAM existente:

   a. Para actualizar la política de permisos del rol de IAM, en la consola de IAM, vaya al rol de IAM que se está utilizando para ejecutar la compactación.

   b. En la sección Agregar permisos, seleccione Crear política. En la ventana del navegador que se acaba de abrir, cree una nueva política para utilizarla con su rol.

   c. En la página Crear política, elija la pestaña JSON. Copie el código JSON que se muestra en la sección Requisitos previos en el campo del editor de políticas.
6. Si prefiere establecer los valores de Configuración de retención de instantáneas de forma manual, elija Personalizar la configuración.

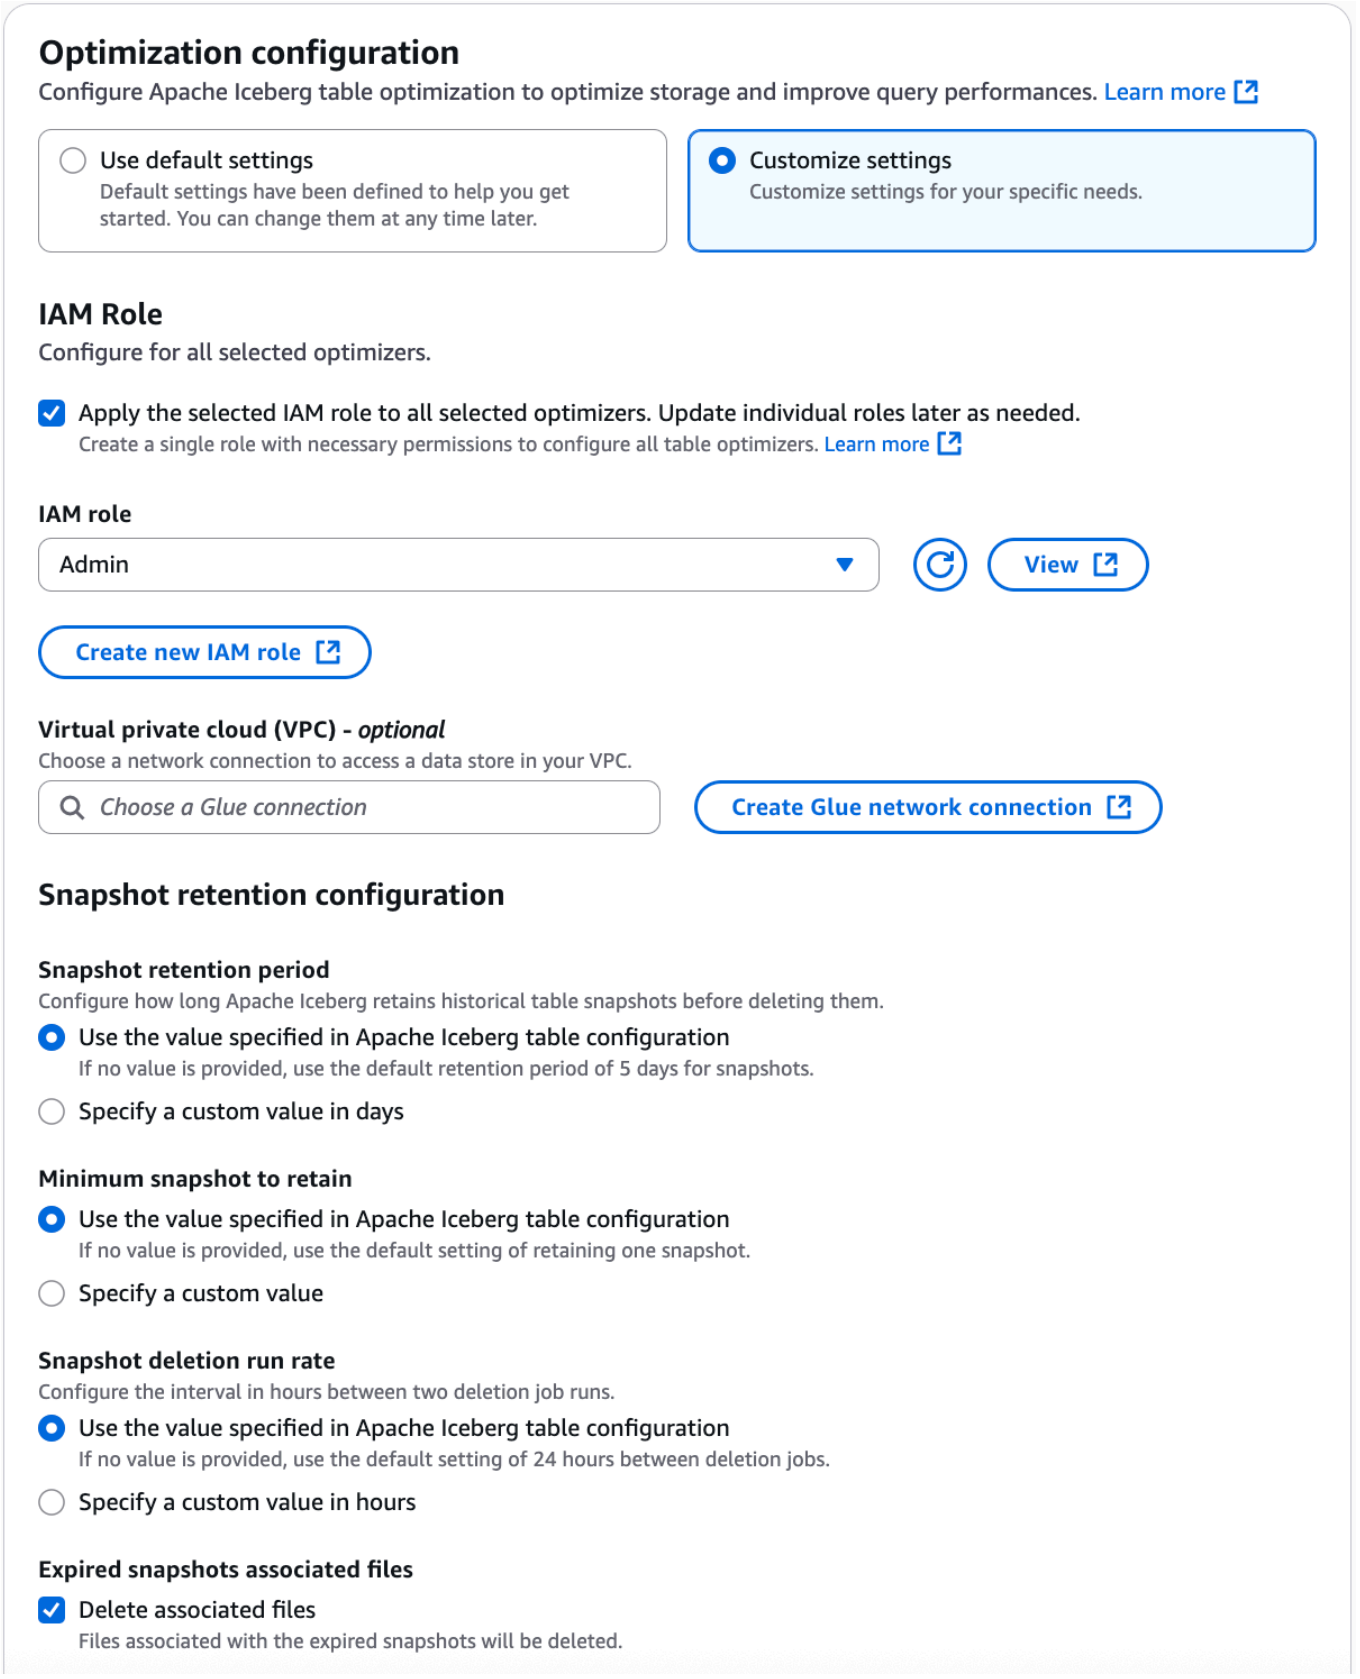
Optimization configuration
Configure Apache Iceberg table optimization to optimize storage and improve query performances. Learn more
Use default settings
Default settings have been defined to help you get started. You can change them at any time later.
Customize settings
Customize settings for your specific needs.
IAM Role
Configure for all selected optimizers.
Apply the selected IAM role to all selected optimizers. Update individual roles later as needed.
Create a single role with necessary permissions to configure all table optimizers. Learn more
IAM role
Admin
View
Create new IAM role
Virtual private cloud (VPC) - optional
Choose a network connection to access a data store in your VPC.
Choose a Glue connection
Create Glue network connection
Snapshot retention configuration
Snapshot retention period
Configure how long Apache Iceberg retains historical table snapshots before deleting them.
Use the value specified in Apache Iceberg table configuration
If no value is provided, use the default retention period of 5 days for snapshots.
Specify a custom value in days
Minimum snapshot to retain
Use the value specified in Apache Iceberg table configuration
If no value is provided, use the default setting of retaining one snapshot.
Specify a custom value
Snapshot deletion run rate
Configure the interval in hours between two deletion job runs.
Use the value specified in Apache Iceberg table configuration
If no value is provided, use the default setting of 24 hours between deletion jobs.
Specify a custom value in hours
Expired snapshots associated files
Delete associated files
Files associated with the expired snapshots will be deleted.

7. Seleccione la casilla Aplicar el rol de IAM seleccionado a los optimizadores seleccionados para usar un solo rol de IAM para todos los optimizadores activados.
8. Si tiene configuraciones de políticas de seguridad en las que el optimizador de tablas de Iceberg necesita acceder a los buckets de Amazon S3 desde una nube privada virtual (VPC) específica, cree una conexión de red de AWS Glue o utilice una existente.

   Si aún no tiene configurada una conexión de VPC de AWS Glue, cree una nueva según los pasos de la sección Creating connections for connectors mediante la consola de AWS Glue, la AWS CLI o los SDK.
9. A continuación, en Configuración de retención de instantáneas, elija usar los valores especificados en Configuración de la tabla de Iceberg o especifique valores personalizados para el período de retención de las instantáneas (history.expire.max-snapshot-age-ms), el número mínimo de instantáneas que se deben retener (history.expire.min-snapshots-to-keep) y el tiempo en horas entre cada ejecución del trabajo de eliminación de instantáneas.
10. Seleccione Eliminar los archivos asociados para eliminar los archivos subyacentes cuando el optimizador de tablas elimine las instantáneas antiguas de los metadatos de la tabla.

    Si no selecciona esta opción, cuando las instantáneas antiguas se eliminen de los metadatos de la tabla, sus archivos asociados permanecerán en el almacenamiento como archivos huérfanos.
11. A continuación, lea la declaración de precaución y seleccione Acepto para continuar.

    > **Note**
    >
    > En el Catálogo de datos, el optimizador de retención de instantáneas respeta el ciclo de vida controlado por las políticas de retención de nivel de ramificación y etiqueta. Para obtener más información, consulte la sección Branching and tagging de la documentación de Iceberg.
12. Revise la configuración y elija Habilitar la optimización.

    Espere unos minutos a que el optimizador de retención se ejecute y caduque las instantáneas antiguas según la configuración.

AWS CLI

Para habilitar la retención de instantáneas en las tablas nuevas Iceberg en AWS Glue, debe crear un optimizador de tablas de tipo `retention` y establecer el campo `enabled` en `true` en `table-optimizer-configuration`. Para ello, puede usar el comando de la AWS CLI `create-table-optimizer` o `update-table-optimizer`. Además, debe especificar los campos de configuración de la retención como `snapshotRetentionPeriodInDays` y `numberOfSnapshotsToRetain` en función de sus requisitos.

En el siguiente ejemplo se muestra cómo habilitar el optimizador de retención de instantáneas. Sustituya el ID de cuenta por un ID de cuenta de AWS válido. Sustituya el nombre de la base de datos y el nombre de la tabla por el nombre real de la tabla de Iceberg y el nombre de la base de datos. Sustituya `roleArn` por el nombre de recurso de AWS (ARN) del rol de IAM y el nombre del rol de IAM que tiene los permisos necesarios para ejecutar el optimizador de retención de instantáneas.

```
aws glue create-table-optimizer \
  --catalog-id 123456789012 \
  --database-name iceberg_db \
  --table-name iceberg_table \
  --table-optimizer-configuration
 '{"roleArn":"arn:aws:iam::123456789012:role/optimizer_role","enabled":'true',
 "vpcConfiguration":{
"glueConnectionName":"glue_connection_name"}, "retentionConfiguration":
{"icebergConfiguration":
{"snapshotRetentionPeriodInDays":7,"numberOfSnapshotsToRetain":3,"cleanExpiredFiles":'true'}
  --type retention
```

Este comando crea un optimizador de retención para la tabla de Iceberg especificada en el catálogo, la base de datos y la región indicados. table-optimizer-configuration especifica el ARN del rol de IAM que se va a utilizar, habilita el optimizador y establece la configuración de retención. En este ejemplo, retiene las instantáneas durante 7 días, conserva un mínimo de 3 instantáneas y limpia los archivos caducados.

- snapshotRetentionPeriodInDays: número de días que se deben retener las instantáneas antes de provocar que caduquen. El valor predeterminado es 5.
- numberOfSnapshotsToRetain: número mínimo de instantáneas que se deben retener, incluso si son anteriores al periodo de retención. El valor predeterminado es 1.

- cleanExpiredFiles: valor booleano que indica si se deben eliminar los archivos de datos caducados después de que las instantáneas hayan caducado. El valor predeterminado es `true`.

  Si se establece en verdadero, las instantáneas más antiguas se eliminan de los metadatos de la tabla, así como sus archivos subyacentes. Si este parámetro se establece en falso, las instantáneas más antiguas se eliminan de los metadatos de la tabla, pero sus archivos subyacentes permanecen en el almacenamiento como archivos huérfanos.

AWS API

Llame a la operación CreateTableOptimizer para habilitar el optimizador de retención de captura de pantalla de una tabla.

Después de activar la compactación, la pestaña de Optimización de la tabla muestra los siguientes detalles de compactación (después de aproximadamente 15 a 20 minutos):

Hora de inicio

Hora a la que se inició el optimizador de retención de instantáneas. El valor es una marca en la hora UTC.

Tiempo de ejecución

La hora muestra el tiempo que tarda el optimizador en completar la tarea. El valor es una marca en la hora UTC.

Estado

Estado de la ejecución del optimizador. Los valores indican éxito o fracaso.

Archivos de datos eliminados

Número total de archivos eliminados.

Archivos de manifiesto eliminados

Número total de archivos de manifiesto eliminados.

Listas de manifiesto eliminadas

Número total de listas de manifiesto eliminadas.

Actualización del optimizador de retención de instantáneas

Puede actualizar la configuración existente de un optimizador de retención de instantáneas para una tabla de Apache Iceberg concreta mediante la consola de AWS Glue, la AWS CLI o la API UpdateTableOptimizer.

Console

Actualización de la configuración de retención de instantáneas

1. Inicie sesión en la Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. Elija la Base de datos y las Tablas. En la lista de tablas, elija la tabla de Iceberg en la que quiera actualizar la configuración del optimizador de retención de instantáneas.
3. En la sección inferior de la página Detalles de las tablas, seleccione la pestaña Optimización de la tabla y, a continuación, elija Editar. También puede seleccionar Editar en Optimización en el menú Acciones ubicado en la esquina superior derecha de la página.
4. En la página Editar optimización, realice los cambios que desee.
5. Seleccione Save.

AWS CLI

Puede usar el siguiente comando para la actualización del optimizador de retención de instantáneas mediante la AWS CLI:

```
aws glue update-table-optimizer \
 --catalog-id 123456789012 \
 --database-name iceberg_db \
 --table-name iceberg_table \
 --table-optimizer-configuration
 '{"roleArn":"arn:aws:iam::123456789012:role/optimizer_role"","enabled":'true',
 "vpcConfiguration":
{"glueConnectionName":"glue_connection_name"},"retentionConfiguration":
{"icebergConfiguration":
{"snapshotRetentionPeriodInDays":7,"numberOfSnapshotsToRetain":3,"cleanExpiredFiles":'true'}
 \
 --type retention
```

Este comando actualiza la configuración de retención para la tabla especificada en el catálogo, la base de datos y la región indicados. Los parámetros clave son:

- snapshotRetentionPeriodInDays: número de días que se deben retener las instantáneas antes de provocar que caduquen. El valor predeterminado es `1`.
- numberOfSnapshotsToRetain: número mínimo de instantáneas que se deben retener, incluso si son anteriores al periodo de retención. El valor predeterminado es `5`.
- cleanExpiredFiles: valor booleano que indica si se deben eliminar los archivos de datos caducados después de que las instantáneas hayan caducado. El valor predeterminado es `true`.

  Si se establece en verdadero, las instantáneas más antiguas se eliminan de los metadatos de la tabla, así como sus archivos subyacentes. Si este parámetro se establece en falso, las instantáneas más antiguas se eliminan de los metadatos de la tabla, pero sus archivos subyacentes permanecen en el almacenamiento como archivos huérfanos.

API

Para actualizar un optimizador de tablas, puede usar la API `UpdateTableOptimizer`. Esta API le permite actualizar la configuración de un optimizador de tablas existente para compactar, retener o eliminar archivos huérfanos. Los parámetros de la solicitud incluyen:

- catalogId (obligatorio): ID del catálogo que contiene la tabla.
- databaseName (opcional): nombre de la base de datos que contiene la tabla.
- tableName (opcional): nombre de la tabla.
- type (obligatorio): tipo de optimizador de tablas (compaction, retention o orphan_file_deletion).
- retentionConfiguration (obligatorio): configuración actualizada del optimizador de tablas, que incluye el ARN del rol, el estado habilitado, la configuración de retención y la configuración de eliminación de archivos huérfanos.

Deshabilitación del optimizador de retención de instantáneas

Puede deshabilitar el optimizador de retención de instantáneas de una tabla Apache Iceberg concreta mediante la consola de AWS Glue o la AWS CLI.

Console

Deshabilitación de la retención de instantáneas

1. Inicie sesión en la Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. Elija la Base de datos y las Tablas. En la lista de tablas, elija la tabla de Iceberg en la que quiera deshabilitar el optimizador de retención de instantáneas.
3. En la sección inferior de la página Detalles de la tabla, seleccione Optimización de la tabla y Desactivar, Retención de instantáneas en Acciones.

   También puede seleccionar Desactivar en Optimización en el menú Acciones ubicado en la esquina superior derecha de la página.
4. Seleccione Deshabilitar en el mensaje de confirmación. Puede volver a habilitar el optimizador de retención de instantáneas en otro momento.

   Tras la confirmación, el optimizador de retención de instantáneas se deshabilita y el estado de retención de instantáneas vuelve a ser `Not enabled`.

AWS CLI

En el siguiente ejemplo, reemplace el ID de cuenta con un ID de AWS válido. Sustituya el nombre de la base de datos y el nombre de la tabla por el nombre real de la tabla de Iceberg y el nombre de la base de datos. Sustituya `roleArn` por el nombre de recurso de AWS (ARN) del rol de IAM y el nombre real del rol de IAM que tiene los permisos necesarios para ejecutar el optimizador de retención.

```
aws glue update-table-optimizer \
  --catalog-id 123456789012 \
  --database-name iceberg_db \
  --table-name iceberg_table \
  --table-optimizer-configuration
 '{"roleArn":"arn:aws:iam::123456789012:role/optimizer_role", "vpcConfiguration":
{"glueConnectionName":"glue_connection_name"}, "enabled":'false'}'\
  --type retention
```

AWS API

Llame a la operación UpdateTableOptimizer para deshabilitar el optimizador de retención de instantáneas de una tabla específica.

Eliminación de archivos huérfanos

AWS Glue Data Catalog le permite eliminar archivos huérfanos de sus tablas de Iceberg. Los archivos huérfanos son archivos sin referencias que existen en su origen de datos de Amazon S3 en la ubicación de la tabla especificada, que no están registrados en los metadatos de la tabla de Iceberg y que son más antiguos que el límite de edad que usted configuró. Con el tiempo, estos archivos huérfanos pueden acumularse debido a errores en operaciones como la compactación, la eliminación de particiones o la reescritura de tablas, y ocupan espacio de almacenamiento innecesario.

El optimizador de eliminación de archivos huérfanos de AWS Glue analiza los metadatos de la tabla y los archivos de datos reales, identifica los archivos huérfanos y los elimina para recuperar espacio de almacenamiento. El optimizador solo elimina los archivos creados después de la fecha de creación del optimizador que también cumplen los criterios de eliminación configurados. Los archivos creados antes de la fecha de creación del optimizador, o en la misma fecha, nunca se eliminan.

Lógica de la eliminación de archivos huérfanos

1. Verificación de la fecha: compara la fecha de creación del archivo con la fecha de creación del optimizador. Si la fecha de creación del archivo es anterior o igual a la fecha de creación del optimizador, se omite.
2. Verificación de la configuración del optimizador: si el archivo es más reciente que la fecha de creación del optimizador, lo compara con el límite de edad configurado. El optimizador elimina el archivo si coincide con los criterios de eliminación. Si no cumple los criterios, lo omite.

Para iniciar la eliminación de archivos huérfanos, cree un optimizador de tablas de eliminación de archivos huérfanos en el Catálogo de datos.

> **Important**
>
> De forma predeterminada, la eliminación de archivos huérfanos evalúa cada archivo en la ubicación de la tabla AWS Glue. Si bien puede configurar un subprefijo para limitar el alcance de la evaluación mediante el uso de un parámetro de API, asegúrese de que la ubicación de

la tabla no contenga archivos de otros orígenes de datos o tablas. Si la ubicación de la tabla se superpone con otros orígenes de datos, es probable que el servicio identifique y elimine archivos que no estén relacionados como si fueran huérfanos.

Temas

- Habilitación de la eliminación de archivos huérfanos
- Actualización del optimizador de eliminación de archivos huérfanos
- Deshabilitación de la eliminación de archivos huérfanos

Habilitación de la eliminación de archivos huérfanos

Puede usar la consola de AWS Glue, la AWS CLI o la API de AWS para habilitar la eliminación de archivos huérfanos de las tablas Apache Iceberg en el Catálogo de datos. Para las tablas nuevas, puede elegir Apache Iceberg como formato de tabla y habilitar el optimizador de eliminación de archivos huérfanos al crear la tabla. La retención de instantáneas está deshabilitada de forma predeterminada para las tablas nuevas.

Console

Para habilitar la eliminación de archivos huérfanos

1. Abra la consola de AWS Glue en https://console.aws.amazon.com/glue/ e inicie sesión como administrador del lago de datos, creador de la tabla o usuario al que se le hayan concedido los permisos `glue:UpdateTable` y `lakeformation:GetDataAccess` de la tabla.
2. En el panel de navegación, en Catálogo de datos, elija Tablas.
3. En la página Tablas, elija una tabla de Iceberg en la que quiera habilitar la eliminación de archivos huérfanos.

   Seleccione la pestaña Optimización de la tabla en la sección inferior de la página y seleccione Activar, Eliminación de archivos huérfanos en Acciones.

   También puede seleccionar Activar en Optimización en el menú Acciones ubicado en la esquina superior derecha de la página.
4. En la página Habilitar la optimización, seleccione Eliminación de archivos huérfanos en Opciones de optimización.

5. Si elige usar Configuración predeterminada, todos los archivos huérfanos se eliminarán después de 3 días. Si desea conservar los archivos huérfanos durante un número específico de días, seleccione Personalizar configuración.
6. A continuación, elija un rol de IAM con los permisos necesarios para eliminar archivos huérfanos.
7. Si tiene configuraciones de políticas de seguridad en las que el optimizador de tablas de Iceberg necesita acceder a los buckets de Amazon S3 desde una nube privada virtual (VPC) específica, cree una conexión de red de AWS Glue o utilice una existente.

   Si aún no tiene configurada una conexión de VPC de AWS Glue, cree una nueva según los pasos de la sección Creating connections for connectors mediante la consola de AWS Glue, la AWS CLI o los SDK.
8. Si elige Personalizar configuración, ingrese el número de días que se van a retener los archivos antes de eliminarlos en Configuración de eliminación de archivos huérfanos. También puede especificar el intervalo entre dos ejecuciones consecutivas del optimizador. El valor de predeterminado es 24 horas.
9. Seleccione Habilitar la optimización.

AWS CLI

Para habilitar la eliminación de archivos huérfanos en una tabla de Iceberg de AWS Glue, debe crear un optimizador de tablas de tipo `orphan_file_deletion` y establecer el campo `enabled` en verdadero. Para crear un optimizador de eliminación de archivos huérfanos para una tabla de Iceberg mediante la AWS CLI, puede utilizar el siguiente comando:

```
aws glue create-table-optimizer \
 --catalog-id 123456789012 \
 --database-name iceberg_db \
 --table-name iceberg_table \
 --table-optimizer-configuration
 '{"roleArn":"arn:aws:iam::123456789012:role/optimizer_role","enabled":true,
 "vpcConfiguration":{
"glueConnectionName":"glue_connection_name"}, "orphanFileDeletionConfiguration":
{"icebergConfiguration":{"orphanFileRetentionPeriodInDays":3, "location":'S3
 location'}}}'\
 --type orphan_file_deletion
```

Este comando crea un optimizador de eliminación de archivos huérfanos para la tabla de Iceberg especificada. Los parámetros clave son:

- roleArn: ARN del rol de IAM con permisos para acceder al bucket de S3 y a los recursos de Glue.
- enabled: se establece en verdadero para habilitar el optimizador.
- orphanFileRetentionPeriodInDays: el número de días necesarios para retener los archivos huérfanos antes de eliminarlos (mínimo 1 día).
- type: se establece en orphan_file_deletion para crear un optimizador de eliminación de archivos huérfanos.

Tras crear el optimizador de tablas, eliminará los archivos huérfanos periódicamente (una vez al día si se deja habilitado). Puede comprobar las ejecuciones mediante la API `list-table-optimizer-runs`. El trabajo de eliminación de archivos huérfanos identificará y eliminará los archivos sin seguimiento en los metadatos de Iceberg de la tabla.

API

Llame a la operación CreateTableOptimizer para crear el optimizador de eliminación de archivos huérfanos para una tabla específica.

Actualización del optimizador de eliminación de archivos huérfanos

Puede modificar la configuración del optimizador de eliminación de archivos huérfanos, por ejemplo, cambiando el periodo de retención de los archivos huérfanos o el rol de IAM utilizado por el optimizador mediante la consola de AWS Glue, la AWS CLI o la operación `UpdateTableOptimizer`.

Consola de administración de AWS

Actualización del optimizador de eliminación de archivos huérfanos

1. Elija la Base de datos y las Tablas. En la lista de tablas, elija la tabla en la que quiera actualizar la configuración del optimizador de eliminación de archivos huérfanos.
2. En la sección inferior de la página Detalles de la tabla, elija Optimización de la tabla y, a continuación, elija Editar.
3. En la página Editar optimización, realice los cambios que desee.
4. Seleccione Save.

AWS CLI

Puede usar la llamada de `update-table-optimizer` para actualizar el optimizador de eliminación de archivos huérfanos en AWS Glue. Esto le permite modificar el parámetro `OrphanFileDeletionConfiguration` en el campo `icebergConfiguration` en el que puede especificar el parámetro `OrphanFileRetentionPeriodInDays` actualizado para establecer el número de días que se retendrán los archivos huérfanos y especificar la ubicación de la tabla de Iceberg desde la que se eliminarán los archivos huérfanos.

```
aws glue update-table-optimizer \
 --catalog-id 123456789012 \
 --database-name iceberg_db \
 --table-name Iceberg_table \
 --table-optimizer-configuration
 '{"roleArn":"arn:aws:iam::123456789012:role/optimizer_role","enabled":true,
 "vpcConfiguration":
{"glueConnectionName":"glue_connection_name"},"orphanFileDeletionConfiguration":
{"icebergConfiguration":{"orphanFileRetentionPeriodInDays":5}}}' \
 --type orphan_file_deletion
```

API

Llame a la operación UpdateTableOptimizer para actualizar el optimizador de eliminación de archivos huérfanos para una tabla.

Deshabilitación de la eliminación de archivos huérfanos

Puede deshabilitar el optimizador de eliminación de archivos huérfanos de una tabla de Apache Iceberg concreta mediante la consola de AWS Glue o la AWS CLI.

Console

Deshabilitación de la eliminación de archivos huérfanos

1. Elija la Base de datos y las Tablas. En la lista de tablas, elija la tabla de Iceberg en la que quiera deshabilitar el optimizador de eliminación de archivos huérfanos.
2. En la sección inferior de la página Detalles de la tabla, seleccione la pestaña Optimización de la tabla.
3. Seleccione Acciones y, a continuación, selecciona Desactivar, Eliminar archivos huérfanos.

También puede seleccionar Deshabilitar en Optimización en el menú Acciones.

4. Seleccione Deshabilitar en el mensaje de confirmación. Puede volver a habilitar el optimizador de eliminación de archivos huérfanos en otro momento.

   Tras la confirmación, el optimizador de eliminación de archivos huérfanos se deshabilita y el estado de la eliminación de archivos huérfanos vuelve a ser `Not enabled`.

AWS CLI

En el siguiente ejemplo, reemplace el ID de cuenta con un ID de AWS válido. Sustituya el nombre de la base de datos y el nombre de la tabla por el nombre real de la tabla de Iceberg y el nombre de la base de datos. Sustituya `roleArn` por el nombre de recurso de AWS (ARN) del rol de IAM y el nombre real del rol de IAM que tiene los permisos necesarios para deshabilitar el optimizador.

```
aws glue update-table-optimizer \
  --catalog-id 123456789012 \
  --database-name iceberg_db \
  --table-name iceberg_table \
  --table-optimizer-configuration
 '{"roleArn":"arn:aws:iam::123456789012:role/optimizer_role", "enabled":'false'}'\
  --type orphan_file_deletion
```

API

Llame a la operación UpdateTableOptimizer para deshabilitar el optimizador de retención de instantáneas de una tabla específica.

Visualización de los detalles de la optimización

Puede ver el estado de optimización de las tablas Apache Iceberg mediante la consola de AWS Glue, la AWS CLI o las operaciones de la API de AWS.

Console

Visualización del estado de optimización de las tablas de Iceberg (consola)

- Para ver el estado de optimización de las tablas de Iceberg en la consola de AWS Glue, seleccione una tabla de Iceberg de la lista Tablas del Catálogo de datos. En Optimización de la tabla. Elija la opción Ver todo

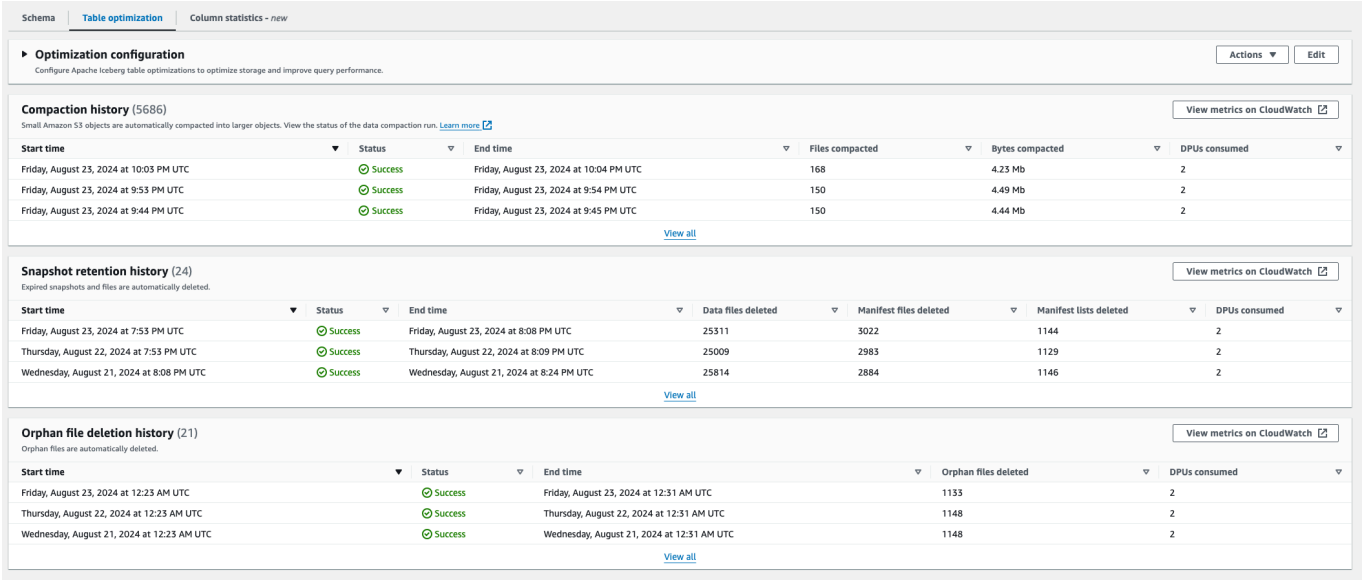

AWS CLI

Puede ver los detalles de la optimización mediante la AWS CLI.

En los siguientes ejemplos, sustituya el identificador de cuenta por un identificador de cuenta de AWS válido, el nombre de la base de datos y el nombre de la tabla por el nombre real de la tabla de Iceberg. Para `type`, proporcione un tipo de optimización. Los valores admitidos son `compaction`, `retention` y `orphan-file-deletion`.

- Obtención de los detalles de la última tanda de compactación de una tabla

```
aws get-table-optimizer \
  --catalog-id 123456789012 \
  --database-name iceberg_db \
  --table-name iceberg_table \
  --type compaction
```

- Utilice el siguiente ejemplo para recuperar el historial de un optimizador de una tabla específica.

```
aws list-table-optimizer-runs \
  --catalog-id 123456789012 \
  --database-name iceberg_db \
  --table-name iceberg_table \
  --type compaction
```

- En el siguiente ejemplo se muestra cómo recuperar la ejecución de optimización y los detalles de configuración de varios optimizadores. Puede especificar un máximo de 20 optimizadores.

```
aws glue batch-get-table-optimizer \
--entries '[{"catalogId":"123456789012", "databaseName":"iceberg_db",
 "tableName":"iceberg_table", "type":"compaction"}]'
```

API

- Utilice la operación `GetTableOptimizer` para recuperar los detalles de la última ejecución de un optimizador.
- Utilice la operación `ListTableOptimizerRuns` para recuperar el historial de un optimizador determinado en una tabla específica. Puede especificar 20 optimizadores en una sola llamada a la API.
- Utilice la operación BatchGetTableOptimizer para recuperar los detalles de configuración de varios optimizadores de su cuenta.

Visualización de métricas de Amazon CloudWatch

Tras ejecutar los optimizadores de tablas correctamente, el servicio crea métricas de Amazon CloudWatch sobre el rendimiento del trabajo de optimización. Puede ir a las Métricas de CloudWatch y elegir Métricas, Todas las métricas. Puede filtrar las métricas por el espacio de nombres específico (por ejemplo AWS Glue), el nombre de la tabla o el nombre de la base de datos.

Para obtener más información, consulte Ver métricas disponibles en la Guía del usuario de Amazon CloudWatch.

Compactación

- Número de bytes compactados
- Número de archivos compactados
- Número de DPU asignadas a los trabajos
- Duración del trabajo (horas)

Retención de instantáneas

- Número de archivos de datos eliminados
- Número de archivos de manifiesto eliminados
- Número de listas de manifiesto eliminadas
- Duración del trabajo (horas)

Eliminación de archivos huérfanos

- Número de archivos huérfanos eliminados
- Duración del trabajo (horas)

Eliminar un optimizador

Puede eliminar un optimizador y los metadatos asociados a la tabla mediante AWS CLI o una operación de API de AWS.

Ejecute el siguiente comando de la AWS CLI para eliminar el historial de optimización de una tabla. Debe especificar el valor de `type` del optimizador junto con el ID del catálogo, el nombre de la base de datos y el nombre de la tabla. Los valores admitidos son `compaction`, `retention` y `orphan_file_deletion`.

```
aws glue delete-table-optimizer \
  --catalog-id 123456789012 \
  --database-name iceberg_db \
  --table-name iceberg_table \
  --type compaction
```

Utilice la operación `DeleteTableOptimizer` para eliminar un optimizador de una tabla.

Consideraciones y limitaciones

En esta sección se incluyen aspectos que se deben tener en cuenta al utilizar optimizadores de tablas en el AWS Glue Data Catalog.

Formatos compatibles y limitaciones de la compactación de datos administrada

La compactación de datos admite una variedad de tipos de datos y formatos de compresión para leer y escribir datos, incluida la lectura de datos de tablas cifradas.

La compactación de datos admite:

- Cifrado: La compactación de datos solo admite el cifrado Amazon S3 (SSE-S3) y el cifrado KMS del lado del servidor (SSE-KMS)
- Estrategias de compactación: Binpack, ordenamiento y ordenamiento Z
- Puede ejecutar la compactación desde la cuenta en la que reside el catálogo de datos cuando el bucket de Amazon S3 que almacena los datos subyacentes esté en otra cuenta. Para ello, el rol de compactación requiere acceso al bucket de Amazon S3.

La compactación de datos actualmente no admite:

- Compactación en tablas con varias cuentas: No se puede ejecutar la compactación en tablas con varias cuentas
- Compactación en tablas de varias regiones: No se puede ejecutar la compactación en tablas de varias regiones
- Habilitar la compactación en los enlaces de recursos
- Tablas de la clase de almacenamiento de Amazon S3 Express One Zone: no puede ejecutar la compactación en tablas de Iceberg S3 Express One Zone.
- La estrategia de compactación por ordenamiento en Z no admite los siguientes tipos de datos:
  - Decimal
  - TimestampWithoutZone

Consideraciones sobre los optimizadores de retención de instantáneas y eliminación de archivos huérfanos

Las siguientes consideraciones se aplican a los optimizadores de retención de instantáneas y de eliminación de archivos huérfanos.

- Los procesos de retención de instantáneas y eliminación de archivos huérfanos tienen un límite máximo de eliminación de 1 000 000 de archivos por ejecución. Al eliminar las instantáneas caducadas, si el número de archivos aptos para su eliminación supera 1 000 000, los archivos restantes que superen ese umbral seguirán existiendo en el almacenamiento de tablas como archivos huérfanos.

- El optimizador de retención de instantáneas conservará las instantáneas solo cuando se cumplan ambos criterios: el número mínimo de instantáneas que se deben conservar y el periodo de retención especificado.
- El optimizador de retención de instantáneas elimina los metadatos de las instantáneas caducadas de Apache Iceberg, lo que evita que las consultas sobre las instantáneas caducadas viajen en el tiempo y, de forma opcional, elimina los archivos de datos asociados.
- El optimizador de eliminación de archivos huérfanos elimina los archivos de datos y metadatos huérfanos a los que los metadatos de Iceberg ya no hacen referencia si su momento de creación es anterior al periodo de retención de la eliminación de archivos huérfanos desde el momento en que se ejecuta el optimizador.
- Apache Iceberg facilita el control de versiones mediante ramas y etiquetas, denominadas punteros para estados de instantáneas específicos. Cada rama y etiqueta sigue su propio ciclo de vida independiente, regido por las políticas de retención definidas en sus niveles respectivos. Los optimizadores de AWS Glue Data Catalog tienen en cuenta estas políticas de ciclo de vida, lo que garantiza el cumplimiento de las reglas de retención especificadas. Las políticas de retención de rama y etiqueta tienen prioridad sobre las configuraciones del optimizador.

  Para obtener más información, consulte la sección Branching and Tagging de la documentación de Apache Iceberg.
- Los optimizadores de retención de instantáneas y de eliminación de archivos huérfanos eliminarán los archivos que puedan limpiarse según los parámetros configurados. Mejore su control sobre la eliminación de archivos mediante la implementación de políticas de control de versiones y ciclo de vida de S3 en los buckets correspondientes.

  Para obtener instrucciones detalladas sobre cómo configurar el control de versiones y crear reglas de ciclo de vida, consulte https://docs.aws.amazon.com/AmazonS3/latest/userguide/Versioning.html.
- Para determinar correctamente los archivos huérfanos, asegúrese de que la ubicación de la tabla proporcionada y las subrutas no se superpongan ni contengan datos de ninguna otra tabla u origen de datos. Si las rutas se superponen, corre el riesgo de sufrir una pérdida de datos irrecuperable debido a la eliminación no intencionada de archivos.

Depuración de excepción **`OversizedAllocationException`**

Para resolver una excepción `OversizedAllocationException`:

- Reduzca el tamaño del lote del lector vectorizado y compruébelo. El tamaño predeterminado del lote es de 5000. Esto se controla en `read.parquet.vectorization.batch-size`.
  - Si esto no funciona incluso después de varias variaciones, desactive la vectorización. Esto se controla en `read.parquet.vectorization.enabled`.
  - Si esto no funciona incluso después de varias variaciones, desactive la vectorización. Esto se controla en `read.parquet.vectorization.enabled`.

Regiones compatibles con los optimizadores de tablas

Las funciones de optimización de tablas (compactación, retención de instantáneas y eliminación de archivos huérfanos) para AWS Glue Data Catalog están disponibles en las siguientes Regiones de AWS:

- Asia-Pacífico (Tokio)
- Asia-Pacífico (Seúl)
- Asia-Pacífico (Mumbai)
- Asia-Pacífico (Singapur)
- Asia-Pacífico (Sídney)
- Asia-Pacífico (Yakarta)
- Canadá (centro)
- Europa (Irlanda)
- Europa (Londres)
- Europa (Fráncfort)
- Europa (Estocolmo)
- Este de EE. UU. (Norte de Virginia)
- Este de EE. UU. (Ohio)
- Oeste de EE. UU. (Oregón)
- América del Sur (São Paulo)

Optimización del rendimiento de las consultas en tablas de Iceberg

Apache Iceberg es un formato de tabla abierto de alto rendimiento para conjuntos de datos de análisis de gran tamaño. AWS Glue permite calcular y actualizar el número de valores distintos

(NDV) para cada columna de las tablas de Iceberg. Estas estadísticas pueden facilitar una mejor optimización de las consultas, administración de los datos y eficiencia del rendimiento para los ingenieros y científicos de datos que trabajan con conjuntos de datos a gran escala.

AWS Glue calcula el número de valores distintos de cada columna de la tabla de Iceberg y los almacena en archivos Puffin de Amazon S3 asociados a las instantáneas de la tabla de Iceberg. Puffin es un formato de archivo de Iceberg diseñado para almacenar metadatos como índices, estadísticas y bocetos. El almacenamiento de bocetos en archivos Puffin vinculados a instantáneas garantiza la coherencia de las transacciones y la actualización de las estadísticas de NDV.

Puede configurarlo para ejecutar la tarea de generación de estadísticas de columnas mediante la consola AWS Glue o AWS CLI. Al iniciar el proceso, AWS Glue inicia un trabajo de Spark en segundo plano y actualiza los metadatos de la tabla AWS Glue en el catálogo de datos. Puede ver las estadísticas de las columnas mediante la consola AWS Glue o AWS CLI, o llamando a la operación de la API GetColumnStatisticsForTable.

> **Note**
>
> Si utiliza los permisos de AWS Lake Formation para controlar el acceso a la tabla, el rol que asume la tarea de estadísticas de columnas requiere acceso total a la tabla para generar estadísticas.

Temas

- Requisitos previos para generar estadísticas de columnas
- Generación de estadísticas de las columnas de las tablas de Iceberg
- Véase también

Requisitos previos para generar estadísticas de columnas

Para generar o actualizar las estadísticas de las columnas de tablas de Iceberg, la tarea de generación de estadísticas adopta un rol de AWS Identity and Access Management (IAM) en su nombre. Según los permisos concedidos al rol, la tarea de generación de estadísticas de columnas puede leer los datos del almacén de datos de Amazon S3.

Al configurar la tarea de generación de estadísticas de la columna, AWS Glue le permite crear un rol que incluye la política administrada de AWS `AWSGlueServiceRole`, más la política insertada necesaria para el origen de datos especificado.

Si especifica un rol existente para generar estadísticas de las columnas, asegúrese de que incluya la política `AWSGlueServiceRole` o equivalente (o una versión reducida de esta política), además de las políticas insertadas requeridas.

Para obtener más información sobre los permisos necesarios, consulte Requisitos previos para generar estadísticas de columnas.

Generación de estadísticas de las columnas de las tablas de Iceberg

Siga estos pasos para configurar una programación para generar estadísticas en el Catálogo de datos mediante la consola de AWS Glue o la AWS CLI, o ejecute la operación StartColumnStatisticsTaskRun.

Generación de estadísticas de columnas

1. Inicie sesión en la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. Seleccione Tablas en el Catálogo de datos.
3. Seleccione una tabla de Iceberg de la lista.
4. Seleccione Generar estadísticas, Generar bajo demanda en el menú Acciones.

   También puede pulsar el botón Generar estadísticas en la pestaña Estadísticas de columnas, en la sección inferior de la página de Tablas.
5. En la página Generar estadísticas, proporcione los detalles de generación de estadísticas. Siga los pasos 6 a 11 de la sección Generación de estadísticas de columnas según una programación a fin de configurar una programación para la generación de estadísticas de las tablas de Iceberg.

   También puede optar por generar estadísticas de columnas bajo demanda si sigue las instrucciones en Generación de estadísticas de columnas bajo demanda

   > **Note**
   >
   > La opción de muestreo no está disponible para las tablas de Iceberg.

   AWS Glue calcula el número de valores distintos de cada columna de la tabla de Iceberg en un nuevo archivo Puffin asignado al ID de instantánea especificado en la ubicación de su instancia de Amazon S3.

Véase también

- Visualización de estadísticas de columnas
- Visualización de las ejecuciones de tareas de estadísticas de columnas
- Detener la ejecución de la tarea de estadísticas de columnas
- Eliminar estadísticas de columnas

Administración del Catálogo de datos

El AWS Glue Data Catalog es un repositorio central de metadatos que almacena los metadatos estructurales y operativos para sus conjuntos de datos de Amazon S3. La administración eficaz del Catálogo de datos es crucial para mantener la calidad, el rendimiento, la seguridad y la gobernanza de los datos.

Si comprende y aplica estas prácticas de administración del Catálogo de datos, puede asegurarse de que sus metadatos sigan siendo precisos, eficaces y seguros, y de que estén bien gestionados a medida que el panorama de sus datos evoluciona.

En esta sección se tratan los siguientes aspectos de la administración del Catálogo de datos:

- Actualización del esquema y las particiones de la tabla: A medida que evolucionan los datos, es posible que deba actualizar el esquema de la tabla o la estructura de particiones definidos en el Catálogo de datos. Para obtener más información sobre cómo realizar estas actualizaciones mediante programación con la ETL de AWS Glue, consulte Cómo actualizar el esquema y añadir nuevas particiones al Catálogo de datos mediante trabajos de ETL de AWS Glue.
- Administración de las estadísticas de columnas: Las estadísticas de columnas precisas ayudan a optimizar los planes de las consultas y a mejorar el rendimiento. Para obtener más información sobre cómo generar, actualizar y administrar las estadísticas de columnas, consulte Cómo optimizar el rendimiento de las consultas con las estadísticas de columnas.
- Cifrado del Catálogo de datos: Para proteger los metadatos confidenciales, puede cifrar el Catálogo de datos mediante el uso de AWS Key Management Service (AWS KMS). En esta sección se explica cómo activar y administrar el cifrado del Catálogo de datos.
- Protección del Catálogo de datos con AWS Lake Formation: Lake Formation proporciona un enfoque integral para abordar la seguridad de los lagos de datos y el control del acceso a estos. Puede usar Lake Formation para proteger y controlar el acceso a su Catálogo de datos y a los datos subyacentes.

Temas

- Cómo actualizar el esquema y añadir nuevas particiones al Catálogo de datos mediante trabajos de ETL de AWS Glue
- Cómo optimizar el rendimiento de las consultas con las estadísticas de columnas
- Cifrado del Catálogo de datos
- Cómo proteger su Catálogo de datos con Lake Formation
- Trabajar con vistas AWS Glue Data Catalog en AWS Glue

Cómo actualizar el esquema y añadir nuevas particiones al Catálogo de datos mediante trabajos de ETL de AWS Glue

Un trabajo de extracción, transformación y carga (ETL) podría crear nuevas particiones de la tabla en el almacén de datos de destino. El esquema del conjunto de datos puede evolucionar y ser cada vez más diferente del esquema del AWS Glue Data Catalog. AWS Glue Los trabajos de ETL ahora cuentan con varias características que se pueden utilizar dentro del script de ETL para actualizar el esquema y las particiones del Data Catalog. Estas características permiten ver los resultados del trabajo de ETL en el Data Catalog sin necesidad de volver a ejecutar el rastreador.

Nuevas particiones

Si desea ver las nuevas particiones del AWS Glue Data Catalog, puede realizar una de las siguientes acciones:

- Cuando el trabajo termine, vuelva a ejecutar el rastreador y, una vez que finalice, consulte las nuevas particiones en la consola.
- Cuando el trabajo termine, podrá ver las nuevas particiones en la consola de inmediato sin necesidad de volver a ejecutar el rastreador. Puede habilitar esta característica agregando algunas líneas de código al script ETL, tal y como se muestra en los siguientes ejemplos. El código utiliza el argumento `enableUpdateCatalog` para indicar que el Data Catalog se va a actualizar durante la ejecución del trabajo a medida que se creen las nuevas particiones.

Método 1

Pase `enableUpdateCatalog` y `partitionKeys` en un argumento de opciones.

Python

```
additionalOptions = {"enableUpdateCatalog": True}
additionalOptions["partitionKeys"] = ["region", "year", "month", "day"]


sink = glueContext.write_dynamic_frame_from_catalog(frame=last_transform,
 database=<target_db_name>,

 table_name=<target_table_name>, transformation_ctx="write_sink",

 additional_options=additionalOptions)
```

Scala

```
val options = JsonOptions(Map(
    "path" -> <S3_output_path>,
    "partitionKeys" -> Seq("region", "year", "month", "day"),
    "enableUpdateCatalog" -> true))
val sink = glueContext.getCatalogSink(
    database = <target_db_name>,
    tableName = <target_table_name>,
    additionalOptions = options)sink.writeDynamicFrame(df)
```

Método 2

Pase `enableUpdateCatalog` y `partitionKeys` en `getSink()` y llame a `setCatalogInfo()` en el objeto `DataSink`.

Python

```
sink = glueContext.getSink(
    connection_type="s3",
    path="<S3_output_path>",
    enableUpdateCatalog=True,
    partitionKeys=["region", "year", "month", "day"])
sink.setFormat("json")
sink.setCatalogInfo(catalogDatabase=<target_db_name>,
 catalogTableName=<target_table_name>)
sink.writeFrame(last_transform)
```

Scala

```
val options = JsonOptions(
   Map("path" -> <S3_output_path>,
       "partitionKeys" -> Seq("region", "year", "month", "day"),
       "enableUpdateCatalog" -> true))
val sink = glueContext.getSink("s3", options).withFormat("json")
sink.setCatalogInfo(<target_db_name>, <target_table_name>)
sink.writeDynamicFrame(df)
```

Ahora, puede crear nuevas tablas de catálogo, actualizar las tablas existentes con un esquema modificado y agregar nuevas particiones de tabla en el Data Catalog utilizando únicamente un trabajo de ETL de AWS Glue, sin necesidad de volver a ejecutar los rastreadores.

Actualización del esquema de la tabla

Si desea sobrescribir el esquema de la tabla del Data Catalog, puede realizar una de las siguientes acciones:

- Cuando termine el trabajo, vuelva a ejecutar el rastreador y asegúrese de que esté configurado para actualizar también la definición de la tabla. Cuando el rastreador finalice, consulte las nuevas particiones en la consola junto con las actualizaciones del esquema. Para obtener más información, consulte Configuración de un rastreador con la API.
- Cuando el trabajo termine, podrá ver de inmediato el esquema modificado en la consola sin necesidad de volver a ejecutar el rastreador. Puede habilitar esta característica agregando algunas líneas de código al script ETL, tal y como se muestra en los siguientes ejemplos. El código utiliza el valor `enableUpdateCatalog` establecido en verdadero y también el valor `updateBehavior` establecido en `UPDATE_IN_DATABASE`, lo que indica que el esquema debe sobrescribirse y deben agregarse nuevas particiones en el Data Catalog durante la ejecución del trabajo.

Python

```
additionalOptions = {
    "enableUpdateCatalog": True,
    "updateBehavior": "UPDATE_IN_DATABASE"}
additionalOptions["partitionKeys"] = ["partition_key0", "partition_key1"]

sink = glueContext.write_dynamic_frame_from_catalog(frame=last_transform,
 database=<dst_db_name>,
```

```
    table_name=<dst_tbl_name>, transformation_ctx="write_sink",
    additional_options=additionalOptions)
job.commit()
```

Scala

```
val options = JsonOptions(Map(
    "path" -> outputPath,
    "partitionKeys" -> Seq("partition_0", "partition_1"),
    "enableUpdateCatalog" -> true))
val sink = glueContext.getCatalogSink(database = nameSpace, tableName = tableName,
 additionalOptions = options)
sink.writeDynamicFrame(df)
```

También puede establecer el valor `updateBehavior` en `LOG` si no desea que el esquema de la tabla se sobrescriba pero sí quiere agregar las nuevas particiones. El valor predeterminado de `updateBehavior` es `UPDATE_IN_DATABASE`, por lo que, si no lo define explícitamente, se sobrescribirá el esquema de la tabla.

Si `enableUpdateCatalog` no se establece en verdadero, independientemente de la opción seleccionada en `updateBehavior`, el trabajo de ETL no actualizará la tabla del Data Catalog.

Creación de nuevas tablas

También puede utilizar las mismas opciones para crear una nueva tabla en el Data Catalog. Puede especificar la base de datos y el nuevo nombre de la tabla con `setCatalogInfo`.

Python

```
sink = glueContext.getSink(connection_type="s3", path="s3://path/to/data",
    enableUpdateCatalog=True, updateBehavior="UPDATE_IN_DATABASE",
    partitionKeys=["partition_key0", "partition_key1"])
sink.setFormat("<format>")
sink.setCatalogInfo(catalogDatabase=<dst_db_name>, catalogTableName=<dst_tbl_name>)
sink.writeFrame(last_transform)
```

Scala

```
val options = JsonOptions(Map(
    "path" -> outputPath,
```

```
    "partitionKeys" -> Seq("<partition_1>", "<partition_2>"),
    "enableUpdateCatalog" -> true,
    "updateBehavior" -> "UPDATE_IN_DATABASE"))
val sink = glueContext.getSink(connectionType = "s3", connectionOptions =
 options).withFormat("<format>")
sink.setCatalogInfo(catalogDatabase = “<dst_db_name>”, catalogTableName =
 “<dst_tbl_name>”)
sink.writeDynamicFrame(df)
```

Restricciones

Tome nota de las siguientes restricciones:

- Solo se soportan los destinos de Amazon Simple Storage Service (Amazon S3).
- La característica `enableUpdateCatalog` no es compatible con las tablas gobernadas.
- Solo se admiten los siguientes formatos: `json`, `csv`, `avro` y `parquet`.
- Para crear o actualiza tablas con la clasificación `parquet`, debe utilizar el escritor de parquet optimizado para DynamicFrames de AWS Glue. Esto se puede lograr con uno de los siguientes:
  - Si va a actualizar una tabla existente en el catálogo con una clasificación `parquet`, la tabla debe tener la propiedad de tabla `"useGlueParquetWriter"` establecida en `true` antes de actualizarla. Puede configurar esta propiedad a través de las API/SDK de AWS Glue, la consola o una instrucción DDL de Athena.

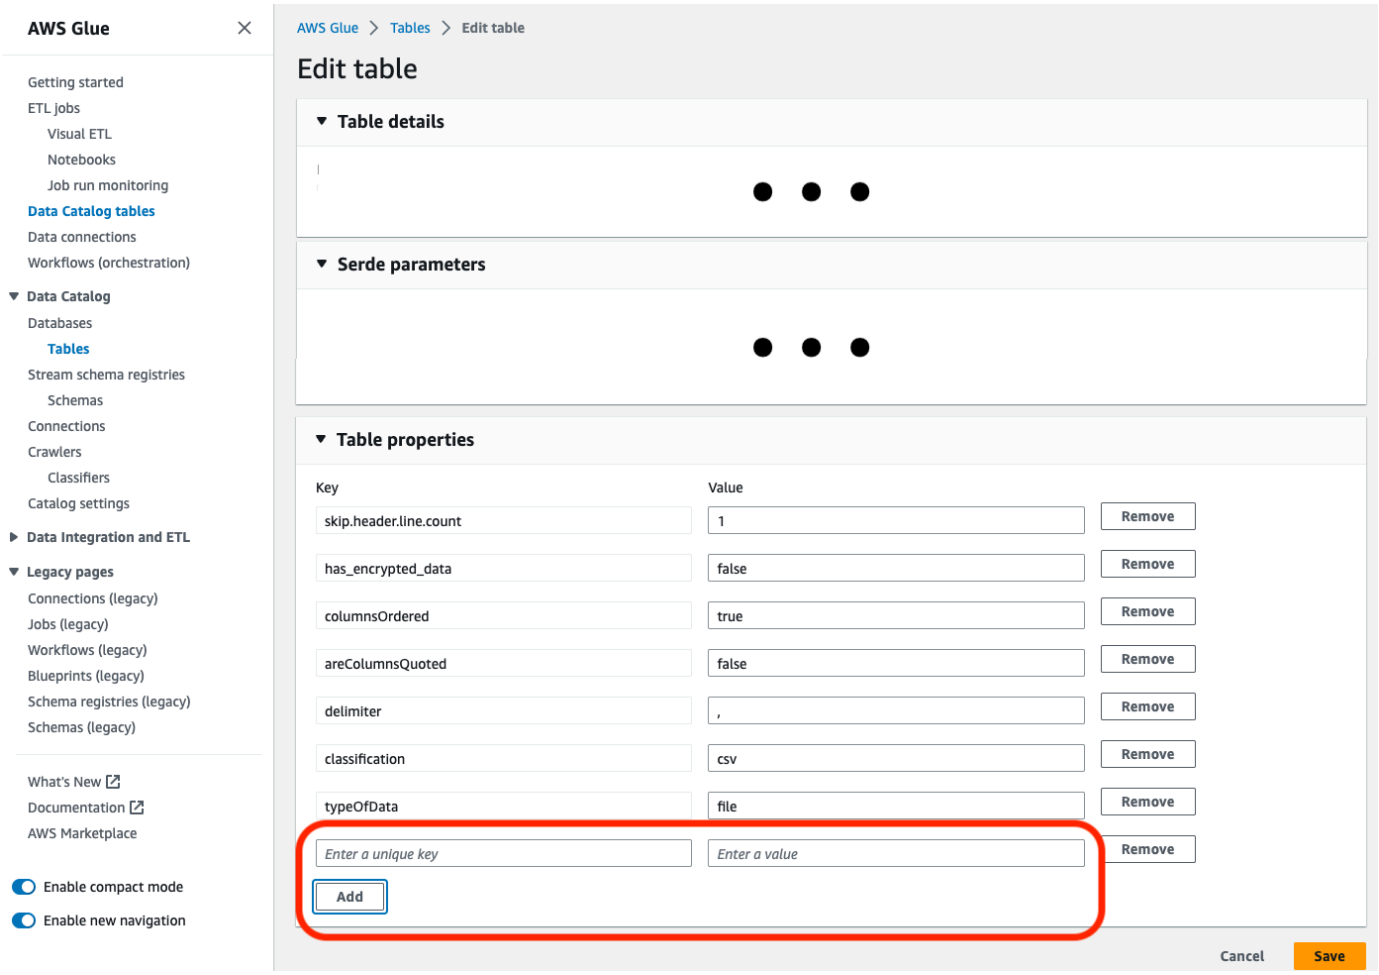

Una vez establecida la propiedad de la tabla de catálogo, puede utilizar el siguiente fragmento de código para actualizar la tabla de catálogo con los nuevos datos:

```
glueContext.write_dynamic_frame.from_catalog(
    frame=frameToWrite,
    database="dbName",
    table_name="tableName",
    additional_options={
        "enableUpdateCatalog": True,
        "updateBehavior": "UPDATE_IN_DATABASE"
    }
)
```

- Si la tabla aún no existe en el catálogo, puede utilizar el método `getSink()` del script con `connection_type="s3"` para agregar la tabla y sus particiones al catálogo, además de escribir los datos en Amazon S3. Proporcione la `partitionKeys` adecuada y la `compression` para su flujo de trabajo.

```
s3sink = glueContext.getSink(
    path="s3://bucket/folder/",
    connection_type="s3",
    updateBehavior="UPDATE_IN_DATABASE",
    partitionKeys=[],
    compression="snappy",
    enableUpdateCatalog=True
)

s3sink.setCatalogInfo(
    catalogDatabase="dbName", catalogTableName="tableName"
)

s3sink.setFormat("parquet", useGlueParquetWriter=True)
s3sink.writeFrame(frameToWrite)
```

  - El valor de formato `glueparquet` es un método heredado para habilitar el escritor de Parquet de AWS Glue.
- Si `updateBehavior` se configura en `LOG`, las nuevas particiones solo se agregarán si el esquema de `DynamicFrame` es igual al subconjunto de las columnas definidas en el esquema de la tabla del Data Catalog, o si contiene un subconjunto de este tipo.
- Las actualizaciones de esquema no son compatibles con las tablas sin particiones (no se utiliza la opción "PartitionKeys").
- Las claves de partición deben ser equivalentes y estar en el mismo orden en el parámetro que se transfirió en el script de ETL y en las claves de partición del esquema de la tabla del catálogo de datos.
- Esta característica aún no admite la actualización/creación de tablas en las que se anidan los esquemas de actualización (por ejemplo, matrices dentro de estructuras).

Para obtener más información, consulte the section called “Glue para Spark AWS”.

Trabajar con conexiones MongoDB en trabajos de ETL

Puede crear una conexión para MongoDB y luego usar esa conexión en su trabajo de AWS Glue. Para obtener más información, consulte the section called “Conexiones a MongoDB” en la guía de progrmación de AWS Glue. La `url`, el `username` y la `password` de la conexión se almacenan en la conexión de MongoDB. Se pueden especificar otras opciones en el script de trabajo de ETL

mediante el parámetro `additionalOptions` de `glueContext.getCatalogSource`. Las otras opciones pueden incluir lo siguiente:

- `database`: (obligatorio) la base de datos de MongoDB de la que se va a leer.
- `collection`: (obligatorio) la colección de MongoDB de la que se va a leer.

Al colocar la información de `database` y `collection` dentro del script de trabajo de ETL, puede utilizar la misma conexión para varios trabajos.

1. Creación de una conexión de AWS Glue Data Catalog para el origen de datos MongoDB. Consulte "connectionType": "mongodb" para ver una descripción de los parámetros de conexión. Puede crear la conexión mediante la consola, las API o CLI.
2. Cree una base de datos en AWS Glue Data Catalog para almacenar las definiciones de la tabla para sus datos de MongoDB. Para obtener más información, consulte Creación de bases de datos.
3. Cree un rastreador que rastree los datos en MongoDB usando la información en la conexión para conectarse a MongoDB. El rastreador crea las tablas en AWS Glue Data Catalog, que describen las tablas en la base de datos MongoDB que usa en su trabajo. Para obtener más información, consulte Uso de rastreadores para completar el Catálogo de datos .
4. Cree un trabajo con un script personalizado. Puede crear un trabajo mediante la consola, la API o CLI. Para obtener más información, consulte Agregar trabajos en AWS Glue.
5. Elija los destinos de datos para su trabajo. Las tablas que representan el destino de datos se pueden definir en el Data Catalog, o bien, el trabajo puede crear las tablas de destino cuando se ejecute. El usuario elige la ubicación de destino al crear el trabajo. Si el destino requiere una conexión, esta también estará referenciada en el trabajo. Si el trabajo requiere varios destinos de datos, puede agregarlos más tarde al editar el script.
6. Personalice el entorno de procesamiento del flujo de trabajo mediante argumentos para el flujo de trabajo y el script que se generó.

   A continuación, se muestra un ejemplo de creación de un `DynamicFrame` desde la base de datos MongoDB en función de la estructura de la tabla definida en el Data Catalog. El código utiliza `additionalOptions` para proporcionar la información adicional del origen de datos:

   Scala

```
val resultFrame: DynamicFrame = glueContext.getCatalogSource(
        database = catalogDB,
```

```
        tableName = catalogTable,
        additionalOptions = JsonOptions(Map("database" -> DATABASE_NAME,
                "collection" -> COLLECTION_NAME))
      ).getDynamicFrame()
```

Python

```
glue_context.create_dynamic_frame_from_catalog(
        database = catalogDB,
        table_name = catalogTable,
        additional_options = {"database":"database_name",
            "collection":"collection_name"})
```

7. Ejecute el trabajo, ya sea bajo demanda o a través de un desencadenador.

Cómo optimizar el rendimiento de las consultas con las estadísticas de columnas

Puede calcular estadísticas a nivel de columna para tablas AWS Glue Data Catalog en formatos de datos como Parquet, ORC, JSON, ION, CSV y XML sin necesidad de configurar canalizaciones de datos adicionales. Las estadísticas de columnas le ayudan a entender los perfiles de datos al obtener información sobre los valores de una columna.

El catálogo de datos le permite generar estadísticas para los valores de las columnas, como el valor mínimo, el valor máximo, los valores nulos totales, los valores distintos totales, la longitud media de los valores y el total de apariciones de valores verdaderos. Los servicios analíticos de AWS como Amazon Redshift y Amazon Athena pueden utilizar estas estadísticas de columnas para generar planes de ejecución de consultas y elegir el plan más adecuado que mejore el rendimiento de las consultas.

Existen tres casos en los que generar estadísticas de columnas:

Automático

AWS Glue admite la generación automática de estadísticas de columnas a nivel de catálogo, para que pueda generar automáticamente estadísticas de las nuevas tablas en AWS Glue Data Catalog.

Programados

AWS Glue permite programar la generación de estadísticas de columnas para que se puedan ejecutar automáticamente según una programación periódica.

Con el cálculo de estadísticas programado, la tarea de estadísticas de columnas actualiza las estadísticas generales a nivel de tabla (como las mínimas, máximas y medias) con las nuevas estadísticas, lo que proporciona a los motores de consultas estadísticas precisas y actualizadas para optimizar la ejecución de las consultas.

Bajo demanda

Utilice esta opción para generar estadísticas de columnas bajo demanda siempre que sea necesario. Esto resulta útil para realizar un análisis ad hoc o cuando es necesario calcular las estadísticas de forma inmediata.

Puede configurar esto para ejecutar la tarea de generación de estadísticas de columnas mediante la consola AWS Glue, AWS CLI y operaciones de API AWS Glue. Al iniciar el proceso, AWS Glue inicia un trabajo de Spark en segundo plano y actualiza los metadatos de la tabla AWS Glue en el catálogo de datos. Puede ver las estadísticas de las columnas mediante la consola AWS Glue o AWS CLI, o llamando a la operación de la API GetColumnStatisticsForTable.

> **Note**
>
> Si utiliza los permisos de Lake Formation para controlar el acceso a la tabla, el rol que asume la tarea de estadísticas de columnas requiere acceso total a la tabla para generar estadísticas.

Temas

- Requisitos previos para generar estadísticas de columnas
- Generación automática de estadísticas de columnas
- Generación de estadísticas de columnas según una programación
- Generación de estadísticas de columnas bajo demanda
- Visualización de estadísticas de columnas
- Visualización de las ejecuciones de tareas de estadísticas de columnas
- Detener la ejecución de la tarea de estadísticas de columnas

- Eliminar estadísticas de columnas
- Consideraciones y limitaciones

Requisitos previos para generar estadísticas de columnas

Para generar o actualizar las estadísticas de las columnas, la tarea de generación de estadísticas adopta un rol de AWS Identity and Access Management (IAM) en su nombre. Según los permisos concedidos al rol, la tarea de generación de estadísticas de columnas puede leer los datos del almacén de datos de Amazon S3.

Al configurar la tarea de generación de estadísticas de la columna, AWS Glue le permite crear un rol que incluye la política administrada de AWS `AWSGlueServiceRole`, más la política insertada necesaria para el origen de datos especificado.

Si especifica un rol existente para generar estadísticas de columnas, asegúrese de que incluya la política `AWSGlueServiceRole` o una equivalente (o una versión reducida de esta política), además de las políticas insertadas requeridas. Para crear un nuevo rol de IAM, siga estos pasos:

> **Note**
>
> Para generar estadísticas para las tablas administradas por Lake Formation, el rol de IAM utilizado para generar estadísticas requiere acceso total a las tablas.

Al configurar la tarea de generación de estadísticas de la columna, AWS Glue le permite crear un rol que incluye la política administrada de AWS `AWSGlueServiceRole`, más la política insertada necesaria para el origen de datos especificado. También puede crear un rol y adjuntar los permisos que se indican en la política siguiente y agregarlo a la tarea de generación de estadísticas de la columna.

Creación de un rol de IAM para generar estadísticas de columnas

1. Para crear un rol de IAM;, consulte Crear un rol de IAM para AWS Glue.
2. Para actualizar un rol existente, en la consola de IAM, vaya al rol de IAM que está utilizando el proceso de generación de estadísticas de columnas.
3. En la sección Agregar permisos, elija Asociar políticas. En la ventana del navegador que se acaba de abrir, elija la política administrada de AWS `AWSGlueServiceRole`.

4. También debe incluir los permisos de lectura de los datos de la ubicación de datos de Amazon S3.

   En la sección Agregar permisos, elija Crear política. En la ventana del navegador que se acaba de abrir, cree una nueva política para utilizarla con su rol.

5. En la página Crear política, elija la pestaña JSON. Copie el siguiente código `JSON` en el campo del editor de política.

   > **Note**
   >
   > En las políticas a continuación, reemplace la ID de cuenta con una Cuenta de AWS válida, `region` con la Región de la tabla y `bucket-name` con el nombre del bucket de Amazon S3.

   JSON

   ```
   {
       "Version":"2012-10-17",
       "Statement": [
           {
               "Sid": "S3BucketAccess",
               "Effect": "Allow",
               "Action": [
                   "s3:ListBucket",
                   "s3:GetObject"
               ],
               "Resource": [
                "arn:aws:s3:::amzn-s3-demo-bucket/*",
          "arn:aws:s3:::amzn-s3-demo-bucket"
               ]
           }
        ]
   }
   ```

6. (Opcional) Si utiliza los permisos de Lake Formation para acceder a sus datos, el rol de IAM requiere permisos `lakeformation:GetDataAccess`.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Sid": "LakeFormationDataAccess",
      "Effect": "Allow",
      "Action": "lakeformation:GetDataAccess",
      "Resource": [
        "*"
      ]
    }
  ]
}
```

Si la ubicación de datos de Amazon S3 está registrada en Lake Formation y el rol de IAM que asume la tarea de generación de estadísticas de columnas no tiene permisos de grupos `IAM_ALLOWED_PRINCIPALS` concedidos en la tabla, el rol requiere los permisos de Lake Formation `ALTER` y `DESCRIBE` en la tabla. El rol utilizado para registrar el bucket de Amazon S3 requiere los permisos de Lake Formation `INSERT` y `DELETE` en la tabla.

Si la ubicación de datos de Amazon S3 no está registrada en Lake Formation y el rol de IAM no tiene permisos de grupo `IAM_ALLOWED_PRINCIPALS` otorgados en la tabla, el rol requiere los permisos de Lake Formation `ALTER`, `DESCRIBE`, `INSERT` y `DELETE` en la tabla.

7. Si ha habilitado la opción `Automatic statistics generation` a nivel de catálogo, el rol de IAM debe tener el permiso `glue:UpdateCatalog` o el permiso `ALTER CATALOG` de Lake Formation en el catálogo de datos predeterminado. Puede utilizar la operación `GetCatalog` para verificar las propiedades del catálogo.
8. (Opcional) La tarea de generación de estadísticas de columnas que escribe Amazon CloudWatch Logs cifrado necesita los siguientes permisos en la política de claves.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
```

```
    {
      "Sid": "CWLogsKmsPermissions",
      "Effect": "Allow",
      "Action": [
        "logs:CreateLogGroup",
        "logs:CreateLogStream",
        "logs:PutLogEvents",
        "logs:AssociateKmsKey"
      ],
      "Resource": [
        "arn:aws:logs:us-east-1:111122223333:log-group:/aws-glue:*"
      ]
    },
    {
      "Sid": "KmsPermissions",
      "Effect": "Allow",
      "Action": [
        "kms:GenerateDataKey",
        "kms:Decrypt",
        "kms:Encrypt"
      ],
      "Resource": [
        "arn:aws:kms:us-east-1:111122223333:key/arn of key used for ETL
 cloudwatch encryption"
      ],
      "Condition": {
        "StringEquals": {
          "kms:ViaService": [
            "glue.us-east-1.amazonaws.com"
          ]
        }
      }
    }
  ]
}
```

9. El rol que utilice para ejecutar las estadística de columnas debe contener el permiso `iam:PassRole` en el rol.

   JSON

```
{
  "Version":"2012-10-17",
```

```
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "iam:PassRole"
      ],
      "Resource": [
        "arn:aws:iam::111122223333:role/columnstats-role-name"
      ]
    }
  ]
}
```

10. Al crear un rol de IAM para generar estadísticas de columnas, el rol también debe tener la siguiente política de confianza que permita al servicio asumirlo.

    JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Sid": "TrustPolicy",
      "Effect": "Allow",
      "Principal": {
        "Service": "glue.amazonaws.com"
      },
      "Action": "sts:AssumeRole"
    }
  ]
}
```

Generación automática de estadísticas de columnas

La generación automática de estadísticas de columnas le permite programar y calcular automáticamente las estadísticas de las nuevas tablas en AWS Glue Data Catalog. Al activar la generación automática de estadísticas, el catálogo de datos indica nuevas tablas con formatos de datos específicos, como Parquet, JSON, CSV, XML, ORC, ION y Apache Iceberg, junto con sus respectivas rutas de bucket. Mediante una configuración de catálogo única, el catálogo de datos genera estadísticas para estas tablas.

Los administradores del lago de datos pueden configurar la generación de estadísticas si seleccionan el catálogo predeterminado en la consola de Lake Formation y habilitando las estadísticas de tablas mediante la opción `Optimization configuration`. Al crear tablas nuevas o actualizar las existentes en el catálogo de datos, este recopila semanalmente el número de valores distintos (NDV) de las tablas de Apache Iceberg y otras estadísticas adicionales, como el número de valores nulos o la longitud máxima, mínima y media de otros formatos de archivo compatibles.

Si configuró la generación de estadísticas a nivel de tabla o si eliminó previamente la configuración de generación de estadísticas de una tabla, esa configuración específica de tabla tendrá prioridad sobre la configuración predeterminada del catálogo para la generación automática de estadísticas de columnas.

La tarea de generación automática de estadísticas analiza el 50 % de los registros de las tablas para calcular las estadísticas. La generación automática de estadísticas de columnas garantiza que el catálogo de datos mantenga las métricas semanales más recientes que pueden utilizar los motores de consultas, como Amazon Athena y Amazon Redshift Spectrum, para mejorar el rendimiento de las consultas y ahorrar costos potenciales. Permite programar la generación de estadísticas mediante las API de AWS Glue o la consola, lo que proporciona un proceso automatizado sin intervención manual.

Temas

- Habilitación de la generación automática de estadísticas a nivel de catálogo
- Visualización configuración automatizada en el nivel de tabla
- Desactivación de la generación de estadísticas de columnas a nivel de catálogo

Habilitación de la generación automática de estadísticas a nivel de catálogo

Puede habilitar la generación automática de estadísticas de columnas en todas las tablas nuevas de Apache Iceberg y las tablas que tengan formatos que no sean OTF (Parquet, JSON, CSV, XML, ORC, ION) del catálogo de datos. Tras crear la tabla, también puede actualizar de forma explícita y manual la configuración de las estadísticas de columnas.

Para actualizar la configuración del catálogo de datos y así poder habilitar el nivel de catálogo, el rol de IAM que utilice debe tener el permiso `glue:UpdateCatalog` o el permiso AWS Lake Formation `ALTER CATALOG` del catálogo raíz. Puede utilizar la API `GetCatalog` para verificar las propiedades del catálogo.

Consola de administración de AWS

Habilitación de la generación automática de estadísticas de columnas a nivel de cuenta

1. Abra la consola de Lake Formation en https://console.aws.amazon.com/lakeformation/.
2. En la barra de navegación izquierda, elija Claves.
3. En la página Resumen del catálogo, seleccione Editar en Configuración de la optimización.

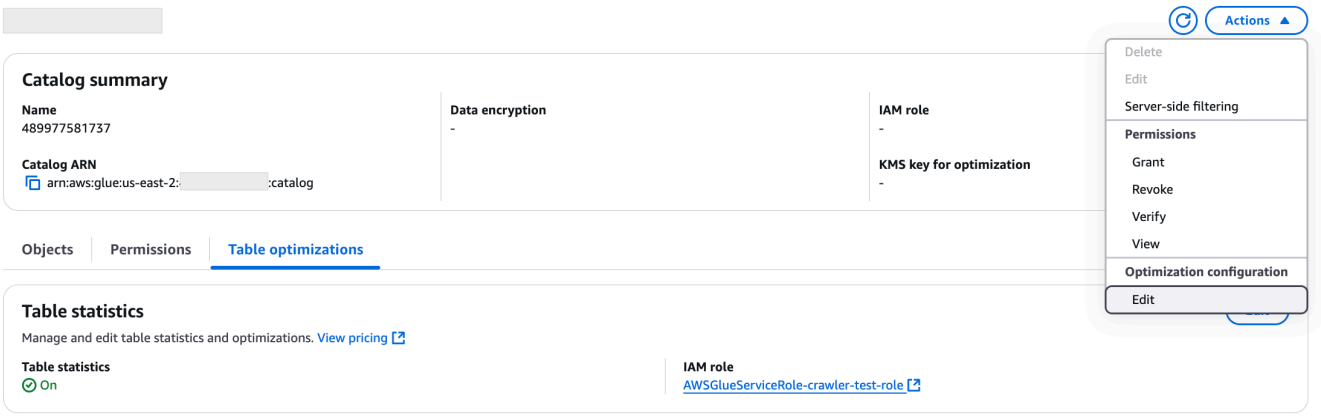

4. En la página Configuración de la optimización de tablas, elija la opción Habilitar la generación automática de estadísticas para las tablas del catálogo.

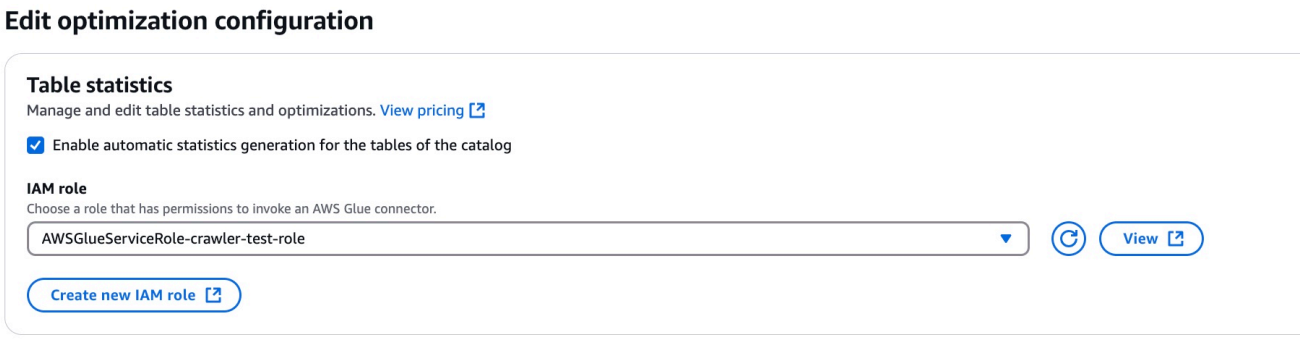

5. Elija un rol de IAM existente o cree uno nuevo con los permisos necesarios para ejecutar la tarea de estadísticas de columnas.
6. Elija Enviar.

AWS CLI

También puede habilitar la recopilación de estadísticas a nivel de catálogo a través de AWS CLI. Para configurar la recopilación de estadísticas a nivel de tabla mediante AWS CLI, ejecute el siguiente comando:

```
aws glue update-catalog --cli-input-json '{
    "name": "123456789012",
    "catalogInput": {
        "description": "Updating root catalog with role arn",
        "catalogProperties": {
            "customProperties": {
                "ColumnStatistics.RoleArn": "arn:aws:iam::"123456789012":role/
service-role/AWSGlueServiceRole",
                "ColumnStatistics.Enabled": "true"
            }
        }
    }
}'
```

El comando anterior llama a operación `UpdateCatalog` de AWS Glue, que adopta una estructura `CatalogProperties` con los siguientes pares clave-valor para generar estadísticas a nivel de catálogo:

- ColumnStatistics.RoleArn: ARN del rol de IAM se utilizará en todas las tareas activadas para la generación de estadísticas a nivel de catálogo
- ColumnStatistics.Enabled: valor booleano que indica si la configuración a nivel de catálogo está habilitada o deshabilitada

Visualización configuración automatizada en el nivel de tabla

Cuando la recopilación de estadísticas en el catálogo está habilitada, cada vez que se crea o actualiza una tabla de Apache Hive o de Apache Iceberg mediante las API de `CreateTable` o de `UpdateTable` a través de Consola de administración de AWS, un SDK o Rastreador de AWS Glue, una configuración de tabla equivalente se crea para esa tabla.

Las tablas que tengan la generación automática de estadísticas habilitada deben seguir una de las siguientes propiedades:

- Utilice una propiedad `InputSerdeLibrary` que comience por org.apache.hadoop y `TableType` sea igual a `EXTERNAL_TABLE`.
- Utilice una propiedad `InputSerdeLibrary` que comience por `com.amazon.ion` y `TableType` sea igual a `EXTERNAL_TABLE`.
- Guarde un valor table_type: “ICEBERG” en su estructura de parámetros.

Después de crear o actualizar una tabla, puede verificar los detalles de esta para confirmar la generación de estadísticas. `Statistics generation summary` muestra el conjunto de propiedades `Schedule` como `AUTO`, y el valor `Statistics configuration` es `Inherited from catalog`. Glue activará automáticamente y de forma interna cualquier configuración de tabla que tenga los siguientes parámetros.

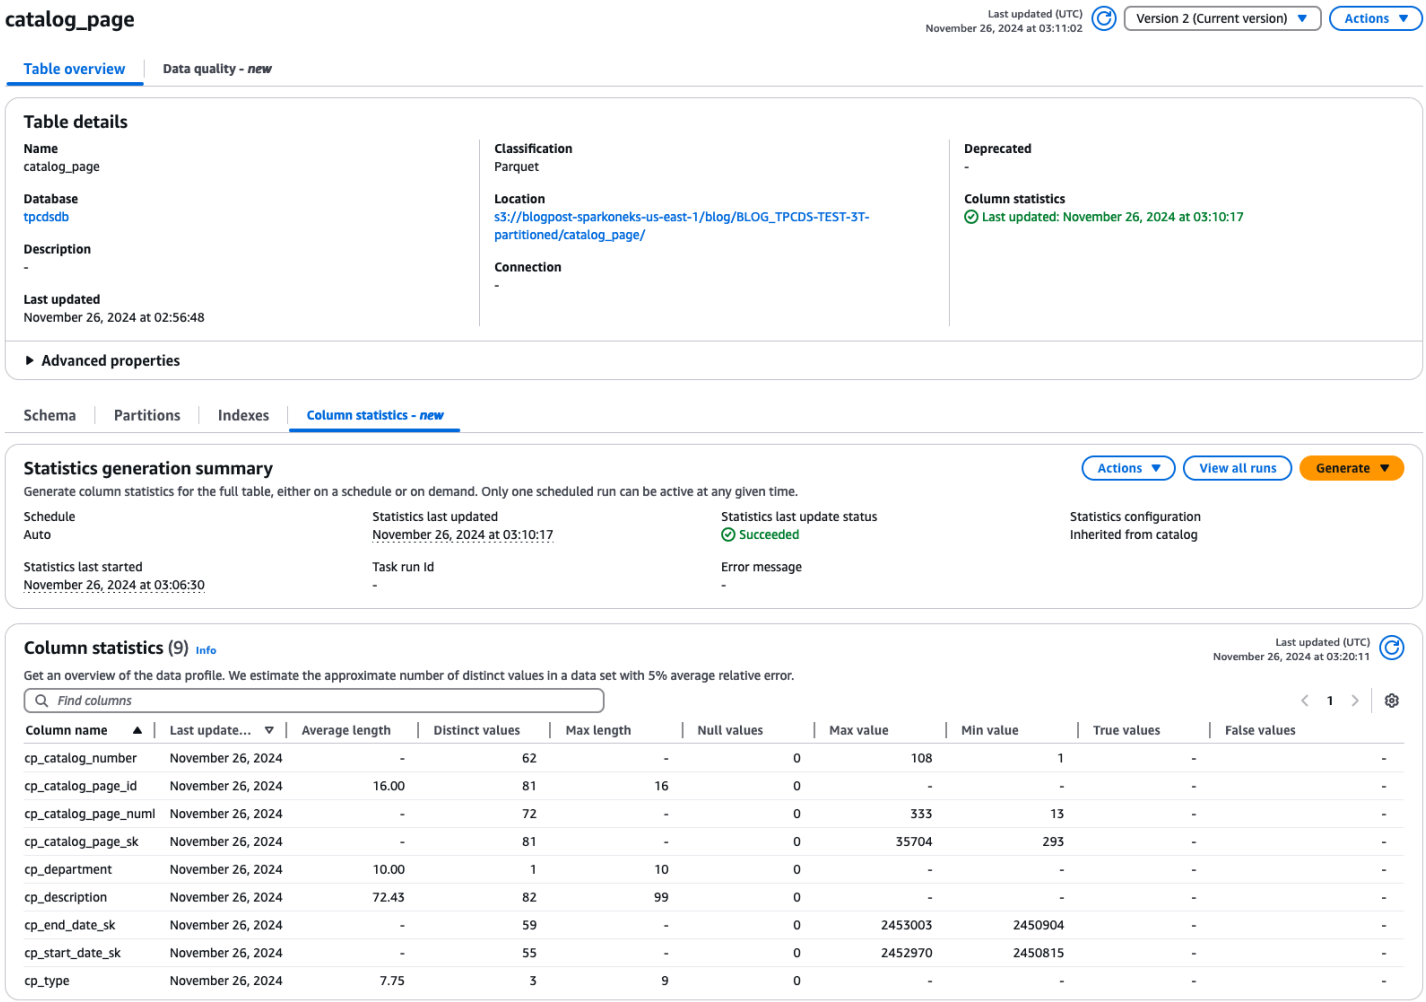

Desactivación de la generación de estadísticas de columnas a nivel de catálogo

Puede deshabilitar la generación automática de estadísticas de columnas en tablas nuevas mediante la consola AWS Lake Formation, la API `glue:UpdateCatalogSettings` o la API `glue:DeleteColumnStatisticsTaskSettings`.

Desactivación de la generación automática de estadísticas de columnas a nivel de cuenta

1. Abra la consola de Lake Formation en https://console.aws.amazon.com/lakeformation/.
2. En la barra de navegación izquierda, elija Claves.

3. En la página Resumen del catálogo, seleccione Editar en Configuración de la optimización.
4. En la página Configuración de la optimización de tablas, anule la selección de la opción Habilitar la generación automática de estadísticas en las tablas del catálogo.
5. Elija Enviar.

Generación de estadísticas de columnas según una programación

Siga estos pasos para configurar una programación para generar estadísticas de columnas en AWS Glue Data Catalog mediante la consola de AWS Glue, la AWS CLI o la operación CreateColumnStatisticsTaskSettings.

Console

Generación de estadísticas de columnas mediante la consola

1. Inicie sesión en la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. Seleccione las tablas del Data Catalog.
3. Seleccione una tabla de la lista.
4. Seleccione la pestaña Estadísticas de columnas en la sección inferior de la página Tablas.
5. También puede seleccionar Generar según una programación en Estadísticas de columnas de la sección Acciones.
6. En la página Generar estadísticas según una programación, configure una programación periódica para ejecutar la tarea de estadísticas de columnas seleccionando la frecuencia y la hora de inicio. Puede elegir la frecuencia para que sea por hora, día o semana, o definir una expresión cron para especificar el horario.

   Una expresión cron es una cadena que representa un patrón de programación y consta de 6 campos separados por espacios: * * * * * <minuto> <hora> <día del mes> <mes> <día de la semana> <año> Por ejemplo, para ejecutar una tarea todos los días a medianoche, la expresión cron sería: 0 0 * * ? *

   Para obtener más información, consulte Expresiones Cron.

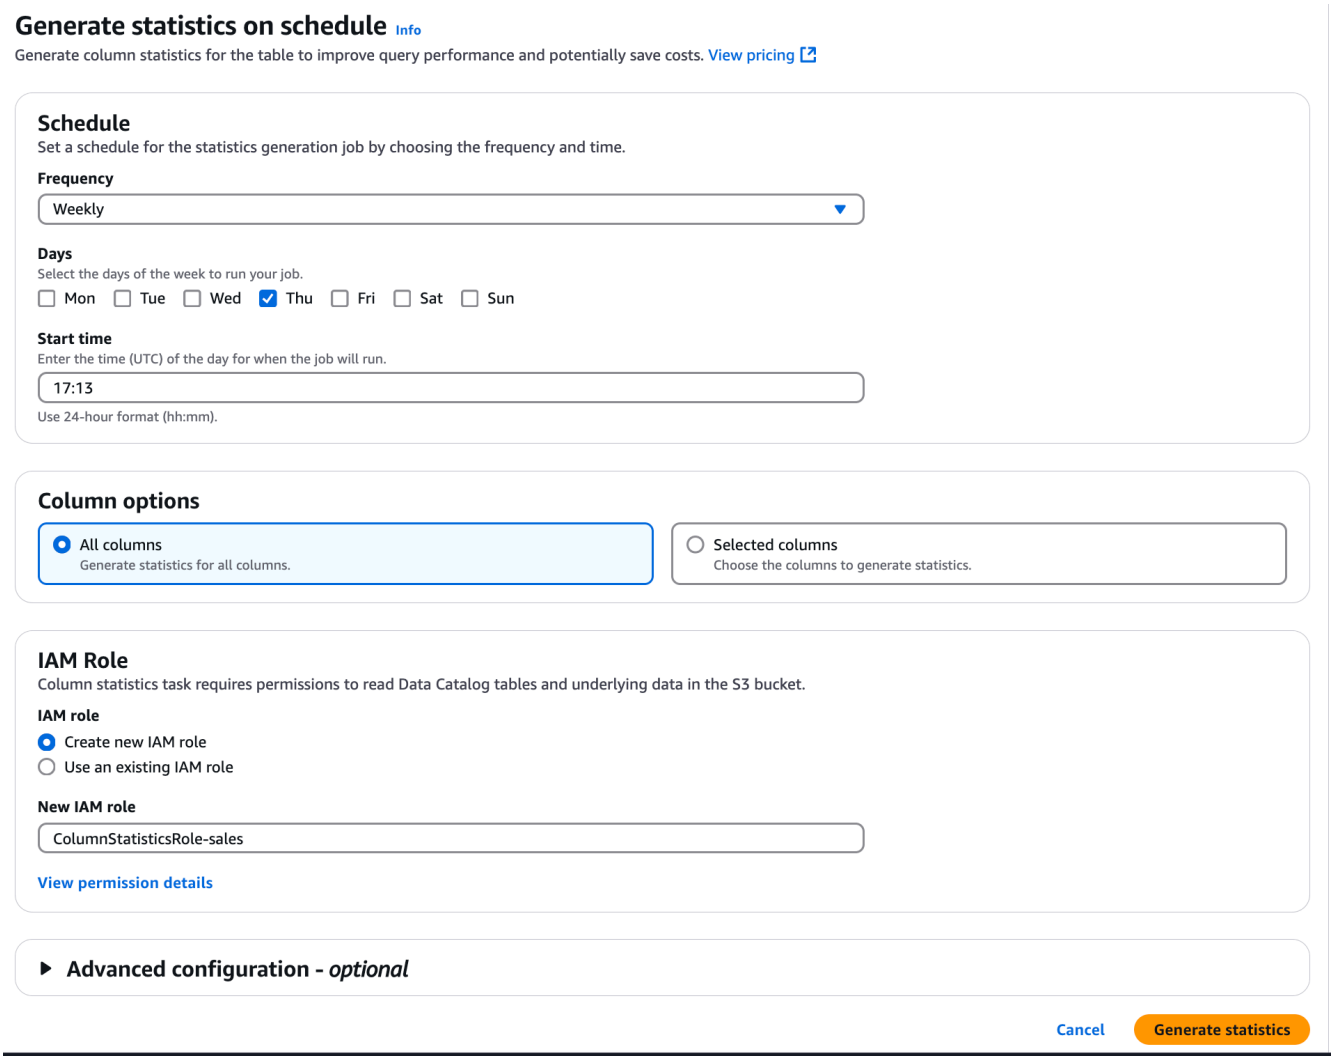

7. A continuación, elija la opción de columnas para generar las estadísticas.

   - Todas las columnas: elija esta opción para generar estadísticas para todas las columnas de la tabla.
   - Columnas seleccionadas: elija esta opción para generar estadísticas para columnas específicas. Puede seleccionar las columnas en la lista desplegable.

8. Elija un rol de IAM o cree un rol existente que tenga permisos para generar estadísticas. AWS Glue asume este rol para generar estadísticas de columnas.

   Un enfoque más rápido es dejar que la consola de AWS Glue cree un rol para usted. El rol que crea es específicamente para generar las estadísticas de columnas e incluye la política `AWSGlueServiceRole` administrada por AWS, más la política en línea necesaria para el origen de datos especificado.

Si especifica un rol existente para generar estadísticas de columnas, asegúrese de que incluya la política `AWSGlueServiceRole` o una equivalente (o una versión reducida de esta política), además de las políticas insertadas requeridas.

9. (Opcional) A continuación, elija una configuración de seguridad para habilitar el cifrado en reposo de los registros.
10. (Opcional) Para elegir un tamaño de muestra, indique solo un porcentaje específico de filas de la tabla para generar estadísticas. El valor predeterminado es Todas las filas. Utilice las flechas hacia arriba y hacia abajo para aumentar o disminuir el valor porcentual.

    Se recomienda incluir todas las filas de la tabla para calcular estadísticas precisas. Utilice filas de muestra para generar estadísticas de columnas solo cuando los valores aproximados sean aceptables.
11. Elija Generar estadísticas para ejecutar la tarea de generación de estadísticas de columnas.

AWS CLI

Puede usar el siguiente AWS CLI de ejemplo para crear una programación de generación de estadísticas de columnas. Database-name, table-name y role son parámetros obligatorios, y los parámetros opcionales son schedule, column-name-list, catalog-id, sample-size, and security-configuration.

```
aws glue create-column-statistics-task-settings \
 --database-name 'database_name' \
 --table-name table_name \
 --role 'arn:aws:iam::123456789012:role/stats-role' \
 --schedule 'cron(0 0-5 14 * * ?)' \
 --column-name-list 'col-1' \
 --catalog-id '123456789012' \
 --sample-size '10.0 ' \
 --security-configuration 'test-security'
```

También puede generar estadísticas de columnas llamando a la operación StartColumnStatisticsTaskRun.

Administración de la programación para la generación de estadísticas de columnas

Puede administrar las operaciones de programación, como actualizar, iniciar, detener y eliminar las programaciones para la generación de estadísticas de columnas en AWS Glue. Puede utilizar la consola de AWS Glue, AWS CLI o las operaciones de la API de estadísticas de columnas de AWS Glue para realizar estas tareas.

Temas

- Actualización de la programación para la generación de estadísticas de columnas
- Detención de la programación para la generación de estadísticas de columnas
- Reanudación de la programación para la generación de estadísticas de columnas
- Eliminación de la programación de estadísticas de columnas

Actualización de la programación para la generación de estadísticas de columnas

Puede actualizar la programación para activar la tarea de generación de estadísticas de columnas después de haberla creado. Puede utilizar la consola de AWS Glue, AWS CLI o ejecutar la operación UpdateColumnStatisticsTaskSettings para actualizar la programación de una tabla. Puede modificar los parámetros de una programación existente, como el tipo de programación (bajo demanda o programada) y otros parámetros opcionales.

Consola de administración de AWS

Para actualizar la configuración de una tarea de estadísticas de columnas

1. Inicie sesión en la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. Elija la tabla que desea actualizar de la lista de tablas.
3. En la sección inferior de la página de detalles de la tabla, elija Estadísticas de columnas.
4. En Acciones, elija Editar para actualizar la programación.
5. Realice los cambios que desee en la programación y seleccione Guardar.

AWS CLI

Si no está utilizando la característica de generación de estadísticas de AWS Glue en la consola, puede actualizar manualmente la programación con el comando `update-column-statistics-task-settings`. En el siguiente ejemplo, se muestra cómo actualizar las estadísticas de las columnas mediante AWS CLI.

```
aws glue update-column-statistics-task-settings \
 --database-name 'database_name' \
 --table-name 'table_name' \
 --role arn:aws:iam::123456789012:role/stats_role \
 --schedule 'cron(0 0-5 16 * * ?)' \
 --column-name-list 'col-1' \
 --sample-size '20.0' \
 --catalog-id '123456789012'\
 --security-configuration 'test-security'
```

Detención de la programación para la generación de estadísticas de columnas

Si ya no necesita estadísticas incrementales, puede detener la generación programada para ahorrar recursos y costos. Pausar la programación no afecta las estadísticas generadas anteriormente. Puede reanudar la programación cuando lo desee.

Consola de administración de AWS

Para detener la programación para una tarea de generación de estadísticas de columnas

1. En la consola AWS Glue, seleccione Tablas en el catálogo de datos.
2. Seleccione una tabla con estadísticas de columnas.
3. En la página de Detalles de la tabla, seleccione Estadísticas de columnas.
4. En Acciones, elija Generación programada y Pausar.
5. Seleccione Pausar para confirmar.

AWS CLI

Para detener la programación de ejecución de una tarea de estadísticas de columnas mediante la AWS CLI, puede utilizar el siguiente comando:

```
aws glue stop-column-statistics-task-run-schedule \
 --database-name ''database_name' \
 --table-name 'table_name'
```

Reemplace `database_name` y `table_name` con los nombres reales de la base de datos y la tabla para las que desea detener la programación de ejecución de la tarea de estadísticas de columnas.

Reanudación de la programación para la generación de estadísticas de columnas

Si ha pausado la programación de generación de estadísticas, AWS Glue le permite reanudarla cuando lo desee. Puede reanudar la programación mediante la consola de AWS Glue, AWS CLI o la operación StartColumnStatisticsTaskRunSchedule.

Consola de administración de AWS

Para reanudar la programación para la generación de estadísticas de columnas

1. En la consola AWS Glue, seleccione Tablas en el catálogo de datos.
2. Seleccione una tabla con estadísticas de columnas.
3. En la página de Detalles de la tabla, seleccione Estadísticas de columnas.
4. En Acciones, elija Generación programada y Reanudar.
5. Seleccione Reanudar para confirmar.

AWS CLI

Reemplace `database_name` y `table_name` con los nombres reales de la base de datos y la tabla para las que desea detener la programación de ejecución de la tarea de estadísticas de columnas.

```
aws glue start-column-statistics-task-run-schedule \
 --database-name 'database_name' \
 --table-name 'table_name'
```

Eliminación de la programación de estadísticas de columnas

Si bien por lo general se recomienda mantener las estadísticas actualizadas para obtener un rendimiento óptimo de las consultas, hay casos de uso específicos en los que eliminar la programación de generación automática podría resultar beneficioso.

- Si los datos permanecen relativamente estáticos, las estadísticas de las columnas existentes pueden seguir siendo precisas durante un período prolongado, lo que reduce la necesidad de

actualizaciones frecuentes. Eliminar la programación puede evitar el consumo innecesario de recursos y la sobrecarga asociada con la regeneración de estadísticas en datos que no sufren modificaciones.

- Cuando se prefiere el control manual sobre la generación de estadísticas. Al eliminar la programación automática, los administradores pueden actualizar selectivamente las estadísticas de las columnas en intervalos específicos o después de cambios significativos en los datos, alineando el proceso con sus estrategias de mantenimiento y necesidades de asignación de recursos.

Consola de administración de AWS

Para eliminar la programación de generación de estadísticas de columnas

1. En la consola AWS Glue, seleccione Tablas en el catálogo de datos.
2. Seleccione una tabla con estadísticas de columnas.
3. En la página de Detalles de la tabla, seleccione Estadísticas de columnas.
4. En Acciones, elija Generación programada y Eliminar.
5. Elija Eliminar para confirmar.

AWS CLI

Reemplace `database_name` y `table_name` con los nombres reales de la base de datos y la tabla para las que desea detener la programación de ejecución de la tarea de estadísticas de columnas.

Puede eliminar la programación de estadísticas de las columnas mediante la operación de API DeleteColumnStatisticsTaskSettings o AWS CLI. En el ejemplo siguiente se muestra cómo eliminar la programación para generar estadísticas de columnas mediante AWS Command Line Interface (AWS CLI).

```
aws glue delete-column-statistics-task-settings \
    --database-name 'database_name' \
    --table-name 'table_name'
```

Generación de estadísticas de columnas bajo demanda

Puede ejecutar la tarea de estadísticas de columnas para la tarea de tablas de AWS Glue Data Catalog bajo demanda sin una programación establecida. Esta opción resulta útil para realizar un análisis ad hoc o cuando es necesario calcular las estadísticas de forma inmediata.

Siga estos pasos para generar las estadísticas de columnas bajo demanda para el catálogo de datos mediante la consola de AWS Glue o AWS CLI.

Consola de administración de AWS

Generación de estadísticas de columnas mediante la consola

1. Inicie sesión en la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. Seleccione las tablas del Data Catalog.
3. Seleccione una tabla de la lista.
4. Seleccione Generar estadísticas en el menú Acciones.

   También puede elegir la opción Generar, Generar bajo demanda en la pestaña Estadísticas de columnas, en la sección inferior de la página de Tabla.
5. Siga los pasos 7 a 11 de Generación de estadísticas de columnas según una programación para generar estadísticas de columnas para la tabla.
6. En la página Generar estadísticas, especifique las siguientes opciones:

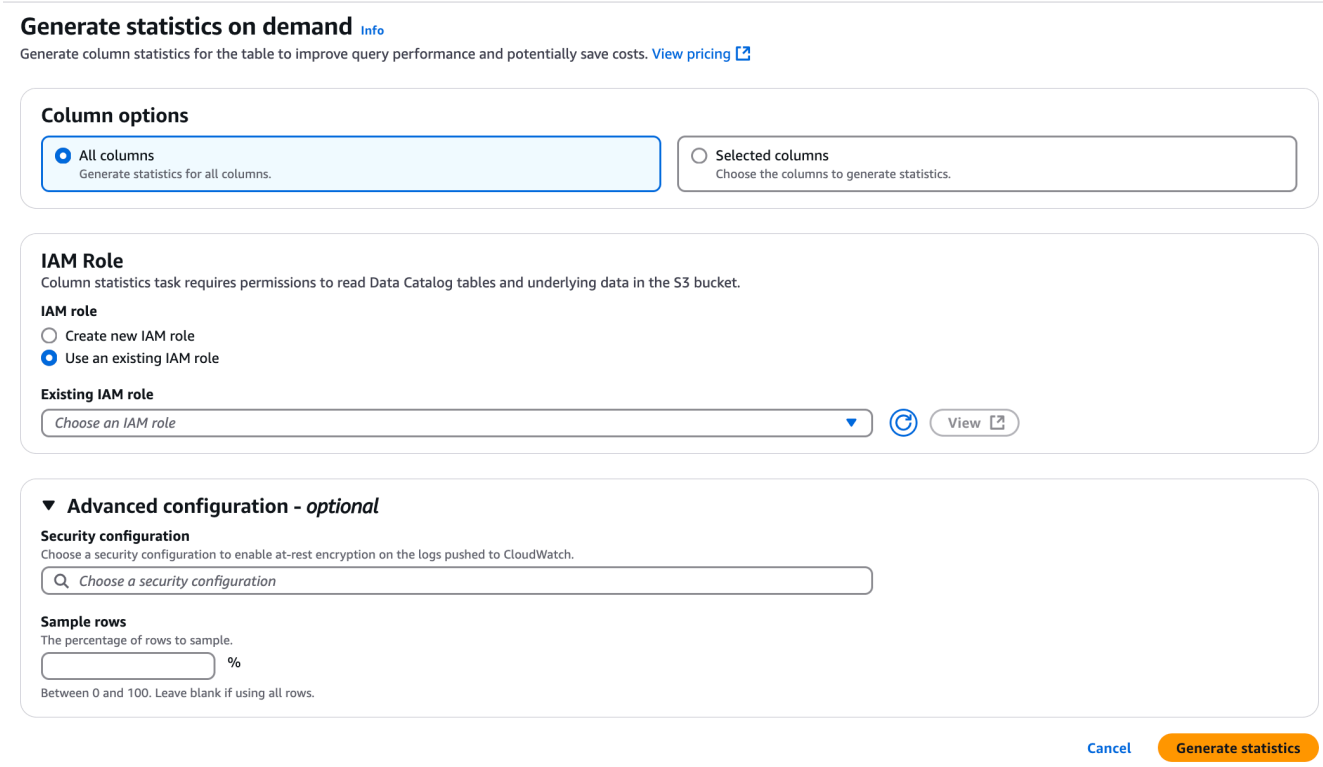

- Todas las columnas: elija esta opción para generar estadísticas para todas las columnas de la tabla.
- Columnas seleccionadas: elija esta opción para generar estadísticas para columnas específicas. Puede seleccionar las columnas en la lista desplegable.
- Rol de IAM: elija Crear un nuevo rol de IAM que tenga las políticas de permisos necesarias para ejecutar la tarea de generación de estadísticas de columnas. Elija Ver detalles del permiso para revisar la declaración de la política. También puede elegir un rol de IAM de la lista. Para obtener más información sobre los permisos necesarios, consulte Requisitos previos para generar estadísticas de columnas.

  AWS Glue asume los permisos del rol que se especifican para generar estadísticas.

  Para obtener más información sobre cómo proporcionar roles para AWS Glue, consulte Políticas basadas en identidad para AWS Glue.
- (Opcional) A continuación, elija una configuración de seguridad para habilitar el cifrado en reposo de los registros.
- Filas de muestra: elija solo un porcentaje específico de filas de la tabla para generar estadísticas. El valor predeterminado es Todas las filas. Utilice las flechas hacia arriba y hacia abajo para aumentar o disminuir el valor porcentual.

> **Note**
>
> Se recomienda incluir todas las filas de la tabla para calcular estadísticas precisas. Utilice filas de muestra para generar estadísticas de columnas solo cuando los valores aproximados sean aceptables.

Elija Generar estadísticas para ejecutar la tarea.

AWS CLI

Este comando activará la ejecución de una tarea de estadísticas de columnas para la tabla especificada. Debe proporcionar el nombre de la base de datos, el nombre de la tabla, un rol de IAM con permisos para generar estadísticas y, de forma opcional, proporcionar los nombres de las columnas y un porcentaje del tamaño de la muestra para el cálculo de las estadísticas.

```
aws glue start-column-statistics-task-run \
    --database-name 'database_name \
    --table-name 'table_name' \
    --role 'arn:aws:iam::123456789012:role/stats-role' \
    --column-name 'col1','col2'  \
    --sample-size 10.0
```

Este comando iniciará una tarea para generar estadísticas de columnas para la tabla especificada.

Actualización de estadísticas de columnas bajo demanda

Mantener las estadísticas de las columnas actualizadas es fundamental para que el optimizador de consultas genere planes de ejecución eficientes, lo que garantiza un mejor rendimiento de las consultas, una reducción del consumo de recursos y un mejor rendimiento general del sistema. Este proceso es especialmente importante después de cambios importantes en los datos, como cargas masivas o modificaciones exhaustivas, que pueden hacer que las estadísticas existentes queden obsoletas.

Debe ejecutar explícitamente la tarea Generar estadísticas desde la consola AWS Glue para actualizar las estadísticas de las columnas. El catálogo de datos no actualiza automáticamente las estadísticas.

Si no utiliza la característica de generación de estadísticas de AWS Glue en la consola, puede actualizar manualmente las estadísticas de las columnas mediante la operación de API UpdateColumnStatisticsForTable o AWS CLI. En el siguiente ejemplo, se muestra cómo actualizar las estadísticas de las columnas mediante AWS CLI.

```
aws glue update-column-statistics-for-table --cli-input-json:

{
    "CatalogId": "111122223333",
    "DatabaseName": "database_name",
    "TableName": "table_name",
    "ColumnStatisticsList": [
        {
            "ColumnName": "col1",
            "ColumnType": "Boolean",
            "AnalyzedTime": "1970-01-01T00:00:00",
            "StatisticsData": {
                "Type": "BOOLEAN",
                "BooleanColumnStatisticsData": {
                    "NumberOfTrues": 5,
                    "NumberOfFalses": 5,
                    "NumberOfNulls": 0
                }
            }
        }
    ]
}
```

Visualización de estadísticas de columnas

Tras generar las estadísticas correctamente, el catálogo de datos almacena esta información para que los optimizadores basados en los costos de Amazon Athena y Amazon Redshift puedan tomar las decisiones óptimas al ejecutar consultas. Las estadísticas varían en función del tipo de columna.

Consola de administración de AWS

Visualización de las estadísticas de columna de una tabla

- Tras ejecutar la tarea de estadísticas de columnas, la pestaña Estadísticas de columnas de la página de Detalles de la tabla muestra las estadísticas de la tabla.

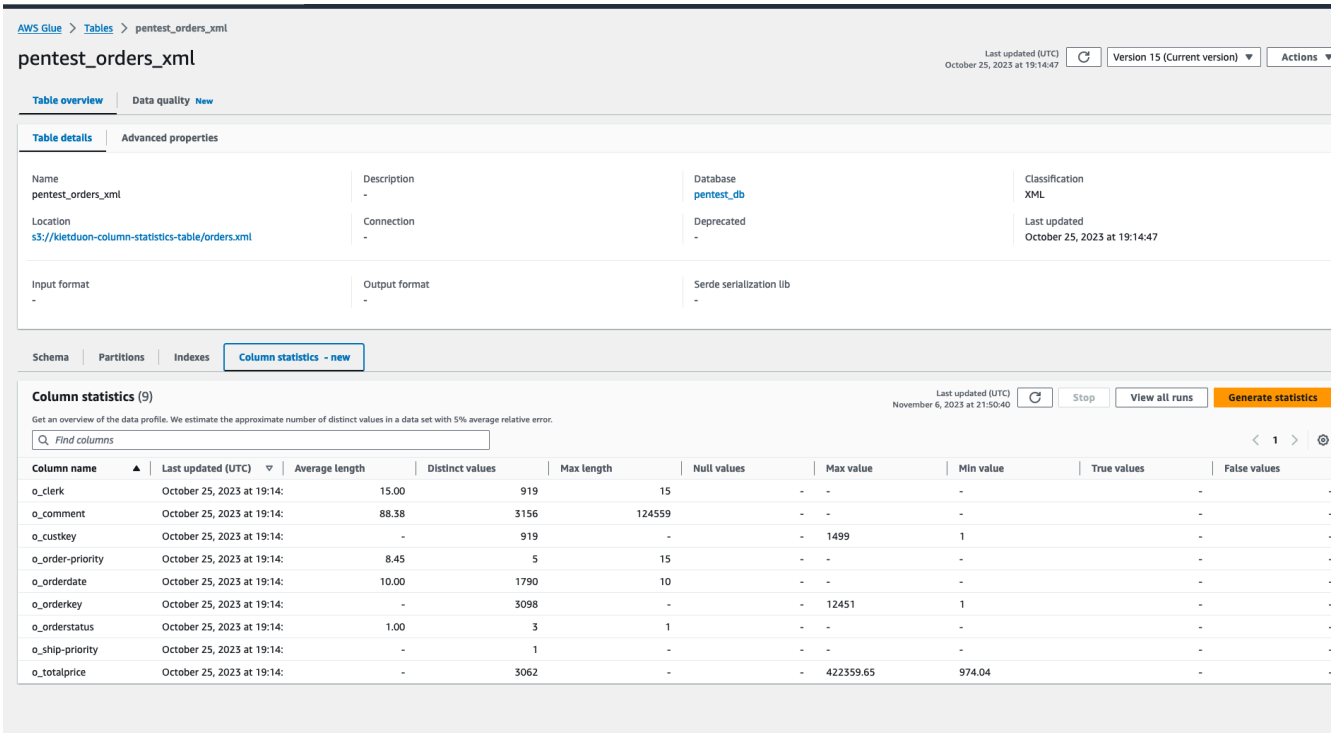

Están disponibles las siguientes estadísticas:

- Nombre de columna: nombre de columna utilizado para generar estadísticas
- Última actualización: fecha y hora en que se generaron las estadísticas
- Longitud media: longitud media de los valores de la columna
- Valores distintos: número total de valores distintos de la columna. Estimamos el número de valores distintos de una columna con un error relativo del 5 %.
- Valor máximo: el valor más alto de la columna.
- Valor mínimo: el valor más bajo de la columna.
- Longitud máxima: longitud del valor más alto de la columna.
- Valores nulos: el número total de valores nulos en la columna.
- Valores verdaderos: el número de valores verdaderos en la columna.
- Valores falsos: el número de valores falsos en la columna.

- numFiles: número total de archivos de la tabla. Este valor está disponible en la pestaña Propiedades avanzadas.

AWS CLI

En el siguiente ejemplo se muestra cómo recuperar estadísticas de columnas mediante AWS CLI.

```
aws glue get-column-statistics-for-table \
    --database-name database_name \
    --table-name table_name \
    --column-names <column_name>
```

También puede ver las estadísticas de las columnas mediante la operación de API GetColumnStatisticsForTable.

Visualización de las ejecuciones de tareas de estadísticas de columnas

Después de ejecutar una tarea de estadísticas de columnas, puede explorar los detalles de la ejecución de la tarea de una tabla mediante la consola AWS Glue, AWS CLI o mediante la operación GetColumnStatisticsTaskRuns.

Console

Para ver los detalles de ejecución de la tarea con estadísticas de columnas

1. En la consola AWS Glue, seleccione Tablas en el catálogo de datos.
2. Seleccione una tabla con estadísticas de columnas.
3. En la página de Detalles de la tabla, seleccione Estadísticas de columnas.
4. Seleccione Ver ejecuciones.

   Puede ver información sobre todas las ejecuciones asociadas a la tabla especificada.

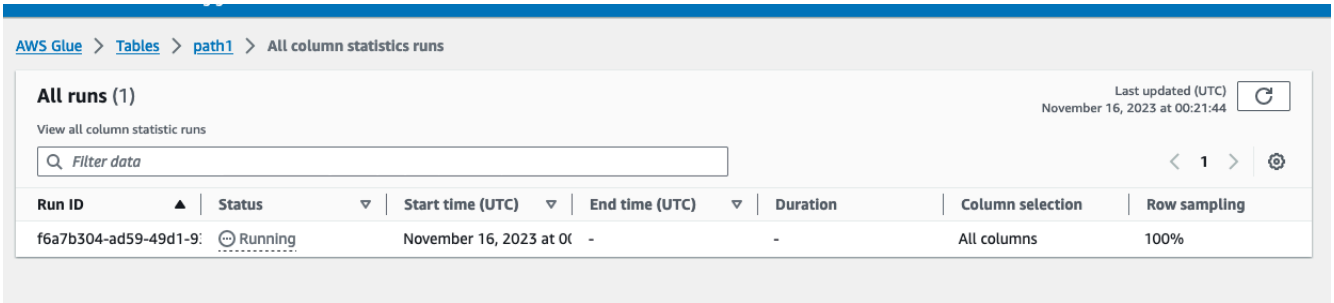

AWS CLI

En el siguiente ejemplo, sustituya los valores de `DatabaseName` y `TableName` por el nombre real de la base de datos y la tabla.

```
aws glue get-column-statistics-task-runs --input-cli-json file://input.json
{
    "DatabaseName": "database_name",
    "TableName": "table_name"
}
```

Detener la ejecución de la tarea de estadísticas de columnas

Puede detener la ejecución de una tarea de estadísticas de columnas para una tabla mediante la consola AWS Glue, AWS CLI o mediante la operación StopColumnStatisticsTaskRun.

Console

Para detener una tarea de estadísticas de columnas, ejecute

1. En la consola AWS Glue, seleccione Tablas en el catálogo de datos.
2. Seleccione la tabla con la columna de La ejecución de la tarea de estadísticas está en curso.
3. En la página de Detalles de la tabla, seleccione Estadísticas de columnas.
4. Elija Detener.

   Si detiene la tarea antes de que se complete la ejecución, no se generarán las estadísticas de las columnas para la tabla.

AWS CLI

En el siguiente ejemplo, sustituya los valores de `DatabaseName` y `TableName` por el nombre real de la base de datos y la tabla.

```
aws glue stop-column-statistics-task-run --input-cli-json file://input.json
{
    "DatabaseName": "database_name",
    "TableName": "table_name"
}
```

Eliminar estadísticas de columnas

Puede eliminar las estadísticas de las columnas mediante la operación de API DeleteColumnStatisticsForTable o AWS CLI. En el ejemplo siguiente se muestra cómo eliminar estadísticas de columnas mediante AWS Command Line Interface (AWS CLI).

```
aws glue delete-column-statistics-for-table \
    --database-name 'database_name' \
    --table-name 'table_name' \
    --column-name 'column_name'
```

Consideraciones y limitaciones

Las siguientes consideraciones y limitaciones se aplican a la generación de estadísticas de columnas.

Consideraciones

- El uso del muestreo para generar estadísticas reduce el tiempo de ejecución, pero puede generar estadísticas inexactas.
- El catálogo de datos no almacena versiones diferentes de las estadísticas.
- Solo puede ejecutar una tarea de generación de estadísticas a la vez por tabla.
- Si una tabla se cifra con la clave AWS KMS de cliente registrada en el catálogo de datos, AWS Glue utiliza la misma clave para cifrar las estadísticas.

La tarea de estadísticas de las columnas permite generar estadísticas:

- Cuando el rol de IAM tiene permisos de tabla completos (IAM o Lake Formation).
- Cuando el rol de IAM tiene permisos sobre la tabla mediante el modo de acceso híbrido de Lake Formation.

La tarea de estadísticas de columnas no admite la generación de estadísticas para:

- Tablas con control de acceso basado en celdas de Lake Formation

- Lagos de datos transaccionales: Fundación Linux Delta Lake, Apache Hudi
- Tablas en bases de datos federadas: recursos compartidos de datos Hive metastore, Amazon Redshift
- Columnas anidadas, matrices y tipos de datos de estructura.
- Tabla que se comparte con usted desde otra cuenta

Cifrado del Catálogo de datos

Para proteger los metadatos en reposo que están almacenados en el AWS Glue Data Catalog, puede usar claves de cifrado administradas por AWS Key Management Service (AWS KMS). En Configuración del Catálogo de datos, puede activar el cifrado del Catálogo de datos para el nuevo catálogo. Puede activar o desactivar el cifrado del Catálogo de datos existente, según lo que necesite. Cuando está activado, AWS Glue cifra todos los metadatos nuevos que se escriben en el catálogo, mientras que los ya existentes permanecen sin cifrar.

Para obtener información detallada sobre el cifrado del Catálogo de datos, consulte Cifrado del Catálogo de datos.

Cómo proteger su Catálogo de datos con Lake Formation

AWS Lake Formation es un servicio que facilita la configuración de un lago de datos seguro en AWS. Proporciona un lugar central para crear y administrar sus lagos de datos de forma segura mediante la definición de permisos detallados para controlar el acceso. Lake Formation usa el Catálogo de datos para almacenar y recuperar metadatos sobre su lago de datos, como las definiciones de tablas, la información de los esquemas y las configuraciones del control de acceso a los datos.

Puede registrar la ubicación de sus datos de Amazon S3 de la base de datos o la tabla de metadatos con Lake Formation y usarla para definir los permisos a nivel de metadatos en los recursos del Catálogo de datos. También puede usar Lake Formation para administrar los permisos de acceso al almacenamiento en los datos subyacentes que se guardan en Amazon S3 en nombre de los motores analíticos integrados.

Para obtener más información, consulte ¿Qué es AWS Lake Formation?.

Trabajar con vistas AWS Glue Data Catalog en AWS Glue

Puede crear y gestionar vistas en AWS Glue Data Catalog, conocidas comúnmente como vistas AWS Glue Data Catalog. Estas vistas son útiles porque admiten varios motores de consultas SQL, lo

que le permite acceder a la misma vista en diferentes servicios AWS, como Amazon Athena, Amazon Redshift y AWS Glue. Puede utilizar vistas basadas en Apache Iceberg, Apache Hudi y Delta Lake.

Al crear una vista en el Catálogo de datos, puede usar concesiones de recursos y controles de acceso basados en etiquetas en AWS Lake Formation para otorgar acceso a dicha vista. Al utilizar este método de control de acceso, no es necesario configurar permisos adicionales para las tablas referenciadas al crear la vista. Este método de concesión de permisos se denomina semántica del definidor y estas vistas se denominan vistas del definidor. Para obtener más información sobre el control de acceso en AWS Lake Formation, consulte la sección Concesión y revocación de permisos en los recursos del Catálogo de datos de en la Guía para desarrolladores de AWS Lake Formation.

Las vistas del Catálogo de datos son útiles para los siguientes casos de uso:

- Control de acceso detallado: puede crear una vista que restrinja el acceso a los datos en función de los permisos que necesite el usuario. Por ejemplo, puede usar las vistas del Catálogo de datos para evitar que el personal que no trabaje en el departamento de Recursos Humanos (RR.HH.) vea información de identificación personal (PII).
- Definición de vista completa: al aplicar determinados filtros a la vista del Catálogo de datos, se asegura de que los registros de datos disponibles en la vista estén siempre completos.
- Seguridad mejorada: La definición de la consulta utilizada para crear la vista debe estar completa, lo que hace que las vistas del Catálogo de datos sean menos susceptibles a comandos SQL de actores maliciosos.
- Uso compartido de datos sencillo: Comparta datos con otras cuentas de AWS sin mover los datos, utilizando el uso compartido de datos entre cuentas en AWS Lake Formation.

Creación de una vista del catálogo de datos

Puede crear vistas del Catálogo de datos utilizando AWS CLI y scripts ETL de AWS Glue usando Spark SQL. La sintaxis para crear una vista del Catálogo de datos incluye especificar el tipo de vista como `MULTI DIALECT` y el predicado `SECURITY` como `DEFINER`, lo que indica una vista de definidor.

Ejemplo de instrucción SQL para crear una vista en el Catálogo de datos:

```
CREATE PROTECTED MULTI DIALECT VIEW database_name.catalog_view SECURITY DEFINER
AS SELECT order_date, sum(totalprice) AS price
FROM source_table
GROUP BY order_date;
```

Después de crear una vista del Catálogo de datos, puede utilizar un rol de IAM con el permiso AWS Lake Formation `SELECT` en la vista para consultarla desde servicios como Amazon Athena, Amazon Redshift o trabajos ETL de AWS Glue. No es necesario conceder acceso a las tablas subyacentes a las que se hace referencia en la vista.

Para obtener más información sobre la creación y configuración de vistas del Catálogo de datos, consulte Creación de vistas del Catálogo de datos de AWS Glue en la Guía para desarrolladores de AWS Lake Formation.

Operaciones de vista admitidas

Los siguientes fragmentos de comandos muestran varias formas de trabajar con las vistas del Catálogo de datos:

CREATE VIEW

Crea una vista del Catálogo de datos. El siguiente es un ejemplo que muestra cómo crear una vista a partir de una tabla existente:

```
CREATE PROTECTED MULTI DIALECT VIEW catalog_view
SECURITY DEFINER AS SELECT * FROM my_catalog.my_database.source_table
```

ALTER VIEW

Sintaxis disponible:

```
ALTER VIEW view_name [FORCE] ADD DIALECT AS query
ALTER VIEW view_name [FORCE] UPDATE DIALECT AS query
ALTER VIEW view_name DROP DIALECT
```

Puede utilizar la opción `FORCE ADD DIALECT` para forzar la actualización del esquema y los subobjetos según el nuevo dialecto del motor. Tenga en cuenta que hacer esto puede provocar errores de consulta si no utiliza también `FORCE` para actualizar otros dialectos del motor. A continuación se muestra un ejemplo:

```
ALTER VIEW catalog_view FORCE ADD DIALECTAS
SELECT order_date, sum(totalprice) AS priceFROM source_tableGROUP BY orderdate;
```

A continuación se muestra cómo modificar una vista para actualizar el dialecto:

```
ALTER VIEW catalog_view UPDATE DIALECT AS
```

```
SELECT count(*) FROM my_catalog.my_database.source_table;
```

DESCRIBE VIEW

Sintaxis disponible para describir una vista:

`SHOW COLUMNS {FROM|IN} view_name [{FROM|IN} database_name]`: Si el usuario tiene los permisos AWS Glue y AWS Lake Formation necesarios para describir la vista, puede enumerar las columnas. A continuación se muestran un par de comandos de ejemplo para mostrar columnas:

```
SHOW COLUMNS FROM my_database.source_table;
SHOW COLUMNS IN my_database.source_table;
```

`DESCRIBE view_name`: Si el usuario tiene los permisos AWS Glue y AWS Lake Formation necesarios para describir la vista, puede enumerar las columnas de la vista junto con sus metadatos.

DROP VIEW

Sintaxis disponible:

```
DROP VIEW [ IF EXISTS ] view_name
```

El siguiente ejemplo muestra una instrucción `DROP` que comprueba si existe una vista antes de eliminarla:

```
DROP VIEW IF EXISTS catalog_view;
```

`SHOW CREATE VIEW view_name`: Muestra la instrucción SQL que crea la vista especificada. El siguiente es un ejemplo que muestra cómo crear una vista en el catálogo de datos:

```
SHOW CREATE TABLE my_database.catalog_view;CREATE PROTECTED MULTI DIALECT VIEW
 my_catalog.my_database.catalog_view (
  net_profit,
  customer_id,
  item_id,
  sold_date)
TBLPROPERTIES (
  'transient_lastDdlTime' = '1736267222')
SECURITY DEFINER AS SELECT * FROM
my_database.store_sales_partitioned_lf WHERE customer_id IN (SELECT customer_id from
 source_table limit 10)
```

SHOW VIEWS

Liste todas las vistas en el catálogo, como vistas regulares, vistas multidialecto (MDV) y MDV sin dialecto de Spark. La sintaxis disponible es la siguiente:

```
SHOW VIEWS [{ FROM | IN } database_name] [LIKE regex_pattern]:
```

A continuación se muestra un comando de ejemplo para mostrar vistas:

```
SHOW VIEWS IN marketing_analytics LIKE 'catalog_view*';
```

Para obtener más información sobre la creación y configuración de vistas de catálogos de datos, consulte Creación de vistas de Catálogos de datos de AWS Glue en la Guía para desarrolladores de AWS Lake Formation.

Consulta de la vista del Catálogo de datos

Tras crear una vista del Catálogo de datos, puede consultar la vista. El rol de IAM configurado en sus trabajos AWS Glue debe tener el permiso SELECT de Lake Formation en la vista del Catálogo de datos. No es necesario conceder acceso a las tablas subyacentes a las que se hace referencia en la vista.

Una vez que haya configurado todo, podrá consultar la vista. Por ejemplo, puede ejecutar la siguiente consulta para acceder a una vista.

```
SELECT * from my_database.catalog_view LIMIT 10;
```

Limitaciones

Tenga en cuenta las siguientes limitaciones cuando utilice las vistas de catálogo de datos.

- Solo puede crear vistas del Catálogo de datos con la versión 5.0 de AWS Glue o superior.
- El creador de la vista en el Catálogo de datos debe tener acceso a `SELECT` a las tablas base subyacentes a las que accede la vista. La creación de la vista en el Catálogo de datos falla si una tabla base específica tiene filtros de Lake Formation impuestos al rol del creador.
- Las tablas base no deben tener el permiso de lago de datos `IAMAllowedPrincipals` en AWS Lake Formation. Si está presente, se produce el error Las vistas de múltiples dialectos solo pueden hacer referencia a tablas sin permisos IAMAllowedPrincipals.

- La ubicación de Amazon S3 de la tabla debe estar registrada como ubicación de lago de datos de AWS Lake Formation. Si la tabla no está registrada, se produce el error `Multi Dialect views may only reference AWS Lake Formation managed tables`. Para obtener información sobre cómo registrar ubicaciones de Amazon S3 en AWS Lake Formation, consulte Registrar una ubicación de Amazon S3 en la Guía para desarrolladores de AWS Lake Formation.
- Solo puede crear vistas del catálogo de datos `PROTECTED`. No se admiten las vistas `UNPROTECTED`.
- No puede hacer referencia a tablas en otra cuenta de AWS en una definición de vista del Catálogo de datos. Tampoco se puede hacer referencia a una tabla de la misma cuenta que esté en una región distinta.
- Para compartir datos entre cuentas o regiones, toda la vista debe compartirse entre cuentas y regiones, mediante enlaces de recursos AWS Lake Formation.
- No se admiten las funciones definidas por el usuario (UDF).
- No puede hacer referencia a otras vistas en las vistas del catálogo de datos.

Cómo acceder al Catálogo de datos

Puede usar el AWS Glue Data Catalog (Catálogo de datos) para detectar y comprender sus datos. El Catálogo de datos proporciona una forma coherente de mantener las definiciones de los esquemas, los tipos de datos, las ubicaciones y otros metadatos. Puede acceder al Catálogo de datos mediante los siguientes métodos:

- Consola de AWS Glue: Puede acceder al Catálogo de datos y administrarlo por medio de la consola de AWS Glue, una interfaz de usuario en línea. La consola le permite explorar y buscar bases de datos, tablas y sus metadatos asociados, así como crear, actualizar y eliminar definiciones de metadatos.
- Rastreador de AWS Glue: Los rastreadores son programas que escanean automáticamente los orígenes de datos y completan el Catálogo de datos con metadatos. Puede crear y ejecutar rastreadores para detectar y catalogar datos de diversas fuentes, como Amazon S3, Amazon RDS, Amazon DynamoDB, Amazon CloudWatch y bases de datos relacionales que cumplen los requisitos de JDBC, como MySQL y PostgreSQL, así como de varias fuentes ajenas a AWS, como Snowflake y Google BigQuery.
- API de AWS Glue: Puede acceder al Catálogo de datos por medio de programación mediante las API de AWS Glue. Estas API le permiten interactuar con el Catálogo de datos por medio de programación, lo que permite la automatización y la integración con otras aplicaciones y servicios.

- AWS Command Line Interface (AWS CLI): Puede usar la AWS CLI para acceder al Catálogo de datos y administrarlo desde la línea de comandos. La CLI proporciona comandos para crear, actualizar y eliminar definiciones de metadatos, así como para consultar y recuperar información de metadatos.
- Integración con otros servicios de AWS: El Catálogo de datos se integra con otros servicios de AWS, lo que le permite acceder a los metadatos almacenados en el Catálogo y usarlos. Por ejemplo, puede usar Amazon Athena para consultar orígenes de datos mediante los metadatos del Catálogo de datos y usar AWS Lake Formation para administrar el acceso a los datos y la gobernanza de los recursos del Catálogo.

Temas

- Conexión al catálogo de datos mediante el punto de conexión de REST de AWS Glue Iceberg
- Conexión al catálogo de datos mediante el punto de conexión de la extensión de REST de AWS Glue Iceberg
- Especificaciones de las API de REST de AWS Glue para Apache Iceberg
- Conexión al catálogo de datos desde una aplicación Spark independiente
- Asignación de datos entre Amazon Redshift y Apache Iceberg
- Consideraciones y limitaciones al utilizar las API del catálogo de REST de Iceberg AWS Glue

Conexión al catálogo de datos mediante el punto de conexión de REST de AWS Glue Iceberg

El punto de conexión de REST de Iceberg de AWS Glue admite las operaciones de API indicadas en la especificación REST de Apache Iceberg. Si usa un cliente de REST de Iceberg, puede conectar la aplicación que se ejecuta en un motor de análisis al catálogo de REST hospedado en el catálogo de datos.

El punto de conexión es compatible con las dos especificaciones de la tabla de Apache Iceberg, v1 y v2; de forma predeterminada, se usará v2. Si utiliza la especificación v1 de la tabla de Iceberg, debe especificar v1 en la llamada a la API. Mediante la operación de API, puede acceder a las tablas de Iceberg que se guardan tanto en el almacenamiento de objetos de Amazon S3 como en el almacenamiento de tablas de Amazon S3.

Configuración de puntos de conexión

Puede acceder al catálogo de REST de AWS Glue Iceberg con el punto de conexión del servicio. Consulte la guía de referencia de puntos de conexión de servicio de AWS Glue para el punto de conexión específico de la región. Por ejemplo, si conecta AWS Glue a la región us-east-1, debe configurar la propiedad URI del punto de conexión como se indica a continuación:

```
Endpoint : https://glue.us-east-1.amazonaws.com/iceberg
```

Propiedades de configuración adicionales: cuando se utiliza el cliente Iceberg para conectar un motor de análisis como Spark al punto de conexión del servicio, es necesario especificar las siguientes propiedades de configuración de la aplicación:

```
catalog_name = "mydatacatalog"
aws_account_id = "123456789012"
aws_region = "us-east-1"
spark = SparkSession.builder \
    ... \
    .config("spark.sql.defaultCatalog", catalog_name) \
    .config(f"spark.sql.catalog.{catalog_name}",
 "org.apache.iceberg.spark.SparkCatalog") \
    .config(f"spark.sql.catalog.{catalog_name}.type", "rest") \
    .config(f"spark.sql.catalog.{catalog_name}.uri", "https://glue.
{aws_region}.amazonaws.com/iceberg") \
    .config(f"spark.sql.catalog.{catalog_name}.warehouse", "{aws_account_id}") \
    .config(f"spark.sql.catalog.{catalog_name}.rest.sigv4-enabled", "true") \
    .config(f"spark.sql.catalog.{catalog_name}.rest.signing-name", "glue") \

 .config("spark.sql.extensions","org.apache.iceberg.spark.extensions.IcebergSparkSessionExtensi
 \
    .getOrCreate()
```

El punto de conexión de Iceberg de AWS Glue, `https://glue.us-east-1.amazonaws.com/iceberg`, admite las siguientes API de REST de Iceberg:

- GetConfig
- ListNamespaces
- CreateNamespace
- LoadNamespaceMetadata
- UpdateNamespaceProperties

- DeleteNamespace
- ListTables
- CreateTable
- LoadTable
- TableExists
- UpdateTable
- DeleteTable

Parámetros de prefijo y ruta de catálogo

Las API del catálogo de REST de Iceberg tienen un prefijo de formato libre en las URL de solicitud. Por ejemplo, la llamada a la API `ListNamespaces` usa el formato URL`GET/v1/{prefix}/namespaces`. El prefijo AWS Gluesiempre sigue la estructura `/catalogs/{catalog}` para garantizar que la ruta de REST alinee la jerarquía de varios catálogos de AWS Glue. El parámetro `{catalog}` de ruta se puede derivar en función de las siguientes reglas:

Patrón de acceso	Estilo de ID de catálogo de Glue	Estilo de prefijo	Ejemplo de ID de catálogo predeterminado	Ejemplo de ruta de REST
Acceda al catálogo predeterminado en la cuenta actual	No obligatorio	:	no aplicable	GET /v1/catalogs/:/namespaces
Acceso al catálogo predeterminado en una cuenta específica	accountID	accountID	111122223333	GET /v1/catalogs/111122223333/namespaces
Acceda al catálogo anidado en la cuenta actual	catalog1/catalog2	catalog1/catalog2	rmscatalog1:db1	GET /v1/catalogs/rmscatalog1:db1/namespaces

Patrón de acceso	Estilo de ID de catálogo de Glue	Estilo de prefijo	Ejemplo de ID de catálogo predeterminado	Ejemplo de ruta de REST
Acceso a un catálogo anidado en una cuenta específica	accountId :catalog1/ catalog2	accountId :catalog1/ catalog2	123456789012/ rmscatalog1:db1	GET /v1/catal ogs/12345 6789012:r mscatalog1:db1/ namespaces

Esta asignación de identificador de catálogo a prefijo solo es necesaria cuando se llama directamente a las API de REST. Si trabaja con las API del catálogo REST de Iceberg de AWS Glue a través de un motor, debe especificar el ID del catálogo de AWS Glue en el parámetro `warehouse` de la configuración de la API del catálogo REST de Iceberg o en el parámetro `glue.id` de la configuración de la API de extensiones de AWS Glue. Por ejemplo, vea cómo puede usarlo con EMR Spark en Use an Iceberg clúster with Spark.

Parámetro de ruta de espacio de nombres

La ruta de API del catálogo de REST de Iceberg para espacios de nombres puede tener varios niveles. Sin embargo, AWS Glue solo admite espacios de nombres de un solo nivel. Para acceder a un espacio de nombres en una jerarquía de catálogos de varios niveles, puede conectarse a un catálogo de varios niveles situado encima del espacio de nombres para hacer referencia al espacio de nombres. Esto permite a cualquier motor de consultas que admita la notación de tres partes de `catalog.namespace.table` acceder a los objetos en la jerarquía del catálogo de varios niveles de AWS Glue sin problemas de compatibilidad, en comparación con el uso del espacio de nombres de varios niveles.

Conexión al catálogo de datos mediante el punto de conexión de la extensión de REST de AWS Glue Iceberg

El punto de conexión de la extensión de REST de AWS Glue Iceberg proporciona API adicionales, que no están presentes en la especificación REST de Apache Iceberg; además, otorga funciones de planificación de escaneo del servidor. Estas API adicionales se utilizan al acceder a las tablas que se guardan en el almacenamiento gestionado de Amazon Redshift. El punto de conexión es accesible desde una aplicación que utiliza extensiones AWS Glue Data Catalog de Apache Iceberg.

Configuración del punto de conexión: se puede acceder a un catálogo con tablas en el almacenamiento administrado de Redshift mediante el punto de conexión del servicio. Consulte la guía de referencia de puntos de conexión de servicio de AWS Glue para el punto de conexión específico de la región. Por ejemplo, si conecta AWS Glue a la región us-east-1, debe configurar la propiedad URI del punto de conexión como se indica a continuación:

```
Endpoint : https://glue.us-east-1.amazonaws.com/extensions
```

```
catalog_name = "myredshiftcatalog"
aws_account_id = "123456789012"
aws_region = "us-east-1"
spark = SparkSession.builder \
    .config("spark.sql.defaultCatalog", catalog_name) \
    .config(f"spark.sql.catalog.{catalog_name}",
 "org.apache.iceberg.spark.SparkCatalog") \
    .config(f"spark.sql.catalog.{catalog_name}.type", "glue") \
    .config(f"spark.sql.catalog.{catalog_name}.glue.id",
 "{123456789012}:redshiftnamespacecatalog/redshiftdb") \

 .config("spark.sql.extensions","org.apache.iceberg.spark.extensions.IcebergSparkSessionExtensi
 \
    .getOrCreate()
```

Especificaciones de las API de REST de AWS Glue para Apache Iceberg

Esta sección contiene especificaciones sobre el catálogo REST Iceberg de AWS Glue y las API de extensión de AWS Glue, así como consideraciones sobre el uso de estas API.

Las solicitudes de API a los puntos de conexión de AWS Glue Data Catalog se autentican mediante AWS Signature Version 4 (SigV4). Consulte la sección de solicitudes de API de la versión de firma 4 de AWS para obtener más información sobre SigV4 de AWS.

Al acceder al punto de conexión del servicio AWS Glue y a los metadatos de AWS Glue, la aplicación asume un rol de IAM que requiere una acción de IAM `glue:getCatalog`.

El acceso al Catálogo de Datos y sus objetos puede gestionarse mediante IAM, Lake Formation o permisos en modo híbrido de Lake Formation.

Los catálogos federados en el catáogo de datos tienen ubicaciones de datos registradas en Lake Formation. Lake Formation trabaja con el catálogo de datos y proporciona permisos similares a los de una base de datos para administrar el acceso de los usuarios a los objetos del catálogo de datos.

Puede usar IAM, AWS Lake Formation o los permisos de modo híbrido de Lake Formation para administrar el acceso al catálogo de datos predeterminado y sus objetos.

Para crear, insertar o eliminar datos en objetos administrados por Lake Formation, debes configurar permisos específicos para el usuario o rol de IAM.

- CREATE_CATALOG: es necesario para crear catálogos
- CREATE_DATABASE: es necesario para crear bases de datos
- CREATE_TABLE: es necesario para crear tablas
- DELETE: es necesario para eliminar datos de una tabla
- DESCRIBE: es necesario para leer los metadatos
- DROP: es necesario para eliminar una tabla o base de datos
- INSERT: es necesario cuando la entidad principal debe insertar datos en una tabla
- SELECT: es necesario cuando la entidad principal necesita seleccionar datos de una tabla

Para obtener más información, consulte Lake Formation permissions reference en la Guía para desarrolladores de AWS Lake Formation.

GetConfig

Información general

Nombre de operación	GetConfig
Tipo	API del catálogo de REST de Iceberg
Ruta de REST	GET /iceberg/v1/config
Acción de IAM	glue:GetCatalog
Permisos de Lake Formation	No aplicable
Evento de CloudTrail	glue:GetCatalog

Definición de API abierta	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api.yaml#L67

Consideraciones y limitaciones

- El parámetro de consulta `warehouse` debe establecerse en el ID del catálogo AWS Glue. Si no se establece, se utiliza el catálogo raíz de la cuenta actual para devolver la respuesta. Para obtener más información, consulte the section called “Parámetros de prefijo y ruta de catálogo”.

GetCatalog

Información general

nombre de operación	GetCatalog
Tipo	API de extensión AWS Glue
Ruta de REST	GET/extensions/v1/catalogs/{catalog}
Acción de IAM	glue:GetCatalog
Permisos de Lake Formation	DESCRIBE
Evento de CloudTrail	glue:GetCatalog
Definición de API abierta	https://github.com/awslabs/glue-extensions-for-iceberg/blob/main/glue-extensions-api.yaml#L40

Consideraciones y limitaciones

- El parámetro de ruta del catálogo debe seguir el estilo descrito en la sección the section called “Parámetros de prefijo y ruta de catálogo”.

ListNamespaces

Información general

Nombre de operación	ListNamespaces

Tipo	API del catálogo de REST de Iceberg
Ruta de REST	GET/iceberg/v1/catalogs/{catalog}/namespaces
Acción de IAM	glue:GetDatabase
Permisos de Lake Formation	ALL, DESCRIBE, SELECT
Evento de CloudTrail	glue:GetDatabase
Definición de API abierta	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api.yaml#L205

Consideraciones y limitaciones

- El parámetro de ruta del catálogo debe seguir el estilo descrito en la sección the section called “Parámetros de prefijo y ruta de catálogo”.
- Solo se muestran los espacios de nombres del siguiente nivel. Para listar los espacios de nombres en niveles más profundos, especifique el ID del catálogo anidado en el parámetro de ruta del catálogo.

CreateNamespace

Información general

Nombre de operación	CreateNamespace
Tipo	API del catálogo de REST de Iceberg
Ruta de REST	POST/iceberg/v1/catalogs/{catalog}/namespaces
Acción de IAM	glue:CreateDatabase
Permisos de Lake Formation	ALL, DESCRIBE, SELECT
Evento de CloudTrail	glue:CreateDatabase
Definición de API abierta	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api.yaml#L256

Consideraciones y limitaciones

- El parámetro de ruta del catálogo debe seguir el estilo descrito en la sección the section called "Parámetros de prefijo y ruta de catálogo".
- Solo se puede crear un espacio de nombres de un solo nivel. Para crear un espacio de nombres de varios niveles, debe crear cada nivel de forma iterativa y conectarse al nivel mediante el parámetro de ruta del catálogo.

StartCreateNamespaceTransaction

Información general

Nombre de operación	StartCreateNamespaceTransaction
Tipo	API de extensiones AWS Glue
Ruta de REST	POST/extensions/v1/catalogs/{catalog}/namespaces
Acción de IAM	glue:CreateDatabase
Permisos de Lake Formation	ALL, DESCRIBE, SELECT
Evento de CloudTrail	glue:CreateDatabase
Definición de API abierta	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api.yaml#L256

Consideraciones y limitaciones

- El parámetro de ruta del catálogo debe seguir el estilo descrito en la sección the section called "Parámetros de prefijo y ruta de catálogo".
- Solo puede crear un espacio de nombres de un solo nivel. Para crear espacios de nombres de varios niveles, debe crear cada nivel de forma iterativa y conectarse al nivel mediante el parámetro de ruta del catálogo.
- La API es asíncrona y devuelve un identificador de transacción que puede usar para realizar un seguimiento mediante la llamada a la API `CheckTransactionStatus`.
- Puedes llamar a esta API solo si la llamada a la API `GetCatalog` contiene el parámetro `use-extensions=true` en la respuesta.

LoadNamespaceMetadata

Información general

Nombre de operación	LoadNamespaceMetadata
Tipo	API del catálogo de REST de Iceberg
Ruta de REST	GET/iceberg/v1/catalogs/{catalog}/namespaces/{ns}
Acción de IAM	glue:GetDatabase
Permisos de Lake Formation	ALL, DESCRIBE, SELECT
Evento de CloudTrail	glue:GetDatabase
Definición de API abierta	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api.yaml#L302

Consideraciones y limitaciones

- El parámetro de ruta del catálogo debe seguir el estilo descrito en la sección the section called “Parámetros de prefijo y ruta de catálogo”.
- Solo puede especificar un espacio de nombres de un solo nivel en el parámetro de ruta de REST. Para obtener más información, consulte la sección the section called “Parámetro de ruta de espacio de nombres”.

UpdateNamespaceProperties

Información general

Nombre de operación	UpdateNamespaceProperties
Tipo	API del catálogo de REST de Iceberg
Ruta de REST	POST /iceberg/v1/catalogs/{catalog}/namespaces/{ns}/properties
Acción de IAM	glue:UpdateDatabase

Permisos de Lake Formation	ALL, ALTER
Evento de CloudTrail	glue:UpdateDatabase
Definición de API abierta	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api.yaml#L400

Consideraciones y limitaciones

- El parámetro de ruta del catálogo debe seguir el estilo descrito en la sección the section called “Parámetros de prefijo y ruta de catálogo”.
- Solo puede especificar un espacio de nombres de un solo nivel en el parámetro de ruta de REST. Para obtener más información, consulte la sección the section called “Parámetro de ruta de espacio de nombres”.

DeleteNamespace

Información general

Nombre de operación	DeleteNamespace
Tipo	API del catálogo de REST de Iceberg
Ruta de REST	DELETE/iceberg/v1/catalogs/{catalog}/namespces/{ns}
Acción de IAM	glue:DeleteDatabase
Permisos de Lake Formation	ALL, DROP
Evento de CloudTrail	glue:DeleteDatabase
Definición de API abierta	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api.yaml#L365

Consideraciones y limitaciones

- El parámetro de ruta del catálogo debe seguir el estilo descrito en la sección the section called “Parámetros de prefijo y ruta de catálogo”.
- Solo puede especificar un espacio de nombres de un solo nivel en el parámetro de ruta de REST. Para obtener más información, consulte la sección the section called “Parámetro de ruta de espacio de nombres”.
- Si hay objetos en la base de datos, la operación fallará.
- La API es asíncrona y devuelve un identificador de transacción que puede usar para realizar un seguimiento mediante la llamada a la API `CheckTransactionStatus`.
- La API solo se puede usar si la llamada a la API `GetCatalog` indica `use-extensions=true` en la respuesta.

StartDeleteNamespaceTransaction

Información general

Nombre de operación	StartDeleteNamespaceTransaction
Tipo	API de extensiones AWS Glue
Ruta de REST	DELETE /extensions/v1/catalogs/{catalog}/namespces/{ns}
Acción de IAM	glue:DeleteDatabase
Permisos de Lake Formation	ALL, DROP
Evento de CloudTrail	glue:DeleteDatabase
Definición de API abierta	https://github.com/awslabs/glue-extensions-for-iceberg/blob/main/glue-extensions-api.yaml#L85

Consideraciones y limitaciones

- El parámetro de ruta del catálogo debe seguir el estilo descrito en la sección the section called “Parámetros de prefijo y ruta de catálogo”.

- Solo puede especificar un espacio de nombres de un solo nivel en el parámetro de ruta REST. Para obtener más información, consulte la sección the section called “Parámetro de ruta de espacio de nombres”.
- Si hay objetos en la base de datos, la operación fallará.
- La API es asíncrona y devuelve un identificador de transacción que puede usar para realizar un seguimiento mediante la llamada a la API `CheckTransactionStatus`.
- La API solo se puede usar si la llamada a la API `GetCatalog` indica `use-extensions=true` en la respuesta.

ListTables

Información general

Nombre de operación	ListTables
Tipo	API del catálogo de REST de Iceberg
Ruta de REST	GET /iceberg/v1/catalogs/{catalog}/namespaces/{ns}/tables
Acción de IAM	glue:GetTable
Permisos de Lake Formation	ALL, SELECT, DESCRIBE
Evento de CloudTrail	glue:GetTable
Definición de API abierta	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api.yaml#L463

Consideraciones y limitaciones

- El parámetro de ruta del catálogo debe seguir el estilo descrito en la sección the section called “Parámetros de prefijo y ruta de catálogo”.
- Solo puede especificar un espacio de nombres de un solo nivel en el parámetro de ruta de REST. Para obtener más información, consulte la sección the section called “Parámetro de ruta de espacio de nombres”.
- Se listarán todas las tablas, incluidas las que no son de Iceberg. Para determinar si una tabla se puede cargar como una tabla de Iceberg o no, llame a la operación `LoadTable`.

CreateTable

Información general

Nombre de operación	CreateTable
Tipo	API del catálogo de REST de Iceberg
Ruta de REST	GET /iceberg/v1/catalogs/{catalog}/namespaces/{ns}/tables
Acción de IAM	glue:CreateTable
Permisos de Lake Formation	ALL, CREATE_TABLE
Evento de CloudTrail	glue:CreateTable
Definición de API abierta	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api.yaml#L497

Consideraciones y limitaciones

- El parámetro de ruta del catálogo debe seguir el estilo descrito en la sección the section called “Parámetros de prefijo y ruta de catálogo”.
- Solo puede especificar un espacio de nombres de un solo nivel en el parámetro de ruta de REST. Para obtener más información, consulte la sección the section called “Parámetro de ruta de espacio de nombres”.
- `CreateTable` con almacenamiento provisional no es compatible. Si se especifica el parámetro de consulta `stageCreate`, la operación fallará. Esto significa que no se admite una operación como `CREATE TABLE AS SELECT`, y el usuario debe utilizar una combinación de `CREATE TABLE` y `INSERT INTO` como solución alternativa.
- La operación de la API `CreateTable` no admite la opción `state-create = TRUE`.

StartCreateTableTransaction

Información general

Nombre de operación	CreateTable

Tipo	API de extensiones AWS Glue
Ruta de REST	POST/extensions/v1/catalogs/{catalog}/namespaces/{ns}/tables
Acción de IAM	glue:CreateTable
Permisos de Lake Formation	ALL, CREATE_TABLE
Evento de CloudTrail	glue:CreateTable
Definición de API abierta	https://github.com/awslabs/glue-extensions-for-iceberg/blob/main/glue-extensions-api.yaml#L107

Consideraciones y limitaciones

- El parámetro de ruta del catálogo debe seguir el estilo descrito en la sección the section called “Parámetros de prefijo y ruta de catálogo”.
- Solo puede especificar un espacio de nombres de un solo nivel en el parámetro de ruta de REST. Para obtener más información, consulte la sección the section called “Parámetro de ruta de espacio de nombres”.
- `CreateTable` con almacenamiento provisional no es compatible. Si se especifica el parámetro de consulta `stageCreate`, la operación fallará. Esto significa que no se admite una operación como `CREATE TABLE AS SELECT`, y el usuario debe utilizar una combinación de `CREATE TABLE` y `INSERT INTO` como solución alternativa.
- La API es asíncrona y devuelve un identificador de transacción que puede usar para realizar un seguimiento mediante la llamada a la API `CheckTransactionStatus`.
- La API solo se puede usar si la llamada a la API `GetCatalog` indica `use-extensions=true` en la respuesta.

LoadTable

Información general

Nombre de operación	LoadTable
Tipo	API del catálogo de REST de Iceberg

Ruta de REST	GET /iceberg/v1/catalogs/{catalog}/namespaces/{ns}/tables/{table}
Acción de IAM	glue:GetTable
Permisos de Lake Formation	ALL, SELECT, DESCRIBE
evento de CloudTrail	glue:GetTable
Definición de API abierta	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api.yaml#L616

Consideraciones

- El parámetro de ruta del catálogo debe seguir el estilo descrito en la sección the section called “Parámetros de prefijo y ruta de catálogo”.
- Solo puede especificar un espacio de nombres de un solo nivel en el parámetro de ruta de REST. Para obtener más información, consulte la sección the section called “Parámetro de ruta de espacio de nombres”.
- `CreateTable` con almacenamiento provisional no es compatible. Si se especifica el parámetro de consulta `stageCreate`, la operación fallará. Esto significa que no se admite una operación como `CREATE TABLE AS SELECT`, y el usuario debe utilizar una combinación de `CREATE TABLE` y `INSERT INTO` como solución alternativa.
- La API es asíncrona y devuelve un identificador de transacción que puede usar para realizar un seguimiento mediante la llamada a la API `CheckTransactionStatus`.
- La API solo se puede usar si la llamada a la API `GetCatalog` indica `use-extensions=true` en la respuesta.

ExtendedLoadTable

Información general

Nombre de operación	LoadTable
Tipo	API de extensiones AWS Glue

Ruta de REST	GET /extensions/v1/catalogs/{catalog}/namespaces/{ns}/tables/{table}
Acción de IAM	glue:GetTable
Permisos de Lake Formation	ALL, SELECT, DESCRIBE
Evento de CloudTrail	glue:GetTable
Definición de API abierta	https://github.com/awslabs/glue-extensions-for-iceberg/blob/main/glue-extensions-api.yaml#L134

Consideraciones

- El parámetro de ruta del catálogo debe seguir el estilo descrito en la sección the section called “Parámetros de prefijo y ruta de catálogo”.
- Solo puede especificar un espacio de nombres de un solo nivel en el parámetro de ruta de REST. Para obtener más información, consulte la sección the section called “Parámetro de ruta de espacio de nombres”.
- Solo se admite el modo `all` para el parámetro de consulta de instantáneas.
- En comparación con la API `LoadTable`, la API `ExtendedLoadTable` se diferencia en los siguientes aspectos:
  - No exige estrictamente que todos los campos estén disponibles.
  - Proporciona los siguientes parámetros adicionales en el campo de configuración de la respuesta:

    Parámetros adicionales

Clave de configuración	Descripción
aws.server-side-capabilities.scan-planning	Indica si la tabla se puede escanear utilizando las API PreparePlan y PlanTable.
aws.server-side-capabilities.data-commit	Indica si la tabla se puede confirmar mediante la transacción StartUpdateTable.

Clave de configuración	Descripción
aws.glue.staging.location	Se utiliza para la planificación de escaneos en el servidor o la confirmación de datos; es una ubicación provisional administrada por el servicio que el motor puede usar para escribir archivos de datos temporales.
aws.glue.staging.access-key-id	Se utiliza para la planificación de escaneos en el servidor o la confirmación de datos; es parte de las credenciales temporales de AWS para acceder a la ubicación provision al administrada por el servicio.
aws.glue.staging.secret-access-key	Se utiliza para la planificación del escaneo del lado del servidor o para la confirmación de datos, y forma parte de las credenciales temporales de AWS para acceder a la ubicación provisional gestionada por el servicio.
aws.glue.staging.session-token	Se utiliza para la planificación del escaneo del lado del servidor o para la confirmación de datos, y forma parte de las credenciales temporales de AWS para acceder a la ubicación provisional gestionada por el servicio.
aws.glue.staging.expiration-ms	Se utiliza para la planificación de escaneos en el servidor o la confirmación de datos; indica el tiempo de expiración de las credenciales para acceder a la ubicación provisional administrada por el servicio.
aws.glue.staging.data-transfer-role-arn	Se utiliza para la planificación de escaneos en el servidor o la confirmación de datos; es un rol de IAM que se puede asumir para acceder a la ubicación provisional administr ada por el servicio.

PreplanTable

Información general

Nombre de operación	PreplanTable

Tipo	API de extensiones AWS Glue
Ruta de REST	POST /extensions/v1/catalogs/{catalog}/namespaces/{ns}/tables/{table}/preplan
Acción de IAM	glue:GetTable
Permisos de Lake Formation	ALL, SELECT, DESCRIBE
Evento de CloudTrail	glue:GetTable
Definición de API abierta	https://github.com/awslabs/glue-extensions-for-iceberg/blob/main/glue-extensions-api.yaml#L211

Consideraciones

- El parámetro de ruta del catálogo debe seguir el estilo descrito en la sección the section called “Parámetros de prefijo y ruta de catálogo”.
- Solo puede especificar un espacio de nombres de un solo nivel en el parámetro de ruta de REST. Para obtener más información, consulte la sección the section called “Parámetro de ruta de espacio de nombres”.
- El llamante de esta API siempre debe determinar si quedan resultados por recuperar en función del token de página. Es posible obtener una respuesta con un elemento de página vacío pero con un token de paginación si el servidor sigue procesando pero no puede generar ningún resultado en el tiempo de respuesta dado.
- Puede usar esta API solo si la respuesta de la API `ExtendedLoadTable` contiene `aws.server-side-capabilities.scan-planning=true`.

PlanTable

Información general

Nombre de operación	PlanTable
Tipo	API de extensiones AWS Glue

Ruta de REST	POST /extensions/v1/catalogs/{catalog}/namespaces/{ns}/tables/{table}/plan
Acción de IAM	glue:GetTable
Permisos de Lake Formation	ALL, SELECT, DESCRIBE
Evento de CloudTrail	glue:GetTable
Definición de API abierta	https://github.com/awslabs/glue-extensions-for-iceberg/blob/main/glue-extensions-api.yaml#L243

Consideraciones

- El parámetro de ruta del catálogo debe seguir el estilo descrito en la sección the section called “Parámetros de prefijo y ruta de catálogo”.
- Solo puede especificar un espacio de nombres de un solo nivel en el parámetro de ruta de REST. Para obtener más información, consulte la sección the section called “Parámetro de ruta de espacio de nombres”.
- El llamante de esta API siempre debe determinar si quedan resultados por recuperar en función del token de página. Es posible obtener una respuesta con un elemento de página vacío pero con un token de paginación si el servidor sigue procesando pero no puede generar ningún resultado en el tiempo de respuesta dado.
- Puede usar esta API solo si la respuesta de la API `ExtendedLoadTable` contiene `aws.server-side-capabilities.scan-planning=true`.

TableExists

Información general

Nombre de operación	TableExists
Tipo	API del catálogo de REST de Iceberg
Ruta de REST	HEAD/iceberg/v1/catalogs/{catalog}/namespaces/{ns}/tables/{table}

Acción de IAM	glue:GetTable
Permisos de Lake Formation	ALL, SELECT, DESCRIBE
Evento de CloudTrail	glue:GetTable
Definición de API abierta	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api.yaml#L833

Consideraciones

- El parámetro de ruta del catálogo debe seguir el estilo descrito en la sección the section called “Parámetros de prefijo y ruta de catálogo”.
- Solo puede especificar un espacio de nombres de un solo nivel en el parámetro de ruta de REST. Para obtener más información, consulte la sección the section called “Parámetro de ruta de espacio de nombres”.

UpdateTable

Información general

Nombre de operación	UpdateTable
Tipo	API del catálogo de REST de Iceberg
Ruta de REST	POST /iceberg/v1/catalogs/{catalog}/namespaces/{ns}/tables/{table}
Acción de IAM	glue:UpdateTable
Permisos de Lake Formation	ALL, ALTER
Evento de CloudTrail	glue:UpdateTable
Definición de API abierta	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api.yaml#L677

Consideraciones

- El parámetro de ruta del catálogo debe seguir el estilo descrito en la sección the section called “Parámetros de prefijo y ruta de catálogo”.
- Solo puede especificar un espacio de nombres de un solo nivel en el parámetro de ruta de REST. Para obtener más información, consulte la sección the section called “Parámetro de ruta de espacio de nombres”.

StartUpdateTableTransaction

Información general

Nombre de operación	StartUpdateTableTransaction
Tipo	API de extensión AWS Glue
Ruta de REST	POST/extensions/v1/catalogs/{catalog}/namespaces/{ns}/tables/{table}
Acción de IAM	glue:UpdateTable
Permisos de Lake Formation	ALL, ALTER
Evento de CloudTrail	glue:UpdateTable
Definición de API abierta	https://github.com/awslabs/glue-extensions-for-iceberg/blob/main/glue-extensions-api.yaml#L154

Consideraciones

- El parámetro de ruta del catálogo debe seguir el estilo descrito en la sección the section called “Parámetros de prefijo y ruta de catálogo”.
- Solo puede especificar un espacio de nombres de un solo nivel en el parámetro de ruta de REST. Para obtener más información, consulte la sección the section called “Parámetro de ruta de espacio de nombres”.
- La API es asíncrona y devuelve un identificador de transacción que puede usar para realizar un seguimiento mediante la llamada a la API `CheckTransactionStatus`.

- También se puede realizar una operación `RenamTable` a través de esta API. Cuando eso ocurre, la persona que llama también debe tener el permiso Glue:CreateTable o LakeFormation CREATE_TABLE para cambiar el nombre de la tabla.
- Puede usar esta API solo si la respuesta de la API `ExtendedLoadTable` contiene `aws.server-side-capabilities.scan-planning=true`.

DeleteTable

Información general

Nombre de operación	DeleteTable
Tipo	API del catálogo de REST de Iceberg
Ruta de REST	DELETE/iceberg/v1/catalogs/{catalog}/namespaces/{ns}/tables/{table}
Acción de IAM	glue:DeleteTable
Permisos de Lake Formation	ALL, DROP
Evento de CloudTrail	glue:DeleteTable
Definición de API abierta	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api.yaml#L793

Consideraciones

- El parámetro de ruta del catálogo debe seguir el estilo descrito en la sección the section called “Parámetros de prefijo y ruta de catálogo”.
- Solo puede especificar un espacio de nombres de un solo nivel en el parámetro de ruta de REST. Para obtener más información, consulte la sección the section called “Parámetro de ruta de espacio de nombres”.
- La operación de API `DeleteTable` admite una opción de purga. Si la purga está establecida en `true`, los datos de la tabla se eliminan; de lo contrario, no se eliminarán. En el caso de las tablas de Amazon S3, la operación no elimina los datos de las tablas. La operación devuelve un error cuando la tabla está almacenada en Amazon S3 y `purge = TRUE,`.

En el caso de las tablas que se guardan en el almacenamiento gestionado de Amazon Redshift, la operación eliminará los datos de la tabla, de forma similar al comportamiento `DROP TABLE` de Amazon Redshift. La operación devuelve un error cuando la tabla está almacenada en Amazon Redshift y `purge = FALSE`.

- `purgeRequest=true` no se admite.

StartDeleteTableTransaction

Información general

Nombre de operación	StartDeleteTableTransaction
Tipo	API de extensiones AWS Glue
Ruta de REST	DELETE /extensions/v1/catalogs/{catalog}/namespaces/{ns}/tables/{table}
Acción de IAM	glue:DeleteTable
Permisos de Lake Formation	ALL, DROP
Evento de CloudTrail	glue:DeleteTable
Definición de API abierta	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api.yaml#L793

Consideraciones

- El parámetro de ruta del catálogo debe seguir el estilo descrito en la sección the section called “Parámetros de prefijo y ruta de catálogo”.
- Solo puede especificar un espacio de nombres de un solo nivel en el parámetro de ruta de REST. Para obtener más información, consulte la sección the section called “Parámetro de ruta de espacio de nombres”.
- `purgeRequest=false` no se admite.
- La API es asíncrona y devuelve un identificador de transacción que se puede rastrear mediante `CheckTransactionStatus`.

CheckTransactionStatus

Información general

Nombre de operación	CheckTransactionStatus
Tipo	API de extensiones AWS Glue
Ruta de REST	POST/extensions/v1/transactions/status
Acción de IAM	El mismo permiso que la acción que inicia la transacción
Permisos de Lake Formation	El mismo permiso que la acción que inicia la transacción
Definición de API abierta	https://github.com/awslabs/glue-extensions-for-iceberg/blob/main/glue-extensions-api.yaml#L273

Consideraciones

- El parámetro de ruta del catálogo debe seguir el estilo descrito en la sección the section called "Parámetros de prefijo y ruta de catálogo".

Conexión al catálogo de datos desde una aplicación Spark independiente

Puede conectarse al catálogo de datos desde una aplicación independiente mediante un conector de Apache Iceberg.

1. Cree un rol de IAM para la aplicación Spark.
2. Conéctese al punto de conexión de REST de Iceberg de AWS Glue mediante el conector de Iceberg.

```
# configure your application. Refer to https://docs.aws.amazon.com/cli/latest/
userguide/cli-configure-envvars.html for best practices on configuring environment
 variables.
export AWS_ACCESS_KEY_ID=$(aws configure get appUser.aws_access_key_id)
export AWS_SECRET_ACCESS_KEY=$(aws configure get appUser.aws_secret_access_key)
export AWS_SESSION_TOKEN=$(aws configure get appUser.aws_secret_token)

export AWS_REGION=us-east-1
export REGION=us-east-1
```

```
export AWS_ACCOUNT_ID = {specify your aws account id here}

~/spark-3.5.3-bin-hadoop3/bin/spark-shell \
    --packages org.apache.iceberg:iceberg-spark-runtime-3.4_2.12:1.6.0 \
    --conf
 "spark.sql.extensions=org.apache.iceberg.spark.extensions.IcebergSparkSessionExtensions"
 \
    --conf "spark.sql.defaultCatalog=spark_catalog" \
    --conf "spark.sql.catalog.spark_catalog=org.apache.iceberg.spark.SparkCatalog" \
    --conf "spark.sql.catalog.spark_catalog.type=rest" \
    --conf "spark.sql.catalog.spark_catalog.uri=https://glue.us-east-1.amazonaws.com/
iceberg" \
    --conf "spark.sql.catalog.spark_catalog.warehouse = {AWS_ACCOUNT_ID}" \
    --conf "spark.sql.catalog.spark_catalog.rest.sigv4-enabled=true" \
    --conf "spark.sql.catalog.spark_catalog.rest.signing-name=glue" \
    --conf "spark.sql.catalog.spark_catalog.rest.signing-region=us-east-1" \
    --conf "spark.sql.catalog.spark_catalog.io-
impl=org.apache.iceberg.aws.s3.S3FileIO" \
    --conf
 "spark.hadoop.fs.s3a.aws.credentials.provider=org.apache.hadoop.fs.s3a.SimpleAWSCredentialP
```

3. Consulte los datos en el catálogo de datos.

```
spark.sql("create database myicebergdb").show()
spark.sql("""CREATE TABLE myicebergdb.mytbl (name string) USING iceberg location
 's3://bucket_name/mytbl'""")
spark.sql("insert into myicebergdb.mytbl values('demo') ").show()
```

Asignación de datos entre Amazon Redshift y Apache Iceberg

Redshift e Iceberg admiten varios tipos de datos. La siguiente matriz de compatibilidad describe la compatibilidad y las limitaciones cuando tenga que asignar datos entre estos dos sistemas de datos. Consulte Tipos de datos de Amazon Redshift y Especificaciones de la tabla de Apache Iceberg para obtener más información sobre los tipos de datos compatibles en sus respectivos sistemas de datos.

Tipo de datos de Redshift	Alias	Tipo de datos de Iceberg
SMALLINT	INT2	int

Tipo de datos de Redshift	Alias	Tipo de datos de Iceberg
INTEGER	INT, INT4	int
BIGINT	INT8	long
DECIMAL	NUMERIC	decimal
REAL	FLOAT4	float
REAL	FLOAT4	float
DOUBLE PRECISION	FLOAT8, FLOAT	double
CHAR	CHARACTER, NCHAR	cadena
VARCHAR	CHARACTER VARYING, NVARCHAR	cadena
BPCHAR		cadena
TEXT		cadena
DATE		date
TIME	TIME WITHOUT TIMEZONE	hora
TIME	TIME WITH TIMEZONE	no admitido
TIMESTAMP	TIMESTAMP WITHOUT TIMEZONE	TIMESTAMP
TIMESTAMPZ	TIMESTAMP WITH TIMEZONE	TIMESTAMPZ
INTERVALO AÑO A MES		No compatible
INTERVALO DÍA A SEGUNDO		No compatible
BOOLEAN	BOOL	bool

Tipo de datos de Redshift	Alias	Tipo de datos de Iceberg
HLLSKETCH		No compatible
SUPER		No compatible
VARBYTE	VARBINARY, BINARY VARYING	binario
GEOMETRY		No compatible
GEOGRAPHY		No compatible

Consideraciones y limitaciones al utilizar las API del catálogo de REST de Iceberg AWS Glue

A continuación, puede ver las consideraciones y limitaciones que surgen al utilizar el comportamiento de la operación de lenguaje de definición de datos (DDL) del catálogo de REST de Apache Iceberg.

Consideraciones

- Comportamiento de la API **`RenameTable`**: la operación `RenameTable` se admite en las tablas de Amazon Redshift, pero no en Amazon S3.
- Operaciones de DDL para espacios de nombres y tablas en Amazon Redshift: las operaciones de creación, actualización y eliminación de espacios de nombres y tablas en Amazon Redshift son operaciones asíncronas porque dependen del momento en que está disponible el grupo de trabajo que administra Amazon Redshift y de si se va a realizar una transacción de DDL y DML conflictiva y la operación tiene que esperar a que se bloquee para confirmar los cambios.

Limitaciones

- Las API de visualización de la especificación de REST de Apache Iceberg no son compatibles con el catálogo de REST de AWS Glue Iceberg.

Prácticas recomendadas para el uso del Catálogo de datos de AWS Glue

En esta sección se describen las prácticas recomendadas para administrar y usar el AWS Glue Data Catalog de forma eficaz. Se hace hincapié en prácticas como el uso eficiente de los rastreadores, la organización de los metadatos, la seguridad, la optimización del rendimiento, la automatización, la gobernanza de los datos y la integración con otros servicios de AWS.

- Use los rastreadores de forma eficaz: Ejecute los rastreadores con regularidad para mantener el Catálogo de datos actualizado con los cambios en los orígenes de datos. Use rastreos progresivos para los orígenes de datos que cambian con frecuencia a fin de mejorar el rendimiento. Configure los rastreadores para añadir automáticamente nuevas particiones o actualizar los esquemas cuando se detecten cambios.
- Organice y asigne nombres a las tablas de metadatos: Establezca una convención de nomenclatura coherente para las bases de datos y las tablas del Catálogo de datos. Agrupe los orígenes de datos relacionados en bases de datos o carpetas de forma lógica para una mejor organización. Use nombres descriptivos que expresen el propósito y el contenido de cada tabla.
- Administre los esquemas de forma eficaz: Aproveche las capacidades de inferencia de los esquemas que tienen los rastreadores de AWS Glue. Revise y actualice los cambios de esquema antes de aplicarlos para evitar interrumpir las aplicaciones posteriores. Use las características de evolución del esquema para gestionar los cambios de este con fluidez.
- Proteja el Catálogo de datos: Active el cifrado de datos en reposo y en tránsito para el Catálogo de datos. Implemente políticas de control de acceso detalladas para restringir el acceso a los datos confidenciales. Audite y revise periódicamente los permisos y los registros de actividad del Catálogo de datos.
- Integre otros servicios de AWS: Use el Catálogo de datos como una capa de metadatos centralizada para servicios como Amazon Athena, Redshift Spectrum y AWS Lake Formation. Aproveche los trabajos de ETL de AWS Glue para transformar y cargar datos en varios almacenes de datos y, al mismo tiempo, mantener los metadatos en el Catálogo de datos.
- Supervise y optimice el rendimiento: Supervise el rendimiento de los rastreadores y los trabajos de ETL mediante el uso de las métricas de Amazon CloudWatch. Particione los conjuntos de datos grandes en el Catálogo de datos para mejorar el rendimiento de las consultas. Implemente optimizaciones de rendimiento para los metadatos a los que se accede con frecuencia.
- Manténgase actualizado con la documentación y las prácticas recomendadas de AWS Glue: Consulte periódicamente la documentación y los recursos de AWS Glue para obtener las últimas

novedades, prácticas recomendadas y recomendaciones. Asista a seminarios web, talleres y otros eventos de AWS Glue para aprender de los expertos y mantenerse informado sobre las nuevas características y capacidades.

Supervisión de métricas de uso del Catálogo de datos en Amazon CloudWatch

Las métricas de uso de AWS Glue Data Catalog ya están disponibles en Amazon CloudWatch, lo que simplifica la supervisión y comprensión del uso de recursos en el catálogo de datos. Ahora dispone de visibilidad inmediata sobre el uso de las API del Catálogo de Glue en relación con catálogos, bases de datos, tablas, particiones y conexiones, lo que facilita el mantenimiento y control del catálogo de datos.

Información general sobre las métricas del Catálogo de datos

AWS Glue Data Catalog publica automáticamente las métricas de uso en Amazon CloudWatch. Con la integración de métricas en CloudWatch, puede supervisar indicadores críticos de rendimiento cada minuto, incluidos:

- Solicitudes de tablas
- Índices de particiones creados
- Conexiones actualizadas
- Estadísticas actualizadas

Estas métricas ayudan a identificar cuellos de botella, detectar anomalías y tomar decisiones basadas en datos para mejorar la fiabilidad general del catálogo de datos. También puede configurar alarmas en CloudWatch para recibir notificaciones cuando las métricas superen los umbrales especificados, lo que permite una administración proactiva de la implementación.

Cómo agregar métricas a un panel de CloudWatch

Puede crear paneles personalizados para supervisar los recursos de AWS Glue Data Catalog y configurar alarmas para recibir notificaciones ante cualquier actividad inusual.

Para agregar métricas del Catálogo de datos al panel de CloudWatch, siga estos pasos:

1. Abra la consola de CloudWatch en https://console.aws.amazon.com/cloudwatch/.

2. En el panel de navegación, seleccione Métricas.
3. Elija Todas las métricas.
4. Elija Uso > Por recurso de AWS.
5. Filtre por Glue para ver las métricas disponibles.
6. Seleccione las métricas que desea agregar al panel.
7. Agregue métricas de catálogos, bases de datos, tablas, particiones y conexiones al gráfico de CloudWatch.

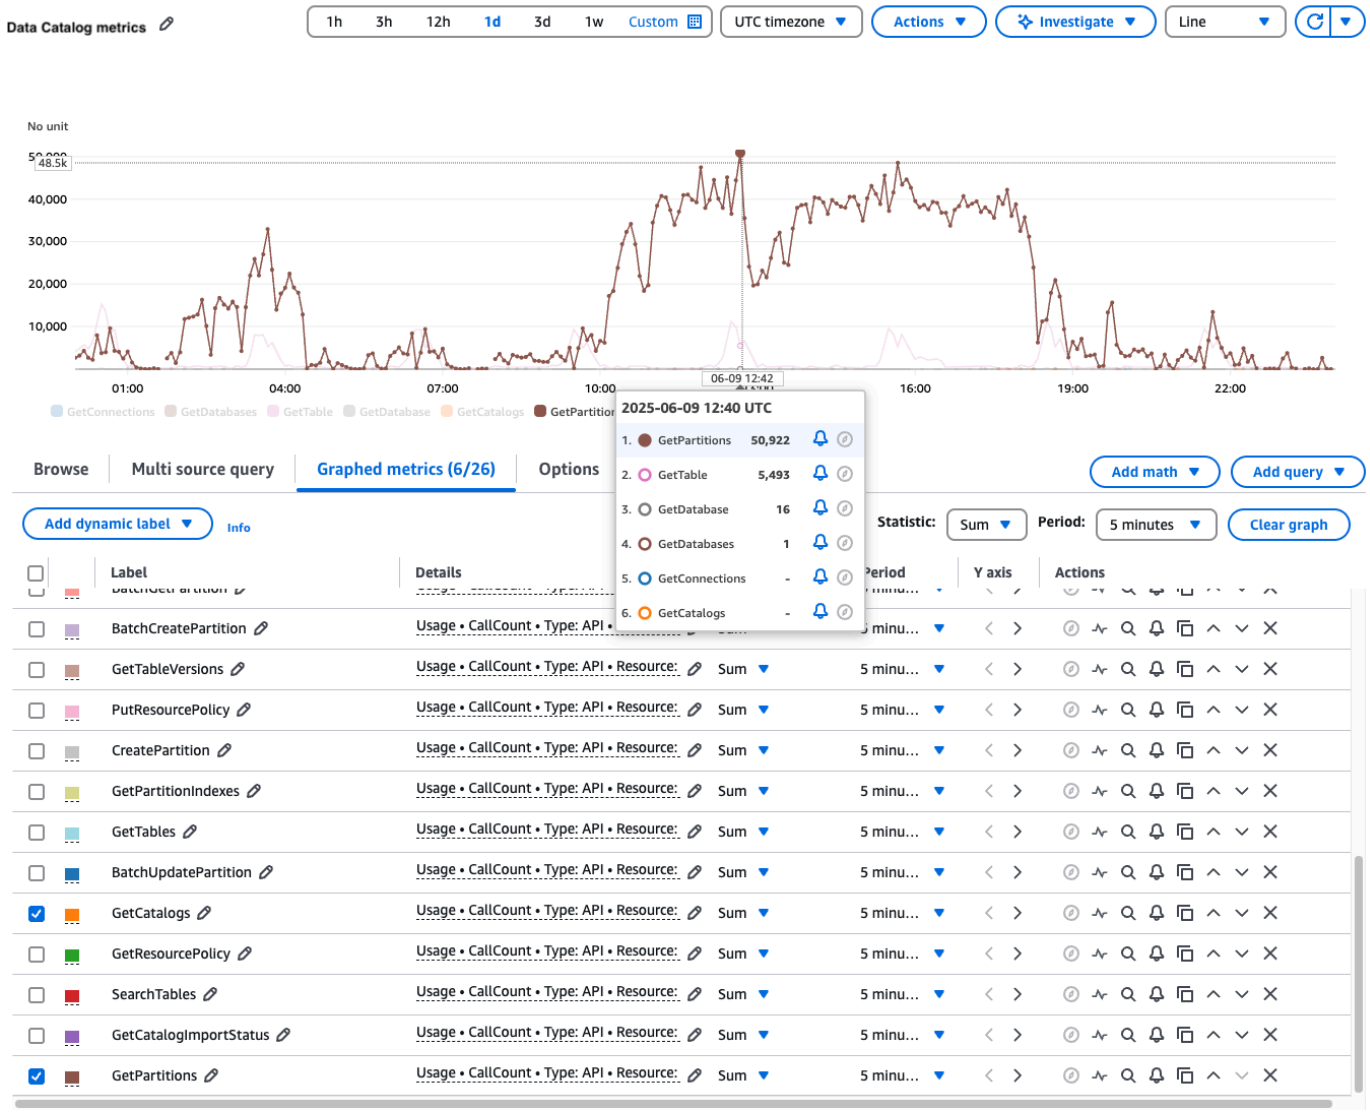

Puede configurar alarmas personalizadas que se activen automáticamente cuando el uso de las API supere los umbrales definidos, con el fin de identificar anomalías en el uso del catálogo de datos.

Para obtener instrucciones detalladas sobre cómo configurar alarmas, consulte Creación de una alarma de Información de métricas en CloudWatch.

AWS Glue Schema Registry

> **Note**
>
> El registro de esquemas de AWS Glue no se admite en la consola de AWS Glue en las siguientes regiones: Asia Pacífico (Yakarta), Europa (Zúrich) y Medio Oriente (EAU).

Con AWS Glue Schema Registry, puede descubrir, controlar y evolucionar de forma centralizada los esquemas de flujo de datos. Un esquema define la estructura y el formato de un registro de datos. Con AWS Glue Schema Registry, puede administrar y aplicar esquemas en sus aplicaciones de streaming de datos mediante integraciones convenientes con Apache Kafka, Amazon Managed Streaming for Apache Kafka, Amazon Kinesis Data Streams, Amazon Managed Service para Apache Flink y AWS Lambda.

Schema Registry admite el formato de datos AVRO (v1.11.4), el formato de datos JSON con formato de esquemas JSON para el esquema (especificaciones Draft-04, Draft-06 y Draft-07) con la validación de esquemas JSON mediante el método biblioteca de Everit, y admite los búferes de protocolo (Protobuf) en las versiones proto2 y proto3 sin soporte para `extensions` o `groups`, y el lenguaje Java, con otros formatos de datos e idiomas que estarán disponibles en el futuro. Las características admitidas incluyen compatibilidad, fuentes de esquemas mediante metadatos, registro automático de esquemas, compatibilidad con IAM y compresión ZLIB opcional para reducir el almacenamiento y la transferencia de datos. Schema Registry funciona sin servidor y es gratuito.

El uso de un esquema como contrato de formato de datos entre productores y consumidores conduce a una mejor gobernanza de los datos, datos de mayor calidad y permite que los consumidores de datos sean resistentes a los cambios posteriores compatibles.

Schema Registry permite que sistemas dispares compartan un esquema para la serialización y la deserialización. Por ejemplo, suponga que tiene un productor y un consumidor de datos. El productor conoce el esquema cuando publica los datos. Schema Registry proporciona un serializador y deserializador para determinados sistemas como Amazon MSK o Apache Kafka.

Para obtener más información, consulte Cómo funciona Schema Registry.

Temas

- Schemas
- Registries
- Compatibilidad y control de versiones de esquemas
- Bibliotecas Serde de código abierto
- Cuotas del Schema Registry
- Cómo funciona Schema Registry
- Introducción a Schema Registry

Schemas

Un esquema define la estructura y el formato de un registro de datos. Un esquema es una especificación versionada para publicación, consumo o almacenamiento de confianza de datos.

En este esquema de ejemplo para Avro, el formato y la estructura están definidos por el diseño y los nombres de campos, y el formato de los nombres de campos está definido por los tipos de datos (por ejemplo, `string`, `int`).

```
{
    "type": "record",
    "namespace": "ABC_Organization",
    "name": "Employee",
    "fields": [
        {
            "name": "Name",
            "type": "string"
        },
        {
            "name": "Age",
            "type": "int"
        },
        {
            "name": "address",
            "type": {
                "type": "record",
                "name": "addressRecord",
                "fields": [
                    {
                        "name": "street",
                        "type": "string"
```

```
                    },
                    {
                        "name": "zipcode",
                        "type": "int"
                    }
                ]
            }
        }
    ]
}
```

En este ejemplo de esquema JSON Draft-07 para JSON, el formato está definido por la organización del esquema JSON.

```
{
 "$id": "https://example.com/person.schema.json",
 "$schema": "http://json-schema.org/draft-07/schema#",
 "title": "Person",
 "type": "object",
 "properties": {
  "firstName": {
   "type": "string",
   "description": "The person's first name."
  },
  "lastName": {
   "type": "string",
   "description": "The person's last name."
  },
  "age": {
   "description": "Age in years which must be equal to or greater than zero.",
   "type": "integer",
   "minimum": 0
  }
 }
}
```

En este ejemplo de Protobuf, el formato se define mediante laversión 2 del lenguaje de búferes de protocolo (proto2).

```
syntax = "proto2";

package tutorial;
```

```
option java_multiple_files = true;
option java_package = "com.example.tutorial.protos";
option java_outer_classname = "AddressBookProtos";

message Person {
  optional string name = 1;
  optional int32 id = 2;
  optional string email = 3;

  enum PhoneType {
    MOBILE = 0;
    HOME = 1;
    WORK = 2;
  }

  message PhoneNumber {
    optional string number = 1;
    optional PhoneType type = 2 [default = HOME];
  }

  repeated PhoneNumber phones = 4;
}

message AddressBook {
  repeated Person people = 1;
}
```

Registries

Un registro es un contenedor lógico de esquemas. Los registros le permiten organizar sus esquemas, así como administrar el control de acceso para sus aplicaciones. Un registro tiene un nombre de recurso de Amazon (ARN) que le permite organizar y establecer diferentes permisos de acceso a las operaciones de esquema dentro del registro.

Puede utilizar el registro predeterminado o crear tantos registros nuevos como sea necesario.

AWS GlueJerarquía de Schema Registry

- RegistryName: [cadena]
  - RegistrYarn: [AWS ARN]
  - CreatedTime: [marca de tiempo]

  - UpdatedTime: [marca de tiempo]

- SchemaName: [cadena]
  - SchemaArn: [AWS ARN]
  - DataFormat: [Avro, Json o Protobuf]
  - Compatibilidad: [por ejemplo, BACKWARD (HACIA ATRÁS), BACKWARD_ALL (HACIA ATRÁS_TODO), FORWARD (HACIA ADELANTE), FORWARD_ALL (HACIA ADELANTE_TODO), FULL (COMPLETO), FULL_ALL (COMPLETO_TODO), NONE (NINGUNO), DISABLED (DESACTIVADO)]
  - Status: [por ejemplo, PENDING (PENDIENTE), AVAILABLE (DISPONIBLE), DELETING (ELIMINACIÓN)]
  - SchemaCheckPoint: [entero]
  - CreatedTime: [marca de tiempo]
  - UpdatedTime: [marca de tiempo]
- SchemaVersion: [cadena]
  - SchemaVersionNumber: [entero]
  - Status: [por ejemplo, PENDIENTE, DISPONIBLE, ELIMINACIÓN, ERROR]
  - SchemaDefinition: [cadena, valor: JSON]
  - CreatedTime: [marca de tiempo]
- SchemaVersionMetadata: [lista]
  - MetadataKey: [cadena]
  - MetadataInfo
  - MetadaValue: [cadena]
  - CreatedTime: [marca de tiempo]

Compatibilidad y control de versiones de esquemas

Cada esquema puede tener varias versiones. El control de versiones se rige por una regla de compatibilidad que se aplica a un esquema. Schema Registry contrasta las solicitudes para registrar nuevas versiones de esquema con esta regla antes de que puedan tener éxito.

Una versión de esquema marcada como punto de verificación se utiliza para determinar la compatibilidad de registrar nuevas versiones de un esquema. Cuando se crea un esquema por primera vez, el punto de verificación predeterminado será la primera versión. A medida que el esquema evoluciona con más versiones, puede utilizar CLI/SDK para cambiar el punto de control a una versión de un esquema mediante la herramienta API `UpdateSchema` que cumple con un conjunto de restricciones. En la consola, la edición de la definición de esquema o el modo de compatibilidad cambiará el punto de control a la última versión de forma predeterminada.

Los modos de compatibilidad permiten controlar cómo los esquemas pueden o no evolucionar con el tiempo. Estos modos forman el contrato entre las aplicaciones que producen y consumen datos. Cuando se envía una nueva versión de un esquema al registro, la regla de compatibilidad aplicada al nombre del esquema se utiliza para determinar si se puede aceptar la nueva versión. Existen ocho modos de compatibilidad: NONE (NINGUNO), DISABLED (DESACTIVADO), BACKWARD (HACIA ATRÁS), BACKWARD_ALL (HACIA ATRÁS_TODO), FORWARD (HACIA ADELANTE), FORWARD_ALL (HACIA ADELANTE_TODO), FULL (COMPLETO), FULL_ALL (COMPLETO_TODO).

En el formato de datos Avro, los campos pueden ser opcionales u obligatorios. Un campo opcional es aquel en el que el `Type` incluye nulo. Los campos obligatorios no tienen nulo como `Type`.

En el formato de datos Protobuf, los campos pueden ser opcionales (incluso repetidos) u obligatorios en la sintaxis proto2, mientras que todos los campos son opcionales (incluidos los repetidos) en la sintaxis proto3. Todas las reglas de compatibilidad se determinan en función de la comprensión de las especificaciones de los búferes de protocolo, así como en función de las pautas en la documentación sobre búferes de protocolo de Google.

- NONE (NINGUNO): no se aplica ningún modo de compatibilidad. Puede utilizar esta opción en escenarios de desarrollo o si no conoce los modos de compatibilidad que desea aplicar a los esquemas. Cualquier nueva versión que se agregue será aceptada sin someterse a una comprobación de compatibilidad.
- DISABLED (DESACTIVADO): esta opción de compatibilidad impide el control de versiones de un esquema en particular. No se pueden agregar nuevas versiones.
- BACKWARD (HACIA ATRÁS): se recomienda esta opción de compatibilidad ya que permite a los consumidores leer tanto la versión actual como la anterior del esquema. Puede utilizar esta opción para comprobar la compatibilidad con la última versión del esquema, al eliminar campos o agregar campos adicionales. Un caso de uso típico para HACIA ATRÁS es cuando la aplicación se ha creado para el esquema más reciente.

AVRO

Por ejemplo, suponga que tiene un esquema definido por nombre (obligatorio), apellido (obligatorio), email (obligatorio) y número de teléfono (opcional).

Si la siguiente versión del esquema elimina el campo de email obligatorio, esto se registraría correctamente. La compatibilidad HACIA ATRÁS requiere que los consumidores puedan leer la versión actual y anterior del esquema. Sus consumidores podrán leer el nuevo esquema a medida que se ignora el campo de email adicional de los mensajes antiguos.

Si tiene una nueva versión de esquema propuesta que agrega un campo obligatorio, por ejemplo, código postal, esto no se registrará correctamente con la compatibilidad HACIA ATRÁS. Los consumidores de la nueva versión no podrían leer mensajes antiguos antes de cambiar el esquema, ya que les faltará el campo de código postal obligatorio. Sin embargo, si el campo de código postal se estableció como opcional en el nuevo esquema, entonces la versión propuesta se registraría correctamente, ya que los consumidores pueden leer el esquema anterior sin el campo de código postal opcional.

JSON

Por ejemplo, supongamos que tiene una versión de esquema definida por nombre (opcional), apellido (opcional), email (opcional) y número de teléfono (opcional).

Si la siguiente versión de esquema agrega la propiedad opcional de número de teléfono, esto se registraría correctamente siempre y cuando la versión original del esquema no permita ninguna propiedad adicional al configurar el campo `additionalProperties` en falso. La compatibilidad HACIA ATRÁS requiere que los consumidores puedan leer la versión actual y anterior del esquema. Sus consumidores podrán leer los datos producidos con el esquema original en el que la propiedad del número de teléfono no existe.

Si tiene una nueva versión de esquema propuesta que agrega la propiedad de número de teléfono opcional, esto no se registrará correctamente con la compatibilidad HACIA ATRÁS, cuando la versión del esquema original establezca el campo `additionalProperties` a verdadero, es decir, cuando permita cualquier propiedad adicional. Los consumidores de la nueva versión no podrían leer mensajes antiguos antes de cambiar el esquema, ya que no pueden leer datos con propiedad de número de teléfono en un tipo diferente, por ejemplo, cadena en lugar de número.

PROTOBUF

Por ejemplo, suponga que tiene una versión de esquema definida por un mensaje `Person` con `first name` (obligatorio), `last name` (obligatorio), `email` (obligatorio) y `phone number` (opcional) en la sintaxis proto2.

En forma semejante a las situaciones de AVRO, si la siguiente versión del esquema elimina el campo de `email` obligatorio, esto se registraría correctamente. La compatibilidad HACIA ATRÁS requiere que los consumidores puedan leer la versión actual y anterior del esquema. Sus consumidores podrán leer el nuevo esquema a medida que se ignora el campo de `email` adicional de los mensajes antiguos.

Si tiene una nueva versión de esquema propuesta que agrega un campo obligatorio, por ejemplo, `zip code`, esto no se registrará correctamente con la compatibilidad CON VERSIONES ANTERIORES. Los consumidores de la nueva versión no podrían leer mensajes antiguos antes de cambiar el esquema, ya que les faltará el campo de `zip code` obligatorio. Sin embargo, si el campo de `zip code` se estableció como opcional en el nuevo esquema, entonces la versión propuesta se registraría correctamente, ya que los consumidores pueden leer el esquema anterior sin el campo de `zip code` opcional.

En caso de un caso de uso de gRPC, agregar un nuevo servicio RPC o un método RPC es un cambio compatible con versiones anteriores. Por ejemplo, suponga que tiene una versión de esquema definida por un servicio RPC `MyService` con dos métodos RPC, `Foo` y `Bar`.

Si la próxima versión de esquema añade un nuevo método RPC llamado `Baz`, esto se registraría correctamente. Los consumidores podrán leer los datos producidos con el esquema original según la compatibilidad CON VERSIONES ANTERIORES desde el método RPC `Baz` recientemente agregado es opcional.

Si tiene una nueva versión de esquema propuesta que agrega un método RPC existente `Foo`, esto no se registrará correctamente con la compatibilidad CON VERSIONES ANTERIORES. Los consumidores de la nueva versión no podrían leer mensajes antiguos antes del cambio de esquema, ya que no pueden entender ni leer datos con el método RPC inexistente `Foo` en una aplicación de gRPC.

- BACKWARD_ALL (HACIA ATRÁS_TODO): esta opción de compatibilidad permite a los consumidores leer tanto la versión actual como todas las versiones anteriores del esquema. Puede utilizar esta opción para comprobar la compatibilidad con la última versión del esquema cuando elimine campos o agregue campos adicionales.

- FORWARD (HACIA ADELANTE): esta opción de compatibilidad permite a los consumidores leer tanto la versión actual como la inmediatamente siguiente del esquema, pero no necesariamente versiones posteriores. Puede utilizar esta opción para comprobar la compatibilidad con la última versión del esquema cuando elimine campos o agregue campos adicionales. Un caso de uso típico de HACIA ADELANTE es cuando la aplicación se ha creado para un esquema anterior y debe poder procesar un esquema más reciente.

  AVRO

  Por ejemplo, supongamos que tiene una versión de esquema definida por nombre (obligatorio), apellido (obligatorio), email (opcional).

  Si tiene una nueva versión de esquema que agrega un campo obligatorio, p. ej., número de teléfono, esto se registraría correctamente. La compatibilidad HACIA ADELANTE requiere que los consumidores puedan leer los datos producidos con el nuevo esquema utilizando la versión anterior.

  Si tiene una sugerencia de una versión de esquema que elimina el campo obligatorio de nombre, esto no se registrará correctamente con la compatibilidad HACIA ADELANTE. Los consumidores de la versión anterior no podrían leer los esquemas propuestos, ya que les falta el campo obligatorio de nombre. Sin embargo, si el campo de nombre original era opcional, entonces el nuevo esquema propuesto se registraría correctamente, ya que los consumidores pueden leer datos basados en el nuevo esquema que no incluye el campo opcional de nombre.

  JSON

  Por ejemplo, supongamos que tiene una versión de esquema definida por nombre (opcional), apellido (opcional), email (opcional) y número de teléfono (opcional).

  Si tiene una nueva versión de esquema que elimina la propiedad opcional de número de teléfono, esto se registraría correctamente siempre y cuando la nueva versión del esquema no permita ninguna propiedad adicional al configurar el campo `additionalProperties` en falso. La compatibilidad HACIA ADELANTE requiere que los consumidores puedan leer los datos producidos con el nuevo esquema utilizando la versión anterior.

  Si tiene una sugerencia de una versión de esquema que elimina la propiedad opcional de número de teléfono, esto no se registraría correctamente con la compatibilidad HACIA ADELANTE cuando la nueva versión del esquema establece el campo `additionalProperties` a verdadero, es decir, permite cualquier propiedad adicional. Los consumidores de la versión anterior no podrían

leer los esquemas propuestos, ya que podrían tener la propiedad de número de teléfono en un tipo diferente, por ejemplo, cadena en lugar de número.

PROTOBUF

Por ejemplo, suponga que tiene una versión de esquema definida por un mensaje `Person` con `first name` (obligatorio), `last name`(obligatorio) y `email` (opcional) en la sintaxis proto2.

De manera semejante a las situaciones de AVRO, si tiene una nueva versión de esquema que agrega un campo obligatorio, p. ej., `phone number`, esto se registraría correctamente. La compatibilidad HACIA ADELANTE requiere que los consumidores puedan leer los datos producidos con el nuevo esquema utilizando la versión anterior.

Si tiene una sugerencia de una versión de esquema que elimina el campo obligatorio de `first name`, esto no se registrará correctamente con la compatibilidad CON VERSIONES FUTURAS. Los consumidores de la versión anterior no podrían leer los esquemas propuestos, ya que les falta el campo obligatorio de `first name`. Sin embargo, si el campo de `first name` original era opcional, entonces el nuevo esquema propuesto se registraría correctamente, ya que los consumidores pueden leer datos basados en el nuevo esquema que no incluye el campo opcional de `first name`.

En caso de un caso de uso de gRPC, quitar un servicio RPC o un método RPC es un cambio compatible con versiones futuras. Por ejemplo, suponga que tiene una versión de esquema definida por un servicio RPC `MyService` con dos métodos RPC, `Foo` y `Bar`.

Si la próxima versión del esquema elimina el método RPC existente denominado `Foo`, esto se registraría correctamente según la compatibilidad CON VERSIONES FUTURAS, ya que los consumidores pueden leer los datos producidos con el nuevo esquema utilizando la versión anterior. Si tiene una sugerencia de una nueva versión de esquema que agrega un método RPC de `Baz`, esto no se registrará correctamente con la compatibilidad CON VERSIONES FUTURAS. Los consumidores de la versión anterior no podrían leer los esquemas propuestos, ya que les falta el método RPC de `Baz`.

- FORWARD_ALL (HACIA ADELANTE_TODO): esta opción de compatibilidad permite a los consumidores leer datos escritos por los productores de cualquier nuevo esquema registrado. Puede utilizar esta opción cuando necesite agregar campos o eliminar campos opcionales, y comprobar la compatibilidad con todas las versiones de esquema anteriores.
- FULL (COMPLETO): esta opción de compatibilidad permite a los consumidores leer los datos escritos por los productores con la versión inmediatamente anterior o siguiente del esquema, pero

no necesariamente versiones anteriores o posteriores. Puede utilizar esta opción para comprobar la compatibilidad con la última versión del esquema cuando elimine campos o agregue campos adicionales.

- FULL_ALL (COMPLETO_TODO): esta opción de compatibilidad permite a los consumidores leer los datos escritos por los productores con todas las versiones de esquema anteriores. Puede utilizar esta opción para comprobar la compatibilidad con todas las versiones anteriores del esquema, cuando agregue o elimine campos opcionales.

Bibliotecas Serde de código abierto

AWS proporciona bibliotecas Serde de código abierto como marco para serializar y deserializar datos. El diseño de código abierto de estas bibliotecas permite que las aplicaciones y marcos de código abierto comunes soporten estas bibliotecas en sus proyectos.

Para obtener más detalles sobre cómo funcionan las bibliotecas de Serde, consulte Cómo funciona Schema Registry.

Cuotas del Schema Registry

Las cuotas, también conocidas como límites en AWS, son el valor máximo de los recursos, acciones y elementos de su cuenta de AWS. Los siguientes son los límites flexibles para el Schema Registry en AWS Glue.

Pares de clave-valor de metadatos de la versión del esquema

Puede tener hasta 10 pares clave-valor por SchemaVersion por región de AWS.

Puede ver o establecer los pares de metadatos clave-valor con las API Acción QuerySchemaVersionMetadata (Python: query_schema_version_metadata) o Acción PutSchemaVersionMetadata (Python: put_schema_version_metadata).

Los siguientes son los límites invariables para el Schema Registry en AWS Glue.

Registries

Puede tener hasta 100 registros por región de AWS para esta cuenta.

SchemaVersion

Puede tener hasta 10 000 versiones de esquema por región de AWS para esta cuenta.

Cada esquema nuevo crea una nueva versión de esquema, por lo que teóricamente puede tener hasta 10 000 esquemas por cuenta por región, si es que cada esquema tiene una sola versión.

Cargas de esquema

Hay un límite de tamaño de 170 KB para las cargas de esquema.

Cómo funciona Schema Registry

En esta sección se describe cómo funcionan los procesos de serialización y deserialización en Schema Registry.

1. Registrar un esquema: si el esquema aún no existe en el registro, puede registrarse con un nombre de esquema igual al nombre del destino (por ejemplo, test_topic, test_stream, prod_firehose) o el productor puede proporcionar un nombre personalizado para el esquema. Los productores también pueden agregar pares clave-valor al esquema como metadatos, como orígenes: msk_kafka_topic_a, o aplicar etiquetas AWS a esquemas en la creación de esquemas. Una vez registrado un esquema, el Schema Registry devuelve el ID de versión del esquema al serializador. Si el esquema existe pero el serializador está utilizando una nueva versión que no existe, Schema Registry comprobará la referencia del esquema en función de una regla de compatibilidad para asegurarse de que la nueva versión es compatible antes de registrarla como una nueva versión.

   Existen dos métodos para registrar un esquema: registro manual y registro automático. Puede registrar un esquema manualmente a través de la consola de AWS Glue o CLI/SDK.

   Cuando el registro automático está activado en la configuración del serializador, se realizará el registro automático del esquema. Si no se proporciona el `REGISTRY_NAME` en las configuraciones del productor, entonces el registro automático registrará la nueva versión del esquema según el registro predeterminado (default-registry). Consulte Instalación de bibliotecas SerDe para obtener información sobre cómo especificar la propiedad de registro automático.
2. El serializador valida los registros de datos respecto del esquema: cuando la aplicación que produce datos ha registrado su esquema, el serializador de Schema Registry valida que el registro que está produciendo la aplicación se estructure con los campos y tipos de datos que coincidan con un esquema registrado. Si el esquema del registro no coincide con un esquema registrado, el serializador devolverá una excepción y la aplicación no entregará el registro al destino.

Si no existe ningún esquema y si el nombre del esquema no se proporciona a través de las configuraciones del productor, el esquema se crea con el mismo nombre que el nombre del tema (si es Apache Kafka o Amazon MSK) o el nombre del flujo (si es Kinesis Data Streams).

Cada registro tiene una definición de esquema y datos. La definición de esquema se consulta respecto de los esquemas y versiones existentes en el Schema Registry.

De forma predeterminada, los productores almacenan en caché las definiciones de esquema y los ID de versión de esquema de los esquemas registrados. Si la definición de versión de esquema de un registro no coincide con lo que está disponible en caché, el productor intentará validar el esquema con Schema Registry. Si la versión del esquema es válida, su ID de versión y definición se almacenarán en caché de manera local en el productor.

Puede ajustar el período de caché predeterminado (24 horas) dentro de las propiedades del productor opcionales en el paso n.º 3 de Instalación de bibliotecas SerDe.

3. Serializar y entregar registros: si el registro cumple con el esquema, el serializador agrega a cada registro el ID de la versión del esquema, serializa el registro en función del formato de datos seleccionado (AVRO, JSON, Protobuf u otros formatos próximamente), comprime el registro (configuración opcional del productor) y lo entrega al destino.
4. Los consumidores deserializan los datos: los consumidores que leen estos datos utilizan la biblioteca del deserializador de Schema Registry que analiza el ID de versión del esquema proveniente de la carga del registro.
5. El deserializador puede solicitar el esquema desde el Schema Registry: si es la primera vez que el deserializador ha visto registros con un identificador de versión de esquema concreto, a través del ID de versión de esquema, el deserializador solicitará el esquema desde Schema Registry y almacenará el esquema localmente en el consumidor. Si Schema Registry no puede deserializar el registro, el consumidor puede registrar los datos a partir del registro y continuar, o detener la aplicación.
6. El deserializador utiliza el esquema para deserializar el registro: cuando el deserializador recupera el ID de versión del esquema de Schema Registry, descomprime el registro (si el registro enviado por el productor está comprimido) y utiliza el esquema para deserializar el registro. La aplicación procesa ahora el registro.

> **Note**
>
> Cifrado: sus clientes se comunican con Schema Registry a través de llamadas a la API que cifran los datos en tránsito mediante el cifrado TLS a través de HTTPS. Los esquemas almacenados en Schema Registry siempre se cifran en reposo mediante una clave AWS Key Management Service (AWS KMS) administrada por el servicio.

> **Note**
>
> Autorización de usuario: el registro de esquemas admite políticas de IAM basadas en identidad.

Introducción a Schema Registry

Las siguientes secciones ofrecen información general y una guía para configurar y empezar a utilizar Schema Registry. Para obtener más información sobre los conceptos y componentes de Schema Registry, consulte AWS Glue Schema Registry.

Temas

- Instalación de bibliotecas SerDe
- Integración con AWS Glue Schema Registry
- Migración desde un registro de esquemas de terceros a AWS Glue Schema Registry

Instalación de bibliotecas SerDe

Las bibliotecas SerDe proporcionan un marco para serializar y deserializar datos.

Instalará el serializador de código abierto para sus aplicaciones que producen datos (colectivamente los “serializadores”). El serializador controla la serialización, la compresión y la interacción con Schema Registry. El serializador extrae automáticamente el esquema de un registro que se está escribiendo en un destino compatible con Schema Registry, como Amazon MSK. Del mismo modo, instalará el deserializador de código abierto en sus aplicaciones que consumen datos.

Implementación de Java

> **Note**
>
> Requisitos previos: antes de completar los siguientes pasos, deberá tener un clúster de Amazon Managed Streaming for Apache Kafka (Amazon MSK) o Apache Kafka en ejecución. Sus productores y consumidores deben ejecutarse en Java 8 o superior.

Para instalar las bibliotecas en productores y consumidores:

1. Dentro de los archivos pom.xml de los productores y consumidores, agregue esta dependencia a través del siguiente código:

   ```
   <dependency>
       <groupId>software.amazon.glue</groupId>
       <artifactId>schema-registry-serde</artifactId>
       <version>1.1.5</version>
   </dependency>
   ```

   También puede clonar el repositorio Github de AWS Glue Schema Registry.

2. Configure sus productores con estas propiedades requeridas:

   ```
   props.put(ProducerConfig.KEY_SERIALIZER_CLASS_CONFIG,
    StringSerializer.class.getName()); // Can replace StringSerializer.class.getName())
    with any other key serializer that you may use
   props.put(ProducerConfig.VALUE_SERIALIZER_CLASS_CONFIG,
    GlueSchemaRegistryKafkaSerializer.class.getName());
   props.put(AWSSchemaRegistryConstants.AWS_REGION, "us-east-2");
   properties.put(AWSSchemaRegistryConstants.DATA_FORMAT, "JSON"); // OR "AVRO"
   ```

   Si no hay esquemas existentes, debe activarse el registro automático (siguiente paso). Si tiene un esquema que desea aplicar, reemplace “my-schema (mi esquema)” con su nombre de esquema. También debe proporcionarse el “registry-name (nombre del registro)” si el registro automático del esquema está desactivado. Si el esquema se crea como “default-registry (registro predeterminado)”, entonces el nombre del registro se puede omitir.

3. (Opcional) configure cualquiera de estas propiedades de productor opcionales. Para ver descripciones detalladas de propiedades, consulte el archivo ReadMe (Léame).

```
props.put(AWSSchemaRegistryConstants.SCHEMA_AUTO_REGISTRATION_SETTING, "true"); // If
 not passed, uses "false"
props.put(AWSSchemaRegistryConstants.SCHEMA_NAME, "my-schema"); // If not passed,
 uses transport name (topic name in case of Kafka, or stream name in case of Kinesis
 Data Streams)
props.put(AWSSchemaRegistryConstants.REGISTRY_NAME, "my-registry"); // If not passed,
 uses "default-registry"
props.put(AWSSchemaRegistryConstants.CACHE_TIME_TO_LIVE_MILLIS, "86400000"); // If
 not passed, uses 86400000 (24 Hours)
props.put(AWSSchemaRegistryConstants.CACHE_SIZE, "10"); // default value is 200
props.put(AWSSchemaRegistryConstants.COMPATIBILITY_SETTING, Compatibility.FULL); //
 Pass a compatibility mode. If not passed, uses Compatibility.BACKWARD
props.put(AWSSchemaRegistryConstants.DESCRIPTION, "This registry is used for several
 purposes."); // If not passed, constructs a description
props.put(AWSSchemaRegistryConstants.COMPRESSION_TYPE,
 AWSSchemaRegistryConstants.COMPRESSION.ZLIB); // If not passed, records are sent
 uncompressed
```

El registro automático registra la versión del esquema en el registro predeterminado (“default-registry”). Si no se especifica un SCHEMA_NAME en el paso anterior, entonces el nombre del tema se infiere como el SCHEMA_NAME.

Consulte Compatibilidad y control de versiones de esquemas para obtener más información sobre los modos de compatibilidad.

4. Configure sus consumidores con estas propiedades obligatorias:

```
props.put(ConsumerConfig.KEY_DESERIALIZER_CLASS_CONFIG,
 StringDeserializer.class.getName());
props.put(ConsumerConfig.VALUE_DESERIALIZER_CLASS_CONFIG,
 GlueSchemaRegistryKafkaDeserializer.class.getName());
props.put(AWSSchemaRegistryConstants.AWS_REGION, "us-east-2"); // Pass an Región de
 AWS
props.put(AWSSchemaRegistryConstants.AVRO_RECORD_TYPE,
 AvroRecordType.GENERIC_RECORD.getName()); // Only required for AVRO data format
```

5. (Opcional) configure estas propiedades de consumidores opcionales. Para ver descripciones detalladas de propiedades, consulte el archivo ReadMe (Léame).

```
properties.put(AWSSchemaRegistryConstants.CACHE_TIME_TO_LIVE_MILLIS, "86400000"); //
 If not passed, uses 86400000
```

```
props.put(AWSSchemaRegistryConstants.CACHE_SIZE, "10"); // default value is 200
props.put(AWSSchemaRegistryConstants.SECONDARY_DESERIALIZER,
 "com.amazonaws.services.schemaregistry.deserializers.external.ThirdPartyDeserializer"); //
 For migration fall back scenario
```

Implementación de C#

> **Note**
>
> Requisitos previos: antes de completar los siguientes pasos, deberá tener un clúster de Amazon Managed Streaming for Apache Kafka (Amazon MSK) o Apache Kafka en ejecución. Sus productores y consumidores deben ejecutarse en .NET 8.0 o superior.

Instalación

Para las aplicaciones de C#, instale el paquete de NuGet de SerDe de registro de esquema de AWS Glue mediante uno de los siguientes métodos:

.NET CLI:

Para instalar el paquete, use el siguiente comando:

```
dotnet add package Aws.Glue.SchemaRegistry --version 1.0.0-<rid>
```

donde `<rid>` podría ser `1.0.0-linux-x64`, `1.0.0-linux-musl-x64` o `1.0.0-linux-arm64`

PackageReference (en su archivo.csproj):

Añada lo siguiente al archivo del proyecto:

```
<PackageReference Include="Aws.Glue.SchemaRegistry" Version="1.0.0-<rid>" />
```

donde `<rid>` podría ser `1.0.0-linux-x64`, `1.0.0-linux-musl-x64` o `1.0.0-linux-arm64`

Configuración del archivo de configuración

Cree un archivo de propiedades de configuración (por ejemplo, `gsr-config.properties`) con los parámetros necesarios:

Configuración mínima:

El siguiente ejemplo es una configuración mínima de muestra:

```
region=us-east-1
registry.name=default-registry
dataFormat=AVRO
schemaAutoRegistrationEnabled=true
```

Uso de la biblioteca de cliente de esquema de Glue de C# para Kafka SerDes

Ejemplo de uso del serializador:

En el siguiente ejemplo se muestra cómo utilizar el serializador:

```
private static readonly string PROTOBUF_CONFIG_PATH = "<PATH_TO_CONFIG_FILE>";
var protobufSerializer = new GlueSchemaRegistryKafkaSerializer(PROTOBUF_CONFIG_PATH);
var serialized = protobufSerializer.Serialize(message, message.Descriptor.FullName);
// send serialized bytes to Kafka using producer.Produce(serialized)
```

Ejemplo de uso del deserializador:

En el siguiente ejemplo se muestra cómo utilizar el deserializador:

```
private static readonly string PROTOBUF_CONFIG_PATH = "<PATH_TO_CONFIG_FILE>";
var dataConfig = new GlueSchemaRegistryDataFormatConfiguration(
    new Dictionary<string, dynamic>
    {
        {
            GlueSchemaRegistryConstants.ProtobufMessageDescriptor, message.Descriptor
        }
    }
);
var protobufDeserializer = new
 GlueSchemaRegistryKafkaDeserializer(PROTOBUF_CONFIG_PATH, dataConfig);

// read message from Kafka using serialized = consumer.Consume()
var deserializedObject = protobufDeserializer.Deserialize(message.Descriptor.FullName,
 serialized);
```

Uso de la biblioteca de cliente de esquema de Glue de C# con KafkaFlow para SerDes

Ejemplo de uso del serializador:

En el siguiente ejemplo se muestra cómo configurar KafkaFlow con el serializador:

```
services.AddKafka(kafka => kafka
    .UseConsoleLog()
    .AddCluster(cluster => cluster
        .WithBrokers(new[] { "localhost:9092" })
        .AddProducer<CustomerProducer>(producer => producer
            .DefaultTopic("customer-events")
            .AddMiddlewares(m => m

 .AddSerializer<GlueSchemaRegistryKafkaFlowProtobufSerializer<Customer>>(
                    () => new
 GlueSchemaRegistryKafkaFlowProtobufSerializer<Customer>("config/gsr-
config.properties")
                )
            )
        )
    )
);
```

Ejemplo de uso del deserializador:

En el siguiente ejemplo se muestra cómo configurar KafkaFlow con el deserializador:

```
.AddConsumer(consumer => consumer
    .Topic("customer-events")
    .WithGroupId("customer-group")
    .WithBufferSize(100)
    .WithWorkersCount(10)
    .AddMiddlewares(middlewares => middlewares
        .AddDeserializer<GlueSchemaRegistryKafkaFlowProtobufDeserializer<Customer>>(
            () => new
 GlueSchemaRegistryKafkaFlowProtobufDeserializer<Customer>("config/gsr-
config.properties")
        )
        .AddTypedHandlers(h => h.AddHandler<CustomerHandler>())
    )
)
```

Propiedades opcionales del productor

Puede ampliar el archivo de configuración con propiedades opcionales adicionales:

```
# Auto-registration (if not passed, uses "false")
schemaAutoRegistrationEnabled=true

# Schema name (if not passed, uses topic name)
schema.name=my-schema

# Registry name (if not passed, uses "default-registry")
registry.name=my-registry

# Cache settings
cacheTimeToLiveMillis=86400000
cacheSize=200

# Compatibility mode (if not passed, uses BACKWARD)
compatibility=FULL

# Registry description
description=This registry is used for several purposes.

# Compression (if not passed, records are sent uncompressed)
compressionType=ZLIB
```

Formatos de fecha admitidos

Las implementaciones de Java y C# admiten los mismos formatos de datos:

- AVRO: formato binario JSON Apache Avro.
- JSON: formato de esquemas JSON
- PROTOBUF: formato de búferes de protocolo

Notas

- Para empezar a utilizar la biblioteca, visite https://www.nuget.org/packages/AWS.Glue.SchemaRegistry
- El código fuente está disponible en: https://github.com/awslabs/aws-glue-schema-registry

Creación de un registro

Puede utilizar el registro predeterminado o crear tantos registros nuevos como sea necesario mediante las API de AWS Glue o la consola de AWS Glue.

Las API de AWS Glue

Puede seguir estos pasos para realizar esta tarea mediante las API de AWS Glue.

Para utilizar AWS CLI para las API de AWS Glue Schema Registry, asegúrese de actualizar su AWS CLI a la versión más reciente.

Para agregar un registro nuevo, use la API de Acción CreateRegistry (Python: create_registry). Especifique `RegistryName` como el nombre del registro que se va a crear con una longitud máxima de 255, y solo puede contener letras, números, guión, guión bajo, signo de dólar o marca hash.

Especifique una `Description` como una cadena cuya extensión no sea más de 2048 bytes y que coincida con el patrón de cadena de varias líneas de la dirección URI.

De manera opcional, especifique una o varias `Tags` para su registro, como matriz de mapas de pares clave-valor.

```
aws glue create-registry --registry-name registryName1 --description description
```

Cuando se crea el registro se le asigna un nombre de recurso de Amazon (ARN). Este ARN lo puede ver en `RegistryArn` de la respuesta de la API. Ahora que ha creado un registro, cree uno o más esquemas para ese registro.

Consola de AWS Glue

Para agregar un nuevo registro en la consola de AWS Glue:

1. Inicie sesión en Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. En el panel de navegación, en Data catalog (Catálogo de datos), elija Schema registries (Registros de esquemas).
3. Elija Add registry (Agregar registro).
4. Escriba un Registry name (Nombre del Registro) para el registro, que conste de letras, números, guiones o guiones bajos. Este nombre no se puede cambiar.
5. Escriba una Description (Descripción) (opcional) para el registro.
6. De manera opcional, aplique una o varias etiquetas a su registro. Elija Add new tag (Agregar nueva etiqueta) y especifique una Tag key (Clave de etiqueta) y, opcionalmente, un Tag value (Valor de etiqueta).
7. Elija Add registry (Agregar registro).

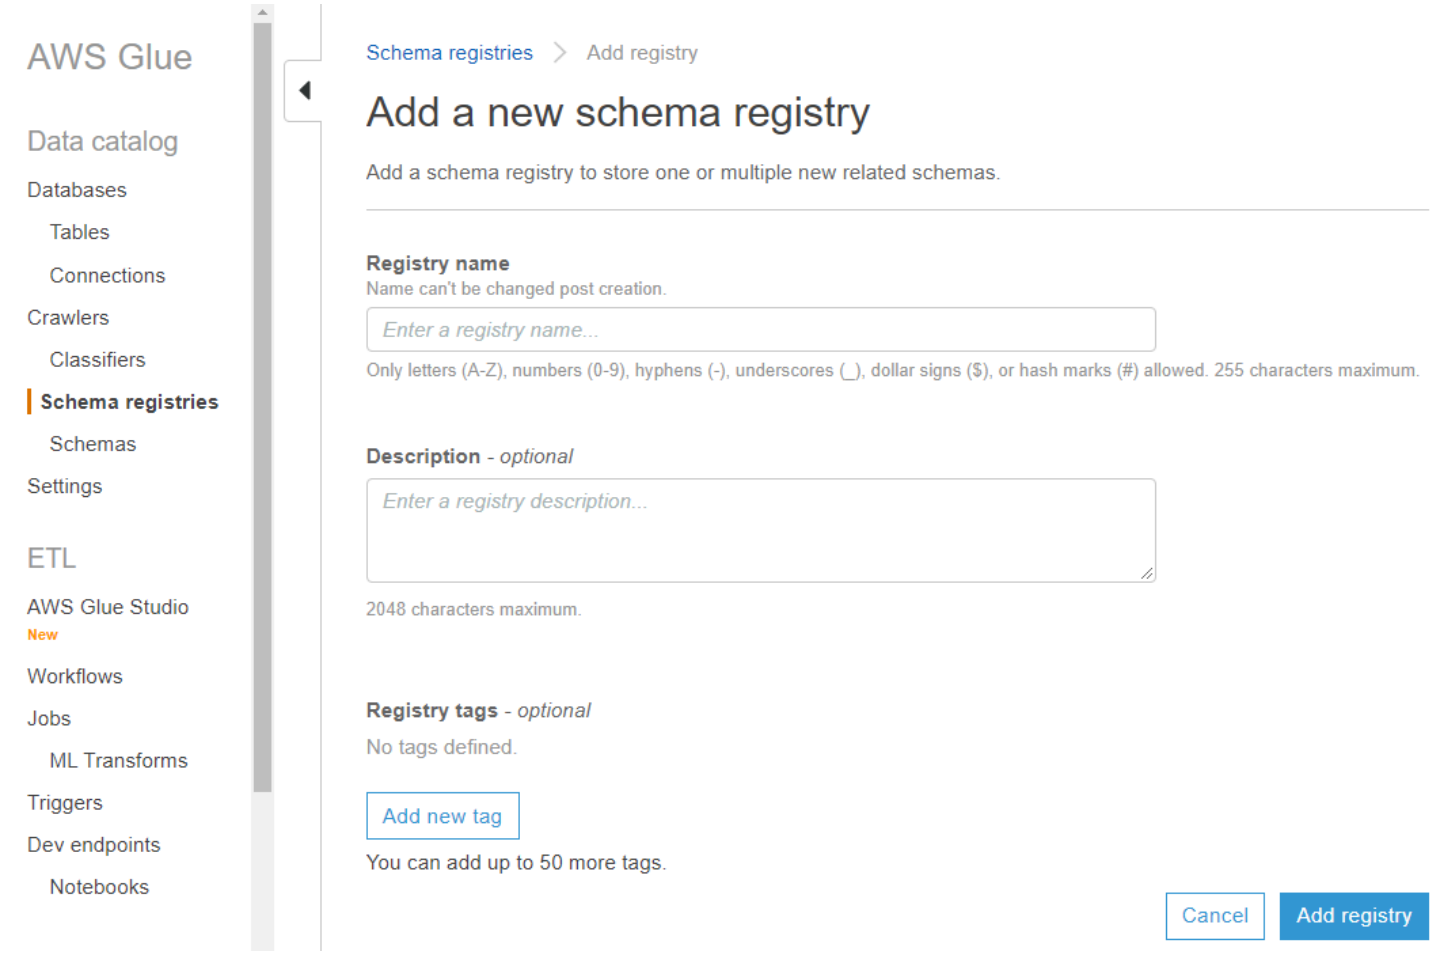

Cuando se crea el registro, se le asigna un nombre de recurso de Amazon (ARN), que puede ver al seleccionar el registro de la lista en Schema registries (Registros de esquemas). Ahora que ha creado un registro, cree uno o más esquemas para ese registro.

Trabajar con un registro específico (JAVA POJO) para JSON

Puede usar un objeto Java antiguo simple (POJO) y transferir el objeto como un registro. Esto es similar a la noción de un registro específico en AVRO. mbknor-jackson-jsonschema puede generar un esquema JSON para el POJO transferido. Esta biblioteca también puede inyectar información adicional en el esquema JSON.

La biblioteca de AWS Glue Schema Registry utiliza el campo “className (nombre de clase)” inyectado en el esquema para proporcionar un nombre de clase completamente clasificado. El deserializador utiliza el campo “className” para deserializar en un objeto de esa clase.

```
 Example class :

@JsonSchemaDescription("This is a car")
```

```
@JsonSchemaTitle("Simple Car Schema")
@Builder
@AllArgsConstructor
@EqualsAndHashCode
// Fully qualified class name to be added to an additionally injected property
// called className for deserializer to determine which class to deserialize
// the bytes into
@JsonSchemaInject(
        strings = {@JsonSchemaString(path = "className",
                value =
 "com.amazonaws.services.schemaregistry.integrationtests.generators.Car")}
)
// List of annotations to help infer JSON Schema are defined by https://github.com/
mbknor/mbknor-jackson-jsonSchema
public class Car {
    @JsonProperty(required = true)
    private String make;

    @JsonProperty(required = true)
    private String model;

    @JsonSchemaDefault("true")
    @JsonProperty
    public boolean used;

    @JsonSchemaInject(ints = {@JsonSchemaInt(path = "multipleOf", value = 1000)})
    @Max(200000)
    @JsonProperty
    private int miles;

    @Min(2000)
    @JsonProperty
    private int year;

    @JsonProperty
    private Date purchaseDate;

    @JsonProperty
    @JsonFormat(shape = JsonFormat.Shape.NUMBER)
    private Date listedDate;

    @JsonProperty
    private String[] owners;
```

```
    @JsonProperty
    private Collection<Float> serviceChecks;

    // Empty constructor is required by Jackson to deserialize bytes
    // into an Object of this class
    public Car() {}
}
```

Creación de un esquema

Puede crear un esquema con las API de AWS Glue o la consola de AWS Glue.

Las API de AWS Glue

Puede seguir estos pasos para realizar esta tarea mediante las API de AWS Glue.

Para agregar un esquema nuevo, use la API de Acción CreateSchema (Python: create_schema).

Especifique una estructura de `RegistryId` para indicar un registro para el esquema. O bien, omita el `RegistryId` para utilizar el registro predeterminado.

Especifique un `SchemaName`, que conste de letras, números, guiones o guiones bajos, y `DataFormat` como **`AVRO`** o **`JSON`**. Una vez configurado el `DataFormat` en un esquema no puede modificarse.

Especifique un modo de `Compatibility`:

- Hacia atrás (recomendado): el consumidor puede leer tanto la versión actual como la anterior.
- Hacia atrás todo: el consumidor puede leer tanto la versión actual como todas las anteriores.
- Hacia adelante: el consumidor puede leer tanto la versión actual como la posterior.
- Hacia adelante todo: el consumidor puede leer tanto la versión actual como todas las versiones posteriores.
- Completo: combinación de hacia atrás y hacia adelante.
- Completo todo: combinación de hacia atrás todos y hacia adelante todos.
- Ninguno: no se realizan comprobaciones de compatibilidad.
- Desactivado: evita cualquier control de versiones para este esquema.

Opcionalmente, especifique `Tags` para su esquema.

Especifique una `SchemaDefinition` para definir el esquema en formato de datos Avro, JSON o Protobuf. Consulte estos ejemplos.

Para el formato de datos Avro:

```
aws glue create-schema --registry-id RegistryName="registryName1" --schema-name
 testschema --compatibility NONE --data-format AVRO --schema-definition "{\"type\":
 \"record\", \"name\": \"r1\", \"fields\": [ {\"name\": \"f1\", \"type\": \"int\"},
 {\"name\": \"f2\", \"type\": \"string\"} ]}"
```

```
aws glue create-schema --registry-id RegistryArn="arn:aws:glue:us-
east-2:901234567890:registry/registryName1" --schema-name testschema --compatibility
 NONE --data-format AVRO  --schema-definition "{\"type\": \"record\", \"name\": \"r1\",
 \"fields\": [ {\"name\": \"f1\", \"type\": \"int\"}, {\"name\": \"f2\", \"type\":
 \"string\"} ]}"
```

Para el formato de datos JSON:

```
aws glue create-schema --registry-id RegistryName="registryName" --schema-name
 testSchemaJson --compatibility NONE --data-format JSON --schema-definition "{\"$schema
\": \"http://json-schema.org/draft-07/schema#\",\"type\":\"object\",\"properties\":
{\"f1\":{\"type\":\"string\"}}}"
```

```
aws glue create-schema --registry-id RegistryArn="arn:aws:glue:us-
east-2:901234567890:registry/registryName" --schema-name testSchemaJson --compatibility
 NONE --data-format JSON --schema-definition "{\"$schema\": \"http://json-schema.org/
draft-07/schema#\",\"type\":\"object\",\"properties\":{\"f1\":{\"type\":\"string\"}}}"
```

Para el formato de datos Protobuf:

```
aws glue create-schema --registry-id RegistryName="registryName" --schema-name
 testSchemaProtobuf --compatibility NONE --data-format PROTOBUF --schema-definition
 "syntax = \"proto2\";package org.test;message Basic { optional int32 basic = 1;}"
```

```
aws glue create-schema --registry-id RegistryArn="arn:aws:glue:us-
east-2:901234567890:registry/registryName" --schema-name testSchemaProtobuf
 --compatibility NONE --data-format PROTOBUF --schema-definition "syntax =
 \"proto2\";package org.test;message Basic { optional int32 basic = 1;}"
```

Consola de AWS Glue

Para agregar un nuevo esquema a través de la consola de AWS Glue:

1. Inicie sesión en la consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. En el panel de navegación, en Data catalog (Catálogo de datos), elija Schema (Esquemas).
3. Elija Add schema (Agregar esquema).
4. Escriba un Schema name (Nombre del esquema), que conste de letras, números, guiones, guiones bajos, signos de dólar o marcas hash. Este nombre no se puede cambiar.
5. Elija el Registry (Registro) en el que se almacenará el esquema del menú desplegable. El registro principal no se puede cambiar después de la creación.
6. Deje el Data format (Formato de los datos) como Apache Avro o JSON. Este formato se aplica a todas las versiones de este esquema.
7. Elija un (Compatibility mode) Modo de compatibilidad.
   - Hacia atrás (recomendado): el receptor puede leer tanto la versión actual como la anterior.
   - Hacia atrás todo: el receptor puede leer tanto la versión actual como todas las anteriores.
   - Hacia adelante: el remitente puede escribir tanto la versión actual como la anterior.
   - Hacia adelante todo: el remitente puede escribir tanto la versión actual como todas las versiones anteriores.
   - Completo: combinación de hacia atrás y hacia adelante.
   - Completo todo: combinación de hacia atrás todos y hacia adelante todos.
   - Ninguno: no se realizan comprobaciones de compatibilidad.
   - Desactivado: evita cualquier control de versiones para este esquema.
8. Escriba una Description (Descripción) para el registro de hasta 250 caracteres.

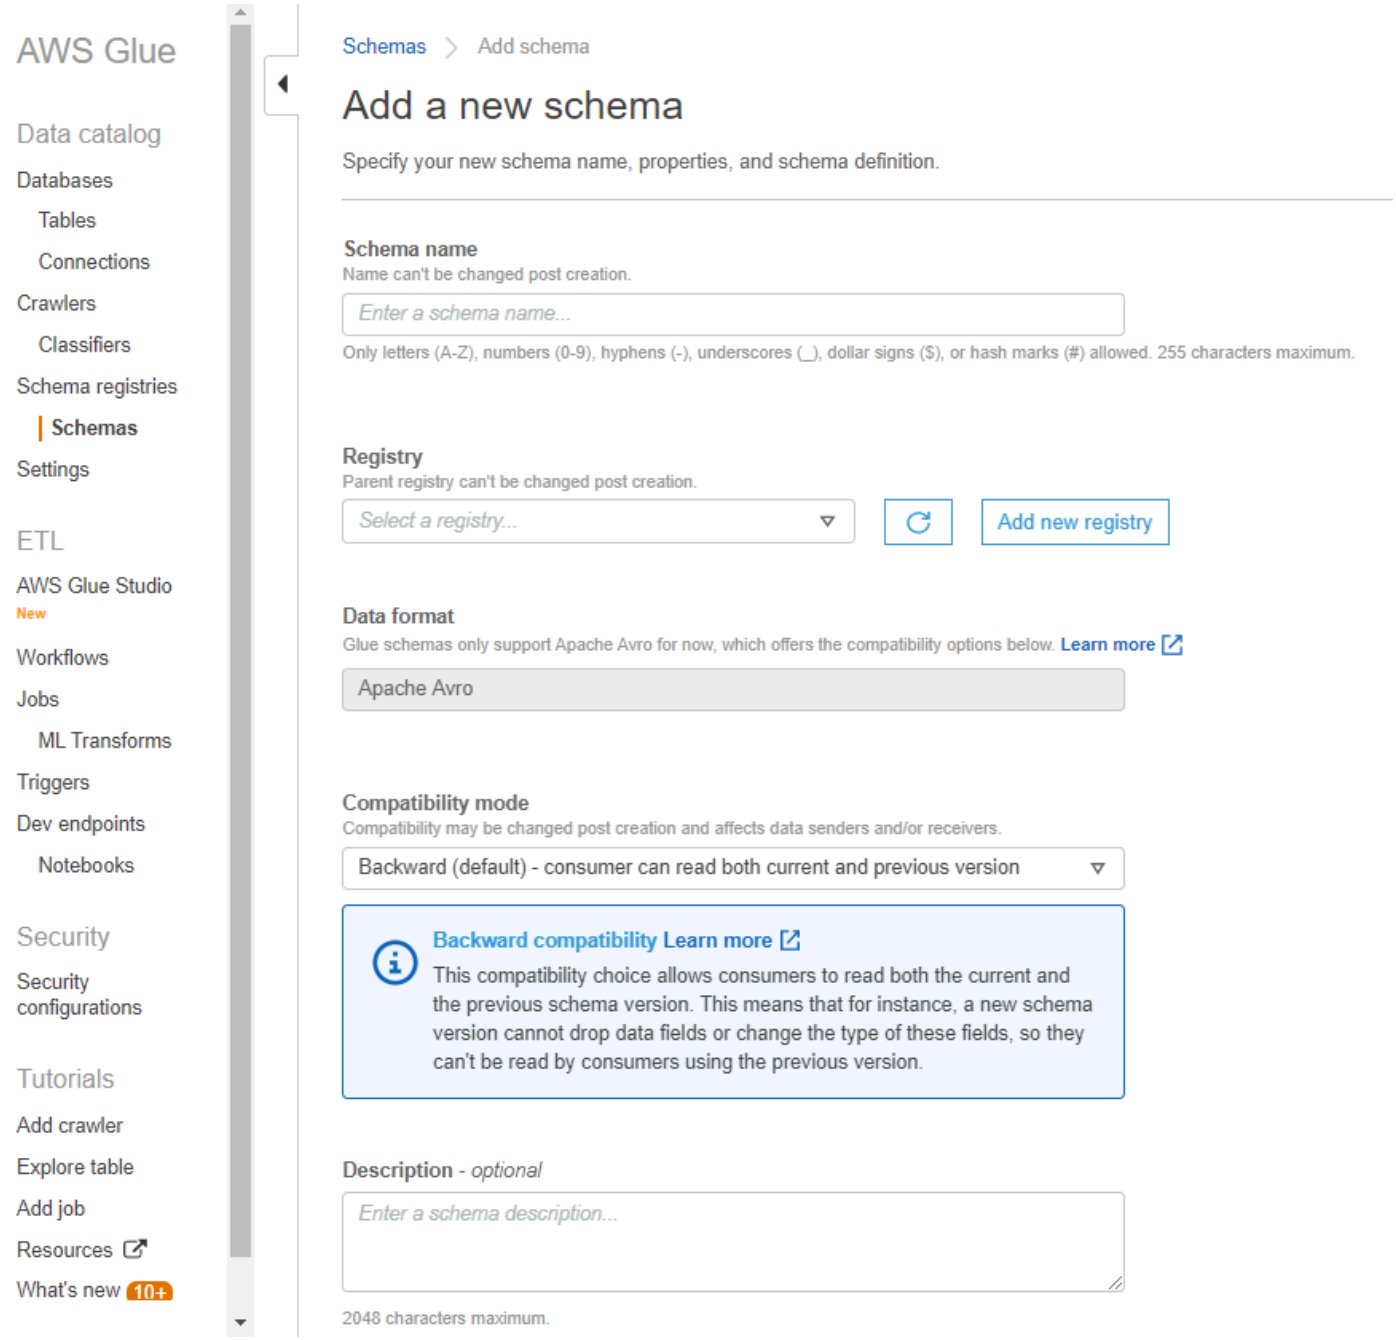

9. De manera opcional, aplique una o varias etiquetas a su esquema. Elija Add new tag (Agregar nueva etiqueta) y especifique una Tag key (Clave de etiqueta) y, opcionalmente, un Tag value (Valor de etiqueta).
10. En la casilla, First schema version (Primera versión del esquema), ingrese o pegue el esquema inicial.

    Para el formato Avro, consulte Trabajar con formato de datos Avro

Para el formato JSON, consulte Trabajar con formato de datos JSON

11. También puede seleccionar Add metadata (Agregar metadatos) para agregar metadatos de versión para anotar o clasificar la versión del esquema.

12. Elija Create schema and version (Crear esquema y versión).

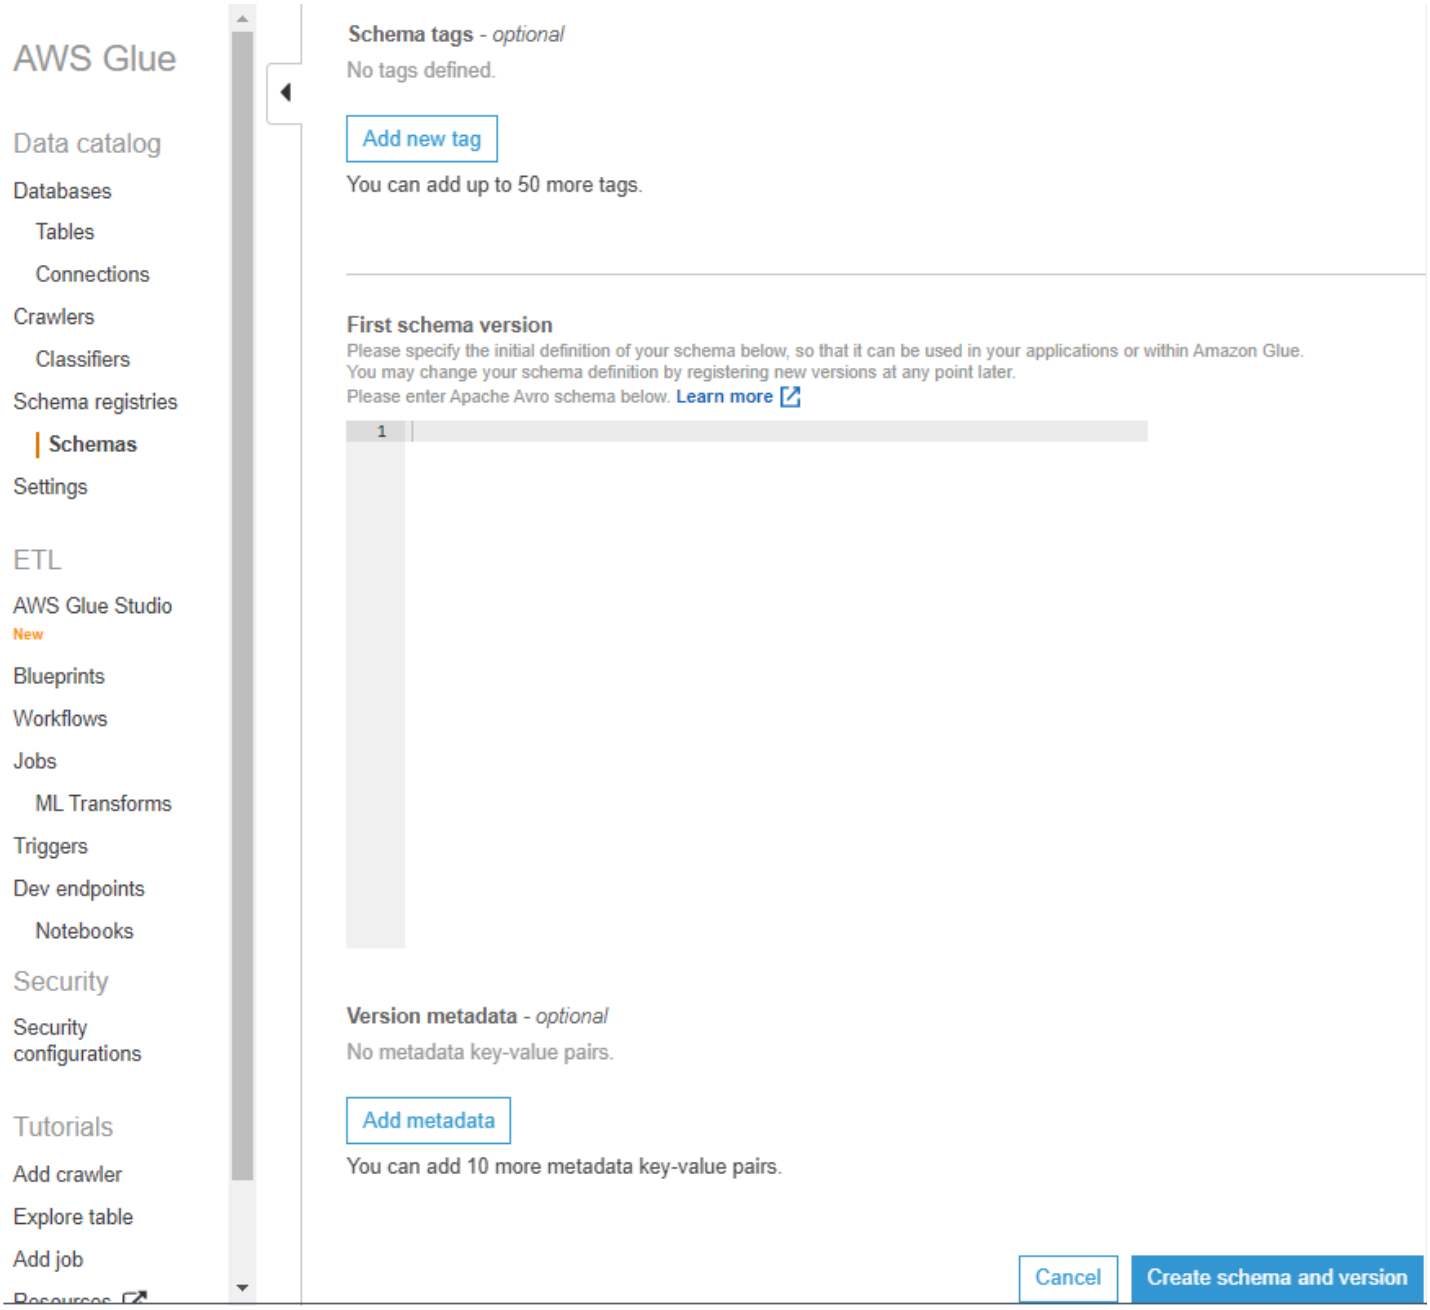

El esquema se crea y aparece en la lista en Schemas (Esquemas).

Trabajar con formato de datos Avro

Avro proporciona servicios de serialización e intercambio de datos. Avro almacena la definición de datos en formato JSON, lo que facilita su lectura e interpretación. Los datos en sí se almacenan en formato binario.

Para obtener información sobre cómo definir un esquema Apache Avro, consulte la especificación de Apache Avro.

Trabajar con formato de datos JSON

Los datos se pueden serializar con formato JSON. Formato de esquemas JSON define el estándar para el formato de esquema JSON.

Actualización de un esquema o registro

Una vez creado, puede editar los esquemas, las versiones de esquema o el registro.

Actualización de un registro

Puede actualizar un registro mediante las API de AWS Glue o la consola de AWS Glue. No se puede editar el nombre de un registro existente. La descripción de un registro puede editarse.

Las API de AWS Glue

Para actualizar un registro existente, use la API Acción UpdateRegistry (Python: update_registry).

Especifique una estructura de `RegistryId` para indicar el registro que desea actualizar. Transferir una `Description` para cambiar la descripción de un registro.

```
aws glue update-registry --description updatedDescription --registry-id
 RegistryArn="arn:aws:glue:us-east-2:901234567890:registry/registryName1"
```

Consola de AWS Glue

Para actualizar un registro mediante la consola de AWS Glue:

1. Inicie sesión en Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. En el panel de navegación, en Data catalog (Catálogo de datos), elija Schema registries (Registros de esquemas).

3. Seleccione un registro de la lista de registros, al marcar la casilla correspondiente.
4. En el menú Action (Acción), elija Edit registry (Editar registro).

Actualización de un esquema

Puede actualizar la descripción o la configuración de compatibilidad de un esquema.

Para actualizar un esquema existente, use la API Acción UpdateSchema (Python: update_schema).

Especifique una estructura de `SchemaId` para indicar el esquema que desea actualizar. Uno de `VersionNumber` o `Compatibility` debe ser proporcionado.

Ejemplos de código 11:

```
aws glue update-schema --description testDescription --schema-id
 SchemaName="testSchema1",RegistryName="registryName1" --schema-version-number
 LatestVersion=true --compatibility NONE
```

```
aws glue update-schema --description testDescription --schema-id
 SchemaArn="arn:aws:glue:us-east-2:901234567890:schema/registryName1/testSchema1" --
schema-version-number LatestVersion=true --compatibility NONE
```

Agregar una versión de esquema.

Cuando agregue una versión de esquema, deberá comparar las versiones para asegurarse de que se aceptará el nuevo esquema.

Para agregar una nueva versión a un esquema existente, utilice la API Acción RegisterSchemaVersion (Python: register_schema_version).

Especifique una estructura de `SchemaId` para indicar el esquema para el que desea agregar una versión, y una `SchemaDefinition` para definir el esquema.

Ejemplos de código 12:

```
aws glue register-schema-version --schema-definition "{\"type\": \"record\", \"name\":
 \"r1\", \"fields\": [ {\"name\": \"f1\", \"type\": \"int\"}, {\"name\": \"f2\", \"type
\": \"string\"} ]}" --schema-id SchemaArn="arn:aws:glue:us-east-1:901234567890:schema/
registryName/testschema"
```

```
aws glue register-schema-version --schema-definition "{\"type\": \"record\", \"name\":
 \"r1\", \"fields\": [ {\"name\": \"f1\", \"type\": \"int\"}, {\"name\": \"f2\", \"type
\": \"string\"} ]}" --schema-id SchemaName="testschema",RegistryName="testregistry"
```

1. Inicie sesión en Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. En el panel de navegación, en Data catalog (Catálogo de datos), elija Schema (Esquemas).
3. Seleccione el esquema de la lista de esquemas, al marcar la casilla correspondiente.
4. Seleccione uno o varios esquemas de la lista, al marcar las casillas correspondientes.
5. En el menú Action (Acción), elija Register new version (Registrar nueva versión).
6. En la casilla New version (Nueva versión), ingrese o pegue el nuevo esquema.
7. Elija Compare with previous version (Comparar con la versión anterior) para ver las diferencias con la versión del esquema anterior.
8. También puede seleccionar Add metadata (Agregar metadatos) para agregar metadatos de versión para anotar o clasificar la versión del esquema. Ingrese Key (Clave) y Value (Valor) opcional.
9. Elija Register version (Registrar versión).

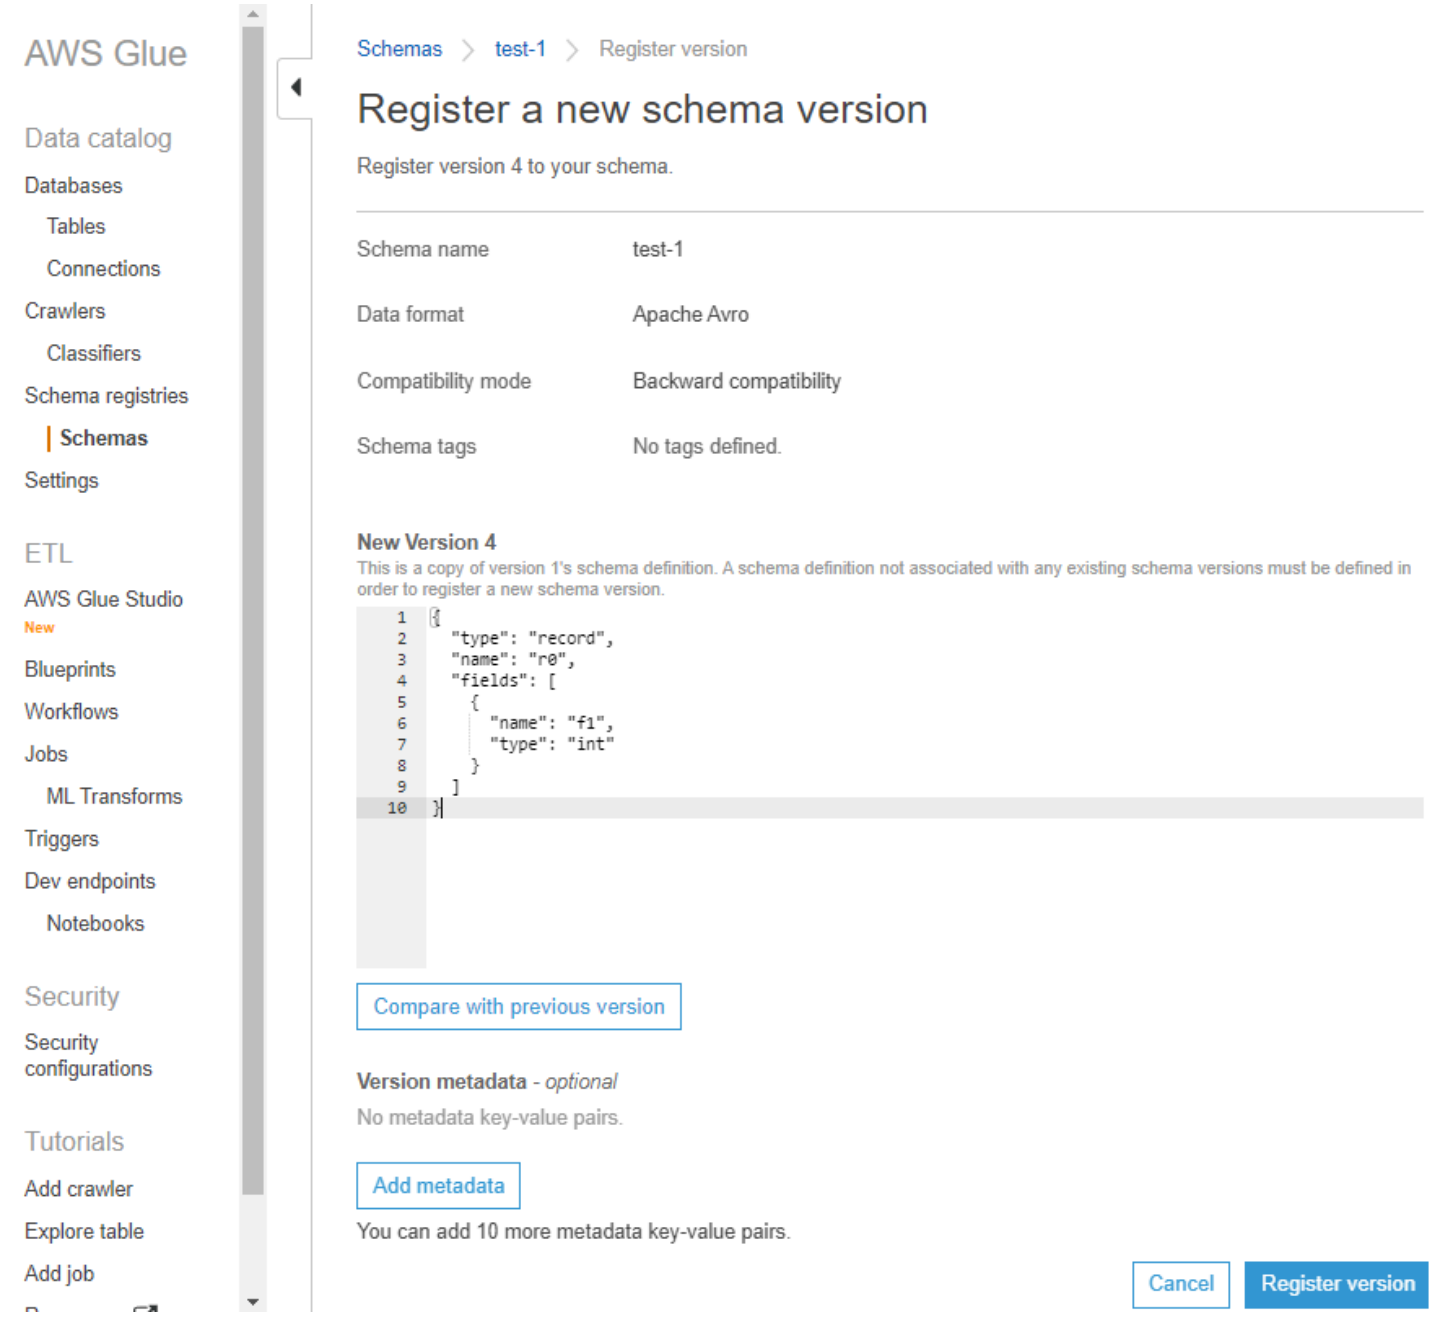

La versión de esquema(s) aparece en la lista de versiones. Si la versión cambió el modo de compatibilidad, la versión se marcará como punto de control.

Ejemplo de comparación de versiones de esquema.

Cuando elige Compare with previous version (Comparar con la versión anterior), verá las versiones anterior y nueva mostradas juntas. La información que se modificó se resaltará de la siguiente manera:

- Amarillo: indica información modificada.
- Verde: indica el contenido agregado en la última versión.
- Rojo: indica el contenido eliminado de la última versión.

También se pueden realizar comparaciones con versiones anteriores.

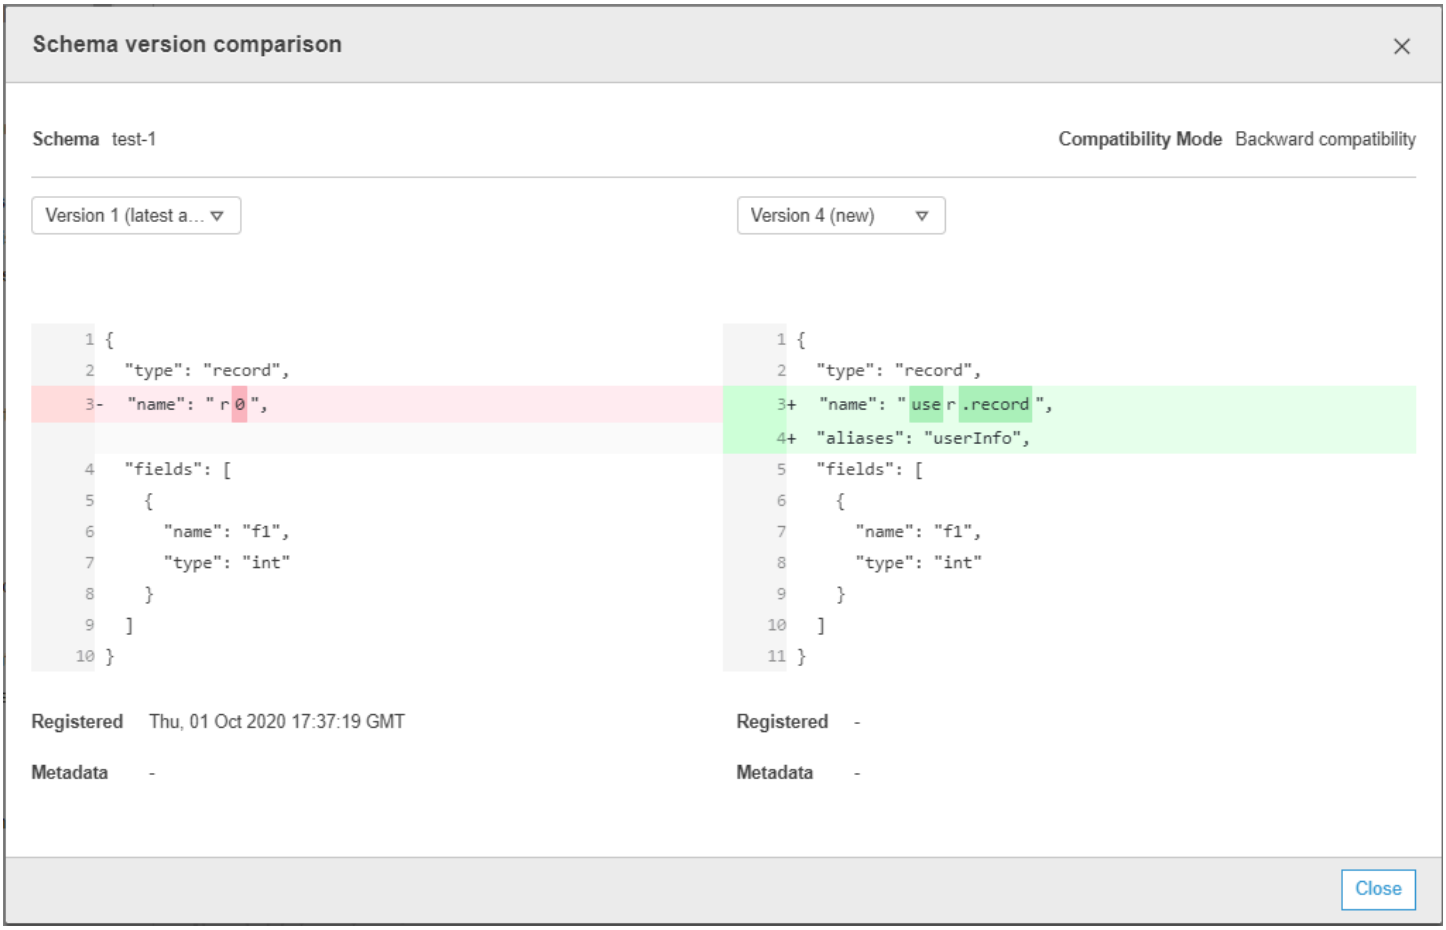

Eliminación de un esquema o registro

Eliminar un esquema, una versión de esquema o un registro son acciones permanentes que no se pueden deshacer.

Eliminación de un esquema

Es posible que desee eliminar un esquema cuando ya no se utilizará dentro de un registro, utilizando la consola Consola de administración de AWS, o la API Acción DeleteSchema (Python: delete_schema).

Eliminar uno o varios esquemas es una acción permanente que no se puede deshacer. Asegúrese de que el esquema o los esquemas ya no son necesarios.

Para eliminar un esquema del registro, llame a la API Acción DeleteSchema (Python: delete_schema), y especifique la estructura de `SchemaId` para identificar el esquema.

Por ejemplo:

```
aws glue delete-schema --schema-id SchemaArn="arn:aws:glue:us-
east-2:901234567890:schema/registryName1/schemaname"
```

```
aws glue delete-schema --schema-id SchemaName="TestSchema6-
deleteschemabyname",RegistryName="default-registry"
```

Consola de AWS Glue

Para eliminar un esquema de la consola de AWS Glue:

1. Inicie sesión en Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. En el panel de navegación, en Data catalog (Catálogo de datos), elija Schema registries (Registros de esquemas).
3. Elija el registro que contiene el esquema de la lista de registros.
4. Seleccione uno o varios esquemas de la lista, al marcar las casillas correspondientes.
5. En el menú Action (Acción), elija Delete schema (Eliminar esquema).
6. Ingrese el texto **`Delete`** en el campo para confirmar la eliminación.
7. Elija Eliminar.

Los esquemas especificados se eliminan del registro.

Eliminar una versión de esquema

A medida que los esquemas se acumulan en el registro, es posible que desee eliminar las versiones de esquema no deseadas mediante la Consola de administración de AWS o la API Acción DeleteSchemaVersions (Python: delete_schema_versions). Eliminar una o varias versiones de esquema es una acción permanente que no se puede deshacer. Asegúrese de que las versiones del esquema ya no sean necesarias.

Al eliminar versiones de esquema, tenga en cuenta las siguientes restricciones:

- No puede eliminar una versión marcada como punto de control.
- El rango de versiones contiguas no puede ser superior a 25.
- La versión del esquema más reciente no debe estar en un estado pendiente.

Especifique la estructura de `SchemaId` para identificar el esquema y especifique las `Versions` como un rango de versiones para eliminar. Para obtener más información sobre cómo especificar una versión o un rango de versiones, consulte Acción DeleteRegistry (Python: delete_registry). Las versiones de los esquemas especificados se eliminan del registro.

Llamar a la API Acción ListSchemaVersions (Python: list_schema_versions) después de esta llamada arrojará una lista del estado de las versiones eliminadas.

Por ejemplo:

```
aws glue delete-schema-versions --schema-id
 SchemaName="TestSchema6",RegistryName="default-registry" --versions "1-1"
```

```
aws glue delete-schema-versions --schema-id SchemaArn="arn:aws:glue:us-
east-2:901234567890:schema/default-registry/TestSchema6-NON-Existent" --versions "1-1"
```

1. Inicie sesión en Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. En el panel de navegación, en Data catalog (Catálogo de datos), elija Schema registries (Registros de esquemas).
3. Elija el registro que contiene el esquema de la lista de registros.
4. Seleccione uno o varios esquemas de la lista, al marcar las casillas correspondientes.
5. En el menú Action (Acción), elija Delete schema (Eliminar esquema).
6. Ingrese el texto **`Delete`** en el campo para confirmar la eliminación.
7. Elija Eliminar.

Las versiones de los esquemas especificados se eliminan del registro.

Eliminación de un registro

Es posible que desee eliminar un registro cuando los esquemas que contiene ya no se organicen en ese registro. Tendrá que reasignar esos esquemas a otro registro.

Eliminar uno o varios registros es una acción permanente que no se puede deshacer. Asegúrese de que el registro o los registros ya no son necesarios.

El registro predeterminado se puede eliminar mediante AWS CLI.

API de AWS Glue

Para eliminar todo el registro, incluido el esquema y todas sus versiones, llame a la API Acción DeleteRegistry (Python: delete_registry). Especifique una estructura de `RegistryId` para identificar el registro.

Por ejemplo:

```
aws glue delete-registry --registry-id RegistryArn="arn:aws:glue:us-
east-2:901234567890:registry/registryName1"
```

```
aws glue delete-registry --registry-id RegistryName="TestRegistry-deletebyname"
```

Para obtener el estado de la operación de eliminación, puede llamar a la API `GetRegistry` después de la llamada asíncrona.

Consola de AWS Glue

Para eliminar un registro de la consola de AWS Glue:

1. Inicie sesión en Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. En el panel de navegación, en Data catalog (Catálogo de datos), elija Schema registries (Registros de esquemas).
3. Seleccione un registro de la lista, al marcar la casilla correspondiente.
4. En el menú Action (Acción), elija Delete registry (Eliminar registro).
5. Ingrese el texto **`Delete`** en el campo para confirmar la eliminación.
6. Elija Eliminar.

Los registros seleccionados se eliminan de AWS Glue.

Ejemplos de IAM para serializadores

> **Note**
>
> AWSLas políticas administradas de conceden los permisos necesarios para los casos de uso comunes. Para obtener información sobre el uso de las políticas para administrar el registro de esquemas, consulte Políticas administradas (predefinidas) por AWS para AWS Glue.

Para los serializadores, debe crear una política mínima similar a la siguiente para poder encontrar el `schemaVersionId` para una definición de esquema determinada. Tenga en cuenta que debe tener permisos de lectura en el registro para poder leer los esquemas del registro. Puede limitar los registros que se pueden leer mediante la cláusula `Resource`.

Ejemplos de código 13:

```
{
    "Sid" : "GetSchemaByDefinition",
    "Effect" : "Allow",
    "Action" :
 [
        "glue:GetSchemaByDefinition"
    ],
        "Resource" : ["arn:aws:glue:us-east-2:012345678:registry/registryname-1",
                      "arn:aws:glue:us-east-2:012345678:schema/registryname-1/
schemaname-1",
                      "arn:aws:glue:us-east-2:012345678:schema/registryname-1/
schemaname-2"
                     ]
}
```

Además, también puede permitir a los productores crear nuevos esquemas y versiones mediante la inclusión de los siguientes métodos adicionales. Tenga en cuenta que debería poder inspeccionar el registro para agregar/eliminar/evolucionar los esquemas dentro de él. Puede limitar los registros que se pueden inspeccionar mediante la cláusula `Resource`.

Ejemplos de código 14:

```
{
```

```
    "Sid" : "RegisterSchemaWithMetadata",
    "Effect" : "Allow",
    "Action" :
 [
        "glue:GetSchemaByDefinition",
        "glue:CreateSchema",
        "glue:RegisterSchemaVersion",
        "glue:PutSchemaVersionMetadata",
    ],
    "Resource" : ["arn:aws:glue:aws-region:123456789012:registry/registryname-1",
                  "arn:aws:glue:aws-region:123456789012:schema/registryname-1/
schemaname-1",
                  "arn:aws:glue:aws-region:123456789012:schema/registryname-1/
schemaname-2"
                ]
}
```

Ejemplos de IAM para deserializadores

Para los deserializadores (lado del consumidor), debe crear una política similar a la siguiente para permitir que el deserializador recupere el esquema de Schema Registry para su deserialización. Tenga en cuenta que debería poder inspeccionar el registro para obtener los esquemas dentro de él.

Ejemplos de código 15:

```
{
    "Sid" : "GetSchemaVersion",
    "Effect" : "Allow",
    "Action" :
 [
        "glue:GetSchemaVersion"
    ],
    "Resource" : ["*"]
}
```

Conectividad privada mediante AWS PrivateLink

Puede usar AWS PrivateLink para conectar la VPC del productor de datos a AWS Glue. Para ello, defina un punto de enlace de la VPC de interfaz para AWS Glue. Cuando se utiliza un punto de enlace de la interfaz de la VPC, la comunicación entre la VPC y AWS Glue se realiza en su totalidad dentro de la red de AWS. Para obtener más información, consulte Uso de AWS Glue con puntos de enlace de la VPC.

Acceso a métricas de Amazon CloudWatch

Las métricas de Amazon CloudWatch están disponibles como parte de la capa gratuita de CloudWatch. También puede acceder a estas métricas en la consola de CloudWatch. Las métricas de nivel de API incluyen CreateSchema (éxito y latencia), GetSchemabyDefinition, (éxito y latencia), GetSchemaVersion (éxito y latencia), RegisterSchemaVersion (éxito y latencia), PutSchemaVersionMetadata (éxito y latencia). Las métricas de nivel de recursos incluyen Registry.ThrottledByLimit, SchemaVersion.ThrottledByLimit, SchemaVersion.Size.

Ejemplo de plantilla de CloudFormation para Schema Registry

A continuación se muestra una plantilla de ejemplo para crear recursos de Schema Registry en CloudFormation. Para crear esta pila en su cuenta, copie la plantilla anterior en un archivo `SampleTemplate.yaml` y ejecute el siguiente comando:

```
aws cloudformation create-stack --stack-name ABCSchemaRegistryStack --template-body
 "'cat SampleTemplate.yaml'"
```

En este ejemplo se utiliza `AWS::Glue::Registry` para crear un registro, `AWS::Glue::Schema` para crear un esquema, `AWS::Glue::SchemaVersion` para crear una versión de esquema y `AWS::Glue::SchemaVersionMetadata` para completar los metadatos de la versión del esquema.

```
Description: "A sample CloudFormation template for creating Schema Registry resources."
Resources:
  ABCRegistry:
    Type: "AWS::Glue::Registry"
    Properties:
      Name: "ABCSchemaRegistry"
      Description: "ABC Corp. Schema Registry"
      Tags:
        Project: "Foo"
  ABCSchema:
    Type: "AWS::Glue::Schema"
    Properties:
      Registry:
        Arn: !Ref ABCRegistry
      Name: "TestSchema"
      Compatibility: "NONE"
      DataFormat: "AVRO"
      SchemaDefinition: >
        {"namespace":"foo.avro","type":"record","name":"user","fields":
[{"name":"name","type":"string"},{"name":"favorite_number","type":"int"}]}
```

```
      Tags:
        Project: "Foo"
  SecondSchemaVersion:
    Type: "AWS::Glue::SchemaVersion"
    Properties:
      Schema:
        SchemaArn: !Ref ABCSchema
      SchemaDefinition: >
        {"namespace":"foo.avro","type":"record","name":"user","fields":
[{"name":"status","type":"string", "default":"ON"}, {"name":"name","type":"string"},
{"name":"favorite_number","type":"int"}]}
  FirstSchemaVersionMetadata:
    Type: "AWS::Glue::SchemaVersionMetadata"
    Properties:
      SchemaVersionId: !GetAtt ABCSchema.InitialSchemaVersionId
      Key: "Application"
      Value: "Kinesis"
  SecondSchemaVersionMetadata:
    Type: "AWS::Glue::SchemaVersionMetadata"
    Properties:
      SchemaVersionId: !Ref SecondSchemaVersion
      Key: "Application"
      Value: "Kinesis"
```

Integración con AWS Glue Schema Registry

En estas secciones se describen las integraciones con AWS Glue Schema Registry. Los ejemplos de esta sección muestran un esquema con formato de datos AVRO. Para obtener más ejemplos, incluidos esquemas con formato de datos JSON, consulte las pruebas de integración y la información de ReadMe (Léame) en el Repositorio de código abierto de AWS Glue Schema Registry.

Temas

- Caso de uso: Conexión de Schema Registry a Amazon MSK o Apache Kafka
- Caso de uso: Integración de Amazon Kinesis Data Streams con AWS Glue Schema Registry
- Caso de uso: Amazon Managed Service para Apache Flink
- Caso de uso: integración con AWS Lambda
- Caso de uso: AWS Glue Data Catalog
- Caso de uso: Streaming de AWS Glue
- Caso de uso: Apache Kafka Streams

Caso de uso: Conexión de Schema Registry a Amazon MSK o Apache Kafka

Supongamos que está escribiendo datos en un tema de Apache Kafka. Puede seguir estos pasos para comenzar.

1. Cree un clúster de Amazon Managed Streaming for Apache Kafka (Amazon MSK) o Apache Kafka con al menos un tema. Si crea un clúster de Amazon MSK, puede utilizar la Consola de administración de AWS. Siga las siguientes isntrucciones: Introducción al uso de Amazon MSK en la Guía para desarrolladores de Amazon Managed Streaming for Apache Kafka.
2. Siga el paso Instalación de bibliotecas SerDe anterior.
3. Para crear registros de esquema, esquemas o versiones de esquema, siga las instrucciones de la sección Introducción a Schema Registry de este documento.
4. Inicie a sus productores y consumidores en el uso de Schema Registry para escribir y leer registros a/desde el tema de Amazon MSK o Apache Kafka. Puede encontrar un ejemplo de código de productor y consumidor en el archivo ReadMe (Léame) de las bibliotecas Serde. La biblioteca de Schema Registry del productor serializará automáticamente el registro y agregará un ID de versión de esquema al registro.
5. Si se ha introducido el esquema de este registro, o si el registro automático está activado, el esquema se habrá registrado en Schema Registry.
6. El consumidor que lee el tema de Amazon MSK o Apache Kafka, con la biblioteca de AWS Glue Schema Registry, buscará automáticamente el esquema desde Schema Registry.

Caso de uso: Integración de Amazon Kinesis Data Streams con AWS Glue Schema Registry

Esta integración requiere que tenga un flujo de datos de Amazon Kinesis. Para obtener más información, consulte Introducción a Amazon Kinesis Data Streams en la Guía para desarrolladores de Amazon Kinesis Data Streams.

Existen dos formas de interactuar con los datos en un flujo de datos de Kinesis.

- A través de las bibliotecas Kinesis Producer Library (KPL) y Kinesis Client Library (KCL) en Java. No se proporciona soporte multilingüe.
- A través de las API `PutRecords`, `PutRecord` y `GetRecords` de Kinesis Data Streams disponibles en AWS SDK para Java.

Si utiliza actualmente las bibliotecas KPL/KCL, le recomendamos seguir utilizando ese método. Hay versiones actualizadas de KCL y KPL con Schema Registry integrado, como se muestra en los

ejemplos. De lo contrario, puede utilizar el código de muestra para aprovechar el AWS Glue Schema Registry si utiliza las API de KDS directamente.

La integración de Schema Registry sólo está disponible con KPL v0.14.2 o posterior y con KCL v2.3 o posterior. La integración de Schema Registry con datos JSON sólo está disponible con KPL v0.14.8 o posterior y con KCL v2.3.6 o posterior.

Interacción con datos mediante SDK de Kinesis V2

En esta sección se describe la interacción con Kinesis mediante SDK de Kinesis V2

```
// Example JSON Record, you can construct a AVRO record also
private static final JsonDataWithSchema record =
 JsonDataWithSchema.builder(schemaString, payloadString);
private static final DataFormat dataFormat = DataFormat.JSON;

//Configurations for Schema Registry
GlueSchemaRegistryConfiguration gsrConfig = new GlueSchemaRegistryConfiguration("us-
east-1");

GlueSchemaRegistrySerializer glueSchemaRegistrySerializer =
        new GlueSchemaRegistrySerializerImpl(awsCredentialsProvider, gsrConfig);
GlueSchemaRegistryDataFormatSerializer dataFormatSerializer =
        new GlueSchemaRegistrySerializerFactory().getInstance(dataFormat, gsrConfig);

Schema gsrSchema =
        new Schema(dataFormatSerializer.getSchemaDefinition(record), dataFormat.name(),
 "MySchema");

byte[] serializedBytes = dataFormatSerializer.serialize(record);

byte[] gsrEncodedBytes = glueSchemaRegistrySerializer.encode(streamName, gsrSchema,
 serializedBytes);

PutRecordRequest putRecordRequest = PutRecordRequest.builder()
        .streamName(streamName)
        .partitionKey("partitionKey")
        .data(SdkBytes.fromByteArray(gsrEncodedBytes))
        .build();
shardId = kinesisClient.putRecord(putRecordRequest)
        .get()
        .shardId();
```

```
GlueSchemaRegistryDeserializer glueSchemaRegistryDeserializer = new
 GlueSchemaRegistryDeserializerImpl(awsCredentialsProvider, gsrConfig);

GlueSchemaRegistryDataFormatDeserializer gsrDataFormatDeserializer =
        glueSchemaRegistryDeserializerFactory.getInstance(dataFormat, gsrConfig);

GetShardIteratorRequest getShardIteratorRequest = GetShardIteratorRequest.builder()
        .streamName(streamName)
        .shardId(shardId)
        .shardIteratorType(ShardIteratorType.TRIM_HORIZON)
        .build();

String shardIterator = kinesisClient.getShardIterator(getShardIteratorRequest)
        .get()
        .shardIterator();

GetRecordsRequest getRecordRequest = GetRecordsRequest.builder()
        .shardIterator(shardIterator)
        .build();
GetRecordsResponse recordsResponse = kinesisClient.getRecords(getRecordRequest)
        .get();

List<Object> consumerRecords = new ArrayList<>();
List<Record> recordsFromKinesis = recordsResponse.records();

for (int i = 0; i < recordsFromKinesis.size(); i++) {
    byte[] consumedBytes = recordsFromKinesis.get(i)
            .data()
            .asByteArray();

    Schema gsrSchema = glueSchemaRegistryDeserializer.getSchema(consumedBytes);
    Object decodedRecord =
 gsrDataFormatDeserializer.deserialize(ByteBuffer.wrap(consumedBytes),

 gsrSchema.getSchemaDefinition());
    consumerRecords.add(decodedRecord);
}
```

Interacción con los datos mediante las bibliotecas KPL/KCL

En esta sección se describe la integración de Kinesis Data Streams con Schema Registry mediante las bibliotecas KPL/KCL. Para obtener más información sobre el uso de KPL/KCL, consulte

Desarrollar productores con Amazon Kinesis Producer Library en la Guía para desarrolladores de Amazon Kinesis Data Streams.

Configuración de Schema Registry en KPL

1. Establezca la definición de esquema para los datos, el formato de datos y el nombre del esquema creados en AWS Glue Schema Registry.
2. Opcionalmente, configure el objeto `GlueSchemaRegistryConfiguration`.
3. Transfiera el objeto de esquema a `addUserRecord API`.

```
private static final String SCHEMA_DEFINITION = "{"namespace": "example.avro",\n"
+ " "type": "record",\n"
+ " "name": "User",\n"
+ " "fields": [\n"
+ " {"name": "name", "type": "string"},\n"
+ " {"name": "favorite_number", "type": ["int", "null"]},\n"
+ " {"name": "favorite_color", "type": ["string", "null"]}\n"
+ " ]\n"
+ "}";

KinesisProducerConfiguration config = new KinesisProducerConfiguration();
config.setRegion("us-west-1")

//[Optional] configuration for Schema Registry.

GlueSchemaRegistryConfiguration schemaRegistryConfig =
new GlueSchemaRegistryConfiguration("us-west-1");

schemaRegistryConfig.setCompression(true);

config.setGlueSchemaRegistryConfiguration(schemaRegistryConfig);

///Optional configuration ends.

final KinesisProducer producer =
      new KinesisProducer(config);

final ByteBuffer data = getDataToSend();

com.amazonaws.services.schemaregistry.common.Schema gsrSchema =
    new Schema(SCHEMA_DEFINITION, DataFormat.AVRO.toString(), "demoSchema");
```

```
ListenableFuture<UserRecordResult> f = producer.addUserRecord(
config.getStreamName(), TIMESTAMP, Utils.randomExplicitHashKey(), data, gsrSchema);

private static ByteBuffer getDataToSend() {
      org.apache.avro.Schema avroSchema =
        new org.apache.avro.Schema.Parser().parse(SCHEMA_DEFINITION);

      GenericRecord user = new GenericData.Record(avroSchema);
      user.put("name", "Emily");
      user.put("favorite_number", 32);
      user.put("favorite_color", "green");

      ByteArrayOutputStream outBytes = new ByteArrayOutputStream();
      Encoder encoder = EncoderFactory.get().directBinaryEncoder(outBytes, null);
      new GenericDatumWriter<>(avroSchema).write(user, encoder);
      encoder.flush();
      return ByteBuffer.wrap(outBytes.toByteArray());
 }
```

Configuración de Kinesis Client Library

Desarrolle un consumidor de Kinesis Client Library en Java. Para obtener más información, consulte Desarrollo de un consumidor de Kinesis Client Library en Java en la Guía para desarrolladores de Amazon Kinesis Data Streams.

1. Cree una instancia de `GlueSchemaRegistryDeserializer` al transferir un objeto `GlueSchemaRegistryConfiguration`.
2. Transfiera el `GlueSchemaRegistryDeserializer` a `retrievalConfig.glueSchemaRegistryDeserializer`.
3. Acceda al esquema de los mensajes entrantes al llamar a `kinesisClientRecord.getSchema()`.

```
GlueSchemaRegistryConfiguration schemaRegistryConfig =
    new GlueSchemaRegistryConfiguration(this.region.toString());

 GlueSchemaRegistryDeserializer glueSchemaRegistryDeserializer =
    new
 GlueSchemaRegistryDeserializerImpl(DefaultCredentialsProvider.builder().build(),
 schemaRegistryConfig);
```

```
RetrievalConfig retrievalConfig =
configsBuilder.retrievalConfig().retrievalSpecificConfig(new
PollingConfig(streamName, kinesisClient));
retrievalConfig.glueSchemaRegistryDeserializer(glueSchemaRegistryDeserializer);

 Scheduler scheduler = new Scheduler(
           configsBuilder.checkpointConfig(),
           configsBuilder.coordinatorConfig(),
           configsBuilder.leaseManagementConfig(),
           configsBuilder.lifecycleConfig(),
           configsBuilder.metricsConfig(),
           configsBuilder.processorConfig(),
           retrievalConfig
       );

public void processRecords(ProcessRecordsInput processRecordsInput) {
           MDC.put(SHARD_ID_MDC_KEY, shardId);
           try {
               log.info("Processing {} record(s)",
               processRecordsInput.records().size());
               processRecordsInput.records()
               .forEach(
                   r ->
                       log.info("Processed record pk: {} -- Seq: {} : data {} with
schema: {}",
                       r.partitionKey(),
r.sequenceNumber(), recordToAvroObj(r).toString(), r.getSchema()));
           } catch (Throwable t) {
               log.error("Caught throwable while processing records. Aborting.");
               Runtime.getRuntime().halt(1);
           } finally {
               MDC.remove(SHARD_ID_MDC_KEY);
           }
}

private GenericRecord recordToAvroObj(KinesisClientRecord r) {
   byte[] data = new byte[r.data().remaining()];
   r.data().get(data, 0, data.length);
   org.apache.avro.Schema schema = new
org.apache.avro.Schema.Parser().parse(r.schema().getSchemaDefinition());
   DatumReader datumReader = new GenericDatumReader<>(schema);

   BinaryDecoder binaryDecoder = DecoderFactory.get().binaryDecoder(data, 0,
data.length, null);
```

```
    return (GenericRecord) datumReader.read(null, binaryDecoder);
 }
```

Interacción con datos mediante las API de Kinesis Data Streams

En esta sección se describe la integración de Kinesis Data Streams con Schema Registry mediante las API de Kinesis Data Streams.

1. Actualice estas dependencias de Maven:

```
<dependencyManagement>
        <dependencies>
            <dependency>
                <groupId>com.amazonaws</groupId>
                <artifactId>aws-java-sdk-bom</artifactId>
                <version>1.11.884</version>
                <type>pom</type>
                <scope>import</scope>
            </dependency>
        </dependencies>
    </dependencyManagement>

    <dependencies>
        <dependency>
            <groupId>com.amazonaws</groupId>
            <artifactId>aws-java-sdk-kinesis</artifactId>
        </dependency>

        <dependency>
            <groupId>software.amazon.glue</groupId>
            <artifactId>schema-registry-serde</artifactId>
            <version>1.1.5</version>
        </dependency>

        <dependency>
            <groupId>com.fasterxml.jackson.dataformat</groupId>
            <artifactId>jackson-dataformat-cbor</artifactId>
            <version>2.11.3</version>
        </dependency>
    </dependencies>
```

2. En el productor, agregue información de encabezado de esquema con la API `PutRecords` o `PutRecord` en Kinesis Data Streams.

```
//The following lines add a Schema Header to the record
        com.amazonaws.services.schemaregistry.common.Schema awsSchema =
            new com.amazonaws.services.schemaregistry.common.Schema(schemaDefinition,
 DataFormat.AVRO.name(),
                schemaName);
        GlueSchemaRegistrySerializerImpl glueSchemaRegistrySerializer =
            new
 GlueSchemaRegistrySerializerImpl(DefaultCredentialsProvider.builder().build(), new
 GlueSchemaRegistryConfiguration(getConfigs()));
        byte[] recordWithSchemaHeader =
            glueSchemaRegistrySerializer.encode(streamName, awsSchema,
 recordAsBytes);
```

3. En el productor, use la API `PutRecords` o `PutRecord` para poner el registro en el flujo de datos.
4. En el consumidor, elimine el registro de esquema del encabezado y serialice un registro de esquemas de Avro.

```
//The following lines remove Schema Header from record
        GlueSchemaRegistryDeserializerImpl glueSchemaRegistryDeserializer =
            new
 GlueSchemaRegistryDeserializerImpl(DefaultCredentialsProvider.builder().build(),
 getConfigs());
        byte[] recordWithSchemaHeaderBytes = new
 byte[recordWithSchemaHeader.remaining()];
        recordWithSchemaHeader.get(recordWithSchemaHeaderBytes, 0,
 recordWithSchemaHeaderBytes.length);
        com.amazonaws.services.schemaregistry.common.Schema awsSchema =
            glueSchemaRegistryDeserializer.getSchema(recordWithSchemaHeaderBytes);
        byte[] record =
 glueSchemaRegistryDeserializer.getData(recordWithSchemaHeaderBytes);

        //The following lines serialize an AVRO schema record
        if (DataFormat.AVRO.name().equals(awsSchema.getDataFormat())) {
            Schema avroSchema = new
 org.apache.avro.Schema.Parser().parse(awsSchema.getSchemaDefinition());
            Object genericRecord = convertBytesToRecord(avroSchema, record);
            System.out.println(genericRecord);
        }
```

Interacción con datos mediante las API de Kinesis Data Streams

El siguiente es el código de ejemplo para usar las API `PutRecords` y `GetRecords`.

```
//Full sample code
import
 com.amazonaws.services.schemaregistry.deserializers.GlueSchemaRegistryDeserializerImpl;
import
 com.amazonaws.services.schemaregistry.serializers.GlueSchemaRegistrySerializerImpl;
import com.amazonaws.services.schemaregistry.utils.AVROUtils;
import com.amazonaws.services.schemaregistry.utils.AWSSchemaRegistryConstants;
import org.apache.avro.Schema;
import org.apache.avro.generic.GenericData;
import org.apache.avro.generic.GenericDatumReader;
import org.apache.avro.generic.GenericDatumWriter;
import org.apache.avro.generic.GenericRecord;
import org.apache.avro.io.Decoder;
import org.apache.avro.io.DecoderFactory;
import org.apache.avro.io.Encoder;
import org.apache.avro.io.EncoderFactory;
import software.amazon.awssdk.auth.credentials.DefaultCredentialsProvider;
import software.amazon.awssdk.services.glue.model.DataFormat;

import java.io.ByteArrayOutputStream;
import java.io.File;
import java.io.IOException;
import java.nio.ByteBuffer;
import java.util.Collections;
import java.util.HashMap;
import java.util.Map;


public class PutAndGetExampleWithEncodedData {
    static final String regionName = "us-east-2";
    static final String streamName = "testStream1";
    static final String schemaName = "User-Topic";
    static final String AVRO_USER_SCHEMA_FILE = "src/main/resources/user.avsc";
    KinesisApi kinesisApi = new KinesisApi();

    void runSampleForPutRecord() throws IOException {
        Object testRecord = getTestRecord();
        byte[] recordAsBytes = convertRecordToBytes(testRecord);
        String schemaDefinition =
 AVROUtils.getInstance().getSchemaDefinition(testRecord);
```

```
       //The following lines add a Schema Header to a record
       com.amazonaws.services.schemaregistry.common.Schema awsSchema =
           new com.amazonaws.services.schemaregistry.common.Schema(schemaDefinition,
DataFormat.AVRO.name(),
               schemaName);
       GlueSchemaRegistrySerializerImpl glueSchemaRegistrySerializer =
           new
GlueSchemaRegistrySerializerImpl(DefaultCredentialsProvider.builder().build(), new
GlueSchemaRegistryConfiguration(regionName));
       byte[] recordWithSchemaHeader =
           glueSchemaRegistrySerializer.encode(streamName, awsSchema, recordAsBytes);

       //Use PutRecords api to pass a list of records
       kinesisApi.putRecords(Collections.singletonList(recordWithSchemaHeader),
streamName, regionName);

       //OR
       //Use PutRecord api to pass single record
       //kinesisApi.putRecord(recordWithSchemaHeader, streamName, regionName);
   }

   byte[] runSampleForGetRecord() throws IOException {
       ByteBuffer recordWithSchemaHeader = kinesisApi.getRecords(streamName,
regionName);

       //The following lines remove the schema registry header
       GlueSchemaRegistryDeserializerImpl glueSchemaRegistryDeserializer =
           new
GlueSchemaRegistryDeserializerImpl(DefaultCredentialsProvider.builder().build(), new
GlueSchemaRegistryConfiguration(regionName));
       byte[] recordWithSchemaHeaderBytes = new
byte[recordWithSchemaHeader.remaining()];
       recordWithSchemaHeader.get(recordWithSchemaHeaderBytes, 0,
recordWithSchemaHeaderBytes.length);

       com.amazonaws.services.schemaregistry.common.Schema awsSchema =
           glueSchemaRegistryDeserializer.getSchema(recordWithSchemaHeaderBytes);

       byte[] record =
glueSchemaRegistryDeserializer.getData(recordWithSchemaHeaderBytes);

       //The following lines serialize an AVRO schema record
       if (DataFormat.AVRO.name().equals(awsSchema.getDataFormat())) {
```

```
            Schema avroSchema = new
org.apache.avro.Schema.Parser().parse(awsSchema.getSchemaDefinition());
            Object genericRecord = convertBytesToRecord(avroSchema, record);
            System.out.println(genericRecord);
        }

        return record;
    }

    private byte[] convertRecordToBytes(final Object record) throws IOException {
        ByteArrayOutputStream recordAsBytes = new ByteArrayOutputStream();
        Encoder encoder = EncoderFactory.get().directBinaryEncoder(recordAsBytes,
null);
        GenericDatumWriter datumWriter = new
GenericDatumWriter<>(AVROUtils.getInstance().getSchema(record));
        datumWriter.write(record, encoder);
        encoder.flush();
        return recordAsBytes.toByteArray();
    }

    private GenericRecord convertBytesToRecord(Schema avroSchema, byte[] record) throws
IOException {
        final GenericDatumReader<GenericRecord> datumReader = new
GenericDatumReader<>(avroSchema);
        Decoder decoder = DecoderFactory.get().binaryDecoder(record, null);
        GenericRecord genericRecord = datumReader.read(null, decoder);
        return genericRecord;
    }

    private Map<String, String> getMetadata() {
        Map<String, String> metadata = new HashMap<>();
        metadata.put("event-source-1", "topic1");
        metadata.put("event-source-2", "topic2");
        metadata.put("event-source-3", "topic3");
        metadata.put("event-source-4", "topic4");
        metadata.put("event-source-5", "topic5");
        return metadata;
    }

    private GlueSchemaRegistryConfiguration getConfigs() {
        GlueSchemaRegistryConfiguration configs = new
GlueSchemaRegistryConfiguration(regionName);
        configs.setSchemaName(schemaName);
        configs.setAutoRegistration(true);
```

```
        configs.setMetadata(getMetadata());
        return configs;
    }

    private Object getTestRecord() throws IOException {
        GenericRecord genericRecord;
        Schema.Parser parser = new Schema.Parser();
        Schema avroSchema = parser.parse(new File(AVRO_USER_SCHEMA_FILE));

        genericRecord = new GenericData.Record(avroSchema);
        genericRecord.put("name", "testName");
        genericRecord.put("favorite_number", 99);
        genericRecord.put("favorite_color", "red");

        return genericRecord;
    }
}
```

Caso de uso: Amazon Managed Service para Apache Flink

Apache Flink es un marco de código abierto y motor de procesamiento distribuido popular para informática con estado sobre flujos de datos ilimitados y delimitados. Amazon Managed Service para Apache Flink es un servicio de AWS completamente administrado que permite crear y administrar aplicaciones de Apache Flink para procesar datos de streaming.

El código abierto Apache Flink proporciona una serie de orígenes y receptores. Por ejemplo, los orígenes de datos predefinidos incluyen la lectura de archivos, directorios y sockets, y la ingesta de datos de recopilaciones e iteradores. Los conectores Apache Flink DataStream proporcionan código para que Apache Flink interactúe con varios sistemas de terceros, como Apache Kafka o Kinesis como orígenes o receptores.

Para obtener más información, consulte la Guía para desarrolladores de Amazon Kinesis Data Analytics.

Conector Kafka de Apache Flink

Apache Flink proporciona un conector de flujo de datos Apache Kafka para leer y escribir datos en temas de Kafka con garantías de una sola vez. El consumidor Kafka de Flink, `FlinkKafkaConsumer`, proporciona acceso a la lectura de uno o más temas de Kafka. El productor Kafka de Apache Flink, `FlinkKafkaProducer`, permite escribir una secuencia de registros en uno o más temas de Kafka. Para obtener más información, consulte Conector de Apache Kafka.

Conector de flujos de Kinesis de Apache Flink

El conector de flujo de datos de Kinesis proporciona acceso a Amazon Kinesis Data Streams. El `FlinkKinesisConsumer` es un origen de datos de streaming en paralelo de exactamente una única vez que se suscribe a múltiples flujos de Kinesis dentro de la misma región de servicio de AWS, y puede manejar de forma transparente la redistribución de flujos mientras el trabajo se está ejecutando. Cada subtarea del consumidor es responsable de obtener registros de datos de múltiples fragmentos de Kinesis. El número de fragmentos obtenidos por cada subtarea cambiará a medida que Kinesis cierre y cree fragmentos. El `FlinkKinesisProducer` utiliza Kinesis Producer Library (KPL) para poner los datos de un flujo de Apache Flink en un flujo de Kinesis. Para obtener más información, consulte Conector de Amazon Kinesis Streams.

Para obtener más información, consulte el repositorio GitHub de esquemas de AWS Glue.

Integración con Apache Flink

La biblioteca SerDes proporcionada con Schema Registry se integra con Apache Flink. Para trabajar con Apache Flink, debe implementar las interfaces de `SerializationSchema` y `DeserializationSchema`, denominadas `GlueSchemaRegistryAvroSerializationSchema` y `GlueSchemaRegistryAvroDeserializationSchema`, que puede conectar a los conectores Apache Flink.

Adición de una dependencia de AWS Glue Schema Registry en la aplicación Apache Flink

Para configurar las dependencias de integración a AWS Glue Schema Registry en la aplicación Apache Flink:

1. Agregue la dependencia al archivo `pom.xml`.

```
<dependency>
    <groupId>software.amazon.glue</groupId>
    <artifactId>schema-registry-flink-serde</artifactId>
    <version>1.0.0</version>
</dependency>
```

Integración de Kafka o Amazon MSK con Apache Flink

Puede usar Managed Service para Apache Flink con Kafka como origen o receptor.

Kafka como origen

En el siguiente diagrama, se muestra la integración de Kinesis Data Streams con Managed Service para Apache Flink, con Kafka como origen.

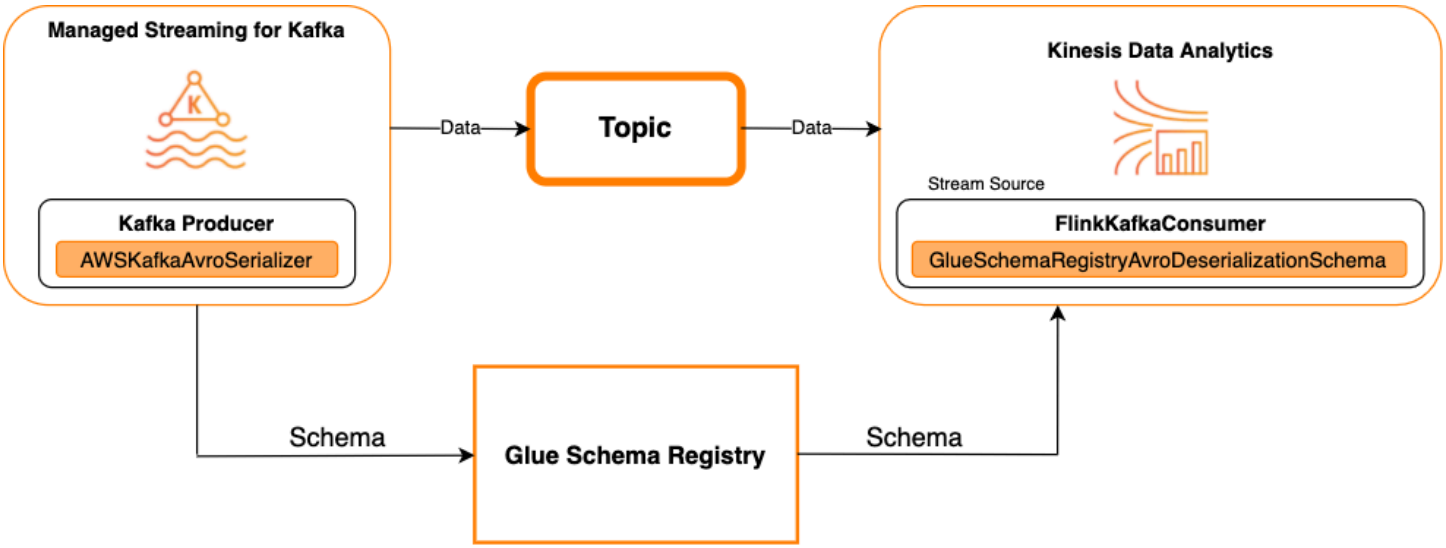

Kafka como receptor

En el siguiente diagrama, se muestra la integración de Kinesis Data Streams con Managed Service para Apache Flink, con Kafka como receptor.

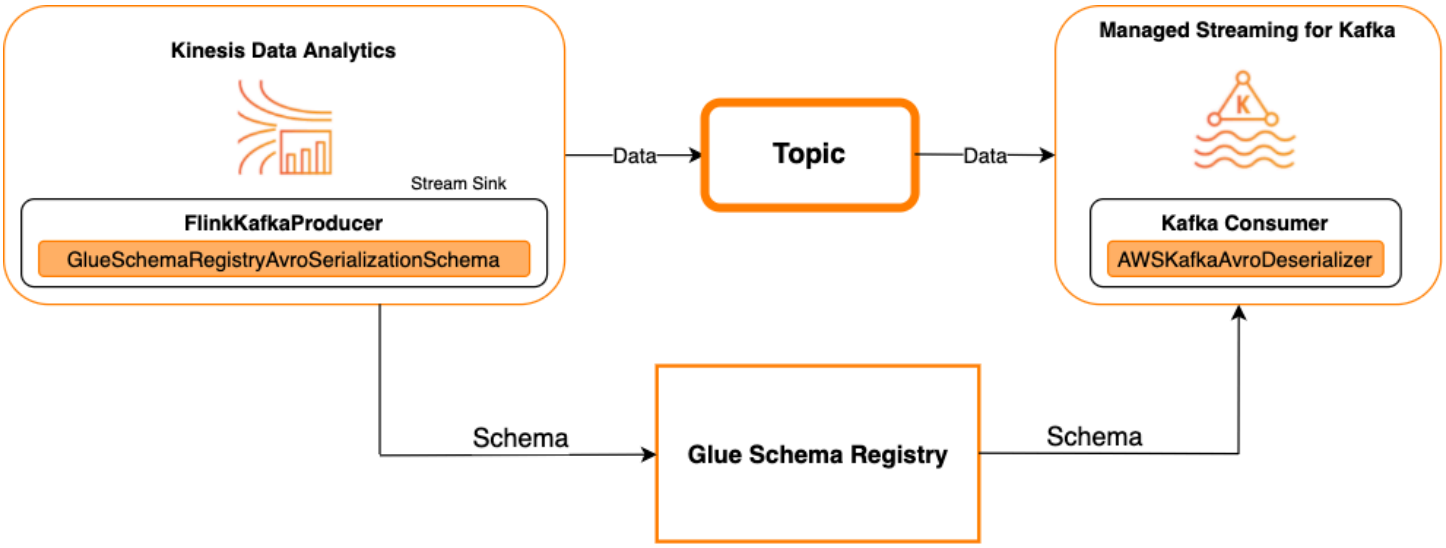

Para integrar Kafka (o Amazon MSK) con Managed Service para Apache Flink, con Kafka como origen o receptor, realice los siguientes cambios de código. Agregue los bloques de código en negrita a su código respectivo en las secciones análogas.

Si Kafka es el origen, entonces use el código deserializador (bloque 2). Si Kafka es el receptor, use el código serializador (bloque 3).

```
StreamExecutionEnvironment env = StreamExecutionEnvironment.getExecutionEnvironment();

String topic = "topic";
Properties properties = new Properties();
properties.setProperty("bootstrap.servers", "localhost:9092");
properties.setProperty("group.id", "test");

// block 1
Map<String, Object> configs = new HashMap<>();
configs.put(AWSSchemaRegistryConstants.AWS_REGION, "aws-region");
configs.put(AWSSchemaRegistryConstants.SCHEMA_AUTO_REGISTRATION_SETTING, true);
configs.put(AWSSchemaRegistryConstants.AVRO_RECORD_TYPE,
 AvroRecordType.GENERIC_RECORD.getName());

FlinkKafkaConsumer<GenericRecord> consumer = new FlinkKafkaConsumer<>(
    topic,
    // block 2
    GlueSchemaRegistryAvroDeserializationSchema.forGeneric(schema, configs),
    properties);

FlinkKafkaProducer<GenericRecord> producer = new FlinkKafkaProducer<>(
    topic,
    // block 3
    GlueSchemaRegistryAvroSerializationSchema.forGeneric(schema, topic, configs),
    properties);

DataStream<GenericRecord> stream = env.addSource(consumer);
stream.addSink(producer);
env.execute();
```

Integración de Kinesis Data Streams con Apache Flink

Puede usar Managed Service para Apache Flink, con Kinesis Data Streams como origen o como receptor.

Kinesis Data Streams como origen

En el siguiente diagrama, se muestra la integración de Kinesis Data Streams con Managed Service para Apache Flink, con Kinesis Data Streams como origen.

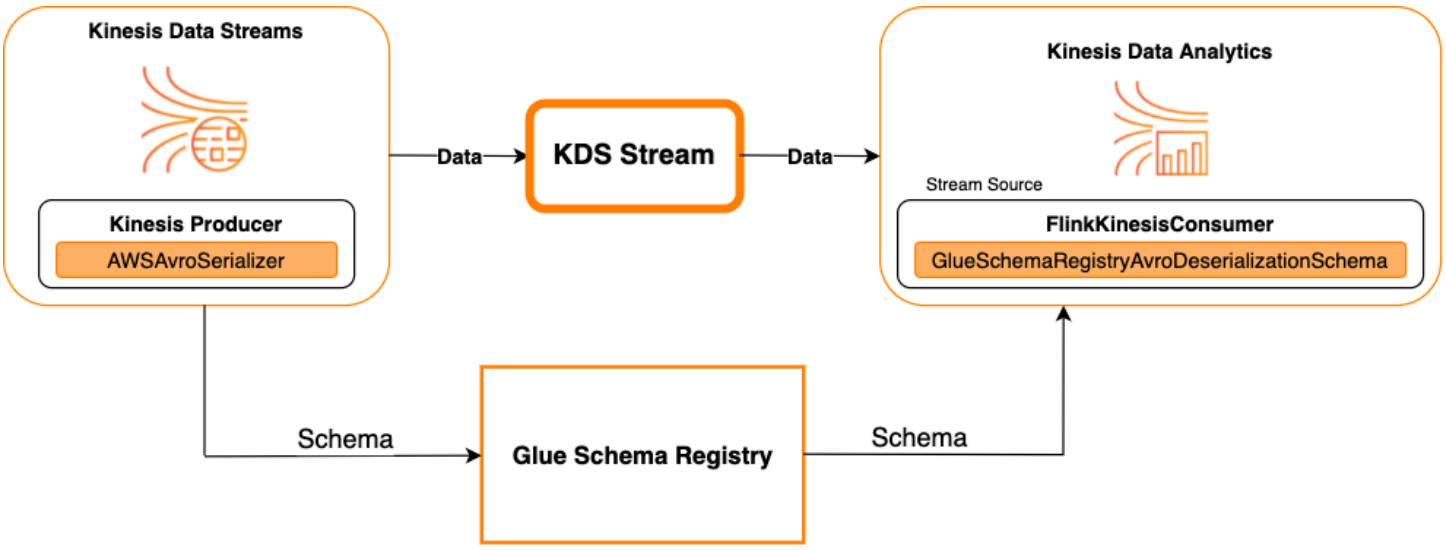

Kinesis Data Streams como receptor

En el siguiente diagrama, se muestra la integración de Kinesis Data Streams con Managed Service para Apache Flink, con Kinesis Data Streams como receptor.

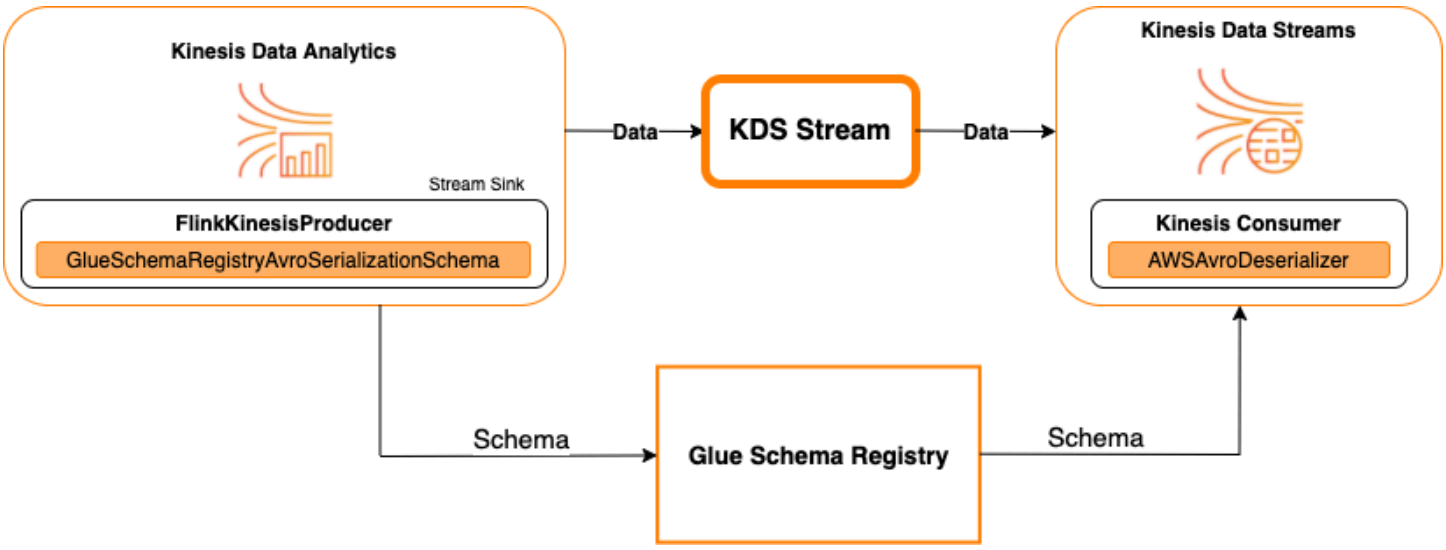

Para integrar Kinesis Data Streams con Managed Service para Apache Flink, con Kinesis Data Streams como origen o receptor, realice los cambios de código que se indican a continuación. Agregue los bloques de código en negrita a su código respectivo en las secciones análogas.

Si Kinesis Data Streams es el origen, utilice el código deserializador (bloque 2). Si Kinesis Data Streams es el receptor, use el código serializador (bloque 3).

```
StreamExecutionEnvironment env = StreamExecutionEnvironment.getExecutionEnvironment();
```

```
String streamName = "stream";
Properties consumerConfig = new Properties();
consumerConfig.put(AWSConfigConstants.AWS_REGION, "aws-region");
consumerConfig.put(AWSConfigConstants.AWS_ACCESS_KEY_ID, "aws_access_key_id");
consumerConfig.put(AWSConfigConstants.AWS_SECRET_ACCESS_KEY, "aws_secret_access_key");
consumerConfig.put(ConsumerConfigConstants.STREAM_INITIAL_POSITION, "LATEST");

// block 1
Map<String, Object> configs = new HashMap<>();
configs.put(AWSSchemaRegistryConstants.AWS_REGION, "aws-region");
configs.put(AWSSchemaRegistryConstants.SCHEMA_AUTO_REGISTRATION_SETTING, true);
configs.put(AWSSchemaRegistryConstants.AVRO_RECORD_TYPE,
 AvroRecordType.GENERIC_RECORD.getName());

FlinkKinesisConsumer<GenericRecord> consumer = new FlinkKinesisConsumer<>(
    streamName,
    // block 2
    GlueSchemaRegistryAvroDeserializationSchema.forGeneric(schema, configs),
    properties);

FlinkKinesisProducer<GenericRecord> producer = new FlinkKinesisProducer<>(
    // block 3
    GlueSchemaRegistryAvroSerializationSchema.forGeneric(schema, topic, configs),
    properties);
producer.setDefaultStream(streamName);
producer.setDefaultPartition("0");

DataStream<GenericRecord> stream = env.addSource(consumer);
stream.addSink(producer);
env.execute();
```

Caso de uso: integración con AWS Lambda

Para utilizar una función AWS Lambda como consumidor Apache Kafka/Amazon MSK y deserializar mensajes codificados por AVRO-con AWS Glue Schema Registry, visite la página de MSK Labs.

Caso de uso: AWS Glue Data Catalog

Las tablas de AWS Glue soportan esquemas que se pueden especificar en forma manual o por referencia a AWS Glue Schema Registry. Schema Registry se integra con el Catálogo de datos para permitirle utilizar opcionalmente esquemas almacenados en Schema Registry al crear o actualizar tablas o particiones de AWS Glue en el Catálogo de datos. Para identificar una definición de esquema en Schema Registry, es necesario conocer, al menos, el ARN del esquema del que forma

parte. Una versión de esquema, que contiene una definición de esquema, puede ser referenciada por su UUID o número de versión. Siempre hay una versión de esquema, la “última” versión, que se puede buscar sin saber su número de versión o UUID.

Al llamar a las operaciones `CreateTable` o `UpdateTable`, transferirá una estructura `TableInput` que contiene un `StorageDescriptor`, que podría tener una `SchemaReference` a un esquema existente en Schema Registry. Del mismo modo, cuando se llama a las API `GetTable` o `GetPartition`, la respuesta puede contener el esquema y la `SchemaReference`. Cuando se crea una tabla o partición mediante referencias de esquema, el Catálogo de datos intentará buscar el esquema para esta referencia de esquema. En caso de que no pueda encontrar el esquema, Schema Registry devuelve un esquema vacío en la respuesta `GetTable`; de lo contrario, la respuesta tendrá el esquema y la referencia del esquema.

Puede realizar las siguientes acciones desde la consola de AWS Glue.

Para realizar estas operaciones y crear, actualizar o ver la información del esquema, debe brindar al usuario que realiza la llamada un rol de IAM que proporcione permisos para la API `GetSchemaVersion`.

Agregar una tabla o actualizar el esquema de una tabla

Agregar una nueva tabla a partir de un esquema existente enlaza la tabla a una versión de esquema específica. Una vez que se registren las nuevas versiones de esquema, puede actualizar esta definición de tabla desde la página View tables (Ver tabla) en la consola de AWS Glue o con la API Acción UpdateTable (Python: update_table).

Agregar una tabla a partir de un esquema existente

Puede crear una tabla de AWS Glue a partir de una versión de esquema en el registro mediante la consola AWS Glue o la API `CreateTable`.

API AWS Glue

Al llamar a la API `CreateTable`, transferirá una `TableInput` que contiene un `StorageDescriptor` con una `SchemaReference` a un esquema existente en Schema Registry.

Consola de AWS Glue

Para crear una tabla desde la consola de AWS Glue:

1. Inicie sesión en Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.

2. En el panel de navegación, en Data catalog (Catálogo de datos), elija Tables (Tablas).
3. En el menú Add tables (Agregar tablas), elija Add table from existing schema (Agregar tabla a partir del esquema existente).
4. Configure las propiedades de la tabla y el almacén de datos según la Guía para desarrolladores de AWS Glue.
5. En la página Choose a Glue schema (Elegir un esquema de Glue), seleccione el Record (Registro) donde reside el esquema.
6. Elija el Schema name (Nombre del esquema) y seleccione la Version (Versión) del esquema que se va a aplicar.
7. Revise la previsualización del esquema y elija Next (Siguiente).
8. Revise y cree la tabla.

El esquema y la versión aplicados a la tabla aparecen en la columna Glue schema (Esquema de Glue) en la lista de tablas. Puede ver la tabla para ver más detalles.

Actualización del esquema de una tabla

Cuando esté disponible una nueva versión de esquema, es posible que desee actualizar el esquema de una tabla mediante la API Acción UpdateTable (Python: update_table) o la consola de AWS Glue.

> **Important**
>
> Al actualizar el esquema de una tabla existente que tiene un esquema de AWS Glue especificado manualmente, el nuevo esquema al que se hace referencia en el Schema Registry puede ser incompatible. Esto puede dar lugar a que sus trabajos presenten errores.

API AWS Glue

Al llamar a la API `UpdateTable`, transferirá una `TableInput` que contiene un `StorageDescriptor` con una `SchemaReference` a un esquema existente en Schema Registry.

Consola de AWS Glue

Para actualizar el esquema de una tabla desde la consola de AWS Glue:

1. Inicie sesión en Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.

2. En el panel de navegación, en Data catalog (Catálogo de datos), elija Tables (Tablas).
3. Vea la tabla de la lista de tablas.
4. Haga clic en Update schema (Actualizar esquema) en el cuadro que le informa sobre una nueva versión.
5. Revise las diferencias entre el esquema actual y el nuevo.
6. Seleccione Show all schema differences (Mostrar todas las diferencias de esquemas) para ver más detalles.
7. Seleccione Save table (Guardar tabla) para aceptar la nueva versión.

Caso de uso: Streaming de AWS Glue

El streaming de AWS Glue consume datos de orígenes de streaming y realiza operaciones ETL antes de escribir en un receptor de salida. El origen del streaming de entrada se puede especificar mediante una tabla de datos o directamente especificando la configuración de origen.

El streaming de AWS Glue admite una tabla del Catálogo de datos para el origen de transmisión creado con el esquema presente en AWS Glue Schema Registry. Puede crear un esquema en AWS Glue Schema Registry y, mediante el uso de este, crear una tabla de AWS Glue con un origen de streaming. Esta tabla de AWS Glue se puede utilizar como entrada para un trabajo de streaming de AWS Glue de manera de deserializar los datos en el flujo de entrada.

Un punto que se debe tener en cuenta aquí es que, cuando cambia el esquema de AWS Glue Schema Registry, debe reiniciar el trabajo de streaming de AWS Glue para que el cambio se vea reflejado.

Caso de uso: Apache Kafka Streams

La API Apache Kafka Streams es una biblioteca cliente para procesar y analizar datos almacenados en Apache Kafka. Esta sección describe la integración de Apache Kafka Streams con AWS Glue Schema Registry, que le permite administrar y aplicar esquemas en sus aplicaciones de streaming de datos. Para obtener más información sobre Apache Kafka Streams, consulte Apache Kafka Streams.

Integración con las bibliotecas SerDes

Existe una clase de `GlueSchemaRegistryKafkaStreamsSerde` con la que puede configurar una aplicación de Streams.

Código de ejemplo de aplicación de Kafka Streams

Para utilizar el AWS Glue Schema Registry dentro de una aplicación Apache Kafka Streams:

1. Configure la aplicación Kafka Streams.

```
final Properties props = new Properties();
    props.put(StreamsConfig.APPLICATION_ID_CONFIG, "avro-streams");
    props.put(StreamsConfig.BOOTSTRAP_SERVERS_CONFIG, "localhost:9092");
    props.put(StreamsConfig.CACHE_MAX_BYTES_BUFFERING_CONFIG, 0);
    props.put(StreamsConfig.DEFAULT_KEY_SERDE_CLASS_CONFIG,
 Serdes.String().getClass().getName());
    props.put(StreamsConfig.DEFAULT_VALUE_SERDE_CLASS_CONFIG,
 AWSKafkaAvroSerDe.class.getName());
    props.put(ConsumerConfig.AUTO_OFFSET_RESET_CONFIG, "earliest");

    props.put(AWSSchemaRegistryConstants.AWS_REGION, "aws-region");
    props.put(AWSSchemaRegistryConstants.SCHEMA_AUTO_REGISTRATION_SETTING, true);
    props.put(AWSSchemaRegistryConstants.AVRO_RECORD_TYPE,
 AvroRecordType.GENERIC_RECORD.getName());
 props.put(AWSSchemaRegistryConstants.DATA_FORMAT, DataFormat.AVRO.name());
```

2. Cree un flujo a partir del tema avro-input.

```
StreamsBuilder builder = new StreamsBuilder();
final KStream<String, GenericRecord> source = builder.stream("avro-input");
```

3. Procese los registros de datos (el ejemplo filtra aquellos registros cuyo valor de color_favorito es rosa o cuyo valor de cantidad es 15).

```
final KStream<String, GenericRecord> result = source
    .filter((key, value) -
> !"pink".equals(String.valueOf(value.get("favorite_color"))));
    .filter((key, value) -> !"15.0".equals(String.valueOf(value.get("amount"))));
```

4. Escriba los resultados en el tema avro-output.

```
result.to("avro-output");
```

5. Inicie la aplicación Apache Kafka Streams.

```
KafkaStreams streams = new KafkaStreams(builder.build(), props);
streams.start();
```

Resultados de implementación

Estos resultados muestran el proceso de filtrado de registros que se filtraron en el paso 3 como color_favorito “rosa” o valor “15,0”.

Registros antes del filtrado:

```
{"name": "Sansa", "favorite_number": 99, "favorite_color": "white"}
{"name": "Harry", "favorite_number": 10, "favorite_color": "black"}
{"name": "Hermione", "favorite_number": 1, "favorite_color": "red"}
{"name": "Ron", "favorite_number": 0, "favorite_color": "pink"}
{"name": "Jay", "favorite_number": 0, "favorite_color": "pink"}

{"id": "commute_1","amount": 3.5}
{"id": "grocery_1","amount": 25.5}
{"id": "entertainment_1","amount": 19.2}
{"id": "entertainment_2","amount": 105}
 {"id": "commute_1","amount": 15}
```

Registros después del filtrado:

```
{"name": "Sansa", "favorite_number": 99, "favorite_color": "white"}
{"name": "Harry", "favorite_number": 10, "favorite_color": "black"}
{"name": "Hermione", "favorite_number": 1, "favorite_color": "red"}
{"name": "Ron", "favorite_number": 0, "favorite_color": "pink"}

{"id": "commute_1","amount": 3.5}
{"id": "grocery_1","amount": 25.5}
{"id": "entertainment_1","amount": 19.2}
{"id": "entertainment_2","amount": 105}
```

Caso de uso: Apache Kafka Connect

La integración de Apache Kafka Connect con el AWS Glue Schema Registry permite obtener información de esquemas a partir de los conectores. Los convertidores Apache Kafka especifican el formato de datos dentro de Apache Kafka y cómo traducirlos a datos Apache Kafka Connect. Cada usuario de Apache Kafka Connect tendrá que configurar estos convertidores en función del formato en el que desea que sus datos estén cargados o almacenados en Apache Kafka. De esta manera, puede definir sus propios convertidores para traducir los datos de Apache Kafka Connect al tipo utilizado en AWS Glue Schema Registry (por ejemplo: Avro) y utilizar nuestro serializador para registrar su esquema y serializar. Los convertidores también pueden usar nuestro deserializador para deserializar los datos recibidos de Apache Kafka y volver a convertirlos en datos Apache Kafka Connect. A continuación se muestra un diagrama de flujo de trabajo de ejemplo.

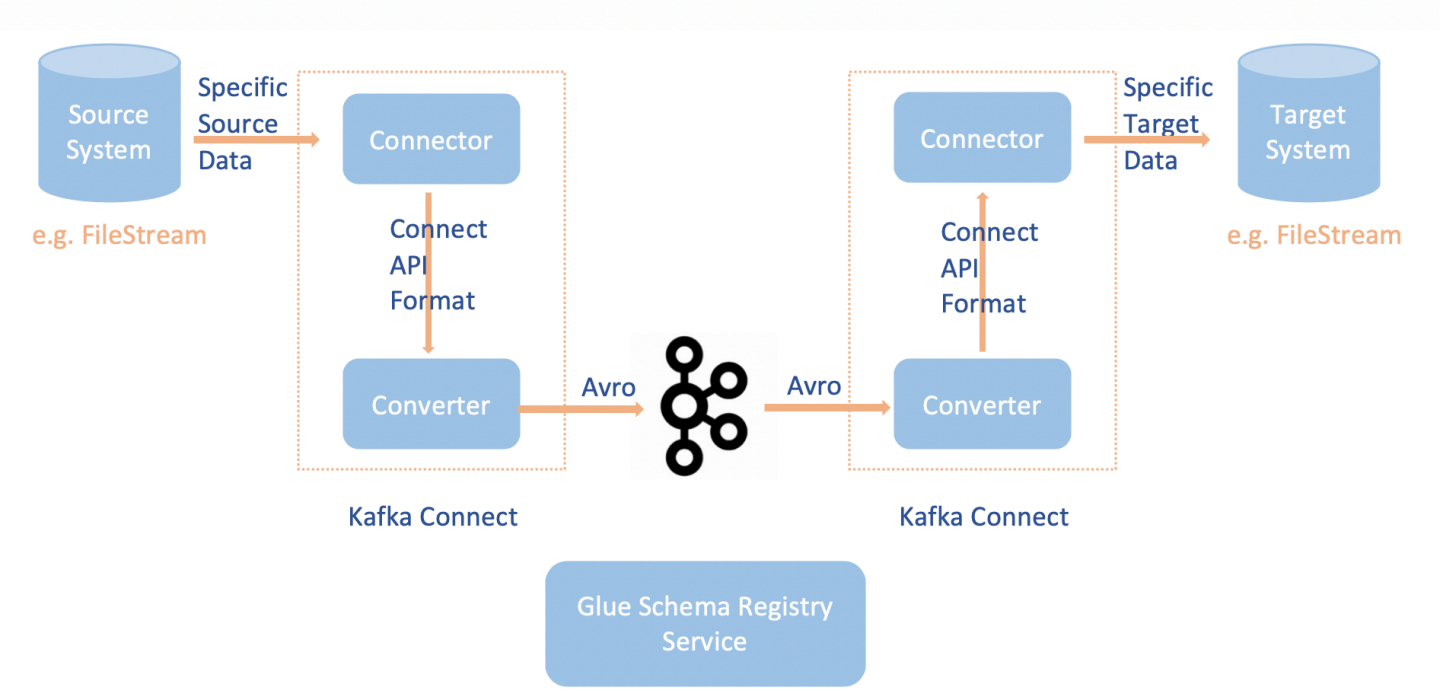

1. Instale el proyecto `aws-glue-schema-registry` al clonar el repositorio de Github para AWS Glue Schema Registry.

```
git clone git@github.com:awslabs/aws-glue-schema-registry.git
cd aws-glue-schema-registry
mvn clean install
mvn dependency:copy-dependencies
```

2. Si planea usar Apache Kafka Connect en modo independiente, actualice connect-standalone.properties según las instrucciones que se incluyen a continuación. Si planea usar Apache Kafka Connect en modo distribuido, actualice connect-avro-distributed.properties según las mismas instrucciones.

   a. Agregue estas propiedades también al archivo de propiedades de conexión Apache Kafka:

   ```
   key.converter.region=aws-region
   value.converter.region=aws-region
   key.converter.schemaAutoRegistrationEnabled=true
   value.converter.schemaAutoRegistrationEnabled=true
   key.converter.avroRecordType=GENERIC_RECORD
   value.converter.avroRecordType=GENERIC_RECORD
   ```

   b. Agregue el siguiente comando a la sección Launch mode (Modo de lanzamiento) en kafka-run-class.sh:

   ```
   -cp $CLASSPATH:"<your AWS GlueSchema Registry base directory>/target/dependency/*"
   ```

3. Agregue el siguiente comando a la sección Launch mode (Modo de lanzamiento) en kafka-run-class.sh

   ```
   -cp $CLASSPATH:"<your AWS GlueSchema Registry base directory>/target/dependency/*"
   ```

   Debería tener un aspecto similar al siguiente:

   ```
   # Launch mode
   if [ "x$DAEMON_MODE" = "xtrue" ]; then
     nohup "$JAVA" $KAFKA_HEAP_OPTS $KAFKA_JVM_PERFORMANCE_OPTS $KAFKA_GC_LOG_OPTS
    $KAFKA_JMX_OPTS $KAFKA_LOG4J_OPTS -cp $CLASSPATH:"/Users/johndoe/aws-glue-schema-
   registry/target/dependency/*" $KAFKA_OPTS "$@" > "$CONSOLE_OUTPUT_FILE" 2>&1 < /dev/
   null &
   else
     exec "$JAVA" $KAFKA_HEAP_OPTS $KAFKA_JVM_PERFORMANCE_OPTS $KAFKA_GC_LOG_OPTS
    $KAFKA_JMX_OPTS $KAFKA_LOG4J_OPTS -cp $CLASSPATH:"/Users/johndoe/aws-glue-schema-
   registry/target/dependency/*" $KAFKA_OPTS "$@"
   fi
   ```

4. Si usa bash, ejecute los siguientes comandos para configurar su CLASSPATH en su bash_profile. Para cualquier otro shell, actualice el entorno en consecuencia.

```
echo 'export GSR_LIB_BASE_DIR=<>' >>~/.bash_profile
echo 'export GSR_LIB_VERSION=1.0.0' >>~/.bash_profile
echo 'export KAFKA_HOME=<your Apache Kafka installation directory>' >>~/.bash_profile
echo 'export CLASSPATH=$CLASSPATH:$GSR_LIB_BASE_DIR/avro-kafkaconnect-converter/
target/schema-registry-kafkaconnect-converter-$GSR_LIB_VERSION.jar:$GSR_LIB_BASE_DIR/
common/target/schema-registry-common-$GSR_LIB_VERSION.jar:$GSR_LIB_BASE_DIR/
avro-serializer-deserializer/target/schema-registry-serde-$GSR_LIB_VERSION.jar'
 >>~/.bash_profile
source ~/.bash_profile
```

5. (Opcional) si desea realizar una prueba con un origen de archivo simple, clone el conector de origen del archivo.

```
git clone https://github.com/mmolimar/kafka-connect-fs.git
cd kafka-connect-fs/
```

   a. En la configuración del conector de origen, edite el formato de datos a Avro, el lector de archivos a `AvroFileReader` y actualice un objeto Avro de ejemplo desde la ruta del archivo de la que está leyendo. Por ejemplo:

```
vim config/kafka-connect-fs.properties
```

```
fs.uris=<path to a sample avro object>
policy.regexp=^.*\.avro$
file_reader.class=com.github.mmolimar.kafka.connect.fs.file.reader.AvroFileReader
```

   b. Instale el conector de origen.

```
mvn clean package
echo "export CLASSPATH=\$CLASSPATH:\"\$(find target/ -type f -name '*.jar'| grep
 '\-package' | tr '\n' ':')\"" >>~/.bash_profile
source ~/.bash_profile
```

   c. Actualice las propiedades del receptor en *<your Apache Kafka installation directory>*`/config/connect-file-sink.properties`, actualice el nombre del tema y el nombre del archivo de salida.

```
file=<output file full path>
topics=<my topic>
```

6. Inicie el conector de origen (en este ejemplo es un conector de origen de archivo).

```
$KAFKA_HOME/bin/connect-standalone.sh $KAFKA_HOME/config/connect-
standalone.properties config/kafka-connect-fs.properties
```

7. Ejecute el conector del receptor (en este ejemplo es un conector receptor de archivo).

```
$KAFKA_HOME/bin/connect-standalone.sh $KAFKA_HOME/config/connect-
standalone.properties $KAFKA_HOME/config/connect-file-sink.properties
```

   Para ver un ejemplo de uso de Kafka Connect, mire el script run-local-tests.sh en la carpeta integration-tests (pruebas de integración) en el repositorio de Github para AWS Glue Schema Registry.

Migración desde un registro de esquemas de terceros a AWS Glue Schema Registry

La migración de un registro de esquema de terceros a AWS Glue Schema Registry tiene una dependencia en el registro de esquemas de terceros existente. Si hay registros en un tema de Apache Kafka que se enviaron mediante un registro de esquemas de terceros, los consumidores necesitan el registro de esquemas de terceros para deserializar esos registros. `AWSKafkaAvroDeserializer` proporciona la capacidad de especificar una clase de deserializador secundario que apunta al deserializador de terceros y se utiliza para deserializar esos registros.

Existen dos criterios para retirar un esquema de terceros. En primer lugar, el retiro sólo puede ocurrir después de que los registros en temas de Apache Kafka que utilizan el registro de esquemas de terceros ya no sean requeridos por o para un consumidor. En segundo lugar, el retiro puede ocurrir si se eliminan los temas de Apache Kafka, dependiendo del período de retención especificado para esos temas. Tenga en cuenta que si tiene temas que tienen retención infinita, puede migrar a AWS Glue Schema Registry, pero no podrá retirar el registro de esquemas de terceros. Como solución alternativa, puede usar una aplicación o Mirror Maker 2 para leer el tema actual y producir un tema nuevo con AWS Glue Schema Registry.

Migración desde un registro de esquemas de terceros a AWS Glue Schema Registry:

1. Cree un registro en AWS Glue Schema Registry o utilice el registro predeterminado.
2. Detenga el consumidor. Modifíquelo para incluir AWS Glue Schema Registry como el deserializador principal y el registro de esquemas de terceros como el secundario.

- Configure las propiedades del consumidor. En este ejemplo, el secondary_deserializer (deserializador secundario) se configura en un deserializador diferente. El comportamiento es el siguiente: el consumidor recupera los registros de Amazon MSK y primero intenta utilizar el `AWSKafkaAvroDeserializer`. Si no puede leer el byte mágico que contiene el ID de esquema de Avro para AWS Glue Schema Registry, el `AWSKafkaAvroDeserializer` luego intenta usar la clase de deserializador proporcionada en el secondary_deserializer (deserializador secundario). Las propiedades específicas del deserializador secundario también deben proporcionarse en las propiedades del consumidor, como schema_registry_url_config (configuración url de registro de esquema) y specific_avro_reader_config (configuración de lector avro específica), como se muestra a continuación.

```
consumerProps.setProperty(ConsumerConfig.KEY_DESERIALIZER_CLASS_CONFIG,
 StringDeserializer.class.getName());
consumerProps.setProperty(ConsumerConfig.VALUE_DESERIALIZER_CLASS_CONFIG,
 AWSKafkaAvroDeserializer.class.getName());
consumerProps.setProperty(AWSSchemaRegistryConstants.AWS_REGION,
 KafkaClickstreamConsumer.gsrRegion);
consumerProps.setProperty(AWSSchemaRegistryConstants.SECONDARY_DESERIALIZER,
 KafkaAvroDeserializer.class.getName());
consumerProps.setProperty(KafkaAvroDeserializerConfig.SCHEMA_REGISTRY_URL_CONFIG,
 "URL for third-party schema registry");
consumerProps.setProperty(KafkaAvroDeserializerConfig.SPECIFIC_AVRO_READER_CONFIG,
 "true");
```

3. Reinicie el consumidor.
4. Detenga el productor y dirija al productor a AWS Glue Schema Registry.
   a. Configure las propiedades del productor. En este ejemplo, el productor utilizará las versiones de esquema de registro predeterminado y registro automático.

```
producerProps.setProperty(ProducerConfig.KEY_SERIALIZER_CLASS_CONFIG,
 StringSerializer.class.getName());
producerProps.setProperty(ProducerConfig.VALUE_SERIALIZER_CLASS_CONFIG,
 AWSKafkaAvroSerializer.class.getName());
producerProps.setProperty(AWSSchemaRegistryConstants.AWS_REGION, "us-east-2");
producerProps.setProperty(AWSSchemaRegistryConstants.AVRO_RECORD_TYPE,
 AvroRecordType.SPECIFIC_RECORD.getName());
producerProps.setProperty(AWSSchemaRegistryConstants.SCHEMA_AUTO_REGISTRATION_SETTING,
 "true");
```

5. (Opcional) mueva manualmente los esquemas y las versiones de esquema existentes del registro de esquemas de terceros actual a AWS Glue Schema Registry, ya sea al registro predeterminado en AWS Glue Schema Registry o a un registro no predeterminado específico en AWS Glue Schema Registry. Esto se puede hacer al exportar esquemas de los registros de esquemas de terceros en formato JSON y crear nuevos esquemas en AWS Glue Schema Registry con Consola de administración de AWS o AWS CLI.

   Este paso puede ser importante si necesita habilitar las comprobaciones de compatibilidad con versiones de esquema anteriores para las versiones de esquema recién creadas mediante AWS CLI y Consola de administración de AWS, o cuando los productores envían mensajes con un nuevo esquema con la función de registro automático de versiones de esquema activada.
6. Inicie el productor.

Conexión a datos

Una conexión de AWS Glue es un objeto del Catálogo de datos que almacena credenciales de inicio de sesión, cadenas de URI, información de nube privada virtual (VPC) y otros datos de un determinado almacén de datos. Los rastreadores, trabajos y puntos de conexión de desarrollo de AWS Glue utilizan conexiones para acceder a ciertos tipos de almacenes de datos. Puede utilizar conexiones para orígenes y destinos, así como reutilizar la misma conexión en varios trabajos de rastreador o de extracción, transformación y carga (ETL).

La última versión del esquema de conexiones de AWS Glue proporciona una forma unificada de administrar las conexiones de datos entre servicios y aplicaciones de AWS, como AWS Glue, Amazon Athena y Amazon SageMaker AI Unified Studio.

Información general del uso de conectores y conexiones

Una conexión contiene las propiedades necesarias para conectarse a un almacén de datos determinado. Cuando se crea una conexión, se almacena en el AWS Glue Data Catalog. Elija un conector y, a continuación, cree una conexión basada en ese conector.

Puede suscribirse a conectores para almacenes de datos soportados de forma no nativa en AWS Marketplace y luego utilizar esos conectores para crear conexiones. Los desarrolladores también pueden crear sus propios conectores, que el usuario puede utilizar para crear conexiones.

> **Note**
>
> Las conexiones creadas con conectores personalizados o de AWS Marketplace en AWS Glue Studio aparecen en la consola de AWS Glue con el tipo configurado en `UNKNOWN` (Desconocido).

Los siguientes pasos describen el proceso general para utilizar conectores en AWS Glue Studio:

1. Suscríbase a un conector en AWS Marketplace o desarrolle su propio conector y cárguelo a AWS Glue Studio. Para obtener más información, consulte Agregar conectores a AWS Glue Studio.
2. Revise la información de uso del conector. Puede encontrar esta información en la pestaña Usage (Uso) en la página de producto del conector. Por ejemplo, si hace clic en la pestaña Usage (Uso) en esta página de producto, Conector para Google BigQuery de AWS Glue, puede ver en la

sección Additional Resources (Recursos adicionales) un enlace a un blog sobre el uso de este conector.

3. Cree una conexión. Puede elegir qué conector usar y proporcionar información adicional para la conexión, como credenciales de inicio de sesión, cadenas de URI e información de nube privada virtual (VPC). Para obtener más información, consulte Creación de conexiones para conectores.
4. Crear un rol de IAM para su trabajo. El flujo de trabajo asume los permisos de la IAM role (función de IAM) que especifica al crearla. Este rol de IAM debe tener permisos para autenticarse con sus almacenes de datos, extraer datos de sus almacén de datos y escribir datos a los mismos.
5. Cree un trabajo de ETL y configure las propiedades de origen de datos para su trabajo de ETL. Proporcione las opciones de conexión y la información de autenticación según las instrucciones del proveedor del conector personalizado. Para obtener más información, consulte Creación de trabajos con conectores personalizados.
6. Personalice su trabajo de ETL mediante al agregado de transformaciones o almacenes de datos adicionales, como se describe en Inicio de trabajos de ETL visuales en AWS Glue Studio.
7. Si utiliza un conector para el destino de datos, configure las propiedades de destino de datos para su trabajo de ETL. Proporcione las opciones de conexión y la información de autenticación según las instrucciones del proveedor del conector personalizado. Para obtener más información, consulte the section called “Creación de trabajos con conectores personalizados”.
8. Personalice el entorno de ejecución de trabajos mediante la configuración de las propiedades del trabajo, como se describe en Modificar las propiedades del trabajo.
9. Ejecute el trabajo.

Conexiones unificadas

AWS introdujo recientemente una nueva característica llamada “SageMaker LakeHouse Connections” o “Conexiones unificadas de AWS Glue”. Esta característica le permite crear conexiones que pueden utilizarse por varios servicios de AWS, como AWS Glue y Amazon Athena. Cuando cree un origen de datos en Amazon Athena, verá una sección que hace referencia a las entradas de conexión de AWS Glue. En este caso, Amazon Athena creará una conexión AWS Glue automáticamente, que incluirá las propiedades específicas de Amazon Athena en la sección `AthenaProperties` de la conexión.

Por otro lado, si crea una conexión directamente en AWS Glue, solo se le pedirá que introduzca propiedades específicas de AWS Glue y Apache Spark, que se almacenarán en las secciones `ConnectionProperties` y `SparkProperties` de la conexión.

En ambos casos, se crea una "conexión unificada", pero las conexiones creadas en Amazon Athena se configuran únicamente para su uso dentro de Amazon Athena, mientras que las conexiones creadas en AWS Glue se configuran únicamente para su uso dentro de AWS Glue. Sin embargo, es posible actualizar estas conexiones con las propiedades que faltan (ya sean propiedades de Amazon Athena o de Spark) para que ambos servicios puedan usarlas. Amazon SageMaker AI Unified Studio se encarga de esto automáticamente al rellenar todas las propiedades necesarias (`ConnectionProperties`, `AthenaProperties` y `SparkProperties`) en la conexión de AWS Glue, lo que garantiza que la conexión pueda ser utilizada tanto por AWS Glue como por Amazon Athena.

Es importante tener en cuenta que, aunque las denominamos “conexiones unificadas”, las conexiones que se crean en AWS Glue o Amazon Athena de forma individual no están realmente unificadas a menos que estén configuradas correctamente para su uso por ambos servicios. Solo las conexiones creadas a través de SageMaker Unified Studio están realmente unificadas y pueden ser utilizadas por múltiples servicios de forma inmediata.

Además, las conexiones creadas en AWS Glue no están visibles en Amazon Athena porque Amazon Athena muestra el origen de datos, que incluye una referencia a una conexión de AWS Glue, pero no son la conexión de AWS Glue en sí. Del mismo modo, las conexiones creadas en Amazon Athena no están visibles en AWS Glue Studio porque AWS Glue Studio filtra cualquier conexión que no se haya configurado con los ajustes necesarios para AWS Glue.

AWS Glue Studio crea conexiones unificadas de forma predeterminada. En la consola de AWS Glue, puede ver la versión de la conexión en la tabla de conexiones de la página de conexiones, en la página de detalles de las conexiones y en la tabla de conexiones de la página de detalles del trabajo.

Puede ver la versión de la conexión en Detalles de la conexión:

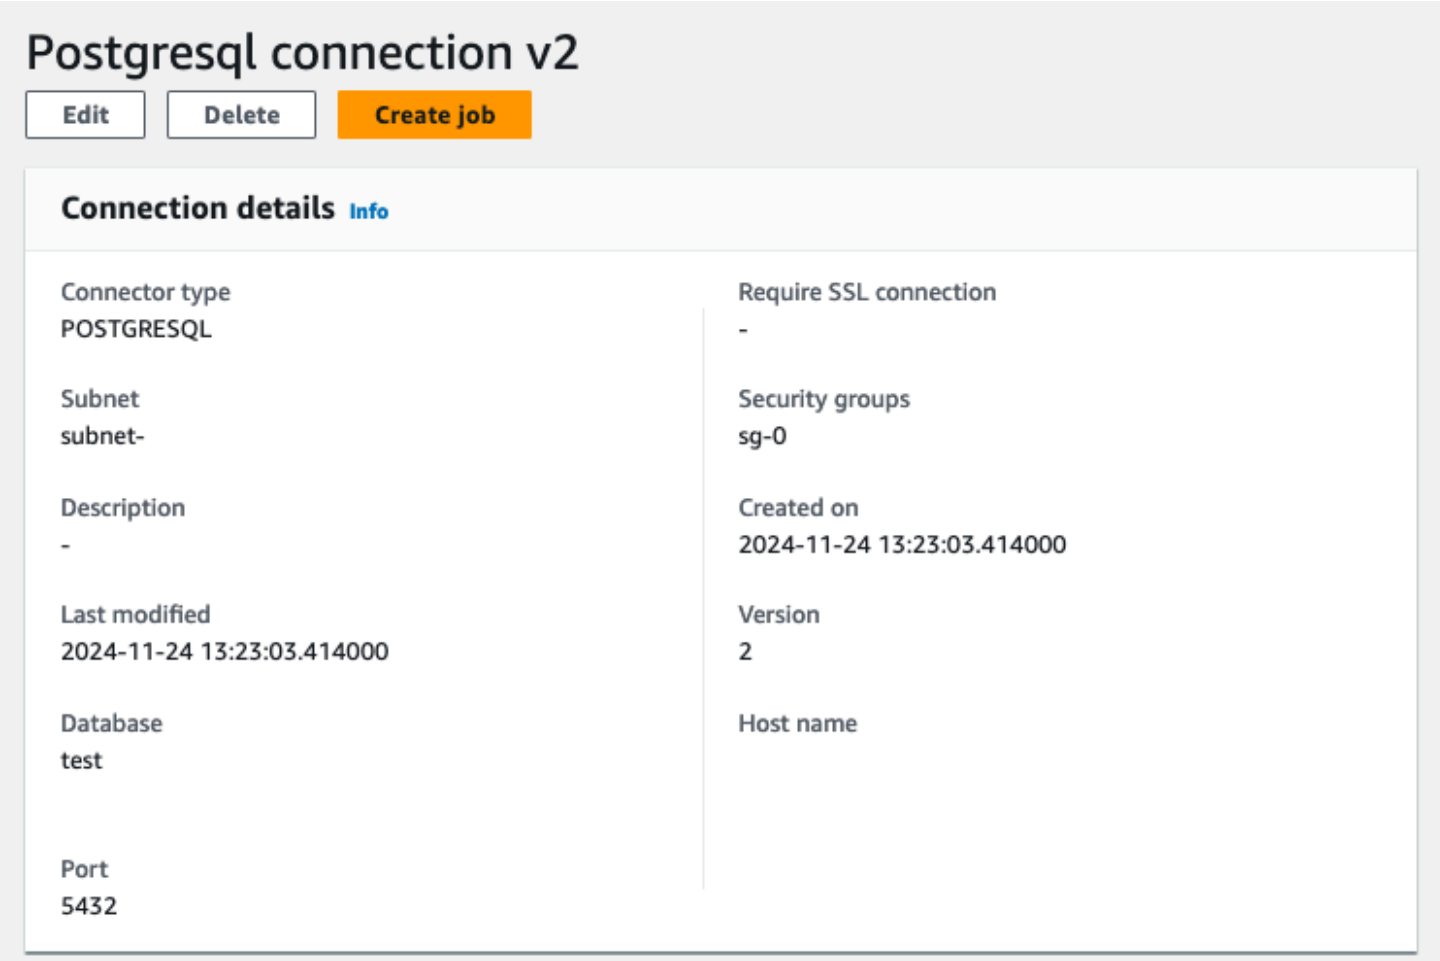

También puede ver la versión de la conexión cuando consulte todas sus conexiones.

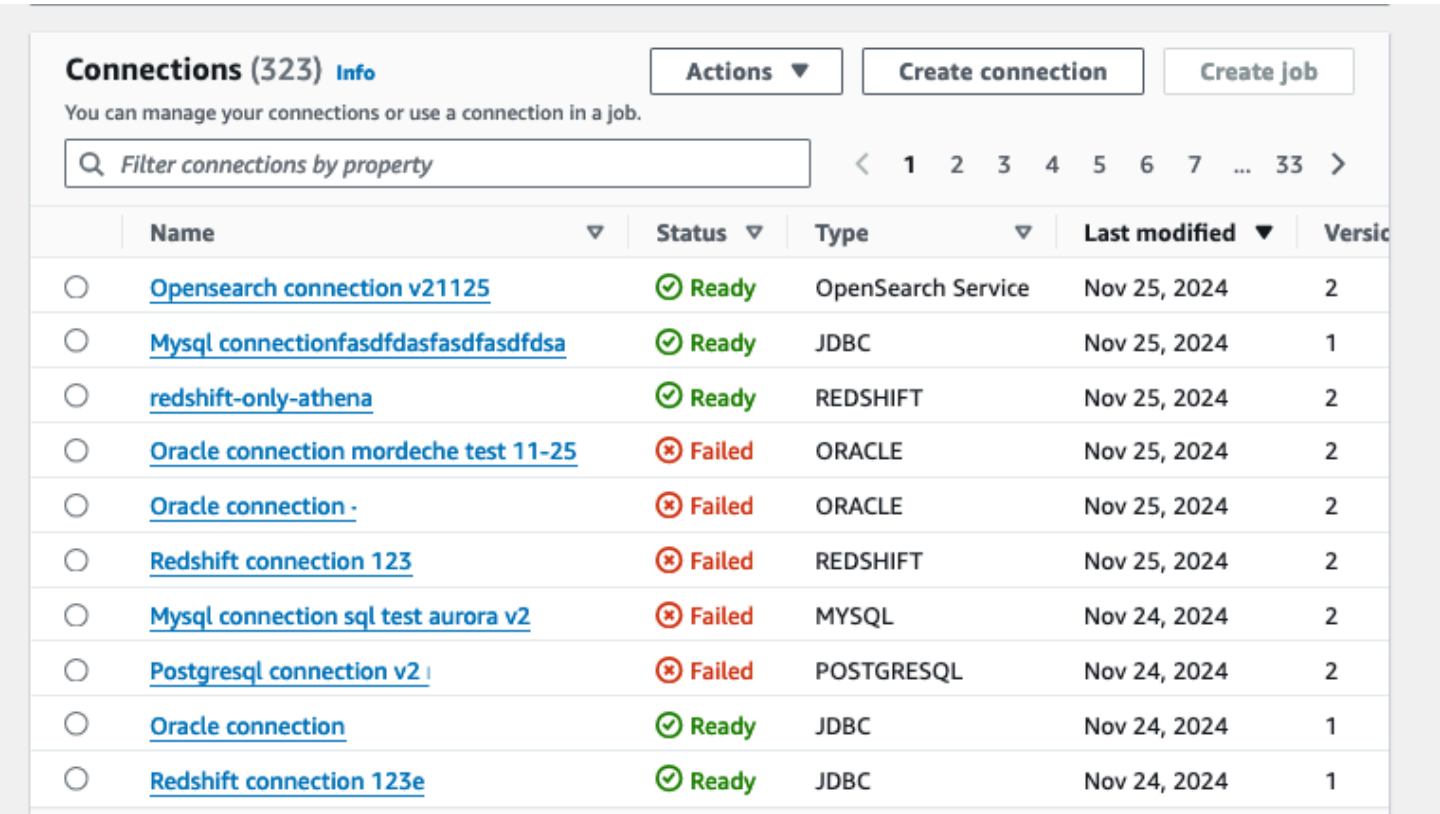

Por último, la versión de conexión está visible en la pestaña Detalles del trabajo de un trabajo.

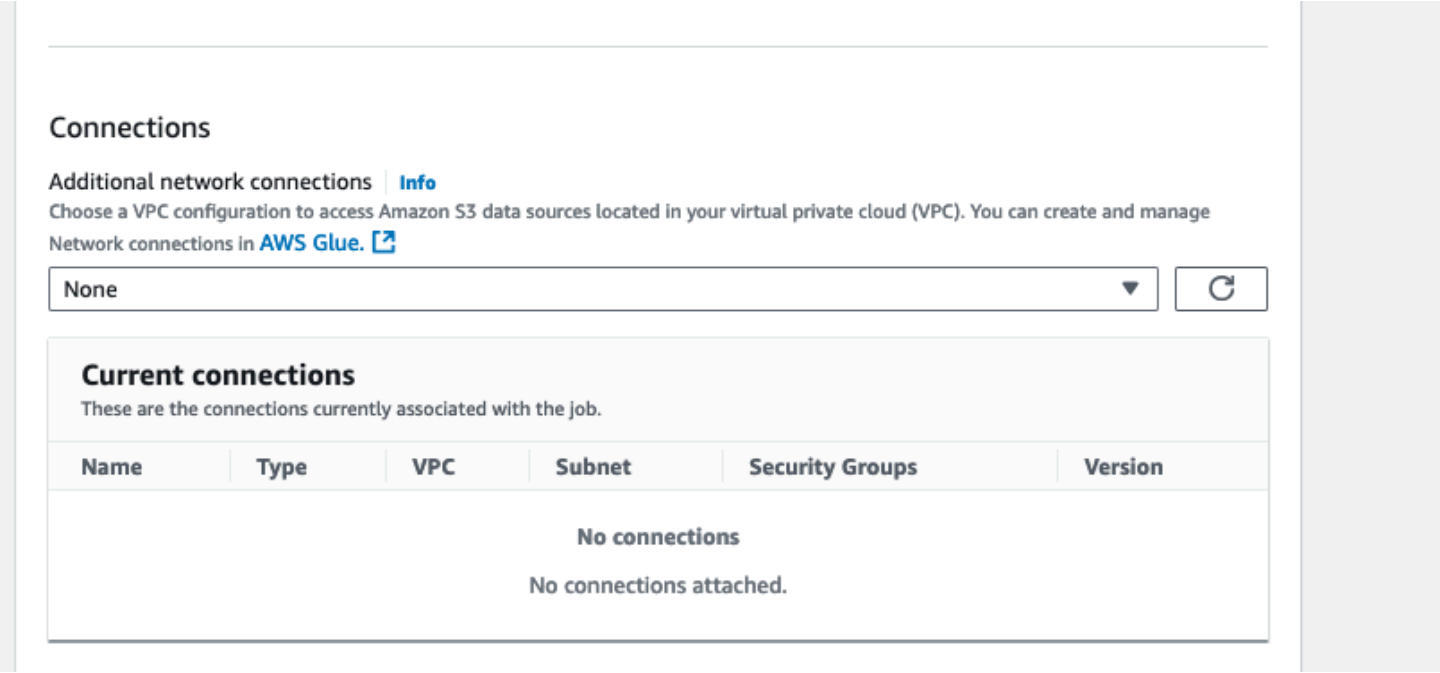

Con las conexiones de la versión 2, dispone de las siguientes capacidades ampliadas de conectividad de datos:

- Detección del tipo de conexión: compatibilidad para crear conexiones mediante plantillas estándar. AWS Glue detecta automáticamente los tipos de conexión a los que puede acceder y las entradas necesarias y opcionales de un tipo de conexión determinado.
- Reusabilidad: son definiciones de conexión que se pueden reutilizar en motores y herramientas de procesamiento de datos de AWS, como AWS Glue, Amazon Athena, y Amazon SageMaker AI. Las conexiones ahora contienen AthenaProperties, SparkProperties y PythonProperties, que permiten indicar propiedades de conexión específicas del entorno o servicio de computación, además de las propiedades comunes almacenadas en ConnectionProperties. Athena ahora crea conexiones en AWS Glue; para ello, debe indicar propiedades específicas de Athena en el mapa de propiedades AthenaProperties.
- Vista previa de datos: tiene la posibilidad de navegar por los metadatos y obtener una vista previa de los datos de los orígenes conectados.
- Metadatos del conector: se pueden utilizar conexiones reutilizables para descubrir los metadatos de las tablas.
- Secretos vinculados al servicio: los usuarios pueden proporcionar las credenciales de autenticación OAuth (básicas o personalizadas) necesarias en la solicitud `CreateConnection`. La API CreateConnection crea un secreto vinculado al servicio en su cuenta y almacena las credenciales en su nombre.

Tipos de autenticación compatibles

Las conexiones unificadas admiten los siguientes tipos de autenticación:

- BÁSICA: la mayoría de los tipos de conexión a bases de datos y los tipos de conexión a AWS Glue existentes admiten la autenticación básica, que consiste en un nombre de usuario y una contraseña. Anteriormente, la asignación de nombres a las claves en SecretsManager era específica del conector y, por ejemplo, podía ser user, username, userName, opensearch.net.http.auth.user, etc. Aquí es donde las conexiones unificadas estandarizan los tipos de conexión de autenticación básica en claves USERNAME y PASSWORD.
- OAUTH2: la mayoría de los tipos de conexión SaaS lanzados recientemente admiten el protocolo OAuth2.
- PERSONALIZADA: algunos tipos de conexión cuentan con algún otro mecanismo de autenticación, como Google BigQuery, en el que se espera que los usuarios proporcionen el JSON que obtienen de Google BigQuery.

Consideraciones

Al crear una conexión unificada para orígenes de datos, tenga en cuenta las siguientes diferencias:

- Al crear una conexión unificada a través de AWS Glue Studio, en lugar de la propia conexión, las credenciales de usuario se almacenan en AWS Secrets Manager. Esto significa que ahora los trabajos necesitan acceso a Secrets Manager.
- Si los trabajos se ejecutan en una VPC, necesitan un punto de conexión de VPC o una puerta de enlace NAT para acceder a AWS Secrets Manager y Secure Token Service (STS), lo que conlleva costos adicionales.
- Para determinados orígenes de datos (Redshift, SQL Server, MySQL, Oracle, PostgreSQL), la creación de una conexión unificada a través de AWS Glue Studio requiere acceso a AWS STS y AWS Secrets Manager. Esto es necesario para establecer una conexión segura y recuperar las credenciales requeridas para acceder a estos orígenes de datos dentro de la nube privada virtual (VPC).
- La creación de una conexión unificada a través de AWS Glue Studio requiere un rol de IAM con permisos para acceder a AWS Secrets Manager y administrar recursos de la VPC (si se utiliza una):
  - secretsmanager:GetSecretValue
  - secretsmanager:PutSecretValue
  - secretsmanager:DescribeSecret
  - ec2:CreateNetworkInterface
  - ec2:DeleteNetworkInterface
  - ec2:DescribeNetworkInterfaces
  - ec2:DescribeSubnets

Conexiones disponibles

AWS Glue admite los siguientes tipos de conexión:

- Adobe Analytics
- Adobe Marketo Engage
- Amazon Aurora (compatible si se utiliza el controlador JDBC nativo. No se pueden aprovechar todas las funciones del controlador)

- Amazon DocumentDB
- Amazon DynamoDB
- Amazon OpenSearch Service, para usarlo con AWS Glue for Spark.
- Amazon Redshift
- Asana
- Azure Cosmos, para usar Azure Cosmos DB para NoSQL con AWS Glue trabajos de ETL
- Azure SQL, para usar con AWS Glue for Spark.
- Blackbaud
- CircleCI
- Datadog
- Docusign Monitor
- Domo
- Dynatrace
- Facebook Ads
- Insights de la página de Facebook
- Freshdesk
- Freshsales
- Google Ads
- Google Analytics 4
- Google BigQuery, para usar con AWS Glue for Spark.
- Consola de búsqueda de Google
- Hojas de cálculo de Google
- HubSpot
- Publicidad en Instagram
- Intercom
- JDBC
- Jira Cloud
- Kafka
- Kustomer

- LinkedIn
- Mailchimp
- Microsoft Dynamics 365 CRM
- Microsoft Teams
- Mixpanel
- Lunes
- MongoDB
- MongoDB Atlas
- Okta
- Oracle NetSuite
- Paypal
- Pendo
- Pipedrive
- Productboard
- QuickBooks
- Salesforce
- Salesforce Commerce Cloud
- Salesforce Marketing Cloud
- Interacción con la cuenta de Salesforce Marketing Cloud (anteriormente Salesforce Pardot)
- SAP HANA, para usar con AWS Glue for Spark.
- SAP OData
- SendGrid
- ServiceNow
- Slack
- Smartsheet
- Snapchat Ads
- Stripe
- Snowflake, para usar con AWS Glue for Spark.
- Teradata Vantage, cuando se usa para AWS Glue for Spark.
- Twilio

- Vertica, para usar con AWS Glue for Spark.
- WooCommerce
- Zendesk
- Zoho CRM
- Zoom Meetings
- Varias ofertas de Amazon Relational Database Service (Amazon RDS).
- Network (Red) (designa una conexión a un origen de datos que se encuentra en un entorno de Amazon Virtual Private Cloud [Amazon VPC])

Con AWS Glue Studio, también se puede crear una conexión para un conector. Un conector es un paquete de códigos opcionales que ayuda a acceder a almacenes de datos en AWS Glue Studio. Para obtener más información, consulte Uso de conectores y conexiones con AWS Glue Studio

Para obtener información acerca de cómo conectarse a bases de datos locales, consulte Cómo acceder a almacenes de datos locales y analizarlos usando AWS Glue en el sitio web del blog de Big Data de AWS.

Para crear una conexión con una configuración de VPC mientras se utiliza un rol de IAM personalizado, este debe tener las siguientes acciones de acceso a la VPC:

- secretsmanager:GetSecretValue
- secretsmanager:PutSecretValue
- secretsmanager:DescribeSecret
- ec2:CreateNetworkInterface
- ec2:DeleteNetworkInterface
- ec2:DescribeNetworkInterfaces
- ec2:DescribeSubnets

Limitaciones

- No puede editar las conexiones a través de la consola de AWS Glue si creó una conexión de tipo v2 mediante las API de AWS Glue:
  - Amazon DocumentDB
  - Amazon Aurora

- MariaDB
- MongoDB Atlas
- MongoDB

AWS GluePropiedades de las conexiones de

Este tema incluye información sobre las propiedades de las conexiones de AWS Glue.

Temas

- Propiedades de conexión requeridas
- AWS GluePropiedades de las conexiones JDBC de
- AWS GluePropiedades de conexión de MongoDB y MongoDB Atlas de
- Propiedades de conexión de Salesforce
- Conexión Snowflake
- Conexión vertical
- Conexión a SAP HANA
- Conexión a Azure SQL
- Conexión de Teradata Vantage
- Conexión de OpenSearch Service
- Conexión de Azure Cosmos
- AWS GluePropiedades de las conexiones SSL de
- Propiedades de las conexiones de Apache Kafka para la autenticación de clientes
- Conexión a Google BigQuery
- Conexión vertical

Propiedades de conexión requeridas

Cuando se define una conexión en la consola de AWS Glue, se deben proporcionar valores para las siguientes propiedades:

Nombre de la conexión

Ingrese un nombre único para la conexión.

Tipo de conexión

Elija JDBC o uno de los tipos de conexión específicos.

Para obtener más información sobre el tipo de conexión JDBC, consulte the section called "Propiedades de las conexiones JDBC"

Elija Red para conectarse a un origen de datos dentro de un entorno de Amazon Virtual Private Cloud (Amazon VPC).

En función del tipo que elija, la consola de AWS Glue muestra otros campos obligatorios. Por ejemplo, si elige Amazon RDS, debe elegir el motor de base de datos.

Exigir conexión SSL

Cuando selecciona esta opción, AWS Glue debe comprobar que se realizó la conexión a la base de datos a través de una conexión de capa de conexión segura (SSL) de confianza.

Para obtener más información, incluidas las opciones adicionales que están disponibles al seleccionar esta opción, consulte the section called "Propiedades de las conexiones SSL".

Seleccione el clúster MSK [solo streaming administrada por Amazon para Apache Kafka (MSK)]

Especifica un clúster MSK de otra cuenta de AWS.

URL de servidor de arranque Kafka (sólo Kafka)

Especifica una lista separada por comas de direcciones URL del servidor de arranque. Incluya el número de puerto. Por ejemplo: b-1.vpc-test-2.o4q88o.c6.kafka.us-east-1.amazonaws.com:9094, b-2.vpc-test-2.o4q88o.c6.kafka.us-east-1.amazonaws.com:9094, b-3.vpc-test-2.o4q88o.c6.kafka.us-east-1.amazonaws.com:9094

AWS GluePropiedades de las conexiones JDBC de

AWS Glue Studio ahora crea conexiones unificadas para orígenes de datos de MySQL, Oracle, PostgresSQL, Redshift y SQL Server, lo que requiere pasos adicionales para acceder a los recursos de la VPC y Secrets Manager. Puede suponer costos adicionales. Para acceder a estas conexiones en AWS Glue Studio, seleccione el nombre de la conexión correspondiente.

Para obtener más información, consulte Consideraciones.

AWS Glue puede conectarse a los siguientes almacenes de datos a través de una conexión JDBC:

- Amazon Redshift

- Amazon Aurora
- Microsoft SQL Server
- MySQL
- Oracle
- PostgreSQL
- Copo de nieve, cuando se utilizan rastreadores AWS Glue.
- Aurora (compatible si se utiliza el controlador JDBC nativo. No se pueden aprovechar todas las características del controlador)
- Amazon RDS for MariaDB

> **Important**
>
> Actualmente, los trabajos de ETL pueden utilizar conexiones JDBC dentro de una sola subred. Si tiene varios almacenes de datos en un trabajo, deben estar en la misma subred, o ser accesibles desde la subred.
> Si decide incorporar sus versiones de controladores JDBC para rastreadores AWS Glue, estos consumirán recursos en trabajos AWS Glue y Amazon S3 para garantizar que los controladores proporcionados se ejecuten en su entorno. El uso adicional de los recursos se reflejará en su cuenta. Además, proporcionar su propio controlador JDBC no significa que el rastreador pueda aprovechar todas las funciones del controlador. Los controladores se limitan a las propiedades descritas en Definir las conexiones en el catálogo de datos.

A continuación, se muestran propiedades adicionales para el tipo de conexión JDBC.

JDBC URL (Dirección URL de JDBC)

Ingrese la dirección URL para el almacén de datos de JDBC. Para la mayoría de motores de base de datos, este campo se encuentra en el siguiente formato. En este formato, sustituya *protocolo*, *host*, *puerto* y *db_name* con su propia información.

```
jdbc:protocol://host:port/db_name
```

En función del motor de base de datos, es posible que se requiera un formato de dirección URL de JDBC diferente. Este formato puede utilizar los dos puntos (:) y la barra inclinada (/) de forma ligeramente diferente o palabras clave distintas para especificar bases de datos.

Para que JDBC se conecte al almacén de datos, se requiere un db_name en el almacén de datos. Se utiliza db_name para establecer una conexión de red con los ajustes `username` y `password` proporcionados. Cuando se haya establecido la conexión, AWS Glue tendrá acceso a otras bases de datos en el almacén de datos para ejecutar un rastreador o un flujo de trabajo de ETL.

Los siguientes ejemplos de dirección URL de JDBC muestran la sintaxis para diversos motores de base de datos.

- Para conectarse a un almacén de datos de clústeres de Amazon Redshift con una base de datos de `dev`:

  ```
  jdbc:redshift://xxx.us-east-1.redshift.amazonaws.com:8192/dev
  ```

- Para conectarse a un almacén de datos de Amazon RDS for MySQL con una base de datos de `employee`:

  ```
  jdbc:mysql://xxx-cluster.cluster-xxx.us-east-1.rds.amazonaws.com:3306/
  employee
  ```

- Para conectarse a un almacén de datos de Amazon RDS for PostgreSQL con una base de datos de `employee`:

  ```
  jdbc:postgresql://xxx-cluster.cluster-xxx.us-
  east-1.rds.amazonaws.com:5432/employee
  ```

- Para conectarse a un almacén de datos de Amazon RDS for Oracle con un nombre de servicio `employee`:

  ```
  jdbc:oracle:thin://@xxx-cluster.cluster-xxx.us-
  east-1.rds.amazonaws.com:1521/employee
  ```

  La sintaxis para Amazon RDS for Oracle puede seguir los siguientes patrones. En estos patrones, sustituya *`host`*, *`puerto`*, *`nombre de servicio`* y *`SID`* con su propia información.

  - `jdbc:oracle:thin://@`*`host`*`:`*`port`*`/`*`service_name`*
  - `jdbc:oracle:thin://@`*`host`*`:`*`port`*`:`*`SID`*

- Para conectarse a un almacén de datos de Amazon RDS for Microsoft SQL Server con una base de datos de `employee`:

  ```
  jdbc:sqlserver://xxx-cluster.cluster-xxx.us-
  east-1.rds.amazonaws.com:1433;databaseName=employee
  ```

La sintaxis para Amazon RDS for SQL Server puede seguir los siguientes patrones. En estos patrones, reemplace *server_name*, *port* y *db_name* por su propia información.

- `jdbc:sqlserver://server_name:port;database=db_name`
- `jdbc:sqlserver://server_name:port;databaseName=db_name`

- Para conectarse a una instancia de Amazon Aurora PostgreSQL de la base de datos de `employee`, especifique el punto de enlace para la instancia de base de datos, el puerto y el nombre de la base de datos:

  `jdbc:postgresql://employee_instance_1.xxxxxxxxxxxx.us-east-2.rds.amazonaws.com:5432/employee`

- Para conectarse a un almacén de datos de Amazon RDS for MariaDB con una base de datos de `employee`, especifique el punto de conexión para la instancia de la base de datos, el puerto y el nombre de la base de datos:

  `jdbc:mysql://xxx-cluster.cluster-xxx.aws-region.rds.amazonaws.com:3306/employee`

- **Warning**

  Las conexiones JDBC de Snowflake solo las admiten los rastreadores AWS Glue. Cuando utilice el conector Snowflake en los trabajos AWS Glue, utilice el tipo de conexión Snowflake.

  Para conectarse a una instancia de Snowflake de la base de datos `sample`, especifique el punto de conexión para la instancia de Snowflake, el usuario, el nombre de la base de datos y el nombre del rol. Si lo desea, puede agregar el parámetro `warehouse`.

  `jdbc:snowflake://account_name.snowflakecomputing.com/?user=user_name&db=sample&role=role_name&warehouse=warehouse_name`

  Important

  Para las conexiones de Snowflake a través de JDBC, se aplica el orden de los parámetros de la URL y se deben ordenar como `user`, db, `role_name` y `warehouse`.

- Para conectarse a una instancia de Snowflake de la base de datos `sample` con un enlace privado de AWS, especifique la URL de JDBC de Snowflake de la siguiente forma:

  ```
  jdbc:snowflake://account_name.region.privatelink.snowflakecomputing.com/?user=user_name&db=sample&role=role_name&warehouse=warehouse_name
  ```

Nombre de usuario

> **Note**
>
> Se recomienda utilizar un secreto de AWS para almacenar las credenciales de conexión en lugar de suministrar su nombre de usuario y contraseña directamente. Para obtener más información, consulte Almacenamiento de credenciales de conexión en AWS Secrets Manager.

Proporcione un nombre de usuario que tenga permisos para obtener acceso al almacén de datos de JDBC.

Contraseña

Ingrese la contraseña para el nombre de usuario con los permisos de acceso al almacén de datos de JDBC.

Puerto

Ingrese el puerto que se utiliza en la URL de JDBC para conectarse a una instancia de Oracle de Amazon RDS. Este campo es solo se muestra cuando se selecciona Solicitar conexión SSL para una instancia de Oracle de Amazon RDS.

VPC

Seleccione el nombre de la nube privada virtual (VPC) que contenga el almacén de datos. La consola de AWS Glue muestra todas las VPC para la región actual.

> **Important**
>
> Al trabajar con una conexión JDBC alojada fuera de AWS, por ejemplo, con datos de Snowflake, la VPC debe tener una puerta de enlace NAT que divida el tráfico en subredes públicas y privadas. La subred pública se utiliza para la conexión al origen externo y la subred interna se utiliza para el procesamiento por parte de AWS Glue. Para obtener información sobre cómo configurar su Amazon VPC para conexiones externas, lea

Conectarse a Internet u otras redes mediante dispositivos NAT y Configuración de Amazon VPC para conexiones JDBC a los almacenes de datos de Amazon RDS de AWS Glue.

Subred

Seleccione la subred dentro de la VPC que contenga el almacén de datos. La consola de AWS Glue incluye todas las subredes para el almacén de datos en la VPC.

Grupos de seguridad

Elija los grupos de seguridad asociados a su almacén de datos. AWS Glue requiere uno o varios grupos de seguridad con una regla de origen de entrada que permite AWS Glue establezca la conexión. La consola de AWS Glue incluye todos los grupos de seguridad con acceso de entrada a su VPC. AWS Glue asocia estos grupos de seguridad con la interfaz de red elástica que se asocia a su subred de VPC.

Nombre de la clase de controlador JDBC: opcional

Proporcione el nombre de la clase de controlador JDBC personalizado:

- Postgres – org.postgresql.Driver
- MySQL – com.mysql.jdbc.Driver, com.mysql.cj.jdbc.Driver
- Redshift – com.amazon.redshift.jdbc.Driver, com.amazon.redshift.jdbc42.Driver
- Oracle – oracle.jdbc.driver.OracleDriver
- Servidor SQL – com.microsoft.sqlserver.jdbc.SQLServerDriver

Ruta S3 del controlador JDBC: opcional

Proporcione la ubicación de Amazon S3 al controlador JDBC personalizado. Esta es una ruta absoluta a un archivo .jar. Si desea disponer de sus propios controladores JDBC para conectarse a los orígenes de datos de las bases de datos compatibles con su rastreador, puede especificar valores para los parámetros `customJdbcDriverS3Path` y `customJdbcDriverClassName`. Utilizar un controlador JDBC suministrado por un cliente se limita a lo requerido Propiedades de conexión requeridas.

AWS GluePropiedades de conexión de MongoDB y MongoDB Atlas de

A continuación, se muestran propiedades adicionales para el tipo de conexión de MongoDB o MongoDB Atlas.

URL de MongoDB

Ingrese la URL de su almacén de datos de MongoDB o MongoDB Atlas:

- Para MongoDB: mongodb://host:port/database. El host puede ser un nombre de host, una dirección IP o un socket de dominio UNIX. Si la cadena de conexión no especifica ningún puerto, utiliza el puerto predeterminado de MongoDB, 27017.
- Para MongoDB Atlas: mongodb+srv://server.example.com/database. El host puede ser un nombre de host que corresponde a un registro SRV de DNS. El formato SRV no requiere ningún puerto y utilizará el puerto MongoDB predeterminado, 27017.

Nombre de usuario

> **Note**
>
> Se recomienda utilizar un secreto de AWS para almacenar las credenciales de conexión en lugar de suministrar su nombre de usuario y contraseña directamente. Para obtener más información, consulte Almacenamiento de credenciales de conexión en AWS Secrets Manager.

Proporcione un nombre de usuario que tenga permisos para obtener acceso al almacén de datos de JDBC.

Contraseña

Ingrese la contraseña para el nombre de usuario con los permisos de acceso al almacén de datos de MongoDB o MongoDB Atlas.

Propiedades de conexión de Salesforce

Las siguientes son propiedades adicionales para el tipo de conexión de Salesforce.

- `ENTITY_NAME`(cadena): (obligatorio) se utiliza para leer y escribir. El nombre de su objeto en Salesforce.

- `API_VERSION`(cadena): (obligatorio) se utiliza para leer y escribir. Versión de la API de REST de Salesforce que desea utilizar.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.
- `PARTITION_FIELD`(cadena): se usa para leer. Campo que se utilizará para particionar la consulta.
- `LOWER_BOUND`(cadena): se usa para leer. Un valor de límite inferior inclusivo del campo de partición elegido.
- `UPPER_BOUND`(cadena): se usa para leer. Un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`(entero): predeterminado: 1. Se usa para leer. Número de particiones para leer.
- `IMPORT_DELETED_RECORDS`(cadena): predeterminado: FALSO. Se usa para leer. Para obtener los registros eliminados durante la consulta.
- `WRITE_OPERATION`(cadena): predeterminado: INSERT. Se utiliza para escribir. El valor debe ser INSERT, UPDATE, UPSERT, DELETE.
- `ID_FIELD_NAMES`(cadena): predeterminado: nulo. Se usa solo para UPSERT.

Conexión Snowflake

Las siguientes propiedades se utilizan para configurar una conexión Snowflake utilizada en los trabajos de ETL AWS Glue. Al rastrear Snowflake, utilice una conexión JDBC.

URL de Snowflake

La URL del punto de conexión de Snowflake. Para obtener más información sobre las URL de los puntos de conexión de Snowflake, consulte Cómo conectarse a sus cuentas en la documentación de Snowflake.

Secreto AWS

El nombre secreto de un secreto en AWS Secrets Manager. AWS Glue se conectará a Snowflake a través de las claves `sfUser` y `sfPassword` de su secreto.

La función de Snowflake (opcional)

Se utilizará un rol AWS Glue de seguridad de Snowflake al conectarse.

Utilice las siguientes propiedades al configurar una conexión a un punto de conexión de Snowflake alojado en Amazon VPC mediante AWS PrivateLink.

VPC

Seleccione el nombre de la nube privada virtual (VPC) que contenga el almacén de datos. La consola de AWS Glue muestra todas las VPC para la región actual.

Subred

Seleccione la subred dentro de la VPC que contenga el almacén de datos. La consola de AWS Glue incluye todas las subredes para el almacén de datos en la VPC.

Grupos de seguridad

Elija los grupos de seguridad asociados a su almacén de datos. AWS Glue requiere uno o varios grupos de seguridad con una regla de origen de entrada que permite AWS Glue establezca la conexión. La consola de AWS Glue incluye todos los grupos de seguridad con acceso de entrada a su VPC. AWS Glue asocia estos grupos de seguridad con la interfaz de red elástica que se asocia a su subred de VPC.

Conexión vertical

Utilice las siguientes propiedades para configurar una conexión de Vertica para los trabajos de AWS Glue ETL.

Host de Vertica

El nombre de host de su instalación de Vertica.

Puerto de Vertica

El puerto a través del cual está disponible su instalación de Vertica.

AWS Secret

El nombre secreto de un secreto en AWS Secrets Manager. AWS Glue se conectará a Vertica a través de las claves de su secreto.

Utilice las siguientes propiedades al configurar una conexión a un punto de conexión de Vertica alojado en Amazon VPC.

VPC

Seleccione el nombre de la nube privada virtual (VPC) que contenga el almacén de datos. La consola de AWS Glue muestra todas las VPC para la región actual.

Subred

Seleccione la subred dentro de la VPC que contenga el almacén de datos. La consola de AWS Glue incluye todas las subredes para el almacén de datos en la VPC.

Grupos de seguridad

Elija los grupos de seguridad asociados a su almacén de datos. AWS Glue requiere uno o varios grupos de seguridad con una regla de origen de entrada que permite AWS Glue establezca la conexión. La consola de AWS Glue incluye todos los grupos de seguridad con acceso de entrada a su VPC. AWS Glue asocia estos grupos de seguridad con la interfaz de red elástica que se asocia a su subred de VPC.

Conexión a SAP HANA

Utilice las siguientes propiedades para configurar una conexión a SAP HANA para trabajos de AWS Glue ETL.

URL DE SAP HANA

UNA URL DE SAP JDBC.

Las URL de JDBC de SAP HANA tienen el formato `jdbc:sap://saphanaHostname:saphanaPort/?databaseName=saphanaDBname,ParameterNa`

AWS Glue requiere los siguientes parámetros de URL de JDBC:

- `databaseName`: una base de datos predeterminada en SAP HANA a la que conectarse.

AWS Secret

El nombre secreto de un secreto en AWS Secrets Manager. AWS Glue se conectará a SAP HANA a través de las claves de su secreto.

Utilice las siguientes propiedades al configurar una conexión a un punto de conexión de SAP HANA alojado en Amazon VPC:

VPC

Seleccione el nombre de la nube privada virtual (VPC) que contenga el almacén de datos. La consola de AWS Glue muestra todas las VPC para la región actual.

Subred

Seleccione la subred dentro de la VPC que contenga el almacén de datos. La consola de AWS Glue incluye todas las subredes para el almacén de datos en la VPC.

Grupos de seguridad

Elija los grupos de seguridad asociados a su almacén de datos. AWS Glue requiere uno o varios grupos de seguridad con una regla de origen de entrada que permite AWS Glue establezca la conexión. La consola de AWS Glue incluye todos los grupos de seguridad con acceso de entrada a su VPC. AWS Glue asocia estos grupos de seguridad con la interfaz de red elástica que se asocia a su subred de VPC.

Conexión a Azure SQL

Utilice las siguientes propiedades para configurar una conexión a Azure SQL para los trabajos de AWS Glue ETL.

Dirección URL de Azure SQL

La dirección URL de JDBC de un punto de conexión de Azure SQL.

La lista de URL debe tener el siguiente formato: `jdbc:sqlserver://databaseServerName:databasePort;databaseName=azuresqlDBname;`.

AWS Glue requiere las siguientes propiedades de URL:

- `databaseName`: una base de datos predeterminada en Azure SQL a la que conectarse.

Para obtener más información sobre las direcciones URL de JDBC para instancias administradas de Azure SQL, consulte la documentación de Microsoft.

AWS Secret

El nombre secreto de un secreto en AWS Secrets Manager. AWS Glue se conectará a Azure SQL a través de las claves de su secreto.

Conexión de Teradata Vantage

Utilice las siguientes propiedades para configurar una conexión de Teradata Vantage para trabajos de AWS Glue ETL.

Dirección URL de Teradata

Para conectarse a una instancia de Teradata, especifique el nombre de host de la instancia de base de datos y los parámetros de Teradata pertinentes:

```
jdbc:teradata://teradataHostname/ParameterName=ParameterValue,ParameterName=Pa
```

AWS Glue es compatible con los siguientes parámetros de consulta de URL de JDBC:

- `DATABASE_NAME`: una base de datos predeterminada de Teradata a la que conectarse.
- `DBS_PORT`: especifica el puerto de Teradata, si no es estándar.

AWS Secret

El nombre secreto de un secreto en AWS Secrets Manager. AWS Glue se conectará a Teradata a través de las claves de su secreto.

Utilice las siguientes propiedades al configurar una conexión a un punto de conexión de Teradata Vantage alojado en Amazon VPC:

VPC

Seleccione el nombre de la nube privada virtual (VPC) que contenga el almacén de datos. La consola de AWS Glue muestra todas las VPC para la región actual.

Subred

Seleccione la subred dentro de la VPC que contenga el almacén de datos. La consola de AWS Glue incluye todas las subredes para el almacén de datos en la VPC.

Grupos de seguridad

Elija los grupos de seguridad asociados a su almacén de datos. AWS Glue requiere uno o varios grupos de seguridad con una regla de origen de entrada que permite AWS Glue establezca la conexión. La consola de AWS Glue incluye todos los grupos de seguridad con acceso de entrada a su VPC. AWS Glue asocia estos grupos de seguridad con la interfaz de red elástica que se asocia a su subred de VPC.

Conexión de OpenSearch Service

Utilice las siguientes propiedades para configurar una conexión con OpenSearch Service para los trabajos de AWS Glue ETL.

Punto de conexión del dominio

Un punto de conexión de dominio de Amazon OpenSearch Service tendrá el siguiente formulario predeterminado: https://search-*domainName*-*unstructuredIdContent*.*region*.es.amazonaws.com. Para obtener más información sobre cómo identificar su punto de conexión de dominio, consulte Crear y administrar dominios de Amazon OpenSearch Service en la documentación de Amazon OpenSearch Service.

Puerto

El puerto abierto en el punto de conexión.

AWS Secret

El nombre secreto de un secreto en AWS Secrets Manager. AWS Glue se conectará a OpenSearch Service a través de las claves de su secreto.

Utilice las siguientes propiedades al configurar una conexión a un punto de conexión de OpenSearch Service alojado en Amazon VPC:

VPC

Seleccione el nombre de la nube privada virtual (VPC) que contenga el almacén de datos. La consola de AWS Glue muestra todas las VPC para la región actual.

Subred

Seleccione la subred dentro de la VPC que contenga el almacén de datos. La consola de AWS Glue incluye todas las subredes para el almacén de datos en la VPC.

Grupos de seguridad

Elija los grupos de seguridad asociados a su almacén de datos. AWS Glue requiere uno o varios grupos de seguridad con una regla de origen de entrada que permite AWS Glue establezca la conexión. La consola de AWS Glue incluye todos los grupos de seguridad con acceso de entrada a su VPC. AWS Glue asocia estos grupos de seguridad con la interfaz de red elástica que se asocia a su subred de VPC.

Conexión de Azure Cosmos

Use las siguientes propiedades para configurar una conexión de Azure Cosmos para trabajos de AWS Glue ETL.

URI de punto de conexión de la cuenta de base de datos de Azure Cosmos DB

El punto de conexión usado para conectarse a Azure Cosmos. Para obtener más información, consulte la documentación de Azure.

AWS Secret

El nombre secreto de un secreto en AWS Secrets Manager. AWS Glue se conectará a Azure Cosmos a través de las claves de su secreto.

AWS GluePropiedades de las conexiones SSL de

A continuación, se muestran los detalles sobre la propiedad Require SSL connection (Solicitar conexión SSL).

Si no se solicita una conexión SSL, AWS Glue ignora los errores cuando utiliza SSL para cifrar una conexión a un almacén de datos. Para obtener instrucciones de configuración consulte la documentación del almacén de datos. Si se selecciona esta opción, se produce un error en la ejecución del trabajo, el rastreador o las instrucciones ETL de un punto de conexión de desarrollo cuando AWS Glue no puede conectarse.

> **Note**
>
> Snowflake admite una conexión SSL de forma predeterminada, por lo que esta propiedad no se aplica a Snowflake.

Esta opción se valida en el lado del cliente de AWS Glue. Para las conexiones JDBC, AWS Glue solo se conecta a través de SSL con validación de certificados y nombres de host. El soporte de conexión SSL está disponible para lo siguiente:

- Base de datos de Oracle
- Microsoft SQL Server
- PostgreSQL

- Amazon Redshift
- MySQL (solo instancias de Amazon RDS)
- Amazon Aurora MySQL (solo instancias de Amazon RDS)
- Amazon Aurora PostgreSQL (solo instancias de Amazon RDS)
- Kafka, que incluye Amazon Managed Streaming for Apache Kafka
- MongoDB

> **Note**
>
> Para habilitar un almacén de datos de Oracle de Amazon RDS para utilizar Solicitar conexión SSL, debe crear y asociar un grupo de opciones a la instancia de Oracle.
>
> 1. Inicie sesión en la Consola de administración de AWS y abra la consola de Amazon RDS en https://console.aws.amazon.com/rds/.
> 2. Agregue un Grupo de opciones a la instancia de Oracle de Amazon RDS. Para obtener más información sobre cómo agregar un grupo de opciones en la consola de Amazon RDS, consulte Creación de un grupo de opciones
> 3. Añada una Opción al grupo de opciones para SSL. El Puerto que especifique para SSL se usará posteriormente al crear una URL de conexión de JDBC de AWS Glue para la instancia de Oracle de Amazon RDS. Para obtener más información sobre cómo agregar una opción en la consola de Amazon RDS, consulte Agregar una opción a un grupo de opciones en la Guía del usuario de Amazon RDS. Para obtener más información acerca de las opciones de SSL de Oracle, consulte SSL de Oracle en la Guía del usuario de Amazon RDS.
> 4. En la consola de AWS Glue, cree una conexión a la instancia de Oracle de Amazon RDS. En la definición de conexión, seleccione Solicitar conexión SSL. Cuando se solicite, ingrese el Puerto que utilizó en la opción SSL de Oracle de Amazon RDS.

Las siguientes propiedades opcionales adicionales están disponibles cuando se selecciona Solicitar conexión SSL para una conexión:

Certificado JDBC personalizado en S3

Si tiene un certificado que utiliza actualmente para la comunicación SSL con sus bases de datos locales o en la nube, puede utilizar dicho certificado para las conexiones SSL a orígenes

o destinos de datos de AWS Glue. Ingrese una ubicación de Amazon Simple Storage Service (Amazon S3) que contenga un certificado raíz personalizado. AWS Glue utiliza este certificado para establecer una conexión SSL a la base de datos. AWS Glue solo controla los certificados X.509. El certificado debe estar codificado en DER y suministrarse en formato PEM con codificación base64.

Si este campo se deja en blanco, se utiliza el certificado predeterminado.

Cadena de certificado JDBC personalizada

Ingrese la información del certificado específico de su base de datos JDBC. Esta cadena se utiliza para la coincidencia de dominios o la coincidencia de nombres distintivos (DN). Para Oracle Database, esta cadena se asigna al parámetro `SSL_SERVER_CERT_DN` de la sección de seguridad del archivo `tnsnames.ora`. Para Microsoft SQL Server, esta cadena se utiliza como `hostNameInCertificate`.

A continuación se muestra un ejemplo del parámetro `SSL_SERVER_CERT_DN` de Oracle Database.

```
cn=sales,cn=OracleContext,dc=us,dc=example,dc=com
```

Ubicación del certificado de CA privada de Kafka

Si tiene un certificado que utiliza actualmente para la comunicación SSL con su almacén de datos de Kafka, puede utilizar dicho certificado con su conexión de AWS Glue. Esta opción es necesaria para los almacenes de datos de Kafka y opcional para almacenes de datos de Amazon Managed Streaming for Apache Kafka. Ingrese una ubicación de Amazon Simple Storage Service (Amazon S3) que contenga un certificado raíz personalizado. AWS Glue utiliza este certificado para establecer una conexión SSL al almacén de datos de Kafka. AWS Glue solo controla los certificados X.509. El certificado debe estar codificado en DER y suministrarse en formato PEM con codificación base64.

Omitir la validación de certificados

Seleccione la casilla de verificación Omitir validación de certificado para omitir la validación del certificado personalizado por AWS Glue. Si decide validar, AWS Glue valida el algoritmo de firma y el algoritmo de clave pública de sujeto para el certificado. Si el certificado no supera la validación, se producirá un error en cualquier trabajo de ETL o rastreador que utilice la conexión.

Los únicos algoritmos de firma permitidos son SHA256withRSA, SHA384withRSA o SHA512withRSA. Para el algoritmo de clave pública del asunto, la longitud de la clave debe ser al menos 2048.

Ubicación del almacén de claves del cliente de Kafka

La ubicación de Amazon S3 del archivo de almacén de claves del cliente para la autenticación del lado del cliente Kafka. La ruta debe tener el formato s3://bucket/prefix/filename.jks. Debe terminar con el nombre de archivo y la extensión .jks.

Contraseña del almacén de claves del cliente de Kafka (opcional)

La contraseña para acceder al almacén de claves proporcionado.

Contraseña de la clave del cliente de Kafka (opcional)

Un almacén de claves puede consistir en varias claves, por lo que esta es la contraseña para acceder a la clave del cliente que se utilizará con la clave del lado del servidor Kafka.

Propiedades de las conexiones de Apache Kafka para la autenticación de clientes

AWS Glue admite el marco del nivel de seguridad y autenticación simples (SASL) para la autenticación cuando se crea una conexión de Apache Kafka. El esquema SASL es compatible con distintos mecanismos de autenticación; AWS Glue ofrece los protocolos SCRAM (nombre de usuario y contraseña), GSSAPI (protocolo Kerberos) y PLAIN.

Utilice AWS Glue Studio para configurar uno de los siguientes métodos de autenticación de clientes. Para obtener más información, consulte Creación de conexiones para conectores en la guía del usuario AWS Glue Studio.

- Ninguno: sin autenticación. Esto resulta útil si se crea una conexión con fines de prueba.
- SASL/SCRAM-SHA-512: la elección de este método de autenticación le permitirá especificar credenciales de autenticación. Existen dos opciones disponibles:
  - Utilizar AWS Secrets Manager (recomendado): si selecciona esta opción, puede almacenar su nombre de usuario y contraseña en AWS Secrets Manager y dejar que AWS Glue acceda a ellos cuando sea necesario. Especificar el secreto donde están almacenadas las credenciales de autenticación SSL o SASL. Para obtener más información, consulte Almacenamiento de credenciales de conexión en AWS Secrets Manager.

  - Proporcione un nombre de usuario y una contraseña directamente.
- SASL/GSSAPI (Kerberos): si selecciona esta opción, puede seleccionar la ubicación del archivo keytab, el archivo krb5.conf e ingresar el nombre principal y el nombre del servicio de Kerberos. Las ubicaciones de los archivos keytab y krb5.conf deben estar en una ubicación de Simple Storage Service (Amazon S3). Dado que MSK aún no admite SASL/GSSAPI, esta opción solo está disponible para clústeres Apache Kafka administrados por el cliente. Para obtener más información, consulte MIT Kerberos Documentation: Keytab (Documentación de MIT Kerberos: Keytab).
- SASL/PLAIN: seleccione este método de autenticación para especificar las credenciales de autenticación. Existen dos opciones disponibles:
  - Utilizar AWS Secrets Manager (recomendado): si selecciona esta opción, puede almacenar sus credenciales en AWS Secrets Manager y dejar que AWS Glue acceda a la información cuando sea necesario. Especificar el secreto donde están almacenadas las credenciales de autenticación SSL o SASL.
  - Brinde de manera directa un usuario y una contraseña.
- Autenticación de cliente SSL: si selecciona esta opción, puede seleccionar la ubicación del almacén de claves del cliente Kafka navegando por Simple Storage Service (Amazon S3). Opcionalmente, puede ingresar la contraseña del almacén de claves del cliente Kafka y la contraseña de clave de cliente Kafka.

Conexión a Google BigQuery

Las siguientes propiedades se utilizan para configurar una conexión Google BigQuery utilizada en los trabajos de ETL de AWS Glue. Para obtener más información, consulte the section called “Conexiones de BigQuery”.

AWS Secret

El Nombre secreto de un secreto en AWS Secrets Manager. AWS Glue Los trabajos de ETL se conectarán a Google BigQuery mediante la clave `credentials` del secreto.

Conexión vertical

Las siguientes propiedades se utilizan para configurar una conexión Vertica utilizada en los trabajos de AWS Glue ETL. Para obtener más información, consulte the section called “Conexiones Vertica”.

Almacenamiento de credenciales de conexión en AWS Secrets Manager

Se recomienda utilizar AWS Secrets Manager para suministrar las credenciales de conexión del almacén de datos. Si se utiliza Secrets Manager de esta manera, se permite que AWS Glue acceda al secreto en el tiempo de ejecución para los trabajos de ETL y las ejecuciones de rastreadores, y ayuda a proteger las credenciales.

Requisitos previos

Para utilizar Secrets Manager con AWS Glue, se debe conceder al rol de IAM de AWS Glue permiso para recuperar valores de secretos. La política `AWSGlueServiceRole`, administrada por AWS, no incluye permisos de AWS Secrets Manager. Para ver ejemplos de políticas de IAM, consulte Ejemplo: Permiso para recuperar valores de secretos en la Guía del usuario de AWS Secrets Manager.

En función de la configuración de la red, es posible que también tenga que crear un punto de conexión de VPC para establecer una conexión privada entre la VPC y Secrets Manager. Para obtener más información, consulte Uso de un punto de conexión de VPC de AWS Secrets Manager.

Para crear un secreto para AWS Glue

1. Siga las instrucciones de Creación y administración de secretos de la Guía del usuario de AWS Secrets Manager. El siguiente ejemplo de JSON muestra cómo especificar las credenciales en la pestaña Plaintext (Texto sin formato) cuando se crea un secreto para AWS Glue.

   ```
   {
     "username": "EXAMPLE-USERNAME",
     "password": "EXAMPLE-PASSWORD"
   }
   ```

2. Asocie un secreto a una conexión mediante la interfaz de AWS Glue Studio. Para obtener instrucciones detalladas, consulte Creación de conexiones para conectores en la Guía del usuario de AWS Glue Studio.

Adición de una conexión de AWS Glue

Puede conectar a orígenes de datos en AWS Glue de Spark mediante programación. Para obtener más información, consulte Tipos de conexión y opciones para ETL en AWS Glue para Spark

Puede usar la consola de AWS Glue para agregar, editar, eliminar y probar conexiones. Para obtener más información acerca de las conexiones a AWS Glue, consulte Conexión a datos.

Temas

- Conexión a Adobe Analytics
- Conexión a Adobe Marketo Engage
- Conexión a Amazon Redshift en AWS Glue Studio
- Conexión a Asana
- Conexión a Azure Cosmos DB en AWS Glue Studio
- Conexión a Azure SQL en AWS Glue Studio
- Conexión a Blackbaud Raiser's Edge NXT
- Conexión a CircleCI
- Conexión a Datadog
- Conexión a Docusign Monitor
- Conexión a Domo
- Conexión a Dynatrace
- Conexión a Anuncios de Facebook
- Conexión a Facebook Page Insights
- Conexión a Freshdesk
- Conexión a Freshsales
- Conexión a Google Ads
- Conexión a Google Analytics 4
- Conexión a Google BigQuery en AWS Glue Studio
- Conexión a Google Search Console
- Conexión a Google Sheets
- Conexión a HubSpot
- Conexión a Anuncios de Instagram
- Conexión a Intercom en AWS Glue Studio
- Conexión a Jira Cloud
- Conexión a Kustomer

- Conexión a LinkedIn
- Conexión a Mailchimp
- Conexión con Microsoft Dynamics 365 CRM
- Conexión a Microsoft Teams
- Conexión a Mixpanel
- Conexión a Monday
- Conexión a MongoDB en AWS Glue Studio
- Conexión a Oracle NetSuite
- Conexión al servicio OpenSearch en AWS Glue Studio
- Conexión a Okta
- Conexión a PayPal
- Conexión a Pendo
- Conexión a Pipedrive
- Conexión a Productboard
- Conexión a QuickBooks
- Conexión a Salesforce
- Conexión a Salesforce Marketing Cloud
- Conexión a Salesforce Commerce Cloud
- Conexión a Salesforce Marketing Cloud Account Engagement
- Conexión a SAP HANA en AWS Glue Studio
- Conexión a SAP OData
- Conexión a SendGrid
- Conexión a ServiceNow
- Conexión a Slack en AWS Glue Studio
- Conexión a Smartsheet
- Conexión a Snapchat Ads en AWS Glue Studio
- Conectarse a Snowflake en AWS Glue Studio
- Conexión a Stripe en AWS Glue Studio
- Conexión a Teradata Vantage en AWS Glue Studio
- Conexión a Twilio

- Conexión a Vertica en AWS Glue Studio
- Conexión a WooCommerce
- Conexión a Zendesk
- Conexión a Zoho CRM
- Conexión a Zoom Meetings
- Agregar una conexión JDBC con sus propios controladores JDBC

Conexión a Adobe Analytics

Adobe Analytics es una plataforma de análisis de datos sólida que recopila datos de experiencias digitales en múltiples canales que respaldan el recorrido del cliente a la vez que proporciona herramientas para analizar los datos. Se trata de una plataforma utilizada habitualmente por profesionales del marketing y analistas de negocio para realizar análisis empresariales. Si es usuario de Adobe Analytics, puede conectar AWS Glue a la cuenta de Adobe Analytics. A continuación, puede utilizar Adobe Analytics como origen de datos en los trabajos de ETL. Ejecute estos trabajos para transferir datos entre Adobe Analytics y los servicios de AWS u otras aplicaciones compatibles.

Temas

- Compatibilidad de AWS Glue con Adobe Analytics
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de Adobe Analytics
- Configuración de las conexiones a Adobe Analytics
- Cómo leer de entidades de Adobe Analytics
- Opciones de conexión de Adobe Analytics
- Creación de una cuenta de Adobe Analytics
- Limitaciones

Compatibilidad de AWS Glue con Adobe Analytics

AWS Glue admite Adobe Analytics de la siguiente manera:

¿Es compatible como origen?

Sí. Puede usar los trabajos de ETL de AWS Glue para consultar datos de Adobe Analytics.

¿Es compatible como destino?

No.

Versiones de la API de Adobe Analytics compatibles

v2.0

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si no desea utilizar el método anterior, como alternativa, utilice las siguientes políticas de IAM administradas:

- AWSGlueServiceRole: concede acceso a los recursos que necesitan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.

- AWSGlueConsoleFullAccess: concede acceso completo a los recursos de AWS Gluecuando una identidad a la que está vinculada la política utiliza la Consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de Adobe Analytics

Antes de poder utilizar AWS Glue para transferir desde Adobe Analytics, deberá cumplir los siguientes requisitos:

Requisitos mínimos

- Tener una cuenta de Adobe Analytics con correo electrónico y contraseña. Para obtener más información sobre cómo crear una cuenta, consulte Creación de una cuenta de Adobe Analytics.
- La cuenta de Adobe Analytics debe estar habilitada para el acceso de API. El acceso de API está habilitado de forma predeterminada para las ediciones Select, Prime y Ultimate.

Si cumple estos requisitos, estará listo para conectar AWS Glue a la cuenta de Adobe Analytics. Para conexiones típicas, no necesita hacer nada más en Adobe Analytics.

Configuración de las conexiones a Adobe Analytics

Adobe Analytics admite el tipo de concesión `AUTHORIZATION_CODE` para `OAuth2`.

Este tipo de concesión se considera un `OAuth` “de tres vías”, ya que se basa en redirigir a los usuarios al servidor de autorización externo para autenticar al usuario. Los usuarios aún pueden optar por crear una aplicación conectada propia en Adobe Analytics y proporcionar un ID y secreto de cliente propios al crear conexiones a través de la consola de AWS Glue. En este escenario, aún se abrirá Adobe Analytics para iniciar sesión y autorizar a AWS Glue para que acceda a sus recursos.

Este tipo de concesión da como resultado un token de actualización y un token de acceso. El token de acceso es de corta duración y se puede actualizar automáticamente sin la interacción del usuario mediante el token de actualización.

Para obtener documentación pública de Adobe Analytics sobre la creación de una aplicación conectada para el flujo AUTHORIZATION_CODE OAuth, consulte API de Adobe Analytics.

Para configurar una conexión a Adobe Analytics:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles:

   En el caso de una aplicación conectada administrada por el cliente, el secreto debe contener el secreto del consumidor de la aplicación conectada con la clave `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET`.

   > **Note**
   >
   > Es imprescindible crear un secreto por conexión en AWS Glue.

2. En AWS Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:

   a. Al seleccionar un Tipo de conexión, elija Adobe Analytics.

   b. Proporcione la `x_api_key, instanceUrl` de Adobe Analytics a la que se desea conectar.

   c. Seleccione el rol de IAM que AWS Glue puede asumir y que cuente con los permisos necesarios para realizar las siguientes acciones:

   JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

   d. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.

e. Seleccione las opciones de red si quiere usar su red.

3. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.

Cómo leer de entidades de Adobe Analytics

Requisitos previos

Un objeto de Adobe Analytics del que desea leer. Consulte la tabla de entidades compatibles que aparece a continuación para comprobar las entidades disponibles.

Entidades compatibles

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite Partición
Anotación	Sí	Sí	Sí	Sí	No
Métricas calculadas	Sí	Sí	Sí	Sí	No
Función de métricas calculadas	Sí	No	No	Sí	No
Metadatos compartidos de componentes	Sí	Sí	No	Sí	No
Rangos de fechas	Sí	Sí	No	Sí	No
Dimensiones	Sí	No	No	Sí	No
Métricas	Sí	No	No	Sí	No
Proyectos	Sí	No	No	Sí	No

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite Partición
Elemento principal de informes	Sí	Sí	No	Sí	No
Segmentos	Sí	Sí	Sí	Sí	No
Registros de uso	Sí	Sí	No	Sí	No

Ejemplo

```
adobeAnalytics_read = glueContext.create_dynamic_frame.from_options(
     connection_type="adobeanalytics",
     connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "annotation/ex*****",
        "API_VERSION": "v2.0"
 })
```

Detalles de entidades y campos de Adobe Analytics

- Annotations
- Métricas calculadas
- Metadatos de los componentes
- Rangos de fechas
- Dimensiones
- Métricas
- Proyectos
- Informes
- Segmentos
- Usuarios
- Registros de uso

Opciones de conexión de Adobe Analytics

Las siguientes son opciones de conexión para Adobe Analytics:

- `ENTITY_NAME`(cadena): (obligatorio) se utiliza para leer y escribir. El nombre del objeto en Adobe Analytics.
- `API_VERSION`(cadena): (obligatorio) se utiliza para leer y escribir. Versión de la API de Rest de Adobe Analytics que desea utilizar. Por ejemplo, v2.0.
- `X_API_KEY`(cadena): (obligatorio) se utiliza para leer y escribir. Se necesita para autenticar al desarrollador o a la aplicación que realiza solicitudes a la API.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.

Creación de una cuenta de Adobe Analytics

1. Para registrarse en el programa de intercambio para socios, acceda al Programa para socios de Adobe.
2. Elija Unirse al programa de intercambio.
3. Regístrese o cree una cuenta con su dirección de correo electrónico corporativa.
4. En el buzón de sugerencias, seleccione la empresa adecuada que tenga una suscripción al producto Adobe Analytics.
5. Asegúrese de que la cuenta esté registrada en una organización válida (de la lista disponible) que tenga una suscripción activa a Adobe Analytics.
6. Tras obtener la aprobación por parte de la administración de la empresa, active la cuenta. Para ello, haga clic en el enlace que aparece en el correo electrónico de aprobación.

Cómo verificar si la cuenta creada tiene acceso al servicio Adobe Analytics

1. Inicie sesión en la Consola de administración de Adobe.
2. Verifique el nombre de la organización que aparece en la esquina superior derecha de la página para asegurarse de que ha iniciado sesión en la empresa correcta.

3. Seleccione Productos y compruebe que Adobe Analytics se encuentra disponible.

> **Note**
>
> Si no hay ninguna organización disponible, o el producto Adobe Analytics aparece en gris o no se encuentra disponible, es probable que la cuenta no esté asociada a ninguna organización o que no tenga una suscripción activa a Adobe Analytics. Contacte al administrador del sistema para solicitar acceso a este servicio para la cuenta.

Creación de un proyecto y credenciales de **`OAuth2.0`**

1. Inicie sesión en la cuenta de Adobe Analytics en la que desea que la aplicación OAuth 2.0 se cree.
2. Seleccione Proyecto y, a continuación, Crear un proyecto nuevo.
3. Para agregar un proyecto, seleccione Agregar al proyecto y, a continuación, seleccione API.
4. Seleccione API de Adobe Analytics.
5. Seleccione OAUTH como autenticación de usuario.
6. Seleccione Web como `OAUTH` y proporcione el URI de redireccionamiento.

   Para conocer el URI de redirección y su patrón, consulte lo siguiente:

   - URI de redireccionamiento predeterminado de `OAuth 2.0`: un URI de redireccionamiento predeterminado es la URL de la página a la que Adobe accederá durante el proceso de autenticación. Por ejemplo, `https://ap-southeast-2.console.aws.amazon.com/appflow/oauth`
   - Patrón URI de redireccionamiento de OAuth 2.0: un patrón URI de redireccionamiento es una ruta URI (o una lista de rutas separada por comas) a la que Adobe puede redirigir (si se solicita) cuando se completa el flujo de inicio de sesión. Por ejemplo, `https://ap-southeast-2\\.console\\.aws\\.amazon\\.com`
7. Agregue los siguientes alcances:

   - `openid`
   - `read_organizations`
   - `additional_info.projectedProductContext`
   - `additional_info.job_function`

8. Elija Guardar credencial.
9. Una vez creada la aplicación, copie los valores `Client ID` y `Client Secret` en un archivo de texto.

Limitaciones

A continuación, se indican las limitaciones del conector de Adobe Analytics:

- Adobe Analytics no admite la partición basada en campos ni en registros. No se admite la partición basada en campos, ya que no se pueden consultar los campos particionados. No se admiten las particiones basadas en registros, ya que no existe ninguna disposición para obtener un “desplazamiento” para la paginación.
- En la entidad `Report Top Item`, los parámetros de consulta `startDate` y `endDate` no funcionan como se esperaba. La respuesta no se filtra en función de estos parámetros, lo que provoca problemas con el filtro y el flujo incremental de esta entidad.
- En el caso de las entidades `Annotation`, `Calculated Metrics`, `Calculated Metrics Function`, `Date Ranges`, `Dimension`, `Metric`, `Project`, `Report Top Items` y `Segment`, el parámetro de consulta `locale` especifica el idioma que se debe utilizar para las secciones localizadas de respuestas y no filtra los registros. Por ejemplo, `locale="ja_JP"` mostrará los datos en japonés.
- Entidad `Report Top Item`: el filtro de los campos `dateRange` y `lookupNoneValues` no funciona actualmente.
- Entidad `Segment`: con el valor de filtro `includeType=“templates”`, los filtros de otros campos no funcionan.
- Entidad `Date Range`: el filtro del campo `curatedRsid` no funciona.
- Entidad `Metric entity`: con el filtro de un campo que se puede segmentar con el valor “falso”, se obtienen resultados tanto para el valor verdadero como para el falso.

Conexión a Adobe Marketo Engage

Adobe Marketo Engage es una plataforma de automatización de marketing que permite a los profesionales del marketing administrar programas y campañas multicanal personalizados para clientes y posibles clientes.

Temas

- Compatibilidad de AWS Glue con Adobe Marketo Engage
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de Adobe Marketo Engage
- Configuración de las conexiones a Adobe Marketo Engage
- Lectura desde entidades de Adobe Marketo Engage
- Escritura en entidades de Adobe Marketo Engage
- Opciones de conexión de Adobe Marketo Engage
- Limitaciones y notas para el conector de Adobe Marketo Engage

Compatibilidad de AWS Glue con Adobe Marketo Engage

AWS Glue es compatible con Adobe Marketo Engage de la siguiente manera:

¿Es compatible como origen?

Sí. Puede usar los trabajos de ETL de AWS Glue para consultar datos de Adobe Marketo Engage.

¿Es compatible como destino?

Sí. Puede usar trabajos de ETL de AWS Glue para escribir datos en Adobe Marketo Engage.

Versiones compatibles de la API de Supported Adobe Marketo

Se admiten las siguientes versiones de la API de Adobe Marketo Engage:

- v1

Para conocer la compatibilidad de entidades por versión específica, consulte Entidades admitidas para el origen.

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS IAM necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
```

```
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si no desea utilizar el método anterior, puede utilizar las siguientes políticas de IAM administradas:

- AWSGlueServiceRole: da acceso a recursos que precisan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: otorga acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la Consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de Adobe Marketo Engage

Antes de poder utilizar AWS Glue para transferir datos desde Adobe Marketo Engage, deberá cumplir estos requisitos:

Requisitos mínimos

Los requisitos mínimos son los siguientes:

- Tener una cuenta de Adobe Marketo Engage con credenciales de cliente.

- La cuenta de Adobe Marketo Engage debe disponer de acceso de API con una licencia válida.

Si cumple estos requisitos, estará listo para conectar AWS Glue a la cuenta de Adobe Marketo Engage. Si es una conexión típica, no necesita hacer nada más en Adobe Marketo Engage.

Obtención de las credenciales de OAuth 2.0

Para obtener las credenciales de la API para poder hacer llamadas autenticadas a la instancia, consulte Adobe Marketo Rest API.

Configuración de las conexiones a Adobe Marketo Engage

Adobe Marketo Engage admite el tipo de concesión CLIENT CREDENTIALS para OAuth2.

- Este tipo de concesión se considera OAuth 2.0 de doble vía, ya que lo utilizan los clientes para obtener un código de acceso fuera del contexto de un usuario. AWS Glue puede utilizar el ID de cliente y el secreto de cliente para autenticar las API de Adobe Marketo Engage que proporcionan los servicios personalizados que se definan.
- Cada servicio personalizado pertenece a un usuario exclusivo de la API con un conjunto de roles y permisos que autorizan al servicio a realizar acciones específicas. Un token de acceso está asociado a un único servicio personalizado.
- Este tipo de concesión da lugar a un token de acceso de corta duración, que se puede renovar mediante una llamada a un punto de conexión de identidad.
- Para consultar la documentación pública de Adobe Marketo Engage para OAuth 2.0 con credenciales de cliente, consulte Autenticación en la Guía para desarrolladores de Adobe Marketo Engage.

Para configurar una conexión a Adobe Marketo Engage:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles:
   a. En el caso de las aplicaciones conectadas administradas por el cliente, el secreto debe contener el secreto del consumidor de la aplicación conectada con `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET` como clave.
   b. Nota: Debe crear un secreto por cada conexión en AWS Glue.
2. En AWS Glue Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:

a. Al seleccionar un Tipo de conexión, elija Adobe Marketo Engage.

b. Proporcione la `INSTANCE_URL` de la instancia de Adobe Marketo Engage a la que se quiere conectar.

c. Seleccione el rol de AWS IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

d. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.

e. Seleccione las opciones de red si quiere usar su red.

3. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.

Lectura desde entidades de Adobe Marketo Engage

Requisito previo

Un objeto de Adobe Marketo Engage desde el que le gustaría leer. Necesitará el nombre del objeto, como clientes potenciales, actividades u objetos personalizados. En las siguientes tablas se muestran las entidades admitidas.

Entidades compatibles con el origen (síncronas):

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
leads	Sí	Sí	No	Sí	No
actividades	Sí	Sí	No	Sí	No
customobjects	Sí	Sí	No	Sí	No

Entidades compatibles con el origen (asíncronas):

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
leads	Sí	No	No	Sí	Sí
actividades	Sí	No	No	Sí	No
customobjects	Sí	No	No	Sí	Sí

Ejemplo:

```
adobe-marketo-engage_read = glueContext.create_dynamic_frame.from_options(
    connection_type="adobe-marketo-engage",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "leads",
        "API_VERSION": "v2",
        "INSTANCE_URL": "https://539-t**-6**.mktorest.com"
    }
```

Detalles de la entidad y el campo de Adobe Marketo Engage:

Entidades con metadatos estáticos:

Entidad	Campo	Tipo de datos:	Operadores admitidos
actividades	sinceDatetime (solo se admite en modo síncrono)	DateTime	>= (solo para el modo síncrono)
	createdAt (solo se admite en modo asíncrono)	DateTime	between (solo para el modo asíncrono)
	activitiesTypeId	Entero	=
	adobe-marketo-engageGUID	Largo	= (solo para el modo síncrono)
	leadId	Largo	N/A
	activityDate	DateTime	N/A
	campaignId	Largo	N/A
	primaryAttributeValueId	Entero	N/A
	primaryAttributeValue	Cadena	N/A
	atributos	Cadena	N/A

Entidades con metadatos dinámicos:

Para las siguientes entidades, Adobe Marketo Engage proporciona puntos de conexión para obtener los metadatos de forma dinámica, de modo que la compatibilidad del operador se capture en el nivel del tipo de datos de cada entidad.

Entidad	Tipo de datos:	Operadores admitidos
leads	Entero	= (solo para el modo síncrono)

Entidad	Tipo de datos:	Operadores admitidos
	DateTime	between (solo para el modo asíncrono)
	Cadena	= (solo para el modo síncrono)
	Largo	N/A
	Booleano	N/A
	Date	N/A
	Flotante	N/A
customobjects	Entero	N/A
	DateTime	between (solo para el modo asíncrono)
	Cadena	= (solo para el modo síncrono)
	Date	N/A
	Largo	N/A
	Booleano	N/A
	Flotante	N/A

Consultas de particionamiento

Puede proporcionar las opciones adicionales de Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` y `NUM_PARTITIONS` si quiere utilizar la simultaneidad en Spark. Con estos parámetros, la consulta original se dividiría en un número `NUM_PARTITIONS` de subconsultas que las tareas de Spark pueden ejecutar simultáneamente.

- `PARTITION_FIELD`: el nombre del campo que se utilizará para particionar la consulta.
- `LOWER_BOUND`: un valor de límite inferior inclusivo del campo de partición elegido.

Para el campo DateTime, aceptamos el valor en formato ISO.

Ejemplo de valor válido:

```
"2024-07-01T00:00:00.000Z"
```

- UPPER_BOUND: un valor límite superior exclusivo del campo de partición elegido.
- NUM_PARTITIONS: el número de particiones.

En la tabla siguiente, se describen los detalles de compatibilidad de campos de particiones de entidades:

Nombre de la entidad	Campos de partición	Tipo de datos:
leads	createdAt	DateTime
	updateAt	DateTime
customobjects	updatedAt	DateTime

Ejemplo:

```
adobe-marketo-engage_read = glueContext.create_dynamic_frame.from_options(
    connection_type="adobe-marketo-engage",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "leads",
        "API_VERSION": "v1",
        "PARTITION_FIELD": "createdAt"
        "LOWER_BOUND": "2024-07-01T00:00:00.000Z"
        "UPPER_BOUND": "2024-07-02T00:00:00.000Z"
        "NUM_PARTITIONS": "10"
    }
```

Escritura en entidades de Adobe Marketo Engage

Requisitos previos

- Un objeto de Adobe Marketo en el que desea escribir. Necesitará el nombre del objeto, como `leads` o `customobjects`.
- El conector de Adobe Marketo admite tres operaciones de escritura:
  - INSERT
  - UPSERT
  - UPDATE
- Para las operaciones de escritura `UPSERT` y `UPDATE`, debe proporcionar la opción `ID_FIELD_NAMES` para especificar el campo de ID para los registros. Cuando trabaje con la entidad `leads`, utilice `email` como `ID_FIELD_NAMES` para las operaciones `UPSERT` y `id` para las operaciones `UPDATE`. Para la entidad `customobjects`, utilice `marketoGUID` como `ID_FIELD_NAMES` tanto para las operaciones `UPDATE` como `UPSERT`.

Entidades compatibles para destino (Sincrónico)

Nombre de la entidad	Se admitirá como conector de destino	Se puede insertar	Se puede actualizar	Se puede actualizar o insertar
leads	Sí	Sí (masivo)	Sí (masivo)	Sí (masivo)
customobjects	Sí	Sí (masivo)	Sí (masivo)	Sí (masivo)

Ejemplo:

Operación INSERT:

```
marketo_write = glueContext.write_dynamic_frame.from_options(
    frame=frameToWrite,
    connection_type="marketo",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "leads",
        "API_VERSION": "v1",
        "WRITE_OPERATION": "INSERT"
    }
```

Operación UPDATE:

```
marketo_write = glueContext.write_dynamic_frame.from_options(
    frame=frameToWrite,
    connection_type="marketo",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "leads",
        "API_VERSION": "v1",
        "WRITE_OPERATION": "UPDATE",
        "ID_FIELD_NAMES": "id"
    }
```

> **Note**
>
> Para las entidades `leads` y `customobjects`, Adobe Marketo proporciona puntos de conexión para recuperar los metadatos de forma dinámica, de modo que los campos modificables se identifiquen en la respuesta de la API de Marketo.

Opciones de conexión de Adobe Marketo Engage

Las siguientes son opciones de conexión para Adobe Marketo Engage:

- `ENTITY_NAME`(cadena): (obligatorio) se usa para lectura. El nombre de su objeto en Adobe Marketo Engage.
- `API_VERSION`(cadena): (obligatorio) se usa para lectura. Versión de la API de Rest de Adobe Marketo Engage que desea utilizar. Por ejemplo: v1.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.
- `PARTITION_FIELD`(cadena): se usa para leer. Campo que se utilizará para particionar la consulta.
- `LOWER_BOUND`(cadena): se usa para leer. Un valor de límite inferior inclusivo del campo de partición elegido.
- `UPPER_BOUND`(cadena): se usa para leer. Un valor límite superior exclusivo del campo de partición elegido.

- `NUM_PARTITIONS`(entero): predeterminado: 1. Se usa para leer. Número de particiones para leer.
- `TRANSFER_MODE`(cadena): Predeterminado: SYNC. Se utiliza para la lectura asíncrona.
- `WRITE_OPERATION`(cadena): predeterminado: INSERT. Se utiliza para escribir. El valor debe ser INSERT, UPDATE, UPSERT.
- `ID_FIELD_NAMES`(cadena): predeterminado: nulo. Necesario para UPDATE y UPSERT.

Limitaciones y notas para el conector de Adobe Marketo Engage

Las siguientes son limitaciones o notas para el conector de Adobe Marketo Engage:

- “sinceDatetime” y “activityTypeId” son parámetros de filtro obligatorios para la entidad de sincronización de actividades.
- A las suscripciones se les asignan 50 000 llamadas a la API al día (que se restablecen diariamente a las 12:00 h CST). Se puede adquirir capacidad diaria adicional como parte de una suscripción a Adobe Marketo Engage. Como referencia, consulte la Adobe Marketo Rest API.
- El intervalo de tiempo máximo para el filtro de intervalo de fechas (`createdAt` o `updatedAt`) es de 31 días. Como referencia, consulte Bulk Extract - Marketo Developers.
- A las suscripciones se les asigna un máximo de 10 trabajos de extracción masiva en la cola en un momento dado. Como referencia, consulte Bulk Extract - Marketo Developers.
- De forma predeterminada, los trabajos de extracción están limitados a 500 MB por día (que se restablece diariamente a las 12:00 h CST). Se puede adquirir capacidad diaria adicional como parte de una suscripción a Adobe Marketo Engage. Como referencia, consulte Bulk Extract - Marketo Developers.
- La cantidad máxima de trabajos de exportación simultáneos es de 2. Como referencia, consulte Bulk Extract - Marketo Developers.
- La cantidad máxima de trabajos de exportación en cola (incluidos los trabajos que se exportan actualmente) es de 10. Como referencia, consulte Bulk Extract - Marketo Developers.
- El tamaño máximo de archivo permitido es de 1 GB para extraer de un trabajo masivo.
- Una vez creado un trabajo asíncrono, el periodo de retención del archivo será de 7 días antes de expirar. Como referencia, consulte Bulk Extract - Marketo Developers.
- `createdAt` o `updatedAt` son parámetros de filtro obligatorios para la entidad Async Leads.
- En la entidad Async Activities, `createdAt` es un parámetro de filtro obligatorio.
- En la entidad Async Custom Object, `updatedAt` es un parámetro de filtro obligatorio.

- Al usar conectores de Saas AWS Glue, los usuarios no pueden identificar qué registros específicos fallaron durante una operación de escritura en las plataformas SaaS de destino en caso de fallos parciales.
- Al utilizar operaciones de escritura sincrónica, todos los campos con valores nulos en el archivo de entrada se eliminarán de forma automática y no se enviarán a la plataforma SaaS.
- Puede crear o actualizar hasta 300 registros en un lote para la escritura sincrónica.

Para obtener más información, consulte Prácticas recomendadas de integración de Adobe Marketo Engage y Extracción masiva.

Conexión a Amazon Redshift en AWS Glue Studio

> **Note**
>
> Puede usar AWS Glue de Spark para leer y escribir en tablas en bases de datos de Amazon Redshift fuera de AWS Glue Studio. Para configurar Amazon Redshift con trabajos de AWS Glue mediante programación, consulte Conexiones Redshift.

AWS Glue proporciona soporte integrado para Amazon Redshift. AWS Glue Studio proporciona una interfaz visual para conectarse a Amazon Redshift, crear trabajos de integración de datos y ejecutarlos en el tiempo de ejecución de Spark sin servidor de AWS Glue Studio.

Temas

- Creación de una conexión de Amazon Redshift
- Crear un nodo de origen de Amazon Redshift
- Crear un nodo de destino de Amazon Redshift
- Opciones avanzadas

Creación de una conexión de Amazon Redshift

Permisos necesarios

Se necesitan permisos adicionales para usar clústeres de Amazon Redshift y entornos de Amazon Redshift sin servidor. Para obtener más información sobre cómo agregar permisos a los trabajos de ETL, consulte Revisar los permisos de IAM necesarios para los trabajos de ETL.

- redshift:DescribeClusters
- redshift-serverless:ListWorkgroups
- redshift-serverless:ListNamespaces

Descripción general

Al agregar una conexión en Amazon Redshift, puede elegir una conexión de Amazon Redshift existente o crear una nueva al agregar un origen de datos (nodo Redshift en AWS Glue Studio).

AWS Glue es compatible tanto con clústeres de Amazon Redshift como con entornos de Amazon Redshift sin servidor. Al crear una conexión, los entornos de Amazon Redshift sin servidor muestran la etiqueta sin servidor junto a la opción de conexión.

Para obtener más información sobre cómo crear una conexión de Amazon Redshift, consulte Mover datos desde y hacia Amazon Redshift.

Crear un nodo de origen de Amazon Redshift

Permisos necesarios

los trabajos de AWS Glue Studio que utilizan orígenes de datos de Amazon Redshift requieren permisos adicionales. Para obtener más información sobre cómo agregar permisos a los trabajos de ETL, consulte Revisar los permisos de IAM necesarios para los trabajos de ETL.

Se necesitan los siguientes permisos para utilizar una conexión de Amazon Redshift.

- redshift-data:ListSchemas
- redshift-data:ListTables
- redshift-data:DescribeTable
- redshift-data:ExecuteStatement
- redshift-data:DescribeStatement
- redshift-data:GetStatementResult

Agregar un origen de datos de Amazon Redshift

Para agregar un nodo de Origen de datos: Amazon Redshift:

1. Elija el tipo de acceso a Amazon Redshift:

- Conexión de datos directa (recomendada): elija esta opción si desea acceder a sus datos de Amazon Redshift directamente. Esta es la opción recomendada y también la predeterminada.
- Data Catalog tables— Elija esta opción si hay tablas del catálogo de datos que desee utilizar.

2. Si elige Conexión de datos directa, elija la conexión para el origen de datos de Amazon Redshift. Esto supone que la conexión ya existe y que puede seleccionar entre las conexiones existentes. Si necesita crear una conexión, elija Crear conexión de Redshift. Para más información, consulte Información general sobre el uso de conectores y conexiones.

   Una vez que haya elegido una conexión, puede ver las propiedades de la conexión mediante un clic en Ver propiedades. La información sobre la conexión está visible, como la URL, los grupos de seguridad, la subred, la zona de disponibilidad, la descripción y las marcas horarias creadas (UTC) y actualizadas por última vez (UTC).

3. Elija una opción de origen de Amazon Redshift:

   - Elija una sola tabla: esta es la tabla que contiene los datos a los que desea acceder desde una sola tabla de Amazon Redshift.
   - Ingresar una consulta personalizada: permite acceder a un conjunto de datos de varias tablas de Amazon Redshift en función del consulta personalizada.

4. Si eligió una sola tabla, elija el esquema de Amazon Redshift. La lista de esquemas disponibles para elegir se determina por la tabla seleccionada.

   O bien, elija Ingresar consulta personalizada. Elija esta opción para acceder a un conjunto de datos personalizado desde varias tablas de Amazon Redshift. Al elegir esta opción, ingrese la consulta de Amazon Redshift.

   Al conectarse a un entorno de Amazon Redshift sin servidor, agregue el siguiente permiso a la consulta personalizada:

   ```
   GRANT SELECT ON ALL TABLES IN <schema> TO PUBLIC
   ```

   Puede elegir Deducir el esquema para leer el esquema en función de la consulta que haya introducido. También puede elegir el editor de consultas Open Redshift para ingresar una consulta de Amazon Redshift. Para obtener más información, vea Consulta de una base de datos mediante el editor de consultas.

5. En Rendimiento y seguridad, elija el directorio provisional de Amazon S3 y el rol de IAM.
   - Directorio de almacenamiento provisional de Amazon S3: elija la ubicación de Amazon S3 para almacenar los datos temporalmente.
   - Rol de IAM: elija la función de IAM que pueda escribir en la ubicación de Amazon S3 que haya seleccionado.
6. En Parámetros de Redshift personalizados (opcional), ingrese el parámetro y el valor.

Crear un nodo de destino de Amazon Redshift

Permisos necesarios

los trabajos de AWS Glue Studio que utilizan los destinos de datos de Amazon Redshift requieren permisos adicionales. Para obtener más información sobre cómo agregar permisos a los trabajos de ETL, consulte Revisar los permisos de IAM necesarios para los trabajos de ETL.

Se necesitan los siguientes permisos para utilizar una conexión de Amazon Redshift.

- redshift-data:ListSchemas
- redshift-data:ListTables

Agregar un nodo de destino de Amazon Redshift

Para crear de un nodo de destino de Amazon Redshift:

1. Elija una tabla Amazon Redshift existente como destino o ingrese un nombre de tabla nuevo.
2. Al utilizar el nodo destino de datos: Redshift, puede elegir entre las siguientes opciones:
   - APPEND: si ya existe una tabla, coloque todos los datos nuevos en la tabla como un inserto. Si la tabla no existe, créela y, a continuación, inserte todos los datos nuevos.

     Además, seleccione la casilla si desea actualizar (UPSERT) los registros existentes en la tabla de destino. La tabla debe existir primero; de lo contrario, la operación fallará.
   - MERGE: AWS Glue actualizará o anexará datos a la tabla de destino en función de las condiciones que especifique.

> **Note**
>
> Para utilizar la acción de combinación en AWS Glue, debe activar la función de combinación de Amazon Redshift. Para obtener instrucciones sobre cómo habilitar la combinación en una instancia de Amazon Redshift, consulte MERGE (vista previa).

Elija opciones:

- Elegir claves y acciones sencillas: elija las columnas que se usarán como claves de coincidencia entre los orígenes de datos y el conjunto de destinos de datos.

  Especifique las siguientes opciones cuando coincidan:

  - Actualice el registro del conjunto de datos de destino con los datos de origen.
  - Elimine el registro del conjunto de datos de destino.

  Especifique las siguientes opciones cuando no coincidan:

  - Inserte los datos de origen como una nueva fila en el conjunto de datos de destino.
  - No hacer nada.
- Ingrese una instrucción MERGE personalizada: a continuación, puede elegir Validar la instrucción MERGE para comprobar si la instrucción es válida o no.

- TRUNCATE: si ya existe una tabla, trunque los datos de la tabla al borrar primero el contenido de la tabla de destino. Si el truncado se realiza correctamente, inserte todos los datos. Si la tabla no existe, créela y, a continuación, inserte todos los datos. Si el truncado no es exitoso, la operación producirá un error.
- DROP: si una tabla ya existe, elimine los metadatos y los datos de la tabla. Si el borrado se realiza correctamente, inserte todos los datos. Si la tabla no existe, créela y, a continuación, inserte todos los datos. Si el descarte no es exitoso, la operación producirá un error.
- CREATE: cree una tabla nueva con el nombre predeterminado. Si el nombre de la tabla ya existe, cree una nueva tabla con un sufijo de nombre `job_datetime` en el nombre para que sea único. Esto insertará todos los datos en la nueva tabla. Si la tabla existe, el nombre final de la tabla tendrá el sufijo adjunto. Si la tabla no existe, se creará una tabla. En cualquier caso, se creará una tabla nueva.

Opciones avanzadas

Consulte Uso del conector Spark de Amazon Redshift en AWS Glue.

Conexión a Asana

Asana es una solución de colaboración en equipo basada en la nube que ayuda a los equipos a organizar, planificar y completar tareas y proyectos. Si es usuario de Asana, la cuenta contiene datos sobre los espacios de trabajo, los proyectos, las tareas, los equipos y mucho más. Puedes transferir datos desde Asana a ciertos servicios de AWS u otras aplicaciones compatibles.

Temas

- Compatibilidad de AWS Glue con Asana
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de Asana
- Configuración de conexiones a Asana
- Cómo leer de las entidades de Asana
- Opciones de conexión a Asana
- Cómo crear una cuenta de Asana
- Limitaciones

Compatibilidad de AWS Glue con Asana

AWS Glue es compatible con Asana de la siguiente manera:

¿Es compatible como origen?

Sí. Puede usar los trabajos de ETL de AWS Glue para consultar datos de Asana.

¿Es compatible como destino?

No.

Versiones de la API de Asana compatibles

1.0

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si no desea utilizar el método anterior, como alternativa, utilice las siguientes políticas de IAM administradas:

- AWSGlueServiceRole: concede acceso a los recursos que necesitan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: concede acceso completo a los recursos de AWS Gluecuando una identidad a la que está vinculada la política utiliza la Consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de Asana

Antes de poder utilizar AWS Glue para transferir desde Asana, deberá cumplir los siguientes requisitos:

Requisitos mínimos

- Tener una cuenta de Asana con correo electrónico y contraseña. Para obtener más información sobre cómo crear una cuenta, consulte Creación de una cuenta de Asana.
- Debe tener una cuenta de AWS creada con el servicio de acceso a AWS Glue.
- Asegúrese de haber creado uno de los siguientes recursos en la cuenta de Asana:
  - Una aplicación para desarrolladores que admite la autenticación de `OAuth 2.0`. Para obtener más instrucciones, consulte OAuth en la Documentación para desarrolladores de Asana. Para otras opciones, consulte the section called “Cómo crear una cuenta de Asana”.
  - Un token de acceso personal. Para obtener más información, consulte el token de acceso personal https://developers.asana.com/docs/personal-access-token en la documentación para desarrolladores de Asana.

Si cumple estos requisitos, estará listo para conectar AWS Glue a la cuenta de Adobe Analytics. Para conexiones típicas, no necesita hacer nada más en Adobe Analytics.

Configuración de conexiones a Asana

Asana admite el tipo de concesión `AUTHORIZATION_CODE` para `OAuth2`.

Este tipo de concesión se considera un `OAuth` “de tres vías”, ya que se basa en redirigir a los usuarios al servidor de autorización externo para autenticar al usuario. Los usuarios aún pueden optar por crear una aplicación conectada propia en Asana y proporcionar un ID y secreto de cliente propios al crear conexiones a través de la consola de AWS Glue. En este escenario, aún se abrirá Asana para iniciar sesión y autorizar a AWS Glue para que acceda a sus recursos.

Este tipo de concesión da como resultado un token de actualización y un token de acceso. El token de acceso es de corta duración y se puede actualizar automáticamente sin la interacción del usuario mediante el token de actualización.

Para consultar la documentación pública de Asana sobre la creación de una aplicación conectada para el flujo `AUTHORIZATION_CODE OAuth`, consulte las API de Asana.

Para configurar una conexión a Asana:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles:
   - En el caso de una aplicación conectada administrada por el cliente, el secreto debe contener el secreto del consumidor de la aplicación conectada con la clave `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET`.
   -
     > **Note**
     >
     > Debe crear un secreto para la conexión en AWS Glue.
2. En AWS Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:
   a. Al seleccionar un Tipo de conexión, seleccione Asana.
   b. Proporcione el entorno de Asana.
   c. Seleccione el rol de IAM que AWS Glue puede asumir y que cuente con los permisos necesarios para realizar las siguientes acciones:

      JSON

      ```
      {
        "Version":"2012-10-17",
        "Statement": [
          {
            "Effect": "Allow",
            "Action": [
              "secretsmanager:DescribeSecret",
              "secretsmanager:GetSecretValue",
              "secretsmanager:PutSecretValue",
              "ec2:CreateNetworkInterface",
              "ec2:DescribeNetworkInterfaces",
              "ec2:DeleteNetworkInterface"
            ],
            "Resource": "*"
          }
        ]
      }
      ```

   d. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.
   e. Seleccione las opciones de red si quiere usar su red.
3. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.

Cómo leer de las entidades de Asana

Requisitos previos

Un objeto de Asana del que le gustaría leer. Consulte la tabla de entidades compatibles que aparece a continuación para comprobar las entidades disponibles.

Entidades admitidas para el origen

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite Partición
Espacio de trabajo	No	Sí	No	Sí	No
Etiqueta	No	Sí	No	Sí	No
Usuario	No	Sí	No	Sí	No
Portafolio	No	Sí	No	Sí	No
Equipo	No	Sí	No	Sí	No
Proyecto	Sí	Sí	No	Sí	No
Sección	No	Sí	No	Sí	No
Tarea	Sí	No	No	Sí	Sí
Objetivo	Sí	Sí	No	Sí	No
AuditLogEvent	Sí	Sí	No	Sí	No
Actualización de estado	Sí	Sí	No	Sí	No
Campo personalizado	No	Sí	No	Sí	No

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite Partición
Breve descripción del proyecto	Sí	No	No	Sí	Sí

Ejemplo

```
read_read = glueContext.create_dynamic_frame.from_options(
    connection_type="Asana",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "task/workspace:xxxx",
        "API_VERSION": "1.0",
        "PARTITION_FIELD": "created_at",
        "LOWER_BOUND": "2024-02-05T14:09:30.115Z",
        "UPPER_BOUND": "2024-06-07T13:30:00.134Z",
        "NUM_PARTITIONS": "3"
    }
```

Detalles de entidades y campos de Asana

- Espacio de trabajo
- Etiqueta
- Servicio
- Portafolio
- Equipo
- Proyecto
- Sección
- Tarea
- Objetivo
- AuditLogEvent
- Actualización de estado
- Campo personalizado

- Breve descripción del proyecto

Consultas de partición

Puede proporcionar las opciones adicionales de Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` y `NUM_PARTITIONS` si quiere usar la simultaneidad en Spark. Con estos parámetros, la consulta original se dividiría en un número `NUM_PARTITIONS` de subconsultas que las tareas de Spark pueden ejecutar simultáneamente.

- `PARTITION_FIELD`: el nombre del campo que se usará para particionar la consulta.
- `LOWER_BOUND`: un valor de límite inferior inclusivo del campo de partición elegido.

  Para la fecha, aceptamos el formato de fecha de Spark que se usa en las consultas de Spark SQL. Ejemplos de valores válidos: `2024-06-07T13:30:00.134Z`.
- `UPPER_BOUND`: un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`: el número de particiones.

Los detalles de compatibilidad del campo de partición por entidad se capturaron en la siguiente tabla.

Nombre de la entidad	Campo de partición	Tipo de datos
Tarea	created_at	DateTime
Tarea	modified_at	DateTime

Ejemplo

```
read_read = glueContext.create_dynamic_frame.from_options(
    connection_type="Asana",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "task/workspace:xxxx",
        "API_VERSION": "1.0",
        "PARTITION_FIELD": "created_at",
        "LOWER_BOUND": "2024-02-05T14:09:30.115Z",
        "UPPER_BOUND": "2024-06-07T13:30:00.134Z",
        "NUM_PARTITIONS": "3"
    }
```

Opciones de conexión a Asana

Las siguientes son opciones de conexión para Asana:

- `ENTITY_NAME`(cadena): (obligatorio) se utiliza para leer y escribir. El nombre del objeto en Asana.
- `API_VERSION`(cadena): (obligatorio) se utiliza para leer y escribir. Versión de la API de REST de Asana que desea usar. Por ejemplo: 1.0.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.
- `PARTITION_FIELD`(cadena): se usa para leer. Campo que se utilizará para particionar la consulta.
- `LOWER_BOUND`(cadena): se usa para leer. Un valor de límite inferior inclusivo del campo de partición elegido.
- `UPPER_BOUND`(cadena): se usa para leer. Un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`(entero): predeterminado: 1. Se usa para leer. Número de particiones para leer.

Cómo crear una cuenta de Asana

1. Regístrese para obtener una cuenta de Asana y elija Registrarse.
2. Tras iniciar sesión, pasará a la página Configuración de la cuenta. Realice los siguientes pasos:
   - Revise el formulario de configuración de cuenta.
   - Complete todos los detalles relevantes para crear la cuenta de Asana.
   - Verifique la exactitud de la información.
3. Elija Crear cuenta o Enviar (el texto exacto del botón puede variar) para finalizar la configuración de la cuenta.

Cómo crear la aplicación en Asana para **`OAuth2.0`**

1. Inicie sesión en la cuenta de Asana con sus credenciales de cliente de Asana.
2. Elija el icono del perfil de usuario en la esquina superior derecha y seleccione Mi configuración en el menú desplegable.

3. Seleccione la pestaña Aplicaciones y, a continuación, seleccione Administrar aplicaciones de desarrollador.
4. Seleccione Crear nueva aplicación e ingrese los detalles pertinentes.
5. Elija Crear aplicaciones.
6. En la página Mis aplicaciones:

   a. Seleccione OAuth y en la sección Credenciales de la aplicación, anote el ID de cliente y el secreto de cliente.

   b. En la sección URL de redirección, agregue las URL de redirección necesarias.

> **Note**
>
> Introduzca el URI de redirección con el siguiente formato: `https://{aws-region-code}.console.aws.amazon.com/gluestudio/oauth`. Ejemplo: para el Este de EE. UU. (Norte de Virginia), utilice: `https://us-east-1.console.aws.amazon.com/gluestudio/oauth`

Cómo crear la aplicación en Asana para el token de **PAT**

1. Inicie sesión en la cuenta de Asana con sus credenciales de cliente de Asana.
2. Elija el icono del perfil de usuario en la esquina superior derecha y seleccione Configuración de mi perfil en el menú desplegable.
3. Seleccione la pestaña Aplicaciones y, a continuación, Cuentas de servicio.
4. Seleccione Crear nueva aplicación e ingrese los detalles pertinentes.
5. Elija Agregar cuenta de servicio.
6. La siguiente página muestra el token, cópielo y guárdelo de forma segura.

> **Important**
>
> Este token solo aparecerá una vez. Asegúrese de copiarlo y almacenarlo de forma segura.

Limitaciones

Las siguientes son limitaciones para el conector de Asana:

- Las cuentas de servicio de los dominios Enterprise solo pueden acceder a los puntos de conexión de la API del registro de auditoría. Para acceder a estos puntos de conexión es necesario autenticarse con un token de acceso personal de la cuenta de servicio.
- Solo las cuentas de usuario con el plan Premium o uno superior pueden acceder a la entidad Goal.
- `Audit Log Event Entity`: en el conector, los campos `start_at` y `end_at` se combinan en un único campo “start_end_at” para permitir el filtrado y la transferencia incremental.
- No es posible realizar particiones en el campo `Date`, aunque se admiten los operadores “mayor que o igual a” y “menor que o igual a”. Escenario: se creó un trabajo con `partitionField` como `due_on` (tipo de datos: fecha), `lowerBound` como `2019-09-14`, `upperBound` como `2019-09-16` y `numPartition` como 2. La parte del filtro de la URL del punto de conexión se crea de la siguiente manera:
  - partition1: due_on.before=2019-09-14&due_on.after=2019-09-14
  - partition2: due_on.before=2019-09-15&due_on.after=2019-09-15 Salida:
  - En partition1, obtenemos datos con due_date como 14/09/2019 y 15/09/2019
  - En partition2, obtenemos los mismos datos con due_date como 15/09/2019 (que estaba en partition1) junto con otros datos, lo que provoca la duplicación de datos.
- El filtrado y la partición no se admiten en el mismo campo, ya que se produce un error de solicitud incorrecta en la parte de SaaS.
- La entidad Task requiere un mínimo de un campo en los criterios de filtrado. Existe una limitación con Asana por la cual la paginación no se identifica sin ordenar los registros con base en un campo basado en el tiempo. Por lo tanto, el campo Created_at se utiliza junto con la paginación para distinguir el siguiente conjunto de registros. El campo Created_at se marca como obligatorio en el filtro, con un valor predeterminado de 2000-01-01T00:00:00Z si no se proporciona. ara obtener más información sobre la paginación, consulte Tareas en un espacio de trabajo.

Conexión a Azure Cosmos DB en AWS Glue Studio

AWS Glue proporciona soporte integrado para Azure Cosmos DB. AWS Glue Studio proporciona una interfaz visual para conectarse a Azure Cosmos DB for NoSQL, crear trabajos de integración de datos y ejecutarlos en el tiempo de ejecución de Spark sin servidor de AWS Glue Studio.

Temas

- Creación de una conexión a Azure Cosmos DB
- Creación de un nodo de origen de Azure Cosmos DB
- Creación de un nodo de destino de Azure Cosmos DB
- Opciones avanzadas

Creación de una conexión a Azure Cosmos DB

Requisitos previos:

- En Azure, tendrá que identificar o generar una clave de Azure Cosmos DB para que la utilice AWS Glue, `cosmosKey`. Para obtener más información, consulte Acceso seguro a los datos en Azure Cosmos DB en la documentación de Azure.

Para configurar una conexión a Azure Cosmos DB:

1. En AWS Secrets Manager, cree un secreto con su clave de datos de Azure Cosmos DB. Para crear un secreto en Secrets Manager, siga el tutorial disponible en Crear un secreto AWS Secrets Manager en la documentación AWS Secrets Manager. Después de crear el secreto, conserve el nombre secreto, *`secretName`*, para el siguiente paso.
   - Al seleccionar pares clave/valor, genere un par para la clave `spark.cosmos.accountKey` con el valor *`cosmosKey`*.
2. En la consola de AWS Glue, genere una conexión mediante los pasos que se indican en the section called “Adición de una conexión de AWS Glue”. Tras crear la conexión, conserve el nombre de la conexión, *`connectionName`*, para el uso futuro en AWS Glue.
   - Al seleccionar un tipo de conexión, seleccione Azure Cosmos DB.
   - Al seleccionar un secreto AWS, proporcione un *`secretName`*.

Creación de un nodo de origen de Azure Cosmos DB

Requisitos previos necesarios

- Una conexión a AWS Glue Azure Cosmos DB, configurada con un AWS Secrets Manager secreto, tal y como se describe en la sección anterior, the section called “Creación de una conexión a Azure Cosmos DB”.
- Permisos adecuados en el trabajo para leer el secreto utilizado por la conexión.
- Un contenedor de Azure Cosmos DB para NoSQL del que desearía leer. Necesitará la información de identificación del contenedor.

  Un contenedor de Azure Cosmos para NoSQL se identifica por su base de datos y su contenedor. Debe proporcionar los nombres de la base de datos, `cosmosDBName`, y del contenedor, `cosmosContainerName`, al conectarse a la API de Azure Cosmos para NoSQL.

Agregar un origen de datos de Azure Cosmos DB

Para agregar un nodo de Origen de datos - Azure Cosmos DB:

1. Elija la conexión para el origen de datos de Azure Cosmos DB. Dado que lo ha creado, debería estar disponible en el menú desplegable. Si es necesario crear una conexión, elija Crear conexión de Azure Cosmos DB. Para obtener más información, consulte la sección the section called “Creación de una conexión a Azure Cosmos DB” anterior.

   Una vez que haya elegido una conexión, puede ver las propiedades de la conexión mediante un clic en Ver propiedades.
2. Elija el Nombre de la base de datos de Cosmos DB: proporcione el nombre de la base de datos desde la que desea leer, `CosmosDBName`.
3. Elija Azure Cosmos DB Container: proporcione el nombre del contenedor desde el que desea leer, `CosmosContainerName`.
4. Si lo desea, elija Azure Cosmos DB Custom Query: proporcione una consulta SQL SELECT para recuperar información específica de Azure Cosmos DB.
5. En Propiedades personalizadas de Azure Cosmos, ingrese los parámetros y valores según sea necesario.

Creación de un nodo de destino de Azure Cosmos DB

Requisitos previos necesarios

- Una conexión a AWS Glue Azure Cosmos DB, configurada con un AWS Secrets Manager secreto, tal y como se describe en la sección anterior, the section called “Creación de una conexión a Azure Cosmos DB”.
- Permisos adecuados en el trabajo para leer el secreto utilizado por la conexión.
- Una tabla de Azure Cosmos DB a la que desearía escribir. Necesitará la información de identificación del contenedor. Debe crear el contenedor antes de llamar al método de conexión.

  Un contenedor de Azure Cosmos para NoSQL se identifica por su base de datos y su contenedor. Debe proporcionar los nombres de la base de datos, *cosmosDBName*, y del contenedor, *cosmosContainerName*, al conectarse a la API de Azure Cosmos para NoSQL.

Agregar un destino de datos de Azure Cosmos DB

Para agregar un nodo de Destino de datos - Azure Cosmos DB:

1. Elija la conexión para el origen de datos de Azure Cosmos DB. Dado que lo ha creado, debería estar disponible en el menú desplegable. Si es necesario crear una conexión, elija Crear conexión de Azure Cosmos DB. Para obtener más información, consulte la sección the section called “Creación de una conexión a Azure Cosmos DB” anterior.

   Una vez que haya elegido una conexión, puede ver las propiedades de la conexión mediante un clic en Ver propiedades.
2. Elija el Nombre de la base de datos de Cosmos DB: proporcione el nombre de la base de datos desde la que desea leer, *CosmosDBName*.
3. Elija Azure Cosmos DB Container: proporcione el nombre del contenedor desde el que desea leer, *CosmosContainerName*.
4. En Propiedades personalizadas de Azure Cosmos, ingrese los parámetros y valores según sea necesario.

Opciones avanzadas

Puede brindar opciones avanzadas al crear un nodo de Azure Cosmos DB. Estas opciones son las mismas que las disponibles cuando se programa AWS Glue para scripts de Spark.

Consulte the section called “Conexiones de Azure Cosmos DB”.

Conexión a Azure SQL en AWS Glue Studio

AWS Glue proporciona soporte integrado para Azure SQL. AWS Glue Studio proporciona una interfaz visual para conectarse a Azure SQL, crear trabajos de integración de datos y ejecutarlos en el tiempo de ejecución de Spark sin servidor de AWS Glue Studio.

Temas

- Creación de una conexión de Azure SQL
- Creación de un nodo de origen de Azure SQL
- Creación de un nodo de destino de Azure SQL
- Opciones avanzadas

Creación de una conexión de Azure SQL

Para conectarse a Azure SQL desde AWS Glue, tendrá que crear y almacenar sus credenciales de Azure SQL en un AWS Secrets Manager secreto y, a continuación, asociar ese secreto a una conexión AWS Glue de Azure SQL.

Para configurar una conexión a Azure SQL:

1. En AWS Secrets Manager, cree un secreto con sus credenciales de Azure SQL. Para crear un secreto en Secrets Manager, siga el tutorial disponible en Crear un secreto AWS Secrets Manager en la documentación AWS Secrets Manager. Después de crear el secreto, conserve el nombre secreto, *`secretName`*, para el siguiente paso.

   - Al seleccionar pares clave/valor, genere un par para la clave `user` con el valor *`azuresqlUsername`*.
   - Al seleccionar pares clave/valor, genere un par para la clave `password` con el valor *`azuresqlPassword`*.
2. En la consola de AWS Glue, genere una conexión mediante los pasos que se indican en the section called “Adición de una conexión de AWS Glue”. Tras crear la conexión, conserve el nombre de la conexión, *`connectionName`*, para el uso futuro en AWS Glue.

   - Al seleccionar un tipo de conexión, seleccione Azure SQL.
   - Al proporcionar una URL de Azure SQL, proporcione una URL de punto de conexión de JDBC.

La lista de URL debe tener el siguiente formato: `jdbc:sqlserver://databaseServerName:databasePort;databaseName=azuresqlDBnam`

AWS Glue requiere las siguientes propiedades de URL:

- `databaseName`: una base de datos predeterminada en Azure SQL a la que conectarse.

Para obtener más información sobre las direcciones URL de JDBC para instancias administradas de Azure SQL, consulte la documentación de Microsoft.

- Al seleccionar un secreto AWS, proporcione un *secretName*.

Creación de un nodo de origen de Azure SQL

Requisitos previos necesarios

- Una conexión de AWS Glue Azure SQL, configurada con un AWS Secrets Manager secreto, como se describe en la sección anterior, the section called “Creación de una conexión de Azure SQL”.
- Permisos adecuados en el trabajo para leer el secreto utilizado por la conexión.
- Una tabla de Azure SQL de la que quiera leer, *tableName*.

Una tabla de Azure SQL se identifica por su base de datos, esquema y nombre de tabla. Debe proporcionar el nombre de la base de datos y el nombre de la tabla al conectarse a Azure SQL. También debe proporcionar el esquema si no es el predeterminado, "público". La base de datos se proporciona a través de una propiedad URL en *connectionName*, y el nombre de la tabla y el esquema a través de `dbtable`.

Agregar un origen de datos de Azure SQL

Para agregar un nodo de Origen de datos - Azure SQL:

1. Elija la conexión para el origen de datos de Azure SQL. Dado que lo ha creado, debería estar disponible en el menú desplegable. Si es necesario crear una conexión, elija Crear conexión de Azure SQL. Para obtener más información, consulte la sección the section called “Creación de una conexión de Azure SQL” anterior.

   Una vez que haya elegido una conexión, puede ver las propiedades de la conexión mediante un clic en Ver propiedades.
2. Elija una opción de Origen de Azure SQL:

- Elija una sola tabla: acceda a todos los datos de una sola tabla.
- Ingresar una consulta personalizada: permite acceder a un conjunto de datos de varias tablas en función del consulta personalizada.

3. Si eligió una sola tabla, ingrese *tableName*.

   Si eligió Introducir una consulta personalizada, introduzca una consulta SELECT de TransactSQL.

4. En Propiedades personalizadas de Azure SQL, ingrese los parámetros y valores según sea necesario.

Creación de un nodo de destino de Azure SQL

Requisitos previos necesarios

- Una conexión de AWS Glue Azure SQL, configurada con un AWS Secrets Manager secreto, como se describe en la sección anterior, the section called “Creación de una conexión de Azure SQL”.
- Permisos adecuados en el trabajo para leer el secreto utilizado por la conexión.
- Una tabla de Azure SQL a la que desearía escribir, *tableName*.

  Una tabla de Azure SQL se identifica por su base de datos, esquema y nombre de tabla. Debe proporcionar el nombre de la base de datos y el nombre de la tabla al conectarse a Azure SQL. También debe proporcionar el esquema si no es el predeterminado, "público". La base de datos se proporciona a través de una propiedad URL en *connectionName*, y el nombre de la tabla y el esquema a través de `dbtable`.

Agregar un destino de datos de Azure SQL

Para agregar un nodo de Destino de datos - Azure SQL:

1. Elija la conexión para el origen de datos de Azure SQL. Dado que lo ha creado, debería estar disponible en el menú desplegable. Si es necesario crear una conexión, elija Crear conexión de Azure SQL. Para obtener más información, consulte la sección the section called “Creación de una conexión de Azure SQL” anterior.

   Una vez que haya elegido una conexión, puede ver las propiedades de la conexión mediante un clic en Ver propiedades.

2. Configure el nombre de la tabla proporcionando *tableName*.
3. En Propiedades personalizadas de Azure SQL, ingrese los parámetros y valores según sea necesario.

Opciones avanzadas

Puede brindar opciones avanzadas al crear un nodo de Azure SQL. Estas opciones son las mismas que las disponibles cuando se programa AWS Glue para scripts de Spark.

Consulte the section called “Conexiones SQL Azure”.

Conexión a Blackbaud Raiser's Edge NXT

Blackbaud Raiser's Edge NXT es una solución integral de software de recaudación de fondos y administración de donantes basada en la nube y creada específicamente para organizaciones sin fines de lucro y la comunidad de beneficencia social en su conjunto. Este conector se basa en la API SKY de Edge NXT de Blackbaud Raiser y proporciona operaciones que ayudan a administrar las entidades que se encuentran dentro de Edge NXT de Raisers.

Temas

- Compatibilidad de AWS Glue con Blackbaud Raiser's Edge NXT
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de Blackbaud Raiser's Edge NXT
- Configuración de las conexiones a Blackbaud Raiser's Edge NXT
- Lectura de entidades de Blackbaud Raiser's Edge NXT
- Opciones de conexión a Blackbaud Raiser's Edge NX.
- Limitaciones de Blackbaud Raiser's Edge NXT

Compatibilidad de AWS Glue con Blackbaud Raiser's Edge NXT

AWS Glue es compatible con Blackbaud Raiser's Edge NXT de la siguiente manera:

¿Es compatible como origen?

Sí. Puede utilizar los trabajos de ETL de AWS Glue para consultar datos de Blackbaud Raiser's Edge NXT.

¿Es compatible como destino?

No.

Versiones de la API de Blackbaud Raiser's Edge NXT compatibles

Las siguientes versiones de la API de Blackbaud Raiser's Edge NXT son compatibles:

- v1

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS IAM necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si no desea utilizar el método anterior, puede utilizar las siguientes políticas de IAM administradas:

- AWSGlueServiceRole: da acceso a recursos que precisan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.

- AWSGlueConsoleFullAccess: otorga acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la Consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de Blackbaud Raiser's Edge NXT

Antes de poder utilizar AWS Glue para transferir datos desde Blackbaud Raiser's Edge NXTl, deberá cumplir estos requisitos:

Requisitos mínimos

Los requisitos mínimos son los siguientes:

- Tener una cuenta de Blackbaud Raiser's Edge NXT.
- Haber generado un token de acceso en la cuenta de Blackbaud Raiser's Edge NXT con el alcance de lectura/escritura adecuado asignado para acceder a las API. Para obtener más información, consulte Autorización.

Si cumple estos requisitos, estará listo para conectar AWS Glue a la cuenta de Blackbaud Raiser's Edge NXT.

Configuración de las conexiones a Blackbaud Raiser's Edge NXT

Blackbaud Raiser's Edge NXT admite el tipo de concesión AUTHORIZATION_CODE para OAuth 2.

- Este tipo de concesión se considera un OAuth de “tres vías”, ya que se basa en redirigir a los usuarios a un servidor de autorización externo para autenticar al usuario. Se utiliza para crear conexiones a través de la consola de AWS Glue. La consola de AWS Glue redirigirá al usuario a Blackbaud Raiser's Edge NXT, donde deberá iniciar sesión y otorgar a AWS Glue los permisos solicitados para acceder a la instancia de Edge NXT de Blackbaud Raiser.
- Los usuarios pueden optar por crear una aplicación conectada propia en Blackbaud Raiser's Edge NXT y proporcionar un ID de cliente, clave de suscripción y URL de instancia propios al crear conexiones a través de la consola de AWS Glue. En este escenario, aún se abriráBlackbaud Raiser's Edge NXT para iniciar sesión y autorizar a AWS Glue para que acceda a sus recursos.

- Este tipo de concesión da como resultado un token de actualización y un token de acceso. El token de acceso es de corta duración y se puede actualizar automáticamente sin la interacción del usuario mediante el token de actualización.
- Para consultar la documentación pública de Edge NXT de Blackbaud Raiser sobre la creación de una aplicación conectada para el flujo Authorization Code OAuth, consulte Autorización.

Para configurar una conexión a Blackbaud Raiser's Edge NXT:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles:
   a. Para la aplicación conectada administrada por el cliente, el secreto debe contener la clave de la API de la aplicación conectada con *USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET* como clave.
   b. Nota: Debe crear un secreto para las conexiones en AWS Glue.

1. En AWS Glue Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:
   a. Al seleccionar un origen de datos, seleccione Blackbaud Raiser's Edge NXT.
   b. Proporcione la `INSTANCE_URL` de la cuenta de Blackbaud Raiser's Edge NX a la que se desea conectar.
   c. Proporcione el `clientId` de la aplicación cliente administrada por el usuario.
   d. Proporcione la clave de suscripción asociada a la cuenta.
   e. Seleccione el rol de AWS IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

      JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
```

```
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

f. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.

g. Seleccione las opciones de red si quiere usar su red.

2. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.

Lectura de entidades de Blackbaud Raiser's Edge NXT

Requisito previo

Un objeto de Blackbaud Raiser's Edge NXT desde el que desea leer. Necesitará el nombre del objeto.

Entidades compatibles como origen:

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Dirección del contacto	Sí	Sí	No	Sí	Sí
Educación del contacto	Sí	Sí	No	Sí	Sí
Dirección de correo electrónico del contacto	Sí	Sí	No	Sí	Sí
Teléfono del contacto	Sí	Sí	No	Sí	Sí

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Nota del contacto	Sí	Sí	No	Sí	Sí
Relación del contacto	Sí	Sí	No	Sí	Sí
Presencia en línea del contacto	Sí	Sí	No	Sí	Sí
Oportunidad	Sí	Sí	No	Sí	Sí
Campaña	Sí	Sí	No	Sí	Sí
Campaña	Sí	Sí	No	Sí	Sí
Fondo	Sí	Sí	No	Sí	Sí
Paquete	Sí	Sí	No	Sí	Sí
Lote de donaciones	Sí	Sí	No	Sí	No
Participante del evento	Sí	Sí	Sí	Sí	Sí
Recaudación de fondos para los electores	No	No	No	Sí	No
Donación	Sí	Sí	Sí	Sí	Sí
Pertenencia	Sí	Sí	No	Sí	Sí
Acción	Sí	Sí	No	Sí	No

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Contacto	Sí	Sí	Sí	Sí	Sí
Bienes del contacto	Sí	Sí	No	Sí	Sí
Evento	Sí	Sí	Sí	Sí	Sí
Campo personalizado de donación	Sí	Sí	No	Sí	Sí

Ejemplo:

```
blackbaud_read = glueContext.create_dynamic_frame.from_options(
    connection_type="BLACKBAUD",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "API_VERSION": "v1",
        "SUBSCRIPTION_KEY": <Subscription key associated with one's developer account>
    }
```

Detalles de entidades y campos de Blackbaud Raiser's Edge NXT

Para obtener más información acerca de las entidades y los detalles de los campos, consulte:

- Action
- Contacto
- Dirección del contacto
- Membresía del contacto
- Constituent Fundraiser Assignment
- Educación del contacto
- Dirección de correo electrónico del contacto
- Teléfono del contacto

- Nota del contacto
- Presencia en línea del contacto
- Relación del contacto
- Evento
- Participante del evento
- Campaña
- Campaña
- Fondo
- Package
- Donación
- Campo personalizado de donación
- Lote de donaciones
- Oportunidad
- Códigos del contacto

> **Note**
>
> Los tipos de datos de estructura y enumeración se convierten en cadenas, y los de fecha y hora se convierten en marcas de tiempo en la respuesta de los conectores.

Consultas de partición

Partición basada en campos:

Blackbaud Raiser's Edge NXT no admite la partición basada en campos ni en registros.

Partición basada en registros:

Puede proporcionar la opción adicional `NUM_PARTITIONS` de Spark si quiere usar la simultaneidad en Spark. Con estos parámetros, la consulta original se dividiría en `NUM_PARTITIONS` subconsultas que las tareas de Spark pueden ejecutar simultáneamente.

En la partición basada en registros, se consulta el número total de registros presentes en la API de Blackbaud Raiser’s Edge NXT y se divide entre el número de `NUM_PARTITIONS` proporcionado. A continuación, cada subconsulta obtiene simultáneamente el número de registros resultante.

- NUM_PARTITIONS: el número de particiones.

Ejemplo:

```
blackbaud_read = glueContext.create_dynamic_frame.from_options(
    connection_type="BLACKBAUD",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "API_VERSION": "v1",
        "NUM_PARTITIONS": "2",
        "SUBSCRIPTION_KEY": <Subscription key associated with one's developer account>
    }
```

Opciones de conexión a Blackbaud Raiser's Edge NX.

Existen las siguientes opciones para establecer conexión con Blackbaud Raiser's Edge NXT:

- ENTITY_NAME(cadena): (obligatorio) se usa para lectura. El nombre del objeto en Blackbaud Raiser's Edge NXT.
- API_VERSION(cadena): (obligatorio) se usa para lectura. La versión de la API de REST de Blackbaud Raiser's Edge NXT que desea utilizar.
- SELECTED_FIELDS(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- FILTER_PREDICATE(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- QUERY(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.
- NUM_PARTITIONS(entero): predeterminado: 1. Se usa para leer. Número de particiones para leer. Valor de ejemplo: 10.
- SUBSCRIPTION_KEY(cadena): (obligatorio) predeterminado: vacío. Se usa para leer. Clave de suscripción asociada a la cuenta de desarrollador.

Limitaciones de Blackbaud Raiser's Edge NXT

Las siguientes son limitaciones o notas correspondientes a Blackbaud Raiser's Edge NXT:

- La solución SaaS solo es compatible con el operador `EQUAL_TO`, que devuelve los resultados creados o modificados en la fecha especificada o posteriormente. Además, el campo “id” es un tipo de datos de cadena. Tampoco se identifican los campos que no admiten valores nulos. Por lo tanto, no se admite la partición basada en campos.
- Únicamente la entidad `Event` admite la extracción incremental con frecuencia diaria, mensual y semanal.
- La entidad Constituent Fundraiser Assignment devuelve un máximo de 20 registros.
- Partición basada en registros:
  - No es compatible con las entidades `Action`, `Constituent Fundraiser Assignment` ni `Gift Batch`.
  - La partición basada en registros con el predicado de filtro solo es compatible con las entidades `Event` y `Event Participant`. Si se utiliza un predicado de filtro con cualquier otra entidad compatible basada en registros, se generará una excepción.
- En la entidad `Gift Custom Field`, el campo “valor” se debe utilizar en conjunto con el campo “categoría”, que, de lo contrario, generará una respuesta sin filtrar. Así, para exigir al usuario que introduzca el campo “categoría” al filtrar con el campo “valor”, se emitirá una excepción si no se cumple el requisito antes mencionado.
- Los campos `date_added` y `last_modified` de todas las entidades correspondientes no admiten operadores comparativos. Solo admiten el operador “igual a”. Además, no hay ningún campo que se pueda emparejar con los anteriores para obtener un rango de registros. Por lo tanto, estos campos solo se pueden consultar y no admiten transferencias incrementales.
- El campo `added_by` de la entidad `Gift Batch` no se considerará filtrable, ya que es posible que no emita los resultados correctos.
- Hay una latencia de aproximadamente 30 minutos para que los registros se recuperen a través del punto de conexión `/GET Gift List` después de la inserción de datos en la entidad `Gift`.
- Se ha eliminado la compatibilidad con la transferencia incremental para la entidad Gift debido a limitaciones en el origen de los datos.
- Existe una latencia de 10 minutos para el campo “estado” en la entidad Opportunity.
- La entidad `Fundraiser Assignment` tiene a `Constituent` como entidad dependiente. El conector carga un máximo de 5000 ID para elegir, a fin de evitar que el tamaño de la respuesta supere el límite máximo de carga útil permitido.

Conexión a CircleCI

CircleCI es una plataforma de integración y entrega continuas. La cuenta de CircleCI contiene datos sobre los proyectos, las canalizaciones y los flujos de trabajo, entre otros. Si es usuario de CircleCI, puede conectar AWS Glue a la cuenta de CircleCI. Tras ello, podrá utilizar CircleCI como origen de datos en los trabajos de ETL. Ejecute estos trabajos para transferir datos entre CircleCI y los servicios de AWS u otras aplicaciones compatibles.

Temas

- Compatibilidad de AWS Glue con CircleCI
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de CircleCI
- Configuración de conexiones a CircleCI
- Lectura de entidades de CircleCI
- Opciones de conexión a CircleCI
- Limitaciones de CircleCI

Compatibilidad de AWS Glue con CircleCI

AWS Glue admite CircleCI de la siguiente manera:

¿Es compatible como origen?

Sí. Puede utilizar los trabajos de ETL de AWS Glue para consultar datos de CircleCI.

¿Es compatible como destino?

No.

Versiones de la API de CircleCI compatibles

Las siguientes versiones de la API de CircleCI son compatibles:

- v2

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS IAM necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si no desea utilizar el método anterior, puede utilizar las siguientes políticas de IAM administradas:

- AWSGlueServiceRole: da acceso a recursos que precisan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: otorga acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la Consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de CircleCI

Antes de poder utilizar AWS Glue para transferir datos desde CircleCI, deberá cumplir estos requisitos:

Requisitos mínimos

Los requisitos mínimos son los siguientes:

- Tener una cuenta en CircleCI que contenga los datos que desea transferir.
- En la configuración de usuario de la cuenta, haber creado un token de API personal. Para obtener más información, consulte Creating a personal API token.
- Se proporciona el token de API personal a AWS Glue al crear la conexión.

Si cumple estos requisitos, estará listo para conectar AWS Glue a la cuenta de CircleCI.

Configuración de conexiones a CircleCI

CircleCI admite la autenticación personalizada.

Para configurar una conexión a CircleCI:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles:
   a. Para la aplicación conectada administrada por el cliente, el secreto debe contener la clave de la API de la aplicación conectada con `Circle-Token` como clave.
   b. Nota: Debe crear un secreto para las conexiones en AWS Glue.

1. En AWS Glue Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:
   a. Al seleccionar un Origen de datos, elija CircleCI.
   b. Seleccione el rol de AWS IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

      JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
```

```
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

c. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.

d. Seleccione las opciones de red si quiere usar su red.

2. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.

Lectura de entidades de CircleCI

Requisito previo

Un objeto de CircleCI desde el que desea leer. Necesitará el nombre del objeto.

Entidades compatibles como origen:

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Contexto	Sí	No	No	Sí	No
Métrica de resumen de la organización	Sí	No	No	Sí	No
Canalización	No	No	No	Sí	No
Flujo de trabajo de canalización	Sí	No	No	Sí	No
Ramificación de proyecto	Sí	No	No	Sí	No

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Prueba inestable del proyecto	No	No	No	Sí	No
Métrica de resumen del proyecto	Sí	No	No	Sí	No
Programación	No	No	No	Sí	No
Serie de tiempo del trabajo del flujo de trabajo	Sí	No	No	Sí	No
Métrica y tendencia del flujo de trabajo	Sí	No	No	Sí	No
Ejecución reciente del flujo de trabajo	Sí	No	No	Sí	No
Métrica de resumen del flujo de trabajo	Sí	No	No	Sí	No

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Métrica de prueba del flujo de trabajo	Sí	No	No	Sí	No

Ejemplo:

```
circleci_read = glueContext.create_dynamic_frame.from_options(
    connection_type="circleci",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "context/e7ea2945-dccb-4205-b673-8391fe1b3a4c",
        "API_VERSION": "v2"
    }
```

Detalles de entidades y campos de CircleCI

Para obtener más información acerca de las entidades y los detalles de los campos, consulte:

- Contextos
- Métricas de resumen del proyecto
- Serie de tiempo del trabajo del flujo de trabajo
- Métricas de resumen de la organización
- Ramificaciones del proyecto
- Pruebas inestables del proyecto
- Ejecuciones recientes del flujo de trabajo
- Métricas de resumen del flujo de trabajo
- Métricas y tendencias del flujo de trabajo
- Métricas de prueba del flujo de trabajo
- Canalizaciones
- Flujos de trabajo de la canalización
- Programas

Entidades con metadatos estáticos:

Entidad	Campo	Tipo de datos:	Operadores admitidos
Contexto	Creado a las	Cadena	
	ID	Cadena	
	Nombre	Cadena	
	Tipo de propietario	Cadena	EQUAL_TO
Métrica de resumen de la organización	Todos los proyectos	Enumeración	
	Datos de la organización	Struct	
	Datos del proyecto de la organización	Enumeración	
	Nombres de proyectos	Cadena	EQUAL_TO
	Periodo de generación de informe	Cadena	EQUAL_TO
Canalización	Rama	Cadena	EQUAL_TO
	Creado a las	Cadena	
	Errores	Enumeración	
	ID	Cadena	
	Número	Entero	
	Formato URL del proyecto	Cadena	
	Estado	Cadena	

Entidad	Campo	Tipo de datos:	Operadores admitidos
	Desencadenador	Struct	
	Parámetros del desencadenante	Struct	
	Actualizado a las	Cadena	
	VCS	Struct	
Flujo de trabajo de canalización	Cancelado por	Cadena	
	Creado a las	Cadena	
	Error causado por	Cadena	
	ID	Cadena	
	Nombre	Cadena	
	ID de canalización	Cadena	
	Número de canalización	Entero	
	Formato URL del proyecto	Cadena	
	Iniciado por	Cadena	
	Estado	Cadena	
	Detenido a las	Cadena	
	Etiqueta	Cadena	
Ramificación de proyecto	Ramificaciones	Enumeración	
	ID de la organización	Cadena	
	ID del proyecto	Cadena	

Entidad	Campo	Tipo de datos:	Operadores admitidos
	Workflow Name	Cadena	EQUAL_TO
Prueba inestable del proyecto	Classname	Cadena	
	Archivos	Cadena	
	Nombre del trabajo	Cadena	
	Número de trabajo	Entero	
	Número de canalización	Entero	
	Origen	Cadena	
	Nombre de la prueba	Cadena	
	Tiempo perdido	Entero	
	Veces que falló	Entero	
	Flujo de trabajo creado a las	Cadena	
	Workflow ID	Cadena	
	Workflow Name	Cadena	
Métrica de resumen del proyecto	Todas las ramificaciones	Enumeración	
	Todos los flujos de trabajo	Enumeración	
	Ramificaciones	Cadena	EQUAL_TO
	ID de organizaciones	Cadena	
	Datos del proyecto	Struct	

Entidad	Campo	Tipo de datos:	Operadores admitidos
	ID del proyecto	Cadena	
	Datos de la ramificación del flujo de trabajo del proyecto	Enumeración	
	Datos del flujo de trabajo del proyecto	Enumeración	
	Periodo de generación de informe	Cadena	EQUAL_TO
	Nombres de flujo de trabajo	Cadena	EQUAL_TO
Programación	Actor	Struct	
	Creado a las	Cadena	
	Descripción	Cadena	
	ID	Cadena	
	Nombre	Cadena	
	Parámetros	Struct	
	Formato URL del proyecto	Cadena	
	Horario	Struct	
	Actualizado a las	Cadena	
Serie de tiempo del trabajo del flujo de trabajo	Rama	Cadena	EQUAL_TO
	Granularity (Grado de detalle)	Cadena	EQUAL_TO

Entidad	Campo	Tipo de datos:	Operadores admitidos
	Hora máxima de finalización	Cadena	
	Métricas	Struct	
	Hora mínima de inicio	Cadena	
	Nombre	Cadena	
	Fecha de inicio y finalización	DateTime	EQUAL_TO, BETWEEN
	Timestamp	Cadena	
Métrica y tendencia del flujo de trabajo	Todas las ramificaciones	Booleano	EQUAL_TO
	Ramificaciones	Cadena	EQUAL_TO
	Métricas	Struct	
	Tendencias	Struct	
	Nombres de flujo de trabajo	Enumeración	
Ejecución reciente del flujo de trabajo	Todas las ramificaciones	Booleano	EQUAL_TO
	Rama	Cadena	EQUAL_TO
	Creado a las	Cadena	
	Créditos utilizados	Entero	
	Duración	Entero	
	ID	Cadena	

Entidad	Campo	Tipo de datos:	Operadores admitidos
	Es aprobación	Booleano	
	Fecha de inicio y finalización	DateTime	EQUAL_TO, BETWEEN
	Estado	Cadena	
	Detenido a las	Cadena	
Métrica de resumen del flujo de trabajo	Todas las ramificaciones	Booleano	EQUAL_TO
	Rama	Cadena	EQUAL_TO
	Métricas	Struct	
	Nombre	Cadena	
	ID del proyecto	Cadena	
	Periodo de generación de informe	Cadena	EQUAL_TO
	Finalización del periodo	Cadena	
	Inicio del periodo	Cadena	
Métrica de prueba del flujo de trabajo	Recuento promedio de pruebas	Entero	
	Rama	Cadena	EQUAL_TO
	Pruebas con más fallos	Enumeración	
	Pruebas con más fallos (extra)	Entero	

Entidad	Campo	Tipo de datos:	Operadores admitidos
	Pruebas más lentas	Enumeración	
	Pruebas más lentas (extra)	Entero	
	Ejecuciones de prueba	Enumeración	
	Total de ejecuciones de prueba	Entero	

> **Note**
>
> Los tipos de datos de estructura y lista se convierten en tipos de datos de cadena en respuesta al conector.

Consultas de partición

CircleCI no admite la partición basada en campos ni registros.

Opciones de conexión a CircleCI

Existen las siguientes opciones para establecer conexión con CircleCI:

- `ENTITY_NAME`(cadena): (obligatorio) se usa para lectura. El nombre del objeto en CircleCI.
- `API_VERSION`(cadena): (obligatorio) se usa para lectura. Versión de la API de REST de CircleCI que desea usar.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.

Limitaciones de CircleCI

Las siguientes son limitaciones o notas correspondientes a CircleCI:

- CircleCI no admite la partición basada en campos ni en registros.
- Los campos de filtro que contengan “-” (guión) solo funcionarán si están encerrados entre comillas invertidas. Por ejemplo: “workflow-name” = “abc”
- No se puede admitir el tipo VCS de GitLab porque no existe una forma de recuperar el “ID del proyecto” que se necesita para la ruta de la entidad VCS de GitLab mediante programación.

Conexión a Datadog

Datadog es una plataforma de supervisión y análisis para aplicaciones a escala de la nube, que incluye infraestructura, aplicaciones, servicios y herramientas.

Temas

- Compatibilidad de AWS Glue con Datadog
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de Datadog
- Configuración de las conexiones a Datadog
- Leer de entidades de Datadog
- Opciones de conexión a Datadog
- Cómo crear una cuenta de Datadog
- Limitaciones

Compatibilidad de AWS Glue con Datadog

AWS Glue admite Datadog de la siguiente manera:

¿Es compatible como origen?

Sí. Puede usar los trabajos de ETL de AWS Glue para consultar datos de Datadog.

¿Es compatible como destino?

No.

Versiones de la API de Datadog compatibles

- v1
- v2

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si no desea utilizar el método anterior, como alternativa, utilice las siguientes políticas de IAM administradas:

- AWSGlueServiceRole: concede acceso a los recursos que necesitan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.

- AWSGlueConsoleFullAccess: concede acceso completo a los recursos de AWS Gluecuando una identidad a la que está vinculada la política utiliza la Consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de Datadog

Antes de poder utilizar AWS Glue para transferir desde Datadog, deberá cumplir los siguientes requisitos:

Requisitos mínimos

- Tener una cuenta de Datadog con DD-API-KEY y DD-APPLICATION-KEY. Para obtener más información sobre cómo crear una cuenta, consulte Creación de una cuenta de Datadog.
- La cuenta de Datadog tiene acceso de API con una licencia válida.

Datadog admite las siguientes seis URL. Todos los clientes de la API de Datadog se configuran de forma predeterminada para consumir las API del sitio US1 de Datadog. Si se encuentra en el sitio de la UE de Datadog, debe seleccionar la URL https://api.datadoghq.eu con la `DD-API-KEY` y la `DD-APPLICATION-KEY` del sitio de la UE de Datadog para acceder a las API. Del mismo modo, para otros sitios, debe seleccionar las URL respectivas con las `DD-API-KEY and DD-APPLICATION-KEY` del sitio correspondiente.

- URL DE LA API DE US1: https://api.datadoghq.comhttps://api.datadoghq.com
- URL DE LA API DE LA UE: https://api.datadoghq.eu
- URL DE LA API DE US3: https://api.us3.datadoghq.com
- URL DE LA API DE US5: https://api.us5.datadoghq.com
- URL DE LA API DE S1-FED: https://api.ddog-gov.com
- URL DE LA API DE JAPÓN: https://api.ap1.datadoghq.com

Si cumple estos requisitos, estará listo para conectar AWS Glue a la cuenta de Datadog.

Configuración de las conexiones a Datadog

Datadog admite la autenticación personalizada. Estos son los pasos que hay que seguir para configurar la conexión a Datadog:

Para configurar una conexión a Datadog:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles:

   Para la aplicación conectada administrada por el cliente: el secreto debe contener el secreto del consumidor de la aplicación conectada con **`API_KEY`** y **`APPLICATION_KEY`** como claves.

   > **Note**
   >
   > Es imprescindible crear un secreto por conexión en AWS Glue.

2. En AWS Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:
   a. Al seleccionar un Tipo de conexión, elija Datadog.
   b. Proporcione la `Instance_Url` de Datadog a la que se desea conectar.
   c. Seleccione el rol de IAM que AWS Glue puede asumir y que cuente con los permisos necesarios para realizar las siguientes acciones:

      JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
```

```
}
```

d. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.

e. Seleccione las opciones de red si quiere usar su red.

3. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.

Leer de entidades de Datadog

Requisitos previos

Un objeto de Datadog desde el que desea leer. Consulte la tabla de entidades compatibles que aparece a continuación para comprobar las entidades disponibles.

Entidades compatibles

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite Partición
Serie de tiempo de métricas	Sí	No	No	Sí	No
Consultas de registros	Sí	Sí	Sí	Sí	No

Ejemplo

```
Datadog_read = glueContext.create_dynamic_frame.from_options(
    connection_type="datadog",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "log-queries",
        "API_VERSION": "v2",
        "INSTANCE_URL": "https://api.datadoghq.com",
        "FILTER_PREDICATE": "from = `2023-10-03T09:00:26Z`"
    }
```

Detalles de entidades y campos de Datadog

Entidad	Campo	Tipo de datos	Operadores admitidos
Serie de tiempo de métricas	error	Cadena	N/D
	aggr	Cadena	N/D
	atributos	Struct	N/D
	display_name	Cadena	N/D
	finales	DateTime	N/D
	expresión	Cadena	N/D
	intervalo	Entero	N/D
	length	Entero	N/D
	métrica	Cadena	N/D
	lista de puntos	Enumeración	N/D
	query_index	Entero	N/D
	scope	Cadena	N/D
	iniciar	DateTime	N/D
	tag_set	Enumeración	N/D
	unidad	Struct	N/D
	from_to_date	DateTime	BETWEEN
	consulta	Cadena	EQUAL_TO
	status	Cadena	N/D
	type	Cadena	N/D
	host	Cadena	N/D

Entidad	Campo	Tipo de datos	Operadores admitidos
Consultas de registros	id	Cadena	N/D
	atributos	Struct	N/D
	marca de tiempo	DateTime	N/D
	type	Cadena	N/D
	desde	DateTime	EQUAL_TO, BETWEEN
	índices	Enumeración	EQUAL_TO
	storage_tier	Cadena	EQUAL_TO
	consulta	Cadena	EQUAL_TO

Opciones de conexión a Datadog

Las siguientes son opciones de conexión para Datadog:

- `ENTITY_NAME`(cadena): (obligatorio) se utiliza para leer y escribir. El nombre del objeto en Datadog.
- `API_VERSION`(cadena): (obligatorio) se utiliza para leer y escribir. La versión de la API de Rest de Datadog que desea utilizar. La versión de `v1` admite la entidad `metrics-timeseries`, mientras que la versión `v2` admite la entidad `log-queries`.
- `INSTANCE_URL`(cadena): (obligatorio) se usa para lectura. URL de la instancia de Datadog. La URL de la instancia de Datadog varía según la región.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.

Cómo crear una cuenta de Datadog

1. Vaya a https://www.datadoghq.com/.
2. Elija COMENZAR DE FORMA GRATUITA.
3. Ingrese la información requerida y regístrese.
4. Instale el Instalador del agente Datadog como se sugiere.
5. Asegúrese de que la cuenta queda registrada en una organización válida (de la lista disponible) que tenga una suscripción activa a Datadog.
6. Después de iniciar sesión en la cuenta de Datadog, pase el cursor sobre el nombre de usuario en la esquina superior derecha para ver los detalles de las claves:
   a. Para obtener la clave de la API, elija Claves de la API.
   b. Para obtener la clave de la aplicación, elija Claves de aplicación.

Limitaciones

Las siguientes son limitaciones para el conector de Datadog:

- Datadog no admite la partición basada en campos ni en registros.
- `from` es un parámetro de filtro obligatorio para la entidad `Log Queries`.
- `from_to_date` y `query` son parámetros de filtro obligatorios para la entidad `Metrics Timeseries`.

Conexión a Docusign Monitor

Docusign Monitor ayuda a las organizaciones a proteger los contratos por medio de un seguimiento ininterrumpido de la actividad. La API Monitor proporciona esta información de seguimiento de la actividad directamente a las pilas de seguridad o herramientas de visualización de datos existentes, lo que permite a los equipos detectar actividades no autorizadas, investigar incidentes y responder rápidamente a las amenazas verificadas. Además, proporciona la flexibilidad que los equipos de seguridad necesitan para personalizar los paneles y las alertas con el fin de satisfacer necesidades empresariales específicas.

Temas

- Compatibilidad de AWS Glue con Docusign Monitor

- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de Docusign Monitor
- Configuración de las conexiones de Docusign Monitor
- Lectura de entidades de Docusign Monitor
- Opciones de conexión a Docusign Monitor
- Limitaciones de Docusign Monitor

Compatibilidad de AWS Glue con Docusign Monitor

AWS Glue es compatible con Docusign Monitor de la siguiente manera:

¿Es compatible como origen?

Sí. Puede utilizar los trabajos de ETL de AWS Glue para consultar datos de Docusign Monitor.

¿Es compatible como destino?

No.

Versiones de la API de Docusign Monitor compatibles

Las siguientes versiones de la API de Docusign Monitor son compatibles:

- v2.0

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS IAM necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
```

```
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si no desea utilizar el método anterior, puede utilizar las siguientes políticas de IAM administradas:

- AWSGlueServiceRole: da acceso a recursos que precisan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: otorga acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la Consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de Docusign Monitor

Antes de poder utilizar AWS Glue para transferir datos desde Docusign Monitor a destinos compatibles, deberá cumplir estos requisitos:

Requisitos mínimos

Los requisitos mínimos son los siguientes:

- Tener una cuenta de Docusign en la que utilice el producto de software de Docusign en Docusign Monitor.
- Haber creado una aplicación de integración OAuth 2.0 para AWS Glue en la consola para desarrolladores de la cuenta de Docusign.

Esta aplicación proporciona las credenciales de cliente que AWS Glue utiliza para acceder a los datos de forma segura cuando hace llamadas autenticadas a la cuenta. Para obtener más información, consulte OAuth 2.0 en la documentación de Docusign Monitor.

Si cumple estos requisitos, estará listo para conectar AWS Glue a la cuenta de Docusign Monitor.

Configuración de las conexiones de Docusign Monitor

Docusign Monitor admite el tipo de concesión AUTHORIZATION_CODE.

- Este tipo de concesión se considera un OAuth de tres vías, ya que se basa en redirigir a los usuarios al servidor de autorización externo para autenticar al usuario. Se utiliza para crear conexiones a través de la consola de AWS Glue.
- Los usuarios aún pueden optar por crear una aplicación conectada propia en Docusign Monitor y proporcionar un ID y secreto de cliente propios al crear conexiones a través de la consola de AWS Glue. En este escenario, aún se abrirá Docusign Monitor para iniciar sesión y autorizar a AWS Glue para que acceda a sus recursos.
- Este tipo de concesión da lugar a un token de actualización y a un token de acceso. El token de acceso es de corta duración y se puede actualizar automáticamente sin la interacción del usuario mediante el token de actualización.
- Si desea consultar la documentación pública de Docusign Monitor sobre la creación de una aplicación conectada para el flujo Authorization Code OAuth, consulte OAuth for Docusign Connect.

Para configurar una conexión a Docusign Monitor:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles:
   a. Para la aplicación conectada administrada por el cliente, el secreto debe contener la clave de la API de la aplicación conectada con `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET` como clave.
   b. Nota: Debe crear un secreto para las conexiones en AWS Glue.

1. En AWS Glue Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:
   a. En Conexiones, elija Crear conexión.

b. Al seleccionar un Origen de datos, seleccione Docusign Monitor.

c. Seleccione el rol de AWS IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

d. Proporcione el ClientId de la aplicación cliente administrada por el usuario de la aplicación Docusign Monitor.

e. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.

f. Seleccione las opciones de red si quiere usar su red.

2. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.

Lectura de entidades de Docusign Monitor

Requisito previo

Un objeto de Docusign Monitor desde el que desea leer.

Entidades compatibles como origen:

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Monitoreo de datos	Sí	Sí	No	Sí	No

Ejemplo:

```
docusignmonitor_read = glueContext.create_dynamic_frame.from_options(
    connection_type="docusign_monitor",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "monitoring-data",
        "API_VERSION": "v2.0"
    }
```

Detalles de entidades y campos de Docusign Monitor

Entidades con metadatos estáticos:

Entidad	Campo	Tipo de datos:	Operadores admitidos
Monitoreo de datos	marca de tiempo	DateTime	N/A
	eventId	Cadena	N/A
	aplicación	Cadena	N/A
	entorno	Cadena	N/A
	site	Cadena	N/A
	traceToken	Cadena	N/A
	organizationId	Cadena	N/A
	accountId	Cadena	N/A
	userId	Cadena	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	objeto	Cadena	N/A
	acción	Cadena	N/A
	propiedad	Cadena	N/A
	campo	Cadena	N/A
	resultado	Cadena	N/A
	IntegratorKey	Cadena	N/A
	customerVisible	Cadena	N/A
	versión	Cadena	N/A
	userAgent	Cadena	N/A
	userAgentClientInfo	Struct	N/A
	ipAddress	Cadena	N/A
	ipAddressLocation	Struct	N/A
	data	Cadena	N/A
	origen	Cadena	N/A
	latitude	Doble	N/A
	longitude	Doble	N/A
	ciudad	Cadena	N/A
	estado	Cadena	N/A
	país	Cadena	N/A
	usUserMem berOfDomain	Booleano	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	affectedUserIsMemberOfDomain	Booleano	N/A
	proxyStatus	Cadena	N/A
	proxyType	Cadena	N/A
	proxyLevel	Cadena	N/A
	referencedUserId	Cadena	N/A
	device	Cadena	N/A
	navegador	Cadena	N/A
	cursor	DateTime	EQUAL_TO

Consultas de partición

Docusign Monitor no admite la partición basada en campos ni en registros.

Opciones de conexión a Docusign Monitor

Existen las siguientes opciones para establecer conexión con Docusign Monitor:

- `ENTITY_NAME`(cadena): (obligatorio) se usa para lectura. El nombre del objeto en Docusign Monitor.
- `API_VERSION`(cadena): (obligatorio) se usa para lectura. Versión de la API de REST de Docusign Monitor que desea utilizar.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.
- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.

Limitaciones de Docusign Monitor

Las siguientes son limitaciones o notas correspondientes a Docusign Monitor:

- Cuando se aplica un filtro con el campo `cursor`, la API recupera registros para los siguientes siete días a partir de la fecha especificada.
- Si no se proporciona un filtro, la API recupera registros de los siete días anteriores a la fecha actual de la solicitud de la API.
- Docusign Monitor no admite la partición basada en campos ni en registros.
- Docusign Monitor no admite la característica Ordenar por.

Conexión a Domo

Domo es una herramienta basada en la nube para la creación y administración de paneles. Con la plataforma de aplicaciones empresariales de Domo, la base que necesita para ampliar Domo ya está en su lugar, lo que permite desarrollar soluciones personalizadas más rápido.

Temas

- Compatibilidad de AWS Glue con Domo
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de Domo
- Configuración de conexiones a Domo
- Lectura de entidades de Domo
- Opciones de conexión a Domo
- Limitaciones de Domo

Compatibilidad de AWS Glue con Domo

AWS Glue admite Domo de la siguiente manera:

¿Es compatible como origen?

Sí. Puede utilizar los trabajos de ETL de AWS Glue para consultar datos de Domo.

¿Es compatible como destino?

No.

Versiones de la API de Domo compatibles

Las siguientes versiones de la API de Domo son compatibles:

- v1

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS IAM necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si no desea utilizar el método anterior, puede utilizar las siguientes políticas de IAM administradas:

- AWSGlueServiceRole: da acceso a recursos que precisan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.

- AWSGlueConsoleFullAccess: otorga acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la Consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de Domo

Antes de poder utilizar AWS Glue para transferir datos desde Domo a destinos compatibles, deberá cumplir estos requisitos:

Requisitos mínimos

Los requisitos mínimos son los siguientes:

- La cuenta de Domo debe estar habilitada para el acceso a la API.
- Debe tener una aplicación en la cuenta de desarrollador de Domo que proporcione las credenciales de cliente que AWS Glue utiliza para acceder a los datos de forma segura cuando hace llamadas autenticadas a la cuenta. Para obtener más información, consulte Creación de una aplicación para desarrolladores de Domo.

Si cumple estos requisitos, estará listo para conectar AWS Glue a la cuenta de Domo.

Creación de una aplicación para desarrolladores de Domo

Para obtener el ID de cliente y el secreto del cliente, debe crear una cuenta de desarrollador.

1. Vaya a la página de inicio de sesión para desarrolladores de Domo.
2. Seleccione Iniciar sesión.
3. Proporcione el nombre de dominio y haga clic en Continuar.
4. Coloque el cursor sobre Mi cuenta y elija Nuevo cliente.
5. Ingrese el nombre y la descripción; seleccione el ámbito (“datos”); y, elija Crear.
6. Recupere el ID de cliente y el secreto de cliente generados del nuevo cliente creado.

Configuración de conexiones a Domo

Domo admite el tipo de concesión CLIENT_CREDENTIALS para OAuth2.

- Este tipo de concesión se considera un OAuth de dos patas, ya que solo la aplicación cliente se autentica ante el servidor, sin la participación del usuario.
- Los usuarios aún pueden optar por crear una aplicación conectada propia en Domo y proporcionar un ID y secreto de cliente propios al crear conexiones a través de la consola de AWS Glue.
- Para ver la documentación pública de Domo sobre la creación de una aplicación conectada para el flujo de Authorization Code OAuth, consulte OAuth Authentication.

Para configurar una conexión a Domo:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles:
   a. Para la aplicación conectada administrada por el cliente, el secreto debe contener el token de acceso de la aplicación conectada, el `client_id` y el `client_secret`.
   b. Nota: Debe crear un secreto para las conexiones en AWS Glue.

1. En AWS Glue Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:
   a. En Conexiones, elija Crear conexión.
   b. Al seleccionar un Origen de datos, elija Domo.
   c. Seleccione el rol de AWS IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

      JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
```

```
  ]
}
```

d. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.

e. Seleccione las opciones de red si quiere usar su red.

2. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.

Lectura de entidades de Domo

Requisito previo

Un objeto de Domo desde el que desea leer. Necesitará el nombre del objeto, como Conjunto de datos o Políticas de permisos de datos. En la siguiente tabla se muestran las entidades admitidas.

Entidades compatibles como origen:

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Conjunto de datos	Sí	Sí	Sí	Sí	Sí
Políticas de permisos de datos	No	No	No	Sí	No

Ejemplo:

```
Domo_read = glueContext.create_dynamic_frame.from_options(
    connection_type="domo",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "dataset",
        "API_VERSION": "v1"
    }
```

Detalles de entidades y campos de Domo

Entidades con metadatos estáticos:

Entidad	Campo	Tipo de datos:	Operadores admitidos
Políticas de permisos de datos	id	Largo	N/A
	type	Cadena	N/A
	nombre	Cadena	N/A
	filters	Enumeración	N/A
	usuarios	Enumeración	N/A
	virtualUsers	Enumeración	N/A
	grupos	Enumeración	N/A

Para la siguiente entidad, Domo proporciona puntos de conexión para obtener metadatos de forma dinámica, de modo que la compatibilidad del operador se capture a nivel de tipo de datos para la entidad.

Entidad	Tipo de datos:	Operadores admitidos
Conjunto de datos	Entero	=, !=, <, >, >=, <=
	Largo	=, !=, <, >, >=, <=
	Cadena	=, !=, CONTAINS
	Date	=, >, >=, <, <=, BETWEEN
	DateTime	=, >, >=, <, <=, BETWEEN
	Booleano	=, !=
	Doble	=, !=, <, >, >=, <=

Entidad	Tipo de datos:	Operadores admitidos
	Enumeración	N/A
	Struct	N/A

Consultas de partición

Partición basada en campos

Puede proporcionar las opciones adicionales de Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` y `NUM_PARTITIONS` si quiere utilizar la simultaneidad en Spark. Con estos parámetros, la consulta original se dividiría en un número `NUM_PARTITIONS` de subconsultas que las tareas de Spark pueden ejecutar simultáneamente.

- `PARTITION_FIELD`: el nombre del campo que se utilizará para particionar la consulta.
- `LOWER_BOUND`: un valor de límite inferior inclusivo del campo de partición elegido.

  Para el campo DateTime, aceptamos el valor en formato ISO.

  Ejemplo de valor válido:

  ```
  "2023-01-15T11:18:39.205Z"
  ```

  En el campo Fecha, aceptamos el valor en formato ISO.

  Ejemplo de valor válido:

  ```
  "2023-01-15"
  ```

- `UPPER_BOUND`: un valor límite superior exclusivo del campo de partición elegido.

  Ejemplo de valor válido:

  ```
  "2023-02-15T11:18:39.205Z"
  ```

- `NUM_PARTITIONS`: el número de particiones.

En la siguiente tabla se detalla la compatibilidad de los campos de partición por entidad:

Nombre de la entidad	Campos de partición	Tipo de datos:
Conjunto de datos	Cualquier campo basado en fecha y hora [metadatos dinámicos]	DateTime
	Cualquier campo basado en fecha [metadatos dinámicos]	Date

Ejemplo:

```
Domo_read = glueContext.create_dynamic_frame.from_options(
    connection_type="domo",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "dataset",
        "API_VERSION": "v1",
        "PARTITION_FIELD": "permissionTime"
        "LOWER_BOUND": "2023-01-15T11:18:39.205Z"
        "UPPER_BOUND": "2023-02-15T11:18:39.205Z"
        "NUM_PARTITIONS": "2"
    }
```

Partición basada en registros

Puede proporcionar la opción adicional `NUM_PARTITIONS` de Spark si quiere usar la simultaneidad en Spark. Con estos parámetros, la consulta original se dividiría en `NUM_PARTITIONS` subconsultas que las tareas de Spark pueden ejecutar simultáneamente.

En la partición basada en registros, se consulta el número total de registros presentes en Domo y se divide entre el número de `NUM_PARTITIONS` proporcionado. A continuación, cada subconsulta obtiene simultáneamente el número de registros resultante.

Ejemplo:

```
Domo_read = glueContext.create_dynamic_frame.from_options(
    connection_type="domo",
    connection_options={
        "connectionName": "connectionName",
```

```
        "ENTITY_NAME": "dataset",
        "API_VERSION": "v1",
        "NUM_PARTITIONS": "2"
    }
```

Opciones de conexión a Domo

Existen las siguientes opciones para establecer conexión con Domo:

- `ENTITY_NAME`(cadena): (obligatorio) se usa para lectura. El nombre del objeto en Domo.
- `API_VERSION`(cadena): (obligatorio) se usa para lectura. Versión de la API de REST de Domo que desea usar.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.
- `PARTITION_FIELD`(cadena): se usa para lectura. Campo que se utilizará para particionar la consulta.
- `LOWER_BOUND`(cadena): se usa para lectura. Un valor de límite inferior inclusivo del campo de partición elegido.
- `UPPER_BOUND`(cadena): se usa para lectura. Un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`(entero): predeterminado: 1. Se usa para leer. Número de particiones para leer.

Limitaciones de Domo

Las siguientes son limitaciones o notas correspondientes a Domo:

- Debido a una limitación del SDK, la filtración no funciona como se espera para los campos que se pueden consultar que comienzan con “_” (por ejemplo: _BATCH_ID).
- Debido a una limitación de la API, la filtración funciona con la fecha anterior a la que se proporciona. Esto también afecta la extracción incremental. Para superar esta limitación, seleccione una fecha según su zona horaria en relación con UTC para obtener los datos de la fecha requerida.

Conexión a Dynatrace

Dynatrace es una plataforma que ofrece análisis y automatización para conseguir observabilidad y seguridad completas. Se especializa en supervisar y optimizar el rendimiento de las aplicaciones, la infraestructura y la experiencia del usuario.

Temas

- Compatibilidad de AWS Glue con Dynatrace
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de Dynatrace
- Configuración de las conexiones a Dynatrace
- Lectura de entidades de Dynatrace
- Opciones de conexión a Dynatrace
- Limitaciones de Dynatrace

Compatibilidad de AWS Glue con Dynatrace

AWS Glue es compatible con Dynatrace de la siguiente manera:

¿Es compatible como origen?

Sí. Puede utilizar los trabajos de ETL de AWS Glue para consultar datos de Dynatrace.

¿Es compatible como destino?

No.

Versiones de la API de Dynatrace compatibles

Las siguientes versiones de la API de Dynatrace son compatibles:

- v2

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS IAM necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si no desea utilizar el método anterior, puede utilizar las siguientes políticas de IAM administradas:

- AWSGlueServiceRole: da acceso a recursos que precisan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: otorga acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la Consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de Dynatrace

Antes de poder utilizar AWS Glue para transferir datos desde Dynatrace, deberá cumplir estos requisitos:

Requisitos mínimos

Los requisitos mínimos son los siguientes:

- Tener una cuenta de Dynatrace.
- Haber generado un token de acceso en la cuenta de Dynatrace con el alcance de lectura/escritura adecuado asignado para acceder a las API. Para obtener más información, consulte Generate a token.

Si cumple estos requisitos, estará listo para conectar AWS Glue a la cuenta de Dynatrace.

Configuración de las conexiones a Dynatrace

Dynatrace admite la autenticación personalizada.

Para configurar una conexión a Dynatrace:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles:
   a. Para la aplicación conectada administrada por el cliente, el secreto debe contener la clave de la API de la aplicación conectada con *apiToken* como clave.
   b. Nota: Debe crear un secreto para las conexiones en AWS Glue.

1. En AWS Glue Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:
   a. Al seleccionar un Origen de datos, elija Dynatrace.
   b. Proporcione la `INSTANCE_URL` de la cuenta de Dynatrace a la que se desea conectar.
   c. Seleccione el rol de AWS IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

      JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
```

```
            "secretsmanager:PutSecretValue",
            "ec2:CreateNetworkInterface",
            "ec2:DescribeNetworkInterfaces",
            "ec2:DeleteNetworkInterface"
        ],
        "Resource": "*"
    }
  ]
}
```

d. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.

e. Seleccione las opciones de red si quiere usar su red.

2. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.

Lectura de entidades de Dynatrace

Requisito previo

Un objeto de Dynatrace desde el que desea leer. Necesitará el nombre del objeto, como “problema”.

Entidades compatibles como origen:

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Problema	Sí	Sí	Sí	Sí	No

Ejemplo:

```
Dynatrace_read = glueContext.create_dynamic_frame.from_options(
    connection_type="Dynatrace",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "problem",
        "API_VERSION": "v2",
        "INSTANCE_URL": "https://[instanceName].live.dynatrace.com"
    }
```

Detalles de entidades y campos de Dynatrace:

Dynatrace proporciona puntos de conexión para obtener metadatos de forma dinámica para entidades compatibles. Por lo tanto, la compatibilidad del operador se captura según el tipo de datos.

Entidad	Campo	Tipo de datos:	Operadores admitidos
Problema	affectedEntities	Enumeración	EQUAL_TO
	displayId	Cadena	EQUAL_TO
	endTime	DateTime	
	entityTags	Enumeración	
	evidenceDetails	Struct	
	impactAnalysis	Struct	
	impactLevel	Cadena	EQUAL_TO
	impactedEntities	Enumeración	EQUAL_TO
	linkedProblemInfo	Struct	
	managementZones	Enumeración	EQUAL_TO
	problemFilters	Enumeración	
	recentComments	Struct	
	rootCauseEntity	Struct	EQUAL_TO
	problemId	Cadena	EQUAL_TO
	severityLevel	Cadena	EQUAL_TO
	startTime	DateTime	BETWEEN
	status	Cadena	EQUAL_TO
	título	Cadena	

Entidad	Campo	Tipo de datos:	Operadores admitidos
	desde	DateTime	EQUAL_TO, BETWEEN
	problemFilterIds	Cadena	EQUAL_TO
	problemFilterNames	Cadena	EQUAL_TO
	managementZoneIds	Cadena	EQUAL_TO
	texto	Cadena	EQUAL_TO
	underMaintenance	Booleano	EQUAL_TO
	message	Cadena	

Consultas de partición

Dynatrace no admite la partición basada en campos ni en registros.

Opciones de conexión a Dynatrace

Existen las siguientes opciones para establecer conexión con Dynatrace:

- `ENTITY_NAME`(cadena): (obligatorio) se usa para lectura. El nombre del objeto en Dynatrace.
- `API_VERSION`(cadena): (obligatorio) se usa para lectura. Versión de la API de Rest de Dynatrace que desea utilizar.
- `INSTANCE_URL`(cadena): se usa para leer. Una URL de instancia de Dynatrace válida.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.

Limitaciones de Dynatrace

Las siguientes son limitaciones o notas correspondientes a Dynatrace:

- Dynatrace no admite la partición basada en campos ni en registros.
- En el caso de la característica Seleccionar todo, si proporciona el “campo” en el filtro, no permitirá que haya más de 10 registros por página.
- Se admite un máximo de 500 por página. Si selecciona alguno de los campos [`evidenceDetails, impactAnalysis, recentComments`] al crear el flujo, la cantidad de registros por página se establecerá de forma predeterminada en 10.

Conexión a Anuncios de Facebook

Anuncios de Facebook es una potente plataforma de publicidad digital que utilizan empresas de todos los tamaños para llegar a su público objetivo y lograr diversos objetivos de marketing. La plataforma permite a los anunciantes crear anuncios personalizados que se pueden mostrar en toda la familia de aplicaciones y servicios de Facebook, incluidos Facebook y Messenger. Gracias a sus capacidades de segmentación avanzadas, Anuncios de Facebook permite que las empresas lleguen a grupos demográficos, intereses, comportamientos y ubicaciones específicos.

Temas

- Compatibilidad de AWS Glue con Anuncios de Facebook
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de Anuncios de Facebook
- Configuración de las conexiones de Anuncios de Facebook
- Lectura desde entidades de Anuncios de Facebook
- Opciones de conexión de Anuncios de Facebook
- Limitaciones y notas del conector de Anuncios de Facebook

Compatibilidad de AWS Glue con Anuncios de Facebook

AWS Glue es compatible con Anuncios de Facebook de la siguiente manera:

¿Es compatible como origen?

Sí. Puede usar los trabajos de ETL de AWS Glue para consultar datos de Anuncios de Facebook.

¿Es compatible como destino?

No.

Versiones de la API de Anuncios de Facebook compatibles

Las siguientes versiones de la API de Anuncios de Facebook son compatibles:

- v17.0
- v18.0
- v19.0
- v20.0

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS IAM necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si no desea utilizar el método anterior, puede utilizar las siguientes políticas de IAM administradas:

- AWSGlueServiceRole: da acceso a recursos que precisan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios.

Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.

- AWSGlueConsoleFullAccess: otorga acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la Consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de Anuncios de Facebook

Antes de poder utilizar AWS Glue para transferir datos hacia o desde Anuncios de Facebook, debe cumplir estos requisitos:

Requisitos mínimos

Los requisitos mínimos son los siguientes:

- Se accede a las cuentas estándar de Facebook directamente a través de Facebook.
- Se necesita la autenticación del usuario para generar el token de acceso.
- El conector del SDK de Anuncios de Facebook implementará el flujo OAuth del token de acceso de usuario.
- Usamos OAuth 2.0 para autenticar nuestras solicitudes de API en Anuncios de Facebook. Esta autenticación basada en la web pertenece a la arquitectura de autenticación multifactor (MFA), que es un superconjunto de 2FA.
- El usuario debe conceder permisos para acceder a los puntos de conexión. Para acceder a los datos del usuario, la autorización del punto de conexión se administra mediante permisos y características.

Obtención de las credenciales de OAuth 2.0

Para obtener las credenciales de la API para poder hacer llamadas autenticadas a la instancia, consulte la API de REST en la guía para desarrolladores de Anuncios de Facebook.

Configuración de las conexiones de Anuncios de Facebook

Anuncios de Facebook admite el tipo de concesión AUTHORIZATION_CODE para OAuth 2.

- Este tipo de concesión se considera un OAuth de tres vías, ya que se basa en redirigir a los usuarios al servidor de autorización externo para autenticar al usuario. Se utiliza para crear conexiones a través de la consola de AWS Glue.
- Los usuarios aún pueden optar por crear su propia aplicación conectada en Anuncios de Facebook y proporcionar su propio ID y secreto de cliente al crear conexiones a través de la consola de AWS Glue. En este caso, se les continuará redirigiendo a Anuncios de Facebook para iniciar sesión y autorizar a AWS Glue para que acceda a sus recursos.
- Este tipo de concesión da como resultado un token acceso. Un token de usuario del sistema que caduca es válido durante 60 días a partir de la fecha de generación o actualización. Para crear continuidad, el desarrollador debe actualizar el token de acceso en un plazo de 60 días. De lo contrario, se pierde el token de acceso y es necesario que el desarrollador obtenga uno nuevo para recuperar el acceso a la API. Consulte Actualización del identificador de acceso.
- Para ver la documentación pública de Anuncios de Facebook sobre cómo crear una aplicación conectada para el flujo de OAuth con código de autorización, consulte Cómo usar OAuth 2.0 para acceder a las API de Google en la guía de Google para desarrolladores.

Configuración de una conexión con Anuncios de Facebook:

1. En AWS Glue Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:
   a. Al seleccionar un Tipo de conexión, seleccione Anuncios de Facebook.
   b. Proporcione la `INSTANCE_URL` de la instancia de Anuncios de Facebook a la que desea conectarse.
   c. Seleccione el rol de AWS IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

      JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
```

```
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

d. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.

e. Seleccione las opciones de red si quiere usar su red.

2. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.

Lectura desde entidades de Anuncios de Facebook

Requisito previo

Un objeto de Anuncios de Facebook desde el cual le gustaría leer. Necesitará el nombre del objeto. En las siguientes tablas se muestran las entidades admitidas.

Entidades compatibles como origen:

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Campaña	Sí	Sí	No	Sí	Sí
Conjunto de anuncios	Sí	Sí	No	Sí	Sí
Anuncios	Sí	Sí	No	Sí	Sí
Creatividad de anuncios	No	Sí	No	Sí	No
Información: cuenta	No	Sí	No	Sí	No
Adaccounts	Sí	Sí	No	Sí	No

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Información: anuncio	Sí	Sí	No	Sí	Sí
Información: conjunto de anuncios	Sí	Sí	No	Sí	Sí
Información: campaña	Sí	Sí	No	Sí	Sí

Ejemplo:

```
FacebookAds_read = glueContext.create_dynamic_frame.from_options(
    connection_type="FacebookAds",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "API_VERSION": "v20.0"
    }
```

Detalles de la entidad y el campo de Anuncios de Facebook

Para obtener más información acerca de las entidades y los detalles de los campos, consulte:

- Cuenta de anuncios
- Campaña
- Conjunto de anuncios
- Anuncio
- Creatividad de anuncios
- Información: cuenta de anuncios
- Información: anuncios
- Información: conjunto de anuncios
- Información: campañas

Para obtener más información, consulte API de marketing.

> **Note**
>
> Los tipos de datos de estructura y lista se convierten en tipos de datos de cadena en respuesta a los conectores.

Consultas de particionamiento

Puede proporcionar las opciones adicionales de Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` y `NUM_PARTITIONS` si quiere utilizar la simultaneidad en Spark. Con estos parámetros, la consulta original se dividiría en un número `NUM_PARTITIONS` de subconsultas que las tareas de Spark pueden ejecutar simultáneamente.

- `PARTITION_FIELD`: el nombre del campo que se utilizará para particionar la consulta.
- `LOWER_BOUND`: un valor de límite inferior inclusivo del campo de partición elegido.

  En el campo DateTime, aceptamos el formato de marca de tiempo de Spark que se utiliza en las consultas de Spark SQL.

  Ejemplo de valor válido:

  ```
  "2022-01-01"
  ```

- `UPPER_BOUND`: un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`: el número de particiones.

Ejemplo:

```
FacebookADs_read = glueContext.create_dynamic_frame.from_options(
    connection_type="FacebookAds",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "API_VERSION": "v20.0",
        "PARTITION_FIELD": "created_time"
        "LOWER_BOUND": "2022-01-01"
        "UPPER_BOUND": "2024-01-02"
```

```
        "NUM_PARTITIONS": "10"
    }
```

Opciones de conexión de Anuncios de Facebook

Las siguientes son opciones de conexión para Anuncios de Facebook:

- `ENTITY_NAME`(cadena): (obligatorio) se usa para lectura. El nombre de su objeto en Anuncios de Facebook.
- `API_VERSION`(cadena): (obligatorio) se usa para lectura. API de REST de Anuncios de Facebook que desea utilizar. Por ejemplo: v1.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.
- `PARTITION_FIELD`(cadena): se usa para lectura. Campo que se utilizará para particionar la consulta.
- `LOWER_BOUND`(cadena): se usa para lectura. Un valor de límite inferior inclusivo del campo de partición elegido.
- `UPPER_BOUND`(cadena): se usa para lectura. Un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`(entero): predeterminado: 1. Se usa para leer. Número de particiones para leer.
- `TRANSFER_MODE`(cadena): Predeterminado: SYNC. Se utiliza para la lectura asíncrona.

Limitaciones y notas del conector de Anuncios de Facebook

Las siguientes son limitaciones o notas para el conector de Anuncios de Facebook:

- Como Anuncios de Facebook admite metadatos dinámicos, se pueden consultar todos los campos. Todos los campos permiten filtrar y los registros se recopilan si los datos están disponibles. De lo contrario, Facebook devuelve una respuesta a una solicitud incorrecta (400) con el mensaje de error adecuado.
- El recuento de llamadas de una aplicación es el número de llamadas que un usuario puede hacer durante un periodo continuo de una hora, multiplicado por 200 por el número de usuarios. Para

obtener información sobre los límites de frecuencia, consulte Límites de frecuencia y Límites de frecuencia de casos de uso comercial.

Conexión a Facebook Page Insights

Facebook Pages permite a las empresas y otros grupos de interés crear páginas para la red social Facebook.com. Las empresas utilizan estas páginas para compartir horarios de atención al público, hacer anuncios e interactuar con los clientes en línea. Si es usuario de Facebook Page Insights, puede conectar AWS Glue a la cuenta de Facebook Page Insights. Puede utilizar Facebook Page Insights como origen de datos en los trabajos de extracción, tratamiento y carga (ETL). Ejecute estos trabajos para transferir datos entre Facebook Page Insights y los servicios de AWS u otras aplicaciones compatibles.

Temas

- Compatibilidad de AWS Glue con Facebook Page Insights
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de las conexiones a Facebook Page Insights
- Configuración de las conexiones de Facebook Page Insights
- Cómo leer de entidades de Facebook Page Insights
- Opciones de conexión a Facebook Page Insights
- Limitaciones y notas del conector de Facebook Page Insights

Compatibilidad de AWS Glue con Facebook Page Insights

AWS Glue es compatible con Facebook Page Insights de la siguiente manera:

¿Es compatible como origen?

Sí. Puede utilizar los trabajos de ETL de AWS Glue para consultar datos de Facebook Page Insights.

¿Es compatible como destino?

No.

Versiones de la API de Facebook Page Insights compatibles

Las siguientes versiones de la API de Facebook Page Insights son compatibles:

- v17
- v18
- v19
- v20
- v21

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS IAM necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si no desea utilizar el método anterior, puede utilizar las siguientes políticas de IAM administradas:

- AWSGlueServiceRole: da acceso a recursos que precisan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.

- AWSGlueConsoleFullAccess: otorga acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la Consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de las conexiones a Facebook Page Insights

Antes de poder utilizar AWS Glue para transferir datos desde Facebook Page Insights, deberá cumplir estos requisitos:

Requisitos mínimos

Los requisitos mínimos son los siguientes:

- Se accede a las cuentas estándar de Facebook directamente a través de Facebook.
- Se necesita la autenticación del usuario para generar el token de acceso.
- El conector de Facebook Page Insights implementa el flujo OAuth de token de acceso de usuario.
- El conector utiliza OAuth2.0 para autenticar nuestras solicitudes de API a Facebook Page Insights. Esto forma parte de la arquitectura de autenticación multifactor (MFA), que es un superconjunto de la 2FA. Se trata de una autenticación basada en la web.
- El usuario necesita conceder permisos para acceder a los puntos de conexión. Para acceder a los datos del usuario, la autorización del punto de conexión se administra mediante permisos y características.

Configuración de las conexiones de Facebook Page Insights

Para configurar una conexión a Facebook Page Insights:

1. En AWS Glue Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:
   a. Al seleccionar un Tipo de conexión, seleccione Facebook Page Insights.
   b. Seleccione el rol de AWS IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

      JSON

```
{
```

```
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

c. Seleccione la URL del código de autorización.

d. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.

e. Seleccione las opciones de red si quiere usar su red.

2. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.

Cómo leer de entidades de Facebook Page Insights

Requisito previo

Un objeto de Facebook Page Insights desde el cual le gustaría leer. Necesitará el nombre del objeto.

Entidades compatibles como origen:

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Contenido de la página	Sí	No	Sí	Sí	Sí
Clics de llamados a la	Sí	No	No	Sí	Sí

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
acción (CTA) de la página					
Interacción con la página	Sí	No	No	Sí	Sí
Impresiones de la página	Sí	No	No	Sí	Sí
Publicaciones en la página	Sí	No	No	Sí	Sí
Interacción con las publicaciones en la página	No	No	No	Sí	No
Reacciones a las publicaciones en la página	No	No	No	Sí	No
Reacciones a la página	Sí	No	No	Sí	Sí
Historias	Sí	No	No	Sí	Sí
Datos demográficos de los usuarios de la página	Sí	No	No	Sí	Sí

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Visualizaciones de videos de la página	Sí	No	No	Sí	Sí
Vistas de la página	Sí	No	No	Sí	Sí
Publicaciones de video de la página	Sí	No	No	Sí	Sí
Páginas	No	Sí	No	Sí	No
Fuentes	Sí	Sí	No	Sí	Sí

Ejemplo:

```
facebookPageInsights_read = glueContext.create_dynamic_frame. from options(
    connection_type="facebookpageinsights",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "API_VERSION": "v21"
   }
```

Detalles de campos de Facebook Page Insights:

Entidad	Campo	Tipo de datos:	Operadores admitidos
Contenido de la página	Nombre	Cadena	N/A
	Periodo	Periodo	EQUAL_TO
	Desde	DateTime	EQUAL_TO

Entidad	Campo	Tipo de datos:	Operadores admitidos
	Valores	Enumeración	N/A
	Título	Cadena	N/A
	Descripción	Cadena	N/A
	description_from_api_doc	Cadena	N/A
	Id	Cadena	N/A
Clics de llamados a la acción (CTA) de la página	Nombre	Cadena	N/A
	Periodo	Periodo	EQUAL_TO
	Desde	DateTime	EQUAL_TO
	Valores	Enumeración	N/A
	Título	Cadena	N/A
	Descripción	Cadena	N/A
	description_from_api_doc	Cadena	N/A
	Id	Cadena	N/A
Interacción con la página	Nombre	Cadena	N/A
	Periodo	Periodo	EQUAL_TO
	Desde	DateTime	EQUAL_TO
	Valores	Enumeración	N/A
	Título	Cadena	N/A
	Descripción	Cadena	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	description_from_api_doc	Cadena	N/A
	Id	Cadena	N/A
Impresiones de la página	Nombre	Cadena	N/A
	Periodo	Periodo	EQUAL_TO
	Desde	DateTime	EQUAL_TO
	Valores	Enumeración	N/A
	Título	Cadena	N/A
	Descripción	Cadena	N/A
	description_from_api_doc	Cadena	N/A
	Id	Cadena	N/A
Publicaciones en la página	Nombre	Cadena	N/A
	Periodo	Periodo	EQUAL_TO
	Desde	DateTime	EQUAL_TO
	Valores	Enumeración	N/A
	Título	Cadena	N/A
	Descripción	Cadena	N/A
	description_from_api_doc	Cadena	N/A
	Id	Cadena	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
Interacción con las publicaciones en la página	Nombre	Cadena	N/A
	Periodo	Periodo	EQUAL_TO
	Valores	Enumeración	N/A
	Título	Cadena	N/A
	Descripción	Cadena	N/A
	description_from_api_doc	Cadena	N/A
	Id	Cadena	N/A
Reacciones a las publicaciones en la página	Nombre	Cadena	N/A
	Periodo	Periodo	EQUAL_TO
	Valores	Enumeración	N/A
	Título	Cadena	N/A
	Descripción	Cadena	N/A
	description_from_api_doc	Cadena	N/A
	Id	Cadena	N/A
Datos demográficos de los usuarios de la página	Nombre	Cadena	N/A
	Periodo	Periodo	EQUAL_TO
	Desde	DateTime	EQUAL_TO
	Valores	Enumeración	N/A
	Título	Cadena	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	Descripción	Cadena	N/A
	description_from_api_doc	Cadena	N/A
	Id	Cadena	N/A
Visualizaciones de videos de la página	Nombre	Cadena	N/A
	Periodo	Periodo	EQUAL_TO
	Desde	DateTime	EQUAL_TO
	Valores	Enumeración	N/A
	Título	Cadena	N/A
	Descripción	Cadena	N/A
	description_from_api_doc	Cadena	N/A
	Id	Cadena	N/A
Vistas de la página	Nombre	Cadena	N/A
	Periodo	Periodo	EQUAL_TO
	Desde	DateTime	EQUAL_TO
	Valores	Enumeración	N/A
	Título	Cadena	N/A
	Descripción	Cadena	N/A
	description_from_api_doc	Cadena	N/A
	Id	Cadena	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
Publicaciones de video de la página	Nombre	Cadena	N/A
	Periodo	Periodo	EQUAL_TO
	Desde	DateTime	EQUAL_TO
	Valores	Enumeración	N/A
	Título	Cadena	N/A
	Descripción	Cadena	N/A
	description_from_api_doc	Cadena	N/A
	Id	Cadena	N/A
Páginas	Nombre	Cadena	N/A
	Acerca de	Cadena	N/A
	access_token	Cadena	N/A
	ad_campaign	Cadena	N/A
	Afiliación	Cadena	N/A
	app_id	Cadena	N/A
	artists_we_like	Cadena	N/A
	Vestimenta	Cadena	N/A
	Premios	Cadena	N/A
	band_interests	Cadena	N/A
	band_members	Cadena	N/A
	best_page	Cadena	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	Biografía	Cadena	N/A
	Birthday	Cadena	N/A
	booking_agent	Cadena	N/A
	Creado	Cadena	N/A
	can_checkin	Cadena	N/A
	can_post	Cadena	N/A
	Categoría	Cadena	N/A
	category_list	Enumeración	N/A
	Registros	Entero	N/A
	company_overview	Cadena	N/A
	connected_instagram_account	Cadena	N/A
	contact_address	Cadena	N/A
	country_page_likes	Entero	N/A
	Cobertura	Struct	N/A
	culinary_team	Cadena	N/A
	current_location	Cadena	N/A
	delivery_and_pickup_option_info	Enumeración	N/A
	Descripción	Cadena	N/A
	description_html	Cadena	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	differently_open_offerings	Enumeración	N/A
	directed_by	Cadena	N/A
	display_subtext	Cadena	N/A
	displayed_message_response_time	Cadena	N/A
	Correos electrónicos	Cadena	N/A
	Interacción	Cadena	N/A
	fan_count	Entero	N/A
	featured_video	Cadena	N/A
	Características	Cadena	N/A
	followers_count	Entero	N/A
	food_styles	Enumeración	N/A
	Fundado	Cadena	N/A
	general_info	Cadena	N/A
	general_manager	Cadena	N/A
	Género	Cadena	N/A
	global_brand_page_name	Cadena	N/A
	global_brand_root_id	Cadena	N/A
	has_added_app	Booleano	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	has_transitioned_to_new_page_experience	Booleano	N/A
	has_whatsapp_business_number	Booleano	N/A
	has_whatsapp_number	Booleano	N/A
	Ciudad natal	Cadena	N/A
	Horas	Struct	N/A
	Aviso legal	Cadena	N/A
	Influencias	Cadena	N/A
	instagram_business_account	Cadena	N/A
	is_always_open	Booleano	N/A
	is_chain	Booleano	N/A
	is_community_page	Booleano	N/A
	is_eligible_for_branded_content	Booleano	N/A
	is_messenger_bot_get_started_enabled	Booleano	N/A
	is_messenger_platform_bot	Booleano	N/A
	is_owned	Booleano	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	is_permanently_closed	Booleano	N/A
	is_published	Booleano	N/A
	Nombre	Cadena	N/A
	Tareas	Enumeración	N/A
	is_unclaimed	Booleano	N/A
	is_webhooks_subscribed	Booleano	N/A
	leadgen_tos_acceptance_time	DateTime	N/A
	leadgen_tos_accepted	Booleano	N/A
	leadgen_tos_accepting_user	Cadena	N/A
	leadgen_tos_accepting_user	Struct	N/A
	Enlace	Enlace	N/A
	Ubicación	Struct	N/A
	Miembros	Cadena	N/A
	merchant_review_status	Cadena	N/A
	messenger_ads_default_icebreakers	Enumeración	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	messenger_ads_default_page_welcome_message	Struct	N/A
	messenger_ads_default_quick_replies	Enumeración	N/A
	messenger_ads_quick_replies_type	Cadena	N/A
	Misión	Cadena	N/A
	Mpg	Cadena	N/A
	name_with_location_descriptor	Cadena	N/A
	Network	Cadena	N/A
	new_like_count	Entero	N/A
	offer_eligible	Booleano	N/A
	overall_star_rating	Flotante	N/A
	page_token	Cadena	N/A
	parent_page	Cadena	N/A
	Estacionamiento	Cadena	N/A
	payment_options	Struct	N/A
	personal_info	Cadena	N/A
	personal_interests	Cadena	N/A
	pharma_safety_info	Cadena	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	Teléfono	Cadena	N/A
	pickup_options	Enumeración	N/A
	place_type	Cadena	N/A
	plot_outline	Cadena	N/A
	press_contact	Cadena	N/A
	price_range	Cadena	N/A
	privacy_info_url	Cadena	N/A
	produced_by	Cadena	N/A
	Productos	Cadena	N/A
	promotion_eligible	Booleano	N/A
	promotion_ineligible_reason	Cadena	N/A
	public_transit	Cadena	N/A
	rating_count	Entero	N/A
	record_label	Cadena	N/A
	release_date	Cadena	N/A
	restaurant_services	Struct	N/A
	restaurant_specialties	Struct	N/A
	Programación	Cadena	N/A
	screenplay_by	Cadena	N/A
	Temporada	Cadena	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	single_line_address	Cadena	N/A
	Protagonista	Cadena	N/A
	start_info	Struct	N/A
	store_code	Cadena	N/A
	store_location_descriptor	Cadena	N/A
	store_number	Entero	N/A
	Estudio	Cadena	N/A
	supports_donate_button_in_live_video	Booleano	N/A
	talking_about_count	Entero	N/A
	temporary_status	Cadena	N/A
	unread_message_count	Entero	N/A
	unread_notif_count	Entero	N/A
	unseen_message_count	Entero	N/A
	Nombre de usuario	Cadena	N/A
	verification_status	Cadena	N/A
	voip_info	Struct	N/A
	Sitio web	Cadena	N/A
	were_here_count	Entero	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	whatsapp_number	Cadena	N/A
written_by	Cadena	N/A	
Carretes	Id	Cadena	N/A
	Acciones	Enumeración	N/A
	admin_creator	Objeto	N/A
	Aplicación	Objeto	N/A
	Archivos adjuntos	Objects	N/A
	backdated_time	DateTime	N/A
	call_to_action	Objeto	N/A
	can_reply_privately	Booleano	N/A
	child_attachments	Enumeración	N/A
	Coordinates	Struct	N/A
	created_time	DateTime	N/A
	Evento	Struct	N/A
	expanded_height	Entero	N/A
	expanded_width	Entero	N/A
	feed_targeting	Objeto	N/A
	De	Objeto	N/A
	full_picture	Cadena	N/A
	Alto	Entero	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	Icono	Cadena	N/A
	instagram_eligibility	Cadena	N/A
	is_eligible_for_promotion	Booleano	N/A
	is_expired	Booleano	N/A
	is_hidden	Booleano	N/A
	is_inline_created	Booleano	N/A
	is_instagram_eligible	Booleano	N/A
	is_popular	Booleano	N/A
	is_published	Booleano	N/A
	is_spherical	Booleano	N/A
	Mensaje	Cadena	N/A
	message_tags	Enumeración	N/A
	multi_share_end_card	Booleano	N/A
	multi_share_optimized	Booleano	N/A
	parent_id	Cadena	N/A
	permalink_url	Cadena	N/A
	Place	Cadena	N/A
	Privacidad	Objeto	N/A
	promotable_id	Cadena	N/A
	promotion_status	Cadena	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	Propiedades	Enumeración	N/A
	scheduled_publish_time	Flotante	N/A
	Veces compartido	Objeto	N/A
	status_type	Cadena	N/A
	Historia	Cadena	N/A
	story_tags	Enumeración	N/A
	Suscrito	Booleano	N/A
	Destino	Struct	N/A
	Indicación del destino	Objeto	N/A
	Para	Objeto	N/A
	timeline_visibility	Cadena	N/A
	updated_time	DateTime	N/A
	Via	Struct	N/A
	video_buying_eligibility	Enumeración	N/A
	Ancho	Entero	N/A
	Desde	DateTime	EQUAL_TO

Consultas de partición

Partición basada en filtros:

Puede proporcionar las opciones adicionales de Spark PARTITION_FIELD, LOWER_BOUND, UPPER_BOUND y NUM_PARTITIONS si quiere utilizar la simultaneidad en Spark. Con estos parámetros, la consulta original se dividiría en un número NUM_PARTITIONS de subconsultas que las tareas de Spark pueden ejecutar simultáneamente.

- PARTITION_FIELD: el nombre del campo que se utilizará para particionar la consulta.
- LOWER_BOUND: un valor de límite inferior inclusivo del campo de partición elegido.

  En el campo Datetime, aceptamos el formato de marca de tiempo de Spark que se utiliza en las consultas SQL de Spark.

  Ejemplos de valor válido:

  ```
  "2024-09-30T01:01:01.000Z"
  ```
- UPPER_BOUND: un valor límite superior exclusivo del campo de partición elegido.
- NUM_PARTITIONS: el número de particiones.

Ejemplo:

```
facebookPageInsights_read = glueContext.create_dynamic_frame.from_options(
     connection_type="facebookpageinsights",
     connection_options={
         "connectionName": "connectionName",
         "ENTITY_NAME": "entityName",
         "API_VERSION": "v21",
         "PARTITION_FIELD": "created_Time"
         "LOWER_BOUND": "2024-10-27T07:00:00+0000"
         "UPPER_BOUND": "2024-10-27T07:00:00+0000"
         "NUM_PARTITIONS": "10"
     }
```

Opciones de conexión a Facebook Page Insights

Las siguientes son opciones de conexión para Facebook Page Insights:

- ENTITY_NAME(cadena): (obligatorio) se usa para lectura. El nombre del objeto en Facebook Page Insights.
- API_VERSION(cadena): (obligatorio) se usa para lectura. La versión de la API de Rest de Facebook Page Insights que desea utilizar.

- SELECTED_FIELDS(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- FILTER_PREDICATE(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- QUERY(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.
- PARTITION_FIELD(cadena): se usa para leer. Campo que se utilizará para particionar la consulta.
- LOWER_BOUND(cadena): se usa para leer. Un valor de límite inferior inclusivo del campo de partición elegido.
- UPPER_BOUND(cadena): se usa para leer. Un valor límite superior exclusivo del campo de partición elegido.
- NUM_PARTITIONS(entero): predeterminado: 1. Se usa para leer. Número de particiones para leer.
- INSTANCE_URL(cadena): (obligatorio) se usa para lectura. Una URL de la instancia de Facebook Page Insights válida.

Limitaciones y notas del conector de Facebook Page Insights

Las siguientes son limitaciones o notas para el conector de Facebook Page Insights:

- La mayoría de las métricas se actualizan una vez cada 24 horas.
- Solo están disponibles los datos de información de los dos últimos años.
- Solo se pueden ver 90 días de información a la vez cuando se utilizan los parámetros `since` y `until`.

Conexión a Freshdesk

Freshdesk es un software de atención al cliente basado en la nube, rico en funciones y fácil de usar. Gracias a los múltiples canales de asistencia disponibles, como el chat en directo, el correo electrónico, el teléfono y las redes sociales, podrá ayudar a los clientes a través del método de comunicación que prefieran. Si es usuario de Freshdesk, puede conectar AWS Glue a la cuenta de Freshdesk. Puede usar Freshdesk como origen de datos en los trabajos de ETL. Ejecute estos trabajos para transferir datos entre Freshdesk y los servicios de AWS u otras aplicaciones compatibles.

Temas

- Compatibilidad de AWS Glue con Freshdesk
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de Freshdesk
- Configuración de las conexiones a Freshdesk
- Cómo leer de entidades de Freshdesk
- Opciones de conexión a Freshdesk
- Limitaciones y notas del conector de Freshdesk

Compatibilidad de AWS Glue con Freshdesk

AWS Glue es compatible con Freshdesk de la siguiente manera:

¿Es compatible como origen?

Sí: sincrónica y asincrónica. Puede utilizar los trabajos de ETL de AWS Glue para consultar datos de Freshdesk.

¿Es compatible como destino?

No.

Versiones de la API de Freshdesk compatibles

Se admiten las siguientes versiones de la API de Freshdesk:

- v2

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS IAM necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
```

```
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si no desea utilizar el método anterior, puede utilizar las siguientes políticas de IAM administradas:

- AWSGlueServiceRole: da acceso a recursos que precisan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: otorga acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la Consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de Freshdesk

Antes de poder utilizar AWS Glue para transferir datos desde Freshdesk, deberá cumplir estos requisitos:

Requisitos mínimos

Los requisitos mínimos son los siguientes:

- Una cuenta de Freshdesk. Puede elegir entre las ediciones Gratuita, Crecimiento, Profesional o Empresarial.

- Una clave de API de usuario de Freshdesk.

Configuración de las conexiones a Freshdesk

Freshdesk admite la autenticación personalizada.

Para consultar la documentación pública de Freshdesk sobre la generación de las claves de la API necesarias para la autenticación personalizada, consulte Freshdesk authentication.

Estos son los pasos que hay que seguir para configurar la conexión a Freshdesk:

- En AWS Secrets Manager, cree un secreto con los siguientes detalles:
  - Para la aplicación conectada administrada por el cliente, el secreto debe contener la clave de la API de la aplicación conectada con `apiKey` como clave. Nota: Debe crear un secreto por conexión en AWS Glue.
- En AWS Glue Studio, siga los pasos que se indican a continuación en Conexiones de datos para crear una conexión:
  - Al seleccionar un Origen de datos, elija Freshdesk.
  - Indique la `INSTANCE_URL` de la instancia de Freshdesk a la que se desea conectar.
  - Seleccione el rol de AWS IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

    JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
```

```
}
```

- Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.
- Seleccione las opciones de red si quiere usar su red.

- Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.
- En la configuración de su trabajo de AWS Glue, proporcione `connectionName` como Conexión de red adicional.

Cómo leer de entidades de Freshdesk

Requisito previo

Un objeto de Freshdesk del que desea leer. Necesitará el nombre del objeto.

Entidades compatibles para el origen sincrónico:

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Agentes	Sí	Sí	No	Sí	Sí
Horario laboral	No	Sí	No	Sí	Sí
Empresa	Sí	Sí	No	Sí	Sí
Contactos	Sí	Sí	No	Sí	Sí
Conversaciones	No	Sí	No	Sí	No
Configuración de correo electrónico	No	Sí	No	Sí	No
Bandejas de entrada	Sí	Sí	Sí	Sí	No

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
de correo electrónico					
Categorías de foro	No	Sí	No	Sí	No
Foros	No	Sí	No	Sí	No
Grupos	No	Sí	No	Sí	No
Productos	No	Sí	No	Sí	No
Roles	No	Sí	No	Sí	No
Calificaciones de satisfacción	Sí	Sí	No	Sí	No
Habilidades	No	Sí	No	Sí	No
Soluciones	Sí	Sí	No	Sí	No
Encuestas	No	Sí	No	Sí	No
Tickets	Sí	Sí	Sí	Sí	Sí
Entradas de tiempo	Sí	Sí	No	Sí	No
Temas	No	Sí	No	Sí	No
Comentarios de tema	No	Sí	No	Sí	No

Entidades compatibles para el origen asíncrono:

Entidad	Versión de la API	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Empresas	v2	No	No	No	No	No
Contactos	v2	No	No	No	No	No

Ejemplo:

```
freshdesk_read = glueContext.create_dynamic_frame.from_options(
    connection_type="freshdesk",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "API_VERSION": "v2"
    }
```

Detalles de entidades y campos de Freshdesk:

Entidad	Campo
Agentes	https://developers.freshdesk.com/api/#list_all_agents
Horario laboral	https://developers.freshdesk.com/api/#list_all_business_hours
Comentarios	https://developers.freshdesk.com/api/#comment_attributess
Empresa	https://developers.freshdesk.com/api/#companies
Contactos	https://developers.freshdesk.com/api/#list_all_contacts

Entidad	Campo
Conversaciones	https://developers.freshdesk.com/api/#list_all_ticket_notes
Configuraciones de correo electrónico	https://developers.freshdesk.com/api/#list_all_email_configs
Bandejas de entrada de correo electrónico	https://developers.freshdesk.com/api/#list_all_email_mailboxes
Categorías de foro	https://developers.freshdesk.com/api/#category_attributes
Foros	https://developers.freshdesk.com/api/#forum_attributes
Grupos	https://developers.freshdesk.com/api/#list_all_groups
Productos	https://developers.freshdesk.com/api/#list_all_products
Roles	https://developers.freshdesk.com/api/#list_all_roles
Calificaciones de satisfacción	https://developers.freshdesk.com/api/#view_all_satisfaction_ratings
Habilidades	https://developers.freshdesk.com/api/#list_all_skills
Soluciones	https://developers.freshdesk.com/api/#solution_content
Encuestas	https://developers.freshdesk.com/api/#list_all_surveys
Tickets	https://developers.freshdesk.com/api/#list_all_tickets

Entidad	Campo
Entradas de tiempo	https://developers.freshdesk.com/api/#list_all_time_entries
Temas	https://developers.freshdesk.com/api/#topic_attributes

Consultas de partición

Partición basada en filtros:

Puede proporcionar las opciones adicionales de Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` y `NUM_PARTITIONS` si quiere utilizar la simultaneidad en Spark. Con estos parámetros, la consulta original se dividiría en un número `NUM_PARTITIONS` de subconsultas que las tareas de Spark pueden ejecutar simultáneamente.

- `PARTITION_FIELD`: el nombre del campo que se utilizará para particionar la consulta.
- `LOWER_BOUND`: un valor de límite inferior inclusivo del campo de partición elegido.

  En el campo Datetime, aceptamos el formato de marca de tiempo de Spark que se utiliza en las consultas SQL de Spark.

  Ejemplos de valor válido:

  ```
  "2024-09-30T01:01:01.000Z"
  ```
- `UPPER_BOUND`: un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`: el número de particiones.

Ejemplo:

```
freshDesk_read = glueContext.create_dynamic_frame.from_options(
     connection_type="freshdesk",
     connection_options={
         "connectionName": "connectionName",
         "ENTITY_NAME": "entityName",
         "API_VERSION": "v2",
         "PARTITION_FIELD": "Created_Time"
```

```
        "LOWER_BOUND": " 2024-10-27T23:16:08Z“
        "UPPER_BOUND": " 2024-10-27T23:16:08Z"
        "NUM_PARTITIONS": "10"
    }
```

Opciones de conexión a Freshdesk

Las siguientes son opciones de conexión para Freshdesk:

- `ENTITY_NAME`(cadena): (obligatorio) se usa para lectura. El nombre del objeto en Freshdesk.
- `API_VERSION`(cadena): (obligatorio) se usa para lectura. Versión de la API de REST de Freshdesk que desea usar.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.
- `PARTITION_FIELD`(cadena): se usa para leer. Campo que se utilizará para particionar la consulta.
- `LOWER_BOUND`(cadena): se usa para leer. Un valor de límite inferior inclusivo del campo de partición elegido.
- `UPPER_BOUND`(cadena): se usa para leer. Un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`(entero): predeterminado: 1. Se usa para leer. Número de particiones para leer.
- `INSTANCE_URL`(cadena): (obligatorio) se usa para lectura. Una URL de instancia de Freshdesk válida.
- `TRANSFER_MODE`(Cadena): se usa para indicar si el tipo de procesamiento como `SYNC` o `ASYNC` está configurado como `SYNC` por defecto. (Opcional)

Limitaciones y notas del conector de Freshdesk

Las siguientes son limitaciones o notas para el conector de Freshdesk:

- Las entidades `Company`, `Contacts` y `Tickets` con filtrado tienen limitaciones de paginación. Devuelven únicamente 30 registros por página y el valor de la página se puede fijar hasta un máximo de 10 (con lo que se obtiene un máximo de 300 registros).

- La entidad `Tickets` no busca registros con una antigüedad superior a 30 días.
- Las entidades `Company`, `Contacts` y `Tickets` admiten el tipo de datos “Fecha” en la filtración. Debe seleccionar las frecuencias de activación “Diaria” en adelante para estas tres entidades. Si selecciona “Minutos” o “Cada hora”, es posible que se dupliquen los datos. Además, al seleccionar estos campos para el filtrado, solo se debe seleccionar el valor de la fecha, ya que solo se tendrá en cuenta la parte de la fecha de la marca de tiempo seleccionada.
- El número de llamadas a la API por minuto depende de su plan. Este límite se aplica a toda la cuenta, independientemente de factores como la cantidad de agentes o las direcciones IP utilizadas para realizar las llamadas. Para todos los usuarios de la versión de prueba, la API tiene un límite predeterminado de 50 llamadas por minuto. Para obtener más detalles, consulte Freshdesk
- Para cualquier entidad, solo se procesa un trabajo de exportación/asincrónico a la vez. Solo se procesará un trabajo nuevo una vez que el trabajo existente se haya completado correctamente o haya fallado. Para obtener más detalles, consulte Freshdesk.
- Los siguientes campos son compatibles con las llamadas a la API sincrónica, pero no se admiten ni se permite pasarlos en el cuerpo de la solicitud de la API asíncrona.
  - id
  - created_at
  - updated_at
  - updated_since
  - activa
  - company_id
  - other_companies
  - avatar
  - view_all_tickets
  - eliminado
  - other_emails
  - estado
  - etiqueta
  - etiquetas

Conexión a Freshsales

Freshsales es un sistema de gestión de las relaciones con los clientes (CRM) intuitivo que permite al personal de ventas dejar de lado las conjeturas. Gracias a las funciones integradas de teléfono y correo electrónico, tareas, citas y notas, los representantes de ventas ya no tienen que alternar entre pestañas para hacer un seguimiento de los clientes potenciales. Puede gestionar mejor los acuerdos gracias a la visualización del embudo de ventas e impulsar el cierre de más acuerdos. Si es usuario de Freshsales, puede conectar AWS Glue a la cuenta de Freshsales. Puede usar Freshsales como origen de datos en los trabajos de ETL. Ejecute estos trabajos para transferir datos entre Freshsales y los servicios de AWS u otras aplicaciones compatibles.

Temas

- Compatibilidad de AWS Glue con Freshsales
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de Freshsales
- Configuración de las conexiones de Freshsales
- Cómo leer de las entidades de Freshsales
- Opciones de conexión de Freshsales
- Limitaciones de Freshsales

Compatibilidad de AWS Glue con Freshsales

AWS Glue es compatible con Freshsales de la siguiente manera:

¿Es compatible como origen?

Sí. Puede utilizar los trabajos de ETL de AWS Glue para consultar datos de Salesforce.

¿Es compatible como destino?

No.

Versiones de la API de Freshsales compatibles

Se admiten las siguientes versiones de la API de Freshsales:

- v1.0

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS IAM necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si no desea utilizar el método anterior, puede utilizar las siguientes políticas de IAM administradas:

- AWSGlueServiceRole: da acceso a recursos que precisan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: otorga acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la Consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de Freshsales

Antes de poder utilizar AWS Glue para transferir datos desde Freshsales, deberá cumplir estos requisitos:

Requisitos mínimos

Los requisitos mínimos son los siguientes:

- Tener una cuenta de Freshsales.
- Tener una clave de API de usuario.

Si cumple estos requisitos, estará listo para conectar AWS Glue a la cuenta de Freshsales. Para conexiones típicas, no necesita hacer nada más en Freshsales.

Configuración de las conexiones de Freshsales

Freshsales admite la autenticación personalizada.

Para consultar la documentación pública de Freshsales sobre la generación de las claves de API necesarias para la autenticación personalizada, consulte Autenticación.

Para configurar una conexión de Freshsales:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles:
   a. Para la aplicación conectada administrada por el cliente, el secreto debe contener la clave de la API de la aplicación conectada con *`apiSecretKey`* como clave. El secreto también debe contener otro par de clave y valor con *`apiKey`* como clave y *`token`* como valor.
   b. Nota: Debe crear un secreto para las conexiones en AWS Glue.

1. En AWS Glue Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:
   a. Al seleccionar un Origen de datos, elija Freshsales.
   b. Proporcione la `INSTANCE_URL` de la cuenta de Freshsales a la que se desea conectar.
   c. Seleccione el rol de AWS IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

d. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.

e. Seleccione las opciones de red si quiere usar su red.

2. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.

Cómo leer de las entidades de Freshsales

Requisito previo

Un objeto de Freshsales del que le gustaría leer. Necesitará el nombre del objeto.

Entidades compatibles como origen:

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Cuentas	Sí	Sí	Sí	Sí	Sí
Contactos	Sí	Sí	Sí	Sí	Sí

Ejemplo:

```
freshSales_read = glueContext.create_dynamic_frame.from_options(
     connection_type="freshsales",
     connection_options={
         "connectionName": "connectionName",
         "ENTITY_NAME": "entityName",
         "API_VERSION": "v1.0"
     }
```

Detalles de las entidades y campos de Freshsales:

Freshsales proporciona puntos de conexión para obtener metadatos de forma dinámica para las entidades compatibles. Por lo tanto, la compatibilidad del operador se captura según el tipo de datos.

Entidad	Tipo de datos:	Operadores admitidos
Entidades de Freshsale (todas)	Entero	!=,=,<,<=,>,>=,BETWEEN
	Cadena	Like, =, !=
	BigInteger	!=,=,<,<=,>,>=,BETWEEN
	Booleano	=
	Doble	!=,=,<,<=,>,>=,BETWEEN
	BigDecimal	!=,=,<,<=,>,>=,BETWEEN
	Date	!=,=,<,<=,>,>=,BETWEEN
	DateTime	!=,=,<,<=,>,>=,BETWEEN
	Struct	N/A
	Enumeración	N/A

Consultas de partición

Partición basada en filtros:

Puede proporcionar las opciones adicionales de Spark PARTITION_FIELD, LOWER_BOUND, UPPER_BOUND y NUM_PARTITIONS si quiere utilizar la simultaneidad en Spark. Con estos parámetros, la consulta original se dividiría en un número NUM_PARTITIONS de subconsultas que las tareas de Spark pueden ejecutar simultáneamente.

- PARTITION_FIELD: el nombre del campo que se utilizará para particionar la consulta.
- LOWER_BOUND: un valor de límite inferior inclusivo del campo de partición elegido.

  En el campo Datetime, aceptamos el valor en formato ISO.

  Ejemplos de valor válido:

  ```
  "2024-09-30T01:01:01.000Z"
  ```

- UPPER_BOUND: un valor límite superior exclusivo del campo de partición elegido.
- NUM_PARTITIONS: el número de particiones.

Ejemplo:

```
freshSales_read = glueContext.create_dynamic_frame.from_options(
     connection_type="freshsales",
     connection_options={
         "connectionName": "connectionName",
         "ENTITY_NAME": "entityName",
         "API_VERSION": "v1",
         "PARTITION_FIELD": "Created_Time"
         "LOWER_BOUND": " 2024-10-15T21:16:25Z"
         "UPPER_BOUND": " 2024-10-20T21:25:50Z"
         "NUM_PARTITIONS": "10"
     }
```

Opciones de conexión de Freshsales

Las siguientes son opciones de conexión para Freshsales:

- ENTITY_NAME(cadena): (obligatorio) se usa para lectura. El nombre del objeto en Freshsales.
- API_VERSION(cadena): (obligatorio) se usa para lectura. Versión de la API de Rest de Freshsales que desea utilizar.

- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.
- `PARTITION_FIELD`(cadena): se usa para leer. Campo que se utilizará para particionar la consulta.
- `LOWER_BOUND`(cadena): se usa para leer. Un valor de límite inferior inclusivo del campo de partición elegido.
- `UPPER_BOUND`(cadena): se usa para leer. Un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`(entero): predeterminado: 1. Se usa para leer. Número de particiones para leer.
- `INSTANCE_URL`(cadena): se usa para leer. Una URL de instancia de Freshsales válida.

Limitaciones de Freshsales

Las siguientes son limitaciones o notas correspondientes a Freshsales:

- En Freshsales, el límite de velocidad de API es de 1000 solicitudes de API por hora por cuenta (consulte Errores. Sin embargo, este límite se puede ampliar con el plan de suscripción Enterprise (consulte la comparación de planes).

Conexión a Google Ads

La API de Google Ads es la interfaz programática de Google Ads que se utiliza para administrar cuentas y campañas de Google Ads grandes o complejas. Si es usuario de Google Ads, puede conectar AWS Glue a la cuenta de Google Ads. Luego, podrá usar Google Ads como origen de datos en los trabajos de ETL. Ejecute estos trabajos para transferir datos entre Google Ads y los servicios de AWS u otras aplicaciones compatibles.

Temas

- Compatibilidad de AWS Glue con Google Ads
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de Google Ads
- Configuración de conexiones a Google Ads

- Lectura desde entidades de Google Ads
- Opciones de conexión a Google Ads
- Crear una cuenta de Google Ads
- Limitaciones

Compatibilidad de AWS Glue con Google Ads

AWS Glue es compatible con Google Ads de la siguiente manera:

¿Es compatible como origen?

Sí. Puede usar los trabajos de ETL de AWS Glue para consultar datos de Google Ads.

¿Es compatible como destino?

No.

Versiones de la API de Google Ads compatibles

v18

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
```

```
    }
  ]
}
```

También puede usar las siguientes políticas de IAM administradas para permitir el acceso:

- AWSGlueServiceRole: concede acceso a los recursos que necesitan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: concede acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de Google Ads

Antes de poder utilizar AWS Glue para transferir datos desde Google Ads, debe cumplir estos requisitos:

Requisitos mínimos

- Tener una cuenta de Google Ads con correo electrónico y contraseña. Para obtener más información sobre cómo crear una cuenta, consulte Creación de una cuenta de Google Ads.
- La cuenta de Google Ads debe estar habilitada para el acceso de API. La API de Google Ads se puede utilizar sin ningún costo adicional.
- Su cuenta de Google Ads le permite instalar aplicaciones conectadas. Si no tiene acceso a esta funcionalidad, contacte con su administrador de Google Ads.

Si cumple estos requisitos, lo tendrá todo listo para conectar AWS Glue a su cuenta de Google Ads.

Configuración de conexiones a Google Ads

Google Ads admite el tipo de concesión `AUTHORIZATION_CODE` para OAuth2.

Este tipo de concesión se considera un OAuth “de tres vías”, ya que se basa en redirigir a los usuarios al servidor de autorización externo para autenticar al usuario. Se utiliza para crear conexiones a través de la consola de AWS Glue. La consola de AWS Glue redirigirá al usuario a Google Ads, donde deberá iniciar sesión y conceder a AWS Glue los permisos solicitados para acceder a la instancia de Google Ads.

Los usuarios pueden optar por crear su propia aplicación conectada en Google Ads y proporcionar su propio ID y secreto de cliente al crear conexiones a través de la consola de AWS Glue. En este escenario, aún se abrirá Google Ads para iniciar sesión y autorizar a AWS Glue para que acceda a sus recursos.

Este tipo de concesión da como resultado un token de actualización y un token de acceso. El token de acceso es de corta duración y se puede actualizar automáticamente sin la interacción del usuario mediante el token de actualización.

Para obtener más información, consulte la documentación pública de Google Ads sobre la creación de una aplicación conectada para el flujo Authorization Code OAuth.

Para configurar una conexión a Google Ads:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles. Es necesario crear un secreto para cada conexión en AWS Glue.
   a. Para el tipo de concesión AuthorizationCode:
      - En el caso de una aplicación conectada administrada por el cliente, el secreto debe contener el secreto del consumidor de la aplicación conectada con la clave `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET`.
2. En AWS Glue Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:
   a. Cuando elija un Tipo de conexión, seleccione Google Ads.
   b. Proporcione la `developer token` de Google Ads a la que se desea conectar.
   c. Proporcione el `MANAGER ID` de Google Ads si desea iniciar sesión como administrador.
   d. Seleccione el rol de IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

      JSON

```
{
  "Version":"2012-10-17",
```

```
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

e. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.

f. Seleccione las opciones de red si quiere usar su red.

3. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.

Lectura desde entidades de Google Ads

Requisitos previos

- Un objeto de Google Ads desde el cual le gustaría leer. Consulte la tabla de entidades compatibles que aparece a continuación para comprobar las entidades disponibles.

Entidades compatibles

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite Partición
Anuncio de grupo de anuncios	Sí	Sí	Sí	No	Sí
Grupo de anuncios	Sí	Sí	Sí	No	Sí

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite Partición
Presupuesto de campaña	Sí	Sí	Sí	Sí	Sí
Presupuesto de cuenta	Sí	No	Sí	Sí	No
Campaña	Sí	Sí	Sí	Sí	Sí
Cuenta	Sí	No	Sí	No	No

Ejemplo

```
googleAds_read = glueContext.create_dynamic_frame.from_options(
    connection_type="googleads",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "campaign-3467***",
        "API_VERSION": "v16"
    }
```

Detalles de la entidad y el campo de Google Ads

Entidad	Campo	Tipo de datos	Operadores admitidos
Cuenta	resourceName	Cadena	!=, =
Cuenta	callReportingEnabled	Booleano	!=, =
Cuenta	callConversionReportingEnabled	Booleano	!=, =
Cuenta	callConversionAction	Cadena	!=, =
Cuenta	conversionTrackingId	BigInteger	BETWEEN, =, !=, <, >, <=, >=

Entidad	Campo	Tipo de datos	Operadores admitidos
Cuenta	crossAccountConversionTrackingId	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Cuenta	payPerConversionEligibilityFailureReasons	Enumeración	
Cuenta	id	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Cuenta	currencyCode	Cadena	!=, =, LIKE
Cuenta	timeZone	Cadena	!=, =, LIKE
Cuenta	autoTaggingEnabled	Booleano	!=, =
Cuenta	hasPartnersBadge	Booleano	!=, =
Cuenta	manager	Booleano	!=, =
Cuenta	testAccount	Booleano	!=, =
Cuenta	date	Date	BETWEEN, =, <, >, <=, >=
Cuenta	costMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Cuenta	acceptedCustomerDataTerms	Booleano	
Cuenta	conversionTrackingStatus	Cadena	!=, =, LIKE
Cuenta	enhancedConversionsForLeadsEnabled	Booleano	

Entidad	Campo	Tipo de datos	Operadores admitidos
Cuenta	googleAdsConversionCustomer	Cadena	
Cuenta	status	Cadena	!=, =
Cuenta	allConversionsByConversionDate	Doble	!=, =, <, >
Cuenta	allConversionsValueByConversionDate	Doble	!=, =, <, >
Cuenta	conversionsByConversionDate	Doble	!=, =, <, >
Cuenta	conversionsValueByConversionDate	Doble	!=, =, <, >
Cuenta	valuePerAllConversionsByConversionDate	Doble	!=, =, <, >
Cuenta	videoViews	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Cuenta	clicks	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Cuenta	invalidClicks	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Cuenta	costPerAllConversions	Doble	!=, =, <, >
Cuenta	costPerConversion	Doble	!=, =, <, >
Cuenta	conversions	Doble	!=, =, <, >

Entidad	Campo	Tipo de datos	Operadores admitidos
Cuenta	absoluteTopImpressionPercentage	Doble	!=, =, <, >
Cuenta	impresiones	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Cuenta	topImpressionPercentage	Doble	!=, =, <, >
Cuenta	averageCpc	Doble	!=, =, <, >
Cuenta	activeViewMeasurableCostMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Cuenta	averageCost	Doble	!=, =, <, >
Cuenta	ctr	Doble	!=, =, <, >
Cuenta	activeViewCtr	Doble	!=, =, <, >
Cuenta	searchImpressionShare	Doble	!=, =, <, >
Cuenta	conversionAction	Cadena	!=, =
Cuenta	conversionActionCategory	Cadena	!=, =
Cuenta	conversionActionName	Cadena	!=, =, LIKE
Presupuesto de cuenta	resourceName	Cadena	!=, =
Presupuesto de cuenta	status	Cadena	!=, =

Entidad	Campo	Tipo de datos	Operadores admitidos
Presupuesto de cuenta	proposedEndTimeType	Cadena	!=, =
Presupuesto de cuenta	approvedEndTimeType	Cadena	!=, =
Presupuesto de cuenta	id	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Presupuesto de cuenta	billingSetup	Cadena	!=, =
Presupuesto de cuenta	nombre	Cadena	!=, =, LIKE
Presupuesto de cuenta	approvedStartDateTime	DateTime	BETWEEN, =, <, >, <=, >=
Presupuesto de cuenta	proposedSpendingLimitMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Presupuesto de cuenta	approvedSpendingLimitMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Presupuesto de cuenta	adjustedSpendingLimitMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Presupuesto de cuenta	amountServedMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Grupo de anuncios	resourceName	Cadena	!=, =, LIKE
Grupo de anuncios	status	Cadena	!=, =, LIKE
Grupo de anuncios	type	Cadena	!=, =, LIKE
Grupo de anuncios	id	BigInteger	BETWEEN, =, !=, <, >, <=, >=

Entidad	Campo	Tipo de datos	Operadores admitidos
Grupo de anuncios	nombre	Cadena	!=, =, LIKE
Grupo de anuncios	campaña	Cadena	!=, =
Grupo de anuncios	cpcBidMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Grupo de anuncios	targetCpaMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Grupo de anuncios	cpmBidMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Grupo de anuncios	cpvBidMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Grupo de anuncios	targetCpmMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Grupo de anuncios	effectiveTargetCpaMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Grupo de anuncios	date	Date	BETWEEN, =, <, >, <=, >=
Grupo de anuncios	costMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Grupo de anuncios	useAudienceGrouped	Booleano	!=, =
Grupo de anuncios	effectiveCpcBidMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Grupo de anuncios	allConversionsByConversionDate	Doble	!=, =, <, >
Grupo de anuncios	allConversionsValueByConversionDate	Doble	!=, =, <, >

Entidad	Campo	Tipo de datos	Operadores admitidos
Grupo de anuncios	conversionsByConversionDate	Doble	!=, =, <, >
Grupo de anuncios	conversionsValueByConversionDate	Doble	!=, =, <, >
Grupo de anuncios	valuePerAllConversionsByConversionDate	Doble	!=, =, <, >
Grupo de anuncios	valuePerConversionsByConversionDate	Doble	!=, =, <, >
Grupo de anuncios	averageCost	Doble	!=, =, <, >
Grupo de anuncios	costPerAllConversions	Doble	!=, =, <, >
Grupo de anuncios	costPerConversion	Doble	!=, =, <, >
Grupo de anuncios	averagePageViews	Doble	!=, =, <, >
Grupo de anuncios	videoViews	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Grupo de anuncios	clicks	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Grupo de anuncios	allConversions	Doble	!=, =, <, >
Grupo de anuncios	averageCpc	Doble	!=, =, <, >
Grupo de anuncios	absoluteTopImpressionPercentage	Doble	!=, =, <, >
Grupo de anuncios	impresiones	BigInteger	BETWEEN, =, !=, <, >, <=, >=

Entidad	Campo	Tipo de datos	Operadores admitidos
Grupo de anuncios	topImpressionPercentage	Doble	!=, =, <, >
Grupo de anuncios	activeViewCtr	Doble	!=, =, <, >
Grupo de anuncios	ctr	Doble	!=, =, <, >
Grupo de anuncios	searchTopImpressionShare	Doble	!=, =, <, >
Grupo de anuncios	searchImpressionShare	Doble	!=, =, <, >
Grupo de anuncios	searchAbsoluteTopImpressionShare	Doble	!=, =, <, >
Grupo de anuncios	relativeCtr	Doble	!=, =, <, >
Grupo de anuncios	conversionAction	Cadena	!=, =
Grupo de anuncios	conversionActionCategory	Cadena	!=, =
Grupo de anuncios	conversionActionName	Cadena	!=, =, LIKE
Grupo de anuncios	updateMask	Cadena	
Grupo de anuncios	crear	Struct	
Grupo de anuncios	actualización	Struct	
Grupo de anuncios	primaryStatus	Cadena	!=, =
Grupo de anuncios	primaryStatusReasons	Enumeración	
Anuncio de grupo de anuncios	resourceName	Cadena	!=, =

Entidad	Campo	Tipo de datos	Operadores admitidos
Anuncio de grupo de anuncios	id	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Anuncio de grupo de anuncios	status	Cadena	!=, =
Anuncio de grupo de anuncios	etiquetas	Enumeración	
Anuncio de grupo de anuncios	adGroup	Cadena	!=, =
Anuncio de grupo de anuncios	costMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Anuncio de grupo de anuncios	approvalStatus	Cadena	!=, =
Anuncio de grupo de anuncios	reviewStatus	Cadena	!=, =
Anuncio de grupo de anuncios	adStrength	Cadena	!=, =
Anuncio de grupo de anuncios	type	Cadena	!=, =
Anuncio de grupo de anuncios	businessName	Cadena	!=, =, LIKE
Anuncio de grupo de anuncios	date	Date	BETWEEN, =, <, >, <=, >=
Anuncio de grupo de anuncios	allConversionsByConversionDate	Doble	!=, =, <, >
Anuncio de grupo de anuncios	allConversionsValueByConversionDate	Doble	!=, =, <, >

Entidad	Campo	Tipo de datos	Operadores admitidos
Anuncio de grupo de anuncios	conversionsByConversionDate	Doble	!=, =, <, >
Anuncio de grupo de anuncios	conversionsValueByConversionDate	Doble	!=, =, <, >
Anuncio de grupo de anuncios	valuePerAllConversionsByConversionDate	Doble	!=, =, <, >
Anuncio de grupo de anuncios	valuePerConversionsByConversionDate	Doble	!=, =, <, >
Anuncio de grupo de anuncios	activeViewMeasurableCostMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Anuncio de grupo de anuncios	averageCost	Doble	!=, =, <, >
Anuncio de grupo de anuncios	costPerAllConversions	Doble	!=, =, <, >
Anuncio de grupo de anuncios	costPerConversion	Doble	!=, =, <, >
Anuncio de grupo de anuncios	clicks	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Anuncio de grupo de anuncios	averagePageViews	Doble	!=, =, <, >
Anuncio de grupo de anuncios	videoViews	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Anuncio de grupo de anuncios	allConversions	Doble	!=, =, <, >

Entidad	Campo	Tipo de datos	Operadores admitidos
Anuncio de grupo de anuncios	averageCpc	Doble	!=, =, <, >
Anuncio de grupo de anuncios	topImpressionPercentage	Doble	!=, =, <, >
Anuncio de grupo de anuncios	impresiones	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Anuncio de grupo de anuncios	absoluteTopImpressionPercentage	Doble	!=, =, <, >
Anuncio de grupo de anuncios	activeViewCtr	Doble	!=, =, <, >
Anuncio de grupo de anuncios	ctr	Doble	!=, =, <, >
Anuncio de grupo de anuncios	conversionAction	Cadena	!=, =
Anuncio de grupo de anuncios	conversionActionCategory	Cadena	!=, =
Anuncio de grupo de anuncios	conversionActionName	Cadena	!=, =, LIKE
Anuncio de grupo de anuncios	updateMask	Cadena	
Anuncio de grupo de anuncios	crear	Struct	
Anuncio de grupo de anuncios	actualización	Struct	
Anuncio de grupo de anuncios	policyValidationParameter	Struct	

Entidad	Campo	Tipo de datos	Operadores admitidos
Anuncio de grupo de anuncios	primaryStatus	Cadena	!=, =
Anuncio de grupo de anuncios	primaryStatusReasons	Enumeración	
Campaña	resourceName	Cadena	!=, =
Campaña	status	Cadena	!=, =
Campaña	baseCampaign	Cadena	!=, =
Campaña	nombre	Cadena	!=, =, LIKE
Campaña	id	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Campaña	campaignBudget	Cadena	!=, =, LIKE
Campaña	startDate	Date	BETWEEN, =, <, >, <=, >=
Campaña	endDate	Date	BETWEEN, =, <, >, <=, >=
Campaña	adServingOptimizationStatus	Cadena	!=, =
Campaña	advertisingChannelType	Cadena	!=, =
Campaña	advertisingChannelSubType	Cadena	!=, =
Campaña	experimentType	Cadena	!=, =
Campaña	servingStatus	Cadena	!=, =
Campaña	biddingStrategyType	Cadena	!=, =

Entidad	Campo	Tipo de datos	Operadores admitidos
Campaña	domainName	Cadena	!=, =, LIKE
Campaña	languageCode	Cadena	!=, =, LIKE
Campaña	useSuppliedUrlsOnly	Booleano	!=, =
Campaña	positiveGeoTargetType	Cadena	!=, =
Campaña	negativeGeoTargetType	Cadena	!=, =
Campaña	paymentMode	Cadena	!=, =
Campaña	optimizationGoalTypes	Enumeración	
Campaña	date	Date	BETWEEN, =, <, >, <=, >=
Campaña	averageCost	Doble	
Campaña	clicks	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Campaña	costMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Campaña	impresiones	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Campaña	useAudienceGrouped	Booleano	!=, =
Campaña	activeViewMeasurableCostMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Campaña	costPerAllConversions	Doble	!=, =, <, >

Entidad	Campo	Tipo de datos	Operadores admitidos
Campaña	costPerConversion	Doble	!=, =, <, >
Campaña	invalidClicks	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Campaña	publisherPurchasedClicks	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Campaña	averagePageViews	Doble	!=, =, <, >
Campaña	videoViews	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Campaña	allConversionsByConversionDate	Doble	!=, =, <, >
Campaña	allConversionsValueByConversionDate	Doble	!=, =, <, >
Campaña	conversionsByConversionDate	Doble	!=, =, <, >
Campaña	conversionsValueByConversionDate	Doble	!=, =, <, >
Campaña	valuePerAllConversionsByConversionDate	Doble	!=, =, <, >
Campaña	valuePerConversionsByConversionDate	Doble	!=, =, <, >
Campaña	allConversions	Doble	!=, =, <, >
Campaña	absoluteTopImpressionPercentage	Doble	!=, =, <, >

Entidad	Campo	Tipo de datos	Operadores admitidos
Campaña	searchAbsoluteTopImpressionShare	Doble	!=, =, <, >
Campaña	averageCpc	Doble	!=, =, <, >
Campaña	searchImpressionShare	Doble	!=, =, <, >
Campaña	searchTopImpressionShare	Doble	!=, =, <, >
Campaña	activeViewCtr	Doble	!=, =, <, >
Campaña	ctr	Doble	!=, =, <, >
Campaña	relativeCtr	Doble	!=, =, <, >
Campaña	updateMask	Cadena	
Campaña	crear	Struct	
Campaña	actualización	Struct	
Presupuesto de campaña	resourceName	Cadena	!=, =
Presupuesto de campaña	id	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Presupuesto de campaña	status	Cadena	!=, =
Presupuesto de campaña	deliveryMethod	Cadena	!=, =
Presupuesto de campaña	periodo	Cadena	!=, =

Entidad	Campo	Tipo de datos	Operadores admitidos
Presupuesto de campaña	type	Cadena	!=, =
Presupuesto de campaña	nombre	Cadena	!=, =, LIKE
Presupuesto de campaña	amountMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Presupuesto de campaña	explicitlyShared	Booleano	!=, =
Presupuesto de campaña	referenceCount	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Presupuesto de campaña	hasRecommendedBudget	Booleano	!=, =
Presupuesto de campaña	date	Date	BETWEEN, =, <, >, <=, >=
Presupuesto de campaña	costMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Presupuesto de campaña	startDate	Date	BETWEEN, =, <, >, <=, >=
Presupuesto de campaña	endDate	Date	BETWEEN, =, <, >, <=, >=
Presupuesto de campaña	maximizeConversionValueTargetRoas	Doble	!=, =, <, >
Presupuesto de campaña	maximizeConversionsTargetCpaMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Presupuesto de campaña	selectiveOptimizationConversionActions	Cadena	

Entidad	Campo	Tipo de datos	Operadores admitidos
Presupuesto de campaña	averageCost	Doble	!=, =, <, >
Presupuesto de campaña	costPerAllConversions	Doble	!=, =, <, >
Presupuesto de campaña	costPerConversion	Doble	!=, =, <, >
Presupuesto de campaña	videoViews	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Presupuesto de campaña	clicks	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Presupuesto de campaña	allConversions	Doble	!=, =, <, >
Presupuesto de campaña	valuePerAllConversions	Doble	!=, =, <, >
Presupuesto de campaña	averageCpc	Doble	!=, =, <, >
Presupuesto de campaña	impresiones	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Presupuesto de campaña	ctr	Doble	!=, =, <, >
Presupuesto de campaña	updateMask	Cadena	
Presupuesto de campaña	crear	Struct	
Presupuesto de campaña	actualización	Struct	

Consultas de partición

Puede proporcionar las opciones adicionales de Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` y `NUM_PARTITIONS` si quiere usar la simultaneidad en Spark. Con estos parámetros, la consulta original se dividiría en un número `NUM_PARTITIONS` de subconsultas que las tareas de Spark pueden ejecutar simultáneamente.

- `PARTITION_FIELD`: el nombre del campo que se usará para particionar la consulta.
- `LOWER_BOUND`: un valor de límite inferior inclusivo del campo de partición elegido.

  Para la fecha, aceptamos el formato de fecha de Spark que se usa en las consultas de Spark SQL. Ejemplos de valores válidos: `"2024-02-06"`.
- `UPPER_BOUND`: un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`: el número de particiones.

Los detalles de compatibilidad del campo de partición por entidad se capturaron en la siguiente tabla.

Nombre de la entidad	Campo de partición	Tipo de datos
Anuncio de grupo de anuncios	date	Date
Grupo de anuncios	date	Date
Campaña	date	Date
Presupuesto de campaña	date	Date

Ejemplo

```
googleads_read = glueContext.create_dynamic_frame.from_options(
    connection_type="googleads",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "campaign-3467***",
        "API_VERSION": "v16",
        "PARTITION_FIELD": "date"
        "LOWER_BOUND": "2024-01-01"
        "UPPER_BOUND": "2024-06-05"
```

```
        "NUM_PARTITIONS": "10"
    }
)
```

Opciones de conexión a Google Ads

Las siguientes son opciones de conexión para Google Ads:

- `ENTITY_NAME`(cadena): (obligatorio) se utiliza para leer y escribir. El nombre del objeto en Google Ads.
- `API_VERSION`(cadena): (obligatorio) se utiliza para leer y escribir. Versión de la API de Rest de Google Ads que desea utilizar. Ejemplo: v16.
- `DEVELOPER_TOKEN`(cadena): (obligatorio) se utiliza para leer y escribir. Se requiere para autenticar al desarrollador o a la aplicación que realiza solicitudes a la API.
- `MANAGER_ID`(cadena): se utiliza para leer y escribir. Un identificador único que permite administrar varias cuentas de Google Ads. Es el ID de cliente del administrador autorizado. Si el acceso a la cuenta de cliente se realiza a través de una cuenta de administrador, es obligatorio ingresar `MANAGER_ID`. Para obtener más información, consulte login-customer-id.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.
- `PARTITION_FIELD`(cadena): se usa para leer. Campo que se utilizará para particionar la consulta.
- `LOWER_BOUND`(cadena): se usa para leer. Un valor de límite inferior inclusivo del campo de partición elegido.
- `UPPER_BOUND`(cadena): se usa para leer. Un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`(entero): predeterminado: 1. Se usa para leer. Número de particiones para leer.

Crear una cuenta de Google Ads

1. Inicie sesión en la cuenta de desarrollador de Google Ads con sus credenciales y vaya a *Mi proyecto.

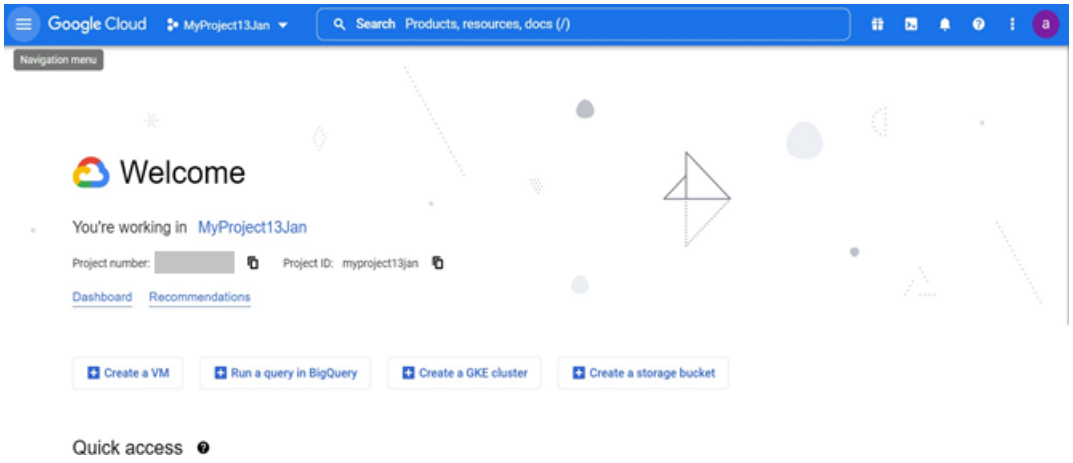

2. Seleccione Nuevo proyecto y proporcione la información necesaria para crear un proyecto de Google si no tiene ninguna aplicación registrada en él.

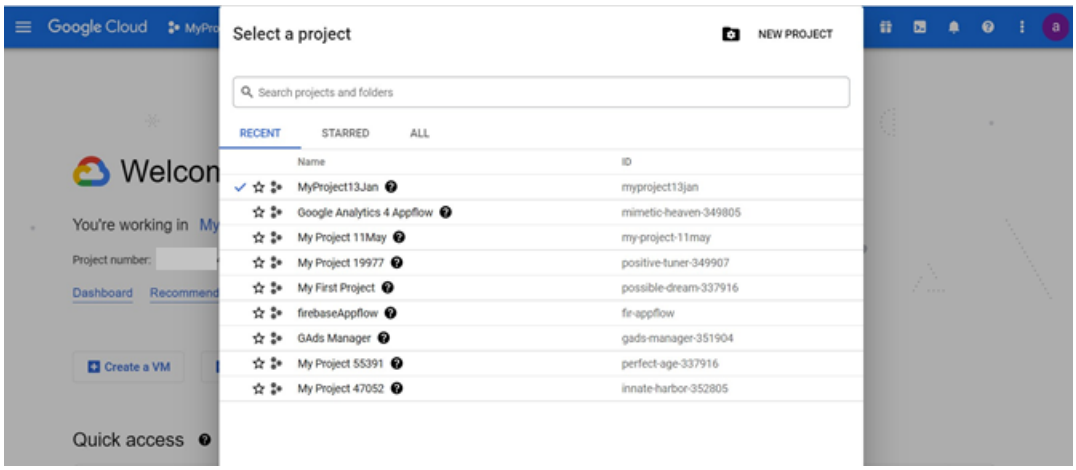

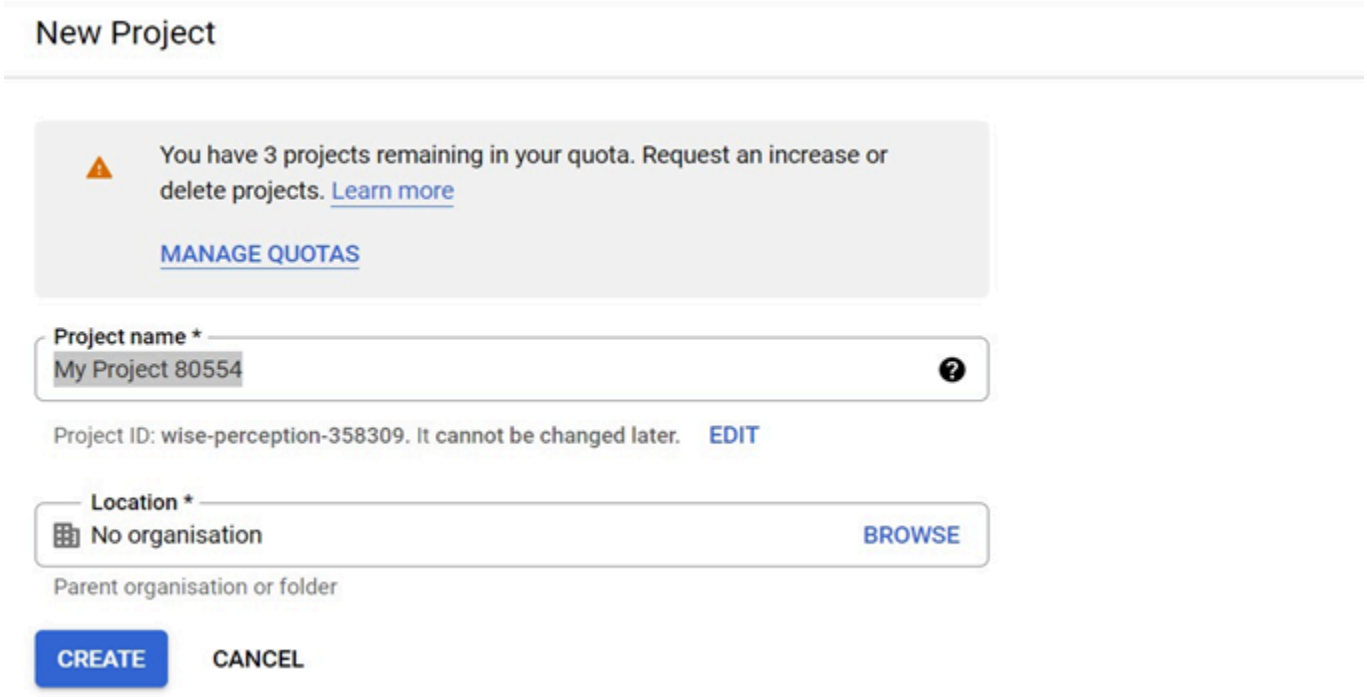

3. Elija la pestaña de navegación, luego API y configuración y Crear ID de cliente y ClientSecret, lo que requerirá una configuración adicional para crear una conexión entre AWS Glue y Google Ads. Para obtener más información, consulte Credenciales de API.

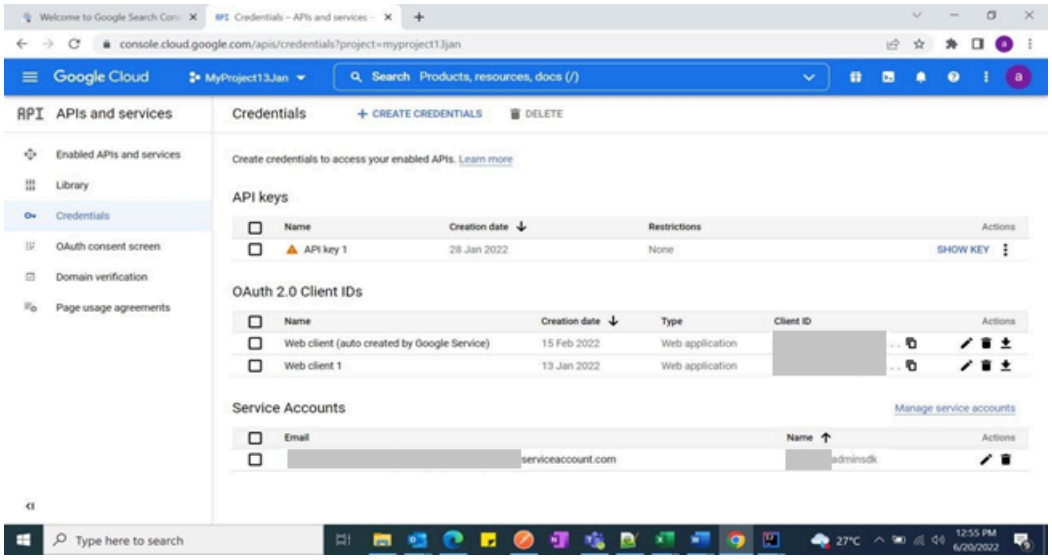

4. Elija CREAR CREDENCIALES y seleccione ID de cliente de OAuth.

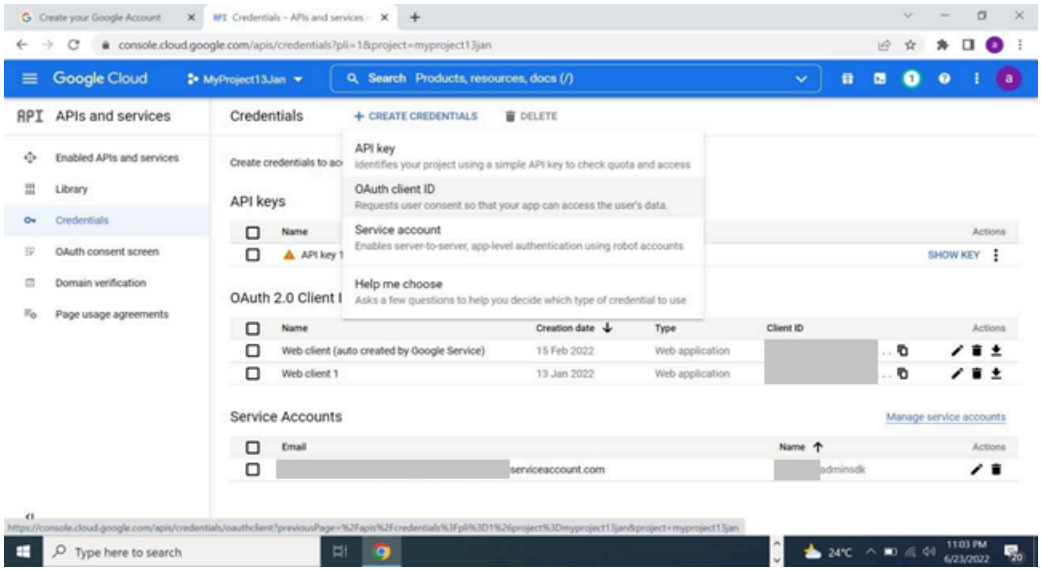

5. Seleccione Aplicación web en Tipo de aplicación.

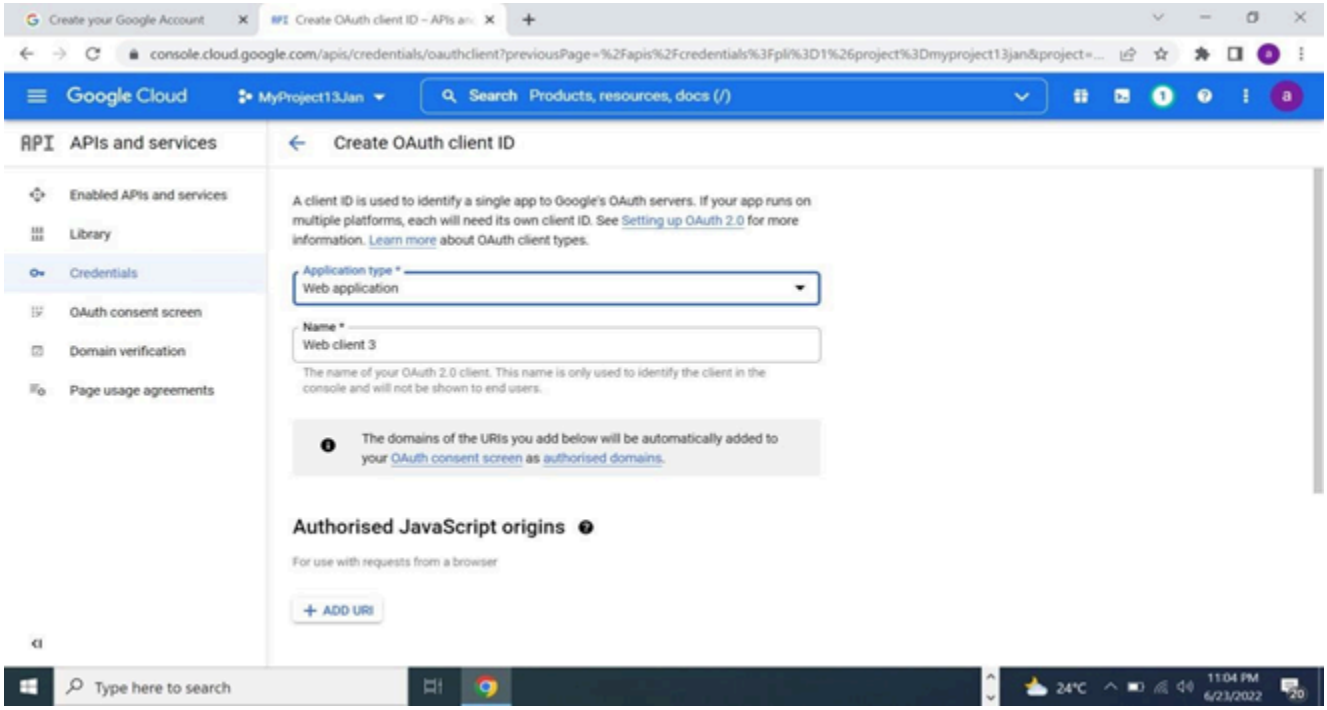

6. En URI de redireccionamiento autorizados, agregue los URI de redireccionamiento de OAuth y elija Crear. Puede agregar varios URI de redireccionamiento si es necesario.

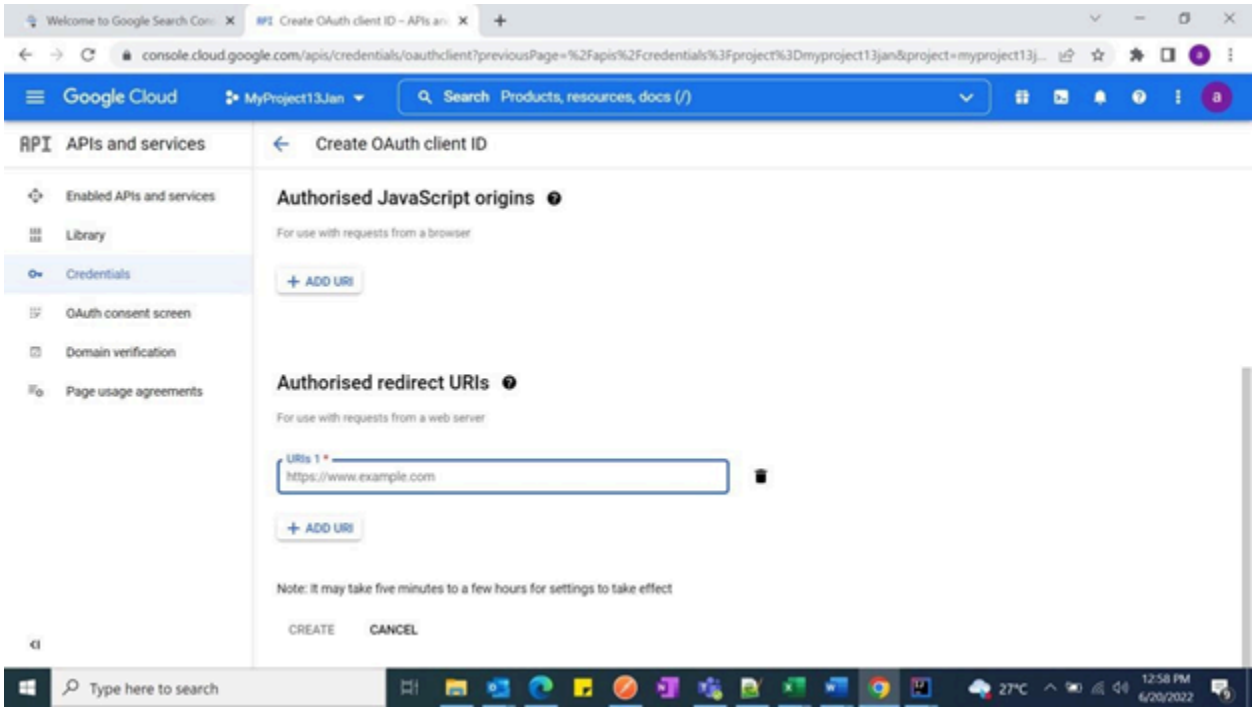

7. Su ID de cliente y su secreto de cliente se generarán al crear una conexión entre AWS Glue y Google Ads.

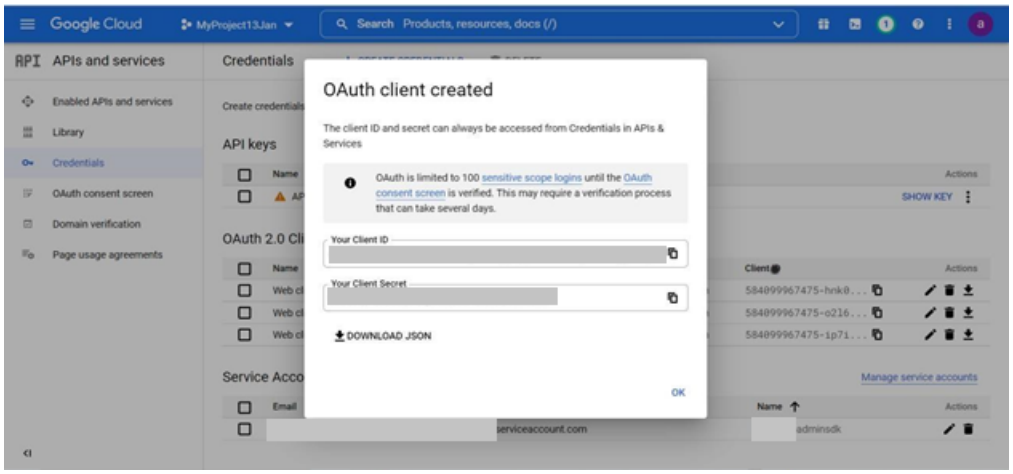

8. Agregue los ámbitos según las necesidades de su aplicación, seleccione la pantalla de consentimiento de OAuth y proporcione la información necesaria y agregue los ámbitos en función de los requisitos.

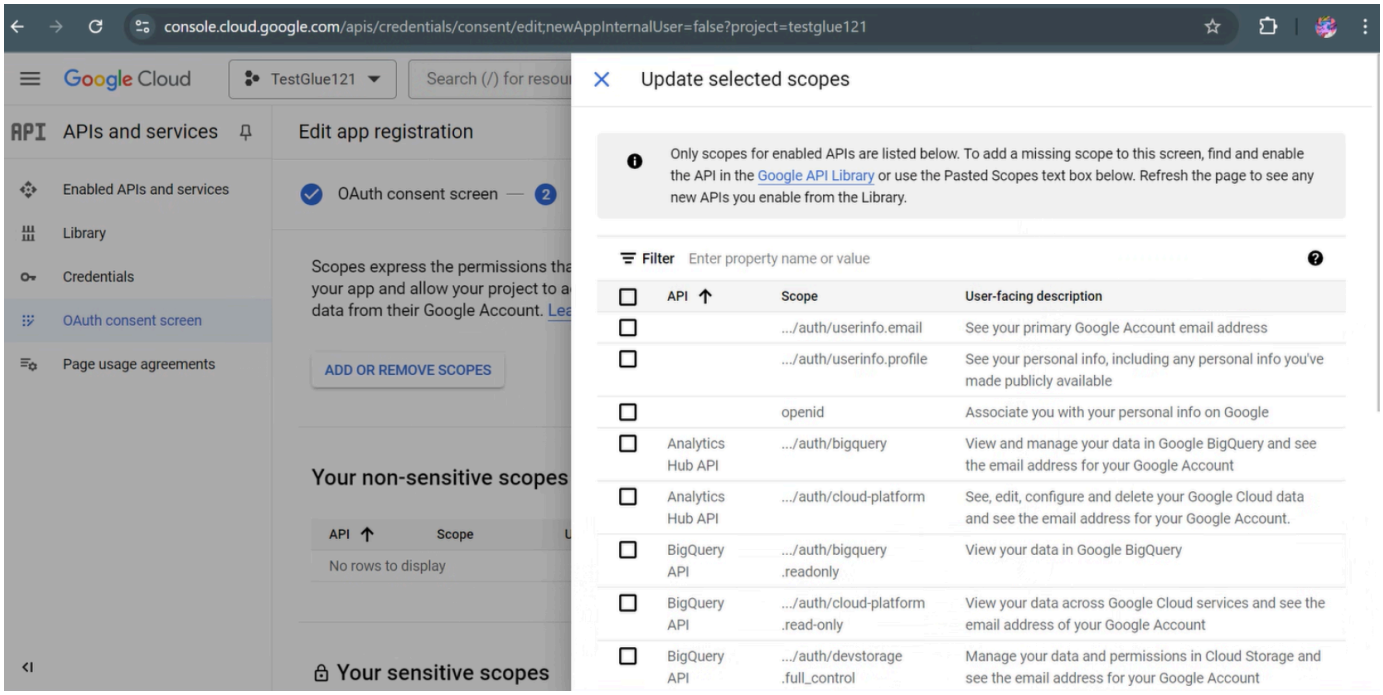

Limitaciones

Las siguientes son limitaciones para el conector de Google Ads:

- `MANAGER_ID` es una entrada opcional al crear una conexión. Sin embargo, cuando se quiere acceder a los clientes subyacentes a un administrador concreto, entonces es obligatorio ingresar `MANAGER_ID`. La siguiente tabla explica las limitaciones de acceso en función de si `MANAGER_ID` está incluido o no en una conexión.

¿Se proporcionó MANAGER_ID al crear la conexión?	Clientes accesibles
Sí	Los clientes que figuran en el MANAGER_ID proporcionado junto con el MANAGER_ID.
No	Aparecerán todos los clientes, pero no se podrá acceder a los clientes subyacentes a cualquier administrador.

- Cuando se elige una cuenta de administrador como objeto, únicamente aparecerá `Account` como subobjeto. En el conector de Google Ads, las entidades, como campañas, anuncios, etc., se recuperan en función de las cuentas de cliente individuales, no de la cuenta del administrador.

- No se pueden recuperar métricas para la cuenta de administrador. En su lugar, puede recuperar métricas para cuentas de clientes individuales.
- Cada cuenta puede tener hasta 10 000 campañas, incluidas las campañas activas y en pausa. Para obtener más información, consulte Límites de campañas y de grupos de anuncios.
- Al crear un informe, si selecciona determinadas métricas para mostrarlas, no se mostrará ninguna fila cuyas métricas seleccionadas sean todas cero. Para obtener más información, consulte Zero Metrics.
- Con los siguientes campos, el flujo de asignación completa no funcionará para las entidades Cuenta, Grupo de anuncios y Anuncio de grupo de anuncios, específicamente para conversionAction, conversionActionCategory, conversionActionName. Para obtener más información, consulte Segment and Metrics.
- El filtro de intervalo de fechas es obligatorio cuando se selecciona el campo `segments.date`.

Conexión a Google Analytics 4

Google Analytics 4 es un servicio de análisis que rastrea e informa las métricas relativas a las interacciones de los visitantes con sus aplicaciones y sitios web. Estas métricas incluyen las visitas a la página, los usuarios activos y los eventos. Si es usuario de Google Analytics 4, puede conectar AWS Glue a la cuenta de Google Analytics 4. Puede utilizar Google Analytics 4 como origen de datos en los trabajos de ETL. Ejecute estos trabajos para transferir datos entre Google Analytics 4 y los servicios de AWS u otras aplicaciones compatibles.

Temas

- Compatibilidad de AWS Glue con Google Analytics 4
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de Google Analytics 4
- Configuración de las conexiones de Google Analytics 4
- Lectura desde entidades de Google Analytics 4
- Opciones de conexión de Google Analytics 4
- Creación de una cuenta de Google Analytics 4
- Pasos para crear una aplicación cliente y credenciales de OAuth 2.0
- Limitaciones y consideraciones

Compatibilidad de AWS Glue con Google Analytics 4

AWS Glue es compatible con Google Analytics 4 de la siguiente manera:

¿Es compatible como origen?

Sí. Puede usar los trabajos de ETL de AWS Glue para consultar datos de Google Analytics 4.

¿Es compatible como destino?

No.

Versiones de la API de Google Analytics 4 compatibles

v1 Beta.

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

También puede usar las siguientes políticas de IAM administradas para permitir el acceso:

- AWSGlueServiceRole: concede acceso a los recursos que necesitan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: concede acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de Google Analytics 4

Antes de poder utilizar AWS Glue para transferir desde Google Analytics 4, deberá cumplir los siguientes requisitos:

Requisitos mínimos

- Tener una cuenta de Google Analytics con uno o más flujos de datos que recopilen los datos que desea transferir.
- Tener una cuenta de Google Cloud Platform y un proyecto de Google Cloud.
- Haber habilitado las siguientes API en el proyecto de Google Cloud:
  - API de Google Analytics
  - API de administración de Google Analytics
  - API de datos de Google Analytics
- Haber configurado en el proyecto de Google Cloud una pantalla de consentimiento OAuth para usuarios externos. Para obtener información acerca de la pantalla de consentimiento de OAuth, consulte Configuración de la pantalla de consentimiento de OAuth en la Ayuda de la Consola de Google Cloud Platform.
- Haber configurado un ID de cliente OAuth 2.0 en el proyecto de Google Cloud. Para obtener más información, consulte Configuración de OAuth 2.0.

Si cumple estos requisitos, estará listo para conectar AWS Glue a la cuenta de Google Analytics 4.

Configuración de las conexiones de Google Analytics 4

Para configurar una conexión a Google Sheets:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles. Es necesario crear un secreto para cada conexión en AWS Glue.
   a. Para el tipo de concesión AuthorizationCode:
      - En el caso de una aplicación conectada administrada por el cliente, el secreto debe contener el secreto del consumidor de la aplicación conectada con la clave `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET`.
2. En AWS Glue Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:
   a. Al seleccionar un Tipo de conexión, elija Google Analytics 4.
   b. Proporcione la `INSTANCE_URL` de Google Analytics 4 a la que se desea conectar.
   c. Seleccione el rol de IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

      JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

   d. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.

e. Seleccione las opciones de red si quiere usar su red.

3. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.

Tipo de concesión `AUTHORIZATION_CODE`.

Este tipo de concesión se considera un OAuth “de tres vías”, ya que se basa en redirigir a los usuarios al servidor de autorización externo para autenticar al usuario. Se utiliza para crear conexiones a través de la consola de AWS Glue. La consola de AWS Glue redirigirá al usuario a Google Analytics 4, donde deberá iniciar sesión y conceder a AWS Glue los permisos solicitados para acceder a la instancia de Google Analytics 4.

Los usuarios aún pueden optar por crear su propia aplicación conectada en Google Analytics 4 y proporcionar su propio ID y secreto de cliente al crear conexiones a través de la consola de AWS Glue. En este escenario, aún se abrirá Google Analytics 4 para iniciar sesión y autorizar a AWS Glue para que acceda a sus recursos.

Este tipo de concesión da como resultado un token de actualización y un token de acceso. El token de acceso es de corta duración y se puede actualizar automáticamente sin la interacción del usuario mediante el token de actualización.

Para obtener más información, consulte Uso de Auth 2.0 para acceder a las API de Google.

Lectura desde entidades de Google Analytics 4

Requisitos previos

- Un objeto de Google Analytics 4 desde el cual le gustaría leer. Consulte la tabla de entidades compatibles que aparece a continuación para comprobar las entidades disponibles.

Entidades compatibles

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite Partición
Informe en tiempo real	Sí	Sí	Sí	Sí	No

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite Partición
Informe principal	Sí	Sí	Sí	Sí	Sí

Ejemplo

```
googleAnalytics4_read = glueContext.create_dynamic_frame.from_options(
    connection_type="GoogleAnalytics4",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "API_VERSION": "v1beta"
    }
```

Detalles de entidades y campos de Google Analytics 4

Entidad	Campo	Tipo de datos	Operadores admitidos
Informe principal	Campos dinámicos		
Informe principal	Campos de dimensiones	Cadena	LIKE, =
Informe principal	Campos de dimensiones	Date	LIKE, =
Informe principal	Campos métricos	Cadena	>, <, >=, <=, = BETWEEN
Informe principal	Dimensiones personalizadas y campos métricos personalizados	Cadena	N/D
Informe en tiempo real	AppVersion	Cadena	LIKE, =

Entidad	Campo	Tipo de datos	Operadores admitidos
Informe en tiempo real	audienceId	Cadena	LIKE, =
Informe en tiempo real	audienceName	Cadena	LIKE, =
Informe en tiempo real	ciudad	Cadena	LIKE, =
Informe en tiempo real	cityId	Cadena	LIKE, =
Informe en tiempo real	país	Cadena	LIKE, =
Informe en tiempo real	countryId	Cadena	LIKE, =
Informe en tiempo real	deviceCategory	Cadena	LIKE, =
Informe en tiempo real	eventName	Cadena	LIKE, =
Informe en tiempo real	minutesAgo	Cadena	LIKE, =
Informe en tiempo real	platform	Cadena	LIKE, =
Informe en tiempo real	streamId	Cadena	LIKE, =
Informe en tiempo real	streamName	Cadena	LIKE, =
Informe en tiempo real	unifiedScreenName	Cadena	LIKE, =

Entidad	Campo	Tipo de datos	Operadores admitidos
Informe en tiempo real	activeUsers	Cadena	>, <, >=, <=, = BETWEEN
Informe en tiempo real	conversions	Cadena	>, <, >=, <=, = BETWEEN
Informe en tiempo real	eventCount	Cadena	>, <, >=, <=, = BETWEEN
Informe en tiempo real	screenPageViews	Cadena	>, <, >=, <=, = BETWEEN

Consultas de partición

1. Partición basada en filtros

   Puede proporcionar las opciones adicionales de Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` y `NUM_PARTITIONS` si quiere usar la simultaneidad en Spark. Con estos parámetros, la consulta original se dividiría en un número `NUM_PARTITIONS` de subconsultas que las tareas de Spark pueden ejecutar simultáneamente.

   - `PARTITION_FIELD`: el nombre del campo que se usará para particionar la consulta.
   - `LOWER_BOUND`: un valor de límite inferior inclusivo del campo de partición elegido.

     Para la fecha, aceptamos el formato de fecha de Spark que se usa en las consultas de Spark SQL. Ejemplos de valores válidos: `"2024-02-06"`.
   - `UPPER_BOUND`: un valor límite superior exclusivo del campo de partición elegido.
   - `NUM_PARTITIONS`: el número de particiones.

   Ejemplo

```
googleAnalytics4_read = glueContext.create_dynamic_frame.from_options(
    connection_type="GoogleAnalytics4",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "API_VERSION": "v1beta",
```

```
        "PARTITION_FIELD": "date"
        "LOWER_BOUND": "2022-01-01"
        "UPPER_BOUND": "2024-01-02"
        "NUM_PARTITIONS": "10"
    }
```

2. Partición basada en registros

   Puede proporcionar las opciones adicionales de Spark `NUM_PARTITIONS` si quiere usar la simultaneidad en Spark. Con estos parámetros, la consulta original se dividiría en un número `NUM_PARTITIONS` de subconsultas que las tareas de Spark pueden ejecutar simultáneamente.

   - `NUM_PARTITIONS`: el número de particiones.

   Ejemplo

```
googleAnalytics4_read = glueContext.create_dynamic_frame.from_options(
    connection_type="GoogleAnalytics4",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "API_VERSION": "v1beta",
        "NUM_PARTITIONS": "10"
    }
```

Opciones de conexión de Google Analytics 4

Las siguientes son opciones de conexión para Google Analytics 4:

- `ENTITY_NAME`(cadena): (obligatorio) se usa para lectura. El nombre del objeto en Google Analytics 4.
- `API_VERSION`(cadena): (obligatorio) se usa para lectura. Versión de la API de Rest de Google Analytics 4 que desea utilizar.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.
- `PARTITION_FIELD`(cadena): se usa para leer. Campo que se utilizará para particionar la consulta.

- `LOWER_BOUND`(cadena): se usa para leer. Un valor de límite inferior inclusivo del campo de partición elegido.
- `UPPER_BOUND`(cadena): se usa para leer. Un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`(entero): predeterminado: 1. Se usa para leer. Número de particiones para leer.
- `INSTANCE_URL`(Entero): se utiliza para la lectura. (Opcional)

Creación de una cuenta de Google Analytics 4

Siga los pasos para crear una cuenta de Google Analytics 4: https://support.google.com/analytics/answer/9304153?hl=en

Pasos para crear una aplicación cliente y credenciales de OAuth 2.0

Para obtener más información, consulte la documentación de la API de Google Analytics4.

1. Cree y configure su cuenta; para ello, inicie sesión en la cuenta de Google Analytics con sus credenciales. A continuación, vaya a Administración > Crear cuenta.
2. Cree una propiedad para la cuenta que ha creado; para ello, elija Crear propiedad. Configure la propiedad con los detalles necesarios. Una vez proporcionados todos los detalles, se generará el identificador de propiedad correspondiente.
3. Agregue un flujo de datos para la propiedad creada al seleccionar Flujos de datos > Agregar flujo > Web en el menú desplegable. Proporcione los detalles del sitio web, como la URL y otros campos obligatorios. Después de proporcionar todos los detalles, se generarán el ID de flujo y el ID de medición correspondientes.
4. Configure Google Analytics en su sitio web al copiar el ID de medición y agregarlo a la configuración de su sitio web.
5. Para crear un informe desde Google Analytics, diríjase a Informes y genere el informe correspondiente.
6. Para autorizar su aplicación, diríjase a console.cloud.google.com, busque la API de datos de Google Analytics y, a continuación, active la API.

    1. Vaya a la página de API y servicios y seleccione Credenciales > Configurar los ID de cliente de OAuth 2.0.
    2. Proporcione la URL de redireccionamiento; para ello, agregue la URL de redireccionamiento de AWS Glue.

7. Copie el ID y el secreto del cliente, que necesitará para crear la conexión.

Limitaciones y consideraciones

A continuación, se indican las limitaciones del conector de Google Analytics 4:

- Para la entidad Informe principal, solo se permite enviar una solicitud con 9 campos de dimensiones y 10 campos de métricas. Si se supera el número de campos permitido, la solicitud fallará y el conector mostrará un mensaje de error.
- Para la entidad Informe en tiempo real, solo se permite enviar una solicitud con 4 campos de dimensiones. Si se supera el número de campos permitido, la solicitud fallará y el conector mostrará un mensaje de error.
- Google Analytics 4 es una herramienta gratuita en versión beta, por lo que habrá actualizaciones periódicas sobre nuevas características, mejoras de entidades, adición de nuevos campos y eliminación de campos existentes.
- Los campos del Informe principal se completan dinámicamente, por lo que se pueden agregar, eliminar y cambiar el nombre de los campos. Además, se pueden imponer nuevos límites a los campos en cualquier momento.
- La fecha de inicio predeterminada es de 30 días y la fecha de finalización es ayer (un día antes de la fecha actual). Estas fechas se anularán en el código de expresión del filtro si el usuario ha establecido el valor o si el flujo es incremental.
- Según la documentación, la entidad Informe en tiempo real devuelve 10 000 registros si no se establece un límite en la solicitud; de lo contrario, la API devuelve un máximo de 250 000 filas por solicitud, independientemente del número que solicite. Para obtener más información, consulte Método: properties.runRealtimeReport en la documentación de Google Analytics.
- La entidad Informe en tiempo real no admite la partición basada en registros, ya que no admite la paginación. Además, no admite la partición basada en campos, ya que ninguno de los campos cumple con los criterios definidos.
- Debido a la limitación del número de campos que se pueden enviar en una solicitud. Estamos configurando los campos de dimensiones y métricas predeterminados dentro de los límites designados. Si elige “seleccionar todo”, solo se recuperarán los datos de esos campos predeterminados.
  - Informe principal

    - Según la limitación del SAAS, se permiten solicitudes de hasta 9 dimensiones y solo hasta 10 métricas; es decir, una solicitud puede contener un máximo de 19 campos (métricas + dimensión).
    - Según la implementación, si el usuario utiliza SELECT_ALL o selecciona más de 25 campos, se enviarán los campos predeterminados en la solicitud.
    - Los siguientes campos se consideran campos predeterminados para el Informe principal: “country”, “city”, “eventName”, “cityId”, “browser”, “date”, “currencyCode”, “deviceCategory”, “transactionId”, “active1DayUsers”, “active28DayUsers”, “active7DayUsers”, “activeUsers”, “averagePurchaseRevenue”, “averageRevenuePerUser”, “averageSessionDuration”, “engagedSessions”, “eventCount”, “engagementRate”.
  - Informe en tiempo real
    - Según la limitación del SAAS, se permiten solicitudes de hasta 4 dimensiones.
    - Si el usuario pasa SELECT_ALL o selecciona más de 15 campos, los campos predeterminados se enviarán en la solicitud.
    - Los siguientes campos se consideran campos predeterminados para el Informe en tiempo real: “country”, “deviceCategory”, “city”, “cityId”, “activeUsers”, “conversions”, “eventCount”, “screenPageViews”.
- En la entidad Informe principal, si la partición en el campo de fecha y el filtro en startDate están presentes simultáneamente. En ese caso, el valor dateRange se reemplaza por el valor del filtro startDate, pero, dado que la partición siempre debe ser la prioridad, se descarta el filtro startDate si la partición en el campo de fecha ya está presente.
- Como ahora cohortSpecs también forma parte del cuerpo de la solicitud del informe principal, hemos mejorado la entidad del informe principal actual para incluir la compatibilidad con el atributo cohortSpec. En el cuerpo de la solicitud de cohortSpecs, casi todos los campos requieren la entrada del usuario. Para solucionar este problema, hemos establecido valores predeterminados para esos atributos/campos y hemos previsto que el usuario anule estos valores si es necesario.

FieldName	Valores predeterminados	Ejemplo de consulta para enviar las opciones de filterPredicate a fin de anular los valores predeterminados
startDate	30 días a partir de la fecha actual	"startDate between "2023-05-09" and "2023-05-10"

FieldName	Valores predeterminados	Ejemplo de consulta para enviar las opciones de filterPredicate a fin de anular los valores predeterminados
endDate	1 día a partir de la fecha actual	"startDate between "2023-05-09" and "2023-05-10"
startOffset	0	startOffset=2
endOffset	1	endOffset=10
Grado de detalle	DAILY	granularity="WEEKLY"

- También puede enviar todos estos filtros a la vez o con otros filtros.
  - Ejemplo 1: filterPredicate: startDate between "2023-05-09" and "2023-05-10" AND startOffset=1 AND endOffset=2 AND granularity="WEEKLY"
  - Ejemplo 2: filterPredicate: city="xyz" AND startOffset=1 AND endOffset=2 AND granularity="WEEKLY"
- En la solicitud de cohorte:
  - Si se incluye "cohortNthMonth" en la solicitud, el valor de granularidad interno se establecerá como "MONTHLY"
  - Del mismo modo, si se pasa "cohortNthWeek", el valor de granularidad se establecerá como "WEEKLY"
  - Y, para "cohortNthDay", el valor de granularidad se establecerá como "DAILY". Para obtener más información, consulte:
    - https://developers.google.com/analytics/devguides/reporting/data/v1/advanced
    - https://developers.google.com/analytics/devguides/reporting/data/v1/rest/v1beta/CohortSpec
  - Se prevé que el usuario anule el valor predeterminado de dateRange y de granularidad. Consulte la tabla anterior.

Conexión a Google BigQuery en AWS Glue Studio

> **Note**

Puede usar AWS Glue para Spark para leer y escribir en tablas de Google BigQuery en AWS Glue 4.0 y versiones posteriores. Para configurar Google BigQuery con trabajos de AWS Glue mediante programación, consulte Conexiones de BigQuery.

AWS Glue Studio proporciona una interfaz visual para conectarse a BigQuery, crear trabajos de integración de datos y ejecutarlos en el tiempo de ejecución de Spark sin servidor de AWS Glue Studio.

Al crear una conexión a Google BigQuery en AWS Glue Studio, se crea una conexión unificada. Para obtener más información, consulte Consideraciones.

En lugar de crear un secreto con las credenciales en un formato específico, `{"credentials": "base64 encoded JSON"}`; ahora, a través de una conexión unificada a Google BigQuery, es posible crear un secreto que incluya directamente el JSON de Google BigQuery: `{"type": "service-account", ...}`.

Temas

- Crear una conexión con BigQuery
- Crear un nodo de origen de BigQuery
- Creación de un nodo de destino de BigQuery
- Opciones avanzadas

Crear una conexión con BigQuery

Para conectarse a Google BigQuery desde AWS Glue, tendrá que generar y almacenar las credenciales de Google Cloud Platform en un secreto de AWS Secrets Manager y, a continuación, asociar ese secreto a una conexión de Google BigQuery AWS Glue.

Para configurar una conexión a BigQuery, siga estos pasos:

1. En Google Cloud Platform, genere e identifique los recursos pertinentes:
   - Genere e identifique un proyecto de GCP que contenga tablas de BigQuery a las que desea conectarse.
   - Habilite la API de BigQuery. Para obtener más información, consulte Cómo usar la API de lectura de almacenamiento de BigQuery para leer datos de tablas.
2. En Google Cloud Platform, genere y exporte las credenciales de la cuenta de servicio:

Puede usar el asistente de credenciales de BigQuery para simplificar este paso: Crear credenciales.

Para crear una cuenta de servicio en GCP, siga el tutorial disponible en Crear cuentas de servicio.

- Al elegir un proyecto, seleccione el proyecto que contiene su tabla de BigQuery.
- Cuando elija los roles de IAM de GCP para la cuenta de servicio, agregue o genere una función que conceda los permisos apropiados para ejecutar los trabajos en BigQuery, como la lectura, escritura o creación de tablas de BigQuery.

Para crear credenciales para la cuenta de servicio, siga el tutorial disponible en Crear una clave de cuenta de servicio.

- Al seleccionar el tipo de clave, seleccione JSON.

Ahora debería haber descargado un archivo JSON que contiene las credenciales de la cuenta de servicio. Debería parecerse a lo que sigue:

```
{
  "type": "service_account",
  "project_id": "*****",
  "private_key_id": "*****",
  "private_key": "*****",
  "client_email": "*****",
  "client_id": "*****",
  "auth_uri": "https://accounts.google.com/o/oauth2/auth",
  "token_uri": "https://oauth2.googleapis.com/token",
  "auth_provider_x509_cert_url": "https://www.googleapis.com/oauth2/v1/certs",
  "client_x509_cert_url": "*****",
  "universe_domain": "googleapis.com"
}
```

3. En AWS Secrets Manager, cree un secreto con el archivo de credenciales que descargó. Puede elegir la pestaña Texto no cifrado y pegar el contenido del archivo con formato JSON. Para crear un secreto en Secrets Manager, siga el tutorial disponible en Crear un secreto AWS Secrets Manager en la documentación AWS Secrets Manager. Después de crear el secreto, conserve el nombre secreto, *secretName*, para el siguiente paso.

4. En el Catálogo de datos de AWS Glue, genere una conexión mediante los pasos que se indican en https://docs.aws.amazon.com/glue/latest/dg/console-connections.html. Tras crear la conexión, conserve el nombre de la conexión, *connectionName*, para el siguiente paso.

   - Cuando elija un Tipo de conexión, seleccione Google BigQuery.
   - Al seleccionar un secreto AWS, proporcione un *secretName*.

5. Otorga permiso al rol de IAM asociado al trabajo de AWS Glue para leer el *secretName*.
6. En la configuración del trabajo de AWS Glue, proporcione un *connectionName* como una Conexión de red adicional.

Crear un nodo de origen de BigQuery

Requisitos previos necesarios

- Una conexión del Catálogo de datos de AWS Glue tipo BigQuery
- Un secreto de AWS Secrets Manager de las credenciales de Google BigQuery, que utiliza la conexión.
- Permisos adecuados en el trabajo para leer el secreto utilizado por la conexión.
- El nombre y el conjunto de datos de la tabla y el proyecto de Google Cloud correspondiente que quiere leer.

Agregar un origen de datos de BigQuery

Para agregar un nodo de Origen de datos: BigQuery:

1. Elija la conexión para el origen de datos de BigQuery. Dado que lo ha creado, debería estar disponible en el menú desplegable. Si es necesario crear una conexión, elija Crear conexión de BigQuery. Para más información, consulte Información general sobre el uso de conectores y conexiones.

   Una vez que haya elegido una conexión, puede ver las propiedades de la conexión mediante un clic en Ver propiedades.

2. Identifique qué datos de BigQuery desea leer y, a continuación, elija una opción de origen de BigQuery

   - Elegir una sola tabla: permite extraer todos los datos de una tabla.

- Introducir una consulta personalizada: permite personalizar los datos que se van a recuperar mediante una consulta.

3. Describa los datos que desea leer

   (Obligatorio) defina el Proyecto principal como el proyecto que contiene la tabla o un proyecto principal de facturación, si corresponde.

   Si ha elegido una sola tabla, establezca Tabla con el nombre de una tabla de Google BigQuery en el siguiente formato: `[dataset].[table]`

   Si ha elegido una consulta, envíela a Consulta. En su consulta, consulte las tablas con su nombre de tabla completo, en el formato: `[project].[dataset].[tableName]`.

4. Proporcionar las propiedades de BigQuery

   Si ha elegido una sola tabla, no será necesario proporcionar propiedades adicionales.

   Si eligió una consulta, debe proporcionar las siguientes Propiedades personalizadas de Google BigQuery:

   - Establezca `viewsEnabled` en true.
   - Establezca `materializationDataset` en un conjunto de datos. La entidad principal de GCP autenticada por las credenciales proporcionadas a través de la conexión de AWS Glue debe poder crear tablas en este conjunto de datos.

Creación de un nodo de destino de BigQuery

Requisitos previos necesarios

- Una conexión del Catálogo de datos de AWS Glue tipo BigQuery
- Un secreto de AWS Secrets Manager de las credenciales de Google BigQuery, que utiliza la conexión.
- Permisos adecuados en el trabajo para leer el secreto utilizado por la conexión.
- El nombre y el conjunto de datos de la tabla y el proyecto de Google Cloud correspondiente al que desea escribir.

Agregar un destino de datos de BigQuery

Para agregar un nodo de Destino de datos: BigQuery, siga estos pasos:

1. Elija la conexión para el destino de datos de BigQuery. Dado que lo ha creado, debería estar disponible en el menú desplegable. Si es necesario crear una conexión, elija Crear conexión de BigQuery. Para más información, consulte Información general sobre el uso de conectores y conexiones.

   Una vez que haya elegido una conexión, puede ver las propiedades de la conexión mediante un clic en Ver propiedades.
2. Identifique en qué tabla de BigQuery desea escribir y, a continuación, elija un Método de escritura.

   - Directo: escribe en BigQuery directamente mediante la API de escritura de BigQuery Storage.
   - Indirecto: escribe en Google Cloud Storage y, luego, copia en BigQuery.

   Si quiere escribir de forma indirecta, proporcione una ubicación de GCS de destino con un bucket de GCS temporal. Deberá proporcionar una configuración adicional en la conexión de AWS Glue. Para obtener más información, consulte Uso de escritura indirecta con Google BigQuery.
3. Describa los datos que desea leer

   (Obligatorio) defina el Proyecto principal como el proyecto que contiene la tabla o un proyecto principal de facturación, si corresponde.

   Si ha elegido una sola tabla, establezca Tabla con el nombre de una tabla de Google BigQuery en el siguiente formato: `[dataset].[table]`

Opciones avanzadas

Puede brindar opciones avanzadas al crear un nodo de BigQuery. Estas opciones son las mismas que las disponibles cuando se programa AWS Glue para scripts de Spark.

Consulte la referencia sobre las opciones de conexión de BigQuery en la guía para desarrolladores de AWS Glue.

Conexión a Google Search Console

Google Search Console es una plataforma gratuita diseñada para que los propietarios de sitios web supervisen cómo Google percibe su sitio y optimicen su presencia en los resultados orgánicos. Esto incluye la visualización de los dominios de referencia, el rendimiento del sitio en dispositivos móviles, los resultados de búsqueda enriquecidos, así como las consultas y páginas con mayor tráfico. Si es usuario de Google Search Console, puede conectar AWS Glue a la cuenta de Google Search Console. Puede utilizar Google Search Console como origen de datos en los trabajos de ETL. Ejecute estos trabajos para transferir datos entre Google Search Console y los servicios de AWS u otras aplicaciones compatibles.

Temas

- Compatibilidad de AWS Glue con Google Search Console
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de Google Search Console
- Configuración de las conexiones a Google Search Console
- Cómo leer de entidades de Google Search Console
- Opciones de conexión de Google Search Console
- Limitaciones de Google Search Console

Compatibilidad de AWS Glue con Google Search Console

AWS Glue es compatible con Google Search Console de la siguiente manera:

¿Es compatible como origen?

Sí. Puede usar los trabajos de ETL de AWS Glue para consultar datos de Google Search Console.

¿Es compatible como destino?

No.

Versiones de la API de Google Search Console compatibles

Se admiten las siguientes versiones de la API de Google Search Console:

- v3

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS IAM necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si no desea utilizar el método anterior, puede utilizar las siguientes políticas de IAM administradas:

- AWSGlueServiceRole: da acceso a recursos que precisan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: otorga acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la Consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de Google Search Console

Antes de poder utilizar AWS Glue para transferir datos desde Google Search Console, deberá cumplir estos requisitos:

Requisitos mínimos

Los requisitos mínimos son los siguientes:

- Tener una cuenta de Google Search Console.
- Tener una cuenta de Google Cloud Platform y un proyecto de Google Cloud.
- Haber habilitado la API de Google Search Console en el proyecto de Google Cloud.
- Haber configurado en el proyecto de Google Cloud una pantalla de consentimiento OAuth para usuarios externos. Para obtener más información, consulte Configuración de la pantalla de consentimiento de OAuth en la Ayuda de la Consola de Google Cloud Platform.
- Haber configurado un ID de cliente OAuth 2.0 en el proyecto de Google Cloud. Consulte Configuración de OAuth 2.0 para conocer las credenciales de cliente que AWS Glue utiliza para acceder a los datos de forma segura cuando realiza llamadas autenticadas a la cuenta.

Si cumple estos requisitos, estará listo para conectar AWS Glue a la cuenta de Google Search Console. Para conexiones típicas, no necesita hacer nada más en Google Search Console.

Configuración de las conexiones a Google Search Console

Google Search Console admite el tipo de concesión AUTHORIZATION_CODE para OAuth2. El tipo de concesión determina la forma en que AWS Glue se comunica con Google Search Console para solicitar acceso a los datos.

- Este tipo de concesión se considera un OAuth de “tres vías”, ya que se basa en redirigir a los usuarios a un servidor de autorización externo para autenticar al usuario. Se utiliza para crear conexiones a través de la consola de AWS Glue.
- Los usuarios aún pueden optar por crear una aplicación conectada propia en Google Search Console y proporcionar un identificador de cliente y un secreto de cliente propios al crear conexiones a través de la consola de AWS Glue. En este caso, aún serán redirigidos a Google Search Console para iniciar sesión y autorizar a AWS Glue a acceder a sus recursos.
- Este tipo de concesión da como resultado un token de actualización y un token de acceso. El token de acceso es de corta duración y se puede actualizar automáticamente sin la interacción del usuario mediante el token de actualización.

- Para consultar la documentación pública de Google Search Console sobre la creación de una aplicación conectada para el flujo OAuth del código de autorización, consulte Uso de OAuth 2.0 para acceder a las API de Google.

Para configurar una conexión a Google Search Console:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles:
   a. En el caso de las aplicaciones conectadas administradas por el cliente, el secreto debe contener el secreto del consumidor de la aplicación conectada con `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET` como clave.
   b. Nota: Debe crear un secreto para las conexiones en AWS Glue.

1. En AWS Glue Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:
   a. Cuando elija un Tipo de conexión, seleccione Google Search Console.
   b. Seleccione el rol de AWS IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

      JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

c. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.

d. Seleccione las opciones de red si quiere usar su red.

2. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.

Cómo leer de entidades de Google Search Console

Requisito previo

Un objeto de Google Search Console desde el cual le gustaría leer. Necesitará el nombre del objeto.

Entidades compatibles como origen:

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Análisis de búsqueda	Sí	Sí	No	Sí	No
Sitios	No	No	No	Sí	No
Mapas del sitio	No	No	No	Sí	No

Ejemplo:

```
googleSearchConsole_read = glueContext.create_dynamic_frame.from_options(
    connection_type="googlesearchconsole",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "API_VERSION": "v3"
    }
```

Detalles de la entidad y el campo de Google Search Console:

Google Search Console proporciona puntos de conexión para obtener metadatos de forma dinámica para las entidades compatibles. Por lo tanto, la compatibilidad del operador se captura según el tipo de datos.

Entidad	Campo	Tipo de datos:	Operadores admitidos	Nota
Análisis de búsqueda	claves	Enumeración	N/A	
	clicks	Doble	N/A	
	impresiones	Doble	N/A	
	ctr	BigDecimal	N/A	Para el tipo de datos BigDecimal, el valor “0” tiene el formato “0E-18”
	position	Doble	N/A	
	start_end_date	Date	BETWEEN	El valor predeterminado de `start_end_date` está comprendido entre <hace 30 días desde la fecha actual> Y <ayer: es decir, hace 1 día desde la fecha actual> Nota: Espera que transmita un valor de fecha en UTC. Ejemplo: start_end_date comprendido entre “01/01/20

Entidad	Campo	Tipo de datos:	Operadores admitidos	Nota
				22” Y “09/09/2024”
	país	Cadena	EQUAL_TO, NOT_EQUAL_TO, CONTAINS	Los valores válidos son “IND”, “CAN”, etc.
	type	Cadena	EQUAL_TO, NOT_EQUAL_TO	Los valores válidos son “discover”, “googleNews”, “news”, “image”, “video”, “web”
	searchAppearance	Cadena	EQUAL_TO, NOT_EQUAL_TO, CONTAINS	Consulte Aspecto de la búsqueda para ver una lista de valores válidos.
	device	Cadena	EQUAL_TO, NOT_EQUAL_TO, CONTAINS	Los valores válidos son “DESKTOP”, “MOBILE”, “TABLET”
	dimensiones	Cadena	EQUAL_TO	Los valores válidos son “country”, “device”
	page	Cadena	EQUAL_TO, NOT_EQUAL_TO, CONTAINS	

Entidad	Campo	Tipo de datos:	Operadores admitidos	Nota
	consulta	Cadena	EQUAL_TO, NOT_EQUAL _TO, CONTAINS	
	dataState	Cadena	EQUAL_TO	Los valores válidos son “all” y “final”
Sitios	siteUrl	Cadena	N/A	
	permissionLevel	Cadena	N/A	
Mapas del sitio	path	Cadena	N/A	
	type	Cadena	N/A	
	lastSubmitted	DateTime	N/A	
	isPending	Booleano	N/A	
	isSitemapsIndex	Booleano	N/A	
	lastDownloaded	DateTime	N/A	
	advertencias	Largo	N/A	
	errores	Largo	N/A	
	contenido	Enumeración	N/A	

> **Note**
>
> Para obtener una lista actualizada de los valores válidos para los filtros, consulte la documentación de la API de Google Search Console.
> El campo `start_end_date` es una combinación de `start_date` y `end_date`.

Consultas de partición

No se admiten las particiones basadas en filtros ni las particiones basadas en registros.

Opciones de conexión de Google Search Console

A continuación se indican las opciones de conexión de Google Search Console:

- `ENTITY_NAME`(cadena): (obligatorio) se usa para lectura. El nombre del objeto en Google Search Console.
- `API_VERSION`(cadena): (obligatorio) se usa para lectura. Versión de la API de Rest de Google Search Console que desea utilizar.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- `FILTER_PREDICATE` (cadena): Valor predeterminado: “start_end_date entre <hace 30 días de la fecha actual> Y <ayer: es decir, hace 1 día desde la fecha actual>”. Se usa para leer. Debe estar en el formato de Spark SQL.
- `QUERY` (cadena): Valor predeterminado: “start_end_date entre <hace 30 días de la fecha actual> Y <ayer: es decir, hace 1 día de la fecha actual>”. Se utiliza para leer. Consulta completa de Spark SQL.
- `INSTANCE_URL`(cadena): se usa para leer. Una URL de instancia de Google Search Console válida.

Limitaciones de Google Search Console

Las siguientes son limitaciones o notas de Google Search Console:

- Google Search Console aplica límites de uso a la API. Para obtener más información, consulte Límites de uso.
- Cuando no se transmite ningún filtro de la entidad de `Search Analytics`, la API suma todos los clics, impresiones, CTR y otros datos de todo el sitio dentro del intervalo de fechas predeterminado especificado y los presenta como un único registro.
- Para desglosar los datos en segmentos más pequeños, es necesario introducir dimensiones en la consulta. Dimensiones indica a la API cómo desea segmentar los datos.
  - Por ejemplo, si agrega `filterPredicate: dimensions="country"` obtendrá un registro por cada país en el que el sitio haya recibido tráfico durante el periodo especificado.

  - Ejemplo para transmitir varias dimensiones: `filterPredicate: dimensions="country" AND dimensions="device" AND dimensions="page"`. En este caso, obtendrá una fila en la respuesta por cada combinación única de estas tres dimensiones.
- Los valores predeterminados se establecen para los campos `start_end_date` y `dataState`.

Nombre del campo	Expresión de filtro predeterminadas	Expresión para anular los valores predeterminados
start_end_date	start_end_date entre <hace 30 días de la fecha actual> Y <ayer: es decir, hace 1 día de la fecha actual>	start_end_date comprendido entre “01/01/2024” Y “05/05/2024”
dateState	dataState="all"	dataState="final"

Conexión a Google Sheets

Google Sheets es un software de hojas de cálculo en línea que le permite organizar grandes cantidades de datos, crear informes personalizados, automatizar cálculos y colaborar con otras personas. Si es usuario de Google Sheets, puede conectar AWS Glue a la cuenta de Google Sheets. Luego, podrá usar Google Sheets como origen de datos en los trabajos de ETL. Ejecute estos trabajos para transferir datos entre Google Sheets y los servicios de AWS u otras aplicaciones compatibles.

Temas

- Compatibilidad de AWS Glue con Google Sheets
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de Google Sheets
- Configuración de las conexiones a Google Sheets
- Cómo leer de entidades de Google Sheets
- Opciones de conexión de Google Sheets
- Configurar el flujo de OAuth del código de autorización para Google Sheets
- Limitaciones del conector de Google Sheets

Compatibilidad de AWS Glue con Google Sheets

AWS Glue es compatible con Sheets de la siguiente manera:

¿Es compatible como origen?

Sí. Puede usar los trabajos de ETL de AWS Glue para consultar datos de Sheets.

¿Es compatible como destino?

No.

Versiones de la API de Sheets compatibles

API de Google Sheets versión 4 y API de Google Drive versión 3

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

También puede usar las siguientes políticas de IAM administradas para permitir el acceso:

- AWSGlueServiceRole: concede acceso a los recursos que necesitan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: concede acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de Google Sheets

Antes de poder utilizar AWS Glue para transferir datos desde Google Sheets, debe cumplir estos requisitos:

Requisitos mínimos

- Tener una cuenta de Google Sheets con correo electrónico y contraseña.
- La cuenta de Google Sheets debe estar habilitada para el acceso de API. La API de Google Sheets se puede utilizar sin ningún costo adicional.
- Su cuenta de Google Sheets le permite instalar aplicaciones conectadas. Si no tiene acceso a esta funcionalidad, contacte con su administrador de Google Sheets.

Si cumple estos requisitos, lo tendrá todo listo para conectar AWS Glue a su cuenta de Google Sheets.

Configuración de las conexiones a Google Sheets

Para configurar una conexión a Google Sheets:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles:
   a. Para el tipo de concesión AuthorizationCode:
      - En el caso de una aplicación conectada administrada por el cliente, el secreto debe contener el secreto del consumidor de la aplicación conectada con la clave `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET`.

2. En AWS Glue Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:
   a. Al seleccionar un Origen de datos, elija Google Sheets.
   b. Proporcione el entorno de Google Sheets.
      i. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.
      ii. Seleccione las opciones de red si quiere usar su red.
3. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.

   JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

Tipo de concesión AUTHORIZATION_CODE

Este tipo de concesión se considera un OAuth “de tres vías”, ya que se basa en redirigir a los usuarios al servidor de autorización externo para autenticar al usuario. Se utiliza para crear conexiones a través de la consola de AWS Glue. La consola de AWS Glue redirigirá al usuario a Google Sheets, donde deberá iniciar sesión y conceder a AWS Glue los permisos solicitados para acceder a la instancia de Google Sheets.

Los usuarios pueden optar por crear su propia aplicación conectada en Google Sheets y proporcionar su propio ID y secreto de cliente al crear conexiones a través de la consola de AWS

Glue. En este escenario, aún se abrirá Google Sheets para iniciar sesión y autorizar a AWS Glue para que acceda a sus recursos.

Este tipo de concesión da como resultado un token de actualización y un token de acceso. El token de acceso es de corta duración y se puede actualizar automáticamente sin la interacción del usuario mediante el token de actualización.

Para obtener más información, consulte la documentación pública de Google Sheets sobre la creación de una aplicación conectada para el flujo Authorization Code OAuth.

Cómo leer de entidades de Google Sheets

Requisitos previos

- Una hoja de cálculo de Google desde la que desee leer. Necesitará el ID de la hoja de cálculo y el nombre de la pestaña de la hoja de cálculo.

Detalles de entidades y campos de Google Sheets:

Entidad	Tipo de datos	Operadores admitidos
Hoja de cálculo	Cadena	N/A (no se admite el filtrado)

Ejemplo

```
googleSheets_read = glueContext.create_dynamic_frame.from_options(
    connection_type="googlesheets",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "{SpreadSheetID}#{SheetTabName}",
        "API_VERSION": "v4"
    }
```

Consultas de partición

Únicamente para la partición basada en registros, `NUM_PARTITIONS` se pueden proporcionar como opciones adicionales de Spark si desea utilizar la simultaneidad en Spark. Con estos parámetros, la consulta original se dividiría en `NUM_PARTITIONS` subconsultas que las tareas de Spark pueden ejecutar simultáneamente.

Ejemplo con **NUM_PARTITIONS**

```
googlesheets_read = glueContext.create_dynamic_frame.from_options(
    connection_type="googlesheets",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "{SpreadSheetID}#{SheetTabName}",
        "API_VERSION": "v4",
        "NUM_PARTITIONS": "10"
    }
```

Opciones de conexión de Google Sheets

Las siguientes son opciones de conexión para Google Sheets:

- `ENTITY_NAME`(cadena): (obligatorio) se usa para lectura. El `SpreadSheet ID` y el `sheetTabName` en Google Sheets. Ejemplo: `{SpreadSheetID}#{SheetTabName}`.
- `API_VERSION`(cadena): (obligatorio) se usa para lectura. Versión de la API de Rest de Google Sheets que desea utilizar.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.
- `NUM_PARTITIONS`(entero): predeterminado: 1. Se usa para leer. Número de particiones para leer.

Configurar el flujo de OAuth del código de autorización para Google Sheets

Requisitos previos

- Una cuenta de Google en la que puede iniciar sesión para usar la aplicación Google Sheets. En su cuenta de Google, Google Sheets contiene los datos que desea transferir.
- Una cuenta de Google Cloud Platform y un proyecto de Google Cloud. Consulte Crear un proyecto de Google Cloud para obtener más información.

Para configurar su cuenta de Google y obtener las credenciales de OAuth 2.0:

1. Una vez configurado el proyecto de Google Cloud, habilite las API de Google Sheets y Google Drive en el proyecto. Para ver los pasos para habilitarlas, consulte Habilitar y deshabilitar las API en la ayuda de la consola de API de Google Cloud Platform.
2. A continuación, configure una pantalla de consentimiento de OAuth para usuarios externos. Para obtener más información acerca de la pantalla de consentimiento de OAuth, consulte Configuración de la pantalla de consentimiento de OAuth en la Ayuda de la Consola de Google Cloud Platform.
3. En la pantalla de consentimiento de OAuth, agregue los siguientes ámbitos:

   - El ámbito de solo lectura de la API de Google Sheets
   - El ámbito de solo lectura de la API de Google Drive

   Para obtener más información sobre estos ámbitos, consulte Ámbitos de OAuth 2.0 para las API de Google en la documentación de Google Identity.
4. Genere el ID y el secreto del cliente de OAuth 2.0. Para obtener información acerca de los pasos para crear este ID de cliente, consulte Configuración de OAuth 2.0 en la Ayuda de la consola de Google Cloud Platform.

   El ID de cliente de OAuth 2.0 debe tener una o más URL de redireccionamiento autorizadas.

   Las URL de redireccionamiento tienen el formato siguiente:

   - https://<aws-region>.console.aws.amazon.com/gluestudio/oauth
5. Tenga en cuenta que el ID de cliente y el secreto del cliente provienen de la configuración de su ID de cliente de OAuth 2.0.

Limitaciones del conector de Google Sheets

A continuación, se indican las limitaciones del conector de Google Sheets:

- El conector de Google Sheets no admite filtros. Por lo tanto, no se puede admitir la partición basada en filtros.
- En la partición basada en registros, no existe ninguna provisión para devolver el recuento exacto de registros por SAAS. Como resultado, se pueden presentar situaciones en las que se creen archivos con registros vacíos.

- Dado que el conector de Google Sheets no admite la partición basada en filtros, `partitionField`, `lowerbound` y `upperbound` no son opciones de conexión válidas. Si se proporcionan estas opciones, es probable que se presente un error en el trabajo de AWS Glue.
- Es esencial designar la primera fila de la hoja como fila de encabezado para evitar problemas de procesamiento de datos.
  - Si no se proporciona, la fila del encabezado se sustituirá por `Unnamed:1`, `Unnamed:2`, `Unnamed:3`... si la hoja contiene datos con la primera fila vacía.
  - Si se proporciona una fila de encabezado, los nombres de las columnas vacías se reemplazarán por `Unnamed:<number of column>`. Por ejemplo, si la fila de encabezado es `['ColumnName1', 'ColumnName2', '', '', 'ColumnName5', 'ColumnName6']`, pasará a ser `['ColumnName1', 'ColumnName2', 'Unnamed:3', 'Unnamed:4', 'ColumnName5', 'ColumnName6'].`
- El conector de Google Sheets no es compatible con las transferencias incrementales.
- El conector de Google Sheets solo admite el tipo de datos String.
- A los encabezados duplicados de una hoja se les cambiará el nombre de forma iterativa mediante un sufijo numérico. Los nombres de encabezado proporcionados por el usuario tendrán prioridad al cambiar el nombre de los encabezados duplicados. Por ejemplo, si la fila del encabezado es ["Nombre", "", "Nombre", nulo, "Sin nombre:6", ""], cambiará a: ["Nombre", "Sin nombre:2", "Nombre1", "Sin nombre:4", "Sin nombre:6", "Sin nombre:61"].
- El conector de Google Sheets no admite espacios en los nombres de una pestaña.
- El nombre de una carpeta no puede contener los siguientes caracteres especiales:
  - #
  - /

Conexión a HubSpot

La plataforma CRM de HubSpot tiene todas las herramientas e integraciones que necesita para el marketing, las ventas, la administración de contenido y la atención al cliente.

- Marketing Hub: software de marketing que ayuda a aumentar el tráfico, convertir más visitantes y ejecutar campañas completas de marketing de entrada a gran escala.
- Sales Hub: software de CRM de ventas que ayuda a obtener información más profunda sobre los clientes potenciales, automatizar las tareas que tiene y cerrar más tratos con mayor rapidez.

- Service Hub: software de atención al cliente que ayuda a conectarse con los clientes, superar las expectativas y convertirlos en promotores que hagan crecer su negocio.
- Operations Hub: software de operaciones que sincroniza sus aplicaciones, limpia y crea los datos de los clientes y automatiza los procesos, de modo que todos sus sistemas y equipos trabajen mejor juntos.

Temas

- Soporte de AWS Glue para HubSpot
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de HubSpot
- Configuración de las conexiones a HubSpot
- Lectura desde entidades de HubSpot
- Escribir a entidades de HubSpot
- Opciones de conexión de HubSpot
- Limitaciones y notas del conector de HubSpot

Soporte de AWS Glue para HubSpot

AWS Glue es compatible con HubSpot de la siguiente manera:

¿Es compatible como origen?

Sí: sincrónico y asincrónico. Puede utilizar los trabajos de ETL de AWS Glue para consultar datos de HubSpot.

¿Es compatible como destino?

Sí. Puede utilizar los trabajos de ETL de AWS Glue para escribir datos en HubSpot.

Versiones compatibles de la API de HubSpot

Las siguientes versiones de la API de HubSpot son compatibles:

- v1
- v2
- v3

- v4

Para obtener información sobre la compatibilidad de entidades por versión específica, consulte Entidades admitidas para el origen sincrónico y Entidades compatibles para el origen asincrónico.

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS IAM necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si no desea utilizar el método anterior, puede utilizar las siguientes políticas de IAM administradas:

- AWSGlueServiceRole: da acceso a recursos que precisan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: otorga acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la Consola de administración de AWS. Si sigue

la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de HubSpot

Antes de poder utilizar AWS Glue para transferir datos desde HubSpot, deberá cumplir estos requisitos:

Requisitos mínimos

Los requisitos mínimos son los siguientes:

- Tiene una cuenta de HubSpot. Para obtener más información, consulte Cómo crear una cuenta de HubSpot.
- La cuenta de HubSpot debe estar habilitada para el acceso de API.
- Debe tener una aplicación en la cuenta de desarrollador de HubSpot que proporcione las credenciales de cliente que AWS Glue utiliza para acceder a los datos de forma segura cuando hace llamadas autenticadas a la cuenta. Para obtener más información, consulte Creación de una aplicación para desarrolladores de HubSpot.

Si cumple estos requisitos, estará listo para conectar AWS Glue a la cuenta de HubSpot. Si es una conexión típica, no necesita hacer nada más en HubSpot.

Cómo crear una cuenta de HubSpot

Para crear una cuenta de HubSpot:

1. Ve a la URL de registro de HubSpot CRM.
2. Introduzca su dirección de correo electrónico y seleccione Verificar correo electrónico (también puede optar por registrarse con una cuenta de Google, Microsoft o Apple).
3. Busque en su bandeja de entrada el código de verificación de HubSpot.
4. Introduzca el código de verificación de 6 dígitos y haga clic en Siguiente.
5. Introduzca una contraseña y haga clic en Siguiente.
6. Introduzca su nombre y apellidos y haga clic en Siguiente, o regístrese mediante el enlace Registrarse con Google.

7. Introduzca su sector y haga clic en Siguiente.
8. Introduzca su puesto de trabajo y haga clic en Siguiente.
9. Introduzca el nombre de su empresa y haga clic en Siguiente.
10. Seleccione el tamaño de su empresa (cantidad de empleados que trabajan en su empresa) y haga clic en Siguiente.
11. Introduzca el sitio web de su empresa y haga clic en Siguiente.
12. Seleccione dónde deben alojarse sus datos (Estados Unidos o Europa) y haga clic en Crear cuenta.
13. Seleccione el propósito de la creación de su cuenta y haga clic en Siguiente.
14. Elija Conectar cuenta de Google o seleccione añadir contactos usted mismo para vincular sus contactos con su cuenta de HubSpot.
15. Inicie sesión en su cuenta de Google si seleccionó la opción Conectar cuenta de Google para vincular sus contactos y empezar a usar su cuenta de HubSpot.

Creación de una aplicación para desarrolladores de HubSpot

Las cuentas de desarrollador de aplicaciones están diseñadas para crear y administrar aplicaciones, integraciones y cuentas de prueba para desarrolladores. También es donde puede crear y administrar listados del App Marketplace. Sin embargo, las cuentas de desarrollador de aplicaciones y sus cuentas de prueba asociadas no están vinculadas a una cuenta estándar de HubSpot. No pueden sincronizar datos o activos a o desde otra cuenta de HubSpot. Para obtener el ID de cliente y el secreto del cliente, debe crear una cuenta de desarrollador.

1. Vaya a https://developers.hubspot.com/
2. Elija Crear cuenta de desarrollador y desplácese hacia abajo.
3. Se le preguntará si desea crear una cuenta de desarrollador de aplicaciones, una cuenta de aplicación privada o una cuenta Sandbox para desarrolladores de CMS. Elija Crear cuenta de desarrollador de aplicaciones.
4. Como ya ha creado una cuenta con HubSpot, puede elegir Continuar con este usuario.
5. Haga clic en Comenzar registro.
6. Introduzca su puesto de trabajo y haga clic en Siguiente.
7. Asigne un nombre a su cuenta de desarrollador y haga clic en Siguiente y, a continuación, en Omitir.

8. Seleccione Crear una aplicación.
9. Una vez creada la aplicación, seleccione Auth.
10. En Auth, tome nota del ID de cliente y el secreto de cliente.
11. Añada la URL de redireccionamiento específica de su región como https://*<aws-region>*.console.aws.amazon.com/gluestudio/oauth. Por ejemplo, agregue https://us-east-1.console.aws.amazon.com/gluestudio/oauth para la región us-east-1.
12. Desplácese hacia abajo y busque los ámbitos. Hay dos tipos de alcances que debe seleccionar bajo los encabezados «CRM» y «Estándar».
13. Agregue los siguientes alcances:

```
content
automation
oauth
crm.objects.owners.read
forms
tickets
crm.objects.contacts.write
e-commerce
crm.schemas.custom.read
crm.objects.custom.read
sales-email-read
crm.objects.custom.write
crm.objects.companies.write
crm.lists.write
crm.objects.companies.read
crm.lists.read
crm.objects.deals.read
crm.objects.deals.write
crm.objects.contacts.read
```

14. Haga clic en Guardar y su cuenta de desarrollador estará lista para usarse.
15. Desplácese hacia arriba para encontrar el ID de cliente.
16. En la misma página, haga clic en Mostrar para obtener el secreto del cliente.

Creación de una cuenta de prueba para desarrolladores de HubSpot

Dentro de las cuentas de desarrollador de aplicaciones, puede crear cuentas de prueba para desarrolladores para probar aplicaciones e integraciones sin que ello afecte a los datos reales de HubSpot. Las cuentas de prueba para desarrolladores no reflejan las cuentas de producción, sino

que tienen acceso a una versión de prueba de 90 días de las versiones Enterprise de Marketing, Sales, Service, CMS y Operations Hub, lo que permite probar la mayoría de las herramientas y API de HubSpot.

1. Haga clic en Inicio.
2. Haga clic en Crear cuenta de prueba.
3. Haga clic en Crear cuenta de prueba de aplicación.
4. Aparece una nueva ventana. Introduzca el nombre de la cuenta de prueba de la aplicación y haga clic en Crear.

   Ya se creó su cuenta de prueba de la aplicación.

> **Note**
>
> La cuenta de desarrollador está relacionada con actividades de desarrollo, como la integración de la API, y la cuenta de prueba de la aplicación se utiliza para ver los datos que crea o extrae la cuenta de desarrollador.

Configuración de las conexiones a HubSpot

HubSpot admite el tipo de concesión AUTHORIZATION_CODE para OAuth2.

- Este tipo de concesión se considera un OAuth de “tres vías”, ya que se basa en redirigir a los usuarios a un servidor de autorización externo para autenticar al usuario. Se utiliza para crear conexiones a través de la consola de AWS Glue. El usuario que crea una conexión necesita proporcionar la información relacionada con OAuth, como el ID de cliente y el secreto de cliente, para su aplicación cliente de HubSpot. La consola de AWS Glue redirigirá al usuario a HubSpot, donde deberá iniciar sesión y conceder a AWS Glue los permisos solicitados para acceder a la instancia de HubSpot.
- Los usuarios aún pueden optar por crear su propia aplicación conectada en HubSpot y proporcionar su propio ID y secreto de cliente al crear conexiones a través de la consola de AWS Glue. En este escenario, aún se abrirá HubSpot para iniciar sesión y autorizar a AWS Glue para que acceda a sus recursos.
- Este tipo de concesión da como resultado un token de actualización y un token de acceso. El token de acceso es de corta duración y se puede actualizar automáticamente sin la interacción del usuario mediante el token de actualización.

- Para consultar la documentación pública de HubSpot sobre la creación de una aplicación conectada para el flujo Authorization Code OAuth, consulte Aplicaciones públicas.

Para configurar una conexión a HubSpot:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles:
   a. En el caso de las aplicaciones conectadas administradas por el cliente, el secreto debe contener el secreto del consumidor de la aplicación conectada con `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET` como clave.
   b. Nota: Debe crear un secreto para la conexión en AWS Glue.
2. En AWS Glue Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:
   a. Al seleccionar un Tipo de conexión, elija HubSpot.
   b. Proporcione el entorno de HubSpot.
   c. Seleccione el rol de AWS IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

      JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

   d. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.

e. Seleccione las opciones de red si quiere usar su red.

3. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.
4. En la configuración de su trabajo de AWS Glue, proporcione `connectionName` como Conexión de red adicional.

Lectura desde entidades de HubSpot

Requisito previo

Un objeto de HubSpot desde el cual le gustaría leer. Necesitará el nombre del objeto, como contacto o tarea. En la siguiente tabla se muestran las entidades admitidas para el origen sincrónico.

Entidades admitidas para el origen sincrónico

Entidad	Versión de la API	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite particiones
Campañas	v1	No	Sí	No	Sí	No
Empresas	v3	Sí	Sí	Sí	Sí	Sí
Contactos	v3	Sí	Sí	Sí	Sí	Sí
Listas de contactos	v1	No	Sí	No	Sí	No
Acuerdos	v3	Sí	Sí	Sí	Sí	Sí
Canalización de CRM (Canalizaciones de acuerdos)	v1	No	No	No	Sí	No

Entidad	Versión de la API	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite particiones
Eventos de correo electrónico	v1	No	Sí	No	Sí	No
Calls	v3	Sí	Sí	Sí	Sí	Sí
Notas	v3	Sí	Sí	Sí	Sí	Sí
Correos electrónicos	v3	Sí	Sí	Sí	Sí	Sí
Reuniones	v3	Sí	Sí	Sí	Sí	Sí
Tareas	v3	Sí	Sí	Sí	Sí	Sí
Correos	v3	Sí	Sí	Sí	Sí	Sí
Objetos personalizados	v3	Sí	Sí	Sí	Sí	Sí
Formularios	v2	No	No	No	Sí	No
Propietarios	v3	No	Sí	No	Sí	No
Productos	v3	Sí	Sí	Sí	Sí	Sí
Tickets	v3	Sí	Sí	Sí	Sí	Sí
Flujos de trabajo	v3	No	No	No	Sí	No

Entidad	Versión de la API	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite particiones
Associations	v4	Sí	No	No	Sí	No
Etiquetas de asociaciones	v4	No	No	No	Sí	No

Ejemplo:

```
hubspot_read = glueContext.create_dynamic_frame.from_options(
    connection_type="hubspot",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "contact",
        "API_VERSION": "v3"
    }
```

Entidades compatibles para el origen asincrónico

Entidad	Versión de la API	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite particiones
Empresas	v3	Sí	No	Sí	Sí	No
Contactos	v3	Sí	No	Sí	Sí	No
Acuerdos	v3	Sí	No	Sí	Sí	No
Calls	v3	Sí	No	Sí	Sí	No
Notas	v3	Sí	No	Sí	Sí	No

Entidad	Versión de la API	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite particiones
Correos electrónicos	v3	Sí	No	Sí	Sí	No
Reuniones	v3	Sí	No	Sí	Sí	No
Tareas	v3	Sí	No	Sí	Sí	No
Correos	v3	Sí	No	Sí	Sí	No
Objetos personalizados	v3	Sí	No	Sí	Sí	No
Productos	v3	Sí	No	Sí	Sí	No
Tickets	v3	Sí	No	Sí	Sí	No

Ejemplo:

```
hubspot_read = glueContext.create_dynamic_frame.from_options(
    connection_type="hubspot",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "contact",
        "API_VERSION": "v3",
        "TRANSFER_MODE": "ASYNC"
    }
```

Detalles de la entidad y el campo de HubSpot:

API de HubSpot v4:

Entidad	Versión de la API	Campo	Tipo de datos:	Operadores admitidos
Etiqueta de asociación	v4	categoría	Cadena	N/A
		typeId	Entero	N/A
		etiqueta	Cadena	N/A
Associations		desde	Struct	N/A
		id	Cadena	"="
		a	Enumeración	N/A

> **Note**
>
> En el caso del objeto `Associations`, para buscar asociaciones entre dos objetos, es necesario proporcionar el “ID de origen” (el ID del primer objeto) mediante un filtro obligatorio al crear un trabajo de AWS Glue. En ese caso, si quiere buscar asociaciones para varios ID de origen, tiene que proporcionar varios ID en la cláusula `where`. Por ejemplo: para buscar `Associations` de los ID de contacto “1” y “151”, debe proporcionar un filtro como `where id=1 AND id=151`.

API de HubSpot v3:

Entidad	Campo	Tipo de datos:	Operadores admitidos
Propietario	firstName	Cadena	N/A
	lastName	Cadena	N/A
	createdAt	DateTime	N/A
	archived	Booleano	N/A
	teams	Enumeración	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	id	Cadena	N/A
	userId	Entero	N/A
	correo electrónico	Cadena	N/A
	updatedAt	DateTime	N/A
Flujo de trabajo	nombre	Cadena	N/A
	id	Entero	N/A
	type	Cadena	N/A
	enabled	Booleano	N/A
	insertedAt	Largo	N/A
	updatedAt	Largo	N/A
	contactListIds	Struct	N/A
	personaTagIds	Enumeración	N/A

Para las siguientes entidades, HubSpot proporciona puntos de conexión para obtener los metadatos de forma dinámica, de modo que la compatibilidad del operador se capture en el nivel del tipo de datos de cada entidad.

> **Note**
>
> `DML_STATUS` es un campo virtual que se agrega a cada registro en tiempo de ejecución para determinar su estado (CREADO/ACTUALIZADO) en el modo sincrónico. El operador `CONTAINS/LIKE` no es compatible con el modo asíncrono.

Entidad	Tipo de datos:	Operadores admitidos
Contacto	Entero	"=, !=, <, >, >=, <="
	Largo	"=, !=, <, >, >=, <="
	Cadena	“=, !=, LIKE”
	Date	N/A
	DateTime	“between”
	Booleano	"="
	Enumeración	N/A
	Struct	N/A
Empresa	Entero	"=, !=, <, >, >=, <="
	Largo	"=, !=, <, >, >=, <="
	Cadena	“=, !=, LIKE”
	Date	N/A
	DateTime	“between”
	Booleano	"="
	Enumeración	N/A
	Struct	N/A
Acuerdo	Entero	"=, !=, <, >, >=, <="
	Largo	"=, !=, <, >, >=, <="
	Cadena	“=, !=, LIKE”
	Date	N/A

Entidad	Tipo de datos:	Operadores admitidos
	DateTime	“between”
	Booleano	"="
	Enumeración	N/A
	Struct	N/A
Ticket	Entero	"=, !=, <, >, >=, <="
	Largo	"=, !=, <, >, >=, <="
	Cadena	“=, !=, LIKE”
	Date	N/A
	DateTime	“between”
	Booleano	"="
	Enumeración	N/A
	Struct	N/A
Producto	Entero	"=, !=, <, >, >=, <="
	Largo	"=, !=, <, >, >=, <="
	Cadena	“=, !=, LIKE”
	Date	N/A
	DateTime	“between”
	Booleano	"="
	Enumeración	N/A
	Struct	N/A

Entidad	Tipo de datos:	Operadores admitidos
Objeto personalizado	Entero	"=, !=, <, >, >=, <="
	Largo	"=, !=, <, >, >=, <="
	Cadena	“=, !=, LIKE”
	Date	N/A
	DateTime	“between”
	Booleano	"="
	Enumeración	N/A
	Struct	N/A
Llame a	Entero	"=, !=, <, >, >=, <="
	Largo	"=, !=, <, >, >=, <="
	Cadena	“=, !=, LIKE”
	Date	N/A
	DateTime	“between”
	Booleano	"="
	Enumeración	N/A
	Struct	N/A
Correo electrónico	Entero	"=, !=, <, >, >=, <="
	Largo	"=, !=, <, >, >=, <="
	Cadena	“=, !=, LIKE”
	Date	N/A

Entidad	Tipo de datos:	Operadores admitidos
	DateTime	“between”
	Booleano	"="
	Enumeración	N/A
	Struct	N/A
Reunión	Entero	"=, !=, <, >, >=, <="
	Largo	"=, !=, <, >, >=, <="
	Cadena	“=, !=, LIKE”
	Date	N/A
	DateTime	“between”
	Booleano	"="
	Enumeración	N/A
	Struct	N/A
Nota	Entero	"=, !=, <, >, >=, <="
	Largo	"=, !=, <, >, >=, <="
	Cadena	“=, !=, LIKE”
	Date	N/A
	DateTime	“between”
	Booleano	"="
	Enumeración	N/A
	Struct	N/A

Entidad	Tipo de datos:	Operadores admitidos
Tarea	Entero	"=, !=, <, >, >=, <="
	Largo	"=, !=, <, >, >=, <="
	Cadena	“=, !=, LIKE”
	Date	N/A
	DateTime	“between”
	Booleano	"="
	Enumeración	N/A
	Struct	N/A
Correo	Entero	"=, !=, <, >, >=, <="
	Largo	"=, !=, <, >, >=, <="
	Cadena	“=, !=, LIKE”
	Date	N/A
	DateTime	“between”
	Booleano	"="
	Enumeración	N/A
	Struct	N/A

API de HubSpot v2:

Entidad	Campo	Tipo de datos:	Operadores admitidos
Formulario	portalId	Entero	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	guid	Cadena	N/A
	nombre	Cadena	N/A
	method	Cadena	N/A
	cssClass	Cadena	N/A
	redireccionamiento	Cadena	N/A
	submitText	Cadena	N/A
	notifyRecipients	Cadena	N/A
	createdAt	Largo	N/A
	updatedAt	Largo	N/A
	ignoreCurrentValues	Booleano	N/A
	deletable	Booleano	N/A
	inlineMessage	Booleano	N/A
	captchaEnabled	Booleano	N/A
	cloneable	Booleano	N/A
	formFieldGroups	Enumeración	N/A
	editable	Booleano	N/A
	deletedAt	Entero	N/A
	themeName	Cadena	N/A
	parentId	Entero	N/A
	estilo	Cadena	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	isPublished	Booleano	N/A
	publishAt	Entero	N/A
	unpublishAt	Entero	N/A
	publishedAt	Entero	N/A
	kickbackEmailWorkflowId	Cadena	N/A
	kickbackEmailsJson	Entero	N/A
	customUid	Cadena	N/A
	createMarketableContact	Booleano	N/A
	editVersion	Entero	N/A
	thankYouMessageJson	Cadena	N/A
	themeColor	Cadena	N/A
	alwaysCreateNewCompany	Booleano	N/A
	internalUpdatedAt	Largo	N/A
	ID de unidad de negocio	Entero	N/A
	portableKey	Cadena	N/A
	paymentSessionTemplateIds	Enumeración	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	selectedExternalOptions	Enumeración	N/A

API de HubSpot v1:

Entidad	Campo	Tipo de datos:	Operadores admitidos
Campaña	id	Entero	N/A
	appId	Entero	N/A
	appName	Cadena	N/A
	lastUpdatedTime	Largo	N/A
Contact_List	dynamic	Booleano	N/A
	nombre	Cadena	N/A
	portalId	Entero	N/A
	createdAt	Largo	N/A
	listId	Entero	N/A
	updatedAt	Largo	N/A
	ListType	Cadena	N/A
	filters	Enumeración	N/A
	authorId	Entero	N/A
	metaData	Struct	N/A
	archived	Booleano	N/A
	ilsFilterBranch	Cadena	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	filterIds	Enumeración	N/A
	limitExempt	Booleano	N/A
	interno	Booleano	N/A
	readOnly	Booleano	N/A
	parentId	Entero	N/A
Email_Event	id	Cadena	N/A
	type	Cadena	N/A
	destinatario	Cadena	N/A
	portalId	Entero	N/A
	appId	Entero	N/A
	appName	Cadena	N/A
	emailCampaignId	Largo	N/A
	attempt	Entero	N/A
	created	Largo	N/A
	sentBy	Struct	N/A
	smtpId	Cadena	N/A
	respuesta	Cadena	N/A
	subject	Cadena	N/A
	cc	Enumeración	N/A
	bcc	Enumeración	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	replyTo	Enumeración	N/A
	desde	Cadena	N/A
	dropReason	Cadena	N/A
	dropMessage	Cadena	N/A
	navegador	Struct	N/A
	userAgent	Cadena	N/A
	duración	Largo	N/A
	ubicación	Struct	N/A
	filteredEvent	Booleano	N/A
	deviceType	Cadena	N/A
	suppressedReason	Cadena	N/A
	suppressedMessage	Cadena	N/A
CRM_Pipeline	pipelineId	Cadena	N/A
	createdAt	Largo	N/A
	updatedAt	Largo	N/A
	objectType	Cadena	N/A
	etiqueta	Cadena	N/A
	displayOrder	Entero	N/A
	activa	Booleano	N/A
	etapas	Enumeración	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	objectTypeId	Cadena	N/A
	predeterminado	Booleano	N/A

Consultas de particionamiento

Puede proporcionar las opciones adicionales de Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` y `NUM_PARTITIONS` si quiere utilizar la simultaneidad en Spark. Con estos parámetros, la consulta original se dividiría en un número `NUM_PARTITIONS` de subconsultas que las tareas de Spark pueden ejecutar simultáneamente.

- `PARTITION_FIELD`: el nombre del campo que se utilizará para particionar la consulta.
- `LOWER_BOUND`: un valor de límite inferior inclusivo del campo de partición elegido.

  Para el campo DateTime, aceptamos el valor en formato ISO.

  Ejemplos de valor válido:

  ```
  “2024-01-01T10:00:00.115Z"
  ```

- `UPPER_BOUND`: un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`: el número de particiones.

En la tabla siguiente, se describen los detalles de compatibilidad de campos de particiones de entidades:

Nombre de la entidad	Campos de partición	Tipo de datos:
contacto	hs_object_id	Largo
	createdate, lastmodifieddate	DateTime
company	hs_object_id	Largo
	createdate, hs_lastmodifieddate	DateTime

Nombre de la entidad	Campos de partición	Tipo de datos:
deal	hs_object_id	Largo
	createdate, hs_createdate, hs_lastmodifieddate	DateTime
ticket	hs_object_id	Largo
	createdate, hs_lastmodifieddate	DateTime
producto	hs_object_id	Largo
	createdate, hs_lastmodifieddate	DateTime
custom_object	hs_object_id	Largo
	createdate, hs_lastmodifieddate	DateTime
call	hs_object_id	Largo
	createdate, hs_lastmodifieddate	DateTime
correo electrónico	hs_object_id	Largo
	createdate, hs_lastmodifieddate	DateTime
reunión	hs_object_id	Largo
	createdate, hs_lastmodifieddate	DateTime
note	hs_object_id	Largo
	createdate, hs_lastmodifieddate	DateTime

Nombre de la entidad	Campos de partición	Tipo de datos:
tarea	hs_object_id	Largo
	createdate, hs_lastmodifieddate	DateTime
postal_mail	hs_object_id	Largo
	createdate, hs_lastmodifieddate	DateTime

Ejemplo:

```
hubspot_read = glueContext.create_dynamic_frame.from_options(
    connection_type="hubspot",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "company",
        "API_VERSION": "v3",
        "PARTITION_FIELD": "hs_object_id"
        "LOWER_BOUND": "50"
        "UPPER_BOUND": "16726619290"
        "NUM_PARTITIONS": "10"
    }
```

Escribir a entidades de HubSpot

Requisitos previos

- Un objeto de HubSpot en el que le gustaría escribir. Necesitará el nombre del objeto, como contacto o ticket.
- El conector de HubSpot admite las siguientes operaciones de escritura:
  - INSERT
  - UPDATE
- Al utilizar la operación de escritura `UPDATE`, debe proporcionar la opción `ID_FIELD_NAMES` para especificar el campo de ID de los registros.

Entidades compatibles para el destino de sincronización

Entidad	Versión de API	Se admitirá como conector de destino	Se puede insertar	Se puede actualizar
Empresas	v3	Sí	Sí (individual, masivo)	Sí (individual, masivo)
Contactos	v3	Sí	Sí (individual, masivo)	Sí (individual, masivo)
Acuerdos	v3	Sí	Sí (individual, masivo)	Sí (individual, masivo)
Productos	v3	Sí	Sí (individual, masivo)	Sí (individual, masivo)
Calls	v3	Sí	Sí (individual, masivo)	Sí (individual, masivo)
Reuniones	v3	Sí	Sí (individual, masivo)	Sí (individual, masivo)
Notas	v3	Sí	Sí (individual, masivo)	Sí (individual, masivo)
Correos electrónicos	v3	Sí	Sí (individual, masivo)	Sí (individual, masivo)
Tareas	v3	Sí	Sí (individual, masivo)	Sí (individual, masivo)
Correos	v3	Sí	Sí (individual, masivo)	Sí (individual, masivo)
Objetos personalizados	v3	Sí	Sí (individual, masivo)	Sí (individual, masivo)

Entidad	Versión de API	Se admitirá como conector de destino	Se puede insertar	Se puede actualizar
Tickets	v3	Sí	Sí (individual, masivo)	Sí (individual, masivo)
Asociaciones	v4	Sí	Sí (individual, masivo)	No
Etiquetas de asociaciones	v4	Sí	Sí (individual, masivo)	Sí (individual, masivo)

Ejemplos:

Operación INSERT

```
hubspot_write = glueContext.write_dynamic_frame.from_options(
    frame=frameToWrite,
    connection_type="hubspot",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "contact",
        "API_VERSION": "v3",
        "WRITE_OPERATION": "INSERT"
    }
)
```

Operación UPDATE

```
hubspot_write = glueContext.write_dynamic_frame.from_options(
    frame=frameToWrite,
    connection_type="hubspot",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "deal",
        "API_VERSION": "v3",
```

```
        "WRITE_OPERATION": "UPDATE",
        "ID_FIELD_NAMES": "hs_object_id"
    }
)
```

Opciones de conexión de HubSpot

Existen las siguientes opciones para establecer conexión con HubSpot:

- `ENTITY_NAME`(cadena): (obligatorio) se usa para lectura. El nombre del objeto en HubSpot.
- `API_VERSION`(cadena): (obligatorio) se usa para lectura. Versión de la API de Rest de HubSpot que desea usar. Por ejemplo: v1,v2,v3,v4.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.
- `PARTITION_FIELD`(cadena): se usa para leer. Campo que se utilizará para particionar la consulta.
- `LOWER_BOUND`(cadena): se usa para leer. Un valor de límite inferior inclusivo del campo de partición elegido.
- `UPPER_BOUND`(cadena): se usa para leer. Un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`(entero): predeterminado: 1. Se usa para leer. Número de particiones para leer.
- `TRANSFER_MODE`(Cadena): se usa para indicar si la consulta debe ejecutarse en modo asíncrono.
- `WRITE_OPERATION`(cadena): predeterminado: INSERT. Se utiliza para escribir. El valor debe ser INSERT o UPDATE.
- `ID_FIELD_NAMES`(cadena): predeterminado: nulo. Requerido para UPDATE.

Limitaciones y notas del conector de HubSpot

Las siguientes son limitaciones o notas para el conector de HubSpot:

- Los puntos de conexión de búsqueda están limitados a un total de 10 000 resultados para una consulta determinada. Cualquier partición que tenga más de 10 000 registros generará un error 400.

- Se describen otras limitaciones importantes del conector en Limitaciones.
- HubSpot acepta un máximo de tres instrucciones de filtrado.
- Actualmente, HubSpot admite asociaciones entre objetos estándar de HubSpot (por ejemplo, contacto, empresa, acuerdo o ticket) y objetos personalizados.
  - Para una cuenta gratuita: solo puede crear hasta 10 tipos de asociación entre cada combinación de objetos (por ejemplo, contactos y empresas).
  - Para una cuenta de superadministrador: solo puede crear hasta 50 tipos de asociación entre cada combinación de objetos.
  - Para obtener más información, consulte Associations v4 y Create and use association labels.
- Los objetos «Quote» y «Communications» no están presentes en las asociaciones, ya que actualmente no son compatibles con el conector.
- Para Async, SaaS ordena los valores solo en orden ascendente.
- Para la entidad `Ticket`, SaaS no devuelve el campo `hs_object_id` en el modo asíncrono.

Conexión a Anuncios de Instagram

Instagram es una popular aplicación para compartir fotos que le permite conectarse con marcas, famosos, líderes de opinión, amigos, familiares y más. Es un servicio de redes sociales y para compartir fotos. Los usuarios pueden tomar fotos o grabar videos cortos y compartirlos con sus seguidores. Los anuncios de Instagram son publicaciones por las que las empresas pueden pagar para ofrecerlas a los usuarios de Instagram.

Temas

- Compatibilidad de AWS Glue con Anuncios de Instagram
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de Anuncios de Instagram
- Configuración de las conexiones de Anuncios de Instagram
- Lectura desde entidades de Anuncios de Instagram
- Opciones de conexión en Anuncios de Instagram
- Limitaciones y notas del conector de Anuncios de Instagram

Compatibilidad de AWS Glue con Anuncios de Instagram

AWS Glue es compatible con Anuncios de Instagram de la siguiente manera:

¿Es compatible como origen?

Sí. Puede usar los trabajos de AWS Glue ETL para consultar datos de Anuncios de Instagram.

¿Es compatible como destino?

No.

Versiones de la API de Anuncios de Instagram compatibles

Las siguientes versiones de la API de Anuncios de Instagram son compatibles:

- v17.0
- v18.0
- v19.0
- v20.0

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS IAM necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si no desea utilizar el método anterior, puede utilizar las siguientes políticas de IAM administradas:

- AWSGlueServiceRole: da acceso a recursos que precisan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: otorga acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la Consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de Anuncios de Instagram

Antes de poder utilizar AWS Glue para transferir datos hacia o desde Anuncios de Instagram, debe cumplir estos requisitos:

Requisitos mínimos

Los requisitos mínimos son los siguientes:

- Se accede a las cuentas estándar de Instagram directamente a través de Facebook.
- Se necesita la autenticación del usuario para generar el token de acceso.
- El conector del SDK de Anuncios de Instagram implementará el flujo OAuth del token de acceso de usuario.
- Usamos OAuth2.0 para autenticar nuestras solicitudes de API en Anuncios de Instagram. Esta autenticación basada en la web pertenece a la arquitectura de autenticación multifactor (MFA), que es un superconjunto de 2FA.
- El usuario debe conceder permisos para acceder a los puntos de conexión. Para acceder a los datos del usuario, la autorización del punto de conexión se administra mediante permisos y características.

Obtención de las credenciales de OAuth 2.0

Para obtener las credenciales de la API para poder hacer llamadas autenticadas a la instancia, consulte API Graph.

Configuración de las conexiones de Anuncios de Instagram

Anuncios de Instagram admite el tipo de concesión AUTHORIZATION_CODE para OAuth 2.

- Este tipo de concesión se considera un OAuth de tres vías, ya que se basa en redirigir a los usuarios al servidor de autorización externo para autenticar al usuario. Se utiliza para crear conexiones a través de la consola de AWS Glue.
- Los usuarios pueden optar por crear una aplicación conectada propia en Instagram Ads y proporcionar su propio ID y secreto de cliente al crear conexiones a través de la consola de AWS Glue. En este caso, se les continuará redirigiendo a Anuncios de Instagram para iniciar sesión y autorizar a AWS Glue para que acceda a sus recursos.
- Este tipo de concesión da como resultado un token acceso. Un token de usuario del sistema que caduca es válido durante 60 días a partir de la fecha de generación o actualización. Para crear continuidad, el desarrollador debe actualizar el token de acceso en un plazo de 60 días. De lo contrario, se pierde el token de acceso y es necesario que el desarrollador obtenga uno nuevo para recuperar el acceso a la API. Consulte Actualización del identificador de acceso.

Configuración de una conexión de Anuncios de Instagram:

1. En AWS Glue Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:
   a. Al seleccionar un Tipo de conexión, seleccione Anuncios de Instagram.
   b. Seleccione el rol de AWS IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

      JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
```

```
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

c. Proporcione el ID de cliente de la aplicación cliente administrada por el usuario.

d. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens. El secreto seleccionado debe tener una clave `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET` cuyo valor sea el secreto del cliente de la aplicación conectada.

e. Seleccione las opciones de red si quiere usar su red.

2. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.

Lectura desde entidades de Anuncios de Instagram

Requisito previo

Un objeto de Anuncios de Instagram desde el cual le gustaría leer. Necesitará el nombre del objeto. En las siguientes tablas se muestran las entidades admitidas.

Entidades compatibles como origen:

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Campaña	Sí	Sí	No	Sí	Sí
Conjunto de anuncios	Sí	Sí	No	Sí	Sí
Anuncios	Sí	Sí	No	Sí	Sí

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Creatividad de anuncios	No	Sí	No	Sí	No
Información: cuenta	No	Sí	No	Sí	No
Imagen del anuncio	Sí	Sí	No	Sí	No
Información: anuncio	Sí	Sí	No	Sí	Sí
Información: conjunto de anuncios	Sí	Sí	No	Sí	Sí
Información: campaña	Sí	Sí	No	Sí	Sí

Ejemplo:

```
instagramAds_read = glueContext.create_dynamic_frame.from_options(
    connection_type="instagramads",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "API_VERSION": "v20.0"
    }
```

Detalles de la entidad y el campo de Anuncios de Instagram

Para obtener más información acerca de las entidades y los detalles de los campos, consulte:

- Campaña
- Conjunto de anuncios
- Anuncio

- Creatividad de anuncios
- Ad Account Insight
- Ad Image
- Ad Insights
- AdSets Insights
- Campaigns Insights

Para obtener más información, consulte API de marketing.

> **Note**
>
> Los tipos de datos de estructura y lista se convierten en tipos de datos de cadena en respuesta a los conectores.

Consultas de particionamiento

Puede proporcionar las opciones adicionales de Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` y `NUM_PARTITIONS` si quiere utilizar la simultaneidad en Spark. Con estos parámetros, la consulta original se dividiría en un número `NUM_PARTITIONS` de subconsultas que las tareas de Spark pueden ejecutar simultáneamente.

- `PARTITION_FIELD`: el nombre del campo que se utilizará para particionar la consulta.
- `LOWER_BOUND`: un valor de límite inferior inclusivo del campo de partición elegido.

  En el campo DateTime, aceptamos el formato de marca de tiempo de Spark que se utiliza en las consultas de Spark SQL.

  Ejemplo de valor válido:

  ```
  "2022-01-01T00:00:00.000Z"
  ```

- `UPPER_BOUND`: un valor límite superior exclusivo del campo de partición elegido.

  Ejemplo de valor válido:

  ```
  "2024-01-02T00:00:00.000Z"
  ```

- NUM_PARTITIONS: el número de particiones.

Ejemplo:

```
instagramADs_read = glueContext.create_dynamic_frame.from_options(
    connection_type="instagramads",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "API_VERSION": "v20.0",
        "PARTITION_FIELD": "created_time"
        "LOWER_BOUND": "2022-01-01T00:00:00.000Z"
        "UPPER_BOUND": "2024-01-02T00:00:00.000Z"
        "NUM_PARTITIONS": "10"
    }
```

Opciones de conexión en Anuncios de Instagram

Las siguientes son opciones de conexión para Anuncios de Instagram:

- ENTITY_NAME(cadena): (obligatorio) se usa para lectura. El nombre de su objeto en Anuncios de Instagram.
- API_VERSION(cadena): (obligatorio) se usa para lectura. La versión de la API de Graph de Anuncios de Instagram que desea utilizar. Por ejemplo: v21.
- SELECTED_FIELDS(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- FILTER_PREDICATE(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- QUERY(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.
- PARTITION_FIELD(cadena): se usa para lectura. Campo que se utilizará para particionar la consulta.
- LOWER_BOUND(cadena): se usa para lectura. Un valor de límite inferior inclusivo del campo de partición elegido.
- UPPER_BOUND(cadena): se usa para lectura. Un valor límite superior exclusivo del campo de partición elegido.
- NUM_PARTITIONS(entero): predeterminado: 1. Se usa para leer. Número de particiones para leer.

Limitaciones y notas del conector de Anuncios de Instagram

Las siguientes son limitaciones o notas para el conector de Anuncios de Instagram:

- El recuento de llamadas de una aplicación es el número de llamadas que un usuario puede hacer durante un periodo continuo de una hora, multiplicado por 200 por el número de usuarios. Para obtener información sobre los límites de frecuencia, consulte Límites de frecuencia y Límites de frecuencia de casos de uso comercial.

Conexión a Intercom en AWS Glue Studio

Intercom es el sistema operativo Engagement, un canal abierto entre su empresa y sus clientes (en cuanto al producto, al momento y según sus condiciones), que crea un diálogo continuo que le permite aprovechar al máximo cada interacción a lo largo del recorrido del cliente.

Temas

- Compatibilidad con AWS Glue para Intercom
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de Intercom
- Configuración de conexiones de Intercom
- Lectura desde entidades de Intercom
- Opciones de conexión de Intercom
- Limitaciones
- Creación de una nueva cuenta de Intercom y configuración de la aplicación cliente

Compatibilidad con AWS Glue para Intercom

AWS Glue es compatible con Intercom de la siguiente manera:

¿Es compatible como origen?

Sí. Puede usar los trabajos de ETL de AWS Glue para consultar datos de Intercom.

¿Es compatible como destino?

No.

Versiones de la API de Intercom que son compatibles

v2.5. Para obtener información sobre la compatibilidad de entidades por versión específica, consulte Lectura desde entidades de Intercom.

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de IAM necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

También puede usar las siguientes políticas de IAM administradas para permitir el acceso:

- AWSGlueServiceRole: concede acceso a los recursos que necesitan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, Amazon CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: concede acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la consola de administración de AWS. Si sigue

la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de Intercom

Antes de poder utilizar AWS Glue para transferir datos hacia o desde Intercom, debe cumplir estos requisitos:

Requisitos mínimos

- Debe tener una cuenta de Intercom. Para obtener más información, consulte Creación de una nueva cuenta de Intercom y configuración de la aplicación cliente.
- Su cuenta de Intercom está habilitada para el acceso a la API.
- Debe tener una aplicación en la cuenta de desarrollador de Intercom que proporcione las credenciales de cliente que AWS Glue utiliza para acceder a sus datos de forma segura cuando hace llamadas autenticadas a su cuenta. Para obtener más información, consulte Intercom- New Account and Client App Creation Steps.

Si cumple estos requisitos, lo tiene todo listo para conectar AWS Glue a su cuenta de Intercom.

Configuración de conexiones de Intercom

Intercom admite el tipo de concesión `AUTHORIZATION_CODE` para OAuth 2.

Este tipo de concesión se considera un OAuth “de tres vías”, ya que se basa en redirigir a los usuarios al servidor de autorización externo para autenticar al usuario. Se utiliza para crear conexiones a través de la consola de AWS Glue. La consola de AWS Glue redirigirá al usuario a Google Ads, donde deberá iniciar sesión y permitir a AWS Glue que los permisos solicitados accedan a su instancia de Intercom.

Los usuarios deben proporcionar su propio ID de cliente y su secreto de cliente al crear conexiones a través de la consola de AWS Glue. En este escenario, se les continuará redirigiendo a Intercom para iniciar sesión y autorizar a AWS Glue para que acceda a sus recursos.

Este tipo de concesión da como resultado un token de actualización y un token de acceso. El token de acceso es de corta duración y se puede actualizar automáticamente sin la interacción del usuario mediante el token de actualización.

Para obtener más información sobre cómo crear una aplicación conectada para el flujo de OAuth con código de autorización, consulte Ads API.

Para configurar una conexión de Intercom:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles. Es necesario crear un secreto para cada conexión en AWS Glue.
   a. En el caso de las aplicaciones conectadas administradas por el cliente, el secreto debe contener el token de acceso a la aplicación conectada, el token de actualización, el client_id y el client_secret.
2. En AWS Glue Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:
   a. Al seleccionar un Tipo de conexión, seleccione Intercom.
   b. Proporcione el entorno de Intercom.
   c. Seleccione el rol de IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

      JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

   d. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.
   e. Seleccione las opciones de red si quiere usar su red.

3. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.

Lectura desde entidades de Intercom

Requisitos previos

- Un objeto de Intercom desde el cual le gustaría leer. Consulte la tabla de entidades compatibles que aparece a continuación para comprobar las entidades disponibles.

Entidades compatibles

Entidad	API_Version	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite Partición
Admins	v2.5	No	No	No	Sí	No
Empresas	v2.5	No	Sí	No	Sí	No
Conversaciones	v2.5	Sí	Sí	Sí	Sí	Sí
Atributos de datos	v2.5	No	No	No	Sí	No
Contactos	v2.5	Sí	Sí	Sí	Sí	Sí
Segmentos	v2.5	No	No	No	Sí	No
Etiquetas	v2.5	No	No	No	Sí	No
Equipos	v2.5	No	No	No	Sí	No

Ejemplo

```
Intercom_read = glueContext.create_dynamic_frame.from_options(
    connection_type="Intercom",
    connection_options={
        "connectionName": "connectionName",
```

```
        "ENTITY_NAME": "company",
        "API_VERSION": "V2.5"
    }
)
```

Detalles de la entidad y el campo de Intercom

Entidad	Campo	Tipo de datos	Operadores admitidos
Admins	type	Cadena	N/D
Admins	id	Cadena	N/D
Admins	avatar	Struct	N/D
Admins	nombre	Cadena	N/D
Admins	correo electrónico	Cadena	N/D
Admins	away_mode_enabled	Booleano	N/D
Admins	away_mode_reassign	Booleano	N/D
Admins	has_inbox_seat	Booleano	N/D
Admins	teams_ids	Enumeración	N/D
Admins	job_title	Cadena	N/D
Empresas	type	Cadena	N/D
Empresas	id	Cadena	N/D
Empresas	app_id	Cadena	N/D
Empresas	created_at	DateTime	N/D
Empresas	remote_created_at	DateTime	N/D
Empresas	updated_at	DateTime	N/D
Empresas	last_request_at	DateTime	N/D

Entidad	Campo	Tipo de datos	Operadores admitidos
Empresas	plan	Struct	N/D
Empresas	company_id	Cadena	N/D
Empresas	nombre	Cadena	N/D
Empresas	custom_attributes	Struct	N/D
Empresas	session_count	Entero	N/D
Empresas	monthly_spend	Entero	N/D
Empresas	user_count	Entero	N/D
Empresas	industry	Cadena	N/D
Empresas	tamaño	Entero	N/D
Empresas	sitio web	Cadena	N/D
Empresas	etiquetas	Struct	N/D
Empresas	segments	Struct	N/D
Contactos	id	Cadena	EQUAL_TO. NOT_EQUAL_TO
Contactos	type	Cadena	N/D
Contactos	workspace_id	Cadena	N/D
Contactos	external_id	Cadena	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Contactos	rol	Cadena	EQUAL_TO. NOT_EQUAL_TO

Entidad	Campo	Tipo de datos	Operadores admitidos
Contactos	correo electrónico	Cadena	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Contactos	phone	Cadena	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Contactos	nombre	Cadena	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Contactos	avatar	Cadena	N/D
Contactos	owner_id	Entero	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Contactos	social_profiles	Struct	N/D
Contactos	has_hard_bounced	Booleano	EQUAL_TO
Contactos	marked_email_as_spam	Booleano	EQUAL_TO
Contactos	unsubscribed_from_emails	Booleano	EQUAL_TO
Contactos	created_at	DateTime	EQUAL_TO, GREATER_THAN, LESS_THAN
Contactos	updated_at	DateTime	EQUAL_TO, GREATER_THAN, LESS_THAN

Entidad	Campo	Tipo de datos	Operadores admitidos
Contactos	signed_up_at	DateTime	EQUAL_TO, GREATER_THAN, LESS_THAN
Contactos	last_seen_at	DateTime	EQUAL_TO, GREATER_THAN, LESS_THAN
Contactos	last_replied_at	DateTime	EQUAL_TO, GREATER_THAN, LESS_THAN
Contactos	last_contacted_at	DateTime	EQUAL_TO, GREATER_THAN, LESS_THAN
Contactos	last_email_opened_at	DateTime	EQUAL_TO, GREATER_THAN, LESS_THAN
Contactos	last_email_clicked_at	DateTime	EQUAL_TO, GREATER_THAN, LESS_THAN
Contactos	language_override	Cadena	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Contactos	navegador	Cadena	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Contactos	browser_version	Cadena	CONTAINS, EQUAL_TO, NOT_EQUAL_TO

Entidad	Campo	Tipo de datos	Operadores admitidos
Contactos	browser_language	Cadena	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Contactos	os	Cadena	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Contactos	ubicación	Struct	N/D
Contactos	location_country	Cadena	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Contactos	location_region	Cadena	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Contactos	location_city	Cadena	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Contactos	android_app_name	Cadena	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Contactos	android_app_version	Cadena	N/D
Contactos	android_device	Cadena	N/D
Contactos	android_os_version	Cadena	N/D
Contactos	android_sdk_version	Cadena	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Contactos	android_last_seen_at	Date	N/D

Entidad	Campo	Tipo de datos	Operadores admitidos
Contactos	ios_app_name	Cadena	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Contactos	ios_app_version	Cadena	N/D
Contactos	ios_device	Cadena	N/D
Contactos	ios_os_version	Cadena	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Contactos	ios_sdk_version	Cadena	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Contactos	ios_last_seen_at	DateTime	N/D
Contactos	custom_attributes	Struct	N/D
Contactos	etiquetas	Struct	N/D
Contactos	notes	Struct	N/D
Contactos	companies	Struct	N/D
Contactos	unsubscribed_from_sms	Booleano	N/D
Contactos	sms_consent	Booleano	N/D
Contactos	opted_out_subscription_types	Struct	N/D
Contactos	referrer	Cadena	N/D
Contactos	utm_campaign	Cadena	N/D
Contactos	utm_content	Cadena	N/D

Entidad	Campo	Tipo de datos	Operadores admitidos
Contactos	utm_medium	Cadena	N/D
Contactos	utm_source	Cadena	N/D
Contactos	utm_term	Cadena	N/D
Conversaciones	type	Cadena	N/D
Conversaciones	id	Entero	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversaciones	created_at	DateTime	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversaciones	updated_at	DateTime	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversaciones	origen	Struct	N/D
Conversaciones	source_id	Cadena	EQUAL_TO, NOT_EQUAL_TO
Conversaciones	source_type	Cadena	EQUAL_TO, NOT_EQUAL_TO,
Conversaciones	source_delivered_as	Cadena	EQUAL_TO, NOT_EQUAL_TO,
Conversaciones	source_subject	Cadena	CONTAINS, EQUAL_TO, NOT_EQUAL_TO

Entidad	Campo	Tipo de datos	Operadores admitidos
Conversaciones	source_body	Cadena	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Conversaciones	source_author_id	Cadena	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Conversaciones	source_author_type	Cadena	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Conversaciones	source_author_name	Cadena	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Conversaciones	source_author_email	Cadena	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Conversaciones	source_url	Cadena	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Conversaciones	contacts	Struct	N/D
Conversaciones	teammates	Struct	N/D
Conversaciones	título	Cadena	N/D
Conversaciones	admin_assignee_id	Entero	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN

Entidad	Campo	Tipo de datos	Operadores admitidos
Conversaciones	team_assignee_id	Entero	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Conversaciones	custom_attributes	Struct	N/D
Conversaciones	open	Booleano	EQUAL_TO
Conversaciones	estado	Cadena	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Conversaciones	lectura	Booleano	EQUAL_TO
Conversaciones	waiting_since	DateTime	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversaciones	snoozed_until	DateTime	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversaciones	etiquetas	Struct	N/D
Conversaciones	first_contact_reply	Struct	N/D
Conversaciones	priority	Cadena	EQUAL_TO, NOT_EQUAL_TO
Conversaciones	temas	Struct	N/D
Conversaciones	sla_applied	Struct	N/D
Conversaciones	conversation_rating	Struct	N/D

Entidad	Campo	Tipo de datos	Operadores admitidos
Conversaciones	conversation_rating_requested_at	DateTime	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversaciones	conversation_rating_replied_at	DateTime	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversaciones	conversation_rating_score	Entero	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversaciones	conversation_rating_remark	Cadena	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Conversaciones	conversation_rating_contact_id	Cadena	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Conversaciones	conversation_rating_admin_id	Cadena	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Conversaciones	statistics	Struct	N/D
Conversaciones	statistics_time_to_assignment	Entero	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN

Entidad	Campo	Tipo de datos	Operadores admitidos
Conversaciones	statistics_time_to_admin_reply	Entero	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversaciones	statistics_time_to_first_close	Entero	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversaciones	statistics_time_to_last_close	Entero	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversaciones	statistics_median_time_to_reply	Entero	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversaciones	statistics_first_contact_reply_at	DateTime	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversaciones	statistics_first_assignment_at	DateTime	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversaciones	statistics_first_admin_reply_at	DateTime	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN

Entidad	Campo	Tipo de datos	Operadores admitidos
Conversaciones	statistics_first_close_at	DateTime	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversaciones	statistics_last_assignment_at	DateTime	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversaciones	statistics_last_assignment_admin_reply_at	DateTime	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversaciones	statistics_last_contact_reply_at	DateTime	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversaciones	statistics_last_admin_reply_at	DateTime	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversaciones	statistics_last_close_at	DateTime	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversaciones	statistics_last_closed_by_id	Cadena	CONTAINS, EQUAL_TO, NOT_EQUAL_TO

Entidad	Campo	Tipo de datos	Operadores admitidos
Conversaciones	statistics_count_reopens	Entero	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversaciones	statistics_count_assignments	Entero	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversaciones	statistics_count_conversation_parts	Entero	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversaciones	conversation_parts	Enumeración	N/D
Atributos de datos	id	Entero	N/D
Atributos de datos	type	Cadena	N/D
Atributos de datos	modelo	Cadena	N/D
Atributos de datos	nombre	Cadena	N/D
Atributos de datos	full_name	Cadena	N/D
Atributos de datos	etiqueta	Cadena	N/D
Atributos de datos	Descripción	Cadena	N/D
Atributos de datos	data_type	Cadena	N/D
Atributos de datos	options	Enumeración	N/D
Atributos de datos	api_writable	Booleano	N/D
Atributos de datos	ui_writable	Booleano	N/D

Entidad	Campo	Tipo de datos	Operadores admitidos
Atributos de datos	personalizado	Booleano	N/D
Atributos de datos	archived	Booleano	N/D
Atributos de datos	created_at	Booleano	N/D
Atributos de datos	updated_at	DateTime	N/D
Atributos de datos	admin_id	Cadena	N/D
Segmentos	type	Cadena	N/D
Segmentos	id	Cadena	N/D
Segmentos	nombre	Cadena	N/D
Segmentos	created_at	DateTime	N/D
Segmentos	updated_at	DateTime	N/D
Segmentos	person_type	Cadena	N/D
Segmentos	count	Entero	N/D
Etiquetas	type	Cadena	N/D
Etiquetas	id	Cadena	N/D
Etiquetas	nombre	Cadena	N/D
Equipos	type	Cadena	N/D
Equipos	id	Cadena	N/D
Equipos	nombre	Cadena	N/D
Equipos	admin_ids	Enumeración	N/D

Consultas de partición

Puede proporcionar las opciones adicionales de Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` y `NUM_PARTITIONS` si quiere usar la simultaneidad en Spark. Con estos parámetros, la consulta original se dividiría en un número `NUM_PARTITIONS` de subconsultas que las tareas de Spark pueden ejecutar simultáneamente.

- `PARTITION_FIELD`: el nombre del campo que se usará para particionar la consulta.
- `LOWER_BOUND`: un valor de límite inferior inclusivo del campo de partición elegido.

  Para la fecha, aceptamos el formato de fecha de Spark que se usa en las consultas de Spark SQL. Ejemplos de valores válidos: `"2024-02-06"`.
- `UPPER_BOUND`: un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`: el número de particiones.

Los detalles de compatibilidad del campo de partición por entidad se capturaron en la siguiente tabla.

Nombre de la entidad	Campo de partición	Tipo de datos
Contactos	created_at, updated_at,last_seen_at	DateTime
Conversaciones	id	Entero
Conversaciones	created_at, updated_at	DateTime

Ejemplo

```
Intercom_read = glueContext.create_dynamic_frame.from_options(
    connection_type="Intercom",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "conversation",
        "API_VERSION": "V2.5",
        "PARTITION_FIELD": "created_at"
        "LOWER_BOUND": "2022-07-13T07:55:27.065Z"
        "UPPER_BOUND": "2022-08-12T07:55:27.065Z"
        "NUM_PARTITIONS": "2"
    }
)
```

Opciones de conexión de Intercom

Las siguientes son opciones de conexión para Intercom:

- `ENTITY_NAME`(cadena): (obligatorio) se usa para lectura. El nombre del objeto en Intercom.
- `API_VERSION`(cadena): (obligatorio) se usa para lectura. Versión de la API de REST de Intercom que desea usar. Ejemplo: v2.5.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.
- `PARTITION_FIELD`(cadena): se usa para leer. Campo que se utilizará para particionar la consulta.
- `LOWER_BOUND`(cadena): se usa para leer. Un valor de límite inferior inclusivo del campo de partición elegido.
- `UPPER_BOUND`(cadena): se usa para leer. Un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`(entero): predeterminado: 1. Se usa para leer. Número de particiones para leer.
- `INSTANCE_URL`(cadena): URL de la instancia en la que el usuario quiere ejecutar las operaciones. Por ejemplo: https://api.intercom.io.

Limitaciones

Las siguientes son limitaciones para el conector de Intercom:

- Al usar la entidad Empresa, hay un límite de 10 000 empresas que se pueden devolver. Para obtener más información, consulte List all companies API.
- Al aplicar Ordenar por, es obligatorio filtrar tanto para las entidades de Contacto como para las de Conversación.
- MCA es compatible con el proveedor de SaaS. Sin embargo, en función de los límites de frecuencia de las API mencionados en la documentación, no alojaremos el MCA en AWS Glue, ya que podría afectar a otras cargas de trabajo y provocar posibles problemas de rendimiento debido a la contención de recursos.

Creación de una nueva cuenta de Intercom y configuración de la aplicación cliente

Creación de una cuenta de Intercom

1. Elija la URL de Intercom y seleccione Iniciar mi prueba gratuita en la esquina superior derecha de la página.
2. Seleccione el botón Probar de forma gratuita en la esquina superior derecha de la página.
3. Elija el tipo de empresa que necesite.
4. En la página, ingrese la información solicitada.
5. Después de ingresar toda la información, seleccione Registrar.

Creación de una aplicación para desarrolladores de Intercom

Para obtener el ID de cliente y el secreto del cliente, debe crear una cuenta de desarrollador.

1. Diríjase a https://app.intercom.com/.
2. Ingrese el ID de correo electrónico y la contraseña (o inicie sesión con Google) e inicie sesión.
3. Elija Perfil de usuario en la esquina inferior izquierda y elija la configuración.
4. Seleccione Aplicaciones e integración.
5. Seleccione la pestaña Hub de desarrolladores en Aplicaciones e integración.
6. Seleccione Nueva aplicación y cree la aplicación aquí.
7. Proporcione el nombre de la aplicación y elija Crear aplicación.
8. Dentro de la aplicación, diríjase a la sección Autenticación.
9. Elija la opción para editar y agregue las URI de redireccionamiento. Agregue la URL de redireccionamiento específica de su región como `https://<aws-region>.console.aws.amazon.com/gluestudio/oauth`. Por ejemplo, agregue `https://us-east-1.console.aws.amazon.com/gluestudio/oauth for the us-east-1 region`.
10. Obtenga el ID de cliente y el secreto de cliente generados en la sección Información básica.

Conexión a Jira Cloud

Jira Cloud es una plataforma desarrollada por Atlassian. La plataforma incluye productos de seguimiento de problemas que ayudan a los equipos a planificar y realizar un seguimiento de sus

proyectos de Agile. Como usuario de Jira Cloud, la cuenta contiene datos sobre los proyectos, como problemas, flujos de trabajo y eventos. Puede utilizar AWS Glue para transferir datos de Jira Cloud a determinados servicios de AWS u otras aplicaciones compatibles.

Temas

- Compatibilidad de AWS Glue con Jira Cloud
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de Jira Cloud
- Configurar las conexiones a Jira Cloud
- Lectura de entidades de Jira Cloud
- Opciones de conexión de Jira Cloud
- Limitaciones y notas del conector de Jira Cloud

Compatibilidad de AWS Glue con Jira Cloud

AWS Glue es compatible con Jira Cloud de la siguiente manera:

¿Es compatible como origen?

Sí. Puede utilizar los trabajos de ETL de AWS Glue para consultar datos de Jira Cloud.

¿Es compatible como destino?

No.

Versiones compatibles de la API de Jira Cloud

Las siguientes versiones de la API de Jira Cloud son compatibles:

- v3

Para obtener información sobre la compatibilidad de entidades por versión específica, consulte Lectura de entidades de Jira Cloud.

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS IAM necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si no desea utilizar el método anterior, puede utilizar las siguientes políticas de IAM administradas:

- AWSGlueServiceRole: da acceso a recursos que precisan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: otorga acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la Consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de Jira Cloud

Antes de poder utilizar AWS Glue para transferir datos desde Jira Cloud a destinos compatibles, deberá cumplir estos requisitos:

Requisitos mínimos

Los requisitos mínimos son los siguientes:

- Tener una cuenta de Atlassian en la que utilice el producto de software Jira en Jira Cloud. Para obtener más información, consulte Crear una cuenta de Jira Cloud.
- Debe tener una cuenta de AWS creada con el servicio de acceso a AWS Glue.
- Esta aplicación proporciona las credenciales de cliente que AWS Glue utiliza para acceder a los datos de forma segura cuando hace llamadas autenticadas a la cuenta. Para obtener más información, consulte Habilitar OAuth 2.0 (3LO) en la documentación de Atlassian Developer.

Si cumple estos requisitos, estará listo para conectar AWS Glue a la cuenta de Jira Cloud.

Crear una cuenta de Jira Cloud

Para crear una cuenta de Jira Cloud:

1. Navegue hasta la URL de registro de Atlassian.
2. Introduzca su correo electrónico laboral y nombre, y elija Acepto. Recibirá un correo electrónico de verificación.
3. Tras verificar su correo electrónico, puede crear una contraseña y seleccionar Registrarse.
4. Escriba el nombre y la contraseña, y elija Registrarse.
5. Se le redirigirá a una página en la que debe ingresar su sitio. Introduzca el nombre del sitio y elija Acepto.

Una vez que se inicie su sitio de Atlassian Cloud, podrá configurar Jira respondiendo a algunas preguntas según sus preferencias de tipo de proyecto.

Para iniciar sesión en una cuenta existente:

1. Vaya a la URL de inicio de sesión de Atlassian e introduzca las credenciales.
2. Introduzca el correo electrónico y la contraseña, y haga clic en Iniciar sesión. Se le redirigirá al panel de Jira.

Creación de una aplicación en Jira Cloud

Para crear una aplicación en Jira Cloud y obtener el ID de cliente y el secreto de cliente de la aplicación cliente administrada:

1. Vaya a la URL de inicio de Jira Cloud e introduzca las credenciales.
2. Elija Crear y seleccione la opción de integración con OAuth 2.0.
3. Introduzca el nombre de la aplicación, consulte los términos y condiciones y seleccione Crear.
4. Vaya a la sección Distribución en el menú de la izquierda y seleccione Editar.
5. En la sección Editar controles de distribución:
   a. Seleccione ESTADO DE DISTRIBUCIÓN como Uso compartido.
   b. Introduzca el nombre del proveedor.
   c. Introduzca la URL de su política de privacidad. Por ejemplo, https://docs.aws.amazon.com/glue/latest/dg/security-iam-awsmanpol.html
   d. Introduzca la URL de sus condiciones de servicio (opcional).
   e. Introduzca la URL de su contacto de atención al cliente (opcional).
   f. Seleccione Sí/No en la DECLARACIÓN DE DATOS PERSONALES y elija Guardar cambios.
6. Vaya a Permisos en el menú de la izquierda de la aplicación correspondiente.
7. Para la API de Jira, seleccione Agregar. Una vez agregada, elija la opción Configuración.
8. En la sección Ámbitos clásicos > API de REST de la plataforma Jira, seleccione Editar ámbitos y marque todos los ámbitos. Haga clic en Guardar.
9. En Ámbitos granulares, seleccione Editar ámbitos y seleccione los siguientes ámbitos:
10. Desplácese hacia abajo y busque los ámbitos. Hay dos tipos de alcances que debe seleccionar bajo los encabezados «CRM» y «Estándar».
11. Agregue los siguientes alcances:

```
read:application-role:jira
read:audit-log:jira
read:avatar:jira
read:field:jira
read:group:jira
read:instance-configuration:jira
read:issue-details:jira
read:issue-event:jira
read:issue-link-type:jira
read:issue-meta:jira
```

```
read:issue-security-level:jira
read:issue-security-scheme:jira
read:issue-type-scheme:jira
read:issue-type-screen-scheme:jira
read:issue-type:jira
read:issue.time-tracking:jira
read:label:jira
read:notification-scheme:jira
read:permission:jira
read:priority:jira
read:project:jira
read:project-category:jira
read:project-role:jira
read:project-type:jira
read:project-version:jira
read:project.component:jir
read:project.property:jira
read:resolution:jira
read:screen:jira
read:status:jira
read:user:jira
read:workflow-scheme:jira
read:workflow:jira
read:field-configuration:jira
read:issue-type-hierarchy:jira
read:webhook:jira
```

12. Vaya a Autenticación en el menú de la izquierda y elija Agregar.
13. Introduzca una URL de devolución de llamada, como https://us-east-1.console.aws.amazon.com/gluestudio/oauth
14. Vaya a Configuración en el menú de la izquierda y desplácese hacia abajo para ver los detalles de Autenticación. Tome nota del ID y el secreto de cliente.

Configurar las conexiones a Jira Cloud

Jira Cloud admite el tipo de concesión AUTHORIZATION_CODE para OAuth2.

- Este tipo de concesión se considera un OAuth de “tres vías”, ya que se basa en redirigir a los usuarios a un servidor de autorización externo para autenticar al usuario. Se utiliza para crear conexiones a través de la consola de AWS Glue. La consola de AWS Glue redirigirá al usuario

a Jira Cloud, donde deberá iniciar sesión y conceder a AWS Glue los permisos solicitados para acceder a la instancia de Jira Cloud.

- Los usuarios aún pueden optar por crear una aplicación conectada propia en Jira Cloud y proporcionar el ID y secreto de cliente propios al crear conexiones a través de la consola de AWS Glue. En este escenario, aún se abrirá Jira Cloud para iniciar sesión y autorizar a AWS Glue para que acceda a sus recursos.
- Este tipo de concesión da como resultado un token de actualización y un token de acceso. El token de acceso es de corta duración y se puede actualizar automáticamente sin la interacción del usuario mediante el token de actualización.
- Para consultar la documentación pública de Jira Cloud sobre la creación de una aplicación conectada para el flujo Authorization Code OAuth, consulte Habilitación de OAuth 2.0 (3LO).

Para configurar una conexión a Jira Cloud:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles:
   a. En el caso de las aplicaciones conectadas administradas por el cliente, el secreto debe contener el secreto del consumidor de la aplicación conectada con `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET` como clave.
   b. Nota: Debe crear un secreto para la conexión en AWS Glue.
2. En AWS Glue Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:
   a. Al seleccionar un Tipo de conexión, elija Jira Cloud.
   b. Proporcione el entorno de Jira Cloud.
   c. Seleccione el rol de AWS IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

      JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
```

```
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

d. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.

e. Seleccione las opciones de red si quiere usar su red.

3. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.

Lectura de entidades de Jira Cloud

Requisito previo

Un objeto de Jira Cloud desde el cual le gustaría leer. Necesitará el nombre del objeto, como Registro de auditoría o Problema. En la siguiente tabla se muestran las entidades admitidas.

Entidades compatibles como origen:

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Registro de auditoría	Sí	Sí	No	Sí	Sí
Problema	Sí	Sí	No	Sí	Sí
Campo de problema	No	No	No	Sí	No
Configuración de campo de problema	Sí	Sí	No	Sí	Sí

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Tipo de enlace de problema	No	No	No	Sí	No
Esquema de notificación de problema	Sí	Sí	No	Sí	Sí
Esquema de seguridad de problema	No	No	No	Sí	No
Esquema de tipo de problema	Sí	Sí	Sí	Sí	Sí
Esquema de pantalla del tipo de problema	Sí	Sí	Sí	Sí	Sí
Tipo de problema	No	No	No	Sí	No
Configuración de Jira	Sí	No	No	Sí	No
Configuración avanzada de Jira	No	No	No	Sí	No
Configuración global de Jira	No	No	No	Sí	No
Etiqueta	No	No	No	Sí	Sí

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Yo	Sí	No	No	Sí	No
Permiso	No	No	No	Sí	No.
Proyecto	Sí	Sí	Sí	Sí	Sí
Categoría de proyecto	No	No	No	Sí	No
Tipo de proyecto	No	No	No	Sí	No
Información del servidor	No	No	No	Sí	No
Usuarios	No	No	No.	Sí	No
Flujo de trabajo	Sí	Sí	Sí	Sí	Sí
Esquema de flujo de trabajo	No	Sí	No	Sí	Sí
Asociación de proyectos del esquema de flujo de trabajo	Sí	No	No	Sí	No
Estado del flujo de trabajo	No	No	No	Sí	No

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Categoría de estado del flujo de trabajo	No	No	No	Sí	No

Ejemplo:

```
jiracloud_read = glueContext.create_dynamic_frame.from_options(
    connection_type="JiraCloud",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "audit-record",
        "API_VERSION": "v3"
    }
```

Detalles de la entidad y el campo de Jira Cloud:

Objeto	Campo	Tipo de datos	Operadores de filtro admitidos
Registro de auditoría	filter	Cadena	"="
	desde	DateTime	"="
	a	DateTime	"="
	id	Entero	N/A
	resumen	Cadena	N/A
	remoteAddress	Cadena	N/A
	authorAccountId	Cadena	N/A
	created	Cadena	N/A

Objeto	Campo	Tipo de datos	Operadores de filtro admitidos
	categoría	Cadena	N/A
	eventSource	Cadena	N/A
	Descripción	Cadena	N/A
	objectItem	Struct	N/A
	changedValues	Enumeración	N/A
	associatedItems	Enumeración	N/A
Grupos	groupName	Enumeración	"="
	nombre	Cadena	N/A
	groupId	Cadena	"="
Problema	affectedVersion	Cadena	"=, !="
	assignee	Cadena	"=, !="
	categoría	Cadena	"=, !="
	componente	Cadena	"=, !="
	creator	Cadena	"=, !="
	due	DateTime	N/A
	epic_link	Cadena	"=, !="
	filter	Cadena	"=, !="
	fixVersion	Cadena	"=, !="
	hierarchyLevel	Entero	"=, !="
	issueKey	Cadena	"=, !=, >, <, >=, <="

Objeto	Campo	Tipo de datos	Operadores de filtro admitidos
	issueLink	Cadena	"=, !="
	issueLinkType	Cadena	"=, !="
	etiquetas	Cadena	"=, !="
	lastViewed	DateTime	“=, >, <, >=, <=, between”
	nivel	Cadena	"=, !="
	parent	Cadena	"=, !="
	priority	Cadena	"=, !="
	proyecto	Cadena	"=, !="
	projectType	Cadena	"=, !="
	reporter	Cadena	"=, !="
	resolución	Cadena	"=, !="
	resolved	DateTime	“=, >, <, >=, <=, between”
	sprint	Cadena	"=, !="
	status	Cadena	"=, !="
	tipo	Cadena	"=, !="
	updated	DateTime	“=, >, <, >=, <=, between”
	voter	Cadena	"=, !="

Objeto	Campo	Tipo de datos	Operadores de filtro admitidos
	votes	Entero	“=, !=, <, >, <=, >=, between”
	watcher	Cadena	"=, !="
	watchers	Entero	“=, !=, <, >, <=, >=, between”
	workRatio	Entero	“=, !=, <, >, <=, >=, between”
	validateQuery	Cadena	"="
	expand	Cadena	"="
	fieldByKeys	Booleano	"="
	id	Cadena	N/A
	self	Cadena	N/A
	key	Cadena	N/A
	renderedFields	Struct	N/A
	propiedades	Enumeración	"="
	names	Struct	N/A
	esquema	Struct	N/A
	transitions	Enumeración	N/A
	operaciones	Struct	N/A
	editmeta	Struct	N/A
	registro de cambios	Struct	N/A

Objeto	Campo	Tipo de datos	Operadores de filtro admitidos
	versionedRepresentations	Struct	N/A
	campos	Enumeración	"="
	fieldsToInclude	Struct	N/A
	warningMessages	Enumeración	N/A
	created	DateTime	N/A
	worklogDate	DateTime	N/A
IssueEvents	id	Entero	N/A
	nombre	Cadena	N/A
Campos de problema	id	Cadena	N/A
	key	Cadena	N/A
	nombre	Cadena	N/A
	personalizado	Booleano	N/A
	orderable	Booleano	N/A
	navigable	Booleano	N/A
	searchable	Booleano	N/A
	clauseNames	Enumeración	N/A
	alcance	Struct	N/A
	esquema	Struct	N/A
Configuraciones de campo de problema	isDefault	Booleano	"="

Objeto	Campo	Tipo de datos	Operadores de filtro admitidos
	consulta	Cadena	"="
	id	Entero	"="
	nombre	Cadena	N/A
	Descripción	Cadena	N/A
Tipo de enlace de problema	id	Cadena	N/A
	nombre	Cadena	N/A
	inward	Cadena	N/A
	outward	Cadena	N/A
	self	Cadena	N/A
Esquemas de notificación de problema	expand	Cadena	"="
	self	Cadena	N/A
	id	Entero	N/A
	nombre	Cadena	N/A
	Descripción	Cadena	N/A
	notificationSchemeEvents	Enumeración	N/A
	alcance	Struct	N/A
Prioridad de problema	self	Cadena	N/A
	statusColor	Cadena	N/A
	Descripción	Cadena	N/A

Objeto	Campo	Tipo de datos	Operadores de filtro admitidos
	iconUrl	Cadena	N/A
	nombre	Cadena	N/A
	id	Cadena	N/A
	isDefault	Booleano	N/A
Resoluciones de problemas	self	Cadena	N/A
	id	Cadena	N/A
	Descripción	Cadena	N/A
	nombre	Cadena	N/A
Esquema de seguridad de problema	self	Cadena	N/A
	id	Entero	N/A
	nombre	Cadena	N/A
	Descripción	Cadena	N/A
	defaultSecurityLevelId	Entero	N/A
	levels	Enumeración	N/A
Tipo de problema	self	Cadena	N/A
	id	Cadena	N/A
	Descripción	Cadena	N/A
	iconUrl	Cadena	N/A
	nombre	Cadena	N/A
	subtask	Booleano	N/A

Objeto	Campo	Tipo de datos	Operadores de filtro admitidos
	avatarId	Entero	N/A
	entityId	Cadena	N/A
	hierarchyLevel	Entero	N/A
	alcance	Struct	N/A
Esquema de tipo de problema	orderBy	Cadena	"="
	expand	Cadena	"="
	queryString	Cadena	"="
	id	Cadena	N/A
	nombre	Cadena	N/A
	Descripción	Cadena	N/A
	defaultIssueTypeId	Cadena	N/A
	isDefault	Booleano	N/A
Esquema de pantalla del tipo de problema	queryString	Cadena	"="
	orderBy	Cadena	"="
	expand	Cadena	"="
	id	Cadena	"="
	nombre	Cadena	N/A
	Descripción	Cadena	N/A
Configuración de Jira	key	Cadena	N/A
	keyFilter	Cadena	"="

Objeto	Campo	Tipo de datos	Operadores de filtro admitidos
	id	Cadena	N/A
	valor	Cadena	N/A
	nombre	Cadena	N/A
	desc	Cadena	N/A
	tipo	Cadena	N/A
	defaultValue	Cadena	N/A
	ejemplo	Cadena	N/A
	allowedValues	Enumeración	N/A
Configuración avanzada de Jira	id	Cadena	N/A
	key	Cadena	N/A
	valor	Cadena	N/A
	nombre	Cadena	N/A
	desc	Cadena	N/A
	tipo	Cadena	N/A
	defaultValue	Cadena	N/A
	ejemplo	Cadena	N/A
	allowedValues	Enumeración	N/A
Configuración global de Jira	votingEnabled	Booleano	N/A
	watchingEnabled	Booleano	N/A

Objeto	Campo	Tipo de datos	Operadores de filtro admitidos
	unassignedIssuesAllowed	Booleano	N/A
	subTasksEnabled	Booleano	N/A
	issueLinkingEnabled	Booleano	N/A
	timeTrackingEnabled	Booleano	N/A
	attachmentsEnabled	Booleano	N/A
	timeTrackingConfiguration	Struct	N/A
Etiqueta	valores	Enumeración	N/A
Yo	expand	Cadena	"="
	self	Cadena	N/A
	accountId	Cadena	N/A
	accountType	Cadena	N/A
	emailAddress	Cadena	N/A
	avatarUrls	Cadena	N/A
	displayName	Cadena	N/A
	activa	Booleano	N/A
	timeZone	Cadena	N/A
	locale	Cadena	N/A
	grupos	Struct	N/A
	applicationRoles	Struct	N/A

Objeto	Campo	Tipo de datos	Operadores de filtro admitidos
Permiso	id	Cadena	N/A
	key	Cadena	N/A
	nombre	Cadena	N/A
	tipo	Cadena	N/A
	Descripción	Cadena	N/A
	havePermission	Booleano	N/A
	deprecatedKey	Booleano	N/A
Proyecto	orderBy	Cadena	"="
	claves	Enumeración	"="
	consulta	Cadena	"="
	typeKey	Cadena	"="
	categoryId	Entero	"="
	acción	Cadena	"="
	expand	Cadena	"="
	status	Enumeración	"="
	self	Cadena	N/A
	id	Entero	"="
	key	Cadena	N/A
	Descripción	Cadena	N/A
	lead	Struct	N/A

Objeto	Campo	Tipo de datos	Operadores de filtro admitidos
	componentes	Enumeración	N/A
	issueTypes	Enumeración	N/A
	url	Cadena	N/A
	correo electrónico	Cadena	N/A
	assigneeType	Cadena	N/A
	control de versiones	Enumeración	N/A
	nombre	Cadena	N/A
	roles	Struct	N/A
	avatarUrls	Struct	N/A
	projectCategory	Struct	N/A
	projectTypeKey	Cadena	N/A
	simplified	Booleano	N/A
	estilo	Cadena	N/A
	favourite	Booleano	N/A
	isPrivate	Booleano	N/A
	issueTypeHierarchy	Struct	N/A
	permisos	Struct	N/A
	propiedades	Enumeración	"="
	uuid	Cadena	N/A
	insight	Struct	N/A

Objeto	Campo	Tipo de datos	Operadores de filtro admitidos
	eliminado	Booleano	N/A
	retentionTillDate	Cadena	N/A
	deletedDate	Cadena	N/A
	deletedBy	Struct	N/A
	archived	Booleano	N/A
	archivedDate	Cadena	N/A
	archivedBy	Struct	N/A
	landedPageInfo	Struct	N/A
Categoría de proyecto	self	Cadena	N/A
	id	Cadena	N/A
	nombre	Cadena	N/A
	Descripción	Cadena	N/A
Tipo de proyecto	key	Cadena	N/A
	formattedKey	Cadena	N/A
	Descripción	Cadena	N/A
	descriptionI18nKey	Cadena	N/A
	icono	Cadena	N/A
	color	Cadena	N/A
Información del servidor	baseUrl	Cadena	N/A
	versión	Cadena	N/A

Objeto	Campo	Tipo de datos	Operadores de filtro admitidos
	versionNumbers	Enumeración	N/A
	deploymentType	Cadena	N/A
	buildNumber	Entero	N/A
	buildDate	DateTime	N/A
	serverTime	DateTime	N/A
	scmInfo	Cadena	N/A
	serverTitle	Cadena	N/A
	healthChecks	Enumeración	N/A
Usuarios	self	Cadena	N/A
	accountId	Cadena	N/A
	accountType	Cadena	N/A
	emailAddress	Cadena	N/A
	avatarUrls	Struct	N/A
	displayName	Cadena	N/A
	activa	Booleano	N/A
	timeZone	Cadena	N/A
	locale	Cadena	N/A
	grupos	Struct	N/A
	applicationRoles	Struct	N/A
	expand	Cadena	N/A

Objeto	Campo	Tipo de datos	Operadores de filtro admitidos
Flujo de trabajo	workflowName	Cadena	"="
	expand	Cadena	"="
	queryString	Cadena	"="
	orderBy	Cadena	"="
	isActive	Booleano	"="
	id	Struct	N/A
	Descripción	Cadena	N/A
	transitions	Enumeración	N/A
	statuses	Enumeración	N/A
	isDefault	Booleano	N/A
	schemes	Enumeración	N/A
	projects	Enumeración	N/A
	hasDraftWorkflow	Booleano	N/A
	operaciones	Struct	N/A
	created	Cadena	N/A
	updated	Cadena	N/A
Esquema de flujo de trabajo	self	Cadena	N/A
	id	Entero	N/A
	nombre	Cadena	N/A
	Descripción	Cadena	N/A

Objeto	Campo	Tipo de datos	Operadores de filtro admitidos
	defaultWorkflow	Cadena	N/A
	issueTypeMappings	Struct	N/A
	originalDefaultWorkflow	Cadena	N/A
	originalIssueTypeMappings	Struct	N/A
	draft	Booleano	N/A
	lastModifiedUser	Struct	N/A
	lastModified	Cadena	N/A
	updateDraftIfNeeded	Booleano	N/A
	issueTypes	Struct	N/A
Asociación de proyectos del esquema de flujo de trabajo	projectId	Entero	"="
	projectIds	Enumeración	N/A
	workflowScheme	Struct	N/A
Estado del flujo de trabajo	self	Cadena	N/A
	Descripción	Cadena	N/A
	iconUrl	Cadena	N/A
	nombre	Cadena	N/A
	id	Cadena	N/A
	StatusCategory	Struct	N/A

Objeto	Campo	Tipo de datos	Operadores de filtro admitidos
Categoría de estado del flujo de trabajo	self	Cadena	N/A
	id	Cadena	N/A
	key	Cadena	N/A
	colorName	Cadena	N/A
	nombre	Cadena	N/A

Consultas de particionamiento

Puede proporcionar la opción adicional `NUM_PARTITIONS` de Spark si quiere usar la simultaneidad en Spark. Con estos parámetros, la consulta original se dividiría en `NUM_PARTITIONS` subconsultas que las tareas de Spark pueden ejecutar simultáneamente.

- `NUM_PARTITIONS`: el número de particiones.

Ejemplo:

```
jiraCloud_read = glueContext.create_dynamic_frame.from_options(
    connection_type="JiraCloud",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "issue",
        "API_VERSION": "v3",
        "NUM_PARTITIONS": "10"
    }
```

Opciones de conexión de Jira Cloud

Existen las siguientes opciones para establecer conexión con Jira Cloud:

- `ENTITY_NAME`(cadena): (obligatorio) se usa para lectura. El nombre del objeto en Jira Cloud.
- `API_VERSION`(cadena): (obligatorio) se usa para lectura. Versión de la API de REST de Jira Cloud que desea usar. Por ejemplo: v3.

- `DOMAIN_URL`(Cadena): (obligatorio) El ID de Jira Cloud que desea utilizar.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.
- `NUM_PARTITIONS`(entero): predeterminado: 1. Se usa para leer. Número de particiones para leer.

Limitaciones y notas del conector de Jira Cloud

Las siguientes son limitaciones o notas para el conector de Jira Cloud:

- El operador `Contains` no es compatible con el campo `resourceName`, que es de tipo de datos `String`.
- De forma predeterminada, si no se aplica ningún filtro explícito, solo se rastrearán los problemas de los últimos 30 días. Los usuarios tienen la opción de anular este filtro predeterminado especificando un filtro personalizado.

Conexión a Kustomer

Kustomer es una potente plataforma de experiencia del cliente que reúne todo lo necesario para mejorar la atención en una herramienta fácil de usar.

Temas

- Compatibilidad de AWS Glue con Kustomer
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de Kustomer
- Configuración de las conexiones a Kustomer
- Lectura de entidades de Kustomer
- Opciones de conexión a Kustomer
- Limitaciones de Kustomer

Compatibilidad de AWS Glue con Kustomer

AWS Glue admite Kustomer de la siguiente manera:

¿Es compatible como origen?

Sí. Puede utilizar los trabajos de ETL de AWS Glue para consultar datos de Kustomer.

¿Es compatible como destino?

No.

Versiones de la API de Kustomer compatibles

Las siguientes versiones de la API de Kustomer son compatibles:

- v1

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS IAM necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si no desea utilizar el método anterior, puede utilizar las siguientes políticas de IAM administradas:

- AWSGlueServiceRole: da acceso a recursos que precisan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: otorga acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la Consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de Kustomer

Antes de poder utilizar AWS Glue para transferir datos desde Kustomer a destinos compatibles, deberá cumplir estos requisitos:

Requisitos mínimos

Los requisitos mínimos son los siguientes:

- Tener una cuenta en Kustomer que contenga los datos que desea transferir.
- Haber creado la clave de API en la configuración de la cuenta. Para obtener más información, consulte Creación de una clave de API.
- Se proporciona la clave de API a AWS Glue al crear la conexión.

Si cumple estos requisitos, estará listo para conectar AWS Glue a la cuenta de Kustomer.

Creación de una clave de API

Para crear una clave de API que utilizará para crear una conexión para el conector de Kustomer en AWS Glue Studio:

1. Inicie sesión en el panel de Kustomer con sus credenciales.
2. Elija el icono Configuración en el menú situado al costado izquierdo.
3. Amplíe el menú desplegable Seguridad y seleccione Claves de API.

4. En la página de creación de la clave de API, seleccione Agregar una clave de API en la esquina superior derecha.
5. Rellene las entradas obligatorias correspondientes a la clave de API que se va a crear.
   - Nombre: cualquier nombre para la clave de API.
   - Roles: se debe seleccionar “org” para que las API de Kustomer funcionen.
   - Caducará (en días): la cantidad de días durante los que desea que la clave de API permanezca válida. Puede establecer esta opción en No caducará nunca, si es lo que el caso de uso precisa.
6. Seleccione Crear.
7. Guarde el valor (token) de la clave de API para usarlo posteriormente a fin de crear una conexión para el conector de Kustomer en AWS Glue Studio.

Configuración de las conexiones a Kustomer

Para configurar una conexión a Kustomer:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles:
   a. En el caso de las aplicaciones conectadas administradas por el cliente, el secreto debe contener el secreto del consumidor de la aplicación conectada con `apiKey` como la clave.
   b. Nota: Debe crear un secreto para las conexiones en AWS Glue.

1. En AWS Glue Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:
   a. En Conexiones, elija Crear conexión.
   b. Al seleccionar un Origen de datos, elija Kustomer.
   c. Seleccione el rol de AWS IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

      JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
```

```
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

d. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.

e. Seleccione las opciones de red si quiere usar su red.

2. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.

Lectura de entidades de Kustomer

Requisito previo

Un objeto de Kustomer desde el que desea leer. Necesitará el nombre del objeto, como Marcas o Tarjetas. En la siguiente tabla se muestran las entidades admitidas.

Entidades compatibles como origen:

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Marcas	No	Sí	No	Sí	No
Tarjetas	No	Sí	No	Sí	No
Configuración del chat	No	No	No	Sí	No
Empresas	Sí	Sí	Sí	Sí	Sí
Conversaciones	Sí	Sí	Sí	Sí	Sí

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Clientes	Sí	Sí	Sí	Sí	Sí
Búsquedas de clientes ancladas	No	Sí	No	Sí	No
Posición de búsquedas de clientes	No	No	No	Sí	No
Enlaces de correo	No	Sí	No	Sí	No
Enlaces web	No	Sí	No	Sí	No
Artículos de KB	No	Sí	No	Sí	No
Categorías de KB	No	Sí	No	Sí	No
Formularios de KB	No	Sí	No	Sí	No
Rutas de KB	No	Sí	No	Sí	No
Etiquetas de KB	No	Sí	No	Sí	No
Plantillas de KB	No	Sí	No	Sí	No
Temas de KB	No	Sí	No	Sí	No
Klasses	No	Sí	No	Sí	No
KViews	No	Sí	No	Sí	No

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Mensajes	Sí	Sí	Sí	Sí	Sí
Notas	Sí	Sí	Sí	Sí	Sí
Notificaciones	No	Sí	No	Sí	No

Ejemplo:

```
Kustomer_read = glueContext.create_dynamic_frame.from_options(
    connection_type="kustomer",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "brands",
        "API_VERSION": "v1"
    }
```

Detalles de entidades y campos de Kustomer

Para obtener más información acerca de las entidades y los detalles de los campos, consulte:

- Marcas
- Tarjetas
- Configuración del chat
- Empresas
- Conversaciones
- Clientes
- Búsquedas de clientes ancladas
- Posición de búsquedas de clientes
- Enlaces de correo
- Enlaces web
- Artículos de KB
- Categorías de KB

- Formularios de KB
- Rutas de KB
- Etiquetas de KB
- Plantillas de KB
- Temas de KB
- Klasses
- KViews
- Mensajes
- Notas
- Notificaciones

API v1

Entidad	Campo	Tipo de datos:	Operadores admitidos
Marcas	id	Cadena	N/A
	nombre	Cadena	N/A
	iconUrl	Cadena	N/A
	createdAt	DateTime	N/A
	updatedAt	DateTime	N/A
	modifiedAt	DateTime	N/A
	predeterminado	Booleano	N/A
Tarjetas	id	Cadena	N/A
	nombre	Cadena	N/A
	createdAt	DateTime	N/A
	updatedAt	DateTime	N/A
	modifiedAt	DateTime	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	Descripción	Cadena	N/A
	url	Cadena	N/A
	contextos	Enumeración	N/A
Configuración del chat	id	Cadena	N/A
	settingsVersion	Entero	N/A
	widgetType	Cadena	N/A
	versión	Entero	N/A
	teamName	Cadena	N/A
	saludo	Cadena	N/A
	respuesta automática	Cadena	N/A
	embedIconUrl	Cadena	N/A
	embedIconColor	Cadena	N/A
	fallbackEmailSubject	Cadena	N/A
	fallbackEmailIntroduction	Cadena	N/A
	enabled	Booleano	N/A
	outboundChatEnabled	Booleano	N/A
	updatedAt	DateTime	N/A
	modifiedAt	DateTime	N/A
	offhoursMessage	Cadena	N/A
	offhoursImageUrl	Cadena	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	closableChat	Booleano	N/A
	noHistory	Booleano	N/A
	disableAttachments	Booleano	N/A
	volumeControl	Struct	N/A
	singleSessonChat	Booleano	N/A
	showTypingIndicatorWeb	Booleano	N/A
Empresas	id	Cadena	N/A
	nombre	Cadena	=, !=, CONTAINS
	createdAt	DateTime	N/A
	updatedAt	DateTime	N/A
	modifiedAt	DateTime	=, !=, <, <=, >, >=, BETWEEN
	etiquetas	Enumeración	N/A
	domains	Enumeración	N/A
	correos electrónicos	Enumeración	N/A
	teléfonos	Enumeración	N/A
	mensajes de WhatsApp	Enumeración	N/A
	redes sociales	Enumeración	N/A
	url	Enumeración	N/A
	ubicaciones	Enumeración	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	roleGroupVersions	Enumeración	N/A
	rev	Entero	N/A
Conversaciones	id	Cadena	N/A
	nombre	Cadena	=, !=, CONTAINS
	vista previa	Cadena	N/A
	canales	Enumeración	N/A
	status	Cadena	=, !=, CONTAINS
	messageCount	Entero	=, !=, >, >=, <, <=
	noteCount	Entero	=, !=, >, >=, <, <=
	satisfacción	Entero	=, !=, >, >=, <, <=
	satisfactionLevel	Struct	N/A
	createdAt	DateTime	=, !=, <, <=, >, >=, BETWEEN
	updatedAt	DateTime	=, !=, <, <=, >, >=, BETWEEN
	modifiedAt	DateTime	=, !=, <, <=, >, >=, BETWEEN
	lastActivityAt	DateTime	N/A
	spam	Booleano	N/A
	finalizó	Booleano	=, !=
	endedAt	DateTime	=, !=, <, <=, >, >=, BETWEEN

Entidad	Campo	Tipo de datos:	Operadores admitidos
	endedReason	Cadena	CONTAINS
	endedByType	Cadena	N/A
	importedAt	Cadena	N/A
	etiquetas	Enumeración	N/A
	suggestedTags	Enumeración	N/A
	opinión	Cadena	N/A
	predicciones	Enumeración	N/A
	suggestedShortcuts	Enumeración	N/A
	firstMessageIn	Struct	N/A
	firstMessageOut	Struct	N/A
	lastMessageIn	Struct	N/A
	lastMessageOut	Struct	N/A
	lastMessageAt	DateTime	=, !=, <, <=, >, >=, BETWEEN
	lastMessageUnrespondedTo	Struct	N/A
	lastMessageUnrespondedToSinceLastDone	Struct	N/A
	assignedUsers	Enumeración	N/A
	assignedTeams	Enumeración	N/A
	firstResponse	Struct	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	firstResponseSince LastDone	Struct	N/A
	lastResponse	Struct	N/A
	firstDone	Struct	N/A
	lastDone	Struct	N/A
	direction	Cadena	=, !=, CONTAINS
	lastMessageDirection	Cadena	N/A
	outboundM essageCount	Entero	N/A
	inboundMe ssageCount	Entero	N/A
	rev	Entero	N/A
	priority	Entero	=, !=, >, >=, <, <=
	roleGroupVersions	Enumeración	N/A
	accessOverride	Enumeración	N/A
	asistente	Struct	N/A
	fase	Cadena	N/A
	Habilidades	Enumeración	N/A
	matchedTi meBasedRules	Enumeración	N/A
Clientes	id	Cadena	N/A
	nombre	Cadena	=, !=, CONTAINS

Entidad	Campo	Tipo de datos:	Operadores admitidos
	displayName	Cadena	N/A
	displayColor	Cadena	N/A
	displayIcon	Cadena	N/A
	externalId	Cadena	=, !=, CONTAINS
	externalIds	Enumeración	N/A
	sharedExternalIds	Enumeración	N/A
	correos electrónicos	Enumeración	N/A
	sharedEmails	Enumeración	N/A
	teléfonos	Enumeración	N/A
	sharedPhones	Enumeración	N/A
	mensajes de WhatsApp	Enumeración	N/A
	facebookIds	Enumeración	N/A
	instagramIds	Enumeración	N/A
	redes sociales	Enumeración	N/A
	sharedSocials	Enumeración	N/A
	url	Enumeración	N/A
	ubicaciones	Enumeración	N/A
	activeUsers	Enumeración	N/A
	monitores	Enumeración	N/A
	recentLocation	Struct	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	locale	Cadena	=, !=, CONTAINS
	timeZone	Cadena	N/A
	gender	Cadena	=, !=, CONTAINS
	createdAt	DateTime	=, !=, <, <=, >, >=, BETWEEN
	updatedAt	DateTime	=, !=, <, <=, >, >=, BETWEEN
	modifiedAt	DateTime	=, !=, <, <=, >, >=, BETWEEN
	lastActivityAt	DateTime	N/A
	eliminado	Booleano	N/A
	lastConversation	Struct	N/A
	conversationCounts	Struct	N/A
	vista previa	Struct	N/A
	etiquetas	Enumeración	N/A
	progressiveStatus	Cadena	=, !=, CONTAINS
	verified	Booleano	N/A
	rev	Entero	N/A
	recentItems	Enumeración	N/A
	defaultLang	Cadena	=, !=, CONTAINS
	satisfactionLevel	Struct	N/A
	roleGroupVersions	Enumeración	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	accessOverride	Enumeración	N/A
	companyName	Cadena	N/A
	firstName	Cadena	N/A
	lastName	Cadena	N/A
Búsquedas de clientes ancladas	id	Cadena	N/A
	buscar	Cadena	N/A
	createdAt	DateTime	N/A
Posición de búsquedas de clientes	id	Cadena	N/A
	positions	Enumeración	N/A
	elemento secundario	Enumeración	N/A
	createdAt	DateTime	N/A
	updatedAt	DateTime	N/A
	modifiedAt	DateTime	N/A
	rev	Entero	N/A
Enlaces de correo	id	Cadena	N/A
	Descripción	Cadena	N/A
	depuración	Booleano	N/A
	correo electrónico	Cadena	N/A
	eventName	Cadena	N/A
	título	Cadena	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	hash	Cadena	N/A
	key	Cadena	N/A
	createdAt	DateTime	N/A
	modifiedAt	DateTime	N/A
	updatedAt	DateTime	N/A
Enlaces web	id	Cadena	N/A
	Descripción	Cadena	N/A
	eventName	Cadena	N/A
	hash	Cadena	N/A
	url	Cadena	N/A
	createdAt	DateTime	N/A
	modifiedAt	DateTime	N/A
	updatedAt	DateTime	N/A
	título	Cadena	N/A
	versión	Entero	N/A
	depuración	Booleano	N/A
Artículos de KB	id	Cadena	N/A
	hash	Cadena	N/A
	título	Cadena	N/A
	origen	Cadena	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	status	Cadena	N/A
	scope	Cadena	N/A
	createdAt	DateTime	N/A
	updatedAt	DateTime	N/A
	eliminado	Booleano	N/A
	deletedAt	DateTime	N/A
	modifiedAt	DateTime	N/A
	publishedAt	DateTime	N/A
	etiquetas	Enumeración	N/A
	categories	Enumeración	N/A
	knowledgeBases	Enumeración	N/A
	metaTitle	Cadena	N/A
	metaDescription	Cadena	N/A
	metaKeywords	Enumeración	N/A
	langVersions	Struct	N/A
	latestLangs	Struct	N/A
Categorías de KB	id	Cadena	N/A
	hash	Cadena	N/A
	createdAt	DateTime	N/A
	modifiedAt	DateTime	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	updatedAt	DateTime	N/A
	publicado	Booleano	N/A
	positions	Enumeración	N/A
	categoryPositions	Enumeración	N/A
	root	Booleano	N/A
	idiomas	Struct	N/A
Formularios de KB	id	Cadena	N/A
	nombre	Cadena	N/A
	URL amigable	Cadena	N/A
	hash	Cadena	N/A
	cuerpo	Cadena	N/A
	diseño	Enumeración	N/A
	layoutV2	Enumeración	N/A
	componentsV2	Struct	N/A
	condiciones	Struct	N/A
	avanzado	Booleano	N/A
	createdAt	DateTime	N/A
	updatedAt	DateTime	N/A
	publishedAt	DateTime	N/A
	modifiedAt	Cadena	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	publicado	Booleano	N/A
	fragmentos	Enumeración	N/A
	recaptcha	Booleano	N/A
	klass	Cadena	N/A
	channel	Cadena	N/A
	desviación	Booleano	N/A
	formHookEnabled	Booleano	N/A
	replyFrom	Cadena	N/A
	wcag	Booleano	N/A
Rutas de KB	id	Cadena	N/A
	url	Cadena	N/A
	routableType	Cadena	N/A
	routableId	Cadena	N/A
	createdAt	DateTime	N/A
	updatedAt	DateTime	N/A
	modifiedAt	DateTime	N/A
Etiquetas de KB	id	Cadena	N/A
	nombre	Cadena	N/A
	createdAt	DateTime	N/A
	updatedAt	DateTime	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	modifiedAt	DateTime	N/A
Plantillas de KB	id	Cadena	N/A
	título	Cadena	N/A
	Descripción	Cadena	N/A
	beta	Booleano	N/A
	manifiesto	Struct	N/A
	jsxSnippets	Enumeración	N/A
	images	Enumeración	N/A
	versión	Cadena	N/A
	createdAt	DateTime	N/A
	updatedAt	DateTime	N/A
Temas de KB	id	Cadena	N/A
	nombre	Cadena	N/A
	activa	Booleano	N/A
	predeterminado	Booleano	N/A
	lastfileUpdatedAt	DateTime	N/A
	personalizado	Booleano	N/A
	status	Cadena	N/A
	templateVersionId	Cadena	N/A
	templateTitle	Cadena	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	templateVersion	Cadena	N/A
	manifiesto	Struct	N/A
	configSnippets	Enumeración	N/A
	jsxSnippets	Enumeración	N/A
	createdAt	DateTime	N/A
	updatedAt	DateTime	N/A
	modifiedAt	DateTime	N/A
	rev	Entero	N/A
Klasses	id	Cadena	N/A
	nombre	Cadena	N/A
	icono	Cadena	N/A
	color	Cadena	N/A
	appDisabled	Booleano	N/A
	status	Cadena	N/A
	updatedAt	DateTime	N/A
	createdAt	DateTime	N/A
	s3DataUrl	Cadena	N/A
KViews	id	Cadena	N/A
	recurso	Cadena	N/A
	plantilla	Cadena	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	context	Cadena	N/A
	meta	Struct	N/A
	appDisabled	Booleano	N/A
	enabled	Booleano	N/A
	avanzado	Booleano	N/A
	diseño	Enumeración	N/A
	componentes	Struct	N/A
	condiciones	Struct	N/A
	rev	Entero	N/A
	createdAt	DateTime	N/A
	modifiedAt	DateTime	N/A
	updatedAt	DateTime	N/A
Notificaciones	id	Cadena	N/A
	nombre	Cadena	N/A
	status	Cadena	N/A
	event	Struct	N/A
	createdAt	DateTime	N/A
	updatedAt	DateTime	N/A
Mensajes	id	Cadena	N/A
	externalId	Cadena	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	channel	Cadena	=, !=, CONTAINS
	aplicación	Cadena	N/A
	tamaño	Entero	=, !=, >, >=, <, <=
	direction	Cadena	=, !=, CONTAINS
	vista previa	Cadena	N/A
	subject	Cadena	N/A
	meta	Struct	N/A
	status	Cadena	=, !=, CONTAINS
	directionType	Cadena	=, !=, CONTAINS
	assignedTeams	Enumeración	N/A
	assignedUsers	Enumeración	N/A
	errorAt	DateTime	=, !=, <, <=, >, >=, BETWEEN
	auto	Booleano	=, !=
	sentAt	DateTime	=, !=, <, <=, >, >=, BETWEEN
	createdAt	DateTime	=, !=, <, <=, >, >=, BETWEEN
	updatedAt	DateTime	N/A
	modifiedAt	DateTime	N/A
	censurado	Booleano	N/A
	createdByTeams	Enumeración	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	rev	Entero	N/A
	reactions	Enumeración	N/A
	intentDetections	Enumeración	N/A
Notas	id	Cadena	N/A
	cuerpo	Cadena	CONTAINS
	createdAt	DateTime	=, !=, <, <=, >, >=, BETWEEN
	updatedAt	DateTime	=, !=, <, <=, >, >=, BETWEEN
	modifiedAt	DateTime	=, !=, <, <=, >, >=, BETWEEN
	createdByTeams	Enumeración	N/A

Consultas de partición

Partición basada en campos

Puede proporcionar las opciones adicionales de Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` y `NUM_PARTITIONS` si quiere utilizar la simultaneidad en Spark. Con estos parámetros, la consulta original se dividiría en un número `NUM_PARTITIONS` de subconsultas que las tareas de Spark pueden ejecutar simultáneamente.

- `PARTITION_FIELD`: el nombre del campo que se utilizará para particionar la consulta.
- `LOWER_BOUND`: un valor de límite inferior inclusivo del campo de partición elegido.

  Para el campo DateTime, aceptamos el valor en formato ISO.

  Ejemplo de valor válido:

```
"2023-01-15T11:18:39.205Z"
```

- UPPER_BOUND: un valor límite superior exclusivo del campo de partición elegido.
- NUM_PARTITIONS: el número de particiones.

En la siguiente tabla se detalla la compatibilidad de los campos de partición por entidad:

Nombre de la entidad	Campos de partición	Tipo de datos:
Empresas	modifiedAt	DateTime
Conversaciones	createdAt, updatedAt , modifiedAt, endedAt, lastMessageAt	DateTime
	messageCount, noteCount	BigInteger
	priority	Entero
Clientes	createdAt, updatedAt, modifiedAt	DateTime
Mensajes	errorAt, sentAt, createdAt	DateTime
	tamaño	BigInteger
Notas	createdAt, updatedAt, modifiedAt	DateTime

Ejemplo:

```
Kustomer_read = glueContext.create_dynamic_frame.from_options(
    connection_type="kustomer",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "conversation",
        "API_VERSION": "v1",
        "PARTITION_FIELD": "createdAt"
        "LOWER_BOUND": "2023-01-15T11:18:39.205Z"
        "UPPER_BOUND": "2023-02-15T11:18:39.205Z"
        "NUM_PARTITIONS": "2"
```

```
    }
```

Opciones de conexión a Kustomer

Existen las siguientes opciones para establecer conexión con Kustomer:

- `ENTITY_NAME`(cadena): (obligatorio) se usa para lectura. El nombre del objeto en Stripe.
- `API_VERSION`(cadena): (obligatorio) se usa para lectura. Versión de la API de REST de Kustomer que desea usar.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.
- `PARTITION_FIELD`(cadena): se usa para lectura. Campo que se utilizará para particionar la consulta.
- `LOWER_BOUND`(cadena): se usa para lectura. Un valor de límite inferior inclusivo del campo de partición elegido.
- `UPPER_BOUND`(cadena): se usa para lectura. Un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`(entero): predeterminado: 1. Se usa para leer. Número de particiones para leer.
- `INSTANCE_URL`(cadena): (obligatorio) se usa para lectura. URL de la instancia de Kustomer.

Limitaciones de Kustomer

Las siguientes son limitaciones o notas correspondientes a Kustomer:

- La entidad `Customer Searches` no es compatible porque la documentación de la API de Kustomer no ha declarado ningún punto de conexión para esta.
- No se admite la filtración ni la transferencia incremental en la entidad `Klasses`.
- “Ordenar por” se puede admitir en varios campos aplicables en una sola solicitud.

  Sin embargo, se ha observado que la ordenación por funcionalidad en varios campos se comporta de manera inconsistente en el SaaS en algunas combinaciones. Es impredecible, ya que puede haber combinaciones “n” que podrían arrojar resultados de ordenación incorrectos. Por ejemplo:

En el caso de la entidad `Customers`, “ordenar por `progressiveStatus desc, name asc`” no arroja el resultado correcto ordenado. Ordena únicamente en función del orden `progressiveStatus`. Si se observa este comportamiento, puede utilizar un único campo para ordenar.

- “Ordenar por” en el campo ID solo es compatible con las entidades `Conversations` y `Messages` como parámetro de consulta. Por ejemplo: https://api.kustomerapp.com/v1/conversations?sort=desc (esto ordena los resultados por ID en orden descendente).

  Además, cualquier otro filtro u ordenación en cualquier otro campo se traduce en un cuerpo de solicitud POST, con el punto de conexión de la API como POST https://api.kustomerapp.com/v1/customers/search Para admitir la ordenación por ID en `Conversations` y `Messages`, solo debe estar presente la ordenación por ID o cualquier otro filtro u ordenación en cualquier otro campo aplicable.

- Kustomer permite obtener un máximo de 10 000 registros, independientemente de si se trata de una solicitud filtrada o no filtrada. Debido a esta limitación, se perderán datos para cualquier entidad que tenga más de 10 000 registros. Existen dos soluciones alternativas que puede aplicar para mitigar parcialmente esta situación:
  - Aplique filtros para obtener un conjunto de registros específico.
  - Si hay más de 10 000 registros con un filtro aplicado, aplique un valor de filtro sucesivo en una nueva solicitud posterior o aplique rangos a los filtros. Por ejemplo:

    filterExpression de la primera solicitud: `modifiedAt >= 2022-03-15T05:26:23.000Z and modifiedAt < 2023-03-15T05:26:23.000Z`

    Suponga que esto agota el límite de registro de 10 000.

    Se puede activar otra solicitud con filterExpression: `modifiedAt >= 2023-03-15T05:26:23.000Z`

- Como comportamiento de SaaS, el operador `CONTAINS` de Kustomer solo admite coincidencias de palabras completas y no coincidencias parciales dentro de una palabra. Por ejemplo: “body CONTAINS 'test record'” coincidirá con un registro que contenga “test” en el campo “body”. Sin embargo, “body CONTAINS 'test'” no coincidirá con un registro que contenga “testAnotherRecord” en el campo “body”.

Conexión a LinkedIn

LinkedIn es una herramienta de marketing de pago que ofrece acceso a las redes sociales de LinkedIn a través de diversas publicaciones patrocinadas y otros métodos. LinkedIn es una herramienta de marketing potente para que las empresas B2B generen clientes potenciales, reconocimiento en línea, compartan contenidos y mucho más.

Temas

- Compatibilidad de AWS Glue con LinkedIn
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de LinkedIn
- Configuración de conexiones a LinkedIn
- Cómo leer de entidades de LinkedIn
- Opción de conexión a LinkedIn
- Cómo crear una cuenta de LinkedIn
- Limitaciones

Compatibilidad de AWS Glue con LinkedIn

AWS Glue es compatible con LinkedIn de la siguiente manera:

¿Es compatible como origen?

Sí. Puede usar los trabajos de ETL de AWS Glue para consultar datos de LinkedIn.

¿Es compatible como destino?

No.

Versiones de la API de LinkedIn compatibles

202406 (junio de 2024)

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si no desea utilizar el método anterior, como alternativa, utilice las siguientes políticas de IAM administradas:

- AWSGlueServiceRole: concede acceso a los recursos que necesitan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: concede acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de LinkedIn

Antes de poder utilizar AWS Glue para transferir desde LinkedIn, deberá cumplir los siguientes requisitos:

Requisitos mínimos

- Tener una cuenta de LinkedIn. Para obtener más información sobre cómo crear una cuenta, consulte Creación de una cuenta de LinkedIn.
- La cuenta de LinkedIn debe estar habilitada para el acceso a la API.
- Haber creado una integración de `OAuth2 API` en la cuenta de LinkedIn. Esta integración proporciona las credenciales de cliente que AWS Glue utiliza para acceder a los datos de forma segura cuando hace llamadas autenticadas a la cuenta. Para obtener más información, consulte the section called “Cómo crear una cuenta de LinkedIn”.

Si cumple estos requisitos, estará listo para conectar AWS Glue a la cuenta de LinkedIn. Para conexiones típicas, no necesita hacer nada más en LinkedIn.

Configuración de conexiones a LinkedIn

LinkedIn admite el tipo de concesión `AUTHORIZATION_CODE` para OAuth2.

Este tipo de concesión se considera un `OAuth` “de tres vías”, ya que se basa en redirigir a los usuarios al servidor de autorización externo para autenticar al usuario. Los usuarios aún pueden optar por crear una aplicación conectada propia en LinkedIn y proporcionar un ID y secreto de cliente propios al crear conexiones a través de la consola de AWS Glue. En este escenario, aún se abrirá LinkedIn para iniciar sesión y autorizar a AWS Glue para que acceda a sus recursos.

Este tipo de concesión da lugar tanto a un token de actualización como a un token de acceso. El token de acceso caduca 60 días después de su creación. Se puede obtener un nuevo token de acceso mediante el token de actualización.

Para consultar la documentación pública de LinkedIn sobre la creación de una aplicación conectada para el flujo de `Authorization Code OAuth`, consulte Flujo de código de autorización (OAuth de 3 vías).

Configuración de una conexión a LinkedIn

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles:

   - En el caso de una aplicación conectada administrada por el cliente, el secreto debe contener el secreto del consumidor de la aplicación conectada con la clave `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET`.

- En el caso de una aplicación conectada administrada por AWS: secreto vacío o un secreto con algún valor temporal.

> **Note**
>
> Es imprescindible crear un secreto por conexión en AWS Glue.

2. En AWS Glue Studio, siga los pasos que se indican a continuación en Conexiones de datos para crear una conexión:

   1. Al seleccionar un Tipo de conexión, elija LinkedIn.
   2. Proporcione el entorno de LinkedIn.
   3. Seleccione el rol de IAM que AWS Glue puede asumir y que cuente con los permisos necesarios para realizar las siguientes acciones:

      JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

   4. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.
   5. Seleccione las opciones de red si quiere usar la red.

3. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.

Cómo leer de entidades de LinkedIn

Requisitos previos

Un objeto de LinkedIn desde el que desea leer. Consulte la tabla de entidades compatibles que aparece a continuación para comprobar las entidades disponibles.

Entidades compatibles

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite Partición
Cuentas de anuncios	Sí	Sí	Sí	Sí	No
Campañas	Sí	Sí	Sí	Sí	No
Grupos de campañas	Sí	Sí	Sí	Sí	No
Creativos	Sí	Sí	Sí	Sí	No
Análisis de anuncios	Sí	No	No	Sí	No
Análisis de anuncios: todas las AdAcocunts	Sí	No	No	Sí	No
Análisis de anuncios: todas las campañas	Sí	No	No	Sí	No
Análisis de anuncios: todos los CampaignGroups	Sí	No	No	Sí	No

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite Partición
Análisis de anuncios: todos los AdCreatives	Sí	No	No	Sí	No
Compartir estadísticas	Sí	No	No	Sí	No
Estadísticas de la página	Sí	No	No	Sí	No
Estadísticas de seguidores	Sí	No	No	Sí	No

Ejemplo

```
netsuiteerp_read = glueContext.create_dynamic_frame.from_options(
    connection_type="linkedin",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "adaccounts",
        "API_VERSION": "202406"
    }
)
```

Detalles de entidades y campos de LinkedIn

Tipo de datos de los campos	Operadores de filtro admitidos
Cadena	=
DateTime	BETWEEN, =
Numérico	=

Tipo de datos de los campos	Operadores de filtro admitidos
Booleano	=

Opción de conexión a LinkedIn

Las siguientes son opciones de conexión para LinkedIn:

- `ENTITY_NAME`(cadena): (obligatorio) se utiliza para leer y escribir. El nombre del objeto en LinkedIn. Por ejemplo, adAccounts.
- `API_VERSION`(cadena): (obligatorio) se utiliza para leer y escribir. Versión de la API de REST de LinkedIn que desea usar. El valor será 202406, ya que LinkedIn actualmente solo admite la versión 202406.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desea seleccionar para la entidad seleccionada.
- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.

Cómo crear una cuenta de LinkedIn

Cómo crear una aplicación de LinkedIn y credenciales de OAuth

1. Vaya a la página de la Red de desarrolladores de LinkedIn e inicie sesión con las credenciales de la cuenta de LinkedIn.
2. Vaya a la página Mis aplicaciones y elija Crear aplicación para crear una nueva aplicación de LinkedIn.
3. Ingrese los siguientes datos en el formulario de registro de la aplicación:
    - Nombre de la empresa: seleccione una empresa existente o cree una nueva.
    - Nombre: ingrese el nombre de la aplicación.
    - Descripción: ingrese la descripción de la aplicación.
    - Logotipo de la aplicación: seleccione un archivo de imagen como logotipo de la aplicación.
    - Uso de la aplicación: seleccione el uso de la aplicación.

- URL del sitio web: ingrese la URL del sitio web que contiene información detallada sobre la aplicación.
- Correo electrónico empresarial: ingrese la dirección de correo electrónico empresarial.
- Teléfono empresarial: ingrese el número de teléfono empresarial.
- Términos de uso de la API de LinkedIn: lea y acepte.

4. Al completar el formulario de registro de la aplicación, seleccione Enviar.

   Se le redirigirá a la página Autenticación, donde aparecerán las claves de autenticación (ID de cliente y secreto de cliente) y otros detalles relevantes.
5. Si la aplicación web necesita acceder a la dirección de correo electrónico del usuario desde su cuenta de LinkedIn, seleccione el permiso `r_emailaddress`. Además, puede especificar las URL de redireccionamiento autorizadas para la aplicación de LinkedIn.

Cómo crear una página en una cuenta de LinkedIn

1. Vaya a Productos de LinkedIn para desarrolladores.
2. En la esquina superior derecha de la página Productos de LinkedIn para desarrolladores, seleccione Mis aplicaciones.
3. En la esquina superior derecha de la página Mis aplicaciones, seleccione Crear aplicación.
4. En la página Crear una aplicación, en el campo Nombre de la aplicación, ingrese el nombre de la aplicación.
5. En el campo Página de LinkedIn, ingrese el nombre o la URL de la página de la empresa.

   > **Note**
   >
   > Si no tiene una página de LinkedIn, puede crear una. Para ello, seleccione Crear una nueva página de LinkedIn.
6. En el campo URL de la política de privacidad, ingrese la URL de la política de privacidad.
7. Elija Cargar un logotipo para cargar una imagen que se mostrará a los usuarios cuando se autoricen con la aplicación.
8. En la sección Contrato jurídico, seleccione He leído y acepto estos términos.
9. Seleccione Crear una aplicación.

   Se creará la nueva aplicación, que estará disponible en la pestaña Mis aplicaciones.

Cómo publicar anuncios de campaña en LinkedIn

1. Inicie sesión en el Administrador de Campañas.
2. Seleccione un Grupo de campaña existente, o elija Crear para crear uno nuevo.
3. Seleccione el objetivo.
4. Seleccione el grupo, el presupuesto y el horario.
5. Establezca el público objetivo.
6. Seleccione el formato del anuncio.
7. Seleccione el presupuesto y el horario.
8. Configure el anuncio o los anuncios.
9. Revise y lance.

Limitaciones

Para los campos `ad_analytics_all_adAccounts`, `ad_analytics_all_campaigns`, `ad_analytics_all_campaign_groups` y `ad_analytics_all_adCreatives` de Analytics, se necesita un filtro para recuperar los registros.

Conexión a Mailchimp

Mailchimp es una plataforma integral de marketing que ayuda a gestionar los clientes, consumidores y otros interesados, así como a comunicarse con ellos. Su enfoque de marketing se centra en buenas prácticas de administración de contactos, correos electrónicos con un diseño atractivo, flujos de trabajo automatizados únicos y un potente análisis de datos. Si es usuario de Mailchimp, puede conectar AWS Glue a la cuenta de Mailchimp. Tras ello, podrá utilizar Mailchimp como origen de datos en los trabajos de ETL. Ejecute estos trabajos para transferir datos entre Mailchimp y los servicios de AWS u otras aplicaciones compatibles.

Temas

- Compatibilidad de AWS Glue con Mailchimp
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de Mailchimp
- Configuración de las conexiones a Mailchimp
- Lectura de entidades de Mailchimp
- Opciones de conexión a Mailchimp

- Creación de una cuenta de Mailchimp
- Limitaciones

Compatibilidad de AWS Glue con Mailchimp

AWS Glue es compatible con Mailchimp de la siguiente manera:

¿Es compatible como origen?

Sí. Puede utilizar los trabajos de ETL de AWS Glue para consultar datos de Mailchimp.

¿Es compatible como destino?

No.

Versiones de la API de Mailchimp compatibles

3.0

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
```

```
}
```

Si no desea utilizar el método anterior, como alternativa, utilice las siguientes políticas de IAM administradas:

- AWSGlueServiceRole: concede acceso a los recursos que necesitan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: concede acceso completo a los recursos de AWS Gluecuando una identidad a la que está vinculada la política utiliza la Consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de Mailchimp

Antes de poder utilizar AWS Glue para transferir desde Mailchimp, deberá cumplir los siguientes requisitos:

Requisitos mínimos

- Tener una cuenta de Mailchimp con correo electrónico y contraseña. Para obtener más información sobre cómo crear una cuenta, consulte Creación de una cuenta de Mailchimp.
- Debe tener una cuenta de AWS creada con el servicio de acceso a AWS Glue.
- Asegúrese de haber creado uno de los siguientes recursos. Estos recursos proporcionan credenciales que AWS Glue utiliza para acceder a los datos de forma segura al realizar llamadas autenticadas a la cuenta.
  - Una aplicación para desarrolladores que admite la autenticación OAuth 2.0. Para obtener más información sobre cómo crear una aplicación para desarrolladores, consulte Creación de una cuenta de Mailchimp.

Si cumple estos requisitos, estará listo para conectar AWS Glue a la cuenta de Mailchimp. Si es una conexión típica, no necesita hacer nada más en Mailchimp.

Configuración de las conexiones a Mailchimp

Mailchimp admite los siguientes dos tipos de mecanismos de autenticación:

- Mailchimp admite el tipo de concesión `AUTHORIZATION_CODE`.
  - Este tipo de concesión se considera un `OAuth` de “tres patas”, ya que depende de redirigir a los usuarios al servidor de autorización de terceros para autenticarlos. Se utiliza para crear conexiones a través de la consola de AWS Glue. El usuario que crea una conexión puede, de forma predeterminada, confiar en una aplicación conectada propiedad de AWS Glue, en la que no necesita proporcionar ninguna información relacionada con `OAuth`, excepto su ID de cliente y secreto de cliente de Mailchimp. La consola de AWS Glue redirigirá al usuario a Mailchimp, donde deberá iniciar sesión y conceder a AWS Gluelos permisos solicitados para acceder a su instancia de Mailchimp.
  - Los usuarios aún pueden optar por crear su propia aplicación conectada en Mailchimp y proporcionar su propio ID y secreto de cliente al crear conexiones a través de la consola de AWS Glue. En este escenario, aún se abrirá Mailchimp para iniciar sesión y autorizar a AWS Glue para que acceda a sus recursos.
  - Para ver la documentación pública de Mailchimp sobre la creación de una aplicación conectada para el flujo `AUTHORIZATION_CODE OAuth`, consulte Access Data on Behalf of Other Users with OAuth 2 .
- Autenticación personalizada: para consultar la documentación pública de Mailchimp sobre cómo generar las claves de API necesarias para la autorización personalizada, consulte About API Keys.

Para configurar una conexión a Mailchimp:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles:
   - Autenticación `OAuth`: en el caso de una aplicación conectada administrada por el cliente, el secreto debe contener el secreto del cliente de la aplicación conectada con `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET` como clave.
   - Autenticación personalizada: en el caso de una aplicación conectada administrada por el cliente, el secreto debe contener el secreto del cliente de la aplicación conectada con “api_key” como clave.

> **Note**
>
> Es imprescindible crear un secreto por conexión en AWS Glue.

2. En AWS Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:

   a. En Conexiones, elija Crear conexión.

   b. Al seleccionar un Origen de datos, elija Mailchimp.

   c. Proporcione la `instanceUrl` de Mailchimp.

   d. Seleccione el rol de IAM que AWS Glue puede asumir y que cuente con los permisos necesarios para realizar las siguientes acciones:

      JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

   e. Seleccione el tipo de autenticación para conectarse a Mailchimp:

      - En el caso de la autenticación `OAuth`: proporcione la URL del token, el ID de cliente de la aplicación cliente administrada por el usuario del Mailchimp al que se desea conectar.
      - En el caso de la autenticación personalizada, seleccione el tipo de autenticación PERSONALIZADA para conectarse a Mailchimp.

f. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.

g. Seleccione las opciones de red si quiere usar su red.

3. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.
4. En la configuración del trabajo de AWS Glue, proporcione `connectionName` como una conexión de red adicional.

Lectura de entidades de Mailchimp

Requisitos previos

Un objeto de Mailchimp desde el que desea leer. Consulte la tabla de entidades compatibles que aparece a continuación para comprobar las entidades disponibles.

Entidades compatibles

- Informes de abuso
- Automatización
- Campaigns (Campañas)
- Detalles de los clics
- Listas
- Miembros
- Detalles de aperturas
- Segmentos
- Almacenes
- Cancelación de suscripción

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite Partición
Automatización	Sí	Sí	Sí	Sí	Sí
Campañas	No	No	No	No	No

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite Partición
Listas	Sí	Sí	No	Sí	Sí
Informa abuso	No	Sí	No	Sí	Sí
Informa aperturas	No	Sí	No	Sí	Sí
Informa clics	Sí	Sí	No	Sí	Sí
Informa cancelaciones de suscripciones	No	Sí	No	Sí	Sí
Segmento	No	Sí	No	Sí	Sí
Segmentar miembros	Sí	Sí	No	Sí	No
Almacenes	Sí	Sí	Sí	Sí	No

Ejemplo

```
mailchimp_read = glueContext.create_dynamic_frame.from_options(
            connection_type="mailchimp",
            connection_options={

                  "connectionName": "connectionName",

                  "ENTITY_NAME": "stores",
"INSTANCE_URL": "https://us14.api.mailchimp.com",
                  "API_VERSION": "3.0"
               })
```

Detalles de entidades y campos de Mailchimp

- Informes de abuso
- Automatización
- Campaigns (Campañas)
- Detalles de los clics
- Listas
- Miembros
- Detalles de aperturas
- Segmentos
- Almacenes
- Cancelación de suscripción

Consultas de particionamiento

Puede proporcionar las opciones adicionales de Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` y `NUM_PARTITIONS` si quiere utilizar la simultaneidad en Spark. Con estos parámetros, la consulta original se dividiría en un número `NUM_PARTITIONS` de subconsultas que las tareas de Spark pueden ejecutar simultáneamente.

- `PARTITION_FIELD`: el nombre del campo que se utilizará para particionar la consulta.
- `LOWER_BOUND`: un valor de límite inferior inclusivo del campo de partición elegido.

  Para el campo DateTime, aceptamos el valor en formato ISO.

  Ejemplo de valor válido:

  ```
  "2024-07-01T00:00:00.000Z"
  ```

- `UPPER_BOUND`: un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`: el número de particiones.

En la tabla siguiente, se describen los detalles de compatibilidad de campos de particiones de entidades:

Nombre de la entidad	Campos de partición	Tipo de datos:

Ejemplo:

```
read_read = glueContext.create_dynamic_frame.from_options(
    connection_type="mailchimp",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "automations",
        "API_VERSION": "3.0",
        "INSTANCE_URL": "https://us14.api.mailchimp.com",
        "PARTITION_FIELD": "create_time",
        "LOWER_BOUND": "2024-02-05T14:09:30.115Z",
        "UPPER_BOUND": "2024-06-07T13:30:00.134Z",
        "NUM_PARTITIONS": "3"
    }
```

Opciones de conexión a Mailchimp

Existen las siguientes opciones para establecer conexión con Mailchimp:

- `ENTITY_NAME`(cadena): (obligatorio) se utiliza para leer y escribir. El nombre del objeto en Mailchimp.
- `INSTANCE_URL`(cadena): (obligatorio) una URL de instancia de Mailchimp válida.
- `API_VERSION`(cadena): (obligatorio) se usa para lectura. Versión de la API de REST de Mailchimp Engage que desea utilizar. Por ejemplo: 3.0.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.
- `PARTITION_FIELD`(cadena): se usa para leer. Campo que se utilizará para particionar la consulta.

- `LOWER_BOUND`(cadena): se usa para leer. Un valor de límite inferior inclusivo del campo de partición elegido.
- `UPPER_BOUND`(cadena): se usa para leer. Un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`(entero): predeterminado: 1. Se usa para leer. Número de particiones para leer.

Creación de una cuenta de Mailchimp

1. Vaya a la página de inicio de sesión de Mailchimp, ingrese la dirección de correo electrónico y la contraseña y, a continuación, elija Iniciar sesión.
2. Abra el correo electrónico de confirmación de Mailchimp y seleccione el enlace de confirmación para verificar la cuenta.

   > **Note**
   >
   > El tiempo de recepción del correo electrónico de activación puede variar. Si no ha recibido el correo electrónico de activación, revise la carpeta de correo no deseado y lea nuestros consejos para solucionar problemas relacionados con el correo electrónico de activación. Mailchimp bloquea los registros desde direcciones de correo electrónico basadas en roles, como admin@pottedplanter.com o security@example.com.

   La primera vez que inicie sesión en la cuenta, Mailchimp solicitará la información requerida. Mailchimp utiliza esta información para ayudar a garantizar que la cuenta cumple con sus Términos de uso y para proporcionar orientación que le resulte relevante y que responda a las necesidades de la empresa.
3. Ingrese la información, siga las peticiones para finalizar el proceso de activación y comience a utilizar su nueva cuenta de Mailchimp.

Cómo registrar una aplicación de **`OAuth2.0`**

1. Vaya a la página de inicio de sesión de Mailchimp, ingrese la dirección de correo electrónico y la contraseña y, a continuación, elija Iniciar sesión.
2. Seleccione el icono Usuario en la esquina superior derecha y, a continuación, elija Cuenta y facturación en el menú desplegable.

3. Seleccione Extras y elija Aplicaciones registradas en el menú desplegable.
4. Busque la opción Registrar una aplicación y selecciónela.
5. Escriba la información siguiente:

   - Nombre de la aplicación: nombre de la aplicación.
   - Empresa/organización: nombre de la empresa u organización.
   - Sitio web de la aplicación: sitio web de la aplicación.
   - URI de redireccionamiento: un patrón de URI de redireccionamiento es una ruta de URI (o una lista de rutas separadas por comas) a la que Mailchimp puede redirigir (si se solicita) cuando finaliza el flujo de inicio de sesión. Por ejemplo, `https://ap-southeast-2\\.console\\.aws\\.amazon\\.com`
6. Seleccione Crear.
7. Ahora aparecerán el ID de cliente y el secreto de cliente. Cópielos y guárdelos en un lugar seguro. A continuación, seleccione Listo.

> **Note**
>
> Las cadenas de ID de cliente y secreto de cliente son las credenciales utilizadas para establecer una conexión con este conector cuando se utiliza AppFlow o AWS Glue.

Cómo generar una clave de API

1. Vaya a la página de inicio de sesión de Mailchimp, ingrese la dirección de correo electrónico y la contraseña y, a continuación, elija Iniciar sesión.
2. Seleccione el icono Usuario en la esquina superior derecha y, a continuación, elija Cuenta y facturación en el menú desplegable.
3. Seleccione Extras y elija Claves de API en el menú desplegable.
4. Elija Crear una clave.
5. Ingrese un nombre para la clave y elija Generar clave.

   En la siguiente página, aparecerá la clave de API generada.
6. Copia la clave, guárdala de forma segura y seleccione Listo.

Limitaciones

El conector de Mailchimp presenta las siguientes limitaciones:

- La filtración solo es compatible con las entidades `Campaigns`, `Automations`, `Lists`, `Open Details`, `Members` y `Segments`.
- Al utilizar un filtro en un campo de tipo de datos `DateTime`, los valores se deben transmitir en este formato: `yyyy-mm-ddThh:MM:ssZ`

Conexión con Microsoft Dynamics 365 CRM

Microsoft Dynamics 365 es una línea de productos de aplicaciones empresariales inteligentes para la planificación de recursos empresariales y administración de relaciones con los clientes.

Temas

- Compatibilidad de AWS Glue con Microsoft Dynamics 365
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de Microsoft Dynamics 365 CRM
- Configuración de conexiones con Microsoft Dynamics 365 CRM
- Lectura de entidades de Microsoft Dynamics 365 CRM
- Referencia de opciones de conexión de Microsoft Dynamics 365 CRM
- Limitaciones

Compatibilidad de AWS Glue con Microsoft Dynamics 365

AWS Glue es compatible con Microsoft Dynamics 365 de la siguiente manera:

¿Es compatible como origen?

Sí. Puede utilizar los trabajos de ETL de AWS Glue para consultar datos de Microsoft Dynamics 365.

¿Es compatible como destino?

No.

Versiones de API de Microsoft Dynamics 365 CRM compatibles

v9.2.

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

También puede usar las siguientes políticas de IAM administradas para permitir el acceso:

- AWSGlueServiceRole: concede acceso a los recursos que necesitan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: concede acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de Microsoft Dynamics 365 CRM

Antes de poder usar AWS Glue para transferir datos desde Microsoft Dynamics 365 CRM, debe cumplir estos requisitos:

Requisitos mínimos

- Tiene una cuenta de desarrollador de Microsoft Dynamics 365 CRM con un ID y un secreto de cliente.
- Su cuenta de Microsoft Dynamics 365 CRM tiene acceso a la API con una licencia válida.

Si cumple estos requisitos, podrá conectar AWS Glue a la cuenta de Microsoft Dynamics 365 CRM. Si se trata de una conexión típica, no necesita hacer nada más en Microsoft Dynamics 365 CRM.

Configuración de conexiones con Microsoft Dynamics 365 CRM

Tipo de concesión AUTHORIZATION_CODE

- Este tipo de concesión se considera un OAuth “de tres vías”, ya que se basa en redirigir a los usuarios al servidor de autorización externo para autenticar al usuario. Se utiliza para crear conexiones a través de la consola de AWS Glue. La consola de AWS Glue redirigirá al usuario a Microsoft Dynamics 365 CRM, donde deberá iniciar sesión y conceder a AWS Glue los permisos solicitados para acceder a su instancia de Microsoft Dynamics 365 CRM.
- Los usuarios pueden optar por crear una aplicación conectada propia en Microsoft Dynamics 365 CRM y proporcionar un ID y secreto de cliente propios al crear conexiones a través de la consola de AWS Glue. En este escenario, aún se les redirigirá a Microsoft Dynamics 365 CRM para iniciar sesión y autorizar a AWS Glue a que acceda a los recursos.
- Este tipo de concesión da como resultado un token de actualización y un token de acceso. El token de acceso es de corta duración y se puede actualizar automáticamente sin la interacción del usuario mediante el token de actualización.
- Para consultar la documentación pública de Microsoft Dynamics 365 CRM sobre la creación de una aplicación conectada para el flujo Authorization Code OAuth, consulte | Microsoft Learn. Registro de aplicaciones de Microsoft.

Microsoft Dynamics 365 CRM admite la autenticación OAuth2.0.

Para configurar una conexión a Microsoft Dynamics 365 CRM, haga lo siguiente:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles. Es necesario crear un secreto para cada conexión en AWS Glue.
   - Para el tipo de concesión AuthorizationCode:

     En el caso de una aplicación conectada administrada por el cliente, el secreto debe contener el secreto del cliente de la aplicación conectada con `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET` como clave.
2. En AWS Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:
   a. Al seleccionar un Origen de datos, seleccione Microsoft Dynamics 365 CRM.
   b. Seleccione INSTANCE_URL de la instancia de Microsoft Dynamics 365 CRM a la que quiere conectarse.
   c. Seleccione el rol de IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

      JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

   d. Seleccione URL del token y URL del código de autorización para acceder a su espacio de trabajo de Microsoft Dynamics 365 CRM.
   e. Proporcione el ID de cliente de la aplicación cliente administrada por el usuario de la aplicación Microsoft Dynamics 365 CRM.

f. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.

g. Seleccione las opciones de red si quiere usar su red.

3. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`. Elija Siguiente.
4. En la configuración de su trabajo de AWS Glue, proporcione `connectionName` como Conexión de red adicional.

Lectura de entidades de Microsoft Dynamics 365 CRM

Requisitos previos

- Un objeto de Microsoft Dynamics 365 CRM desde el que desea leer. Necesitará el nombre del objeto, como contactos o cuentas. En la siguiente tabla se muestran las entidades admitidas.

Entidades compatibles

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite Partición
Entidad dinámica	Sí	Sí	Sí	Sí	Sí

Ejemplo

```
dynamics365_read = glueContext.create_dynamic_frame.from_options(
    connection_type="microsoftdynamics365crm",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "dynamic_entity",
        "API_VERSION": "v9.2",
        "INSTANCE_URL": "https://{tenantID}.api.crm.dynamics.com"
    }
```

Detalles de entidades y campos de Microsoft Dynamics 365 CRM

Entidades con metadatos dinámicos:

Microsoft Dynamics 365 CRM proporciona puntos de conexión para obtener metadatos de forma dinámica. Por lo tanto, para las entidades dinámicas, la compatibilidad del operador se captura según el tipo de datos.

Entidad	Tipo de datos	Operadores admitidos
Entidad dinámica	DateTime	=, >, >=, <, <=, BETWEEN
	Date	=, <, <=, >, >=
	Cadena	=, !=
	Doble	=, <, <=, >, >=
	Entero	=, <, <=, >, >=
	Decimal	=, <, <=, >, >=
	Largo	=, <, <=, >, >=
	BigInteger	=, <, <=, >, >=
	Enumeración	N/D
	Struct	N/D
	Asignación	N/D

Consultas de partición

Microsoft Dynamics 365 CRM solo admite la partición basada en campos.

Puede proporcionar las opciones adicionales de Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` y `NUM_PARTITIONS` si quiere usar la simultaneidad en Spark. Con estos parámetros, la consulta original se dividiría en un número `NUM_PARTITIONS` de subconsultas que las tareas de Spark pueden ejecutar simultáneamente.

- `PARTITION_FIELD`: el nombre del campo que se usará para particionar la consulta.
- `LOWER_BOUND`: un valor de límite inferior inclusivo del campo de partición elegido.

En DateTime, aceptamos el formato de marca de tiempo de Spark que se utiliza en las consultas de Spark SQL. Ejemplos de valores válidos: `"2024-01-30T06:47:51.000Z"`.

- `UPPER_BOUND`: un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`: el número de particiones.

Los detalles de compatibilidad del campo de partición por entidad se muestran en la siguiente tabla:

Nombre de la entidad	Campos de partición	DataType
Entidad dinámica (entidad estándar)	Campos de DateTime dinámicos que se pueden consultar	createdon, modifiedon
Entidad dinámica (entidad personalizada)	createdon, modifiedon	createdon, modifiedon

Ejemplo

```
dynamics365_read = glueContext.create_dynamic_frame.from_options(
    connection_type="microsoftdynamics365crm",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "dynamic_entity",
        "API_VERSION": "v9.2",
        "instanceUrl": "https://{tenantID}.api.crm.dynamics.com"
        "PARTITION_FIELD": "createdon"
        "LOWER_BOUND": "2024-01-30T06:47:51.000Z"
        "UPPER_BOUND": "2024-06-30T06:47:51.000Z"
        "NUM_PARTITIONS": "10"
    }
```

Referencia de opciones de conexión de Microsoft Dynamics 365 CRM

Existen las siguientes opciones para establecer conexión con Microsoft Dynamics 365 CRM:

- `ENTITY_NAME`(cadena): (obligatorio) se usa para lectura. El nombre de su objeto en Microsoft Dynamics 365 CRM.

- `API_VERSION`(cadena): (obligatorio) se usa para lectura. Versión de la API de REST de Microsoft Dynamics 365 CRM que desea utilizar.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.
- `INSTANCE_URL`(cadena): (obligatorio) una URL de instancia de Microsoft Dynamics 365 CRM válida con el formato: `https://{tenantID}.api.crm.dynamics.com`
- `NUM_PARTITIONS`(entero): predeterminado: 1. Se usa para leer. Número de particiones para leer.
- `PARTITION_FIELD`(cadena): se usa para leer. Campo que se utilizará para particionar la consulta.
- `LOWER_BOUND`(cadena): se usa para leer. Un valor de límite inferior inclusivo del campo de partición elegido. Ejemplo: `2024-01-30T06:47:51.000Z`.
- `UPPER_BOUND`(cadena): se usa para leer. Un valor límite superior exclusivo del campo de partición elegido. Ejemplo: `2024-06-30T06:47:51.000Z`.

Limitaciones

El conector de Microsoft Dynamics 365 CRM presenta las siguientes limitaciones:

- En Microsoft Dynamics 365 CRM, no se admite la partición basada en registros, ya que no admite un parámetro de compensación.
- La paginación se establece en un máximo de 500 registros por página para evitar excepciones del servidor interno de SaaS debido a una combinación de limitaciones de tamaño y velocidad de los datos.
  - Documentación de SaaS sobre paginación
  - Documentación de SaaS sobre límites de tasas
- Microsoft Dynamics 365 CRM solo admite `order by` en los campos principales de todas las entidades. `order by` no se admite en los subcampos.
  - Se admiten las direcciones ASC y DESC.
  - `order by` se admite en varios campos.
- Al filtrar en el campo “createddatetime” de la entidad `aadusers` estándar, se produce un error de solicitud incorrecta desde SaaS, aunque admite la filtración. No se identificó ninguna otra entidad

que tenga un problema similar debido a la naturaleza dinámica de los metadatos y tampoco se conoce la causa raíz. Por lo tanto, no se puede solucionar.

- Los tipos de objetos complejos, como Struct, List y Map, no admiten la filtración.
- Muchos campos que se pueden recuperar de una respuesta tienen `isRetrievable` marcado como `false` en las respuestas de metadatos dinámicas. Para evitar la pérdida de datos, `isRetrievable` está configurado en `true` para todos los campos.
- Todas las entidades admiten la partición basada en campos cuando cumplen con los siguientes criterios:
  - Los campos consultables de DateTime deben estar presentes en las entidades estándar o en los campos `createdon` y `modifiedon` (generados por el sistema) en las entidades personalizadas.
  - No existe una identificación exclusiva de los campos generados por el sistema ni de la propiedad anulable de ninguna API de metadatos de SaaS; sin embargo, es una práctica general que solo los campos disponibles de forma predeterminada sean filtrables y no anulables. Por lo tanto, el criterio anterior de selección de campos se considera seguro frente a valores nulos y, si es filtrable, es elegible para la partición.

Conexión a Microsoft Teams

Microsoft Teams es un espacio de trabajo colaborativo dentro de Microsoft 365 que funciona como un centro para conversaciones laborales, trabajo en equipo, videollamadas y uso compartido de documentos, todo diseñado para mejorar la productividad con un conjunto unificado de herramientas.

Temas

- Compatibilidad de AWS Glue con Microsoft Teams
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de Microsoft Teams
- Configuración de las conexiones de Microsoft Teams
- Lectura de entidades de Microsoft Teams
- Referencia de opciones de conexión de Microsoft Teams
- Limitaciones
- Cómo crear una nueva cuenta de Microsoft Teams:

Compatibilidad de AWS Glue con Microsoft Teams

AWS Glue es compatible con Microsoft Teams de la siguiente manera:

¿Es compatible como origen?

Sí. Puede utilizar los trabajos de ETL de AWS Glue para consultar datos de Microsoft Teams.

¿Es compatible como destino?

No.

Versiones de la API de Microsoft Teams compatibles

v1. Para conocer la compatibilidad de entidades por versión específica, consulte Entidades compatibles para el origen.

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

También puede usar las siguientes políticas de IAM administradas para permitir el acceso:

- AWSGlueServiceRole: concede acceso a los recursos que necesitan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: concede acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de Microsoft Teams

Antes de poder utilizar AWS Glue para transferir datos desde Microsoft Teams, deberá cumplir estos requisitos:

Requisitos mínimos

- Tener una cuenta de desarrollador de Microsoft Teams con correo electrónico y contraseña. Para obtener más información, consulte Cómo crear una nueva cuenta de Microsoft Teams:.
- Haber configurado una aplicación OAuth2 en la cuenta de Microsoft que proporcione las credenciales de ID y secreto de cliente que AWS Glue utiliza para acceder a los datos de forma segura cuando hace llamadas autenticadas a la cuenta. Para obtener más información, consulte Cómo crear una nueva cuenta de Microsoft Teams:.

Si cumple estos requisitos, estará listo para conectar AWS Glue a la cuenta de Microsoft Teams. Si se trata de una conexión típica, no necesita hacer nada más en Microsoft Teams.

Configuración de las conexiones de Microsoft Teams

Microsoft Teams admite los siguientes dos tipos de mecanismos de autenticación:

1. Autenticación OAuth: Microsoft Teams admite el tipo de concesión AUTHORIZATION_CODE para OAuth2.
   - Este tipo de concesión se considera un OAuth “de tres vías”, ya que se basa en redirigir a los usuarios al servidor de autorización externo para autenticar al usuario. Se utiliza para crear

conexiones a través de la consola de AWS Glue. El usuario que crea una conexión puede, de forma predeterminada, confiar en una aplicación conectada propiedad de AWS Glue en la que no necesita proporcionar ninguna información relacionada con OAuth, excepto la URL de la instancia de Microsoft Teams. La consola de AWS Glue redirigirá al usuario a Microsoft Teams, donde deberá iniciar sesión y conceder a AWS Glue los permisos solicitados para acceder a su instancia de Microsoft Teams.

- Los usuarios aún pueden optar por crear una aplicación conectada propia en Microsoft Teams y proporcionar un ID y secreto de cliente propios al crear conexiones a través de la consola de AWS Glue. En este escenario, aún serán redirigidos a Microsoft Teams para iniciar sesión y autorizar a AWS Glue para que acceda a los recursos.
- Este tipo de concesión da como resultado un token de actualización y un token de acceso. El token de acceso permanecerá válido durante una hora y se puede actualizar automáticamente sin la interacción del usuario mediante el token de actualización.
- Para consultar la documentación pública de Microsoft Teams sobre la creación de una aplicación conectada para el flujo Authorization Code OAuth, consulte | Microsoft Learn. Registre una aplicación en la plataforma de identidades de Microsoft: Microsoft Graph.

Para configurar una conexión a Microsoft Teams:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles. Es necesario crear un secreto para cada conexión en AWS Glue.
   a. Para la autenticación OAuth:
      - En el caso de aplicaciones conectadas administradas por el cliente, el secreto debe contener el secreto del consumidor de la aplicación conectada con USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET como clave.
2. En AWS Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:
   a. En Conexiones de datos, elija Crear conexión.
   b. Al seleccionar un Origen de datos, seleccione Microsoft Teams.
   c. Proporcione el ID de inquilino de Microsoft Teams.
   d. Seleccione el rol de IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

e. Proporcione el ID de cliente de la aplicación cliente administrada por el usuario de la aplicación Microsoft Teams.

f. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.

g. Seleccione las opciones de red si quiere usar su red.

3. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`. Elija Siguiente.

4. En la configuración de su trabajo de AWS Glue, proporcione `connectionName` como Conexión de red adicional.

Lectura de entidades de Microsoft Teams

Requisitos previos

- Un objeto de Microsoft Teams desde el que desea leer. Necesitará el nombre del objeto, como equipo o channel-message. En la siguiente tabla se muestran las entidades admitidas.

Entidades admitidas para el origen

Todas las entidades se admiten con la versión 1.0 de la API.

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite Partición
Equipos	No	No	No	Sí	No
Miembros del equipo	Sí	Sí	No	Sí	Sí
Grupos	Sí	Sí	Sí	Sí	Sí
Miembro del grupo	Sí	Sí	No	Sí	No
Canales	Sí	No	No	Sí	Sí
Mensaje del canal	No	Sí	No	Sí	No
Respuestas a los mensajes del canal	No	Sí	No	Sí	No
Pestañas de canales	Sí	No	No	Sí	No
Chats	Sí	Sí	Sí	Sí	Sí
Eventos del calendario	Sí	Sí	Sí	Sí	Sí

Ejemplo

```
MicrosoftTeams_read = glueContext.create_dynamic_frame.from_options(
    connection_type="MicrosoftTeams",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "company",
        "API_VERSION": "v1.0"
```

```
    }
```

Detalles de entidades y campos de Microsoft Teams

Lista de entidades:

- Equipo: https://docs.microsoft.com/en-us/graph/api/user-list-joinedteams?view=graph-rest-1.0
- Miembro del equipo: https://docs.microsoft.com/en-us/graph/api/team-list-members?view=graph-rest-1.0
- Grupo: https://docs.microsoft.com/en-us/graph/api/group-list?view=graph-rest-1.0
- Miembro del grupo: https://docs.microsoft.com/en-us/graph/api/group-list-members?view=graph-rest-1.0
- Canal: https://docs.microsoft.com/en-us/graph/api/channel-list?view=graph-rest-1.0
- Mensaje del canal: https://docs.microsoft.com/en-us/graph/api/channel-list-messages?view=graph-rest-1.0
- Respuesta a mensaje del canal: https://docs.microsoft.com/en-us/graph/api/chatmessage-list-replies?view=graph-rest-1.0
- Pestaña del canal: https://docs.microsoft.com/en-us/graph/api/channel-list-tabs?view=graph-rest-1.0
- Chat: https://docs.microsoft.com/en-us/graph/api/chat-list?view=graph-rest-1.0
- Evento del calendario: https://docs.microsoft.com/en-us/graph/api/group-list-events?view=graph-rest-1.0

Consultas de partición

Puede proporcionar las opciones adicionales de Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` y `NUM_PARTITIONS` si quiere usar la simultaneidad en Spark. Con estos parámetros, la consulta original se dividiría en un número `NUM_PARTITIONS` de subconsultas que las tareas de Spark pueden ejecutar simultáneamente.

- `PARTITION_FIELD`: el nombre del campo que se usará para particionar la consulta.
- `LOWER_BOUND`: un valor de límite inferior inclusivo del campo de partición elegido.

  Para la fecha, aceptamos el formato de fecha de Spark que se usa en las consultas de Spark SQL. Ejemplos de valores válidos: `"2024-02-06"`.

- UPPER_BOUND: un valor límite superior exclusivo del campo de partición elegido.
- NUM_PARTITIONS: el número de particiones.

Los detalles de compatibilidad del campo de partición por entidad se muestran en la siguiente tabla:

Nombre de la entidad	Campos de partición	Tipo de datos
Miembros del equipo	visibleHistoryStartDateTime	DateTime
Grupos	createdDateTime	DateTime
Canales	createdDateTime	DateTime
Chats	createdDateTime, lastModifiedDateTime	DateTime
Eventos del calendario	createdDateTime, lastModifiedDateTime, originalStart	DateTime

Ejemplo

```
microsoftteams_read = glueContext.create_dynamic_frame.from_options(
    connection_type="MicrosoftTeams",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "group",
        "API_VERSION": "v1.0",
        "PARTITION_FIELD": "createdDateTime"
        "LOWER_BOUND": "2022-07-13T07:55:27.065Z"
        "UPPER_BOUND": "2022-08-12T07:55:27.065Z"
        "NUM_PARTITIONS": "2"
    }
```

Referencia de opciones de conexión de Microsoft Teams

Existen las siguientes opciones para establecer conexión con Microsoft Teams:

- ENTITY_NAME(cadena): (obligatorio) se usa para lectura. El nombre del objeto en Microsoft Teams.

- `API_VERSION`(cadena): (obligatorio) se usa para lectura. Versión de la API de REST de Microsoft Teams que desea utilizar. Ejemplo: v1.0.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.
- `PARTITION_FIELD`(cadena): se usa para leer. Campo que se utilizará para particionar la consulta.
- `LOWER_BOUND`(cadena): se usa para leer. Un valor de límite inferior inclusivo del campo de partición elegido.
- `UPPER_BOUND`(cadena): se usa para leer. Un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`(entero): predeterminado: 1. Se usa para leer. Número de particiones para leer.

Limitaciones

El conector de Microsoft Teams presenta las siguientes limitaciones:

- La API de Microsoft Teams devuelve una cantidad de registros inferior a la especificada para las entidades de chat y miembros del equipo. Se ha informado de este problema a Microsoft Teams Support y está en proceso de investigación.

Cómo crear una nueva cuenta de Microsoft Teams:

1. Vaya a la página de inicio de Microsoft Teams, https://account.microsoft.com/account/, y elija Iniciar sesión.
2. Elija Crear una.
3. Ingrese la información requerida para la creación de la cuenta y cree una nueva cuenta.
4. Vaya al sitio web de Microsoft Teams: https://www.microsoft.com/en-in/microsoft-teams/log-in.
5. Regístrese con la cuenta de Microsoft que acaba de crear.
6. Después de registrarse correctamente en Teams, vaya a https://account.microsft.com/services.
7. Elija Probar Microsoft 365.
8. Active una de las siguientes suscripciones de Microsoft 365 o Microsoft Teams para acceder a todas las características necesarias del conector de Microsoft Teams:

- Microsoft Teams Essentials
- Microsoft 365 Business
- Microsoft 365 Business Basic
- Microsoft 365 Business Standard
- Microsoft 365 Business Premium

Cómo crear una aplicación cliente administrada:

1. Para crear una aplicación administrada, debe registrar una nueva aplicación OAuth en Microsoft Entra (anteriormente Azure Active Directory):
2. Inicie sesión en el Centro de administración de Microsoft Entra.
3. Si tiene acceso a varios inquilinos, utilice el icono de Configuración en el menú superior para cambiar al inquilino en el que desea registrar la aplicación desde el menú Directorios + suscripciones.
4. Vaya a Identidad > Aplicaciones > Registros de aplicaciones y seleccione Nuevo registro.
5. Ingrese un Nombre de visualización para la aplicación.
6. Especifique quién puede usar la aplicación en la sección Tipos de cuenta admitidos. Para que esta aplicación sea global, seleccione “Cuentas en cualquier directorio organizacional” o “Cuentas en cualquier directorio organizacional y cuentas personales de Microsoft”.
7. Ingrese el URI de redirección `https://{region}.console.aws.amazon.com/appflow/oauth`. Por ejemplo, en el caso de `us-west-2 region`, agregue `https://us-west-2.console.aws.amazon.com/appflow/oauth`. Puede agregar varias URL para las diferentes regiones que desea utilizar.
8. Registre la aplicación.
9. Anote el ID de cliente para usarlo más adelante.
10. Seleccione Agregar un certificado o secreto en la sección Esenciales.
11. Seleccione Nuevo secreto de cliente.
12. Ingrese la descripción y la duración del vencimiento.
13. Copie y guarde el secreto de cliente para usarlo después.
14. En la lista del menú lateral izquierdo, seleccione Permisos de API.
15. Elija Agregar un permiso.
16. Seleccione “Microsoft Graph”.

17. Seleccione “Permisos delegados”.
18. Marque todos los permisos que aparecen a continuación:

    - User.Read
    - Offline_access
    - User.Read.All
    - User.ReadWrite.All
    - TeamsTab.ReadWriteForTeam
    - TeamsTab.ReadWriteForChat
    - TeamsTab.ReadWrite.All
    - TeamsTab.Read.All
    - TeamSettings.ReadWrite.All
    - TeamSettings.Read.All
    - TeamMember.ReadWrite.All
    - TeamMember.Read.All
    - Team.ReadBasic.All
    - GroupMember.ReadWrite.All
    - GroupMember.Read.All
    - Group.ReadWrite.All
    - Group.Read.All
    - Directory.ReadWrite.All
    - Directory.Read.All
    - Directory.AccessAsUser.All
    - Chat.ReadWrite
    - Chat.ReadBasic
    - Chat.Read
    - ChannelSettings.ReadWrite.All
    - ChannelSettings.Read.All
    - ChannelMessage.Read.All
    - Channel.ReadBasic.All

19. Elija Añadir permisos. La aplicación se ha configurado correctamente. Puede utilizar el ID de cliente y el secreto de cliente para crear una nueva conexión. Para obtener más información, consulte https://learn.microsoft.com/en-us/graph/auth-register-app-v2.

Conexión a Mixpanel

Mixpanel es una potente plataforma de análisis en tiempo real que ayuda a las empresas a medir y optimizar la interacción con los usuarios. Mixpanel es una aplicación que se utiliza para realizar un seguimiento del comportamiento de los clientes. Permite realizar un seguimiento de cómo los usuarios interactúan con el producto, así como analizar estos datos a través de informes interactivos con los que se pueden consultar y visualizar los resultados con tan solo unos clics. Como usuario de Mixpanel, puede conectar AWS Glue a la cuenta de Mixpanel. A continuación, puede utilizar Mixpanel como origen de datos en los trabajos de ETL. Ejecute estos trabajos para transferir datos entre Mixpanel y los servicios de AWS u otras aplicaciones compatibles.

Temas

- Compatibilidad de AWS Glue con Mixpanel
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de Mixpanel
- Configuración de las conexiones a Mixpanel
- Cómo leer de entidades de Mixpanel
- Opciones de conexión a Mixpanel
- Creación de una cuenta de Mixpanel y configuración de la aplicación cliente
- Limitaciones

Compatibilidad de AWS Glue con Mixpanel

AWS Glue admite Mixpanel de la siguiente manera:

¿Es compatible como origen?

Sí. Puede usar los trabajos de ETL de AWS Glue para consultar datos de Mixpanel.

¿Es compatible como destino?

No.

Versiones de la API de Mixpanel compatibles

2.0

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si no desea utilizar el método anterior, como alternativa, utilice las siguientes políticas de IAM administradas:

- AWSGlueServiceRole: concede acceso a los recursos que necesitan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: concede acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la consola de administración de AWS. Si sigue

la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de Mixpanel

Antes de poder utilizar AWS Glue para transferir datos hacia o desde Mixpanel, deberá cumplir estos requisitos:

Requisitos mínimos

- Tener una cuenta de Mixpanel. Para obtener más información sobre cómo crear una cuenta, consulte Creación de una cuenta de Mixpanel.
- La cuenta de Mixpanel debe estar habilitada para el acceso a la API. El acceso a la API está habilitado de forma predeterminada para las ediciones Enterprise, Unlimited, Developer y Performance.

Si cumple estos requisitos, estará listo para conectar AWS Glue a la cuenta de Mixpanel. Para conexiones típicas, no necesita hacer nada más en Mixpanel.

Configuración de las conexiones a Mixpanel

Mixpanel admite nombre de usuario y contraseña para `BasicAuth`. La autenticación básica es un método de autenticación simple en el que los clientes proporcionan credenciales directamente para acceder a los recursos protegidos. AWS Glue puede utilizar el nombre de usuario y la contraseña para autenticar las API de Mixpanel.

Para consultar la documentación pública de Mixpanel sobre el flujo `BasicAuth`, consulte Cuentas de servicio de Mixpanel.

Para configurar una conexión a Mixpanel:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles:
   - Para la autenticación básica, el secreto debe contener el secreto del consumidor de la aplicación conectada con `USERNAME` y `PASSWORD` como clave.

> **Note**
>
> Es imprescindible crear un secreto por conexión en AWS Glue.

2. En AWS Glue Studio, siga los pasos que se indican a continuación en Conexiones de datos para crear una conexión:
   a. Al seleccionar un Tipo de conexión, elija Mixpanel.
   b. Proporcione la `INSTANCE_URL` de la instancia de Mixpanel a la que se quiere conectar.
   c. Seleccione el rol de IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

      JSON

      ```
      {
        "Version":"2012-10-17",
        "Statement": [
          {
            "Effect": "Allow",
            "Action": [
              "secretsmanager:DescribeSecret",
              "secretsmanager:GetSecretValue",
              "secretsmanager:PutSecretValue",
              "ec2:CreateNetworkInterface",
              "ec2:DescribeNetworkInterfaces",
              "ec2:DeleteNetworkInterface"
            ],
            "Resource": "*"
          }
        ]
      }
      ```

   d. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.
   e. Seleccione Opciones de red si quiere usar la red.
3. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.

Cómo leer de entidades de Mixpanel

Requisitos previos

Debe tener un objeto de Mixpanel, como `Funnels`, `Retention` o `Retention Funnels`, del que desee leer datos. Además, necesitará conocer el nombre del objeto.

Entidades compatibles

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite Partición
Embudos	Sí	No	No	Sí	No
Retención	Sí	No	No	Sí	No
Segmentación	Sí	No	No	Sí	No
Suma de segmentación	Sí	No	No	Sí	No
Promedio de segmentación	Sí	No	No	Sí	No
Cohortes	Sí	No	No	Sí	No
Uso de	No	Sí	No	Sí	No
Eventos	Sí	No	No	Sí	No
Eventos principales	Sí	No	No	Sí	No
Nombres de eventos	Sí	No	No	Sí	No
Propiedades de eventos	Sí	No	No	Sí	No

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite Partición
Principales propiedades de eventos	Sí	No	No	Sí	No
Valores de propiedades de eventos	Sí	No	No	Sí	No
Anotaciones	Sí	No	No	Sí	No
Actividad de evento de perfil	Sí	No	No	Sí	No

Ejemplo

```
mixpanel_read = glueContext.create_dynamic_frame.from_options(
    connection_type="mixpanel",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "/cohorts/list?project_id=2603353",
        "API_VERSION": "2.0",
        "INSTANCE_URL": "https://www.mixpanel.com/api/app/me"
    }
```

Detalles de entidades y campos de Mixpanel

Entidad	Campo	Tipo de datos	Operadores admitidos
Embudo	funnel_id	Entero	'='
	workspace_id	Entero	'='
	from_date	Date	'='
	to_date	Date	'=’

Entidad	Campo	Tipo de datos	Operadores admitidos
	length	Entero	'='
	length_unit	Cadena	'='
	intervalo	Entero	'='
	unidad	Cadena	'='
	límite	Entero	'='
	data	Struct	
	meta	Struct	
Retención	workspace_id	Entero	'='
	unidad	Cadena	'='
	addiction_unit	Cadena	'='
	from_date	Date	'='
	to_date	Date	'='
	event	Cadena	'='
	límite	Entero	'='
	data	Struct	
Segmentación	workspace_id	Entero	'='
	event	Cadena	'='
	from_date	Date	'='
	to_date	Date	'='
	unidad	Cadena	'='

Entidad	Campo	Tipo de datos	Operadores admitidos
	intervalo	Entero	'='
	límite	Entero	'='
	type	Cadena	'='
	serie	Enumeración	
	valores	Struct	
	data	Struct	
Segmentación numérica	workspace_id	Entero	'='
	event	Cadena	'='
	on	Cadena	'='
	from_date	Date	'='
	to_date	Date	'='
	unidad	Cadena	'='
	type	Cadena	'='
	serie	Enumeración	
	valores	Struct	
Suma de segmentación	workspace_id	Entero	'='
	event	Cadena	'='
	on	Cadena	'='
	from_date	Date	'='
	to_date	Date	'='

Entidad	Campo	Tipo de datos	Operadores admitidos
	unidad	Cadena	'='
	metadatos	Struct	
	resultados	Struct	
Promedio de segmentación	workspace_id	Entero	'='
	event	Cadena	'='
	on	Cadena	'='
	from_date	Date	'='
	to_date	Date	'='
	unidad	Cadena	'='
	metadatos	Struct	
	resultados	Struct	
Cohortes	count	Entero	
	is_visible	Entero	
	Descripción	Cadena	
	created	DateTime	
	project_id	Entero	
	id	BigInteger	
	nombre	Cadena	
	data_group_id	Cadena	
Uso de	distinct_id	Cadena	

Entidad	Campo	Tipo de datos	Operadores admitidos
		propiedades	Struct
Evento	espacio de trabajo	Entero	'='
	event	Cadena	'='
	type	Cadena	'='
	unidad	Cadena	'='
	intervalo	Entero	'='
	from_date	Date	'='
	to_date	Date	'='
	serie	Enumeración	
	valores	Struct	
Eventos principales	type	Cadena	'='
	workspace_id	Entero	'='
	límite	Entero	'='
	cantidad	Entero	
	event	Cadena	
	percent_change	Flotante	
Nombre del evento	data	Enumeración	
	workspace_id	Entero	'='
	type	Cadena	'='
	límite	Entero	'='

Entidad	Campo	Tipo de datos	Operadores admitidos
Propiedades de eventos	workspace_id	Entero	'='
	event	Cadena	'='
	nombre	Cadena	'='
	type	Cadena	'='
	unidad	Cadena	'='
	intervalo	Entero	'='
	from_date	Date	'='
	to_date	Date	'='
	límite	Entero	'='
	data	Struct	
	serie	Enumeración	
	valores	Struct	
Principales propiedades de eventos	workspace_id	Entero	'='
	event	Cadena	'='
	límite	Entero	'='
	data	Struct	
Valores de propiedades de eventos	workspace_id	Entero	'='
	event	Cadena	'='
	límite	Entero	'='
	nombre	Cadena	'='

Entidad	Campo	Tipo de datos	Operadores admitidos
	data	Enumeración	
Anotación	workspace_id	Entero	
	date	DateTime	
	project_id	Entero	
	id	BigInteger	
	Descripción	Cadena	
	from_date	Date	BETWEEN
Actividad de evento de perfil	workspace_id	Entero	'='
	distinct_ids	Cadena	'='
	from_date	Date	'='
	to_date	Date	'='
	event	Cadena	
	propiedades	Struct	

Opciones de conexión a Mixpanel

Las siguientes son opciones de conexión para Mixpanel:

- `ENTITY_NAME`(cadena): (obligatorio) se utiliza para leer y escribir. El nombre del objeto en Mixpanel.
- `API_VERSION`(cadena): (obligatorio) se utiliza para leer y escribir. Versión de la API de Rest de Mixpanel que desea usar. Por ejemplo, v2.0.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: vacío (SELECTO *). Se usa para leer. Columnas que desee seleccionar para el objeto.

- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.

Creación de una cuenta de Mixpanel y configuración de la aplicación cliente

Creación de una cuenta de Mixpanel

1. Vaya a la Página de inicio de Mixpanel/.
2. En la página de inicio de Mixpanel, elija Registrarse en la esquina superior derecha de la página.
3. En la página Comencemos, realice las siguientes acciones:
   - Ingrese su dirección de correo electrónico en el campo designado.
   - Seleccione la casilla necesaria para aceptar las condiciones.
   - Elija Comenzar para continuar.

   Al finalizar con éxito, recibirá un correo electrónico de verificación.
4. Revise su bandeja de entrada para encontrar un correo de verificación, ábralo y siga las instrucciones proporcionadas para confirmar su dirección de correo electrónico.
5. En la página de verificación, elija Verificar correo electrónico para completar la verificación del correo electrónico.
6. En la página Asigne un nombre a la organización, ingrese el nombre de la organización y elija Siguiente.
7. En la página Su primer proyecto, ingrese los detalles del proyecto y seleccione Crear.
8. En la página siguiente, elija Comencemos para terminar de crear la cuenta.

Inicio de sesión en una cuenta de Mixpanel

1. Vaya a la Página de inicio de sesión de Mixpanel/.
2. Ingrese la dirección de correo electrónico y elija Continuar.
3. Revise su bandeja de entrada para encontrar un correo de verificación, ábralo y siga las instrucciones proporcionadas para confirmar su dirección de correo electrónico.
4. En la página siguiente, elija el botón Iniciar sesión para iniciar sesión en la cuenta.

Cómo adquirir un plan de Mixpanel

1. En la página de Mixpanel, seleccione el icono Configuración que se encuentra en la esquina superior derecha de la página.
2. En la lista de opciones, seleccione Detalles del plan y facturación.
3. En la página Detalles del plan y facturación, seleccione Actualizar o Modificar.
4. En la página siguiente, seleccione el plan que desee comprar.

   Con esto se completa el proceso de creación de la cuenta y de adquisición del plan.

Creación de un nombre de usuario y un secreto de cliente (para registrar la aplicación)

1. En la página de Mixpanel, seleccione el icono Configuración que se encuentra en la esquina superior derecha de la página.
2. En la lista de opciones, seleccione Configuración del proyecto.
3. En la página Configuración del proyecto, seleccione Cuentas de servicio y, a continuación, Agregar cuenta de servicio.
4. En la lista desplegable Cuenta de servicio, seleccione la Cuenta de servicio o ingrese el nombre que desea crear, agregue el Rol del proyecto, especifique los vencimientos y seleccione Agregar.

   > **Important**
   >
   > Una vez completado el paso anterior, aparecerá la siguiente página con la clave secreta de la cuenta de servicio. Asegúrese de guardar la clave secreta de la cuenta de servicio. No podrá volver a acceder a esta después de este punto.

Limitaciones

Las siguientes son limitaciones para el conector de Mixpanel:

- En el caso de la entidad `Segmentation Numeric`, la API de Mixpanel arroja un error `400 (Bad Request)` si no se encuentran datos numéricos para los filtros obligatorios. Tratamos esto como una respuesta `OK` para evitar una falla en el flujo.
- El campo que se puede consultar `limit` se ha eliminado de las entidades compatibles debido a que:

  - Causaba errores porque se interpretaba como la característica límite del SDK
  - El filtro no tenía ninguna utilidad práctica
  - La funcionalidad equivalente ahora la desempeña la implementación de la característica límite
- No se puede admitir la partición basada en campos debido a la ausencia de operadores necesarios (>=, <=, <, > y `between`) para la partición desde la plataforma SaaS. Aunque admite el operador `between`, los campos para los que admite este operador no se pueden recuperar. Por lo tanto, no se cumplen los criterios para la partición por campos.
- Dado que no existe ninguna provisión para obtener un valor de “desplazamiento” para las entidades que admiten paginación, no es posible admitir la partición basada en registros en el caso de Mixpanel.
- La entidad `Cohorts` solo admite el campo `CreatedDate/Time`, y no hay ningún campo para identificar `UpdatedDate/Time`, por lo que no se puede identificar `DML_Status`. Además, no existe un punto de conexión para identificar los registros eliminados. Por lo tanto, no se puede admitir CDC.
- Para ejecutar un trabajo de AWS Glue para las entidades que se mencionan a continuación, se requieren filtros obligatorios. Consulte la tabla que aparece a continuación para conocer los nombres de las entidades y los filtros necesarios.

  Nombre de la entidad y filtros necesarios

Nombre de la entidad	Filtros obligatorios
Anotaciones	from_date, to_date
Cohortes	Ninguno
Uso de	Ninguno
Evento	evento, tipo, unidad, from_date, to_date, el
Nombre del evento	type
Propiedades de eventos	evento, nombre, tipo, unidad, from_date, to_date
Principales propiedades de eventos	event
Valores de propiedades de eventos	evento, nombre

Nombre de la entidad	Filtros obligatorios
Eventos principales	type
Embudos	funnel_id, from_date, to_date
Actividad de evento de perfil	distinct_ids, from_date, to_date
Retención	from_date, to_date, unidad, addiction_unit
Segmentación	evento, from_date, to_date
Promedio de segmentación	evento, from_date, to_date, el
Segmentación numérica	evento, from_date, to_date, el
Suma de segmentación	evento, from_date, to_date, el

Conexión a Monday

Monday.com es un sistema operativo de trabajo versátil que optimiza la administración de proyectos y la colaboración en equipo. Ofrece flujos de trabajo personalizables, paneles visuales y herramientas de automatización para mejorar la productividad. Los usuarios pueden realizar el seguimiento de las tareas, administrar recursos y comunicarse de manera efectiva en una plataforma integrada.

Temas

- Compatibilidad de AWS Glue con Monday
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de Monday
- Configuración de conexiones a Monday
- Lectura de entidades de Monday
- Referencia de opciones de conexión de Monday
- Limitaciones
- Cómo crear una cuenta nueva de Monday:

Compatibilidad de AWS Glue con Monday

AWS Glue admite Monday de la siguiente manera:

¿Es compatible como origen?

Sí. Puede utilizar los trabajos de ETL de AWS Glue para consultar datos de Monday.

¿Es compatible como destino?

No.

Versiones de la API de Monday compatibles

v2

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

También puede usar las siguientes políticas de IAM administradas para permitir el acceso:

- AWSGlueServiceRole: concede acceso a los recursos que necesitan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: concede acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de Monday

Antes de poder utilizar AWS Glue para transferir datos desde Monday, deberá cumplir estos requisitos:

Requisitos mínimos

- Tener una cuenta para desarrolladores de Monday con correo electrónico y contraseña. Para obtener más información, consulte Cómo crear una cuenta nueva de Monday:.
- La cuenta para desarrolladores de Monday debe estar habilitada para el acceso de API. La API de Monday se puede utilizar sin ningún costo adicional durante el periodo de prueba. Una vez finalizado el periodo de prueba, deberá comprar una suscripción para crear datos y acceder a estos. Para obtener más información, consulte la página de licencias de Monday.

Si cumple estos requisitos, estará listo para conectar AWS Glue a la cuenta de Monday. Si se trata de una conexión típica, no necesita hacer nada más en Monday.

Configuración de conexiones a Monday

Monday admite los siguientes dos tipos de mecanismos de autenticación:

1. Autenticación OAuth: Monday admite el tipo de concesión AUTHORIZATION_CODE para OAuth2.
   - Este tipo de concesión se considera un OAuth “de tres vías”, ya que se basa en redirigir a los usuarios al servidor de autorización externo para autenticar al usuario. Se utiliza para crear conexiones a través de la consola de AWS Glue. El usuario que crea una conexión puede, de

forma predeterminada, confiar en una aplicación conectada propiedad de AWS Glue en la que no necesita proporcionar ninguna información relacionada con OAuth, excepto la URL de la instancia de Monday. La consola de AWS Glue redirigirá al usuario a Monday, donde deberá iniciar sesión y conceder a AWS Glue los permisos solicitados para acceder a su instancia de Monday.

- Los usuarios deberían optar por crear una aplicación conectada propia en Monday y proporcionar su propio ID y secreto de cliente al crear conexiones a través de la consola de AWS Glue. En este escenario, aún se abrirá Monday para iniciar sesión y autorizar a AWS Glue para que acceda a sus recursos.
- Este tipo de concesión da como resultado un token de actualización y un token de acceso. El token de acceso permanecerá válido durante una hora y se puede actualizar automáticamente sin la interacción del usuario mediante el token de actualización.
- Para obtener más información, consulte la documentación sobre la creación de una aplicación conectada para el flujo Authorization Code OAuth.

2. Autenticación personalizada:
   - Para consultar la documentación de Monday sobre cómo generar las claves de API necesarias para la autorización personalizada, consulte https://developer.monday.com/api-reference/docs/authentication#api-token-permissions .

Para configurar una conexión a Monday:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles. Es necesario crear un secreto para cada conexión en AWS Glue.
   a. Para la autenticación OAuth:
      - En el caso de aplicaciones conectadas administradas por el cliente, el secreto debe contener el secreto del consumidor de la aplicación conectada con USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET como clave.
   b. Para la autenticación personalizada:
      - En el caso de una aplicación conectada administrada por el cliente, el secreto debe contener el secreto del consumidor de la aplicación conectada con `personalAccessToken` como clave.
2. En AWS Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:
   a. En Conexiones de datos, elija Crear conexión.

b. Al seleccionar un Origen de datos, elija Monday.

c. Proporcione la URL de instancia de Monday.

d. Seleccione el rol de IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

e. Seleccione el tipo de autenticación para conectarse a Monday

- En el caso de la autenticación OAuth: proporcione la URL del token, el ID de cliente de la aplicación cliente administrada por el usuario del Monday al que se desea conectar.
- En el caso de la autenticación personalizada, seleccione el tipo de autenticación PERSONALIZADA para conectarse a Monday.

f. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.

g. Seleccione las opciones de red si quiere usar su red.

3. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`. Elija Siguiente.

4. En la configuración de su trabajo de AWS Glue, proporcione `connectionName` como Conexión de red adicional.

Lectura de entidades de Monday

Requisitos previos

- Un objeto de Monday desde el que desea leer. Consulte la tabla de entidades compatibles que aparece a continuación para comprobar las entidades disponibles.

Entidades admitidas para el origen

Lista de entidades:

- Cuenta: https://developer.monday.com/api-reference/docs/account#queries
- Tablero: https://developer.monday.com/api-reference/docs/boards#queries
- Columna: https://developer.monday.com/api-reference/docs/columns#queries
- Documentos: https://developer.monday.com/api-reference/docs/docs#queries
- Bloque de documentos: https://developer.monday.com/api-reference/docs/blocks#queries
- Archivos: https://developer.monday.com/api-reference/docs/files#queries
- Carpetas: https://developer.monday.com/api-reference/docs/folders#queries
- Grupos: https://developer.monday.com/api-reference/docs/groups#queries
- Elemento: https://developer.monday.com/api-reference/docs/items#queries
- Subelementos: https://developer.monday.com/api-reference/docs/subitems#queries
- Etiquetas: https://developer.monday.com/api-reference/docs/tags-queries#queries
- Equipos: https://developer.monday.com/api-reference/docs/teams#queries
- Actualizaciones: https://developer.monday.com/api-reference/docs/updates#queries
- Usuarios: https://developer.monday.com/api-reference/docs/users#queries
- Espacios de trabajo: https://developer.monday.com/api-reference/docs/workspaces#queries

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite Partición
Cuenta	No	No	No	Sí	No
Tableros	Sí	Sí	No	Sí	No

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite Partición
Columnas	No	No	No	Sí	No
Documentos	Sí	Sí	No	Sí	No
Bloques de documentos	No	Sí	No	Sí	No
Archivos	Sí	No	No	Sí	No
Grupos	No	No	No	Sí	No
Elemento	Sí	Sí	No	Sí	No
Subelementos	No	No	No	Sí	No
Etiquetas	Sí	No	No	Sí	Sí
Equipos	Sí	No	No	Sí	No
Actualizaciones	No	Sí	No	Sí	No
Usuarios	Sí	Sí	No	Sí	No
Workspaces	Sí	Sí	No	Sí	No
Carpetas	Sí	Sí	No	Sí	No

Ejemplo

```
monday_read = glueContext.create_dynamic_frame.from_options(
     connection_type="monday",
     connection_options={
         "connectionName": "connectionName",
         "ENTITY_NAME": "account",
         "API_VERSION": "v2"
```

```
    }
```

Referencia de opciones de conexión de Monday

Existen las siguientes opciones para establecer conexión con Monday:

- `ENTITY_NAME`(cadena): (obligatorio) se utiliza para leer y escribir. El nombre del objeto en Monday.
- `API_VERSION`(cadena): (obligatorio) se utiliza para leer y escribir. Versión de la API de REST de Monday que desea usar. Ejemplo: v2.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.

Limitaciones

El conector de Monday presenta las siguientes limitaciones:

- La respuesta de metadatos dinámicos presenta ciertos conflictos con la documentación, como se menciona a continuación:
  - La entidad Grupo, Columna admite las operaciones de filtrado, pero no está presente en el punto de conexión de los metadatos dinámicos, por lo que se mantiene como entidad no filtrable.
  - El punto de conexión dinámico consta de más de 15 000 líneas y devuelve los metadatos de todas las entidades en una sola respuesta. Como resultado, los campos tardan un promedio de 10 segundos en cargarse, lo que implica un tiempo adicional mientras se ejecuta un trabajo.
  - Consulte la siguiente tabla para conocer el límite de tasa de Monday. El gran tamaño de los datos de respuesta de la entidad dinámica genera un retraso notable, lo que hace que los campos tarden en promedio 10 segundos en cargarse.

Límite de complejidad	5 000 000 (5 millones) de puntos de complejidad
Límite de llamadas por día	10 000 en el plan Pro

Límite de complejidad	5 000 000 (5 millones) de puntos de complejidad
Límite de minutos	500 consultas por minuto
Límite de simultaneidad	Máximo de 100 solicitudes simultáneas para el Plan Pro

Cómo crear una cuenta nueva de Monday:

1. Vaya a la página de inicio de Monday, https://monday.com/ y elija Iniciar sesión.
2. Se le redirigirá a la página de inicio de sesión. En la parte inferior de la página, elija Registrarse.
3. Ingrese la dirección de correo electrónico y elija Continuar. Como alternativa, puede iniciar sesión con Google.
4. Ingrese los detalles requeridos y seleccione Continuar.
5. Complete las preguntas de la encuesta y siga los pasos para finalizar el proceso de creación de la cuenta.

Cómo registrar una aplicación OAuth.

1. Inicie sesión en la cuenta de monday.com. Haga clic en el avatar (icono de imagen) en la esquina inferior izquierda de la pantalla.
2. Elija Desarrollador.
3. Seleccione Crear una aplicación.
4. Complete los campos obligatorios de nombre y descripción.
5. Vaya a la sección “OAuth” ubicada en el lado derecho, agregue los ámbitos y seleccione “Guardar característica”.
6. Vaya a la pestaña “URL de redirección” junto al ámbito, agregue la URL de redirección y seleccione “Guardar característica”.
7. En la pestaña URL de redirección, indique la URL de la aplicación. Debe ser https://{region-code}.console.aws.amazon.com/appflow/oauth. Por ejemplo, si utiliza `us-east-1` , puede agregar `https://us-east-1.console.aws.amazon.com/appflow/oauth`.
8. La aplicación ya está lista para su uso. Puede encontrar las credenciales en la sección “Información básica”. Tome nota de las cadenas de ID de cliente y secreto de cliente. Estas

cadenas se utilizan para establecer conexión con esta aplicación mediante un conector AppFlow.

Cómo generar un token de acceso personal:

Actualmente, monday.com solo ofrece tokens de API V2, los cuales son tokens personales. Para acceder a los tokens de API, puede utilizar uno de los dos métodos disponibles según el nivel de usuario. Los usuarios administradores pueden utilizar ambos métodos para obtener los tokens de API. Los usuarios miembros pueden acceder a sus tokens de API desde la pestaña Desarrollador.

Administradores: si es un usuario administrador en la cuenta de monday.com, puede acceder a los tokens de API desde la pestaña “Administrador”. Para ello, siga estos pasos:

1. Inicie sesión en la cuenta de monday.com. Haga clic en el avatar (icono de imagen) en la esquina inferior izquierda de la pantalla.
2. Seleccione “Administración” en el menú que aparece (para esto debe contar con permisos de administrador).
3. Vaya a la sección “API” y genere un “Token de API V2”. Puede copiar el token y usarlo.

Desarrollador: si es un usuario miembro en la cuenta de monday.com, puede acceder a los tokens de API desde la pestaña “Desarrollador”. Para ello, siga estos pasos:

1. Inicie sesión en la cuenta de monday.com. Haga clic en el avatar (icono de imagen) en la esquina inferior izquierda de la pantalla.
2. Seleccione “Desarrolladores” en el menú que aparece.
3. En el menú superior, seleccione el desplegable “Desarrollador”. Seleccione la primera opción del menú desplegable titulada “Mis tokens de acceso”.

Conexión a MongoDB en AWS Glue Studio

AWS Glue proporciona soporte integrado para MongoDB. AWS Glue Studio proporciona una interfaz visual para conectarse a MongoDB, crear trabajos de integración de datos y ejecutarlos en el tiempo de ejecución de Spark sin servidor de AWS Glue Studio.

Temas

- Creación de una conexión de MongoDB

- Creación de un nodo de origen de MongoDB
- Creación de un nodo de destino de MongoDB
- Opciones avanzadas

Creación de una conexión de MongoDB

Requisitos previos:

- Si su instancia de MongoDB está en una Amazon VPC, configure Amazon VPC para permitir que su trabajo de AWS Glue se comunique con la instancia de MongoDB sin que el tráfico atraviese la Internet pública.

  En Amazon VPC, identifique o cree una VPC, una subred y un grupo de seguridad que AWS Glue utilizará al ejecutar el trabajo. Además, debe asegurarse de que Amazon VPC esté configurada para permitir el tráfico de red entre su instancia de MongoDB y esta ubicación. Según el diseño de la red, esto puede requerir cambios en las reglas de los grupos de seguridad, las ACL de red, las puertas de enlace de NAT y las conexiones entre pares.

Para configurar una conexión a MongoDB:

1. Si lo desea, en AWS Secrets Manager, cree un secreto con sus credenciales de MongoDB. Para crear un secreto en Secrets Manager, siga el tutorial disponible en Crear un secreto AWS Secrets Manager en la documentación AWS Secrets Manager. Después de crear el secreto, conserve el nombre secreto, *`secretName`*, para el siguiente paso.

   - Al seleccionar pares clave/valor, genere un par para la clave `username` con el valor *`mongodbUser`*.

     Al seleccionar pares clave/valor, genere un par para la clave `password` con el valor *`mongodbPass`*.

2. En la consola de AWS Glue, genere una conexión mediante los pasos que se indican en the section called “Adición de una conexión de AWS Glue”. Tras crear la conexión, conserve el nombre de la conexión, *`connectionName`*, para el uso futuro en AWS Glue.

   - Al seleccionar un tipo de conexión, seleccione MongoDB o MongoDB Atlas.
   - Al seleccionar la URL de MongoDB o la URL de MongoDB Atlas, proporciona el nombre de host de la instancia de MongoDB.

Se proporciona una URL de MongoDB en este formato `mongodb://mongoHost:mongoPort/mongoDBname`.

Se proporciona una URL de MongoDB Atlas en este formato `mongodb+srv://mongoHost:mongoPort/mongoDBname`.

Proporcionar la base de datos predeterminada para la conexión, *mongoDBname* es opcional.

- Si eligió crear un secreto de Secrets Manager, elija el tipo de credencial AWS Secrets Manager.

  Luego, en AWS Secret, ingrese *secretName*.

- Si decide proporcionar el nombre de usuario y la contraseña, proporcione *mongoDBuser* y *mongodbPass*.

3. En las siguientes situaciones, es posible que necesite una configuración adicional:

   - Para instancias de MongoDB alojadas AWS en una VPC de Amazon
     - Deberá proporcionar la información de conexión de Amazon VPC a la conexión AWS Glue que define sus credenciales de seguridad de MongoDB. Al crear o actualizar la conexión, configure los VPC, Subred y los grupos de seguridad en Opciones de red.

Tras crear una conexión con AWS Glue MongoDB, deberá realizar los siguientes pasos antes de ejecutar su trabajo de AWS Glue:

- Cuando trabaje con trabajos AWS Glue en el editor visual, debe proporcionar la información de conexión de Amazon VPC para que su trabajo se conecte a MongoDB. Identifique una ubicación adecuada en Amazon VPC y envíela a su conexión de AWS Glue MongoDB.
- Si opta por crear un secreto de Secrets Manager, conceda permiso al rol de IAM asociado a su trabajo de AWS Glue para leer *secretName*.

Creación de un nodo de origen de MongoDB

Requisitos previos necesarios

- Una conexión AWS Glue MongoDB, como se describe en la sección anterior,. the section called “Creación de una conexión de MongoDB”

- Si eligió crear un secreto de Secrets Manager, asigne los permisos necesarios para leer el secreto utilizado por la conexión.
- Una colección de MongoDB de la que quiera leer. Necesitará información de identificación para la colección.

  Una colección MongoDB se identifica mediante un nombre de base de datos y un nombre de colección, *`mongodbName`*, *`mongodbCollection`*.

Agregar un origen de datos de MongoDB

Para agregar un nodo de Origen de datos - MongoDB:

1. Elija la conexión para el origen de datos de MongoDB. Dado que lo ha creado, debería estar disponible en el menú desplegable. Si es necesario crear una conexión, elija Crear conexión de MongoDB. Para obtener más información, consulte la sección the section called “Creación de una conexión de MongoDB” anterior.

   Una vez que haya elegido una conexión, puede ver las propiedades de la conexión mediante un clic en Ver propiedades.
2. Elija una Base de datos. Introduzca *`mongodbName.`*
3. Elija una Colección. Ingrese a *`mongodbCollection.`*
4. Elija el Particionador, el tamaño de la partición (MB) y la Clave de partición. Para obtener más información sobre los parámetros de particiones, consulte the section called “"connectionType": "mongodb" como origen”.
5. En Propiedades personalizadas de MongoDB, ingrese los parámetros y valores según sea necesario.

Creación de un nodo de destino de MongoDB

Requisitos previos necesarios

- Una conexión AWS Glue MongoDB, configurada con un AWS Secrets Manager secreto, como se describe en la sección anterior, the section called “Creación de una conexión de MongoDB”.
- Permisos adecuados en el trabajo para leer el secreto utilizado por la conexión.
- Una tabla de MongoDB a la que desearía escribir, *`tableName`*.

Agregar un destino de datos de MongoDB

Para añadir un nodo de Destino de datos - MongoDB:

1. Elija la conexión para el origen de datos de MongoDB. Dado que lo ha creado, debería estar disponible en el menú desplegable. Si es necesario crear una conexión, elija Crear conexión de MongoDB. Para obtener más información, consulte la sección the section called “Creación de una conexión de MongoDB” anterior.

   Una vez que haya elegido una conexión, puede ver las propiedades de la conexión mediante un clic en Ver propiedades.
2. Elija una Base de datos. Introduzca *mongodbName.*
3. Elija una Colección. Ingrese a *mongodbCollection.*
4. Elija el Particionador, el tamaño de la partición (MB) y la Clave de partición. Para obtener más información sobre los parámetros de particiones, consulte the section called “"connectionType": "mongodb" como origen”.
5. Seleccione Reintentar escrituras si lo desea.
6. En Propiedades personalizadas de MongoDB, ingrese los parámetros y valores según sea necesario.

Opciones avanzadas

Puede brindar opciones avanzadas al crear un nodo de MongoDB. Estas opciones son las mismas que las disponibles cuando se programa AWS Glue para scripts de Spark.

Consulte the section called “Conexión a MongoDB”.

Conexión a Oracle NetSuite

Oracle NetSuite es una solución integral de administración empresarial en la nube que ayuda a las organizaciones a operar de forma más eficaz mediante la automatización de los procesos principales y la visibilidad en tiempo real del rendimiento operativo y financiero. Con un conjunto único e integrado de aplicaciones para administrar la contabilidad, el procesamiento de pedidos, la administración del inventario, la producción, la cadena de suministro y las operaciones de almacén, Oracle NetSuite ofrece a las empresas una visibilidad clara de sus datos y un control más estricto sobre sus negocios.

Temas

- Compatibilidad de AWS Glue para Oracle NetSuite
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de Oracle NetSuite
- Configuración de las conexiones a Oracle NetSuite
- Lectura de entidades de Oracle NetSuite
- Opciones de conexión a Oracle NetSuite
- Limitaciones y notas para el conector de Oracle NetSuite

Compatibilidad de AWS Glue para Oracle NetSuite

AWS Glue es compatible con Oracle NetSuite de la siguiente manera:

¿Es compatible como origen?

Sí. Puede utilizar los trabajos de ETL de AWS Glue para consultar datos de Oracle NetSuite.

¿Es compatible como destino?

No.

Versiones de la API de Oracle NetSuite compatibles

Las siguientes versiones de la API de Oracle NetSuite son compatibles:

- v1

Para conocer la compatibilidad de entidades por versión específica, consulte Entidades admitidas para el origen.

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS IAM necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
```

```
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si no desea utilizar el método anterior, puede utilizar las siguientes políticas de IAM administradas:

- AWSGlueServiceRole: da acceso a recursos que precisan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: otorga acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la Consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de Oracle NetSuite

Antes de poder utilizar AWS Glue para transferir datos hacia o desde Oracle NetSuite, deberá cumplir estos requisitos:

Requisitos mínimos

Los requisitos mínimos son los siguientes:

- Tener una cuenta de Oracle NetSuite. Para obtener más información, consulte Creación de una cuenta de Oracle NetSuite.

- La cuenta de Oracle NetSuite debe estar habilitada para el acceso de API.
- Ha creado una integración de la API de OAuth 2.0 en su cuenta de desarrollador de Oracle NetSuite. Esta integración proporciona las credenciales de cliente que AWS Glue utiliza para acceder a los datos de forma segura cuando hace llamadas autenticadas a la cuenta. Para obtener más información, consulte Creación de una aplicación cliente de Oracle NetSuite y credenciales de OAuth 2.0.

Si cumple estos requisitos, estará listo para conectar AWS Glue a la cuenta de Oracle NetSuite.

Creación de una cuenta de Oracle NetSuite

Vaya a Oracle NetSuite y elija Recorrido gratuito por el producto. Complete los detalles requeridos para obtener un recorrido gratuito por el producto, a través del cual podrá ponerse en contacto con un proveedor. El proceso para obtener una cuenta es el siguiente:

- La adquisición de una cuenta de NetSuite se realiza a través de un proveedor, que proporciona un formulario o presupuesto que debe revisarse legalmente.
- La cuenta que se va a adquirir para el conector Oracle NetSuite es de Standard Cloud Service.
- El proveedor crea esta cuenta y comparte las credenciales temporales. Recibirá un correo de bienvenida de NetSuite <billing@notification.netsuite.com> <system@sent-via.netsuite.com> con detalles como su nombre de usuario y un enlace para configurar su contraseña.
- Utilice el enlace Establecer su contraseña para establecer la contraseña del nombre de usuario proporcionado por el proveedor.

Creación de una aplicación cliente de Oracle NetSuite y credenciales de OAuth 2.0

Para obtener el ID de cliente y el secreto de cliente, debe crear una aplicación cliente de Oracle NetSuite:

1. Inicie sesión en su cuenta de NetSuite a través del inicio de sesión de cliente de NetSuite.
2. Seleccione Configuración > Empresa > Habilitar características.
3. Vaya a la sección SuiteCloud y seleccione la casilla de verificación REST WEB SERVICES en SuiteTalk (servicios web).
4. Seleccione la casilla de verificación OAUTH 2.0 en Administrar autenticación. Haga clic en Guardar.

5. Vaya a Configuración > Integración > Administrar integraciones y seleccione Nueva para crear una aplicación OAuth2.0.
6. Introduzca un nombre de su elección y mantenga el ESTADO como Habilitado.
7. Si están marcadas, desactive las casillas de verificación TBA: FLUJO DE AUTORIZACIÓN y AUTENTICACIÓN BASADA EN TOKEN que aparecen en Autenticación basada en token.
8. Seleccione las casillas de verificación CONCESIÓN DE CÓDIGO DE AUTORIZACIÓN y CLIENTE PÚBLICO en OAuth 2.0.
9. En Auth, tome nota del ID de cliente y el secreto de cliente.
10. Introduzca un URI DE REDIRECCIÓN. Por ejemplo, https://us-east-1.console.aws.amazon.com/gluestudio/oauth
11. Seleccione la casilla SERVICIOS WEB REST en ÁMBITO.
12. Seleccione la casilla de verificación CREDENCIALES DE USUARIO en Credenciales de usuario. Seleccione Save.
13. Anote la CLAVE DEL CONSUMIDOR/ID DE CLIENTE y el SECRETO DEL CONSUMIDOR/SECRETO DEL CLIENTE en las Credenciales de cliente. Estos valores se muestran solo una vez.
14. Cree un rol de ADMINISTRADOR si es necesario; para ello, vaya a Usuario/Roles > Administrar roles > Nuevo.
15. Al crear un rol personalizado, agregue acceso completo en la pestaña Permisos para las siguientes entidades/funcionalidades:
    - “Depósito”, “Artículos”, “Cumplimiento de artículos”, “Realizar entrada en el diario”, “Orden de compra”, “Filiales”, “Proveedores”, “Facturas”, “Autorización de devolución del proveedor”, “Seguimiento del tiempo”, “Pago del cliente”, “Entradas de registro personalizadas”, “Tipos de registros personalizados”, “Servicios web REST”, “Administración de aplicaciones autorizadas de OAuth 2.0”, “Campos de entidad personalizados”, “Iniciar sesión con los tokens de acceso de OAuth 2.0”.

Para obtener más información, consulte OAuth 2.0 en la documentación de NetSuite Applications Suite.

Configuración de las conexiones a Oracle NetSuite

Oracle NetSuite admite el tipo de concesión AUTHORIZATION_CODE para OAuth2. El tipo de concesión determina cómo se comunica AWS Glue con Oracle NetSuite para solicitar el acceso a los datos.

- Este tipo de concesión se considera un OAuth de “tres vías”, ya que se basa en redirigir a los usuarios a un servidor de autorización externo para autenticar al usuario. Se utiliza para crear conexiones a través de la consola de AWS Glue. El usuario que crea una conexión puede, de forma predeterminada, confiar en una aplicación conectada propiedad de AWS Glue (aplicación cliente administrada por AWS Glue) en la que no necesita proporcionar ninguna información relacionada con OAuth, excepto la URL de la instancia de Oracle NetSuite. La consola de AWS Glue redirigirá al usuario a Oracle NetSuite, donde deberá iniciar sesión y conceder a AWS Glue los permisos solicitados para acceder a su instancia de Oracle NetSuite.
- Los usuarios aún pueden optar por crear su propia aplicación conectada en Oracle NetSuite y proporcionar su propio ID y secreto de cliente al crear conexiones a través de la consola de AWS Glue. En este escenario, aún serán redirigidos a Oracle NetSuite para iniciar sesión y autorizar a AWS Glue para que acceda a sus recursos.
- Este tipo de concesión da como resultado un token de actualización y un token de acceso. El token de acceso es de corta duración y se puede actualizar automáticamente sin la interacción del usuario mediante el token de actualización.
- Para consultar la documentación pública de Oracle NetSuite sobre la creación de una aplicación conectada para el flujo Authorization Code OAuth, consulte Aplicaciones públicas.

Para configurar una conexión a Oracle NetSuite:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles:
   a. En el caso de las aplicaciones conectadas administradas por el cliente, el secreto debe contener el secreto del consumidor de la aplicación conectada con `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET` como clave.
   b. Nota: Debe crear un secreto para su conexión en AWS Glue.
2. En AWS Glue Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:
   a. Al seleccionar un Tipo de conexión, elija Oracle NetSuite.
   b. Proporcione el entorno de Oracle NetSuite.
   c. Seleccione el rol de AWS IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

      JSON

```
{
  "Version":"2012-10-17",
```

```
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

d. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.

e. Seleccione las opciones de red si quiere usar su red.

3. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.

Lectura de entidades de Oracle NetSuite

Requisito previo

Un objeto de Oracle NetSuite desde el cual le gustaría leer. Necesitará el nombre del objeto, como `deposit` o `timebill`. En la siguiente tabla se muestran las entidades admitidas.

Entidades compatibles como origen:

Entidad	Se puede filtrar	Admite Ordenar por	Admite límite	Admite SELECCIONAR *	Admite partición
Depósito	Sí	No	Sí	Sí	Sí
Artículo de la descripción	Sí	No	Sí	Sí	Sí

Entidad	Se puede filtrar	Admite Ordenar por	Admite límite	Admite SELECCIONAR *	Admite partición
Artículo de inventario	Sí	No	Sí	Sí	Sí
Procesamiento de artículos	Sí	No	Sí	Sí	Sí
Grupo de artículos	Sí	No	Sí	Sí	Sí
Entrada de diario	Sí	No	Sí	Sí	Sí
Artículo de compra no incluido en el inventario	Sí	No	Sí	Sí	Sí
Artículo de reventa no incluido en el inventario	Sí	No	Sí	Sí	Sí
Artículo de venta no incluido en el inventario	Sí	No	Sí	Sí	Sí
Orden de compra	Sí	No	Sí	Sí	Sí
Filial	Sí	No	Sí	Sí	Sí
Proveedor	Sí	No	Sí	Sí	Sí

Entidad	Se puede filtrar	Admite Ordenar por	Admite límite	Admite SELECCIONAR *	Admite partición
Factura de proveedor	Sí	No	Sí	Sí	Sí
Autorización de devolución del proveedor	Sí	No	Sí	Sí	Sí
Factura de tiempo	Sí	No	Sí	Sí	Sí
Pago de cliente	Sí	No	Sí	Sí	Sí
Solicitud de cumplimiento	Sí	No	Sí	Sí	Sí
Elemento	Sí	Sí	Sí	Sí	Sí
Línea de transacción	Sí	Sí	Sí	Sí	Sí
Línea de contabilidad de transacciones	Sí	Sí	Sí	Sí	Sí
Tipos de registros personalizados (dinámicos)	Sí	Sí	Sí	Sí	Sí

Ejemplo:

```
netsuiteerp_read = glueContext.create_dynamic_frame.from_options(
    connection_type="netsuiteerp",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "deposit",
        "API_VERSION": "v1"
    }
)
```

Detalles de la entidad y el campo de Oracle NetSuite:

Oracle NetSuite carga dinámicamente los campos disponibles en la entidad seleccionada. Según el tipo de datos de los campos, se admiten los operadores de filtro siguientes.

Tipo de datos de los campos	Operadores de filtro admitidos
Cadena	LIKE, =, !=
Date	BETWEEN, =, <, <=, >, >=
DateTime	BETWEEN, <, <=, >, >=
Numérico	=, !=, <, <=, >, >=
Booleano	=, !=

Formato de entrada esperado para los valores booleanos en Expresión de filtro:

Entidad	Formato de valor booleano “true”	Formato de valor booleano “false”	Ejemplo
Entidades de Elemento, Línea de transacción, Línea de contabilidad de transacciones y Tipo de registro personalizado	T o t	F o f	isinactive = “T” o isinactive = “t”

Entidad	Formato de valor booleano “true”	Formato de valor booleano “false”	Ejemplo
Todas las demás entidades	true	false	isinactive = true

Consultas de partición

Partición basada en campos

El conector de Oracle NetSuite tiene metadatos dinámicos, de modo que los campos compatibles para la partición basada en campos se eligen de forma dinámica. La partición basada en campos se admite en los campos que tienen el tipo de datos Integer, BigInteger, Date o DateTime.

Puede proporcionar las opciones adicionales de Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` y `NUM_PARTITIONS` si quiere utilizar la simultaneidad en Spark. Con estos parámetros, la consulta original se dividiría en un número `NUM_PARTITIONS` de subconsultas que las tareas de Spark pueden ejecutar simultáneamente.

- `PARTITION_FIELD`: el nombre del campo que se utilizará para particionar la consulta.
- `LOWER_BOUND`: un valor de límite inferior inclusivo del campo de partición elegido.

  Para el campo de marca de tiempo, aceptamos el formato de marca de tiempo de Spark que se usa en las consultas de Spark SQL.

  Ejemplos de valores válidos:

  ```
  "TIMESTAMP \"1707256978123\""
  "TIMESTAMP \"1702600882\""
  "TIMESTAMP '2024-02-06T22:00:00:00.000Z'"
  "TIMESTAMP '2024-02-06T22:00:00:00Z'"
  "TIMESTAMP '2024-02-06'"
  ```
- `UPPER_BOUND`: un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`: el número de particiones.

Ejemplo:

```
netsuiteerp_read = glueContext.create_dynamic_frame.from_options(
```

```
    connection_type="netsuiteerp",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "deposit",
        "API_VERSION": "v1",
        "PARTITION_FIELD": "id",
        "LOWER_BOUND": "1",
        "UPPER_BOUND": "10000",
        "NUM_PARTITIONS": "10"
    }
```

Partición basada en registros

Puede proporcionar la opción adicional NUM_PARTITIONS de Spark si quiere usar la simultaneidad en Spark. Con estos parámetros, la consulta original se dividiría en NUM_PARTITIONS subconsultas que las tareas de Spark pueden ejecutar simultáneamente.

En la partición basada en registros, el número total de registros presentes se consulta desde la API de Oracle NetSuite y se divide entre el NUM_PARTITIONS proporcionado. A continuación, cada subconsulta obtiene simultáneamente el número de registros resultante.

- NUM_PARTITIONS: el número de particiones.

Ejemplo:

```
netsuiteerp_read = glueContext.create_dynamic_frame.from_options(
    connection_type="netsuiteerp",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "deposit",
        "API_VERSION": "v1",
        "NUM_PARTITIONS": "3"
    }
```

Opciones de conexión a Oracle NetSuite

Las siguientes son opciones de conexión para Oracle NetSuite:

- ENTITY_NAME(cadena): (obligatorio) se usa para lectura. El nombre de la entidad de Oracle NetSuite. Ejemplo: depósito.

- `API_VERSION`(cadena): (obligatorio) se usa para lectura. Versión de la API de REST de Oracle NetSuite que desea usar. El valor será v1, ya que Oracle NetSuite actualmente solo admite la versión 1.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Lista de columnas separadas por comas que quiere seleccionar para la entidad seleccionada.
- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.
- `PARTITION_FIELD`(cadena): se usa para leer. Campo que se utilizará para particionar la consulta (partición basada en campos).
- `LOWER_BOUND`(cadena): se usa para leer. Un valor de límite inferior inclusivo del campo de partición elegido, que se utiliza en la partición basada en campos.
- `UPPER_BOUND`(cadena): se usa para leer. Un valor límite superior exclusivo del campo de partición elegido, que se utiliza en la partición basada en campos.
- `NUM_PARTITIONS`(entero): predeterminado: 1. Se usa para leer. Número de particiones para leer. Se utiliza en la partición basada en campos y registros.
- `INSTANCEE_URL`(cadena): una URL de instancia de NetSuite válida con el formato https://{account-id}.suitetalk.api.netsuite.com.

Limitaciones y notas para el conector de Oracle NetSuite

Las siguientes son limitaciones o notas para el conector de Oracle NetSuite:

- Los valores de los parámetros access_token y refresh_token están en formato JSON Web Token (JWT). access_token es válido durante 60 minutos, mientras que refresh_token es válido durante siete días.
- Al generar el ID y el secreto de cliente, si selecciona “PUBLIC CLIENT” junto con “AUTHORIZATION CODE GRANT”, el token de actualización solo es válido durante tres horas y solo se puede usar una vez.
- Puede obtener un máximo de 100 000 de registros mediante el conector. Para obtener más información, consulte Executing SuiteQL Queries Through REST Web Services.
- Las particiones se crean de manera que cada partición recupere los registros en múltiplos de 1000, excepto posiblemente la última, que recuperará los registros restantes.

- En el caso de los objetos Elemento, Línea de transacción y Línea de contabilidad de transacciones, el conector no admite algunos operadores por los siguientes motivos:
  - Al aplicar los operadores de filtro `EQUAL_TO`, `NOT_EQUAL_TO` a campos de tipo Fecha, se obtienen resultados poco fiables.
  - Al aplicar el operador de filtro `LESS_THAN_OR_EQUAL_TO` a campos de tipo Fecha, se obtienen resultados poco fiables y el operador se comporta de forma similar al operador `LESS_THAN`.
  - Al aplicar el operador de filtro `GREATER_THAN` a campos de tipo Fecha=, se obtienen resultados poco fiables y el operador se comporta de forma similar al operador `GREATER_THAN_OR_EQUAL_TO`.
- En el caso de los objetos Elemento, Línea de transacción, Línea de contabilidad de transacciones y Tipo de registro personalizado, los valores booleanos aparecen en el formato T/F en lugar del estándar true/false. El conector asigna los valores t/f a true/false para garantizar la coherencia de los datos.

Conexión al servicio OpenSearch en AWS Glue Studio

AWS Glue proporciona soporte integrado para Amazon OpenSearch Service. AWS Glue Studio proporciona una interfaz visual para conectarse a Amazon OpenSearch Service, crear trabajos de integración de datos y ejecutarlos en el tiempo de ejecución de Spark sin servidor de AWS Glue Studio. Esta característica no es compatible con OpenSearch Service sin servidor.

AWS Glue Studio crea una conexión unificada para Amazon OpenSearch Service. Para obtener más información, consulte Consideraciones.

Temas

- Crear una conexión con OpenSearch Service
- Crear un nodo fuente de OpenSearch Service
- Crear un nodo de destino de OpenSearch Service
- Opciones avanzadas

Crear una conexión con OpenSearch Service

Requisitos previos:

- Identifique el punto de conexión del dominio, el *`AOSEndpoint`* y el puerto, *`AOSport`* desde el que desea leer o cree el recurso siguiendo las instrucciones de la documentación de Amazon

OpenSearch Service. Para obtener más información sobre la creación de un dominio, consulte Crear y administrar dominios de Amazon OpenSearch Service en la documentación de Amazon OpenSearch Service.

Un punto de conexión de dominio de Amazon OpenSearch Service tendrá el siguiente formulario predeterminado: https://search-*domainName*-*unstructuredIdContent*.*region*.es.amazonaws.com. Para obtener más información sobre cómo identificar su punto de conexión de dominio, consulte Crear y administrar dominios de Amazon OpenSearch Service en la documentación de Amazon OpenSearch Service.

Identifique o genere credenciales de autenticación básica HTTP, *aosUser* y *aosPassword* para su dominio.

Para configurar una conexión a OpenSearch Service:

1. En AWS Secrets Manager, cree un secreto con sus credenciales de OpenSearch Service. Para crear un secreto en Secrets Manager, siga el tutorial disponible en Crear un secreto AWS Secrets Manager en la documentación AWS Secrets Manager. Después de crear el secreto, conserve el nombre secreto, *secretName*, para el siguiente paso.
   - Al seleccionar pares clave/valor, genere un par para la clave `USERNAME` con el valor *aosUser*.
   - Al seleccionar pares clave/valor, genere un par para la clave `PASSWORD` con el valor *aosPassword*.
2. En la consola de AWS Glue, genere una conexión mediante los pasos que se indican en the section called “Adición de una conexión de AWS Glue”. Tras crear la conexión, conserve el nombre de la conexión, *connectionName*, para el uso futuro en AWS Glue.
   - Al seleccionar un tipo de conexión, seleccione OpenSearch Service.
   - Al seleccionar un punto de conexión de dominio, proporcione *aosEndpoint*.
   - Al seleccionar un puerto, proporcione *aosPort*.
   - Al seleccionar un secreto AWS, proporcione un *secretName*.

Crear un nodo fuente de OpenSearch Service

Requisitos previos necesarios

- Una conexión AWS Glue de OpenSearch Service, configurada con un AWS Secrets Manager secreto, como se describe en la sección anterior, the section called “Crear una conexión con OpenSearch Service”.
- Permisos adecuados en el trabajo para leer el secreto utilizado por la conexión.
- Un índice de OpenSearch Service del que quiera leer, *aosIndex*.

Agregar un origen de datos de OpenSearch Service

Para añadir un nodo de origen de datos: OpenSearch Service:

1. Elija la conexión para el origen de datos de OpenSearch Service. Dado que lo ha creado, debería estar disponible en el menú desplegable. Si es necesario crear una conexión, elija Crear conexión de OpenSearch Service. Para obtener más información, consulte la sección the section called “Crear una conexión con OpenSearch Service” anterior.

   Una vez que haya elegido una conexión, puede ver las propiedades de la conexión mediante un clic en Ver propiedades.
2. Proporcione Index, el índice que desea leer.
3. Si lo desea, proporcione Query, una consulta de OpenSearch para obtener resultados más específicos. Para obtener más información sobre cómo escribir consultas de OpenSearch, consulte the section called “Lea de OpenSearch Service”.
4. En las propiedades personalizadas de OpenSearch Service, ingrese los parámetros y valores según sea necesario.

Crear un nodo de destino de OpenSearch Service

Requisitos previos necesarios

- Una conexión AWS Glue de OpenSearch Service, configurada con un AWS Secrets Manager secreto, como se describe en la sección anterior, the section called “Crear una conexión con OpenSearch Service”.
- Permisos adecuados en el trabajo para leer el secreto utilizado por la conexión.
- Un índice de OpenSearch Service al que desearía escribir, *aosIndex*.

Agregar un destino de datos de OpenSearch Service

Para añadir un nodo de Destino de datos: OpenSearch Service:

1. Elija la conexión para el origen de datos de OpenSearch Service. Dado que lo ha creado, debería estar disponible en el menú desplegable. Si es necesario crear una conexión, elija Crear conexión de OpenSearch Service. Para obtener más información, consulte la sección the section called “Crear una conexión con OpenSearch Service” anterior.

   Una vez que haya elegido una conexión, puede ver las propiedades de la conexión mediante un clic en Ver propiedades.
2. Proporcione Index, el índice que desea leer.
3. En las propiedades personalizadas de OpenSearch Service, ingrese los parámetros y valores según sea necesario.

Opciones avanzadas

Puede brindar opciones avanzadas al crear un nodo de OpenSearch Service. Estas opciones son las mismas que las disponibles cuando se programa AWS Glue para scripts de Spark.

Consulte the section called “Conexiones de OpenSearch Service”.

Conexión a Okta

La API de Okta es la interfaz programática de Okta que se utiliza para administrar cuentas y campañas de Okta grandes o complejas. Si es usuario de Okta, puede conectar AWS Glue a la cuenta de Okta. Tras ello, podrá utilizar Okta como origen de datos en los trabajos de ETL. Ejecute estos trabajos para transferir datos entre Okta y los servicios de AWS u otras aplicaciones compatibles.

Temas

- Compatibilidad de AWS Glue con Okta
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de Okta
- Configuración de conexiones a Okta
- Lectura de entidades de Okta
- Referencia de opciones de conexión de Okta

- Pasos para crear una nueva cuenta y una aplicación para desarrolladores de Okta
- Limitaciones

Compatibilidad de AWS Glue con Okta

AWS Glue es compatible con Okta de la siguiente manera:

¿Es compatible como origen?

Sí. Puede utilizar los trabajos de ETL de AWS Glue para consultar datos de Okta.

¿Es compatible como destino?

No.

Versiones de la API de Okta compatibles

v1.

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

También puede usar las siguientes políticas de IAM administradas para permitir el acceso:

- AWSGlueServiceRole: concede acceso a los recursos que necesitan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: concede acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de Okta

Antes de poder utilizar AWS Glue para transferir datos hacia o desde Okta, deberá cumplir estos requisitos:

Requisitos mínimos

- Tener una cuenta de Okta. Para obtener más información sobre cómo crear una cuenta, consulte Pasos para crear una nueva cuenta y una aplicación para desarrolladores de Okta.
- La cuenta de Okta debe estar habilitada para el acceso de API.
- Haber creado una integración de API de OAuth2 en la cuenta de Okta. Esta integración proporciona las credenciales de cliente que AWS Glue utiliza para acceder a los datos de forma segura cuando hace llamadas autenticadas a la cuenta. Para obtener más información, consulte los Pasos que se deben seguir para crear una aplicación cliente y las credenciales de OAuth2.0: pasos para crear una nueva cuenta en Okta y una aplicación para desarrolladores
- Tener una cuenta Okta de con un OktaApiToken. Consulte la documentación de Okta.

Si cumple estos requisitos, estará listo para conectar AWS Glue a la cuenta de Okta. Si es una conexión típica, no necesita hacer nada más en Okta.

Configuración de conexiones a Okta

Okta admite dos tipos de mecanismos de autenticación:

- Autenticación OAuth: Okta admite el tipo de concesión `AUTHORIZATION_CODE`.
  - Este tipo de concesión se considera un OAuth “de tres vías”, ya que se basa en redirigir a los usuarios al servidor de autorización externo para autenticar al usuario. Se utiliza para crear conexiones a través de la consola de AWS Glue. La consola de AWS Glue redirigirá al usuario a Okta, donde deberá iniciar sesión y conceder a AWS Glue los permisos solicitados para acceder a su instancia de Okta.
  - Los usuarios pueden optar por crear su propia aplicación conectada en Okta y proporcionar su propio ID y secreto de cliente al crear conexiones a través de la consola de AWS Glue. En este escenario, aún se abrirá Okta para iniciar sesión y autorizar a AWS Glue para que acceda a sus recursos.
  - Este tipo de concesión da como resultado un token de actualización y un token de acceso. El token de acceso es de corta duración y se puede actualizar automáticamente sin la interacción del usuario mediante el token de actualización.
  - Para obtener más información, consulte la documentación pública de Okta sobre la creación de una aplicación conectada para el flujo Authorization Code OAuth.
- Autenticación personalizada:
  - Para consultar la documentación pública de Okta sobre cómo generar las claves de API necesarias para la autorización personalizada, consulte la documentación de Okta.

Para configurar una conexión a Okta:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles. Es necesario crear un secreto para cada conexión en AWS Glue.
   a. Para la autenticación OAuth:
      - En el caso de una aplicación conectada administrada por el cliente, el secreto debe contener el secreto del consumidor de la aplicación conectada con la clave `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET`.
   b. Para la autenticación personalizada:
      - En el caso de una aplicación conectada administrada por el cliente, el secreto debe contener el secreto del consumidor de la aplicación conectada con `OktaApiToken` como clave.
2. En AWS Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:
   a. En Conexiones, elija Crear conexión.
   b. Al seleccionar un Origen de datos, elija Okta

c. Proporcione el subdominio de Okta.

d. Seleccione la URL del dominio de Okta de la cuenta de Okta.

e. Seleccione el rol de IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

f. Seleccione el tipo de autenticación para conectarse al origen de datos.

g. Para el tipo de autenticación OAuth2, proporcione el ID de cliente de la aplicación cliente administrada por el usuario de la aplicación de Okta.

h. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.

i. Seleccione las opciones de red si quiere usar su red.

3. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.

4. En la configuración de su trabajo de AWS Glue, proporcione `connectionName` como Conexión de red adicional.

Lectura de entidades de Okta

Requisitos previos

- Un objeto de Okta desde el que desea leer. Consulte la tabla de entidades compatibles que aparece a continuación para comprobar las entidades disponibles.

Entidades compatibles

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite Partición
Aplicaciones	Sí	Sí	No	Sí	No
Dispositivos	Sí	Sí	No	Sí	Sí
Grupos	Sí	Sí	Sí	Sí	Sí
Usuarios	Sí	Sí	Sí	Sí	Sí
Tipos de usuario	No	No	No	Sí	No

Ejemplo

```
okta_read = glueContext.create_dynamic_frame.from_options(
    connection_type="Okta",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "applications",
        "API_VERSION": "v1"
    }
```

Detalles de entidades y campos de Okta

Lista de entidades:

- Aplicación: https://developer.okta.com/docs/api/openapi/okta-management/management/tag/Application/
- Dispositivo: https://developer.okta.com/docs/api/openapi/okta-management/management/tag/Device/
- Grupo: https://developer.okta.com/docs/api/openapi/okta-management/management/tag/Group/

- Usuario: https://developer.okta.com/docs/api/openapi/okta-management/management/tag/User/
- Tipo de usuario: https://developer.okta.com/docs/api/openapi/okta-management/management/tag/UserType/

Consultas de partición

Puede proporcionar las opciones adicionales de Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` y `NUM_PARTITIONS` si quiere usar la simultaneidad en Spark. Con estos parámetros, la consulta original se dividiría en un número `NUM_PARTITIONS` de subconsultas que las tareas de Spark pueden ejecutar simultáneamente.

- `PARTITION_FIELD`: el nombre del campo que se usará para particionar la consulta.
- `LOWER_BOUND`: un valor de límite inferior inclusivo del campo de partición elegido.

  Para la fecha, aceptamos el formato de fecha de Spark que se usa en las consultas de Spark SQL. Ejemplos de valores válidos: `"2024-02-06"`.
- `UPPER_BOUND`: un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`: el número de particiones.

Ejemplo

```
okta_read = glueContext.create_dynamic_frame.from_options(
    connection_type="okta",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "lastUpdated",
        "API_VERSION": "v1",
        "PARTITION_FIELD": "lastMembershipUpdated"
        "LOWER_BOUND": "2022-08-10T10:28:46.000Z"
        "UPPER_BOUND": "2024-08-10T10:28:46.000Z"
        "NUM_PARTITIONS": "10"
    }
```

Referencia de opciones de conexión de Okta

Existen las siguientes opciones para establecer conexión con Okta:

- `ENTITY_NAME`(cadena): (obligatorio) se utiliza para leer y escribir. El nombre del objeto en Okta.

- `API_VERSION`(cadena): (obligatorio) se utiliza para leer y escribir. Versión de la API de REST de Okta que desea usar. Ejemplo: v1.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.
- `PARTITION_FIELD`(cadena): se usa para leer. Campo que se utilizará para particionar la consulta.
- `LOWER_BOUND`(cadena): se usa para leer. Un valor de límite inferior inclusivo del campo de partición elegido.
- `UPPER_BOUND`(cadena): se usa para leer. Un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`(entero): predeterminado: 1. Se usa para leer. Número de particiones para leer.

Pasos para crear una nueva cuenta y una aplicación para desarrolladores de Okta

Cree una cuenta para desarrolladores en Okta para acceder a la API de Okta. Una cuenta para desarrolladores gratuita de Okta proporciona acceso a la mayoría de las características clave para desarrolladores necesarias para acceder a la API de Okta.

Para crear una cuenta para desarrolladores en Okta

1. Vaya a https://developer.okta.com/signup/.
2. Ingrese la información de la cuenta: correo electrónico, nombre, apellido y país/región. Seleccione No soy un robot y luego haga clic en Registrarse.
3. Se enviará un correo de verificación a la dirección de correo registrada. Recibirá un enlace en el correo electrónico para activar la cuenta para desarrolladores de Okta. Seleccione Activar.
4. Será redirigido a la página de restablecimiento de contraseña. Ingrese la nueva contraseña dos veces y seleccione Restablecer contraseña.
5. Será redirigido al panel de la cuenta para desarrolladores de Okta.

Para crear una aplicación cliente y credenciales de OAuth 2.0

1. En el panel para desarrolladores, seleccione la opción para crear una integración de aplicaciones.

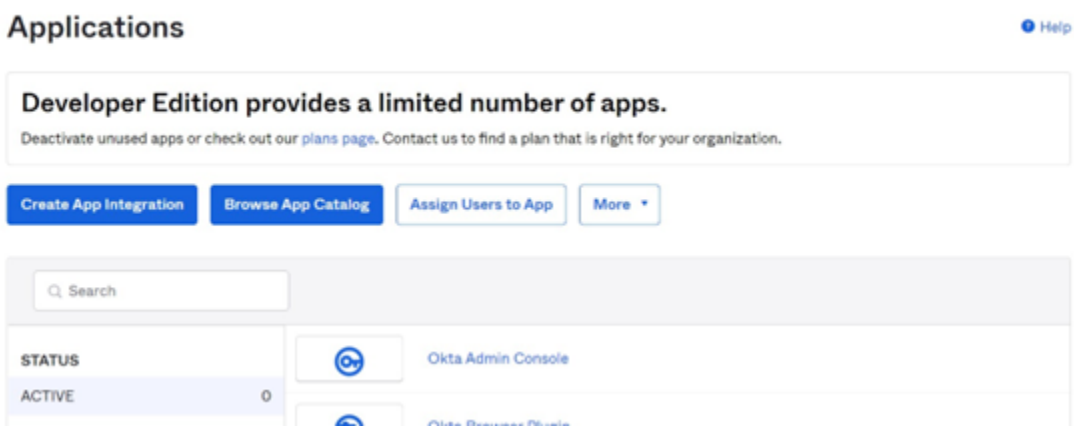

2. La ventana Crear una nueva integración de aplicación aparecerá y mostrará varios métodos de inicio de sesión. Seleccione OIDC – OpenID Connect.
3. Desplácese hacia abajo hasta la sección Tipo de aplicación. Seleccione Aplicación web y haga clic en Siguiente.
4. En la pantalla “Nueva integración de aplicación web”, complete la siguiente información:
   - Nombre de la integración de la aplicación: ingrese el nombre de la aplicación.
   - Tipo de concesión: seleccione Código de autorización y Token de actualización de la lista.
   - URI de redireccionamiento de inicio de sesión: elija Agregar URI y agregue `https://{regioncode}.console.aws.amazon.com/appflow/oauth`. Por ejemplo, si utiliza `us-west-2 (Oregon)`, puede agregar `https://us-east-1.console.aws.amazon.com/appflow/oauth`.
   - Acceso controlado: asigne la aplicación a los grupos de usuarios según lo necesite y seleccione Guardar.
5. Se generan tanto el ID de cliente como el secreto de cliente.

Limitaciones

El conector de Okta presenta las siguientes limitaciones:

- Para la entidad “Aplicaciones”, solo se puede aplicar un único filtro. Si se aplica más de un filtro, se devolverá un error 400 de solicitud errónea con el siguiente resumen: “Los criterios de búsqueda no son válidos”.

- “Ordenar por” solo se admite con consultas de búsqueda. Por ejemplo, `http://dev-15940405.okta.com/api/v1/groups?search=type e.q. "OKTA_GROUP"&sortBy=lastUpdated&sortOrder=asc`

Conexión a PayPal

PayPal es un sistema de pagos que facilita las transferencias de dinero en línea entre partes, por ejemplo, transferencias entre clientes y proveedores en línea. Si es usuario de PayPal, la cuenta contiene datos sobre las transacciones, como los pagadores, las fechas y los estados. Puede utilizar AWS Glue para transferir datos de PayPal a determinados servicios de AWS u otras aplicaciones compatibles.

Temas

- Compatibilidad de AWS Glue con PayPal
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de PayPal
- Configuración de conexiones a PayPal
- Cómo leer datos de entidades de PayPal
- Opciones de conexión a PayPal
- Limitaciones y notas del conector de PayPal

Compatibilidad de AWS Glue con PayPal

AWS Glue admite PayPal de la siguiente manera:

¿Es compatible como origen?

Sí. Puede usar los trabajos de ETL de AWS Glue para consultar datos de PayPal.

¿Es compatible como destino?

No.

Versión de API de PayPal compatibles

Las siguientes versiones de la API de PayPal son compatibles:

- v1

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS IAM necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si no desea utilizar el método anterior, puede utilizar las siguientes políticas de IAM administradas:

- AWSGlueServiceRole: da acceso a recursos que precisan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: otorga acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la Consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios

dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de PayPal

Antes de poder utilizar AWS Glue para transferir datos desde PayPal, deberá cumplir estos requisitos:

Requisitos mínimos

Los requisitos mínimos son los siguientes:

- Tiene una cuenta PayPal con credenciales de cliente.
- La cuenta de PayPal tiene acceso de API con una licencia válida.

Si cumple estos requisitos, estará listo para conectar AWS Glue a la cuenta de PayPal. Para conexiones típicas, no necesita hacer nada más en PayPal.

Configuración de conexiones a PayPal

PayPal admite el tipo de concesión CLIENT CREDENTIALS para OAuth2.

- Este tipo de concesión se considera OAuth 2.0 de doble vía, ya que lo utilizan los clientes para obtener un código de acceso fuera del contexto de un usuario. AWS Glue puede utilizar el ID de cliente y el secreto de cliente para autenticar las API de PayPal que proporcionan los servicios personalizados que se definan.
- Cada servicio personalizado pertenece a un usuario exclusivo de la API con un conjunto de roles y permisos que autorizan al servicio a realizar acciones específicas. Un token de acceso está asociado a un único servicio personalizado.
- Este tipo de concesión da lugar a un token de acceso de corta duración, y se puede renovar mediante una nueva llamada al punto de conexión `/v2/oauth2/token`.
- Para consultar la documentación pública de PayPal para OAuth 2.0 con credenciales de cliente, consulte Autenticación.

Para configurar una conexión a PayPal:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles:

a. En el caso de las aplicaciones conectadas administradas por el cliente, el secreto debe contener el secreto del consumidor de la aplicación conectada con `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET` como clave.

b. Nota: Debe crear un secreto para las conexiones en AWS Glue.

1. En AWS Glue Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:

   a. Al seleccionar un Tipo de conexión, elija PayPal.

   b. Proporcione la `INSTANCE_URL` de la instancia de PayPal a la que se quiere conectar.

   c. Seleccione el rol de AWS IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

      JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

   d. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.

   e. Seleccione las opciones de red si quiere usar su red.

2. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.

Obtención de las credenciales de OAuth 2.0

Para llamar a la API de Rest, tendrá que intercambiar el ID de cliente y el secreto de cliente por un token de acceso. Para obtener más información, consulte Introducción a las API de REST de PayPal.

Cómo leer datos de entidades de PayPal

Requisito previo

Un objeto de PayPal desde el que desea leer. Necesitará el nombre del objeto, `transaction`.

Entidades compatibles como origen:

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
transacción	Sí	Sí	No	Sí	Sí

Ejemplo:

```
paypal_read = glueContext.create_dynamic_frame.from_options(
    connection_type="paypal",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "transaction",
        "API_VERSION": "v1",
        "INSTANCE_URL": "https://api-m.paypal.com"
    }
```

Detalles de entidades y campos de PayPal:

Entidades con metadatos estáticos:

Entidad	Campo	Tipo de datos:	Operadores admitidos
transacción	transaction_initiation_date	DateTime	Entre
	last_refreshed_datetime	Cadena	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	payment_instrument_type	Cadena	=
	balance_affecting_records_only	Cadena	=
	id_tienda	Cadena	=
	terminal_id	Cadena	=
	transaction_currency	Cadena	=
	transaction_id	Cadena	N/A
	transaction_status	Cadena	N/A
	transaction_type	Cadena	N/A
	transaction_info	Struct	N/A
	payer_info	Struct	N/A
	shipping_info	Struct	N/A
	cart_info	Struct	N/A
	store_info	Struct	N/A
	auction_info	Struct	N/A
	incentive_info	Struct	N/A

Consultas de particionamiento

Puede proporcionar las opciones adicionales de Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` y `NUM_PARTITIONS` si quiere utilizar la simultaneidad en Spark. Con estos parámetros, la consulta original se dividiría en un número `NUM_PARTITIONS` de subconsultas que las tareas de Spark pueden ejecutar simultáneamente.

- PARTITION_FIELD: el nombre del campo que se utilizará para particionar la consulta.
- LOWER_BOUND: un valor de límite inferior inclusivo del campo de partición elegido.

  En el campo Datetime, aceptamos el valor en formato ISO.

  Ejemplos de valor válido:

  ```
  "2024-07-01T00:00:00.000Z"
  ```
- UPPER_BOUND: un valor límite superior exclusivo del campo de partición elegido.
- NUM_PARTITIONS: el número de particiones.

Se admite el siguiente campo para la partición por entidades:

Nombre de la entidad	Campos de partición	Tipo de datos:
transacción	transaction_initiation_date	DateTime

Ejemplo:

```
paypal_read = glueContext.create_dynamic_frame.from_options(
    connection_type="paypal",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "transaction",
        "API_VERSION": "v1",
        "PARTITION_FIELD": "transaction_initiation_date"
        "LOWER_BOUND": "2024-07-01T00:00:00.000Z"
        "UPPER_BOUND": "2024-07-02T00:00:00.000Z"
        "NUM_PARTITIONS": "10"
    }
```

Opciones de conexión a PayPal

Las siguientes son opciones de conexión para PayPal:

- ENTITY_NAME(cadena): (obligatorio) se usa para lectura. El nombre del objeto en PayPal.
- API_VERSION(cadena): (obligatorio) se usa para lectura. Versión de la API de Rest de PayPal que desea usar.

- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.
- `PARTITION_FIELD`(cadena): se usa para leer. Campo que se utilizará para particionar la consulta.
- `LOWER_BOUND`(cadena): se usa para leer. Un valor de límite inferior inclusivo del campo de partición elegido.
- `UPPER_BOUND`(cadena): se usa para leer. Un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`(entero): predeterminado: 1. Se usa para leer. Número de particiones para leer.

Limitaciones y notas del conector de PayPal

Las siguientes son limitaciones o notas para el conector de PayPal:

- La documentación sobre transacciones de PayPal indica que las transacciones ejecutadas tardan un máximo de tres horas en reflejarse en la llamada a lista de transacciones. Sin embargo, se ha observado que lleva más tiempo que eso según la `last_refreshed_datetime`. En este caso, `last_refreshed_datetime` es la cantidad de tiempo durante el cual tiene disponibles los datos de las API.
- Si la `last_refreshed_datetime` es anterior a la `end_date` solicitada, la `end_date` pasa a ser igual a la `last_refreshed_datetime`, ya que solo tenemos datos hasta ese momento.
- El campo `transaction_initiation_date` es un filtro obligatorio que se debe proporcionar para la entidad `transaction` y el intervalo de fechas máximo admitido para este campo es de 31 días.
- Cuando llama a la solicitud de API de la entidad `transaction` con filtros (parámetros de consulta) distintos del campo `transaction_initiation_date`, se espera que el valor del campo `ending_balance` no aparezca en la respuesta.

Conexión a Pendo

Pendo proporciona un rico almacén de datos para los datos de interacción con los usuarios. Los clientes transferirán estos datos a AWS para poder unirlos con otros datos de productos, realizar análisis adicionales y crear paneles, así como establecer alertas si así lo desean.

Temas

- Compatibilidad de AWS Glue con Pendo
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de Pendo
- Configuración de conexiones a Pendo
- Lectura de entidades de Pendo
- Opciones de conexión a Pendo
- Limitaciones

Compatibilidad de AWS Glue con Pendo

AWS Glue admite Pendo de la siguiente manera:

¿Es compatible como origen?

Sí. Puede utilizar los trabajos de ETL de AWS Glue para consultar datos de Pendo.

¿Es compatible como destino?

No.

Versiones de la API de Pendo compatibles

v1

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
```

```
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si no desea utilizar el método anterior, como alternativa, utilice las siguientes políticas de IAM administradas:

- AWSGlueServiceRole: concede acceso a los recursos que necesitan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: concede acceso completo a los recursos de AWS Gluecuando una identidad a la que está vinculada la política utiliza la Consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de Pendo

Antes de poder utilizar AWS Glue para transferir desde Pendo, deberá cumplir los siguientes requisitos:

Requisitos mínimos

- Tener una cuenta de Pendo con una `apiKey` con `write access` habilitado.
- La cuenta de Pendo debe disponer de acceso de API con una licencia válida.

Si cumple estos requisitos, estará listo para conectar AWS Glue a la cuenta de Pendo. Si es una conexión típica, no necesita hacer nada más en Pendo.

Configuración de conexiones a Pendo

Pendo admite la autenticación personalizada.

Para consultar la documentación pública de Pendo sobre la generación de las claves de API necesarias para la autorización personalizada, consulte Authentication – Pendo REST API Documentation.

Para configurar una conexión a Pendo:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles:
   - En el caso de una aplicación conectada administrada por el cliente, el secreto debe contener el secreto del consumidor de la aplicación conectada con `apiKey` como clave.

   > **Note**
   >
   > Es imprescindible crear un secreto por conexión en AWS Glue.

2. En AWS Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:
   a. Al seleccionar un Origen de datos, elija Pendo.
   b. Proporcione la `instanceUrl` de la instancia de Pendo a la que se quiere conectar.
   c. Seleccione el rol de IAM que AWS Glue puede asumir y que cuente con los permisos necesarios para realizar las siguientes acciones:

      JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
```

```
    }
  ]
}
```

d. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.

e. Seleccione las opciones de red si quiere usar su red.

3. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.
4. En la configuración del trabajo de AWS Glue, proporcione `connectionName` como una conexión de red adicional.

Lectura de entidades de Pendo

Requisitos previos

Un objeto de Pendo desde el que desea leer. Consulte la tabla de entidades compatibles que aparece a continuación para comprobar las entidades disponibles.

Entidades compatibles

- Característica
- Guía
- Página
- Informe
- Datos del informe
- Visitante
- Cuenta
- Evento
- Evento de característica
- Evento guía
- Evento de página
- Evento de encuesta
- Evento de seguimiento

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite Partición
Característica	No	No	No	Sí	No
Guía	No	No	No	Sí	No
Page	No	No	No	Sí	No
Informar	No	No	No	Sí	No
Datos del informe	No	No	No	Sí	No
Visitante (API de agregación)	Sí	No	Sí	Sí	No
Cuenta (API de agregación)	Sí	No	Sí	Sí	No
Cuenta (API de agregación)	Sí	No	Sí	Sí	No
Evento de característica (API de agregación)	Sí	No	Sí	Sí	Sí
Evento de guía (API de agregación)	Sí	No	Sí	Sí	Sí
Cuenta (API de agregación)	Sí	No	Sí	Sí	Sí

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite Partición
Evento de página (API de agregación)	Sí	No	Sí	Sí	Sí
Evento de encuesta (API de agregación)	Sí	No	Sí	Sí	Sí
Evento de seguimiento (API de agregación)	Sí	No	Sí	Sí	Sí

Ejemplo

```
Pendo_read = glueContext.create_dynamic_frame.from_options(
    connection_type="glue.spark.Pendo",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "feature",
        "API_VERSION": "v1",
        "INSTANCE_URL": "instanceUrl"
    }
```

Consultas de particionamiento

Puede proporcionar las opciones adicionales de Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` y `NUM_PARTITIONS` si quiere utilizar la simultaneidad en Spark. Con estos parámetros, la consulta original se dividiría en un número `NUM_PARTITIONS` de subconsultas que las tareas de Spark pueden ejecutar simultáneamente.

- `PARTITION_FIELD`: el nombre del campo que se utilizará para particionar la consulta.
- `LOWER_BOUND`: un valor de límite inferior inclusivo del campo de partición elegido.

Para el campo DateTime, aceptamos el valor en formato ISO.

Ejemplo de valor válido:

```
"2024-07-01T00:00:00.000Z"
```

- UPPER_BOUND: un valor límite superior exclusivo del campo de partición elegido.
- NUM_PARTITIONS: el número de particiones.

En la tabla siguiente, se describen los detalles de compatibilidad de campos de particiones de entidades:

Nombre de la entidad
Evento
Evento de característica
Evento de guía
Evento de página
Evento de encuesta
Evento de seguimiento

Ejemplo:

```
pendo_read = glueContext.create_dynamic_frame.from_options(
    connection_type="glue.spark.pendo",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "event",
        "API_VERSION": "v1",
        "INSTANCE_URL": "instanceUrl"
        "NUM_PARTITIONS": "10",
        "PARTITION_FIELD": "appId"
        "LOWER_BOUND": "4656"
        "UPPER_BOUND": "7788"
```

```
    }
```

Opciones de conexión a Pendo

Existen las siguientes opciones para establecer conexión con Pendo:

- `ENTITY_NAME`(cadena): (obligatorio) se utiliza para leer y escribir. El nombre del objeto en Pendo.
- `INSTANCE_URL`(cadena): (obligatorio) una URL de instancia de Pendo válida con los siguientes valores permitidos:
  - Predeterminado
  - Europa
  - US1
- `API_VERSION`(cadena): (obligatorio) se usa para lectura. Versión de la API de REST de Pendo Engage que desea utilizar. Por ejemplo: 3.0.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.
- `PARTITION_FIELD`(cadena): se usa para leer. Campo que se utilizará para particionar la consulta.
- `LOWER_BOUND`(cadena): se usa para leer. Un valor de límite inferior inclusivo del campo de partición elegido.
- `UPPER_BOUND`(cadena): se usa para leer. Un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`(entero): predeterminado: 1. Se usa para leer. Número de particiones para leer.

Limitaciones

El conector de Pendo presenta las siguientes limitaciones:

- No se admite la paginación en Pendo.
- La filtración solo es compatible con los objetos de la API de agregación: (`Account`, `Event`, `Feature Event`, `Guide Events`, `Page Event`, `Poll Event`, `Track Event` y `Visitor`).
- DateTimeRange es un parámetro de filtro obligatorio para los objetos de la API de agregación (`Event`, `Feature Event`, `Guide Events`, `Page Event`, `Poll Event`, y `Track Event`)

- El periodo dayRange se redondeará hacia abajo hasta el comienzo del periodo en la zona horaria correspondiente. Por ejemplo, si se proporciona el filtro `2023-01-12T07:55:27.065Z`, este periodo se redondeará al inicio del período, es decir `2023-01-12T00:00:00Z`.

Conexión a Pipedrive

Pipedrive es un CRM de administración de embudos de ventas diseñado para ayudar a las pequeñas empresas a administrar clientes potenciales, dar seguimiento a las actividades comerciales y cerrar más negocios. Pipedrive permite a los equipos de ventas de pequeñas empresas optimizar procesos y consolidar datos de ventas en una única herramienta unificada de CRM de ventas. Si es usuario de Pipedrive, puede conectar AWS Glue a la cuenta de Pipedrive. Tras ello, podrá utilizar Pipedrive como origen de datos en los trabajos de ETL. Ejecute estos trabajos para transferir datos entre Pipedrive y los servicios de AWS u otras aplicaciones compatibles.

Temas

- Compatibilidad de AWS Glue con Pipedrive
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de Pipedrive
- Configuración de las conexiones de Pipedrive
- Lectura de entidades de Pipedrive
- Referencia de opciones de conexión de Pipedrive
- Limitaciones

Compatibilidad de AWS Glue con Pipedrive

AWS Glue es compatible con Pipedrive de la siguiente manera:

¿Es compatible como origen?

Sí. Puede utilizar los trabajos de ETL de AWS Glue para consultar datos de Pipedrive.

¿Es compatible como destino?

No.

Versiones de la API de Pipedrive compatibles

v1.

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

También puede usar las siguientes políticas de IAM administradas para permitir el acceso:

- AWSGlueServiceRole: concede acceso a los recursos que necesitan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: concede acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de Pipedrive

Antes de poder utilizar AWS Glue para transferir datos desde Pipedrive, deberá cumplir estos requisitos:

Requisitos mínimos

- Tener una cuenta de Pipedrive.
- La cuenta de Pipedrive debe estar habilitada para el acceso de API.

Si cumple estos requisitos, estará listo para conectar AWS Glue a la cuenta de Pipedrive. Si es una conexión típica, no necesita hacer nada más en Pipedrive.

Configuración de las conexiones de Pipedrive

Pipedrive admite el tipo de concesión AUTHORIZATION_CODE para OAuth2.

- Este tipo de concesión se considera un OAuth “de tres vías”, ya que se basa en redirigir a los usuarios al servidor de autorización externo para autenticar al usuario. Se utiliza para crear conexiones a través de la consola de AWS Glue. El usuario que crea una conexión puede, de forma predeterminada, confiar en una aplicación conectada propiedad de AWS Glue en la que no necesita proporcionar ninguna información relacionada con OAuth, excepto la URL de la instancia de Pipedrive. La consola de AWS Glue redirigirá al usuario a Pipedrive, donde deberá iniciar sesión y conceder a AWS Glue los permisos solicitados para acceder a su instancia de Pipedrive.
- Los usuarios deberían optar por crear una aplicación conectada propia en Pipedrive y proporcionar su propio ID y secreto de cliente al crear conexiones a través de la consola de AWS Glue. En este escenario, aún se abrirá Pipedrive para iniciar sesión y autorizar a AWS Glue para que acceda a sus recursos.
- Este tipo de concesión da como resultado un token de actualización y un token de acceso. El token de acceso permanecerá válido durante una hora y se puede actualizar automáticamente sin la interacción del usuario mediante el token de actualización.
- Para obtener más información, consulte la documentación sobre la creación de una aplicación conectada para el flujo Authorization Code OAuth.

Para configurar una conexión a Pipedrive:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles. Es necesario crear un secreto para cada conexión en AWS Glue.

a. En el caso de aplicaciones conectadas administradas por el cliente, el secreto debe contener el secreto del consumidor de la aplicación conectada con USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET como clave.

2. En AWS Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:

   a. En Conexiones de datos, elija Crear conexión.

   b. Al seleccionar un Origen de datos, elija Pipedrive.

   c. Proporcione la URL de la instancia de Pipedrive.

   d. Seleccione el rol de IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

      JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

   e. Proporcione el ID de cliente de la aplicación cliente administrada por el usuario de Pipedrive a la que se desea conectar.

   f. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.

   g. Seleccione las opciones de red si quiere usar su red.

3. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`. Elija Siguiente.

4. Proporcione el connectionName y elija Siguiente.
5. En la página siguiente, elija Crear conexión. Se le pedirá que inicie sesión en Pipedrive. Indique su nombre de usuario y la contraseña y elija Iniciar sesión.
6. Una vez que haya iniciado sesión, seleccione Continuar a la aplicación. La conexión está lista para usarse.
7. En la configuración de su trabajo de AWS Glue, proporcione `connectionName` como Conexión de red adicional.

Lectura de entidades de Pipedrive

Requisitos previos

- Un objeto de Pipedrive del que desea leer. Consulte la tabla de entidades compatibles que aparece a continuación para comprobar las entidades disponibles.

Entidades compatibles

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite Partición
Actividades	Sí	Sí	No	Sí	Sí
Tipo de actividad	No	No	No	Sí	No
Registros de llamadas	No	No	No	Sí	No
Divisas	Sí	Sí	No	Sí	No
Acuerdos	Sí	Sí	Sí	Sí	Sí
Leads	Sí	Sí	Sí	Sí	No
Fuentes de clientes potenciales	No	Sí	No	Sí	No

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite Partición
Etiquetas de clientes potenciales	No	No	No	No	No
Notas	Sí	Sí	Sí	Sí	Sí
Organización	Sí	Sí	No	Sí	Sí
Conjuntos de permisos	Sí	No	No	Sí	No
Personas	Sí	Sí	Sí	Sí	Sí
Canalizaciones	No	Sí	No	Sí	No
Productos	Sí	Sí	No	Sí	Sí
Roles	No	Sí	No	Sí	No
Etapas	Sí	Sí	No	Sí	No
Usuarios	No	No	No	Sí	No

Ejemplo

```
pipedrive_read= glueContext.create_dynamic_frame.from_options(
    connection_type="PIPEDRIVE",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "activites",
        "API_VERSION": "v1"
    }
```

Detalles de entidades y campos de Pipedrive

Lista de entidades:

- Actividades: https://developers.pipedrive.com/docs/api/v1/Activities
- Tipo de actividad: https://developers.pipedrive.com/docs/api/v1/ActivityTypes
- Registros de llamadas: https://developers.pipedrive.com/docs/api/v1/CallLogs
- Divisas: https://developers.pipedrive.com/docs/api/v1/Currencies
- Negocios: https://developers.pipedrive.com/docs/api/v1/Deals
- Clientes potenciales: https://developers.pipedrive.com/docs/api/v1/Leads
- Fuentes de clientes potenciales: https://developers.pipedrive.com/docs/api/v1/LeadSources
- Etiquetas de clientes potenciales: https://developers.pipedrive.com/docs/api/v1/LeadLabels
- Notas: https://developers.pipedrive.com/docs/api/v1/Notes
- Organizaciones: https://developers.pipedrive.com/docs/api/v1/Organizations
- Conjuntos de permisos: https://developers.pipedrive.com/docs/api/v1/PermissionSets
- Personas: https://developers.pipedrive.com/docs/api/v1/Persons
- Embudos de ventas: https://developers.pipedrive.com/docs/api/v1/Pipelines
- Productos: https://developers.pipedrive.com/docs/api/v1/Products
- Roles: https://developers.pipedrive.com/docs/api/v1/Roles
- Etapas: https://developers.pipedrive.com/docs/api/v1/Stages
- Usuarios: https://developers.pipedrive.com/docs/api/v1/Users

Entidad	Tipo de datos	Operadores admitidos
Actividades, negocios, notas, organización, personas y productos.	Date	'='
	Entero	'='
	Cadena	'='
	Booleano	'='

Consultas de partición

En Pipedrive, solo un campo (due_date) de la entidad Actividades admite la partición basada en campos. Se trata de un campo de fecha.

Puede proporcionar las opciones adicionales de Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` y `NUM_PARTITIONS` si quiere usar la simultaneidad en Spark. Con estos parámetros, la consulta original se dividiría en un número `NUM_PARTITIONS` de subconsultas que las tareas de Spark pueden ejecutar simultáneamente.

- `PARTITION_FIELD`: el nombre del campo que se usará para particionar la consulta.
- `LOWER_BOUND`: un valor de límite inferior inclusivo del campo de partición elegido.

  Para la fecha, aceptamos el formato de fecha de Spark que se usa en las consultas de Spark SQL. Ejemplos de valores válidos: `"2024-02-06"`.
- `UPPER_BOUND`: un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`: el número de particiones.

Ejemplo

```
pipedrive_read = glueContext.create_dynamic_frame.from_options(
    connection_type="PIPEDRIVE",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "activites",
        "API_VERSION": "v1",
        "PARTITION_FIELD": "due_date"
        "LOWER_BOUND": "2023-09-07T02:03:00.000Z"
        "UPPER_BOUND": "2024-05-07T02:03:00.000Z"
        "NUM_PARTITIONS": "10"
    }
```

Referencia de opciones de conexión de Pipedrive

Existen las siguientes opciones para establecer conexión con Pipedrive:

- `ENTITY_NAME`(cadena): (obligatorio) se utiliza para leer y escribir. El nombre del objeto en Pipedrive.

- API_VERSION(cadena): (obligatorio) se utiliza para leer y escribir. Versión de la API de Rest de Pipedrive que desea usar. Ejemplo: v1.
- INSTANCE_URL(cadena): (obligatorio) URL de la instancia en la que el usuario desea ejecutar las operaciones. Ejemplo: v1.
- SELECTED_FIELDS(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- FILTER_PREDICATE(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- QUERY(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.
- PARTITION_FIELD(cadena): se usa para leer. Campo que se utilizará para particionar la consulta.
- LOWER_BOUND(cadena): se usa para leer. Un valor de límite inferior inclusivo del campo de partición elegido.
- UPPER_BOUND(cadena): se usa para leer. Un valor límite superior exclusivo del campo de partición elegido.
- NUM_PARTITIONS(entero): predeterminado: 1. Se usa para leer. Número de particiones para leer.

Limitaciones

El conector de Pipedrive presenta las siguientes limitaciones:

- Pipedrive admite la partición basada en campos únicamente para una entidad (Actividades).
- Pipedrive admite la partición basada en registros para las entidades Actividades, Negocios, Notas, Personas, Organizaciones y Productos.
- En la entidad Negocios, el campo de estado como filtro devolverá todos los registros si se usa un valor de filtro no válido.
- En la entidad Negocios, no se admite la ordenación por múltiples campos.
- Para obtener datos de rendimiento, utilizamos una cuenta de AWS local. Sin embargo, debido a la limitación en la actualización del token de acceso a nivel local, el trabajo de AWS Glue falla al procesar 1 GB de datos. Como consecuencia, hemos optimizado la prueba de rendimiento con 179 MB de datos, y los resultados anteriores se basan en esta optimización. No obstante, hemos observado que, a medida que aumenta la cantidad de particiones, el punto de conexión SaaS tarda más tiempo en comparación con una única partición. Hemos consultado con el equipo de soporte de Pipedrive sobre este comportamiento, y nos informaron que Pipedrive limita

silenciosamente las solicitudes y retrasa la respuesta. Por lo tanto, al ejecutar el trabajo de AWS Glue con conjuntos de datos grandes o al llamar varias veces al mismo punto de conexión de la API, se puede producir un problema de tiempo de espera debido a la implementación de la API de Pipedrive. Sin embargo, los tiempos de respuesta del conector y de la capa intermedia disminuyen como se esperaba a medida que aumenta la cantidad de particiones.

Conexión a Productboard

Productboard es un sistema de administración de productos que ayuda a los equipos encargados de ellos a lanzar al mercado los productos adecuados con mayor rapidez. Más de 3000 empresas modernas orientadas al producto, como Zendesk, UiPath y Microsoft, utilizan Productboard para comprender lo que realmente necesitan los usuarios, priorizar qué desarrollar a continuación y alinear a todos en torno a su hoja de ruta.

Temas

- Compatibilidad de AWS Glue con Productboard
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de Productboard
- Configuración de las conexiones a Productboard
- Lectura de entidades de Productboard
- Opciones de conexión a Productboard
- Creación de una cuenta de Productboard
- Limitaciones

Compatibilidad de AWS Glue con Productboard

AWS Glue es compatible con Productboard de la siguiente manera:

¿Es compatible como origen?

Sí. Puede usar los trabajos de ETL de AWS Glue para consultar datos de Productboard.

¿Es compatible como destino?

No.

Versiones de la API de Productboard compatibles

v1

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si no desea utilizar el método anterior, como alternativa, utilice las siguientes políticas de IAM administradas:

- AWSGlueServiceRole: concede acceso a los recursos que necesitan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: concede acceso completo a los recursos de AWS Gluecuando una identidad a la que está vinculada la política utiliza la Consola de administración de AWS. Si

sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de Productboard

Antes de poder utilizar AWS Glue para transferir desde Productboard, deberá cumplir los siguientes requisitos:

Requisitos mínimos

- Tener una cuenta de Productboard con correo electrónico y contraseña. Para obtener más información sobre cómo crear una cuenta, consulte Creating a Productboard account.
- Debe tener una cuenta de AWS creada con el servicio de acceso a AWS Glue.
- Contar con los detalles de autenticación de una cuenta de Productboard: el token JWT si quiere utilizar la autenticación personalizada o el ID y el secreto de cliente si quiere utilizar OAuth2.0.
- Si el usuario quiere utilizar `OAuth2.0`, registre la aplicación en Productboard y configúrela. Para ello, siga las instrucciones que se encuentran en la documentación para desarrolladores How to integrate with Productboard via OAuth2.

Si cumple estos requisitos, estará listo para conectar AWS Glue a la cuenta de Productboard. Si se trata de una conexión típica, no necesita hacer nada más en Productboard.

Configuración de las conexiones a Productboard

Productboard admite la autenticación personalizada y `OAuth2.0`. En el caso de `OAuth2.0`, Productboard admite el tipo de concesión `AUTHORIZATION_CODE`.

- Este tipo de concesión se considera un `OAuth` de “tres patas”, ya que depende de redirigir a los usuarios al servidor de autorización de terceros para autenticarlos. Se utiliza para crear conexiones a través de la consola de AWS Glue. El usuario que crea una conexión puede, de forma predeterminada, depender de una aplicación conectada propiedad de AWS Glue, en la que no necesita proporcionar ninguna información relacionada con `OAuth`, excepto su ID de cliente y secreto de cliente de Productboard. La consola de AWS Glue redirigirá al usuario a Productboard, donde deberá iniciar sesión y conceder a AWS Glue los permisos solicitados para acceder a su instancia de Productboard.

- Los usuarios aún pueden optar por crear su propia aplicación conectada en Productboard y proporcionar su propio ID y secreto de cliente al crear conexiones a través de la consola de AWS Glue. En este escenario, aún se abrirá Productboard para iniciar sesión y autorizar a AWS Glue para que acceda a sus recursos.
- Este tipo de concesión da como resultado un token de actualización y un token de acceso. El token de acceso es de corta duración y se puede actualizar automáticamente sin la interacción del usuario mediante el token de actualización.
- Para ver la documentación pública de Productboard sobre la creación de una aplicación conectada para el flujo `AUTHORIZATION_CODE OAuth`, consulte la documentación para desarrolladores How to integrate with Productboard via OAuth2.

Para configurar una conexión a Productboard:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles:
   - Para la autenticación `OAuth`, en el caso de una aplicación conectada administrada por el cliente: el secreto debe contener el secreto del cliente de la aplicación conectada con `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET` como clave.
   - Para `Custom auth`, en el caso de una aplicación conectada administrada por el cliente: el secreto debe contener el `JWT token` de la aplicación conectada con `access_token` como clave.

   > **Note**
   >
   > Es imprescindible crear un secreto por conexión en AWS Glue.

2. En AWS Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:
   a. Al seleccionar un Origen de datos, elija Productboard.
   b. Seleccione el rol de IAM que AWS Glue puede asumir y que cuente con los permisos necesarios para realizar las siguientes acciones:

   JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
```

```
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

c. Seleccione el tipo de autenticación para conectarse al origen de datos:

- Para la autenticación `OAuth`: proporcione el `Token URL`, así como el `User Managed Client Application ClientId` de la aplicación de Productboard.

d. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.

e. Seleccione las opciones de red si quiere usar su red.

3. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.
4. En la configuración del trabajo de AWS Glue, proporcione `connectionName` como una conexión de red adicional.

Lectura de entidades de Productboard

Requisitos previos

Un objeto de Productboard desde el que desea leer. Consulte la tabla de entidades compatibles que aparece a continuación para comprobar las entidades disponibles.

Entidades compatibles

- Informes de abuso
- Automatización
- Campaigns (Campañas)
- Detalles de los clics
- Listas

- Miembros
- Detalles de aperturas
- Segmentos
- Almacenes
- Cancelación de suscripción

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite Partición
Características	Sí	Sí	No	Sí	Sí
Componentes	No	Sí	No	Sí	No
Productos	No	Sí	No	Sí	No
Estados de las características	No	Sí	No	Sí	Sí
Definiciones de campo personalizado	No	Sí	No	Sí	No
Valores de campo personalizado	Sí	Sí	No	Sí	No

Ejemplo

```
Productboard_read = glueContext.create_dynamic_frame.from_options(
    connection_type="Productboard",
    connection_options={
```

```
        "connectionName": "connectionName",
        "ENTITY_NAME": "feature",
        "API_VERSION": "1"
    }
```

Detalles de entidades y campos de Productboard

- Características
- Componentes
- Estados de las características
- Productos
- Definiciones de campo personalizado
- Valores de campo personalizado

Opciones de conexión a Productboard

Existen las siguientes opciones para establecer conexión con Productboard:

- `ENTITY_NAME`(cadena): (obligatorio) se utiliza para leer y escribir. El nombre del objeto en Productboard.
- `API_VERSION`(cadena): (obligatorio) se usa para lectura. Versión de la API de REST de Productboard Engage que desea utilizar. Por ejemplo: 3.0.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.

Creación de una cuenta de Productboard

1. Vaya a la página de registro de Productboard, ingrese su dirección de correo electrónico y contraseña y, a continuación, seleccione Iniciar sesión.
2. En el campo Nombre de la cuenta, ingrese el nombre de la cuenta de Productboard y, a continuación, active la casilla Acepto la política de privacidad.

3. En la página Cree ahora el espacio de trabajo, en el campo URL del espacio de trabajo, ingrese la URL del nuevo espacio de trabajo. A continuación, elija Continuar para pasar a la página siguiente y proporcionar el resto de los detalles.

   Esto crea la cuenta de prueba. La cuenta de prueba es gratuita durante 15 días. Una vez que venza el periodo de prueba, podrá comprar un plan de pago. Anote la dirección de correo electrónico, contraseña y URL del espacio de trabajo. Necesitará esta información para acceder a la cuenta en el futuro.

Cómo registrar una aplicación de **`OAuth2.0`**

1. Vaya a la página de inicio de sesión de Productboard, ingrese la dirección de correo electrónico y contraseña y, a continuación, seleccione Iniciar sesión.
2. Seleccione el icono Usuario en la esquina superior derecha y, a continuación, elija Cuenta y facturación en el menú desplegable.
3. Seleccione Extras y elija Aplicaciones registradas en el menú desplegable.
4. Busque la opción Registrar una aplicación y selecciónela.
5. Escriba la información siguiente:

   - Nombre de la aplicación: nombre de la aplicación.
   - Empresa/organización: nombre de la empresa u organización.
   - Sitio web de la aplicación: sitio web de la aplicación.
   - URI de redireccionamiento: un patrón de URI de redireccionamiento es una ruta de URI (o una lista de rutas separadas por comas) a la que Productboard puede redirigir (si se solicita) cuando finaliza el flujo de inicio de sesión. Por ejemplo, `https://ap-southeast-2\\.console\\.aws\\.amazon\\.com`
6. Seleccione Crear.
7. Ahora aparecerán el ID de cliente y el secreto de cliente. Cópielos y guárdelos en un lugar seguro. A continuación, seleccione Listo.

> **Note**
>
> Las cadenas de ID de cliente y secreto de cliente son las credenciales utilizadas para establecer una conexión con este conector cuando se utiliza AppFlow o AWS Glue.

Cómo recuperar credenciales de CustomAuth

1. Vaya a la página de inicio de sesión de Productboard, ingrese la dirección de correo electrónico y la contraseña y, a continuación, seleccione Iniciar sesión.

   Será redirigido a la página de inicio.
2. En la página de inicio, vaya a Configuración del espacio de trabajo > Integraciones > API públicas > Token de acceso.

   > **Note**
   >
   > Si la sección API públicas no aparece, es posible que su cuenta esté en el plan Essentials. Para acceder a los tokens de la API, se requiere al menos un plan Pro. Las características y los nombres de los planes pueden estar sujetos a cambios. Para obtener más información sobre los paquetes, consulte Precios de Productboard.
3. Elija + para generar un nuevo token y asegúrese de guardarlo de forma segura para consultarlo en el futuro.

Creación de credenciales de **`OAuth2.0`**

Para utilizar la autenticación `OAuth2.0` con el conector de Productboard, debe registrar la aplicación en la plataforma de Productboard y generar tanto el `Client ID` como el `Client Secret`.

1. Vaya a la página de inicio de sesión de Productboard, ingrese la dirección de correo electrónico y la contraseña y, a continuación, seleccione Iniciar sesión.
2. Para registrar una nueva aplicación OAuth2 en la cuenta de Productboard, vaya a la página de Productboard.
3. Complete los campos obligatorios y seleccione los ámbitos necesarios para cada entidad a la que desee acceder.

   > **Note**
   >
   > Ha seleccionado los siguientes cuatro ámbitos, que son obligatorios para las seis entidades compatibles.
4. La URL de redireccionamiento debe tener el siguiente formato: `https://ap-southeast-2\\.console\\.aws\\.amazon\\.com`

> **Note**
>
> Las URL de redireccionamiento de Appflow están sujetas a cambios. Cuando estén disponibles, actualice las URL de redireccionamiento de la plataforma de AWS Glue.

5. Ahora aparecerán el ID de cliente y el secreto de cliente. Cópielos y guárdelos en un lugar seguro.
6. Puede configurar y verificar `OAuth2`. Para ello, siga los pasos que se indican en la documentación para desarrolladores de How to Integrate with Productboard via OAuth2.

Limitaciones

El conector de Productboard presenta las siguientes limitaciones:

- Productboard no admite la partición basada en campos ni en registros.

Conexión a QuickBooks

QuickBooks es una aplicación de contabilidad líder dirigida a pequeñas y medianas empresas. Las aplicaciones de contabilidad QuickBooks se remontan a la década de 1980, cuando fueron lanzadas como uno de los primeros productos de Intuit y, en consecuencia, originalmente se desarrollaron como software de escritorio. En la actualidad, QuickBooks ofrece diversas aplicaciones de contabilidad y gestión financiera empresarial, disponibles tanto como software instalable como en su versión SaaS basada en la nube. Como usuario de QuickBooks, puede conectar AWS Glue a la cuenta de QuickBooks. A continuación, puede utilizar QuickBooks como origen de datos en los trabajos de ETL. Ejecute estos trabajos para transferir datos entre QuickBooks y los servicios de AWS u otras aplicaciones compatibles.

Temas

- Compatibilidad de AWS Glue con QuickBooks
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de QuickBooks
- Configuración de conexiones a QuickBooks
- Cómo leer a partir de entidades de QuickBooks
- Opciones de conexión a QuickBooks

- Limitaciones y notas del conector de QuickBooks

Compatibilidad de AWS Glue con QuickBooks

AWS Glue admite QuickBooks de la siguiente manera:

¿Es compatible como origen?

Sí. Puede usar los trabajos de ETL de AWS Glue para consultar datos de QuickBooks.

¿Es compatible como destino?

No.

Versiones de la API de QuickBooks compatibles

Se admiten las siguientes versiones de la API de QuickBooks:

- v3

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS IAM necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
```

```
    }
  ]
}
```

Si no desea utilizar el método anterior, puede utilizar las siguientes políticas de IAM administradas:

- AWSGlueServiceRole: da acceso a recursos que precisan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: otorga acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la Consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de QuickBooks

Antes de poder utilizar AWS Glue para transferir datos desde QuickBooks, deberá cumplir estos requisitos:

Requisitos mínimos

Los requisitos mínimos son los siguientes:

- Tener una cuenta de QuickBooks.
- La cuenta de QuickBooks está habilitada para el acceso a la API.

Para obtener más información, consulte los siguientes temas en la documentación de QuickBooks:

- Creación de una cuenta de Intuit
- Cómo crear y comenzar a desarrollar la aplicación

Si cumple estos requisitos, estará listo para conectar AWS Glue a la cuenta de QuickBooks. Para conexiones típicas, no necesita hacer nada más en QuickBooks.

Configuración de conexiones a QuickBooks

QuickBooks admite el tipo de concesión AUTHORIZATION_CODE para OAuth 2. El tipo de concesión determina cómo se comunica AWS Glue con QuickBooks para solicitar el acceso a los datos.

- Este tipo de concesión se considera un OAuth de “tres vías”, ya que se basa en redirigir a los usuarios a un servidor de autorización externo para autenticar al usuario. Se utiliza para crear conexiones a través de la consola de AWS Glue.
- Los usuarios aún pueden optar por crear su propia aplicación conectada en QuickBooks y proporcionar su propio ID y secreto de cliente al crear conexiones a través de la consola de AWS Glue. En este escenario, aún se abrirá QuickBooks para iniciar sesión y autorizar a AWS Glue para que acceda a sus recursos.
- Este tipo de concesión da como resultado un token de actualización y un token de acceso. El token de acceso es de corta duración y se puede actualizar automáticamente sin la interacción del usuario mediante el token de actualización.
- Para consultar la documentación pública de QuickBooks sobre la creación de una aplicación conectada para el flujo Authorization Code OAuth, consulte Configuración de OAuth 2.0.

Para configurar una conexión a QuickBooks:

1. En AWS Glue Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:
   a. Al seleccionar un Tipo de conexión, elija QuickBooks.
   b. Proporcione la URL de instancia y el ID de la empresa de la instancia QuickBooks a la que se desea conectar.
   c. Seleccione el rol de AWS IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

      JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
```

```
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

d. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.

e. Seleccione las opciones de red si quiere usar su red.

2. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.

Cómo leer a partir de entidades de QuickBooks

Requisito previo

Un objeto de QuickBooks desde el que desea leer.

Entidades compatibles como origen:

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Cuenta	Sí	Sí	Sí	Sí	Sí
Factura	Sí	Sí	Sí	Sí	Sí
Información de la empresa	No	No	No	Sí	No
Cliente	Sí	Sí	Sí	Sí	Sí
Empleado	Sí	Sí	Sí	Sí	Sí
Estimación	Sí	Sí	Sí	Sí	Sí

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Factura	Sí	Sí	Sí	Sí	Sí
Elemento	Sí	Sí	Sí	Sí	Sí
Pago	Sí	Sí	Sí	Sí	Sí
Preferencias	No	No	No	Sí	No
Pérdidas y ganancias	Sí	No	No	Sí	No
Agencia fiscal	Sí	Sí	Sí	Sí	Sí
Proveedores	Sí	Sí	Sí	Sí	Sí

Ejemplo:

```
QuickBooks_read = glueContext.create_dynamic_frame.from_options(
    connection_type="quickbooks",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "Account",
        "API_VERSION": "v3"
    }
```

Detalles de entidades y campos de QuickBooks:

Para obtener más información acerca de las entidades y los detalles de los campos, consulte:

- Cuenta
- Factura
- CompanyInfo
- Cliente
- Empleado
- Estimación

- Factura
- Elemento
- Pago
- Preferencias
- ProfitAndLoss
- TaxAgency
- Vendor

Consultas de partición

Partición basada en campos:

En QuickBooks, los campos de tipo de datos Integer y DateTime admiten la partición basada en campos.

Puede proporcionar las opciones adicionales de Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` y `NUM_PARTITIONS` si quiere utilizar la simultaneidad en Spark. Con estos parámetros, la consulta original se dividiría en un número `NUM_PARTITIONS` de subconsultas que las tareas de Spark pueden ejecutar simultáneamente.

- `PARTITION_FIELD`: el nombre del campo que se utilizará para particionar la consulta.
- `LOWER_BOUND`: un valor de límite inferior inclusivo del campo de partición elegido.

  En el campo Datetime, aceptamos el formato de marca de tiempo de Spark que se utiliza en las consultas SQL de Spark.

  Ejemplos de valor válido:

  ```
  "2024-05-07T02:03:00.00Z"
  ```
- `UPPER_BOUND`: un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`: el número de particiones.

Ejemplo:

```
QuickBooks_read = glueContext.create_dynamic_frame.from_options(
    connection_type="quickbooks",
```

```
    connection_options={
        "connectionName": "connectionName",
        "REALMID": "12345678690123456789",
        "ENTITY_NAME": "Account",
        "API_VERSION": "v3",
        "PARTITION_FIELD": "MetaData_CreateTime"
        "LOWER_BOUND": "2023-09-07T02:03:00.000Z"
        "UPPER_BOUND": "2024-05-07T02:03:00.000Z"
        "NUM_PARTITIONS": "10"
    }
```

Partición basada en registros:

La consulta original se divide en un número `NUM_PARTITIONS` de subconsultas que se pueden ejecutar por tareas Spark de forma simultánea:

- `NUM_PARTITIONS`: el número de particiones.

Ejemplo:

```
QuickBooks_read = glueContext.create_dynamic_frame.from_options(
    connection_type="quickbooks",
    connection_options={
        "connectionName": "connectionName",
        "REALMID": "1234567890123456789",
        "ENTITY_NAME": "Bill",
        "API_VERSION": "v3",
        "NUM_PARTITIONS": "10"
    }
```

Opciones de conexión a QuickBooks

Las siguientes son opciones de conexión para QuickBooks:

- `ENTITY_NAME`(cadena): (obligatorio) se usa para lectura. El nombre del objeto en QuickBooks.
- `INSTANCE_URL`(Cadena): (obligatorio) una URL de instancia de QuickBooks válida.
- `API_VERSION`(cadena): (obligatorio) se usa para lectura. Versión de la API de REST de QuickBooks que desea usar.
- `REALM_ID`(Cadena): un identificador que identifica a una empresa individual de QuickBooks Online a la que se envían las solicitudes.

- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.
- `PARTITION_FIELD`(cadena): se usa para leer. Campo que se utilizará para particionar la consulta.
- `LOWER_BOUND`(cadena): se usa para leer. Un valor de límite inferior inclusivo del campo de partición elegido.
- `UPPER_BOUND`(cadena): se usa para leer. Un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`(entero): predeterminado: 1. Se usa para leer. Número de particiones para leer.

Limitaciones y notas del conector de QuickBooks

Las siguientes son limitaciones o notas para el conector de QuickBooks:

- En la API de `taxAgency`, el orden por filtrado no funciona como se esperaba.

Conexión a Salesforce

Salesforce proporciona un software de administración de relaciones con los clientes (CRM) que le ayuda con las ventas, el servicio al cliente, el comercio electrónico y mucho más. Si es usuario de Salesforce, puede conectar AWS Glue a su cuenta de Salesforce. A continuación, puede utilizar Salesforce como origen o destino de datos en sus trabajos de ETL. Ejecute estos trabajos para transferir datos entre Salesforce y los servicios de AWS u otras aplicaciones compatibles.

Temas

- Compatibilidad de AWS Glue con Salesforce
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de Salesforce
- Aplicar el perfil Administrador del sistema
- Configuración de conexiones de Salesforce
- Lectura desde Salesforce
- Escritura en Salesforce

- Opciones de conexión de Salesforce
- Limitaciones del conector de Salesforce
- Configuración del flujo de códigos de autorización de Salesforce
- Configuración del flujo OAuth del portador JWT para Salesforce

Compatibilidad de AWS Glue con Salesforce

AWS Glue admite Salesforce de la siguiente manera:

¿Es compatible como origen?

Sí. Puede utilizar los trabajos de ETL de AWS Glue para consultar datos de Salesforce.

¿Es compatible como destino?

Sí. Puede usar los trabajos de ETL de AWS Glue para escribir registros en Salesforce.

Versiones compatibles de la API de Salesforce

Las siguientes versiones de la API de Salesforce son compatibles

- v58.0
- v59.0
- v60.0

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de la política de IAM se describen los permisos necesarios para crear, administrar y utilizar conexiones de Salesforce con los trabajos de ETL de AWS Glue. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
```

```
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

También puede usar las siguientes políticas de IAM para permitir el acceso:

- AWSGlueServiceRole: da acceso a recursos que precisan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: otorga acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la Consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Si se proporcionan opciones de red al crear una conexión de Salesforce, también debe incluir las siguientes acciones en el rol de IAM:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
```

```
      "Effect": "Allow",
      "Action": [
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

Para las conexiones de Salesforce sin ETL, consulte los requisitos previos de ETL cero.

Para las conexiones de Salesforce sin ETL, consulte los requisitos previos de ETL cero.

Configuración de Salesforce

Antes de poder utilizar AWS Glue para transferir datos hacia o desde Salesforce, debe cumplir estos requisitos:

Requisitos mínimos

Los requisitos mínimos son los siguientes:

- Debe tener una cuenta de Salesforce.
- Su cuenta de Salesforce está habilitada para el acceso a la API. El acceso a la API está habilitado de forma predeterminada para las ediciones Enterprise, Unlimited, Developer y Performance.

Si cumple estos requisitos, lo tiene todo listo para conectar AWS Glue a su cuenta de Salesforce. AWS Glue administra los requisitos restantes con la aplicación conectada administrada por AWS.

La aplicación conectada administrada por AWS para Salesforce

La aplicación conectada administrada por AWS le permite crear conexiones de Salesforce en menos pasos. En Salesforce, una aplicación conectada es un marco que autoriza a aplicaciones externas, como AWS Glue, a acceder a sus datos de Salesforce mediante OAuth 2.0. Para usar la aplicación conectada administrada por AWS, cree una conexión de Salesforce mediante la consola de AWS Glue. Al configurar la conexión, defina el Tipo de concesión OAuth en Código de autorización y deje seleccionada la casilla Utilizar la aplicación de cliente administrada por AWS.

Al guardar la conexión, se le redirigirá a Salesforce para iniciar sesión y aprobar el acceso de AWS Glue a su cuenta de Salesforce.

Aplicar el perfil Administrador del sistema

En Salesforce, siga los pasos para aplicar el perfil de administrador del sistema:

1. En Salesforce, vaya a Configuración > Aplicaciones conectadas > Uso de OAuth de aplicaciones conectadas.
2. En la lista de aplicaciones conectadas, busque AWS Glue y seleccione Instalar. Si es necesario, seleccione Desbloquear.
3. Vaya aConfiguración > Administrar aplicaciones conectadas y seleccione AWS Glue.
   En Políticas de OAuth, seleccione Los usuarios aprobados por el administrador están preautorizados y seleccione el perfil Administrador del sistema. Esta acción restringe el acceso a AWS Glue únicamente a los usuarios con el perfil Administrador del sistema.

Aplicar el perfil Administrador del sistema

En Salesforce, siga los pasos para aplicar el perfil de administrador del sistema:

1. En Salesforce, vaya a Configuración > Aplicaciones conectadas > Uso de OAuth de aplicaciones conectadas.
2. En la lista de aplicaciones conectadas, busque AWS Glue y seleccione Instalar. Si es necesario, seleccione Desbloquear.
3. Vaya aConfiguración > Administrar aplicaciones conectadas y seleccione AWS Glue.
   En Políticas de OAuth, seleccione Los usuarios aprobados por el administrador están preautorizados y seleccione el perfil Administrador del sistema. Esta acción restringe el acceso a AWS Glue únicamente a los usuarios con el perfil Administrador del sistema.

Configuración de conexiones de Salesforce

Para configurar una conexión de Salesforce:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles:
   a. Para el tipo de concesión JWT_TOKEN, el secreto debe contener la clave JWT_TOKEN con su valor.
   b. Para el tipo de concesión AuthorizationCode:

i. En el caso de una aplicación conectada administrada de AWS, es necesario proporcionar un secreto vacío o un secreto con algún valor temporal.

ii. En el caso de una aplicación conectada administrada por el cliente, el secreto debe contener la aplicación conectada de `Consumer Secret` con `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET` como la clave.

c. Nota: Debe crear un secreto para su conexión en AWS Glue.

2. En AWS Glue Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:

a. Al seleccionar un Tipo de conexión, seleccione Salesforce.

b. Proporcione el valor INSTANCE_URL de la instancia de Salesforce a la que desea conectarse.

c. Proporcione el entorno de Salesforce.

d. Seleccione el rol de AWS IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

e. Seleccione el tipo de concesión de OAuth2 que desee utilizar para las conexiones. El tipo de concesión determina cómo se comunica AWS Glue con Salesforce para solicitar el acceso a sus datos. Su elección afecta a los requisitos que debe cumplir antes de crear la conexión. Puede elegir uno de estos tipos:

- Tipo de concesión JWT_BEARER: este tipo de concesión funciona bien en escenarios de automatización, ya que permite crear un token web JSON (JWT) por adelantado con los permisos de un usuario concreto en la instancia de Salesforce. El creador tiene el control sobre el tiempo de validez del JWT. AWS Glue puede usar el JWT para obtener un token de acceso que se utiliza para llamar a las API de Salesforce.

  Este flujo requiere que el usuario haya creado una aplicación conectada en su instancia de Salesforce que permita emitir tokens de acceso basados en JWT para los usuarios.

  Para obtener información sobre cómo crear una aplicación conectada para el flujo OAuth del portador de JWT, consulte OAuth 2.0 JWT bearer flow for server-to-server integration. Para configurar el flujo portador de JWT con la aplicación conectada a Salesforce, consulte Configuración del flujo OAuth del portador JWT para Salesforce.
- Tipo de concesión AUTHORIZATION_CODE: este tipo de concesión se considera un OAuth "de tres vías", ya que se basa en redirigir a los usuarios al servidor de autorización externo para autenticar al usuario. Se utiliza para crear conexiones a través de la consola. Se utiliza para crear conexiones a través de la consola de AWS Glue. El usuario que crea una conexión puede utilizar de forma predeterminada una aplicación conectada de AWS Glue (aplicación de AWS Glue administrada por el cliente), en la que no necesita proporcionar ninguna información relacionada con OAuth, excepto la URL de su instancia de Salesforce. La consola de AWS Glue redirigirá al usuario a Salesforce, donde deberá iniciar sesión y permitir a AWS Glue que los permisos solicitados accedan a su instancia de Salesforce.

  Los usuarios aún pueden optar por crear su propia aplicación conectada en Salesforce y proporcionar su propio ID y secreto de cliente al crear conexiones a través de la consola de AWS Glue. En este escenario, se les continuará redirigiendo a Salesforce para iniciar sesión y autorizar a AWS Glue para que acceda a sus recursos.

  Este tipo de concesión da como resultado un token de actualización y un token de acceso. El token de acceso es de corta duración y se puede actualizar automáticamente sin la interacción del usuario mediante el token de actualización.

  Para obtener más información sobre cómo crear una aplicación conectada para el flujo de OAuth con código de autorización, consulte the section called "Configuración del flujo de códigos de autorización de Salesforce".

f. Seleccione el elemento `secretName` que desee usar para esta conexión en AWS Glue para guardar los tokens de OAuth 2.0.

g. Seleccione las opciones de red si quiere usar su red.

3. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.
4. Si proporciona opciones de red, conceda también al rol de IAM los siguientes permisos:

   JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

Configuración de conexiones de Salesforce con la CLI de AWS

Puede crear conexiones de Salesforce mediante la CLI de AWS:

```
aws glue create-connection --connection-input \
"{\"Name\": \"salesforce-conn1\",\"ConnectionType\": \"SALESFORCE\",
\"ConnectionProperties\": {\"ROLE_ARN\": \"arn:aws:iam::123456789012:role/glue-role\",
\"INSTANCE_URL\": \"https://example.my.salesforce.com\"},\"ValidateCredentials\": true,
\"AuthenticationConfiguration\": {\"AuthenticationType\": \"OAUTH2\",\"SecretArn\":
 \"arn:aws:secretsmanager:us-east-1:123456789012:secret:salesforce-conn1-secret-IAmcdk
\",\"OAuth2Properties\": {\"OAuth2GrantType\": \"JWT_BEARER\",\"TokenUrl\": \"https://
login.salesforce.com/services/oauth2/token\"}}}" \
--endpoint-url https://glue.us-east-1.amazonaws.com \
--region us-east-1
```

Lectura desde Salesforce

Requisito previo

Un objeto de Salesforce del que le gustaría leer. Necesitará el nombre del objeto, como `Account`, `Case` o `Opportunity`.

Ejemplo:

```
salesforce_read = glueContext.create_dynamic_frame.from_options(
    connection_type="salesforce",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "Account",
        "API_VERSION": "v60.0"
    }
)
```

Consultas de particionamiento

Puede proporcionar las opciones adicionales de Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` y `NUM_PARTITIONS` si quiere utilizar la simultaneidad en Spark. Con estos parámetros, la consulta original se dividiría en un número `NUM_PARTITIONS` de subconsultas que las tareas de Spark pueden ejecutar simultáneamente.

- `PARTITION_FIELD`: el nombre del campo que se utilizará para particionar la consulta.
- `LOWER_BOUND`: un valor de límite inferior inclusivo del campo de partición elegido.

  Para los campos Marca de tiempo o Fecha, el conector acepta el formato de marca de tiempo de Spark que se usa en las consultas de Spark SQL.

  Ejemplos de valores válidos:

  ```
  "TIMESTAMP \"1707256978123\""
  "TIMESTAMP '2018-01-01 00:00:00.000 UTC'"
  "TIMESTAMP \"2018-01-01 00:00:00 Pacific/Tahiti\""
  "TIMESTAMP \"2018-01-01 00:00:00\""
  "TIMESTAMP \"-123456789\" Pacific/Tahiti"
  "TIMESTAMP \"1702600882\""
  ```

- `UPPER_BOUND`: un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`: el número de particiones.
- `TRANSFER_MODE`: admite dos modos: `SYNC` y `ASYNC`. El valor predeterminado es `SYNC`. Cuando se establece en `ASYNC`, se utilizará Bulk API 2.0 Query para el procesamiento.

Ejemplo:

```
salesforce_read = glueContext.create_dynamic_frame.from_options(
    connection_type="salesforce",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "Account",
        "API_VERSION": "v60.0",
        "PARTITION_FIELD": "SystemModstamp",
        "LOWER_BOUND": "TIMESTAMP '2021-01-01 00:00:00 Pacific/Tahiti'",
        "UPPER_BOUND": "TIMESTAMP '2023-01-10 00:00:00 Pacific/Tahiti'",
        "NUM_PARTITIONS": "10",
        "TRANSFER_MODE": "ASYNC"
    }
)
```

Opción FILTER_PREDICATE

FILTER_PREDICATE: es un parámetro opcional. Esta opción se utiliza para el filtro de consultas.

Ejemplos de FILTER_PREDICATE:

```
     Case 1: FILTER_PREDICATE with single criterion
     Examples:
       LastModifiedDate >= TIMESTAMP '2025-04-01 00:00:00 Pacific/Tahiti'
       LastModifiedDate <= TIMESTAMP "2025-04-01 00:00:00"
       LastModifiedDate >= TIMESTAMP '2018-01-01 00:00:00.000 UTC'
       LastModifiedDate <= TIMESTAMP "-123456789 Pacific/Tahiti"
       LastModifiedDate <= TIMESTAMP "1702600882"

     Case 2: FILTER_PREDICATE with multiple criteria
     Examples:
       LastModifiedDate >= TIMESTAMP '2025-04-01 00:00:00 Pacific/Tahiti' AND Id =
 "0012w00001CotGiAAJ"
       LastModifiedDate >= TIMESTAMP "1702600882" AND Id = "001gL000002i26MQAQ"

     Case 3: FILTER_PREDICATE single criterion with LIMIT
     Examples:
       LastModifiedDate >= TIMESTAMP "1702600882" LIMIT 2

     Case 4: FILTER_PREDICATE with LIMIT
     Examples:
       LIMIT 2
```

Escritura en Salesforce

Requisitos previos

Un objeto de Salesforce en el que le gustaría escribir. Necesitará el nombre del objeto, como `Account`, `Case` o `Opportunity`.

El conector de Salesforce admite cuatro operaciones de escritura:

- INSERT
- UPSERT
- UPDATE
- DELETE

Al utilizar la operación de escritura `UPSERT`, debe proporcionar la opción `ID_FIELD_NAMES` para especificar el campo de ID externo de los registros.

También se pueden agregar opciones de conexión:

- `TRANSFER_MODE`: admite dos modos: `SYNC` y `ASYNC`. El valor predeterminado es `SYNC`. Cuando se establece en `ASYNC`, se utilizará Bulk API 2.0 Ingest para el procesamiento.
- `FAIL_ON_FIRST_ERROR`: el valor predeterminado es `FALSE`, lo que significa que el trabajo de AWS Glue continuará procesando todos los datos incluso si hay algunos registros de escritura con error. Cuando se establece en `TRUE`, el trabajo de AWS Glue presentará fallas si hay algún registro de escritura con error y no continuará el procesamiento.

Ejemplo

```
salesforce_write = glueContext.write_dynamic_frame.from_options(
    frame=frameToWrite,
    connection_type="salesforce",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "Account",
        "API_VERSION": "v60.0",
        "WRITE_OPERATION": "INSERT",
        "TRANSFER_MODE": "ASYNC",
        "FAIL_ON_FIRST_ERROR": "true"
    }
```

```
)
```

Opciones de conexión de Salesforce

A continuación, encontrará las opciones de conexión que se admiten en el conector de Salesforce:

- `ENTITY_NAME`(cadena): (obligatorio) se utiliza para leer y escribir. El nombre de su objeto en Salesforce.
- `API_VERSION`(cadena): (obligatorio) se utiliza para leer y escribir. Versión de la API de REST de Salesforce que desea utilizar.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.

  Al proporcionar un predicado de filtro, solo el operador `AND` es compatible. Otros operadores, como `OR` y `IN` no son compatibles actualmente.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.
- `PARTITION_FIELD`(cadena): se usa para leer. Campo que se utilizará para particionar la consulta.
- `LOWER_BOUND`(cadena): se usa para leer. Un valor de límite inferior inclusivo del campo de partición elegido.
- `UPPER_BOUND`(cadena): se usa para leer. Un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`(entero): predeterminado: 1. Se usa para leer. Número de particiones para leer.
- `IMPORT_DELETED_RECORDS`(cadena): predeterminado: FALSO. Se usa para leer. Para obtener los registros eliminados durante la consulta.
- `WRITE_OPERATION`(cadena): predeterminado: INSERT. Se utiliza para escribir. El valor debe ser INSERT, UPDATE, UPSERT, DELETE.
- `ID_FIELD_NAMES`(cadena): predeterminado: nulo. Necesario para UPDATE y UPSERT.

Limitaciones del conector de Salesforce

Las siguientes son limitaciones para el conector de Salesforce:

- Solo admitimos Spark SQL; Salesforce SOQL no es compatible.

- No se admiten los marcadores de trabajo.
- Todos los nombres de campo de Salesforce distinguen entre mayúsculas y minúsculas. Al escribir en Salesforce, los datos deben coincidir con las mayúsculas y minúsculas de los campos definidos en Salesforce.

Configuración del flujo de códigos de autorización de Salesforce

Consulte la documentación pública de Salesforce para habilitar el flujo de códigos de autorización de OAuth 2.0.

Para configurar la aplicación conectada:

1. Active la casilla Habilitar la configuración de OAuth.
2. En el campo de texto URL de devolución de llamada, introduzca una o más URL de redireccionamiento para AWS Glue.

   Las URL de redireccionamiento tienen el formato siguiente:

   https://*region*.console.aws.amazon.com/gluestudio/oauth

   En esta URL, la región es el código de la región AWS en la que se utiliza AWS Glue para transferir datos desde Salesforce. Por ejemplo, el código de la región del Este de EE. UU. (Norte de Virginia) es `us-east-1`. Para esa región, la URL es la siguiente:

   https://us-east-1.console.aws.amazon.com/gluestudio/oauth

   Para las regiones de AWS que admite AWS Glue, consulte Cuotas y puntos de conexión de AWS Glue en la Referencia general de AWS.
3. Active la casilla Solicitar secreto para el flujo del servidor web.
4. En la lista Ámbitos de OAuth disponibles, añada los siguientes ámbitos:
   - Administración de los datos de los usuarios a través de las API (api)
   - Acceso a permisos personalizados (custom_permissions)
   - Acceso al servicio de URL de identidad (ID, perfil, correo electrónico, dirección, teléfono)
   - Acceso a los identificadores de usuario únicos (openid)
   - Realización de solicitudes en cualquier momento (refresh_token, offline_access)
5. Establezca la política de token de actualización para la aplicación conectada, de forma que el token de actualización sea válido hasta que se revoque. De lo contrario, los trabajos devolverán

un error cuando el token de actualización caduque. Para obtener más información sobre cómo comprobar y editar la política de token de actualización, consulte Manage OAuth Access Policies for a Connected App en la documentación de Salesforce.

Configuración del flujo OAuth del portador JWT para Salesforce

Consulte la documentación pública de Salesforce para activar la integración de servidor a servidor con los Tokens web JSON de OAuth 2.0.

Una vez que haya creado un JWT y configurado la aplicación conectada de forma adecuada en Salesforce, podrá crear una nueva conexión de Salesforce con la clave `JWT_TOKEN` establecida en el Secreto de Secrets Manager. Establezca el tipo de concesión de OAuth en Token del portador de JWT al crear la conexión.

Conexión a Salesforce Marketing Cloud

Salesforce Marketing Cloud es un proveedor de software de automatización y análisis de marketing para marketing por correo electrónico, teléfono móvil, redes sociales y en línea. También ofrece servicios de consultoría e implementación. Como usuario de Salesforce Marketing Cloud, puede conectar AWS Glue a su cuenta de Salesforce Marketing Cloud. A continuación, puede utilizar Salesforce Marketing Cloud como un destino u origen de datos en sus trabajos de ETL. Ejecute estos trabajos para transferir datos entre Salesforce Marketing Cloud y los servicios de AWS u otras aplicaciones compatibles.

Temas

- Compatibilidad de AWS Glue con Salesforce Marketing Cloud
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de Salesforce Marketing Cloud
- Configuración de las conexiones de Salesforce Marketing Cloud
- Lectura de entidades de Salesforce Marketing Cloud
- Escritura en entidades de Salesforce Marketing Cloud
- Opciones de conexión de Salesforce Marketing Cloud
- Limitaciones y notas del conector de Salesforce Marketing Cloud

Compatibilidad de AWS Glue con Salesforce Marketing Cloud

AWS Glue es compatible con Salesforce Marketing Cloud de la siguiente manera:

¿Es compatible como origen?

Sí. Puede utilizar los trabajos de ETL de AWS Glue para consultar datos de Salesforce Marketing Cloud.

¿Es compatible como destino?

No.

Versiones de la API de Salesforce Marketing Cloud

Son compatibles las siguientes versiones de la API de Salesforce Marketing Cloud:

- v1

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS IAM necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si no desea utilizar el método anterior, puede utilizar las siguientes políticas de IAM administradas:

- AWSGlueServiceRole: da acceso a recursos que precisan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: otorga acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la Consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de Salesforce Marketing Cloud

Antes de poder utilizar AWS Glue para transferir datos desde Salesforce Marketing Cloud, debe cumplir estos requisitos:

Requisitos mínimos

Los requisitos mínimos son los siguientes:

- Debe tener una cuenta de Salesforce Marketing Cloud. Para obtener más información, consulte Creación de una cuenta de Salesforce Marketing Cloud.
- Su cuenta de Salesforce Marketing Cloud debe estar habilitada para el acceso a la API. El acceso a la API está habilitado de forma predeterminada para las ediciones Enterprise, Unlimited, Developer y Performance.

Si cumple estos requisitos, tendrá todo listo para conectar AWS Glue a su cuenta de Salesforce Marketing Cloud. Para las conexiones típicas, no es necesario que haga nada más en Salesforce Marketing Cloud.

Creación de una cuenta de Salesforce Marketing Cloud

En el caso de Salesforce Marketing Cloud, debe contactar con el proveedor para crear la cuenta. Si usted o su empresa tienen una asociación con Salesforce, contacte con el administrador de cuentas

de Salesforce para solicitar una licencia de Salesforce Marketing Cloud. De lo contrario, puede solicitar el contacto de un representante de Salesforce de la siguiente manera:

1. Vaya a https://www.salesforce.com/in/products/marketing-cloud/overview/ y elija Registrarse.
2. Seleccione el enlace Contacto en la parte superior derecha de la página.
3. Ingrese la información necesaria en el formulario y elija Continuar.

Un representante de Salesforce se pondrá en contacto con usted para hablar sobre sus requisitos.

Creación de un proyecto y credenciales de OAuth 2.0

Obtención de un proyecto y las credenciales de OAuth 2.0:

1. Inicie sesión en la instancia de Salesforce Marketing Cloud con su nombre de usuario y contraseña y autentíquese con su número de teléfono móvil registrado.
2. Haga clic en su perfil en la esquina superior derecha y, a continuación, vaya a Configuración.
3. En Herramientas de plataforma, elija Aplicaciones y, a continuación, elija Paquetes instalados.

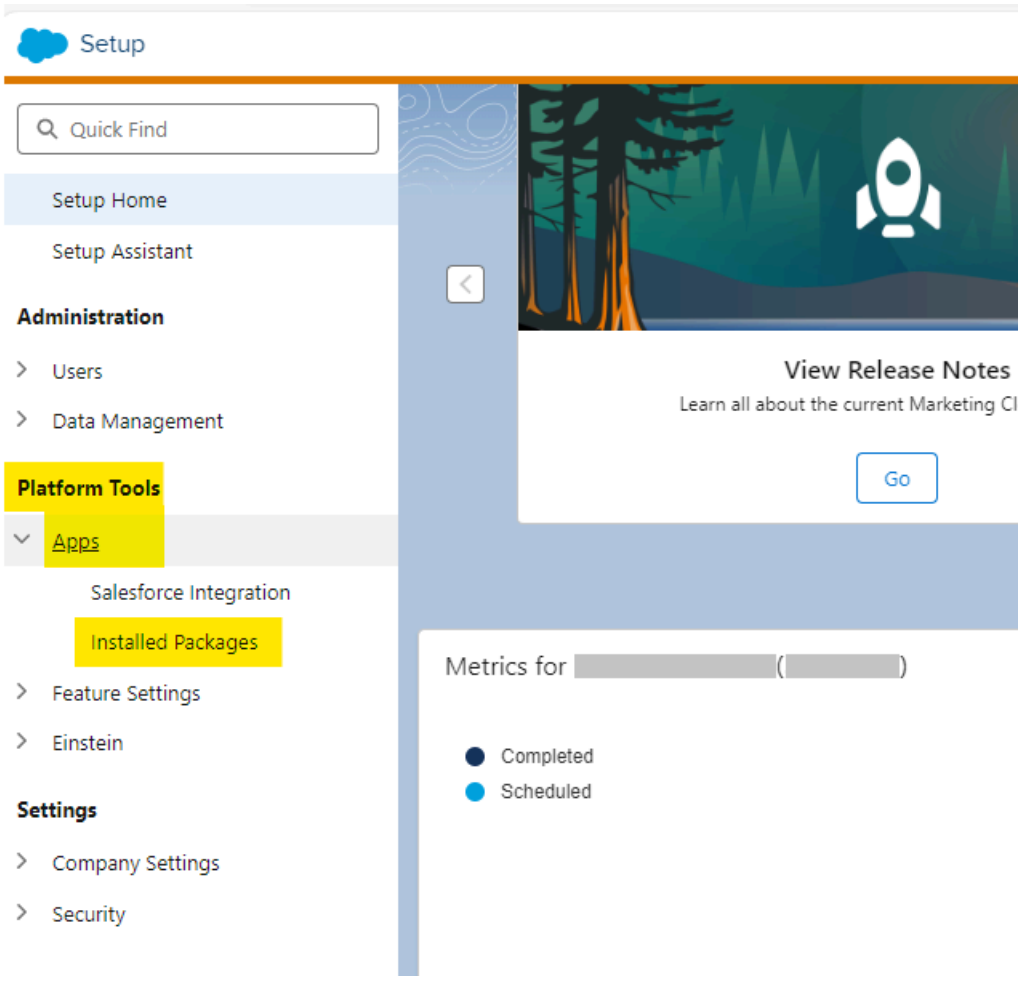

4. En la página Paquetes instalados, haga clic en Nuevo en la esquina superior derecha. Proporcione el nombre y la descripción del paquete.

   Guarde el paquete. Una vez guardado, podrá ver los detalles del paquete.

5. En la página Detalles del paquete, en la sección Componente, elija Agregar componente.

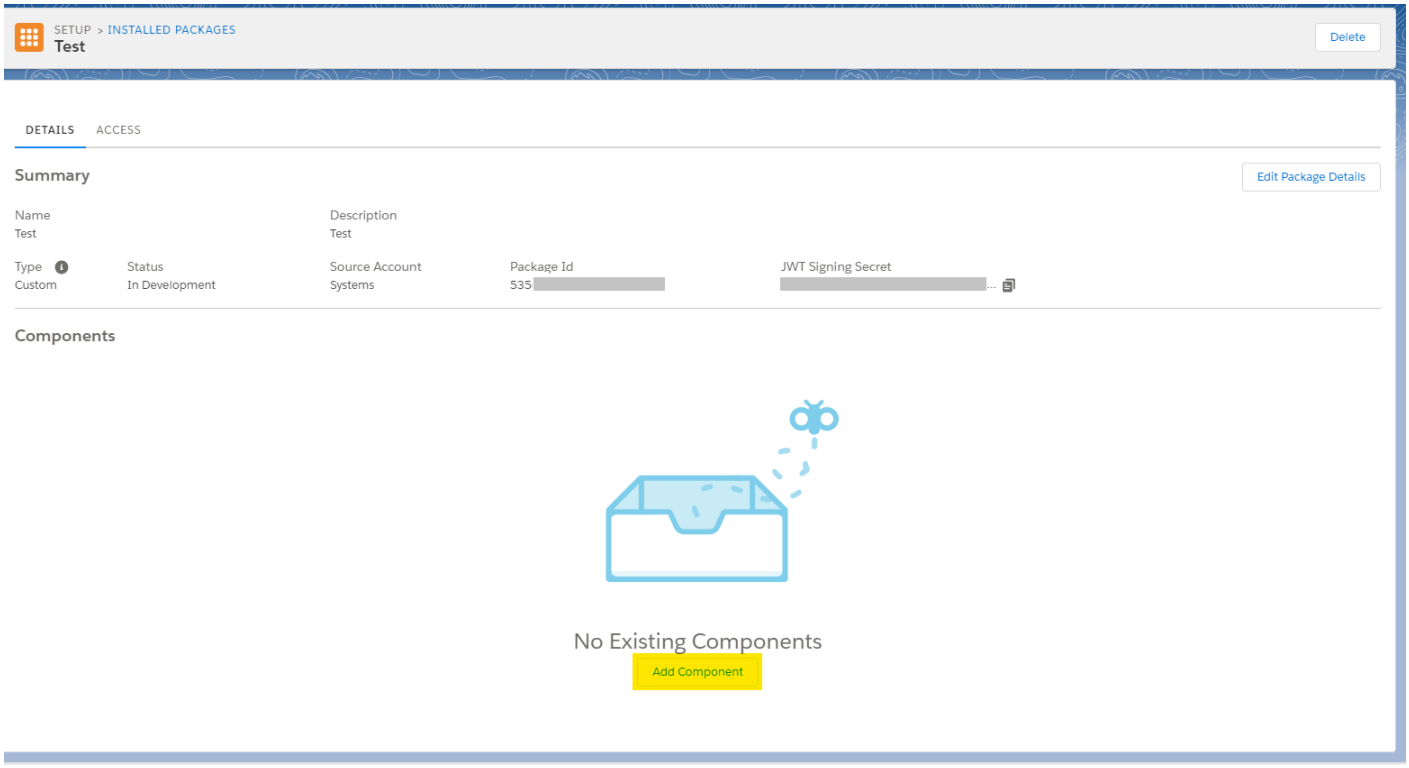

6. Seleccione el Tipo de componente como “Integración de API” y haga clic en Siguiente.
7. Seleccione el Tipo de integración como “Servidor a servidor” (que tiene las credenciales de cliente del tipo otorgado por OAuth) y haga clic en Siguiente.
8. Agregue los ámbitos en función de sus requisitos y haga clic en Guardar.

Configuración de las conexiones de Salesforce Marketing Cloud

Salesforce Marketing Cloud admite el tipo de concesión CREDENCIALES DEL CLIENTE para OAuth2.

- Este tipo de concesión se considera OAuth 2.0 de doble vía, ya que los clientes lo utilizan para obtener un token de acceso fuera del contexto de un usuario. AWS Glue puede utilizar el ID de cliente y el secreto de cliente para autenticar las API de Salesforce Marketing Cloud que los servicios personalizados que defina proporcionen.
- Cada servicio personalizado pertenece a un usuario exclusivo de la API con un conjunto de roles y permisos que autorizan al servicio a realizar acciones específicas. Un token de acceso está asociado a un único servicio personalizado.
- Este tipo de concesión da lugar a un token de acceso de corta duración, que se puede renovar mediante una llamada a un punto de conexión de identidad.

- Para consultar la documentación pública de Salesforce Marketing Cloud para OAuth 2.0 con credenciales de cliente, consulte Configuración del entorno de desarrollo para paquetes mejorados.

Para configurar una conexión de Salesforce Marketing Cloud:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles:
   a. En el caso de las aplicaciones conectadas administradas por el cliente, el secreto debe contener el secreto del consumidor de la aplicación conectada con `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET` como clave.
   b. Nota: Debe crear un secreto para las conexiones en AWS Glue.
2. En AWS Glue Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:
   a. Al seleccionar un Tipo de conexión, elija Salesforce Marketing Cloud.
   b. Proporcione el `Subdomain Endpoint` de Salesforce Marketing Cloud al que se desea conectar.
   c. Seleccione el rol de AWS IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

      JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

d. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.

e. Seleccione las opciones de red si quiere usar su red.

3. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.

Lectura de entidades de Salesforce Marketing Cloud

Requisito previo

Un objeto de Salesforce Marketing Cloud desde el cual le gustaría leer. Necesitará el nombre del objeto, como `Activity` o `Campaigns`. En la siguiente tabla se muestran las entidades admitidas.

Entidades compatibles como origen:

Entidad	Interfaz	Se puede filtrar	Admite límite	Admite Ordenar por	Admite SELECCIONAR *	Admite partición
Devolución de llamadas para notificaciones de eventos	REST	No	No	No	Sí	No
Lista de semillas	REST	No	Sí	No	Sí	No
Configuración	REST	Sí	Sí	No	Sí	No
Verificación de dominio	REST	Sí	Sí	Sí	Sí	No

Entidad	Interfaz	Se puede filtrar	Admite límite	Admite Ordenar por	Admite SELECCIONAR *	Admite partición
Etiquetas anidadas de objetos	REST	Sí	No	No	Sí	No
Contacto	REST	No	Sí	No	Sí	No
Suscripción a notificaciones de eventos	REST	No	No	No	Sí	No
Mensajería	REST	No	Sí	No	Sí	No
Actividad	SOAP	No	No	No	Sí	Sí
Evento de devolución	SOAP	No	No	No	Sí	Sí
Evento de clic	SOAP	No	No	No	Sí	Sí
Área de contenido	SOAP	No	No	No	Sí	Sí
Extensión de datos	SOAP	No	Sí	No	Sí	Sí
Correo electrónico	SOAP	No	Sí	No	Sí	Sí
Evento de correo electrónico reenviado	SOAP	No	Sí	No	Sí	Sí

Entidad	Interfaz	Se puede filtrar	Admite límite	Admite Ordenar por	Admite SELECCIONAR *	Admite partición
Evento de consentimiento de reenvío de correo electrónico	SOAP	No	Sí	No	Sí	Sí
Enlace	SOAP	No	Sí	No	Sí	Sí
Envío de enlace	SOAP	No	Sí	No	Sí	Sí
Enumeración	SOAP	No	Sí	No	Sí	Sí
Suscriptor de lista	SOAP	No	Sí	No	Sí	Sí
Evento de no envío	SOAP	No	Sí	No	Sí	Sí
Evento de apertura	SOAP	No	Sí	No	Sí	Sí
Send	SOAP	No	Sí	No	Sí	Sí
Evento de envío	SOAP	No	Sí	No	Sí	Sí
Suscriptor	SOAP	No	Sí	No	Sí	Sí
Evento de encuesta	SOAP	No	Sí	No	Sí	Sí

Entidad	Interfaz	Se puede filtrar	Admite límite	Admite Ordenar por	Admite SELECCIONAR *	Admite partición
Evento de subscripción anulada	SOAP	No	Sí	No	Sí	Sí
Eventos de auditoría	REST	No	Sí	Sí	Sí	No
Campañas	REST	No	Sí	Sí	Sí	No
Interacciones	REST	No	Sí	Sí	Sí	No
Activos de contenido	REST	No	Sí	Sí	Sí	No

Ejemplo de REST:

```
salesforcemarketingcloud_read = glueContext.create_dynamic_frame.from_options(
    connection_type="salesforcemarketingcloud",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "Campaigns",
        "API_VERSION": "v1",
        "INSTANCE_URL": "https://**********.rest.marketingcloudapis.com"
    }
)
```

Ejemplo de SOAP:

```
salesforcemarketingcloud_read = glueContext.create_dynamic_frame.from_options(
    connection_type="salesforcemarketingcloud",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "Activity",
        "API_VERSION": "v1",
```

```
        "INSTANCE_URL": "https://**********************.soap.marketingcloudapis.com"
    }
)
```

Detalles de la entidad y el campo de Salesforce Marketing Cloud:

Las siguientes tablas describen las entidades de Salesforce Marketing Cloud. Hay entidades REST con metadatos estáticos y entidades SOAP con metadatos dinámicos.

Entidades REST con metadatos estáticos:

Entidad	Campo	Tipo de datos:	Operadores admitidos
Devolución de llamadas para notificaciones de eventos	callbackId	Cadena	
	callbackName	Cadena	
	url	Cadena	
	maxBatchSize	Entero	
	status	Cadena	
	statusReason	Cadena	
Lista de semillas	id	Cadena	
	nombre	Cadena	
	Descripción	Cadena	
	activeSeedCount	Entero	
Configuración	customerKey	Cadena	
	nombre	Cadena	
	Descripción	Cadena	
	locationType	Cadena	'='

Entidad	Campo	Tipo de datos:	Operadores admitidos
	awsFileTransferLocation	Struct	
Verificación de dominio	enterpriseId	Entero	
	status	Cadena	'='
	domainType	Cadena	'='
	memberId	Entero	
	emailSendTime	DateTime	
	Dominio	Cadena	
	isSendable	Booleano	
Etiquetas anidadas de objetos	id	Entero	
	modifiedDate	DateTime	
	etiquetas	Enumeración	
	nombre	Cadena	
	Descripción	Cadena	
	parentId	Entero	
Contacto	valores	Enumeración	
Suscripción a notificaciones de eventos	subscriptionName	Cadena	
	callbackId	Cadena	
	callbackName	Cadena	
	eventCategoryTypes	Enumeración	
	filters	Enumeración	

Entidad	Campo	Tipo de datos:	Operadores admitidos
	url	Cadena	
	maxBatchSize	Entero	
	subscriptionId	Cadena	
	status	Cadena	
	statusReason	Cadena	
Mensajería	deliveryTime	DateTime	
	id	Cadena	
	messageId	Cadena	
	status	Cadena	
	a	Struct	
Interacciones	status	Cadena	'='
	id	Cadena	
	key	Cadena	
	nombre	Cadena	
	lastPublishedDate	DateTime	
	Descripción	Cadena	
	versión	Entero	
	workflowApiVersion	Entero	
	createdDate	DateTime	
	modifiedDate	DateTime	

Entidad	Campo	Tipo de datos:	Operadores admitidos
	goals	Struct	
	stats	Struct	
	entryMode	Cadena	
	defaults	Struct	
	executionMode	Struct	
	definitionId	Cadena	
Activos de contenido	id	Entero	
	customerKey	Cadena	
	objectId	Cadena	
	contentType	Cadena	
	assetType	Struct	
	nombre	Cadena	
	Descripción	Cadena	
	owner	Struct	
	createdDate	DateTime	
	createdBy	Struct	
	modifiedDate	DateTime	
	modifiedBy	Struct	
	miniatura	Struct	
	categoría	Struct	

Entidad	Campo	Tipo de datos:	Operadores admitidos
	meta	Struct	
	vistas	Struct	
	availableViews	Struct	
	data	Struct	
	legacyData	Struct	
	modelVersion	Entero	
	Versión	Entero	
	Locked (Bloqueado)	Booleano	
	FileProperties	Struct	
	Etiquetas	Enumeración	
	Contenidos	Cadena	
	Diseño	Cadena	
	SuperContent	Cadena	
	CustomFields	Struct	
	Bloques	Struct	
	MinBlocks	Entero	
	MaxBlocks	Entero	
	Canales	Struct	
	AllowedBlocks	Enumeración	
	Slots	Struct	

Entidad	Campo	Tipo de datos:	Operadores admitidos
	BusinessUnitAvailability	Struct	
	sharingProperties	Struct	
	sharingProperties.sharedWith	Struct	
	sharingProperties.sharingType	Cadena	
	Plantilla	Struct	
	Archivos	Cadena	
	GenerateFrom	Cadena	
Eventos de auditoría	id	Entero	
	createdDate	DateTime	
	memberId	Entero	
	enterpriseId	Entero	
	employee	Struct	
	objectType	Struct	
	operación	Struct	
	objeto	Struct	
	transactionId	Cadena	
Campañas	id	Entero	
	createdDate	DateTime	
	modifiedDate	DateTime	

Entidad	Campo	Tipo de datos:	Operadores admitidos
	nombre	Cadena	
	Descripción	Cadena	
	campaignCode	Cadena	
	color	Cadena	
	favorite	Booleano	

Entidades SOAP con metadatos dinámicos:

Entidad	Tipo de datos:	Operadores admitidos
Actividad	Cadena	LIKE,!=,=
	Struct	
	Entero	!=,=,>=,<=,<,>
	Doble	!=,=,>=,<=,<,>
	Booleano	!=,=
	DateTime	>=,<=,<,>,=,BETWEEN
Evento de devolución	Entero	!=,=,>=,<=,<,>
	DateTime	>=,<=,<,>,=,BETWEEN
	Cadena	LIKE,!=,=
	Struct	
Evento de clic	Entero	!=,=,>=,<=,<,>
	DateTime	>=,<=,<,>,=,BETWEEN

Entidad	Tipo de datos:	Operadores admitidos
	Cadena	LIKE,!=,=
	Struct	
Área de contenido	Struct	
	Cadena	LIKE,!=,=
	Entero	!=,=,>=,<=,<,>
	DateTime	>=,<=,<,>,=,BETWEEN
	Booleano	!=,=
Extensión de datos	DateTime	>=,<=,<,>,=,BETWEEN
	Cadena	LIKE,!=,=
Correo electrónico	Entero	!=,=,>=,<=,<,>
	Cadena	LIKE,!=,=
	DateTime	>=,<=,<,>,=,BETWEEN
	Booleano	!=,=
	Struct	
Evento de correo electrónico reenviado	Entero	!=,=,>=,<=,<,>
	Cadena	LIKE,!=,=
	DateTime	>=,<=,<,>,=,BETWEEN
	Struct	
Evento de consentimiento de correo electrónico reenviado	Entero	!=,=,>=,<=,<,>
	Cadena	LIKE,!=,=

Entidad	Tipo de datos:	Operadores admitidos
	DateTime	>=,<=,<,>,=,BETWEEN
	Struct	
Enlace	Entero	!=,=,>=,<=,<,>
Envío de enlace	Entero	!=,=,>=,<=,<,>
	Cadena	LIKE,!=,=
	Doble	!=,=,>=,<=,<,>
Enumeración	Entero	!=,=,>=,<=,<,>
	Cadena	LIKE,!=,=
	DateTime	>=,<=,<,>,=,BETWEEN
	Struct	
Suscriptor de lista	Entero	!=,=,>=,<=,<,>
	Cadena	LIKE,!=,=
	DateTime	>=,<=,<,>,=,BETWEEN
	Struct	
Evento de no envío	Entero	!=,=,>=,<=,<,>
	Cadena	LIKE,!=,=
	DateTime	>=,<=,<,>,=,BETWEEN
	Struct	
Evento de apertura	Entero	!=,=,>=,<=,<,>
	Cadena	LIKE,!=,=

Entidad	Tipo de datos:	Operadores admitidos
	DateTime	>=,<=,<,>,=,BETWEEN
	Struct	
Send	Entero	!=,=,>=,<=,<,>
	Cadena	LIKE,!=,=
	DateTime	>=,<=,<,>,=,BETWEEN
	Booleano	!=,=
	Struct	
Evento de envío	Entero	!=,=,>=,<=,<,>
	Cadena	LIKE,!=,=
	DateTime	>=,<=,<,>,=,BETWEEN
	Struct	
Suscriptor	Entero	!=,=,>=,<=,<,>
	Cadena	LIKE,!=,=
	DateTime	>=,<=,<,>,=,BETWEEN
	Struct	
Evento de encuesta	Entero	!=,=,>=,<=,<,>
	Cadena	LIKE,!=,=
	DateTime	>=,<=,<,>,=,BETWEEN
	Struct	
Evento de subscripción anulada	Entero	!=,=,>=,<=,<,>

Entidad	Tipo de datos:	Operadores admitidos
	Cadena	LIKE,!=,=
	DateTime	>=,<=,<,>,=,BETWEEN
	Booleano	!=,=
	Struct	

Consultas de partición

En Salesforce Marketing Cloud, los campos de tipo de datos Entero y Fecha y hora admiten la partición basada en campos.

Puede proporcionar las opciones adicionales de Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` y `NUM_PARTITIONS` si quiere utilizar la simultaneidad en Spark. Con estos parámetros, la consulta original se dividiría en un número `NUM_PARTITIONS` de subconsultas que las tareas de Spark pueden ejecutar simultáneamente.

- `PARTITION_FIELD`: el nombre del campo que se utilizará para particionar la consulta.
- `LOWER_BOUND`: un valor de límite inferior inclusivo del campo de partición elegido.

  Para el campo de marca de tiempo, aceptamos el formato de marca de tiempo de Spark que se usa en las consultas de Spark SQL.

  Ejemplos de valor válido:

  ```
  “2024-05-07T02:03:00.00Z"
  ```
- `UPPER_BOUND`: un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`: el número de particiones.

Ejemplo:

```
salesforcemarketingcloud_read = glueContext.create_dynamic_frame.from_options(
    connection_type="salesforcemarketingcloud",
    connection_options={
        "connectionName": "connectionName",
```

```
        "ENTITY_NAME": "ListSubscriber",
        "API_VERSION": "v1",
        "PARTITION_FIELD": "CreatedDate",
        "LOWER_BOUND": "2023-09-07T02:03:00.000Z",
        "UPPER_BOUND": "2024-05-07T02:03:00.000Z",
        "NUM_PARTITIONS": "10"
    }
)
```

Escritura en entidades de Salesforce Marketing Cloud

Requisitos previos

- Un objeto de Salesforce Marketing en el que desea escribir. Deberá especificar el nombre del objeto, por ejemplo, `List` o `Campaigns` o cualquiera de las demás entidades que se indican en la siguiente tabla.
- El conector de Salesforce Marketing Cloud admite tres operaciones de escritura:
  - INSERT
  - UPSERT
  - UPDATE

  Al utilizar las operaciones de escritura `UPDATE` y `UPSERT`, debe proporcionar la opción `ID_FIELD_NAMES` para especificar el campo de ID externo de los registros.

Entidades compatibles para el destino:

Entidad	Priority (Prioridad)	Interfaz (REST, SOAP, etc.)	Se puede insertar	Se puede actualizar	Se puede actualizar o insertar
Campañas	P0	REST	Sí	Sí: individual	N
Activos de contenido	P0	REST	Sí: individual, masivo	Sí: individual	N
Contacto	P1	REST	Sí	Sí: individual	N

Entidad	Priority (Prioridad)	Interfaz (REST, SOAP, etc.)	Se puede insertar	Se puede actualizar	Se puede actualizar o insertar
Verificación de dominio	P1	REST	Sí: individual	Sí: individual, masivo	N
Devolución de llamadas para notificaciones de eventos	P1	REST	Sí	Sí: individual	N
Suscripción a notificaciones de eventos	P1	REST	Sí	Sí: individual	N
Mensajería	P1	REST	Sí	N	N
Etiqueta anidada de objeto	P2	REST	Sí	Sí: individual	N
Lista de semillas	P1	REST	Sí	Sí: individual	N
Configuración	P1	REST	Sí	Sí: individual	N
Extensión de datos	P0	SOAP	Sí: individual	Sí: individual	Sí: individual
Correo electrónico	P0	SOAP	Sí: individual	Sí: individual	N
Enumeración	P0	SOAP	Sí: individual	Sí: individual	N
Send	P0	SOAP	Sí: individual	N	N
Suscriptor	P0	SOAP	Sí: individual	Sí: individual	N

Ejemplo de operación INSERT para REST:

```
salesforcemarketingcloud_write = glueContext.write_dynamic_frame.from_options(
    connection_type="salesforcemarketingcloud",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "Campaigns",
        "API_VERSION": "v1",
        "writeOperation" : "INSERT",
        "INSTANCE_URL": "https://**********.rest.marketingcloudapis.com"
    }
)
```

Ejemplo de operación INSERT para SOAP:

```
salesforcemarketingcloud_write = glueContext.write_dynamic_frame.from_options(
    connection_type="salesforcemarketingcloud",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "List",
        "API_VERSION": "v1",
        "writeOperation" : "INSERT",
        "INSTANCE_URL": "https://**********.rest.marketingcloudapis.com"
    }
)
```

Ejemplo de operación UPDATE para REST:

```
salesforcemarketingcloud_write = glueContext.write_dynamic_frame.from_options(
    connection_type="salesforcemarketingcloud",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "Campaigns",
        "API_VERSION": "v1",
        "writeOperation" : "UPDATE",
         "ID_FIELD_NAMES": "id",
        "INSTANCE_URL": "https://**********.rest.marketingcloudapis.com"
    }
)
```

Ejemplo de operación UPDATE para SOAP:

```
salesforcemarketingcloud_write = glueContext.write_dynamic_frame.from_options(
    connection_type="salesforcemarketingcloud",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "List",
        "API_VERSION": "v1",
        "writeOperation" : "UPDATE",
         "ID_FIELD_NAMES": "id",
        "INSTANCE_URL": "https://**********************.rest.marketingcloudapis.com"
    }
)
```

Ejemplo de operación UPSERT para SOAP:

```
salesforcemarketingcloud_write = glueContext.write_dynamic_frame.from_options(
    connection_type="salesforcemarketingcloud",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "DataExtension/Insert-***E/6*******3",
        "API_VERSION": "v1",
        "writeOperation" : "UPSERT",
        "INSTANCE_URL": "https://**********************.rest.marketingcloudapis.com"
    }
)
```

Opciones de conexión de Salesforce Marketing Cloud

Las siguientes son opciones de conexión para Salesforce Marketing Cloud:

- `ENTITY_NAME`(cadena): (obligatorio) se usa para lectura. El nombre del objeto en Salesforce Marketing Cloud.
- `API_VERSION`(cadena): (obligatorio) se usa para lectura. Versión de la API de SOAP y de Salesforce Marketing Cloud Rest que quiere utilizar.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.
- `PARTITION_FIELD`(cadena): se usa para leer. Campo que se utilizará para particionar la consulta.

- `LOWER_BOUND`(cadena): se usa para leer. Un valor de límite inferior inclusivo del campo de partición elegido.
- `UPPER_BOUND`(cadena): se usa para leer. Un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`(entero): predeterminado: 1. Se usa para leer. Número de particiones para leer.
- `WRITE_OPERATION`(cadena): predeterminado: INSERT. Se utiliza para escribir. El valor debe ser INSERT, UPDATE, UPSERT.
- `ID_FIELD_NAMES`(cadena): predeterminado: nulo. Necesario para UPDATE/UPSERT.

Limitaciones y notas del conector de Salesforce Marketing Cloud

Las siguientes son limitaciones o notas para el conector de Salesforce Marketing Cloud:

- Al utilizar el filtro en el campo de tipo de datos DateTime, debe pasar el valor en el formato «aaaa-mm-ddthh:mm:ssz».
- En la vista previa de datos, el valor booleano del tipo de datos aparece en blanco.
- Para las entidades SOAP, puede definir un máximo de dos filtros, y para las entidades REST, solo puede definir un filtro, lo que restringe las pruebas de particionamiento con filtros.
- Se han observado varios comportamientos inesperados desde el lado del SaaS: el campo `Link.Alias` de la entidad `linksend` no admite el operador CONTAINS (por ejemplo, `Link.Alias CONTAINS "ViewPrivacyPolicy"`) y los operadores de filtro para las entidades de extensión de datos (como EQUALS y GREATER THAN) no devuelven los resultados esperados.
- La API de SOAP ClickEvent de SFMC tarda en reflejar los registros recién creados, por lo que es posible que no estén disponibles de inmediato en la respuesta de la API.

  Ejemplo: si crea 5 registros nuevos de ClickEvent el 2025-01-10T a las 14:30:00 y los obtiene de inmediato mediante la API de SOAP, es posible que la respuesta no incluya los 5 registros. Es posible que pasen hasta 5 minutos antes de que los registros recién creados aparezcan en la respuesta de la API. Este retraso también puede afectar tanto a la recuperación de datos como a las ejecuciones programadas.
- Se admiten dos formatos de DateTime diferentes: 2025-03-11T04:46:00 (sin milisegundos) y 2025-03-11T04:46:00.000Z cuando se realizan operaciones de escritura en AWS Glue (con milisegundos).

- Para la entidad Suscripción a notificaciones de eventos, solo se puede crear una suscripción para una URL de devolución de llamada verificada y se pueden tener hasta 200 suscripciones por devolución de llamada.
- Para la entidad Devolución de llamadas para notificaciones de eventos, se puede crear un máximo de 50 registros por cuenta.

Conexión a Salesforce Commerce Cloud

La API B2C Commerce es un conjunto de API de RESTful diseñadas para interactuar con instancias de B2C Commerce. Se conoce por varios nombres: API Salesforce Commerce, el acrónimo SCAPI o simplemente API Commerce.

La API permite a los desarrolladores crear una amplia variedad de aplicaciones: desde tiendas en línea completas hasta herramientas personalizadas para comerciantes, con el fin de ampliar las funciones de Business Manager. La API se encuentra disponible sin costo adicional para todos los clientes de B2C Commerce.

La API se divide en dos grupos principales de API: API para compradores y API para administradores. Además, dentro de cada grupo, se dividen en familias de API y en grupos más pequeños centrados en funcionalidades relacionadas.

Temas

- Compatibilidad de AWS Glue con Salesforce Commerce Cloud
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de Salesforce Commerce Cloud
- Configuración de las conexiones de Salesforce Commerce Cloud
- Lectura de entidades de Salesforce Commerce Cloud
- Referencia de opciones de conexión de Salesforce Commerce Cloud
- Limitaciones

Compatibilidad de AWS Glue con Salesforce Commerce Cloud

AWS Glue es compatible con Salesforce Commerce Cloud de la siguiente manera:

¿Es compatible como origen?

Sí. Puede utilizar los trabajos de ETL de AWS Glue para consultar datos de Salesforce Commerce Cloud.

¿Es compatible como destino?

No.

Versiones compatibles de la API de Salesforce Commerce Cloud

v1.

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

También puede usar las siguientes políticas de IAM administradas para permitir el acceso:

- AWSGlueServiceRole: concede acceso a los recursos que necesitan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura

en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.

- AWSGlueConsoleFullAccess: concede acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de Salesforce Commerce Cloud

Antes de poder utilizar AWS Glue para transferir datos desde Salesforce Commerce Cloud, deberá cumplir estos requisitos:

Requisitos mínimos

- Tener una aplicación cliente de Salesforce Commerce Cloud con el ID y el secreto de cliente.
- La cuenta de Salesforce Commerce Cloud debe estar habilitada para el acceso a la API.

Si cumple estos requisitos, estará listo para conectar AWS Glue a la cuenta de Salesforce Commerce Cloud. Si es una conexión típica, no es necesario que haga nada más en Salesforce Commerce Cloud.

Configuración de las conexiones de Salesforce Commerce Cloud

Salesforce Commerce Cloud admite el tipo de concesión CREDENCIALES DEL CLIENTE para OAuth2.

- Este tipo de concesión se considera OAuth 2.0 de dos patas, ya que los clientes lo utilizan para obtener un token de acceso fuera del contexto de un usuario. AWS Glue puede utilizar el ID de cliente y el secreto de cliente para autenticar las API de Salesforce Commerce Cloud que los servicios personalizados que defina proporcionen.
- Cada servicio personalizado pertenece a un usuario exclusivo de la API con un conjunto de roles y permisos que autorizan al servicio a realizar acciones específicas. Un token de acceso está asociado a un único servicio personalizado.
- Este tipo de concesión da lugar a un token de acceso de corta duración, que se puede renovar mediante una llamada al punto de conexión de identidad.

- Para más información sobre la documentación de Salesforce Commerce Cloud acerca de la generación de credenciales de cliente, consulte la documentación de Salesforce.

Para configurar una conexión de Salesforce Commerce Cloud:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles. Es necesario crear un secreto para cada conexión en AWS Glue.
   a. En el caso de aplicaciones conectadas administradas por el cliente, el secreto debe contener el secreto del consumidor de la aplicación conectada con USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET como clave.
2. En AWS Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:
   a. En Conexiones de datos, elija Crear conexión.
   b. Al seleccionar un Origen de datos, seleccione Salesforce Commerce Cloud.
   c. Proporcione el código abreviado, el ID de la organización y el ID de sitio de Salesforce Commerce Cloud.
   d. Seleccione la URL de dominio de Salesforce Commerce Cloud de la cuenta de Salesforce Commerce Cloud.
   e. Seleccione el rol de IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

      JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
```

```
  ]
}
```

f. Proporcione los alcances de OAuth (opcional) y el ID de cliente de la aplicación cliente administrada por el usuario de Salesforce Commerce Cloud a la que se desea conectar.

g. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.

h. Seleccione las opciones de red si quiere usar su red.

3. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.
4. En la configuración de su trabajo de AWS Glue, proporcione `connectionName` como Conexión de red adicional.

Lectura de entidades de Salesforce Commerce Cloud

Requisitos previos

- Un objeto de Salesforce Commerce Cloud desde el cual le gustaría leer. Consulte la tabla de entidades compatibles que aparece a continuación para comprobar las entidades disponibles.

Entidades compatibles

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite Partición
Asignaciones	Sí	Sí	Sí	Sí	Sí
Campañas	Sí	Sí	Sí	Sí	Sí
Catálogos	Sí	Sí	Sí	Sí	Sí
Categorías	Sí	Sí	Sí	Sí	Sí
Cupones	Sí	Sí	Sí	Sí	Sí
Certificados de regalo	Sí	Sí	Sí	Sí	Sí
Productos	Sí	Sí	Sí	Sí	Sí

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite Partición
Promociones	Sí	Sí	Sí	Sí	Sí
Grupos de código fuente	Sí	Sí	Sí	Sí	Sí

Ejemplo

```
salesforce_commerce_cloud_read = glueContext.create_dynamic_frame.from_options(
     connection_type="SalesforceCommerceCloud",
     connection_options={
         "connectionName": "connectionName",
         "ENTITY_NAME": "campaign",
         "API_VERSION": "v1"
     }
)
```

Detalles de entidades y campos de Salesforce Commerce Cloud:

Lista de entidades:

- Asignaciones: https://developer.salesforce.com/docs/commerce/commerce-api/references/assignments
- Campañas: https://developer.salesforce.com/docs/commerce/commerce-api/references/campaigns
- Catálogos: https://developer.salesforce.com/docs/commerce/commerce-api/references/catalogs
- Categorías: https://developer.salesforce.com/docs/commerce/commerce-api/references/catalogs?meta=searchCategories
- Certificados de regalo: https://developer.salesforce.com/docs/commerce/commerce-api/references/gift-certificates
- Productos: https://developer.salesforce.com/docs/commerce/commerce-api/references/products
- Promociones: https://developer.salesforce.com/docs/commerce/commerce-api/references/promotions
- Grupos de código fuente: https://developer.salesforce.com/docs/commerce/commerce-api/references/source-code-groups

Consultas de partición

Puede proporcionar las opciones adicionales de Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` y `NUM_PARTITIONS` si quiere usar la simultaneidad en Spark. Con estos parámetros, la consulta original se dividiría en un número `NUM_PARTITIONS` de subconsultas que las tareas de Spark pueden ejecutar simultáneamente.

- `PARTITION_FIELD`: el nombre del campo que se usará para particionar la consulta.
- `LOWER_BOUND`: un valor de límite inferior inclusivo del campo de partición elegido.

  Para la fecha, aceptamos el formato de fecha de Spark que se usa en las consultas de Spark SQL. Ejemplos de valores válidos: `"2024-02-06"`.
- `UPPER_BOUND`: un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`: el número de particiones.

Los detalles sobre la compatibilidad de los campos de partición por entidad se presentan en la siguiente tabla.

Entidad	Campo de partición	DataType
Campañas	lastModified	DateTime
Campañas	startDate	DateTime
Campañas	endDate	DateTime
Catálogos	creationDate	DateTime
Categorías	creatiionDate	DateTime
Certificados de regalo	merchantId	Cadena
Certificados de regalo	creatiionDate	DateTime
Productos	creatiionDate	DateTime
Productos	lastModified	DateTime
Grupos de código fuente	creationDate	DateTime

Entidad	Campo de partición	DataType
Grupos de código fuente	startTime	DateTime
Grupos de código fuente	endTime	DateTime

Ejemplo

```
salesforceCommerceCloud_read = glueContext.create_dynamic_frame.from_options(
    connection_type="SalesforceCommerceCloud",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "coupons",
        "API_VERSION": "v1",
        "PARTITION_FIELD": "creationDate",
        "LOWER_BOUND": "2020-05-01T20:55:02.000Z",
        "UPPER_BOUND": "2024-07-11T20:55:02.000Z",
        "NUM_PARTITIONS": "10"
    }
)
```

Referencia de opciones de conexión de Salesforce Commerce Cloud

Existen las siguientes opciones para establecer conexión con Salesforce Commerce Cloud:

- `ENTITY_NAME`(cadena): (obligatorio) se usa para lectura. El nombre del objeto en Salesforce Commerce Cloud.
- `API_VERSION`(cadena): (obligatorio) se utiliza para leer y escribir. Versión de la API de REST de Salesforce Commerce Cloud que desea utilizar. Ejemplo: v1.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.
- `PARTITION_FIELD`(cadena): se usa para leer. Campo que se utilizará para particionar la consulta.
- `LOWER_BOUND`(cadena): se usa para leer. Un valor de límite inferior inclusivo del campo de partición elegido.

- `UPPER_BOUND`(cadena): se usa para leer. Un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`(entero): predeterminado: 1. Se usa para leer. Número de particiones para leer.

Limitaciones

Las siguientes son limitaciones para el conector de Salesforce Commerce Cloud:

- El filtro Contiene no funciona como se esperaba al particionar.
- La entidad de Zonas CDN no admite instancias de entorno de prueba y solo es compatible con los tipos de instancia Desarrollo y Producción. Para obtener más información, consulte https://help.salesforce.com/s/articleView?id=cc.b2c_embedded_cdn_overview.htm .
- En Salesforce Commerce Cloud, no hay ningún punto de conexión de API para obtener metadatos dinámicos. Por lo tanto, no se contempla la compatibilidad con los campos personalizados en las entidades Producto y Categoría.
- El identificador del sitio es un parámetro de consulta obligatorio. Debe transmitir el valor del ID del sitio a través de la configuración del conector personalizado. Para obtener más información, consulte Base URL and Request Formation .
- Puede aplicar filtros en un máximo de dos campos (excluido Niveles, si está presente) en una única solicitud de API, con la combinación de diferentes operadores indicada en la siguiente tabla.

Criterios del filtro	¿Se admite?
Un campo con el operador CONTIENE en una única solicitud de API.	Sí
Un campo con el operador Igual en una única solicitud de API.	Sí
Un campo con el operador ENTRE en una única solicitud de API.	Sí
Dos o más campos con el operador CONTIENE en una única solicitud de API.	No
Dos o más campos con el operador Igual en una única solicitud de API.	No

Criterios del filtro	¿Se admite?
Dos o más campos con el operador ENTRE en una única solicitud de API.	No
Un campo con el operador Igual y un campo con el operador CONTIENE en una única solicitud de API.	Sí
Un campo con el operador ENTRE y un campo con el operador CONTIENE en una única solicitud de API.	Sí
Un campo con el operador ENTRE y un campo con el operador Igual en una única solicitud de API.	Sí
Un campo con el operador Igual, un campo con el operador CONTIENE y un campo con el operador ENTRE en una única solicitud de API.	No
Un campo con el operador Igual cuando se aplica EXTRACCIÓN INCREMENTAL en una única solicitud de API.	Sí
Un campo con el operador CONTIENE cuando se aplica EXTRACCIÓN INCREMENTAL en una única solicitud de API.	Sí
Un campo con el operador ENTRE cuando se aplica EXTRACCIÓN INCREMENTAL en una única solicitud de API.	No
Un campo con el operador Igual y un campo con el operador CONTIENE cuando se aplica EXTRACCIÓN INCREMENTAL en una única solicitud de API.	No

- En algunas entidades, el tipo de dato de los campos al recuperarlos es diferente del que se usa cuando se configuran como campos que se pueden buscar. Como resultado, no se admite la característica de filtrado para estos campos. La siguiente tabla proporciona detalles sobre estos campos.

Sr. No.	Nombre de la entidad	Nombre del campo que se puede buscar	Tipo de datos como: se puede buscar	Tipo de datos como: se puede recuperar
1	Catálogo	nombre	Cadena	Struct
2	Catálogo	Descripción	Cadena	Struct
3	Categoría	nombre	Cadena	Struct
4	Categoría	Descripción	Cadena	Struct
5	Producto	nombre	Cadena	Struct
6	Producto	searchable	Booleano	Struct
7	Producto	validFrom	DateTime	Struct
8	Producto	validTo	DateTime	Struct
9	Producto	type	Cadena	Struct
10	Producto	onlineFlag	Booleano	Struct
11	promoción	nombre	Cadena	Struct

Conexión a Salesforce Marketing Cloud Account Engagement

Salesforce Marketing Cloud Account Engagement es una solución de automatización de marketing que ayuda a las empresas a crear conexiones significativas, generar más canalizaciones y permitir que los representantes de ventas logren más acuerdos. Si es usuario de Salesforce Marketing Cloud Account Engagement, puede conectar AWS Glue a su cuenta de Salesforce Marketing Cloud Account Engagement. Puede utilizar Salesforce Marketing Cloud Account Engagement como

origen de datos en sus trabajos de ETL. Ejecute estos trabajos para transferir datos de Salesforce Marketing Cloud Account Engagement a servicios de AWS u otras aplicaciones compatibles.

Temas

- Compatibilidad de AWS Glue con Salesforce Marketing Cloud Account Engagement
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de Salesforce Marketing Cloud Account Engagement
- Configuración de las conexiones de Salesforce Marketing Cloud Account Engagement
- Lectura de entidades de Salesforce Marketing Cloud Account Engagement
- Opciones de conexión de Salesforce Marketing Cloud Account Engagement
- Limitaciones y notas del conector de Salesforce Marketing Cloud Account Engagement

Compatibilidad de AWS Glue con Salesforce Marketing Cloud Account Engagement

Compatibilidad de AWS Glue con Salesforce Marketing Cloud Account Engagement de la siguiente manera:

¿Es compatible como origen?

Sí. Puede utilizar los trabajos de ETL de AWS Glue para consultar datos de Salesforce Marketing Cloud Account Engagement en modo sincrónico o asincrónico.

¿Es compatible como destino?

No.

Versiones de la API de Salesforce Marketing Cloud Account Engagement

Son compatibles las siguientes versiones de la API de Salesforce Marketing Cloud Account Engagement:

- v5

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS IAM necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si no desea utilizar el método anterior, puede utilizar las siguientes políticas de IAM administradas:

- AWSGlueServiceRole: da acceso a recursos que precisan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: otorga acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la Consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de Salesforce Marketing Cloud Account Engagement

Antes de poder utilizar AWS Glue para transferir datos desde Salesforce Marketing Cloud Account Engagement, debe cumplir estos requisitos:

Requisitos mínimos

Los requisitos mínimos son los siguientes:

- Tener una cuenta de marketing de Salesforce.
- Tener un plan de participación de Account Engagement para la cuenta de Salesforce.
- Haber sincronizado el usuario de Salesforce con el usuario de Account Engagement.
- Haber creado una nueva aplicación conectada en Administrador de aplicaciones para obtener las credenciales de OAuth.

Si cumple estos requisitos, lo tiene todo listo para conectar AWS Glue a su cuenta de Salesforce Marketing Cloud Account Engagement.

Configuración de las conexiones de Salesforce Marketing Cloud Account Engagement

El tipo de concesión determina cómo se comunica AWS Glue con Salesforce Marketing Cloud Account Engagement para solicitar el acceso a sus datos. Su elección afecta a los requisitos que debe cumplir antes de crear la conexión. Salesforce Marketing Cloud Account Engagement solo admite el tipo de concesión AUTHORIZATION_CODE para OAuth 2.0.

- Este tipo de concesión se considera un OAuth de “tres vías”, ya que se basa en redirigir a los usuarios a un servidor de autorización externo para autenticar al usuario. Se utiliza para crear conexiones a través de la consola de AWS Glue.
- Los usuarios aún pueden optar por crear su propia aplicación conectada en Salesforce Marketing Cloud Account Engagement y proporcionar su propio ID y secreto de cliente al crear conexiones a través de la consola de AWS Glue. En este escenario, aún se abrirá Salesforce Marketing Cloud Account Engagement para iniciar sesión y autorizar a AWS Glue para que acceda a sus recursos.
- Este tipo de concesión da como resultado un token de actualización y un token de acceso. El token de acceso es de corta duración y se puede actualizar automáticamente sin la interacción del usuario mediante el token de actualización.
- Para ver la documentación pública de Salesforce Marketing Cloud Account Engagement sobre la creación de una aplicación conectada para el flujo de OAuth con código de autorización, consulte Autenticación.

Para configurar una conexión de Salesforce Marketing Cloud Account Engagement, haga lo siguiente:

1. En AWS Glue Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:

   a. Al seleccionar un Tipo de conexión, seleccione Salesforce Marketing Cloud Account Engagement.

   b. Proporcione el elemento `INSTANCE_URL` de la instancia de Salesforce Marketing Cloud Account Engagement a la que quiere conectarse.

   c. Proporcione el elemento `PARDOT_BUSINESS_UNIT_ID` de la instancia de Salesforce Marketing Cloud Account Engagement a la que quiere conectarse.

   d. Seleccione la URL de código de autorización correspondiente en el menú desplegable.

   e. Seleccione la URL del token correspondiente en el menú desplegable.

   f. Seleccione el rol de AWS IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

      JSON

      ```
      {
        "Version":"2012-10-17",
        "Statement": [
          {
            "Effect": "Allow",
            "Action": [
              "secretsmanager:DescribeSecret",
              "secretsmanager:GetSecretValue",
              "secretsmanager:PutSecretValue",
              "ec2:CreateNetworkInterface",
              "ec2:DescribeNetworkInterfaces",
              "ec2:DeleteNetworkInterface"
            ],
            "Resource": "*"
          }
        ]
      }
      ```

   g. Proporcione el ID de cliente de la aplicación cliente administrada por el usuario (el ID de cliente de la aplicación conectada).

   h. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens. El secreto seleccionado debe tener una clave `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET` cuyo valor sea el secreto del cliente de la aplicación conectada.

i. Seleccione las opciones de red si quiere usar su red.

2. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.
3. En la configuración de su trabajo de AWS Glue, proporcione `connectionName` como Conexión de red adicional.

Lectura de entidades de Salesforce Marketing Cloud Account Engagement

Requisito previo

Un objeto de Salesforce Marketing Cloud Account Engagement desde el cual le gustaría leer. Necesitará el nombre del objeto.

Entidades compatibles para el origen sincrónico:

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Campaña	Sí	Sí	Sí	Sí	Sí
Dynamic Content	Sí	Sí	Sí	Sí	Sí
Correo electrónico	Sí	Sí	Sí	Sí	Sí
Plantilla de correo electrónico	Sí	Sí	Sí	Sí	Sí
Programa Engagement Studio	Sí	Sí	Sí	Sí	Sí
Contenido de carpeta	Sí	Sí	Sí	Sí	Sí
Página de destino	Sí	Sí	Sí	Sí	Sí

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Historia del ciclo de vida	Sí	Sí	Sí	Sí	Sí
Etapa del ciclo de vida	Sí	Sí	Sí	Sí	Sí
Enumeración	Sí	Sí	Sí	Sí	Sí
Correo electrónico de listado	Sí	Sí	Sí	Sí	Sí
Suscripción al listado	Sí	Sí	Sí	Sí	Sí
Oportunidad	Sí	Sí	Sí	Sí	Sí
Posible cliente	Sí	Sí	Sí	Sí	Sí
Cuenta de posible cliente	Sí	Sí	Sí	Sí	Sí
Usuario	Sí	Sí	Sí	Sí	Sí

Ejemplo:

```
salesforcepardot_read = glueContext.create_dynamic_frame.from_options(
    connection_type="SalesforcePardot",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "API_VERSION": "v5"
    }
   )
```

Entidades compatibles para el origen asincrónico:

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Campaña	Sí	No	No	Sí	No
Dynamic Content	Sí	No	No	Sí	No
Plantilla de correo electrónico	Sí	No	No	Sí	No
Página de destino	Sí	No	No	Sí	No
Historia del ciclo de vida	Sí	No	No	Sí	No
Etapa del ciclo de vida	Sí	No	No	Sí	No
Lista	Sí	No	No	Sí	No
Correo electrónico de listado	Sí	No	No	Sí	No
Suscripción al listado	Sí	No	No	Sí	No
Oportunidad	Sí	No	No	Sí	No
Posible cliente	Sí	No	No	Sí	No
Cuenta de posible cliente	Sí	No	No	Sí	No

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Usuario	Sí	No	No	Sí	No

Ejemplo:

```
salesforcepardot_read = glueContext.create_dynamic_frame.from_options(
    connection_type="SalesforcePardot",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "API_VERSION": "v5",
        "TRANSFER_MODE": "ASYNC"
    }
   )
```

Detalles de la entidad y el campo de Salesforce Marketing Cloud Account Engagement:

Para ver los detalles de los campos de las siguientes entidades, vaya a Salesforce Marketing Cloud Account Engagement API, seleccione Guías, desplácese hacia abajo hasta Open Source API Wrappers, expanda Version 5 Docs en el menú y elija una entidad.

Lista de entidades:

- Campaña
- Dynamic Content
- Correo electrónico
- Plantilla de correo electrónico
- Programa Engagement Studio
- Contenido de carpeta
- Página de destino
- Historia del ciclo de vida
- Etapa del ciclo de vida
- Enumeración
- Correo electrónico de listado

- Suscripción al listado
- Oportunidad
- Posible cliente
- Cuenta de posible cliente
- Usuario

Además de los campos que mencionamos anteriormente, el modo asíncrono admite campos filtrables específicos para cada entidad, como se muestra en la siguiente tabla.

Entidad	Campos filtrables adicionales admitidos en Asincrónico
Campaña	`createdAfter` , `createdBefore` , `deleted`, `updatedAfter` , `updatedBefore`
Dynamic Content	`createdAfter` , `createdBefore` , `deleted`, `updatedAfter` , `updatedBefore`
Plantilla de correo electrónico	`createdAfter` , `createdBefore` , `deleted`, `updatedAfter` , `updatedBefore`
Programa Engagement Studio	-
Página de destino	`createdAfter` , `createdBefore` , `deleted`, `updatedAfter` , `updatedBefore`
Historia del ciclo de vida	`createdAfter` , `createdBefore`
Etapa del ciclo de vida	`createdAfter` , `createdBefore` , `deleted`, `updatedAfter` , `updatedBefore`

Entidad	Campos filtrables adicionales admitidos en Asincrónico
Enumeración	`createdAfter` , `createdBefore` , `deleted`, `updatedAfter` , `updatedBefore`
Correo electrónico de listado	`createdAfter` , `createdBefore` , `deleted`, `updatedAfter` , `updatedBefore`
Suscripción al listado	`createdAfter` , `createdBefore` , `deleted`, `updatedAfter` , `updatedBefore`
Oportunidad	`createdAfter` , `createdBefore` , `deleted`, `updatedAfter` , `updatedBefore`
Posible cliente	`createdAfter` , `createdBefore` , `deleted`, `updatedAfter` , `updatedBefore`
Cuenta de posible cliente	`createdAfter` , `createdBefore` , `deleted`
Usuario	`createdAfter` , `createdBefore` , `deleted`, `updatedAfter` , `updatedBefore`

Para obtener más información sobre los campos adicionales, consulte Salesforce Export API

Tenga en cuenta las siguientes consideraciones para el conector:

- El valor del campo `delete` en las entidades puede ser `false` (predeterminado) `true` o `all`.

Consultas de partición

Partición basada en filtros:

Puede proporcionar las opciones adicionales de Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` y `NUM_PARTITIONS` si quiere utilizar la simultaneidad en Spark. Con estos parámetros, la consulta original se dividiría en un número `NUM_PARTITIONS` de subconsultas que las tareas de Spark pueden ejecutar simultáneamente.

- `PARTITION_FIELD`: el nombre del campo que se utilizará para particionar la consulta.
- `LOWER_BOUND`: un valor de límite inferior inclusivo del campo de partición elegido.

  En el campo DateTime, aceptamos el formato de marca de tiempo de Spark que se utiliza en las consultas de Spark SQL.

  Ejemplos de valor válido:

  ```
  "2022-01-01T01:01:01.000Z"
  ```

- `UPPER_BOUND`: un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`: el número de particiones.
- `PARTITION_BY`: el tipo de partición que se hará. En caso de partición basada en campos, se debe pasar “FIELD”.

Ejemplo:

```
salesforcepardot_read = glueContext.create_dynamic_frame.from_options(
    connection_type="salesforcepardot",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "API_VERSION": "v5",
        "PARTITION_FIELD": "createdAt"
        "LOWER_BOUND": "2022-01-01T01:01:01.000Z"
        "UPPER_BOUND": "2024-01-01T01:01:01.000Z"
        "NUM_PARTITIONS": "10",
        "PARTITION_BY": "FIELD"
    }
   )
```

Opciones de conexión de Salesforce Marketing Cloud Account Engagement

Las siguientes son opciones de conexión para Salesforce Marketing Cloud Account Engagement:

- `ENTITY_NAME`(cadena): (obligatorio) se usa para lectura. El nombre del objeto en Salesforce Marketing Cloud Account Engagement.
- `PARDOT_BUSINESS_UNIT_ID`: (obligatorio) se utiliza para crear una conexión. El ID de unidad de negocio de la instancia de Salesforce Marketing Cloud Account Engagement a la que quiere conectarse.
- `API_VERSION`(cadena): (obligatorio) se usa para lectura. Versión de la API de REST de Salesforce Marketing Cloud Account Engagement que quiere utilizar.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- `FILTER_PREDICATE`(cadena)
  - En modo sincrónico, predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
  - En modo asincrónico, predeterminado: valor de `DateTime` actual (según la zona horaria del usuario) - 1 año. Se usa para leer.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.
- `PARTITION_FIELD`(cadena): se usa para leer. Campo que se utilizará para particionar la consulta.
- `LOWER_BOUND`(cadena): se usa para leer. Un valor de límite inferior inclusivo del campo de partición elegido.
- `UPPER_BOUND`(cadena): se usa para leer. Un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`(entero): predeterminado: 1. Se usa para leer. Número de particiones para leer.
- `INSTANCE_URL`(cadena): (obligatorio) se usa para lectura. Una URL válida de instancia de Salesforce Marketing Cloud Account Engagement.
- `PARTITION_BY`(cadena): (obligatorio) se usa para lectura. El tipo de partición que se hará. En caso de partición basada en campos, se debe pasar “FIELD”.
- `TRANSFER_MODE`(Cadena): (Opcional) Valor que se utilizará para ejecutar un trabajo en modo ASINCRÓNICO; si no se proporciona esta opción, el trabajo se ejecutará en modo SINCRÓNICO.

Limitaciones y notas del conector de Salesforce Marketing Cloud Account Engagement

Se aplican las siguientes notas y limitaciones:

- Cuando se aplican un límite y una partición, el límite prevalece sobre la partición.
- Según los documentos de la API, `SalesforceMarketingCloudEngagement` aplicó un RateLimit a las solicitudes diarias y simultáneas. Para más información, consulte Rate Limits.
- La API de exportación está sujeta al límite diario de llamadas a la API de Account Engagement y al límite de llamadas simultáneas a la API de Account Engagement de su cuenta.
- Al igual que en una cola, las llamadas a la API de exportación/asincrónicas se ejecutan de forma secuencial para cada cuenta. Las exportaciones más antiguas se procesan antes que las exportaciones más recientes.
- La partición no es compatible con el modo asíncrono.
- El número de campos seleccionados especificados en las llamadas a la API de exportación/asincrónicas no puede superar los 150.
- La entidad Prospect admite más de 150 campos, pero solo se pueden seleccionar 150 campos a la vez. Si se selecciona `Select All`, se excluirán algunos campos. Para recuperar los datos de estos campos excluidos, debe incluirlos en la opción `Selected Fields`.

  La siguiente es la lista de campos excluidos en `SELECT_ALL`: `updatedBy.firstName`, `updatedBy.lastName`, `updatedBy.jobTitle`, `updatedBy.roleName`, `updatedBy.salesforceId`, `updatedBy.createdAt`, `updatedBy.updatedAt`, `updatedBy.isDeleted`, `updatedBy.createdById`, `updatedBy.updatedById`, `updatedBy.tagReplacementLanguage`
- Los campos de colección no se pueden exportar para la API asíncrona. Por ejemplo, en Lista de correos electrónicos no se admiten los campos `senderOptions` y `replyToOptions`.
- Para todas las entidades, el filtro es obligatorio. Si no se proporciona ningún filtro, el predicado de filtro predeterminado se establece en el campo `Created After` con un valor de la fecha y hora actual (ajustado a su zona horaria) menos un año.
- Según las limitaciones de Salesforce Marketing Cloud Account Engagement, en Asincrónico, el intervalo máximo para obtener datos es de 1 año. Si se proporciona una consulta para más de 1 año, el trabajo generará un error.
- En la actualidad, hay un error en Salesforce Pardot. Cuando el trabajo incluye un solo campo que no contiene ningún dato, el valor del campo no devuelve el resultado correcto y, en su lugar,

se devuelve varias veces el nombre del campo. El equipo de Salesforce Pardot está al tanto del problema y está trabajando activamente en una solución.

Conexión a SAP HANA en AWS Glue Studio

AWS Glue proporciona soporte integrado para SAP HANA. AWS Glue Studio proporciona una interfaz visual para conectarse a SAP HANA, crear trabajos de integración de datos y ejecutarlos en el tiempo de ejecución de Spark sin servidor de AWS Glue Studio.

AWS Glue Studio crea una conexión unificada para SAP HANA. Para obtener más información, consulte Consideraciones.

Temas

- Crear una conexión SAP HANA
- Crear un nodo de origen de SAP HANA
- Crear un nodo de destino de SAP HANA
- Opciones avanzadas

Crear una conexión SAP HANA

Para conectarse a SAP HANA desde AWS Glue, tendrá que crear y almacenar sus credenciales de SAP HANA en un AWS Secrets Manager secreto y, a continuación, asociar ese secreto a una conexión de AWS Glue de SAP HANA. Deberá configurar la conectividad de red entre su servicio SAP HANA y AWS Glue.

Requisitos previos:

- Si su servicio SAP HANA está en una Amazon VPC, configure Amazon VPC para permitir que su trabajo de AWS Glue se comunique con el servicio SAP HANA sin que el tráfico atraviese la Internet pública.

  En Amazon VPC, identifique o cree una VPC, una subred y un grupo de seguridad que AWS Glue utilizará al ejecutar el trabajo. Además, debe asegurarse de que Amazon VPC esté configurada para permitir el tráfico de red entre su punto de conexión SAP HANA y esta ubicación. Su trabajo deberá establecer una conexión TCP con su puerto JDBC de SAP HANA. Para obtener más información sobre los puertos de SAP HANA, consulte la documentación de SAP HANA. Según el

diseño de la red, esto puede requerir cambios en las reglas de los grupos de seguridad, las ACL de red, las puertas de enlace de NAT y las conexiones entre pares.

Para configurar una conexión a SAP HANA:

1. En AWS Secrets Manager, cree un secreto con sus credenciales de SAP HANA. Para crear un secreto en Secrets Manager, siga el tutorial disponible en Crear un secreto AWS Secrets Manager en la documentación AWS Secrets Manager. Después de crear el secreto, conserve el nombre secreto, *secretName*, para el siguiente paso.

   - Al seleccionar pares clave/valor, genere un par para la clave `username/USERNAME` con el valor *saphanaUsername*.
   - Al seleccionar pares clave/valor, genere un par para la clave `password/PASSWORD` con el valor *saphanaPassword*.

2. En la consola de AWS Glue, genere una conexión mediante los pasos que se indican en the section called “Adición de una conexión de AWS Glue”. Tras crear la conexión, conserve el nombre de la conexión, *connectionName*, para el uso futuro en AWS Glue.

   - Al seleccionar un tipo de conexión, seleccione SAP HANA.
   - Al proporcionar la URL de SAP HANA, proporcione la URL de su instancia.

     Las URL de JDBC de SAP HANA tienen el formato `jdbc:sap://`*saphanaHostname*`:`*saphanaPort*`/?`*databaseName*`=`*saphanaDBname*`,`*Paramete*

     AWS Glue requiere los siguientes parámetros de URL de JDBC:

     - `databaseName` — Una base de datos predeterminada en SAP HANA a la que conectarse.
   - Al seleccionar un secreto AWS, proporcione un *secretName*.

Tras crear una conexión con AWS Glue SAP HANA, deberá realizar los siguientes pasos antes de ejecutar su trabajo de AWS Glue:

- Otorga permiso al rol de IAM asociado al trabajo de AWS Glue para leer el *secretName*.

Crear un nodo de origen de SAP HANA

Requisitos previos necesarios

- Una conexión AWS Glue SAP HANA, configurada con un AWS Secrets Manager secreto, tal y como se describe en la sección anterior, the section called “Crear una conexión SAP HANA”.
- Permisos adecuados en el trabajo para leer el secreto utilizado por la conexión.
- Una tabla de SAP HANA de la que le gustaría leer, *`tableName`*, o consultar *`targetQuery`*.

  Se puede especificar una tabla con un nombre de tabla y un nombre de esquema de SAP HANA, en la forma *`schemaName`*`.`*`tableName`*. El nombre del esquema y el separador "." no son necesarios si la tabla está en el esquema predeterminado, "public". Esto se llama *`tableIdentifier`*. Tenga en cuenta que la base de datos se proporciona como un parámetro de URL de JDBC en `connectionName`.

Agregar un origen de datos de SAP HANA

Para agregar un nodo de Origen de datos: SAP HANA:

1. Elija la conexión para el origen de datos de SAP HANA. Dado que lo ha creado, debería estar disponible en el menú desplegable. Si es necesario crear una conexión, elija Crear conexión de SAP HANA. Para obtener más información, consulte la sección the section called “Crear una conexión SAP HANA” anterior.

   Una vez que haya elegido una conexión, puede ver las propiedades de la conexión mediante un clic en Ver propiedades.
2. Elija una opción de origen de SAP HANA:

   - Elija una sola tabla: acceda a todos los datos de una sola tabla.
   - Ingresar una consulta personalizada: permite acceder a un conjunto de datos de varias tablas en función del consulta personalizada.
3. Si eligió una sola tabla, ingrese *`tableName`*.

   Si eligió Introducir una consulta personalizada, introduzca una consulta SQL SELECT.
4. En las propiedades personalizadas de SAP HANA, ingrese los parámetros y valores según sea necesario.

Crear un nodo de destino de SAP HANA

Requisitos previos necesarios

- Una conexión AWS Glue SAP HANA, configurada con un AWS Secrets Manager secreto, como se describe en la sección anterior, the section called “Crear una conexión SAP HANA”.
- Permisos adecuados en el trabajo para leer el secreto utilizado por la conexión.
- Una tabla de SAP HANA en la que le gustaría escribir, *`tableName`*.

  Se puede especificar una tabla con un nombre de tabla y un nombre de esquema de SAP HANA, en la forma *`schemaName`*`.`*`tableName`*. El nombre del esquema y el separador "." no son necesarios si la tabla está en el esquema predeterminado, "public". Esto se llama *`tableIdentifier`*. Tenga en cuenta que la base de datos se proporciona como un parámetro de URL de JDBC en `connectionName`.

Agregar un destino de datos de SAP HANA

Para añadir un nodo de destino de datos: SAP HANA:

1. Elija la conexión para el origen de datos de SAP HANA. Dado que lo ha creado, debería estar disponible en el menú desplegable. Si es necesario crear una conexión, elija Crear conexión de SAP HANA. Para obtener más información, consulte la sección the section called “Crear una conexión SAP HANA” anterior.

   Una vez que haya elegido una conexión, puede ver las propiedades de la conexión mediante un clic en Ver propiedades.
2. Configure el nombre de la tabla proporcionando *`tableName`*.
3. En las propiedades personalizadas de Teradata, ingrese los parámetros y valores según sea necesario.

Opciones avanzadas

Puede brindar opciones avanzadas al crear un nodo de SAP HANA. Estas opciones son las mismas que las disponibles cuando se programa AWS Glue para scripts de Spark.

Consulte the section called “Conexiones SAP HANA”.

Conexión a SAP OData

SAP OData es un protocolo web estándar que se utiliza para consultar y actualizar los datos presentes en SAP mediante ABAP (programación avanzada de aplicaciones empresariales), que aplica y aprovecha tecnologías web como HTTP para proporcionar acceso a la información desde una variedad de aplicaciones, plataformas y dispositivos externos. Con el producto, puede acceder a todo lo que necesita para integrarse sin problemas con su sistema, aplicación o datos de SAP.

Temas

- Compatibilidad de AWS Glue con SAP OData
- Creación de conexiones de
- Creación de un trabajo de SAP OData
- Escribir en SAP OData
- Uso del script de administración de estado de SAP OData
- Particiones para entidades que no sean ODP
- Opciones de conexión de SAP OData
- Detalles de la entidad y del campo de SAP OData

Compatibilidad de AWS Glue con SAP OData

AWS Glue es compatible con SAP OData de la siguiente manera:

¿Es compatible como origen?

Sí. Puede usar los trabajos de ETL de AWS Glue para consultar datos de SAP OData.

¿Es compatible como destino?

Sí. Puede usar los trabajos de ETL de AWS Glue para escribir registros en SAP OData.

Versiones de la API de SAP OData compatibles

Las siguientes versiones de la API de SAP OData son compatibles:

- 2.0

Orígenes compatibles

Se admiten los siguientes orígenes:

- Orígenes de ODP (Aprovisionamiento de datos operativos):
  - Extractores BW (DataSources)
  - Vistas CDS
  - SLT
- Orígenes que no sean ODP, por ejemplo:
  - Servicios de vistas CDS
  - Servicios basados en RFC
  - Servicios ABAP personalizados

Componentes SAP admitidos

Los requisitos mínimos son los siguientes:

- Debe habilitar el servicio de catálogo para la detección de servicios.
  - Configure los orígenes de datos de aprovisionamiento de datos operativos (ODP) para la extracción en el SAP Gateway de su sistema SAP.
  - OData V2.0: puede habilitar los servicios de catálogo de OData V2.0 en SAP Gateway mediante la transacción `/IWFND/MAINT_SERVICE`.
  - Habilite los servicios OData V2.0 en su SAP Gateway mediante la transacción `/IWFND/MAINT_SERVICE`.
  - El servicio SAP OData debe admitir opciones de paginación o consulta del lado del cliente, como `$top` y `$skip`. También debe admitir la opción de consulta del sistema `$count`.
  - Debe proporcionar la autorización requerida para que el usuario de SAP descubra los servicios y extraiga datos mediante los servicios OData de SAP. Consulte la documentación de seguridad proporcionada por SAP.
- Si desea utilizar OAuth 2.0 como mecanismo de autorización, debe habilitar OAuth 2.0 para el servicio OData y registrar el cliente OAuth según la documentación de SAP.
- Para generar un servicio OData basado en orígenes de datos ODP, SAP Gateway Foundation debe instalarse localmente en su pila de ERP/BW o en una configuración de hub.
  - Para sus aplicaciones de ERP/BW, la pila SAP NetWeaver AS ABAP debe ser de la versión 7.50 SP02 o superior.
  - Para el sistema hub (SAP Gateway), el SAP NetWeaver AS ABAP del sistema hub debe ser de la versión 7.50 SP01 o superior para la configuración de hub remoto.

- Para orígenes que no sean ODP, la versión de la pila de SAP NetWeaver debe ser 7.40 SP02 o posterior.

Métodos de autenticación compatibles

Se admiten los siguientes métodos de autenticación:

- Autenticación básica
- OAuth 2.0

Requisitos previos

Antes de iniciar un trabajo AWS Glue de extracción de datos de SAP OData mediante la conexión de SAP OData, complete los siguientes requisitos previos:

- El servicio OData de SAP correspondiente debe estar activado en el sistema SAP para garantizar que el origen de datos esté disponible para su consumo. Si el servicio OData no está activado, el trabajo de Glue no podrá acceder a los datos de SAP ni extraerlos.
- Los mecanismos de autenticación apropiados, como la autenticación básica (personalizada) u OAuth 2.0, deben configurarse en SAP para garantizar que el trabajo AWS Glue pueda establecer una conexión con el servicio OData de SAP correctamente.
- Configure las políticas de IAM para conceder los permisos adecuados al trabajo AWS Glue para acceder a SAP, Secrets Manager y otros recursos de AWS involucrados en el proceso.
- Si el sistema SAP está alojado en una red privada, la conectividad de la VPC debe configurarse para garantizar que el trabajo AWS Glue pueda comunicarse de forma segura con SAP sin exponer datos confidenciales a través de la Internet pública.

AWS Secrets Manager se puede utilizar para almacenar información confidencial de forma segura, como las credenciales de SAP, que el trabajo AWS Glue puede recuperar de forma dinámica en el tiempo de ejecución. Este enfoque elimina la necesidad de una codificación rígida de las credenciales, lo que mejora la seguridad y la flexibilidad.

Los siguientes requisitos previos proporcionan una guía paso a paso sobre cómo configurar cada componente para una integración fluida entre AWS Glue y SAP OData.

Temas

- Activación de SAP OData

- Políticas de IAM
- Conectividad/Conexión de VPC
- Autenticación SAP
- AWS Secrets Manager para almacenar su secreto de autenticación

Activación de SAP OData

Siga los pasos que se describen a continuación para realizar la conexión SAP OData:

Orígenes de ODP

Antes de poder transferir desde un proveedor ODP, deberá cumplir los siguientes requisitos:

- Tiene una instancia de SAP NetWeaver AS ABAP.
- Su instancia de SAP NetWeaver contiene un proveedor ODP del que desea transferir datos. Los proveedores ODP incluyen:
  - SAP DataSources (código de transacción RSO2)
  - Vistas de SAP Core Data Services ABAP CDS
  - Sistemas SAP BW o SAP BW/4HANA (InfoObject, DataStore Object)
  - Replicación en tiempo real de tablas y vistas de bases de datos desde SAP Source System mediante SAP Landscape Replication Server (SAP SLT)
  - Vistas de información de SAP HANA en orígenes basados en SAP ABAP
- Su instancia de SAP NetWeaver tiene el componente SAP Gateway Foundation.
- Ha creado un servicio OData que extrae datos de su proveedor ODP. Para crear el servicio OData, utilice SAP Gateway Service Builder. Para acceder a los datos de ODP, Amazon AppFlow llama a este servicio mediante la API de OData. Para obtener más información, consulte Generación de un servicio para extraer datos de ODP mediante OData en la documentación de SAP BW/4HANA.
- Para generar un servicio OData basado en orígenes de datos ODP, SAP Gateway Foundation debe instalarse localmente en su pila de ERP/BW o en una configuración de hub.
  - Para sus aplicaciones de ERP/BW, la pila SAP NetWeaver AS ABAP debe ser de la versión 7.50 SP02 o superior.
  - Para el sistema hub (SAP Gateway), el SAP NetWeaver AS ABAP del sistema hub debe ser de la versión 7.50 SP01 o superior para la configuración de hub remoto.

Fuentes que no sean ODP

- La versión de la pila de SAP NetWeaver debe ser 7.40 SP02 o posterior.
- Debe habilitar el servicio de catálogo para la detección de servicios.
  - OData V2.0: puede habilitar los servicios de catálogo de OData V2.0 en su SAP Gateway mediante la transacción `/IWFND/MAINT_SERVICE`.
- El servicio SAP OData debe admitir opciones de paginación o consulta del lado del cliente, como `$top` y `$skip`. También debe admitir la opción de consulta del sistema `$count`.
- Para OAuth 2.0, debe habilitar OAuth 2.0 para el servicio OData y registrar el cliente OAuth según la documentación de SAP y configurar la redirección de URL autorizada de la siguiente manera:
  - `https://<region>.console.aws.amazon.com/gluestudio/oauth`, sustituyendo `<region>` por la región en la que se ejecuta AWS Glue, por ejemplo: us-east-1.
  - Debe habilitar una configuración segura para conectarse a través de HTTPS.
- Debe proporcionar una autorización requerida para que el usuario de SAP descubra los servicios y extraiga datos mediante los servicios OData de SAP. Consulte la documentación de seguridad proporcionada por SAP.

Políticas de IAM

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS IAM necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
```

```
      ],
      "Resource": "*"
    },
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue"
      ],
      "Resource": "*"
    }
  ]
}
```

El rol debe conceder acceso a todos los recursos que utiliza el trabajo como, por ejemplo, Amazon S3. Si no desea utilizar el método anterior, puede utilizar las siguientes políticas de IAM administradas.

- AWSGlueServiceRole: da acceso a recursos que precisan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: otorga acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la Consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.
- SecretsManagerReadWrite: proporciona acceso de lectura y escritura a AWS Secrets Manager a través de la Consola de administración de AWS. Nota: Esto excluye las acciones de IAM, así que combínelas con `IAMFullAccess`, en caso de que se requiera una configuración de rotación.

Políticas de IAM/permisos necesarios para configurar la VPC

Se requieren los siguientes permisos de IAM al utilizar la conexión de VPC para crear la Conexión a AWS Glue. Para obtener más información, consulte crear una política de IAM para AWS Glue.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "ec2:CreateNetworkInterface",
        "ec2:DeleteNetworkInterface",
        "ec2:DescribeNetworkInterfaces"
      ],
      "Resource": [
        "*"
      ]
    }
  ]
}
```

Conectividad/Conexión de VPC

Pasos para la conexión de VPC:

1. Utilice la conexión de VPC existente o cree una nueva siguiendo la Documentación de Amazon VPC.
2. Asegúrese de tener una puerta de enlace NAT que dirija el tráfico a Internet.
3. Elija el punto de conexión de VPC como puerta de enlace de Amazon S3 para crear la conexión.
4. Habilite la resolución de DNS y el nombre de host de DNS para utilizar los servicios de DNS de AWS proporcionados.
5. Vaya a la VPC creada y agregue los puntos de conexión necesarios para diferentes servicios como STS, AWS Glue o Secret Managers.
   a. Seleccione Crear punto de conexión.
   b. Para Categoría de servicio, elija Servicios de AWS.
   c. En Nombre del servicio, elija el nombre del servicio con el que se va a conectar.
   d. Elija VPC y Habilitar el nombre de DNS.
   e. Puntos de conexión de VPC necesarios para la conexión de VPC:
      i. STS

ii. AWS Glue

iii. Secrets Manager

Configuración del grupo de seguridad

El grupo de seguridad debe permitir que el tráfico llegue a su puerto de escucha desde la VPC de AWS Glue para que AWS Glue pueda conectarse a él. Una práctica recomendada es restringir el rango de direcciones IP de origen tanto como sea posible.

AWS Glue requiere un grupo de seguridad especial que permita todo el tráfico entrante desde sí mismo. Puede crear una regla con autorreferencia que permita todo el tráfico que se origine en el grupo de seguridad. Puede modificar un grupo de seguridad existente y especificar el grupo de seguridad como origen.

Abra la comunicación desde los puertos HTTPS del punto de conexión de la URL (ya sea un NLB o una instancia SAP).

Opciones de conectividad

- Conexión HTTPS con NLB interno y externo, certificado SSL de la entidad de certificación (CA), SSL no certificado autofirmado
- Conexión HTTPS con certificado SSL de instancia SAP de la autoridad de certificación (CA), no certificado SSL autofirmado

Autenticación SAP

El conector SAP admite los métodos de autenticación CUSTOM (se trata de la autenticación SAP BASIC) y OAUTH.

Autenticación personalizada

AWS Glue admite Custom (autenticación básica) como método para establecer conexiones con sus sistemas SAP, lo que permite el uso de un nombre de usuario y una contraseña para un acceso seguro. Este tipo de autenticación funciona bien en escenarios de automatización, ya que permite utilizar el nombre de usuario y la contraseña por adelantado con los permisos de un usuario en particular en la instancia de SAP OData. AWS Glue puede usar el nombre de usuario y la contraseña para autenticar las API de SAP OData. En AWS Glue, la autorización básica se implementa como autorización personalizada.

Para ver la documentación pública de SAP OData sobre el flujo de autenticación básica, consulte HTTP Basic Authentication.

Autenticación OAuth 2.0

AWS Glue también es compatible con OAuth 2.0 como mecanismo de autenticación seguro para establecer conexiones con sus sistemas SAP. Esto permite una integración perfecta, al tiempo que garantiza el cumplimiento de los estándares de autenticación modernos y mejora la seguridad del acceso a los datos.

Tipo de concesión AUTHORIZATION_CODE

El tipo de concesión determina cómo se comunica AWS Glue con SAP OData para solicitar el acceso a sus datos. SAP OData solo admite el tipo de concesión `AUTHORIZATION_CODE`. Este tipo de concesión se considera un OAuth de “tres vías”, ya que se basa en redirigir a los usuarios al servidor de autorización externo para autenticar al usuario. Se utiliza para crear conexiones a través de la consola de AWS Glue.

Los usuarios aún pueden optar por crear su propia aplicación conectada en SAP OData y proporcionar su propio ID y secreto de cliente al crear conexiones a través de la consola de AWS Glue. En este escenario, aún se abrirá SAP OData para iniciar sesión y autorizar a AWS Glue para que acceda a sus recursos.

Este tipo de concesión da como resultado un token de actualización y un token de acceso. El token de acceso es de corta duración y se puede actualizar automáticamente sin la interacción del usuario mediante el token de actualización.

Para ver la documentación pública de SAP OData sobre la creación de una aplicación conectada para el flujo de OAuth con código de autorización, consulte Authentication Using OAuth 2.0.

AWS Secrets Manager para almacenar su secreto de autenticación

Tendrá que almacenar los secretos de la conexión de OData de SAP en AWS Secrets Manager, configurar los permisos necesarios para la recuperación tal y como se especifica en la sección Políticas de IAM y utilizarlos al crear una conexión.

Utilice la Consola de administración de AWS de AWS Secrets Manager para crear un secreto para su origen de SAP. Para obtener más información, consulte Crear un secreto de AWS Secrets Manager. Los detalles en AWS Secrets Manager deben incluir los elementos presentes en el siguiente código.

Secreto de autenticación personalizado

Tendrá que ingresar su nombre de usuario del sistema SAP en lugar de <su nombre de usuario de SAP> y su contraseña en lugar de <su contraseña de nombre de usuario de SAP> y True o False. En este contexto, cambiar `basicAuthDisableSSO` a `true` desactiva el inicio de sesión único (SSO) para las solicitudes de autenticación básica, exigiendo credenciales de usuario explícitas para cada solicitud. Por el contrario, establecerlo en `false` permite el uso de las sesiones de SSO existentes, si están disponibles.

```
{
   "basicAuthUsername": "<your SAP username>",
   "basicAuthPassword": "<your SAP username password>",
   "basicAuthDisableSSO": "<True/False>",
   "customAuthenticationType": "CustomBasicAuth"
}
```

Secreto de OAuth 2.0

En caso de que utilice OAuth 2.0 como mecanismo de autenticación, el secreto en AWS Secrets Manager debe tener el ClientId de la aplicación cliente gestionada por el usuario con el siguiente formato. Tendrá que ingresar su secreto de cliente SAP en lugar de <su secreto de cliente>.

```
{"USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET": "<your client secret>"
}
```

Creación de conexiones de

Configuración de una conexión de SAP OData:

1. Inicie sesión en la consola de administración de AWS y abra la consola de AWS Glue. En el AWS Glue Studio, siga los pasos que se indican a continuación para crear una conexión:
   a. En el panel izquierdo, haga clic en Conexiones de datos.
   b. Haga clic en Crear conexión.
   c. Seleccione SAP OData en Elegir origen de datos
   d. Proporcione la URL del host de la aplicación de la instancia de SAP OData a la que quiere conectarse. Esta URL del host de la aplicación debe ser accesible a través de Internet pública para una conexión que no sea de VPC.

e. Proporcione la Ruta del servicio de aplicación de la instancia de SAP OData a la que quiere conectarse. Es la misma que la ruta del servicio de catálogo. Por ejemplo: `/sap/opu/odata/iwfnd/catalogservice;v=2`. AWS Glue no acepta una ruta de objeto específica.

f. Proporcione el Número de cliente de la instancia de SAP OData a la que quiere conectarse. Los valores admitidos son [001-999].. Ejemplo: 010

g. Proporcione el Número de puerto de la instancia de SAP OData a la que quiere conectarse. Ejemplo: 443

h. Proporcione el Idioma de inicio de sesión de la instancia de SAP OData a la que quiere conectarse. Ejemplo: EN

i. Seleccione el rol de AWS IAM que AWS Glue pueda asumir y que tenga los permisos descritos en la sección Políticas de IAM.

j. Seleccione el Tipo de autenticación que quiere utilizar para esta conexión en AWS Glue de la lista del menú desplegable: OAUTH2 o CUSTOM

   i. CUSTOM: seleccione el secreto que creó tal como se especifica en la sección AWS Secrets Manager para almacenar su secreto de autenticación.

   ii. OAUTH 2.0: ingrese las siguientes entradas solo en el caso de OAuth 2.0:

      A. En ClientId de la aplicación cliente gestionada por el usuario, ingrese su ID de cliente.

      B. `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET` (su secreto de cliente) en el AWS Secrets Manager que creó en la sección AWS Secrets Manager para almacenar su secreto de autenticación.

      C. En URL del código de autorización, ingrese la URL del código de autorización.

      D. En URL de los tokens de autorización, ingrese la URL del token de autorización.

      E. En Ámbitos de OAuth, introduzca sus ámbitos de OAuth separados por espacios. Ejemplo: `/IWFND/SG_MED_CATALOG_0002 ZAPI_SALES_ORDER_SRV_0001`

k. Seleccione las opciones de red si quiere usar su red. Para obtener más información, consulta Conectividad/Conexión de VPC.

2. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`. Para obtener más información, consulte Políticas de IAM.

3. Elija Probar conexión y pruebe su conexión. Si la prueba de conexión es satisfactoria, haga clic en siguiente, ingrese el nombre de su conexión y guárdela. La funcionalidad de prueba de conexión no está disponible si ha elegido Opciones de red (VPC).

Creación de un trabajo de SAP OData

Consulte Creación de trabajos de Visual ETL con AWS Glue Studio

Orígenes de aprovisionamiento de datos operativos (ODP)

El aprovisionamiento de datos operativos (ODP) proporciona una infraestructura técnica que puede utilizar para respaldar la extracción y replicación de datos para diversas aplicaciones de destino y admite mecanismos delta en estos escenarios. En el caso de un procedimiento delta, los datos de un origen (proveedor de ODP) se escriben automáticamente en una cola delta (cola delta operativa, ODQ) mediante un proceso de actualización, o se pasan a la cola delta mediante una interfaz de extracción. Un proveedor de ODP puede ser un DataSource (extractores), vistas de ABAP Core Data Services (vistas de ABAP CDS), SAP BW o SAP BW/4HANA, SAP Landscape Transformation Replication Server (SLT) y vistas de información de SAP HANA (vistas de cálculo). Las aplicaciones de destino (denominadas “suscriptores” de ODQ o, más generalmente, “consumidores de ODP”) recuperan los datos de la cola delta y continúan procesándolos.

Carga completa

En el contexto de las entidades OData y ODP de SAP, una carga completa se refiere al proceso de extraer todos los datos disponibles de una entidad ODP en una sola operación. Esta operación recupera el conjunto de datos completo del sistema de origen, lo que garantiza que el sistema de destino tenga una copia completa y actualizada de los datos de la entidad. Las cargas completas se suelen utilizar para orígenes que no admiten cargas incrementales o cuando es necesario actualizar el sistema de destino.

Ejemplo

Puede establecer la marca `ENABLE_CDC` de forma explícita en false al crear el DynamicFrame. Nota: `ENABLE_CDC` es false de forma predeterminada. Si no quiere inicializar la cola delta, no tiene que enviar esta marca ni establecerla en true. Si no se establece esta marca en true, se realizará una extracción de carga completa.

```
sapodata_df = glueContext.create_dynamic_frame.from_options(
    connection_type="SAPOData",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "ENABLE_CDC": "false"
    }, transformation_ctx=key)
```

Carga incremental

Una carga incremental en el contexto de las entidades ODP (Aprovisionamiento de datos operativos) implica extraer solo los datos nuevos o modificados (deltas) del sistema de origen desde la última extracción de datos, evitando el reprocesamiento de los registros ya procesados. Este enfoque mejora considerablemente la eficiencia, reduce los volúmenes de transferencia de datos, mejora el rendimiento, garantiza la sincronización efectiva entre sistemas y minimiza el tiempo de procesamiento, especialmente en el caso de conjuntos de datos grandes que cambian con frecuencia.

Transferencias incrementales basadas en tokens Delta

Para habilitar la transferencia incremental mediante la Captura de datos de cambios (CDC) para las entidades habilitadas para ODP que la admiten, siga estos pasos:

1. Cree el trabajo de transferencia incremental en modo script.
2. Al crear el marco de datos o el DynamicFrame de Glue, debe pasar la opción `"ENABLE_CDC": "True"`. Esta opción garantiza que recibirá un token Delta de SAP, que podrá utilizar para recuperar posteriormente los datos modificados.

El token Delta estará presente en la última fila del marco de datos, en la columna DELTA_TOKEN. Este token puede utilizarse como opción de conexión en llamadas posteriores para recuperar de forma incremental el siguiente conjunto de datos.

Ejemplo

- Establecemos la marca `ENABLE_CDC` en `true` al crear el DynamicFrame. Nota: `ENABLE_CDC` es `false` de forma predeterminada. Si no quiere inicializar la cola delta, no necesita enviar esta marca ni establecerla como verdadera. No establecer esta marca como verdadera resultará en una extracción de carga completa.

```
sapodata_df = glueContext.create_dynamic_frame.from_options(
    connection_type="SAPOData",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "ENABLE_CDC": "true"
    }, transformation_ctx=key)

# Extract the delta token from the last row of the DELTA_TOKEN column
```

```
delta_token_1 = your_logic_to_extract_delta_token(sapodata_df) # e.g.,
 D20241029164449_000370000
```

- El token delta extraído puede pasarse como opción para recuperar nuevos eventos.

```
sapodata_df_2 = glueContext.create_dynamic_frame.from_options(
    connection_type="SAPOData",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        // passing the delta token retrieved in the last run
        "DELTA_TOKEN": delta_token_1
    } , transformation_ctx=key)

# Extract the new delta token for the next run
delta_token_2 = your_logic_to_extract_delta_token(sapodata_df_2)
```

Tenga en cuenta que el último registro, en el que `DELTA_TOKEN` está presente, no es un registro transaccional del origen y solo existe con la finalidad de pasar el valor del token delta.

Además de `DELTA_TOKEN`, se devuelven los siguientes campos en cada fila del marco de datos.

- GLUE_FETCH_SQ: se trata de un campo de secuencia, generado a partir de la marca de tiempo de EPOC en el orden en que se recibió el registro, y es único para cada registro. Se puede utilizar si necesita conocer o establecer el orden de los cambios en el sistema de origen. Este campo solo estará presente para las entidades habilitadas para ODP.
- DML_STATUS: esto mostrará `UPDATED` para todos los registros recién insertados y actualizados a partir del origen y `DELETED` para los registros que se hayan eliminado del origen.

Para obtener más información sobre cómo gestionar el estado y reutilizar el token delta para recuperar los registros modificados a través de un ejemplo, consulte la sección Uso del script de administración de estado de SAP OData.

Invalidación del token Delta

Un token delta está asociado a la colección de servicios y a un usuario. Si se inicia una nueva extracción inicial con `“ENABLE_CDC” : “true”` para la misma colección de servicios y para el mismo usuario, el servicio OData de SAP invalidará todos los tokens delta anteriores emitidos como

resultado de una inicialización anterior. Invocar el conector con un token delta caducado provocará una excepción:

`Could not open data access via extraction API RODPS_REPL_ODP_OPEN`

Servicios OData (orígenes que no son ODP)

Carga completa

Para los sistemas que no son ODP (Aprovisionamiento de datos operativos), una carga completa implica extraer todo el conjunto de datos del sistema de origen y cargarlo en el sistema de destino. Dado que los sistemas que no son ODP no son compatibles de por sí con mecanismos avanzados de extracción de datos, como los deltas, el proceso es sencillo, pero puede requerir muchos recursos en función del tamaño de los datos.

Carga incremental

Para los sistemas o entidades que no admiten el ODP (Aprovisionamiento de datos operativos), la transferencia incremental de datos se puede gestionar manualmente mediante la implementación de un mecanismo basado en marcas de tiempo para seguir y extraer los cambios.

Transferencias incrementales basadas en marca temporal

Para las entidades no habilitadas para ODP (o para las entidades habilitadas para ODP que no usan la marca ENABLE_CDC), puede usar una opción `filteringExpression` en el conector para indicar el intervalo de `datetime` para el que se quiere recuperar los datos. Este método se basa en un campo de fecha y hora en los datos que representa cuándo se creó o modificó cada registro por última vez.

Ejemplo

Recuperar registros que se modificaron después de 2024-01-01T00:00:00.000

```
sapodata_df = glueContext.create_dynamic_frame.from_options(
    connection_type="SAPOData",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "filteringExpression": "LastChangeDateTime >= 2024-01-01T00:00:00.000"
    }, transformation_ctx=key)
```

Nota: En este ejemplo, `LastChangeDateTime` es el campo que representa cuándo se modificó por última vez cada registro. El nombre real del campo puede variar en función de la entidad específica de SAP OData.

Para obtener un nuevo subconjunto de datos en las siguientes ejecuciones, debe actualizar la opción `filteringExpression` con una nueva marca de tiempo. Normalmente, sería el valor máximo de la marca de tiempo de los datos recuperados anteriormente.

Ejemplo

```
max_timestamp = get_max_timestamp(sapodata_df)  # Function to get the max timestamp
 from the previous run
next_filtering_expression = f"LastChangeDateTime > {max_timestamp}"

# Use this next_filtering_expression in your next run
```

En la siguiente sección, proporcionaremos un enfoque automatizado para gestionar estas transferencias incrementales basadas en marcas de tiempo, lo que elimina la necesidad de actualizar manualmente la expresión de filtrado entre ejecuciones.

Escribir en SAP OData

En esta sección se describe cómo escribir datos en su servicio SAP OData mediante el conector de AWS Glue para SAP OData.

Requisitos previos

- Acceso a un servicio de SAP OData
- Un objeto de SAP OData EntitySet en el que le gustaría escribir. Necesitará el nombre del objeto.
- Credenciales de SAP OData válidas y una conexión válida
- Permisos adecuados, tal como se describe en las políticas de IAM

El conector de SAP OData admite dos operaciones de escritura:

- INSERT
- UPDATE

Al usar la operación de escritura UPDATE, debe proporcionar ID_FIELD_NAMES para especificar el campo de ID externo de los registros.

Ejemplo:

```
sapodata_write = glueContext.write_dynamic_frame.from_options(
    frame=frameToWrite,
    connection_type="sapodata",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "WRITE_OPERATION": "INSERT"
    }
```

Uso del script de administración de estado de SAP OData

Para utilizar el script de administración de estado de SAP OData en el trabajo de AWS Glue, haga lo siguiente:

- Descargue el script de gestión de estado: `s3://aws-blogs-artifacts-public/artifacts/BDB-4789/sap_odata_state_management.zip` desde el bucket público de Amazon S3.
- Cargue el script en un bucket de Amazon S3 al que el trabajo de AWS Glue tenga permiso de acceso.
- Referencia al script de su trabajo de AWS Glue: al crear o actualizar su trabajo de AWS Glue, pase la opción `'--extra-py-files'` para hacer referencia a la ruta del script en el bucket de Amazon S3. Por ejemplo: `--extra-py-files s3://your-bucket/path/to/sap_odata_state_management.py`
- Importe y use la biblioteca de administración de estados en los scripts del trabajo de AWS Glue.

Ejemplo de transferencias incrementales basadas en tokens Delta

A continuación, se muestra un ejemplo de cómo usar el script de administración de estados para transferencias incrementales basadas en token delta:

```
from sap_odata_state_management import StateManagerFactory, StateManagerType, StateType

# Initialize the state manager
state_manager = StateManagerFactory.create_manager(
    manager_type=StateManagerType.JOB_TAG,
    state_type=StateType.DELTA_TOKEN,
    options={
        "job_name": args['JOB_NAME'],
        "logger": logger
```

```
    }
)

# Get connector options (including delta token if available)
key = "SAPODataNode"
connector_options = state_manager.get_connector_options(key)

# Use the connector options in your Glue job
df = glueContext.create_dynamic_frame.from_options(
    connection_type="SAPOData",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "ENABLE_CDC": "true",
        **connector_options
    }
)

# Process your data here...

# Update the state after processing
state_manager.update_state(key, sapodata_df.toDF())
```

Ejemplo de transferencias incrementales basadas en marca temporal

A continuación, se muestra un ejemplo de cómo usar el script de administración de estados para transferencias incrementales basadas en token delta:

```
from sap_odata_state_management import StateManagerFactory, StateManagerType, StateType

# Initialize the state manager
state_manager = StateManagerFactory.create_manager(
    manager_type=StateManagerType.JOB_TAG,
    state_type=StateType.DELTA_TOKEN,
    options={
        "job_name": args['JOB_NAME'],
        "logger": logger
    }
)

# Get connector options (including delta token if available)
key = "SAPODataNode"
connector_options = state_manager.get_connector_options(key)
```

```
# Use the connector options in your Glue job
df = glueContext.create_dynamic_frame.from_options(
    connection_type="SAPOData",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "ENABLE_CDC": "true",
        **connector_options
    }
)

# Process your data here...

# Update the state after processing
state_manager.update_state(key, sapodata_df.toDF())
```

En ambos ejemplos, el script de administración del estado administra las complejidades del almacenamiento del estado (ya sea un token delta o una marca de tiempo) entre las ejecuciones de los trabajos. Recupera automáticamente el último estado conocido al obtener las opciones del conector y actualiza el estado después del procesamiento, lo que garantiza que cada trabajo que se ejecute solo procese datos nuevos o modificados.

Particiones para entidades que no sean ODP

En Apache Spark, el particionamiento se refiere a la forma en que los datos se dividen y distribuyen entre los nodos de trabajo de un clúster para su procesamiento paralelo. Cada partición es un fragmento lógico de datos que una tarea puede procesar de forma independiente. El particionamiento es un concepto fundamental en Spark que afecta directamente al rendimiento, la escalabilidad y la utilización de los recursos. Los trabajos de AWS Glue utilizan el mecanismo de particionamiento de Spark para dividir el conjunto de datos en fragmentos más pequeños (particiones) que se pueden procesar en paralelo en los nodos de trabajo del clúster. Tenga en cuenta que el particionamiento no se aplica a las entidades ODP.

Para obtener más información, consulte AWS GlueTrabajos de Spark y PySpark.

Requisitos previos

Un Objeto de SAP OData desde el cual desearía leer. Necesitará el nombre del objeto/EntitySet. Por ejemplo: `/sap/opu/odata/sap/API_SALES_ORDER_SRV/A_SalesOrder` .

Ejemplo

```
sapodata_read = glueContext.create_dynamic_frame.from_options(
    connection_type="SAPOData",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "/sap/opu/odata/sap/API_SALES_ORDER_SRV/A_SalesOrder"
    }, transformation_ctx=key)
```

Consultas de partición

Partición basada en campos

Puede proporcionar las opciones adicionales de Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` y `NUM_PARTITIONS` si quiere utilizar la simultaneidad en Spark. Con estos parámetros, la consulta original se dividiría en un número `NUM_PARTITIONS` de subconsultas que las tareas de Spark pueden ejecutar simultáneamente. Los campos Entero, Fecha y hora y Fecha admiten la partición basada en campos en el conector SAP OData.

- `PARTITION_FIELD`: el nombre del campo que se utilizará para particionar la consulta.
- `LOWER_BOUND`: un valor de límite inferior inclusivo del campo de partición elegido.

  En cualquier campo cuyo tipo de dato sea DateTime, se acepta el formato de marca de tiempo de Spark que se utiliza en las consultas de Spark SQL.

  Ejemplos de valores válidos: `"2000-01-01T00:00:00.000Z"`
- `UPPER_BOUND`: un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`: el número de particiones.
- `PARTITION_BY`: el tipo de particionamiento que se va a realizar, `FIELD` se debe pasar en caso de particionamiento basado en Campos.

Ejemplo

```
sapodata= glueContext.create_dynamic_frame.from_options(
    connection_type="sapodata",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "/sap/opu/odata/sap/SEPM_HCM_SCENARIO_SRV/EmployeeSet",
        "PARTITION_FIELD": "validStartDate"
        "LOWER_BOUND": "2000-01-01T00:00:00.000Z"
        "UPPER_BOUND": "2020-01-01T00:00:00.000Z"
```

```
        "NUM_PARTITIONS": "10",
        "PARTITION_BY": "FIELD"
    }, transformation_ctx=key)
```

Partición basada en registros

La consulta original se dividiría en un número NUM_PARTITIONS de subconsultas que las tareas de Spark pueden ejecutar simultáneamente.

La partición basada en registros solo se admite para entidades que no son de ODP, ya que la paginación en las entidades de ODP se admite a través del siguiente token o token de omisión.

- PARTITION_BY: el tipo de particionamiento que se va a realizar. COUNT se debe pasar en caso de particionamiento basado en registros.

Ejemplo

```
sapodata= glueContext.create_dynamic_frame.from_options(
    connection_type="sapodata",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "/sap/opu/odata/sap/SEPM_HCM_SCENARIO_SRV/EmployeeSet",
        "NUM_PARTITIONS": "10",
        "PARTITION_BY": "COUNT"
    }, transformation_ctx=key)
```

Limitaciones/Avisos

- Las entidades ODP no son compatibles con la partición basada en registros, ya que la paginación se gestiona mediante un token de omisión o token delta. En consecuencia, para la partición basada en registros, el valor predeterminado de maxConcurrency se establece en “null”, independientemente de la entrada del usuario.
- Cuando se aplican un límite y una partición, el límite prevalece sobre el particionamiento.

Opciones de conexión de SAP OData

Las siguientes son opciones de conexión para SAP OData:

- ENTITY_NAME(cadena): (obligatorio) se usa para lectura. El nombre del objeto en SAP OData.

Por ejemplo: /sap/opu/odata/sap/API_SALES_ORDER_SRV/A_SalesOrder

- API_VERSION(cadena): (opcional) Se usa para leer. Versión de la API de REST de SAP OData que quiere usar. Ejemplo: 2.0.
- SELECTED_FIELDS(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.

  Por ejemplo: SalesOrder
- FILTER_PREDICATE(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.

  Por ejemplo: `SalesOrder = "10"`
- QUERY(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.

  Por ejemplo: `SELECT * FROM /sap/opu/odata/sap/API_SALES_ORDER_SRV/A_SalesOrder`
- PARTITION_FIELD(cadena): se usa para leer. Campo que se utilizará para particionar la consulta.

  Por ejemplo: `ValidStartDate`
- LOWER_BOUND(cadena): se usa para leer. Un valor de límite inferior inclusivo del campo de partición elegido.

  Por ejemplo: `"2000-01-01T00:00:00.000Z"`
- UPPER_BOUND(cadena): se usa para leer. Un valor límite superior exclusivo del campo de partición elegido.

  Por ejemplo: `"2024-01-01T00:00:00.000Z"`
- NUM_PARTITIONS(entero): predeterminado: 1. Se usa para leer. Número de particiones para leer.
- INSTANCE_URL(cadena): la URL del host de la aplicación de la instancia de SAP.

  Por ejemplo: `https://example-externaldata.sierra.aws.dev`
- SERVICE_PATH(cadena): la ruta del servicio de la aplicación de la instancia de SAP.

  Por ejemplo: `/sap/opu/odata/iwfnd/catalogservice;v=2`
- CLIENT_NUMBER(cadena): el número de cliente de la aplicación de la instancia de SAP.

  Por ejemplo: 100

- PORT_NUMBER(cadena). Valor predeterminado: el número de puerto de la aplicación de la instancia de SAP.

  Por ejemplo: 443

- LOGON_LANGUAGE(cadena): idioma de inicio de sesión de la aplicación de instancias de SAP.

  Por ejemplo: EN

- ENABLE_CDC(cadena): define si se debe ejecutar un trabajo con CDC habilitado, es decir, con el seguimiento de los cambios.

  Por ejemplo: True/False

- DELTA_TOKEN(cadena): ejecuta una extracción de datos incremental basada en el token Delta válido proporcionado.

  Por ejemplo: D20241107043437_000463000

- PAGE_SIZE(entero): define el tamaño de la página para consultar los registros. El tamaño de página predeterminado es 50 000. Cuando se especifica un tamaño de página, SAP devuelve solo el número definido de registros por llamada a la API, en lugar del conjunto de datos completo. El conector seguirá proporcionando el número total de registros y gestionará la paginación utilizando el tamaño de página que especificó. Si necesita un tamaño de página mayor, puede elegir cualquier valor de hasta 500 000, el cual es el máximo permitido. Se ignorará cualquier tamaño de página especificado superior a 500 000. En su lugar, el sistema utilizará el tamaño de página máximo permitido. Puede especificar el tamaño de página en la interfaz de usuario de AWS Glue Studio agregando una opción de conexión PAGE_SIZE con el valor que desee.

  Por ejemplo: 20000

Detalles de la entidad y del campo de SAP OData

Entidad	Tipo de datos:	Operadores admitidos
Tablas (entidades dinámicas)	Cadena	=, !=, >, >=, <, <=, BETWEEN, LIKE
	Entero	=, !=, >, >=, <, <=, BETWEEN, LIKE

Entidad	Tipo de datos:	Operadores admitidos
	Largo	=, !=, >, >=, <, <=, BETWEEN, LIKE
	Doble	=, !=, >, >=, <, <=, BETWEEN, LIKE
	Date	=, !=, >, >=, <, <=, BETWEEN, LIKE
	DateTime	=, !=, >, >=, <, <=, BETWEEN, LIKE
	Booleano	=, !=
	Struct	=, !=, >, >=, <, <=, BETWEEN, LIKE

Conexión a SendGrid

SendGrid es una plataforma de comunicación con el cliente para correos electrónicos transaccionales y de marketing.

- El conector de SendGrid ayuda a crear y administrar listas de contactos y a crear campañas de marketing por correo electrónico.
- SendGrid permite a empresas en línea, organizaciones sin ánimo de lucro y otras entidades en línea crear y enviar mensajes de correo electrónico de marketing dirigidos a grandes audiencias, así como supervisar la interacción con dichos mensajes.

Temas

- Compatibilidad de AWS Glue con SendGrid
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de SendGrid
- Configuración de las conexiones a SendGrid
- Cómo leer de entidades de SendGrid

- Opciones de conexión a SendGrid
- Limitaciones de SendGrid

Compatibilidad de AWS Glue con SendGrid

AWS Glue admite SendGrid de la siguiente manera:

¿Es compatible como origen?

Sí. Puede usar los trabajos de ETL de AWS Glue para consultar datos de SendGrid.

¿Es compatible como destino?

No.

Versiones de la API de SendGrid compatibles

Se admiten las siguientes versiones de la API de SendGrid:

- v3

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS IAM necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
```

```
      "Resource": "*"
    }
  ]
}
```

Si no desea utilizar el método anterior, puede utilizar las siguientes políticas de IAM administradas:

- AWSGlueServiceRole: da acceso a recursos que precisan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: otorga acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la Consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de SendGrid

Antes de poder utilizar AWS Glue para transferir datos desde SendGrid, deberá cumplir estos requisitos:

Requisitos mínimos

Los requisitos mínimos son los siguientes:

- Tener una cuenta de SendGrid con una clave de API.
- La cuenta de SendGrid debe tener acceso a la API con una licencia válida.

Si cumple estos requisitos, estará listo para conectar AWS Glue a la cuenta de SendGrid. Para conexiones típicas, no necesita hacer nada más en SendGrid.

Configuración de las conexiones a SendGrid

SendGrid admite la autenticación personalizada.

Para consultar la documentación pública de SendGrid sobre la generación de las claves de API necesarias para la autenticación personalizada, consulte Autenticación.

Para configurar una conexión a SendGrid:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles:
   a. En el caso de las aplicaciones conectadas administradas por el cliente, el secreto debe contener el secreto del consumidor de la aplicación conectada con *api_key* como clave.
   b. Nota: Debe crear un secreto para las conexiones en AWS Glue.

1. En AWS Glue Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:
   a. Al seleccionar un Tipo de conexión, elija SendGrid.
   b. Proporcione la `INSTANCE_URL` de la instancia de SendGrid a la que se quiere conectar.
   c. Seleccione el rol de AWS IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

      JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

   d. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.

e. Seleccione las opciones de red si quiere usar su red.

2. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.

Cómo leer de entidades de SendGrid

Requisito previo

Un objeto de SendGrid desde el que desea leer. Necesitará el nombre del objeto, como `lists`, `singlesends` o `segments`.

Entidades compatibles como origen:

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Listas	No	Sí	No	Sí	No
Envíos únicos	Sí	Sí	No	Sí	No
Estadísticas y automatizaciones de campañas de marketing	Sí	Sí	No	Sí	No
Estadísticas de la campaña de marketing: envíos únicos	Sí	Sí	No	Sí	No
Segmentos	Sí	No	No	Sí	No
Contactos	Sí	No	No	Sí	No
Categoría	No	No	No	Sí	No
Estadísticas	Sí	No	No	Sí	No

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Anular la suscripción de grupos	Sí	No	No	Sí	No

Ejemplo:

```
sendgrid_read = glueContext.create_dynamic_frame.from_options(
    connection_type="sendgrid",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "lists",
        "API_VERSION": "v3",
        "INSTANCE_URL": "instanceUrl"
    }
```

Detalles de la entidad y el campo de SendGrid:

Entidades con metadatos estáticos:

Entidad	Campo	Tipo de datos:	Operadores admitidos	
Listas	id	Cadena	N/A	
	nombre	Cadena	N/A	
	contact_count	Entero	N/A	
	_metadata	Struct	N/A	
Envíos únicos	id	Cadena	N/A	
	nombre	Cadena	EQUAL_TO	
	abtest	Struct	N/A	
	status	Cadena	EQUAL_TO	

Entidad	Campo	Tipo de datos:	Operadores admitidos	
	categories	Enumeración	EQUAL_TO	
	send_at	Cadena	N/A	
	is_abtest	Booleano	N/A	
	updated_at	Cadena	N/A	
	created_at	Cadena	N/A	
	canales	Enumeración	N/A	
Estadísticas y automatiz aciones de campañas de marketing	id	Cadena	N/A	
	agregación	Cadena	N/A	
	step_id	Cadena	N/A	
	stats	Struct	N/A	
	automation_ids	Enumeración	EQUAL_TO	
Estadísticas de la campaña de marketing: envíos únicos	id	Cadena	N/A	
	ab_variation	Cadena	N/A	
	ab_phase	Cadena	N/A	
	agregación	Cadena	N/A	
	stats	Struct	N/A	
	singlesend_ids	Enumeración	EQUAL_TO	
Segmentos	id	Cadena	N/A	
	nombre	Cadena	N/A	
	query_version	Cadena	N/A	

Entidad	Campo	Tipo de datos:	Operadores admitidos	
	contacts_count	Entero	N/A	
	sample_updated_at	Cadena	N/A	
	next_sample_update	Cadena	N/A	
	created_at	Cadena	N/A	
	updated_at	Cadena	N/A	
	parent_list_id	Cadena	N/A	
	status	Struct	N/A	
	parent_list_ids	Cadena	EQUAL_TO	
	no_parent_list_id	Booleano	EQUAL_TO	
Contactos	id	Cadena	N/A	
	first_name	Cadena	N/A	
	last_name	Cadena	N/A	
	unique_name	Cadena	N/A	
	correo electrónico	Cadena	N/A	
	alternate_emails	Enumeración	N/A	
	address_line_1	Cadena	N/A	
	address_line_2	Cadena	N/A	
	ciudad	Cadena	N/A	

Entidad	Campo	Tipo de datos:	Operadores admitidos	
	state_province_region	Cadena	N/A	
	país	Cadena	N/A	
	postal_code	Cadena	N/A	
	phone_number	Cadena	N/A	
	whatsapp	Cadena	N/A	
	línea	Cadena	N/A	
	facebook	Cadena	N/A	
	list_ids	Enumeración	N/A	
	custom_fields	Struct	N/A	
	created_at	Cadena	N/A	
	updated_at	Cadena	N/A	
	_metadata	Struct	N/A	
	event_timestamp	DateTime	BETWEEN	
Categoría	categories	Enumeración	N/A	
Estadísticas	date	Cadena	N/A	
	stats	Enumeración	N/A	
	start_date	DateTime	EQUAL_TO, BETWEEN	
	aggregated_by	Cadena	EQUAL_TO	

Entidad	Campo	Tipo de datos:	Operadores admitidos	
Anular la suscripción de grupos	id	Entero	EQUAL_TO	
	nombre	Cadena	N/A	
	Descripción	Cadena	N/A	
	last_email_sent_at	Entero	N/A	
	is_default	Booleano	N/A	
	anulaciones de suscripciones	Entero	N/A	

> **Note**
>
> Los tipos de datos de estructura y enumeración se convierten en cadenas, y los de fecha y hora se convierten en marcas de tiempo en la respuesta de los conectores.

Consultas de partición

SendGrid no admite la partición basada en filtros ni la partición basada en registros.

Opciones de conexión a SendGrid

Las siguientes son opciones de conexión para SendGrid:

- `ENTITY_NAME`(cadena): (obligatorio) se usa para lectura. El nombre del objeto en SendGrid.
- `API_VERSION`(cadena): (obligatorio) se usa para lectura. Versión de la API de REST de SendGrid que desea usar.
- `INSTANCE_URL`(cadena): (obligatorio) se usa para lectura. Una URL de instancia de SendGrid válida.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.

- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.

Limitaciones de SendGrid

Las siguientes son limitaciones o notas correspondientes a SendGrid:

- La extracción incremental solo es compatible con la entidad Estadísticas en el campo `start_date` y con la entidad Contacto en el campo `event_timestamp`.
- La paginación solo es compatible con las entidades Estadísticas de campaña de marketing (automatizaciones), Estadísticas de campaña de marketing (envíos únicos), Envíos únicos y Listas.
- En la entidad Estadísticas, `start_date` es un parámetro de filtro obligatorio.
- Una clave de API con acceso restringido no puede admitir el acceso de lectura para la API de correo electrónico y las entidades de estadísticas. Utilice una clave de API con acceso pleno. Para obtener más información, consulte Información general de la API.

Conexión a ServiceNow

ServiceNow es una plataforma SaaS basada en la nube para automatizar los flujos de trabajo de administración de TI. La plataforma ServiceNow se integra fácilmente con otras herramientas, lo que permite a los usuarios administrar proyectos, equipos e interacciones con los clientes mediante una variedad de aplicaciones y complementos. Como usuario de ServiceNow, puede conectar AWS Glue a su cuenta de ServiceNow. Tras ello, podrá utilizar ServiceNow como origen de datos en los trabajos de ETL. Ejecute estos trabajos para transferir datos entre ServiceNow y los servicios de AWS u otras aplicaciones compatibles.

Temas

- Compatibilidad de AWS Glue con ServiceNow
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de ServiceNow
- Configuración de conexiones a ServiceNow
- Lectura de entidades de ServiceNow
- Opciones de conexión a ServiceNow
- Limitaciones y notas del conector de ServiceNow

Compatibilidad de AWS Glue con ServiceNow

AWS Glue es compatible con ServiceNow de la siguiente manera:

¿Es compatible como origen?

Sí. Puede utilizar los trabajos de ETL de AWS Glue para consultar datos de ServiceNow.

¿Es compatible como destino?

No.

Versiones de la API de ServiceNow compatibles

Las siguientes versiones de la API de ServiceNow son compatibles:

- v2

Para conocer la compatibilidad de entidades por versión específica, consulte Entidades admitidas para el origen.

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS IAM necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
```

```
  ]
}
```

Si no desea utilizar el método anterior, puede utilizar las siguientes políticas de IAM administradas:

- AWSGlueServiceRole: da acceso a recursos que precisan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: otorga acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la Consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de ServiceNow

Antes de poder utilizar AWS Glue para transferir datos desde ServiceNow, deberá cumplir estos requisitos:

Requisitos mínimos

Los requisitos mínimos son los siguientes:

- Tener una cuenta de ServiceNow con correo electrónico y contraseña. Para obtener más información, consulte Creación de una cuenta de ServiceNow.
- La cuenta de ServiceNow debe estar habilitada para el acceso de API. La API de ServiceNow se puede utilizar sin ningún costo adicional.

Si cumple estos requisitos, estará listo para conectar AWS Glue a la cuenta de ServiceNow.

Creación de una cuenta de ServiceNow

Para crear una cuenta de ServiceNow:

1. Diríjase a la página de registro de servicenow.com, introduzca sus datos y haga clic en Continuar.

2. Una vez que reciba un código de verificación en su correo electrónico registrado, introdúzcalo y seleccione Verificar.
3. Configure la autenticación multifactor u omita este paso.

Se crea la cuenta y ServiceNow muestra su perfil.

Crear una instancia de desarrollador de ServiceNow

Solicite una instancia de desarrollador después de iniciar sesión en ServiceNow.

1. En la página de inicio de sesión de ServiceNow, introduzca las credenciales de su cuenta.
2. Seleccione el Programa para desarrolladores de ServiceNow.

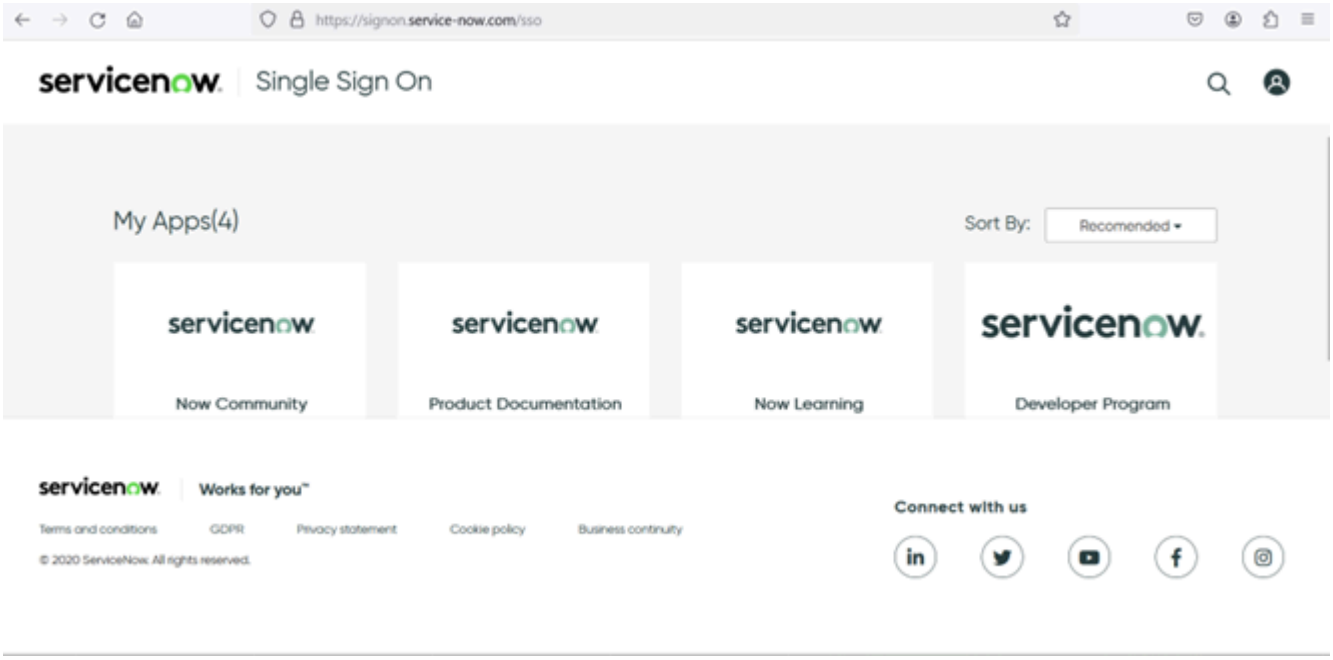

3. Seleccione Solicitar instancia en la esquina superior derecha.
4. Introduzca sus responsabilidades laborales. Indique que está de acuerdo con las condiciones de uso y seleccione Finalizar la configuración.
5. Una vez creada la instancia, anote la URL y las credenciales de la instancia.

Recuperar credenciales de autenticación básica

Para recuperar las credenciales de autenticación básica para una cuenta gratuita:

1. En la página de inicio de sesión de ServiceNow, introduzca las credenciales de su cuenta.

2. En la página de inicio, elija la sección de edición de perfil (esquina superior derecha) y seleccione Administrar contraseña de instancia.
3. Recupere las credenciales de inicio de sesión, como el nombre de usuario, la contraseña y la URL de la instancia.

> **Note**
>
> Si está habilitada la MFA para la cuenta, añada el token de la MFA al final de la contraseña del usuario en la autenticación básica: <nombredeusuario>:<contraseña><token de MFA>

Para obtener más información, consulte Compilación de aplicaciones en la documentación de ServiceNow.

Creación de credenciales de OAuth 2.0

Para usar OAuth2.0 en el conector de ServiceNow, debe crear un cliente entrante para generar el ID de cliente y el secreto del cliente:

1. En la página de inicio de sesión de ServiceNow, introduzca las credenciales de su cuenta.
2. En la página de inicio, elija Iniciar compilación.
3. En la página de App Engine Studio, busque Registro de aplicaciones.
4. Seleccione Nuevo en la esquina superior derecha.
5. Elija la opción Crear un punto de conexión de la API de OAuth para clientes externos.
6. Realice los cambios necesarios en la configuración de OAuth y seleccione Actualizar.

   Ejemplo de URL de redirección: https://us-east-1.console.aws.amazon.com/gluestudio/oauth
7. Seleccione la aplicación cliente de OAuth recién creada para recuperar el ID de cliente y el secreto del cliente.
8. Guarde el ID de cliente y el secreto del cliente para su posterior procesamiento.

Para configurar OAuth en una cuenta de desarrollador que no sea de producción:

1. Use el tema Crear un perfil de autenticación de la documentación de ServiceNow para crear un perfil de autenticación.

2. En el perfil de autenticación de OAuth, seleccione Tipo como OAuth y seleccione el cliente entrante creado anteriormente para configurar la Entidad de OAuth.
3. Si hay varios clientes, debe crear varios perfiles de autenticación para establecer la entidad OAuth requerida en el perfil de autenticación.
4. Si no se configuró, cree una política de acceso a la API de REST para dar acceso a la API TABLE. Consulte Crear una política de acceso a la API de REST.

Configuración de conexiones a ServiceNow

El tipo de concesión determina cómo AWS Glue se comunica con ServiceNow para solicitar el acceso a los datos. Su elección afecta a los requisitos que debe cumplir antes de crear la conexión. ServiceNow solo admite el tipo de concesión AUTHORIZATION_CODE para OAuth 2.0.

- Este tipo de concesión se considera un OAuth de “tres vías”, ya que se basa en redirigir a los usuarios a un servidor de autorización externo para autenticar al usuario. Se utiliza para crear conexiones a través de la consola de AWS Glue. La consola de AWS Glue redirigirá al usuario a ServiceNow, donde deberá iniciar sesión y otorgar a AWS Glue los permisos solicitados para acceder a la instancia de ServiceNow.
- Los usuarios aún pueden optar por crear una aplicación conectada propia en ServiceNow y proporcionar un identificador de cliente y un secreto de cliente propios al crear conexiones a través de la consola de AWS Glue. En este escenario, aún se abrirá ServiceNow para iniciar sesión y autorizar a AWS Glue para que acceda a sus recursos.
- Este tipo de concesión da como resultado un token de actualización y un token de acceso. El token de acceso es de corta duración y se puede actualizar automáticamente sin la interacción del usuario mediante el token de actualización.
- Para consultar la documentación pública de ServiceNow sobre la creación de una aplicación conectada para el flujo Authorization Code OAuth, consulte Configuración de OAuth.

Para configurar una conexión a ServiceNow:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles:
   a. Para la autenticación básica, el secreto debe contener el secreto del consumidor de la aplicación conectada con `USERNAME` y `PASSWORD` como clave.

b. Para un tipo de concesión de código de autorización, el secreto debe contener el secreto del consumidor de la aplicación conectada con `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET` como clave.

c. Nota: Debe crear un secreto por cada conexión en AWS Glue.

2. En AWS Glue Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:

a. Al seleccionar el Tipo de conexión, elija ServiceNow.

b. Proporcione el valor INSTANCE_URL de la instancia de ServiceNow a la que se desea conectar.

c. Seleccione el rol de AWS IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

d. Seleccione el Tipo de autenticación que quiere utilizar para esta conexión en AWS Glue.

i. Autenticación básica: este tipo de autenticación funciona bien en escenarios de automatización, ya que permite utilizar el nombre de usuario y la contraseña desde el comienzo con los permisos de un usuario en particular en la instancia de ServiceNow. AWS Glue puede usar el nombre de usuario y la contraseña para autenticar las API de ServiceNow. Introduzca las siguientes entradas solo en el caso de la autenticación básica: `Username` y `Password`.

ii. OAuth 2: ingrese las siguientes entradas solo en el caso de OAuth 2: `ClientId`, `ClientSecret`, `Authorization URL` y `Authorization Token URL`.

e. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.

f. Seleccione las opciones de red si quiere usar su red.

3. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.

Lectura de entidades de ServiceNow

Requisito previo

Un objeto de tablas de ServiceNow desde el cual desearía leer. Necesitará el nombre del objeto, como pa_bucket o incident.

Ejemplo:

```
servicenow_read = glueContext.create_dynamic_frame.from_options(
    connection_type="servicenow",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "pa_buckets",
        "API_VERSION": "v2"
        "instanceUrl": "https://<instance-name>.service-now.com"
    }
)
```

Detalles de la entidad y del campo de ServiceNow:

Para las siguientes entidades, ServiceNow proporciona puntos de conexión para obtener los metadatos de forma dinámica, de modo que la compatibilidad del operador se capture según el tipo de datos de cada entidad.

Entidad	Tipo de datos:	Operadores admitidos
Tablas (entidades dinámicas)	Entero	=, !=, <, <=, >, >=, BETWEEN
	BigDecimal	=, !=, <, <=, >, >=, BETWEEN
	Flotante	=, !=, <, <=, >, >=, BETWEEN

Entidad	Tipo de datos:	Operadores admitidos
	Largo	=, !=, <, <=, >, >=, BETWEEN
	Date	=, !=, <, <=, >, >=, BETWEEN
	DateTime	=, !=, <, <=, >, >=, BETWEEN
	Booleano	=, !=
	Cadena	=, !=, <, <=, >, >=, BETWEEN, LIKE
	Struct	N/A

> **Note**
>
> El tipo de datos de estructura se convierte en un tipo de datos de cadena en la respuesta del conector.

> **Note**
>
> `DML_STATUS` es un atributo adicional definido por el usuario que se utiliza para hacer un seguimiento de los registros CREADOS o ACTUALIZADOS.

Consultas de partición

Partición basada en campos:

Puede proporcionar las opciones adicionales de Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` y `NUM_PARTITIONS` si quiere utilizar la simultaneidad en Spark. Con estos parámetros, la consulta original se dividiría en un número `NUM_PARTITIONS` de subconsultas que las tareas de Spark pueden ejecutar simultáneamente.

Nombre de la entidad	Campos de partición	Tipo de datos:
Entidad dinámica	sys_mod_count	Entero
	sys_created_on, sys_updated_on	DateTime

- `PARTITION_FIELD`: el nombre del campo que se utilizará para particionar la consulta.
- `LOWER_BOUND`: un valor de límite inferior inclusivo del campo de partición elegido.

  En el campo DateTime, aceptamos el formato de marca de tiempo de Spark que se utiliza en las consultas de Spark SQL.

  Ejemplos de valor válido:

  ```
  "2024-01-30T06:47:51.000Z"
  ```
- `UPPER_BOUND`: un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`: el número de particiones.

En la tabla siguiente, se describen los detalles de compatibilidad de campos de particiones de entidades:

Ejemplo:

```
servicenow_read = glueContext.create_dynamic_frame.from_options(
    connection_type="servicenow",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "pa_buckets",
        "API_VERSION": "v2",
        "instanceUrl": "https://<instance-name>.service-now.com"
        "PARTITION_FIELD": "sys_created_on"
        "LOWER_BOUND": "2024-01-30T06:47:51.000Z"
        "UPPER_BOUND": "2024-06-30T06:47:51.000Z"
        "NUM_PARTITIONS": "10"
    }
```

Partición basada en registros:

Puede proporcionar la opción adicional NUM_PARTITIONS de Spark si quiere usar la simultaneidad en Spark. Con estos parámetros, la consulta original se divide en un número NUM_PARTITIONS de subconsultas que las tareas de Spark pueden ejecutar simultáneamente.

En la partición basada en registros, el número total de registros presentes se consulta desde la API de ServiceNow y se divide por el número proporcionado NUM_PARTITIONS. A continuación, cada subconsulta obtiene simultáneamente el número de registros resultante.

- NUM_PARTITIONS: el número de particiones.

Ejemplo:

```
servicenow_read = glueContext.create_dynamic_frame.from_options(
    connection_type="servicenow",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "pa_buckets",
        "API_VERSION": "v2",
        "instanceUrl": "https://<instance-name>.service-now.com"
        "NUM_PARTITIONS": "2"
    }
```

Opciones de conexión a ServiceNow

Estas son las opciones para establecer la conexión con ServiceNow:

- ENTITY_NAME(cadena): (obligatorio) se usa para lectura. El nombre del objeto en ServiceNow.
- API_VERSION(cadena): (obligatorio) se usa para lectura. Versión de la API de REST de ServiceNow que desea usar. Por ejemplo: v1,v2,v3,v4.
- SELECTED_FIELDS(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- FILTER_PREDICATE(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- QUERY(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.
- PARTITION_FIELD(cadena): se usa para leer. Campo que se utilizará para particionar la consulta.
- LOWER_BOUND(cadena): se usa para leer. Un valor de límite inferior inclusivo del campo de partición elegido. Por ejemplo: 2024-01-30T06:47:51.000Z.

- UPPER_BOUND(cadena): se usa para leer. Un valor límite superior exclusivo del campo de partición elegido. Por ejemplo: 2024-06-30T06:47:51.000Z.
- NUM_PARTITIONS(entero): predeterminado: 1. Se usa para leer. Número de particiones para leer. Por ejemplo, 10.
- INSTANCE_URL(cadena): (obligatorio) una URL de instancia de ServiceNow válida con el formato https://<nombre-de-instancia>.servicenow.com.
- PAGE_SIZE(entero): define el tamaño de la página para consultar los registros. El tamaño de página predeterminado es 1000. Cuando se especifica un tamaño de página, ServiceNow devuelve solo el número definido de registros por llamada a la API, en lugar del conjunto de datos completo. El conector seguirá proporcionando el número total de registros y gestionará la paginación utilizando el tamaño de página que especificó. Si necesita un tamaño de página mayor, puede elegir cualquier valor de hasta 10 000, que es el máximo permitido. Se ignorará cualquier tamaño de página especificado superior a 10 000. En su lugar, el sistema utilizará el tamaño de página máximo permitido. Puede especificar el tamaño de página en la interfaz de usuario de AWS Glue Studio agregando una opción de conexión PAGE_SIZE con el valor que desee. Por ejemplo, 5000.

Limitaciones y notas del conector de ServiceNow

Las siguientes son limitaciones o notas del conector de ServiceNow:

- Según la documentación de SaaS, sys_created_on, sys_updated_on y sys_mod_count son campos generados por el sistema. El conector se basa en las API de SaaS para proporcionar estos campos en el cuerpo de la respuesta.
  - Si SaaS no genera estos campos para ninguna entidad, no se puede admitir la partición basada en filtros.
- Si las API de SaaS no devuelven los campos sys_created_on y sys_updated_on de la respuesta, DML_STATUS no se pueden calcular.
- Mejore el rendimiento y la eficiencia de lectura
  - El conector ServiceNow ahora clasifica automáticamente los registros en orden ascendente por el campo sys_id (debe estar presente en los metadatos) cuando el usuario no especifica ninguna cláusula ORDER BY. En este caso, los registros se paginarán mediante la nueva paginación optimizada basada en conjuntos de claves.

- Si se especifica la cláusula ORDER BY, no se utilizará la nueva optimización y los registros se obtendrán mediante el método existente (paginación definida por el usuario con Order By y basada en Offset-Limit).

Conexión a Slack en AWS Glue Studio

Slack es una aplicación de comunicación empresarial que permite a los usuarios enviar mensajes y archivos adjuntos a través de varios canales públicos y privados. Si es usuario de Slack, puede conectar AWS Glue a su cuenta de Slack. Luego, puede usar Slack como origen de datos en sus trabajos de ETL. Ejecute estos trabajos para transferir datos entre Slack y los servicios de AWS u otras aplicaciones compatibles.

Temas

- Compatibilidad de AWS Glue con Slack
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de Slack
- Configuración de las conexiones de Slack
- Lectura desde entidades de Slack
- Opciones de conexión de Slack
- Limitaciones
- Creación de una nueva cuenta de Slack y configuración de la aplicación cliente

Compatibilidad de AWS Glue con Slack

AWS Glue es compatible con Slack de la siguiente manera:

¿Es compatible como origen?

Sí. Puede usar los trabajos de ETL de AWS Glue para consultar datos de Slack.

¿Es compatible como destino?

No.

Versiones de la API de Slack compatibles

Slack API v2.

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de IAM necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

También puede usar las siguientes políticas de IAM administradas para permitir el acceso:

- AWSGlueServiceRole: concede acceso a los recursos que necesitan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, Amazon CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: concede acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de Slack

Antes de poder utilizar AWS Glue para transferir datos hacia o desde Slack, debe cumplir estos requisitos:

Requisitos mínimos

- Debe tener una cuenta de Slack. Para obtener más información, consulte Creación de una nueva cuenta de Slack y configuración de la aplicación cliente.

Si cumple estos requisitos, lo tendrá todo listo para conectar AWS Glue a su cuenta de Slack.

Configuración de las conexiones de Slack

Slack admite el tipo de concesión `AUTHORIZATION_CODE` para OAuth 2.

Este tipo de concesión se considera un OAuth “de tres vías”, ya que se basa en redirigir a los usuarios al servidor de autorización externo para autenticar al usuario. Se utiliza para crear conexiones a través de la consola de AWS Glue. La consola de AWS Glue redirigirá al usuario a Slack, donde deberá iniciar sesión y permitir a AWS Glue que los permisos solicitados accedan a su instancia de Slack.

Los usuarios aún pueden optar por crear su propia aplicación conectada en Slack y proporcionar su propio ID y secreto de cliente al crear conexiones a través de la consola de AWS Glue. En este escenario, aún se abrirá Slack para iniciar sesión y autorizar a AWS Glue para que acceda a sus recursos.

Este tipo de concesión da como resultado un token de actualización y un token de acceso. El token de acceso caduca una hora después de su creación. Se puede obtener un nuevo token de acceso mediante el token de actualización.

Para obtener más información sobre cómo crear una aplicación conectada para el flujo de OAuth con código de autorización, consulte Slack API.

Para configurar una conexión de Slack, haga lo siguiente:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles. Debe crear un secreto para la conexión en AWS Glue.

a. En el caso de una aplicación conectada administrada por el cliente, el secreto debe contener el secreto del consumidor de la aplicación conectada con la clave `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET`.

2. En AWS Glue Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:

   a. Al seleccionar un Tipo de conexión, seleccione Slack.

   b. Proporcione el entorno de Slack.

   c. Seleccione el rol de IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

      JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

   d. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.

   e. Seleccione las opciones de red si quiere usar su red.

3. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.

Lectura desde entidades de Slack

Requisitos previos

- Un objeto de Slack desde el que desea leer.

Entidades compatibles

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite Partición
conversaciones	Sí	Sí	No	Sí	Sí

Ejemplo

```
slack_read = glueContext.create_dynamic_frame.from_options(
    connection_type="slack",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "conversations/C058W38R5J8"
    }
)
```

Detalles de la entidad y el campo de Slack

Entidad	Campo	Tipo de datos	Operadores admitidos
conversaciones	attachments	Enumeración	N/D
conversaciones	bot_id	Cadena	N/D
conversaciones	blocks	Enumeración	N/D
conversaciones	client_msg_id	Cadena	N/D
conversaciones	is_starred	Booleano	N/D
conversaciones	last_read	Cadena	N/D
conversaciones	latest_reply	Cadena	N/D
conversaciones	reactions	Enumeración	N/D

Entidad	Campo	Tipo de datos	Operadores admitidos
conversaciones	replies	Enumeración	N/D
conversaciones	reply_count	Entero	N/D
conversaciones	reply_users	Enumeración	N/D
conversaciones	reply_users_count	Entero	N/D
conversaciones	subscribed	Booleano	N/D
conversaciones	subtype	Cadena	N/D
conversaciones	texto	Cadena	N/D
conversaciones	team	Cadena	N/D
conversaciones	thread_ts	Cadena	N/D
conversaciones	ts	Cadena	EQUAL_TO, BETWEEN, LESS_THAN , LESS_THAN _OR_EQUAL_TO, GREATER_T HAN, GREATER_T HAN_OR_EQUAL_TO
conversaciones	type	Cadena	N/D
conversaciones	usuario	Cadena	N/D
conversaciones	inviter	Cadena	N/D
conversaciones	root	Struct	N/D
conversaciones	is_locked	Booleano	N/D
conversaciones	files	Enumeración	N/D

Entidad	Campo	Tipo de datos	Operadores admitidos
conversaciones	sala	Struct	N/D
conversaciones	carga	Booleano	N/D
conversaciones	display_as_bot	Booleano	N/D
conversaciones	channel	Cadena	N/D
conversaciones	no_notifications	Booleano	N/D
conversaciones	permalink	Cadena	N/D
conversaciones	pinned_to	Enumeración	N/D
conversaciones	pinned_info	Struct	N/D
conversaciones	edited	Struct	N/D
conversaciones	app_id	Cadena	N/D
conversaciones	bot_profile	Struct	N/D
conversaciones	metadatos	Struct	N/D

Consultas de partición

Puede proporcionar las opciones adicionales de Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` y `NUM_PARTITIONS` si quiere usar la simultaneidad en Spark. Con estos parámetros, la consulta original se dividiría en un número `NUM_PARTITIONS` de subconsultas que las tareas de Spark pueden ejecutar simultáneamente.

- `PARTITION_FIELD`: el nombre del campo que se usará para particionar la consulta.
- `LOWER_BOUND`: un valor de límite inferior inclusivo del campo de partición elegido.

  Para la fecha, aceptamos el formato de fecha de Spark que se usa en las consultas de Spark SQL. Ejemplo de valor válido: `"2024-07-01T00:00:00.000Z"`.
- `UPPER_BOUND`: un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`: el número de particiones.

Los detalles de compatibilidad del campo de particionamiento por entidad se muestran en la siguiente tabla.

Nombre de la entidad	Campo de partición	Tipo de datos
conversaciones	ts	Cadena

Ejemplo

```
slack_read = glueContext.create_dynamic_frame.from_options(
    connection_type="slack",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "conversations/C058W38R5J8",
        "PARTITION_FIELD": "ts"
        "LOWER_BOUND": "2022-12-01T00:00:00.000Z"
        "UPPER_BOUND": "2024-09-23T15:00:00.000Z"
        "NUM_PARTITIONS": "2"
    }
)
```

Opciones de conexión de Slack

Las siguientes son opciones de conexión para Slack:

- `ENTITY_NAME`(cadena): (obligatorio) se usa para lectura. El nombre de entidad compatible. Ejemplo: `conversations/C058W38R5J8`.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Campos que quiere seleccionar para el objeto.
- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.
- `NUM_PARTITIONS`(entero): predeterminado: 1. Se usa para leer. Número de particiones para leer.

Limitaciones

Las siguientes son limitaciones para el conector de Slack:

- No se admite la partición basada en registros, ya que el conector no proporciona ningún medio para obtener el número total de registros (mensajes) disponibles en una conversación determinada.

Creación de una nueva cuenta de Slack y configuración de la aplicación cliente

Creación de una cuenta de Slack

1. Abra la página de inicio de Slack para crear una cuenta.
2. Elija REGISTRARSE CON UNA DIRECCIÓN DE CORREO ELECTRÓNICO. Escriba su ID de correo electrónico y elija Continuar.
3. Ingrese el código de seis caracteres enviado a su dirección de correo electrónico y se abrirá la página para crear un espacio de trabajo o unirse a uno existente.
4. Seleccione Crear un espacio de trabajo para crear un espacio de trabajo nuevo. Se abrirá una página para que responda algunas preguntas como parte del proceso de configuración.
   - Nombre de la empresa
   - Su nombre
   - Adición de compañeros por correo electrónico
   - ¿En qué trabaja su equipo? (Este será el nombre del canal)
5. Rellene los campos de entrada de estas preguntas y continúe. Su cuenta ya está lista para su uso.

Creación de una aplicación para desarrolladores de Slack

1. Inicie sesión en su cuenta de Slack e inicie sesión en su espacio de trabajo de Slack.
2. En el menú del espacio de trabajo, seleccione Herramientas y configuración y, a continuación, seleccione Administrar aplicaciones.
3. En el menú Directorio de aplicaciones de Slack, seleccione Crear.
4. En la página Sus aplicaciones, seleccione Crear una aplicación.
5. En la página Crear una aplicación, seleccione Desde cero.
6. En el cuadro de diálogo Asignar nombre a la aplicación y elegir el espacio de trabajo que se abre, agregue un nombre de aplicación y elija un espacio de trabajo en el que implementar su aplicación. A continuación, seleccione Crear aplicación.

7. Tenga en cuenta que su ID de cliente y secreto se muestran en las credenciales de la aplicación.
8. En la barra lateral de OAuth y permisos, vaya a Ámbitos y elija Agregar un ámbito de OAuth. Puede agregar las URL de redireccionamiento a la aplicación para configurarlas, generar automáticamente el botón “Agregar a Slack” o distribuir la aplicación. Desplácese hasta la sección URL de redireccionamiento, seleccione Agregar nueva URL de redireccionamiento y guarde.
9. A continuación, desplácese hasta la sección de Tokens de OAuth para su espacio de trabajo y seleccione Instalar en el espacio de trabajo.
10. En el cuadro de diálogo que se abre para informarle de que la aplicación que ha creado solicita permiso para acceder al espacio de trabajo de Slack al que quería conectarse, seleccione Permitir.
11. Al finalizar correctamente, la consola mostrará la pantalla Tokens de OAuth para su espacio de trabajo.
12. En la pantalla Tokens de OAuth para su espacio de trabajo, copie y guarde el token de OAuth que usará para conectarse a AWS Glue
13. A continuación, recuperará el ID de su equipo de Slack. En el menú del espacio de trabajo de Slack, seleccione Herramientas y configuración y, a continuación, seleccione Administrar aplicaciones. Encontrará el ID de su equipo en la URL de la página que se abre.
14. Para distribuir la aplicación de manera pública y activarla, vaya al botón Administrar distribución de la barra lateral. Desplácese hacia abajo hasta la sección Compartir aplicación con otros espacios de trabajo y elija Eliminar información con codificación rígida. Dé su consentimiento y seleccione Distribución pública activa.
15. La aplicación ahora se distribuye de manera pública. Para acceder a las API de la entidad, la aplicación debe agregarse a todos los canales de espacio de trabajo desde los que el usuario quiera acceder.
16. Inicie sesión en su cuenta de Slack y abra el espacio de trabajo a cuyo canal necesita acceder.
17. En el espacio de trabajo, abra el canal al que quiere acceder la aplicación y elija el título del canal. Seleccione la pestaña Integraciones en el elemento emergente y agregue la aplicación. De esta forma, la aplicación se integra con el canal para tener acceso a su API.

    El ID de cliente de OAuth 2.0 debe tener una o más URL de redireccionamiento autorizadas. Las URL de redireccionamiento tienen el formato siguiente:

> **Note**
>
> Las URL de redireccionamiento de AppFlow están sujetas a cambios. Las URL de redireccionamiento posteriores para la plataforma de AWS Glue están disponibles. El ID de cliente y el secreto del cliente provienen de la configuración de su ID de cliente de OAuth 2.0.

La URL de redireccionamiento puede ser una de las siguientes opciones	
URL de redireccionamiento para el entorno de Gamma	
https://us-west-2.console.aws.amazon.com/appflow/oauth	https://us-east-1.awsc-integ.aws.amazon.com/appflow/oauth
https://us-east-2.console.aws.amazon.com/appflow/oauth	
https://us-west-1.console.aws.amazon.com/appflow/oauth	
https://ap-south-1.console.aws.amazon.com/appflow/oauth	
https://ap-southeast-1.console.aws.amazon.com/appflow/oauth	
https://ap-southeast-2.console.aws.amazon.com/appflow/oauth	
https://ap-northeast-1.console.aws.amazon.com/appflow/oauth	
https://ap-northeast-2.console.aws.amazon.com/appflow/oauth	

La URL de redireccionamiento puede ser una de las siguientes opciones	
URL de redireccionamiento para el entorno de Gamma	
https://ca-central-1.console.aws.amazon.com/appflow/oauth	
https://eu-central-1.console.aws.amazon.com/appflow/oauth	
https://eu.west-1.console.aws.amazon.com/appflow/oauth	
https://eu-west-2.console.aws.amazon.com/appflow/oauth	
https://eu-west-3.console.aws.amazon.com/appflow/oauth	
https://sa-east-1.console.aws.amazon.com/appflow/oauth	
https://us-west-2.awsc-integ.aws.amazon.com/appflow/oauth	
https://af-south-1.console.aws.amazon.com/appflow/oauth	

Conexión a Smartsheet

Smartsheet es un producto SaaS de colaboración y administración del trabajo. En esencia, Smartsheet permite a los usuarios utilizar objetos similares a hojas de cálculo para crear, almacenar y utilizar datos empresariales.

Temas

- Compatibilidad de AWS Glue con Smartsheet

- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de Smartsheet
- Configuración de las conexiones a Smartsheet
- Cómo leer de entidades de Smartsheet
- Opción de conexión a Smartsheet
- Creación de una cuenta de Smartsheet
- Limitaciones

Compatibilidad de AWS Glue con Smartsheet

AWS Glue es compatible con Smartsheet de la siguiente manera:

¿Es compatible como origen?

Sí. Puede usar los trabajos de ETL de AWS Glue para consultar datos de Smartsheet.

¿Es compatible como destino?

No.

Versiones de la API de Smartsheet compatibles

v2.0

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
```

```
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si no desea utilizar el método anterior, como alternativa, utilice las siguientes políticas de IAM administradas:

- AWSGlueServiceRole: concede acceso a los recursos que necesitan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: concede acceso completo a los recursos de AWS Gluecuando una identidad a la que está vinculada la política utiliza la Consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de Smartsheet

Antes de poder utilizar AWS Glue para transferir desde Smartsheet, deberá cumplir los siguientes requisitos:

Requisitos mínimos

- Tener una cuenta de Smartsheet con correo electrónico y contraseña. Para obtener más información sobre cómo crear una cuenta, consulte Cómo crear una cuenta de Smartsheet.
- La cuenta de Smartsheet tiene acceso a la API con una licencia válida.
- La cuenta de Smartsheet tiene un plan de precios Pro para la entidad `Sheets` y un plan de precios Enterprise con el complemento de informes de eventos para la entidad `Events`.

Si cumple estos requisitos, estará listo para conectar AWS Glue a la cuenta de Smartsheet. Para conexiones típicas, no necesita hacer nada más en Smartsheet.

Configuración de las conexiones a Smartsheet

Smartsheet admite el tipo de concesión `AUTHORIZATION_CODE` para OAuth2.

Este tipo de concesión se considera un `OAuth` "de tres vías", ya que se basa en redirigir a los usuarios al servidor de autorización externo para autenticar al usuario. Los usuarios aún pueden optar por crear una aplicación conectada propia en Smartsheet y proporcionar un ID y secreto de cliente propios al crear conexiones a través de la consola de AWS Glue. En este escenario, aún se abrirá Smartsheet para iniciar sesión y autorizar a AWS Glue para que acceda a sus recursos.

Este tipo de concesión da como resultado un token de actualización y un token de acceso. El token de acceso es de corta duración y se puede actualizar automáticamente sin la interacción del usuario mediante el token de actualización.

Para obtener documentación pública de Smartsheet sobre la creación de una aplicación conectada para el flujo AUTHORIZATION_CODE OAuth, consulte API de Smartsheet.

Para configurar una conexión a Smartsheet:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles:

   En el caso de una aplicación conectada administrada por el cliente, el secreto debe contener el secreto del consumidor de la aplicación conectada con la clave `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET`.

   > **Note**
   >
   > Es imprescindible crear un secreto por conexión en AWS Glue.

2. En AWS Glue Studio, siga los pasos que se indican a continuación en Conexiones de datos para crear una conexión:
   a. Al seleccionar un Tipo de conexión, elija Smartsheet.
   b. Proporcione la `instanceUrl` de Smartsheet a la que se desea conectar.
   c. Seleccione el rol de IAM que AWS Glue puede asumir y que cuente con los permisos necesarios para realizar las siguientes acciones:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

d. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.

e. Seleccione las opciones de red si quiere usar su red.

3. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.

Cómo leer de entidades de Smartsheet

Requisitos previos

Un objeto de `Smartsheet` desde el que desea leer. Consulte la tabla de entidades compatibles que aparece a continuación para comprobar las entidades disponibles.

Entidades compatibles

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite Partición
Listar hoja	Sí	Sí	No	Sí	No

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite Partición
Metadatos de fila	Sí	Sí	No	Sí	No
Metadatos de hoja	No	No	No	Sí	No
Datos de hoja	Sí	Sí	Sí	Sí	No
Evento	Sí	Sí	No	Sí	No

Ejemplo

```
Smartsheet_read = glueContext.create_dynamic_frame.from_options(
    connection_type="smartsheet",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "list-sheets",
        "API_VERSION": "2.0",
        "INSTANCE_URL": "https://api.smartsheet.com"
    })
```

Detalles de entidades y campos de Smartsheet

Entidad	Campo	Tipo de datos	Operadores admitidos
Listar hojas	id	Largo	N/D
	accessLevel	Cadena	N/D
	createdAt	DateTime	N/D
	modifiedAt	DateTime	N/D
	nombre	Cadena	N/D
	permalink	Cadena	N/D

Entidad	Campo	Tipo de datos	Operadores admitidos
	modifiedSince	DateTime	>=
	versión	Entero	N/D
	origen	Struct	N/D
Metadatos de fila	id	Largo	N/D
	sheetId	Largo	N/D
	accessLevel	Cadena	N/D
	attachments	Enumeración	N/D
	columns	Enumeración	N/D
	conditionalFormat	Cadena	N/D
	createdAt	DateTime	N/D
	createdBy	Struct	N/D
	discusiones	Enumeración	N/D
	pruebas	Struct	N/D
	ampliada	Booleano	N/D
	filteredOut	Booleano	N/D
	formato	Cadena	N/D
	inCriticalPath	Booleano	N/D
	bloqueado	Booleano	N/D
	lockedForUser	Booleano	N/D
	modifiedAt	DateTime	N/D

Entidad	Campo	Tipo de datos	Operadores admitidos
	modifiedBy	Struct	N/D
	permalink	Cadena	N/D
	rowNumber	Entero	N/D
	versión	Entero	N/D
	totalRowCount	Entero	N/D
	rowsModifiedSince	DateTime	>
	filterId	Largo	“="
	siblingId	Largo	N/D
	parentId	Largo	N/D
Metadatos de hoja	id	Largo	N/D
	fromId	Largo	N/D
	ownerId	Largo	N/D
	accessLevel	Cadena	N/D
	attachments	Enumeración	N/D
	columns	Enumeración	N/D
	createdAt	DateTime	N/D
	crossSheetReferences	Enumeración	N/D
	dependenciesEnabled	Booleano	N/D
	discusiones	Enumeración	N/D

Entidad	Campo	Tipo de datos	Operadores admitidos
	effectiveAttachmentOptions	Enumeración	N/D
	favorite	Booleano	N/D
	ganttEnabled	Booleano	N/D
	hasSummaryFields	Booleano	N/D
	modifiedAt	DateTime	N/D
	nombre	Cadena	N/D
	owner	Cadena	N/D
	permalink	Cadena	N/D
	projectSettings	Struct	N/D
	readOnly	Booleano	N/D
	resourceManagementEnabled	Booleano	N/D
	showParentRowsForFilters	Booleano	N/D
	origen	Struct	N/D
	resumen	Struct	N/D
	totalRowCount	Entero	N/D
	userPermissions	Struct	N/D
	userSettings	Struct	N/D
	versión	Entero	N/D
	espacio de trabajo	Struct	N/D

Entidad	Campo	Tipo de datos	Operadores admitidos
	filters	Enumeración	N/D
	ganttConfig	Struct	N/D
	resourceManagementType	Cadena	N/D
	cellImageUploadEnabled	Booleano	N/D
	isMultiPicklistEnabled	Booleano	N/D
Eventos	eventId	Cadena	N/D
	objectType	Cadena	N/D
	acción	Cadena	N/D
	objectId	Largo	N/D
	eventTimestamp	DateTime	N/D
	userId	Largo	N/D
	requestUserId	Largo	N/D
	accessTokenName	Cadena	N/D
	origen	Cadena	N/D
	additionalDetails	Struct	N/D
	since	DateTime	>=

Entidades con metadatos dinámicos:

Para la siguiente entidad, Smartsheet proporciona un punto de conexión para obtener los metadatos de forma dinámica, de modo que la compatibilidad con el operador se capture a nivel del tipo de datos.

Entidad	Tipo de datos	Operadores admitidos
Datos de la hoja	Cadena	N/D
Datos de la hoja	Largo	"="
Datos de la hoja	Entero	N/D
Datos de la hoja	DateTime	>

Ejemplo

```
Smartsheet_read = glueContext.create_dynamic_frame.from_options(
    connection_type="smartsheet",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "list-sheets",
        "API_VERSION": "2.0",
        "INSTANCE_URL": "https://api.smartsheet.com"
    }
```

Opción de conexión a Smartsheet

Las siguientes son opciones de conexión para Smartsheet:

- `ENTITY_NAME`(cadena): (obligatorio) se utiliza para leer y escribir. El nombre del objeto en Smartsheet.
- `API_VERSION`(cadena): (obligatorio) se utiliza para leer y escribir. Versión de la API de REST de Smartsheet que desea usar. Por ejemplo, v2.0.
- `INSTANCE_URL`(cadena): (obligatorio) se usa para lectura. URL de la instancia de Smartsheet.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.

Creación de una cuenta de Smartsheet

1. Para registrarse y obtener una cuenta de Smartsheet, acceda a la página de registro de Smartsheet.
2. Seleccione Crear una para crear una cuenta nueva o inicie sesión con la cuenta registrada de Google, Microsoft o Apple.
3.
4.
5. Abra el correo electrónico de confirmación de Smartsheet y seleccione el enlace de confirmación para verificar la cuenta.

   Quedará suscrito al plan de prueba de forma predeterminada.
6. En la esquina inferior izquierda, elija el icono Cuenta y seleccione Agregar licencias/Ampliar para mejorar el plan de precios.

   > **Note**
   >
   > Esto es necesario para acceder al Informe de eventos, que es un complemento del plan Enterprise.
7. En el plan Enterprise, elija Contáctenos para solicitar una actualización de cuenta al equipo de soporte.
8. En el formulario de solicitud de soporte, proporcione los detalles requeridos y sus requisitos para actualizar el plan.

   Esto completa la actualización al plan Enterprise.

Creación de credenciales de **`OAuth2.0`**

1. Después de actualizar el plan de precios de la cuenta para obtener acceso a las Herramientas para desarrolladores, acceda a Desarrolladores de Smartsheet.

   Recibirá un correo electrónico de activación.
2. Abra un correo electrónico de activación de Smartsheet y elija el enlace de activación para activar las herramientas para desarrolladores en la cuenta.

   La herramienta para desarrolladores permite crear la aplicación.

3. Abra la página de inicio de la cuenta de Smartsheet y seleccione Cuenta para comprobar el acceso.
4. Elija Herramientas para desarrolladores en la lista de servicios e ingrese los detalles del Perfil de desarrollador.
5. Elija Crear nueva aplicación.
6. Ingrese los siguientes datos en el formulario de registro de la aplicación:

   - Nombre: el nombre de la aplicación.
   - Descripción: descripción de la aplicación.
   - URL: URL que permite lanzar la aplicación o la URL de la página de destino.
   - Contacto/soporte: información de contacto del equipo de soporte.
   - URL de redireccionamiento: URL (también conocida como URL de devolución de llamada) de la aplicación que recibirá las credenciales de OAuth 2.0.
7. Seleccione Save.

   Smartsheet asigna un ID de cliente y un secreto de cliente a la aplicación. Registre estos valores para los siguientes pasos. También puede volver a buscarlos más tarde en la sección Herramientas para desarrolladores.

Limitaciones

Smartsheet no admite la partición basada en campos o registros.

Conexión a Snapchat Ads en AWS Glue Studio

Snapchat es una aplicación y un servicio multimedia de mensajería instantánea desarrollado por Snap Inc., originalmente Snapchat Inc. Una de las principales características de Snapchat es que las imágenes y los mensajes suelen estar disponibles solo durante un breve periodo de tiempo antes de que sus destinatarios no puedan acceder a ellos. El marketing de Snapchat consiste en publicaciones por las que las empresas pueden pagar para ofrecerlas a los usuarios de Snapchat.

Temas

- Compatibilidad de AWS Glue con anuncios de Snapchat
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de Snapchat Ads

- Configuración de conexiones de Snapchat Ads
- Lectura desde entidades de Snapchat Ads
- Opciones de conexión de Snapchat Ads
- Creación de una cuenta de Snapchat Ads y configuración de la aplicación cliente
- Creación de una aplicación en la cuenta de Snapchat Ads

Compatibilidad de AWS Glue con anuncios de Snapchat

AWS Glue es compatible con Snapchat Ads de la siguiente manera:

¿Es compatible como origen?

Sí. Puede usar los trabajos de AWS Glue ETL para consultar datos de Snapchat Ads.

¿Es compatible como destino?

No.

Versiones de la API de Snapchat Ads compatibles

v1.

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
```

```
      ],
      "Resource": "*"
    }
  ]
}
```

También puede usar las siguientes políticas de IAM administradas para permitir el acceso:

- AWSGlueServiceRole: concede acceso a los recursos que necesitan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, Amazon CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: concede acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de Snapchat Ads

Antes de poder utilizar AWS Glue para transferir datos desde Snapchat Ads, debe cumplir estos requisitos:

Requisitos mínimos

- Tener una cuenta de Snapchat Ads. Para obtener más información sobre cómo crear una cuenta, consulte Creación de una cuenta de Snapchat Ads y configuración de la aplicación cliente .
- Haber creado una aplicación OAuth 2 en su cuenta de Snapchat Ads. Esta integración proporciona las credenciales que AWS Glue utiliza para acceder a sus datos de forma segura cuando hace llamadas autenticadas a su cuenta. Para obtener más información, consulte Creación de una aplicación en la cuenta de Snapchat Ads .

Si cumple estos requisitos, lo tendrá todo listo para conectar AWS Glue a su cuenta de Snapchat Ads. En Snapchat Ads, una aplicación conectada es un marco que autoriza a aplicaciones externas, como AWS Glue, a acceder a sus datos de Snapchat Ads.

Configuración de conexiones de Snapchat Ads

Snapchat Ads solo admite el tipo de concesión `AUTHORIZATION_CODE`.

Este tipo de concesión se considera un OAuth “de tres vías”, ya que se basa en redirigir a los usuarios al servidor de autorización externo para autenticar al usuario. Se utiliza para crear conexiones a través de la consola de AWS Glue. El usuario que crea una conexión puede utilizar de forma predeterminada una aplicación conectada de AWS Glue (aplicación cliente administrada por AWS Glue), en la que no necesita proporcionar ninguna información relacionada con OAuth, excepto la URL de su instancia de Snapchat Ads. La consola de AWS Glue redirigirá al usuario a Snapchat Ads, donde deberá iniciar sesión y permitir a AWS Glue que los permisos solicitados accedan a su instancia de Snapchat Ads.

Los usuarios aún pueden optar por crear su propia aplicación conectada en Snapchat Ads y proporcionar su propio ID y secreto de cliente al crear conexiones a través de la consola de AWS Glue. En este caso, aún se abrirá Snapchat Ads para iniciar sesión y autorizar a AWS Glue para que acceda a sus recursos.

Este tipo de concesión da como resultado un token de actualización y un token de acceso. El token de acceso caduca una hora después de su creación. Se puede obtener un nuevo token de acceso mediante el token de actualización.

Para obtener más información sobre cómo crear una aplicación conectada para el flujo de OAuth con código de autorización, consulte Ads API.

Configuración de una conexión con Snapchat Ads:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles. Es necesario crear un secreto para cada conexión en AWS Glue.
   a. En el caso de una aplicación conectada administrada por el cliente, el secreto debe contener el secreto del consumidor de la aplicación conectada con la clave `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET`.
2. En AWS Glue Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:
   a. Al seleccionar un Tipo de conexión, seleccione Snapchat Ads.
   b. Proporcione el entorno de Snapchat Ads.
   c. Seleccione el rol de IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

d. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.

e. Seleccione las opciones de red si quiere usar su red.

3. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.

Lectura desde entidades de Snapchat Ads

Requisitos previos

- Un objeto de Snapchat Ads desde el que desea leer. Consulte la tabla de entidades compatibles que aparece a continuación para comprobar las entidades disponibles.

Entidades compatibles

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite Partición
Organización	No	No	No	Sí	No

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite Partición
Cuenta de anuncios	No	No	No	Sí	No
Creatividad	No	No	No	Sí	No
Multimedia	No	No	No	Sí	No
Campaña	Sí	No	No	Sí	No
Anuncio en cuenta de anuncios	Sí	No	No	Sí	No
Anuncio en campaña	No	No	No	Sí	No
Equipo de anuncios	Sí	No	No	Sí	No
Segmento	No	No	No	Sí	No

Ejemplo

```
snapchatads_read = glueContext.create_dynamic_frame.from_options(
    connection_type="snapchatAds",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "organization",
        "API_VERSION": "v1"
    }
)
```

Detalles de la entidad y el campo de Snapchat Ads

Snapchat Ads carga dinámicamente los campos disponibles en la entidad seleccionada. Según el tipo de datos de los campos, se admiten los operadores de filtro siguientes.

Tipo de datos de los campos	Operadores de filtro admitidos
Booleano	=

Consultas de partición

- Partición basada en campos: no se admite.
- Partición basada en registros: no se admite.

Opciones de conexión de Snapchat Ads

Las siguientes son opciones de conexión para Snapchat Ads:

- `ENTITY_NAME`(cadena): (obligatorio) se usa para lectura. El nombre de la entidad de Snapchat Ads. Ejemplo: `campaign` .
- `API_VERSION`(cadena): (obligatorio) se usa para lectura. API de REST de Snapchat Ads que desea utilizar. El valor será v1, ya que Snapchat Ads actualmente solo admite la versión 1.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Lista de columnas separadas por comas que quiere seleccionar para la entidad seleccionada.
- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.

Creación de una cuenta de Snapchat Ads y configuración de la aplicación cliente

Temas

- Suscripción a Snapchat Ads
- Pasos para crear una cuenta de Snapchat Ads

Suscripción a Snapchat Ads

Suscripción a Snapchat Ads:

1. Vaya a Ads Manager de Snapchat. Seleccione Registrarse junto a ¿Nuevo en Snapchat?.

2. En la pantalla Crear cuenta, siga las instrucciones para ingresar el nombre de su empresa, correo electrónico, contraseña, etc. Elija Siguiente.
3. En la pantalla Crear perfil, ingrese los valores para Nombre de usuario y Sitio web (opcional) y seleccione Crear cuenta. Esto le dará la opción de agregar una foto de perfil y una biografía en la pantalla Editar perfil. Elija Confirmar.
4. En la pantalla Información empresarial, rellene los campos obligatorios, como País, Moneda, Número de teléfono, GSTIN, etc., y seleccione Siguiente para completar el proceso de creación de la cuenta.

Pasos para crear una cuenta de Snapchat Ads

Creación de una cuenta de Snapchat Ads:

1. Inicie sesión en Ads Manager. A continuación, haga clic en la barra de navegación de la esquina superior y seleccione Cuentas de anuncios.
2. Seleccione + Nueva cuenta de anuncios. Ingrese los detalles de su anunciante:
   - Seleccione si es una agencia que compra anuncios en nombre de un anunciante o no. Si selecciona “Sí”, es posible que se rechace su anuncio si usa parámetros de segmentación como la segmentación por edad, sexo o código postal. La segmentación por edad mínima se puede aplicar a personas de hasta 21 años.
   - Seleccione si en su cuenta de anuncios se publicarán anuncios de vivienda, crédito o empleo. Si selecciona “Sí”, es posible que se rechace su anuncio si usa parámetros de segmentación como la segmentación por edad, sexo o código postal. La segmentación por edad mínima se puede aplicar a personas de hasta 21 años.
   - Seleccione si va a utilizar la cuenta de anuncios para anuncios políticos. Si publica un anuncio político, ingrese la organización política o el grupo de defensa patrocinador que paga el anuncio. Si no escribe correctamente la organización política, es posible que se rechacen sus anuncios. También tendrá que rellenar el “formulario de revisión de anuncios políticos”, enlazado obligatoriamente, antes de enviar anuncios.
3. Seleccione Detalles de la cuenta y rellene la información de su cuenta publicitaria:

Campo	Descripción
Nombre	El nombre de su cuenta de anuncios.

Campo	Descripción
Account Type	Seleccione su tipo de cuenta, si no se rellena automáticamente.
Tipo de facturación	Si quiere tener acceso continuo a su fuente de financiación, seleccione “Renovable”. Esto le permite reponer su línea de crédito y, a menudo, se elige para publicar anuncios en Ads Manager. Si prefiere lanzar una campaña única con un límite de gasto, puede elegir Orden de inserción. Si crea una cuenta con orden de inserción , pero quiere establecer un límite de gasto más adelante, puede dejar el límite de gasto en 0 USD. De esta forma, la cuenta tendrá un límite de gasto de 0 USD, pero podrá aplicarlo más adelante.
Organización anunciante	La organización que compra anuncios.
Centro de facturación	Elija el centro de facturación en el que desearía recibir las facturas. Puede usar el que se creó automáticamente cuando reclamó su empresa por primera vez o agregar otro centro de facturación según los pasos del Centro de ayuda para empresas.
Divisa	Elija su moneda.
Límite de gastos	Si ha elegido “Orden de inserción” como tipo de facturación, ingrese el presupuesto de una cuenta de anuncios.
Zona horaria	Seleccione su zona horaria.

4. Elija Crear cuenta. Se creará su cuenta de anuncios y podrá encontrarla en la sección Cuentas de anuncios de Ads Manager. Para empezar a publicar anuncios, tendrá que ingresar un método de pago. También puede agregar miembros a su cuenta de anuncios.
5. Seleccione si desea utilizar un método de pago existente o crear uno nuevo. A continuación, seleccione Guardar método de pago.
6. Seleccione cualquier miembro que haya invitado a su empresa para agregarlo a la cuenta de anuncios. Para obtener más información sobre los roles y los permisos que se pueden asignar, consulte Roles and Permissions Overview. Los miembros que se agreguen podrán iniciar sesión en Ads Manager y acceder a esta cuenta de anuncios. Cuando haya terminado, guarde sus miembros.

Para obtener más información sobre las cuentas de anuncios, consulte https://businesshelp.snapchat.com/s/article/roles-permissions?language=en_UShttps://businesshelp.snapchat.com/s/article/roles-permissions?language=en_US

Creación de una aplicación en la cuenta de Snapchat Ads

Para activar el acceso a la API de marketing de Snapchat, asegúrese de tener configurada una cuenta empresarial. A continuación, siga los pasos que se indican a continuación:

1. Inicie sesión en Ads Manager. A continuación, seleccione el menú de la esquina superior izquierda, seleccione Panel de control empresarial y, a continuación, Detalles del negocio.
2. Elija + Aplicación OAuth.
3. Ingrese el nombre de su aplicación y agregue la siguiente URL como URI de Snap Redirect: `https://<aws-region>.console.aws.amazon.com/gluestudio/oauth`. Por ejemplo, si utiliza la región us-west-1, la URL sería `https://us-west-1.console.aws.amazon.com/gluestudio/oauth) and choose` **`Create OAuth App`**. Elija Crear aplicación OAuth.
4. Aparecerán las credenciales de su aplicación (ID de cliente y secreto de cliente). Guárdelos, ya que se necesitan para crear una conexión.

Conectarse a Snowflake en AWS Glue Studio

> **Note**
>
> Puede usar AWS Glue para Spark para leer y escribir en tablas de Snowflake en AWS Glue 4.0 y versiones posteriores. Para configurar una conexión de Snowflake con trabajos de AWS Glue mediante programación, consulte Conexiones Redshift.

AWS Glue proporciona soporte integrado para Snowflake. AWS Glue Studio proporciona una interfaz visual para conectarse a Snowflake, crear trabajos de integración de datos y ejecutarlos en el tiempo de ejecución de Spark sin servidor de AWS Glue Studio.

AWS Glue Studio crea una conexión unificada para Snowflake. Para obtener más información, consulte Consideraciones.

Temas

- Crear una conexión con Snowflake
- Creación de un nodo de origen de Snowflake
- Creación de un nodo de destino de Snowflake
- Opciones avanzadas

Crear una conexión con Snowflake

> **Note**
>
> Las conexiones unificadas (conexión v2) estandarizan todas las conexiones de modo que utilicen claves `USERNAME`, `PASSWORD` para las credenciales de autenticación básica. Aún puede crear una conexión v1 a través de la API con secretos que contengan `sfUser`, `sfPassword`.

Al agregar un origen de datos: nodo Snowflake en AWS Glue Studio, puede elegir una conexión de Snowflake en AWS Glue existente o crear una nueva conexión. Debe elegir un tipo de conexión `SNOWFLAKE` y no un tipo de conexión `JDBC` configurado para conectarse a Snowflake. Utilice el siguiente procedimiento para crear una conexión con Snowflake en AWS Glue:

Crear una conexión con Snowflake

1. En Snowflake, genere un usuario *snowflakeUser* y una contraseña *snowflakePassword*.
2. Determine con qué almacén de Snowflake interactuará este usuario, *snowflakeWarehouse*. Configúrelo como DEFAULT_WAREHOUSE para *snowflakeUser* en Snowflake o recuérdelo para el siguiente paso.
3. En AWS Secrets Manager, cree un secreto con sus credenciales de Snowflake. Para crear un secreto en Secrets Manager, siga el tutorial disponible en Crear un secreto AWS Secrets Manager en la documentación AWS Secrets Manager. Después de crear el secreto, conserve el nombre secreto, *secretName*, para el siguiente paso.
   - Al seleccionar pares clave/valor, cree un par para *snowflakeUser* con la clave `sfUser`.
   - Al seleccionar pares clave/valor, cree un par para *snowflakePassword* con la clave `sfPassword`.
   - *Al seleccionar **pares clave/valor**, cree un par para snowflakeWarehouse* con la clave `sfWarehouse`. Esto no es necesario si hay un valor predeterminado en Snowflake.
4. En el catálogo de datos de AWS Glue, cree una conexión mediante los pasos que se indican en Agregar una conexión en AWS Glue. Tras crear la conexión, conserve el nombre de la conexión, *connectionName*, para el siguiente paso.
   - Al seleccionar un tipo de conexión, seleccione Snowflake.
   - Al seleccionar la URL de Snowflake, proporcione el nombre de host de la instancia de Snowflake. La URL utilizará un nombre de host en el formulario *account_identifier*`.snowflakecomputing.com`.
   - Al seleccionar un secreto AWS, proporcione un *secretName*.

Creación de un nodo de origen de Snowflake

Permisos necesarios

los trabajos de AWS Glue Studio que utilizan orígenes de datos de Snowflake requieren permisos adicionales. Para obtener más información sobre cómo agregar permisos a los trabajos de ETL, consulte Revisar los permisos de IAM necesarios para los trabajos de ETL.

las conexiones de SNOWFLAKE en AWS Glue utilizan un secreto de AWS Secrets Manager para proporcionar información sobre las credenciales. Sus roles de vista previa de datos y trabajos en AWS Glue Studio deben tener permiso para leer este secreto.

Agregar un origen de datos de Snowflake

Requisitos previos:

- Un secreto de AWS Secrets Manager para sus credenciales de Snowflake
- Una conexión del catálogo de datos de AWS Glue tipo Snowflake

Para agregar un nodo de Origen de datos: Snowflake:

1. Elija la conexión para el origen de datos de Snowflake. Esto supone que la conexión ya existe y que puede seleccionar entre las conexiones existentes. Si necesita crear una conexión, elija Crear conexión de Snowflake. Para más información, consulte Información general sobre el uso de conectores y conexiones.

   Una vez que haya elegido una conexión, puede ver las propiedades de la conexión mediante un clic en Ver propiedades. La información sobre la conexión está visible, como la URL, los grupos de seguridad, la subred, la zona de disponibilidad, la descripción y las marcas horarias creadas (UTC) y actualizadas por última vez (UTC).
2. Elija una opción de origen de Snowflake:

   - Elija una sola tabla: esta es la tabla que contiene los datos a los que desea acceder desde una sola tabla de Snowflake.
   - Ingresar una consulta personalizada: permite acceder a un conjunto de datos de varias tablas de Snowflake en función de la consulta personalizada.
3. Si ha elegido una sola tabla, ingrese el nombre de un esquema de Snowflake.

   O bien, elija Ingresar consulta personalizada. Elija esta opción para acceder a un conjunto de datos personalizado desde varias tablas de Snowflake. Al elegir esta opción, ingrese la consulta Snowflake.
4. En las opciones de rendimiento y seguridad (opcional),

   - Habilite la función desplegable de consultas: elija si quiere transferir el trabajo a la instancia de Snowflake.

5. En las propiedades personalizadas de Snowflake (opcional), ingrese los parámetros y valores según sea necesario.

Creación de un nodo de destino de Snowflake

Permisos necesarios

los trabajos de AWS Glue Studio que utilizan orígenes de datos de Snowflake requieren permisos adicionales. Para obtener más información sobre cómo agregar permisos a los trabajos de ETL, consulte Revisar los permisos de IAM necesarios para los trabajos de ETL.

las conexiones de `SNOWFLAKE` en AWS Glue utilizan un secreto de AWS Secrets Manager para proporcionar información sobre las credenciales. Sus roles de vista previa de datos y trabajos en AWS Glue Studio deben tener permiso para leer este secreto.

Agregar un destino de datos de Snowflake

Crear de un nodo de destino de Snowflake:

1. Elija una tabla Snowflake existente como destino o ingrese un nombre de tabla nuevo.
2. Al utilizar el nodo destino de datos: Snowflake, puede elegir entre las siguientes opciones:

   - APPEND: si ya existe una tabla, coloque todos los datos nuevos en la tabla como un inserto. Si la tabla no existe, créela y, a continuación, inserte todos los datos nuevos.
   - MERGE: AWS Glue actualizará o anexará datos a la tabla de destino en función de las condiciones que especifique.

     Elija opciones:

     - Elegir claves y acciones sencillas: elija las columnas que se usarán como claves de coincidencia entre los orígenes de datos y el conjunto de destinos de datos.

       Especifique las siguientes opciones cuando coincidan:

       - Actualice el registro del conjunto de datos de destino con los datos de origen.
       - Elimine el registro del conjunto de datos de destino.

       Especifique las siguientes opciones cuando no coincidan:

       - Inserte los datos de origen como una nueva fila en el conjunto de datos de destino.
       - No hacer nada.

    - Ingrese una instrucción MERGE personalizada: a continuación, puede elegir Validar la instrucción MERGE para comprobar si la instrucción es válida o no.
- TRUNCATE: si ya existe una tabla, trunque los datos de la tabla al borrar primero el contenido de la tabla de destino. Si el truncado se realiza correctamente, inserte todos los datos. Si la tabla no existe, créela y, a continuación, inserte todos los datos. Si el truncado no es exitoso, la operación producirá un error.
- DROP: si una tabla ya existe, elimine los metadatos y los datos de la tabla. Si el borrado se realiza correctamente, inserte todos los datos. Si la tabla no existe, créela y, a continuación, inserte todos los datos. Si el descarte no es exitoso, la operación producirá un error.

Opciones avanzadas

Consulte las conexiones de Snowflake en la guía para desarrolladores de AWS Glue.

Conexión a Stripe en AWS Glue Studio

Stripe es una plataforma de procesamiento de pagos y tarjetas de crédito en línea para empresas. La plataforma Stripe permite a las empresas aceptar pagos en línea, crear suscripciones (facturación periódica) para su comercio electrónico y configurar una cuenta pendiente para recibir los pagos. Stripe también admite pagos de varios participantes, lo que permite a las empresas configurar su sitio web y cobrar los pagos y, posteriormente, abonarlos a vendedores o proveedores de servicios a través de una cuenta “conectada”.

Temas

- Compatibilidad de AWS Glue con Stripe
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de Stripe
- Configuración de las conexiones de Stripe
- Lectura desde entidades de Stripe
- Opciones de conexión de Stripe
- Limitaciones
- Creación de una nueva cuenta de Stripe y configuración de la aplicación cliente

Compatibilidad de AWS Glue con Stripe

AWS Glue admite Stripe de la siguiente manera:

¿Es compatible como origen?

Sí. Puede usar los trabajos de ETL de AWS Glue para consultar datos de Stripe.

¿Es compatible como destino?

No.

Versiones de la API de Slack compatibles

v1.

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de IAM necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

También puede usar las siguientes políticas de IAM administradas para permitir el acceso:

- AWSGlueServiceRole: concede acceso a los recursos que necesitan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, Amazon CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: concede acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de Stripe

Antes de poder utilizar AWS Glue para transferir datos desde Stripe, debe cumplir estos requisitos:

Requisitos mínimos

- Tener una cuenta de Stripe con correo electrónico y contraseña. Para obtener más información, consulte Creación de una nueva cuenta de Stripe y configuración de la aplicación cliente.
- Su cuenta de Stripe está habilitada para el acceso a la API. La API de Stripe se puede utilizar sin ningún costo adicional.

Si cumple estos requisitos, lo tendrá todo listo para conectar AWS Glue a su cuenta de Stripe.

Configuración de las conexiones de Stripe

Stripe admite la autenticación personalizada. Para más información sobre cómo generar las claves de API necesarias para la autorización personalizada, consulte la documentación de la API de REST de Stripe.

Para configurar una conexión de Stripe:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles. Es necesario crear un secreto para cada conexión en AWS Glue.
   a. En el caso de una aplicación conectada administrada por el cliente, el secreto debe contener el secreto del consumidor de la aplicación conectada con la clave `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET`.

2. En AWS Glue Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:

   a. Al seleccionar un Tipo de conexión, seleccione Stripe.

   b. Seleccione el rol de IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

      JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

   c. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.

   d. Seleccione las opciones de red si quiere usar su red.

3. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.

Lectura desde entidades de Stripe

Requisitos previos

- Un objeto de Stripe desde el que desea leer.

Entidades compatibles

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite Partición
Saldo	No	No	No	Sí	No
Transacciones de saldo	Sí	Sí	No	Sí	Sí
Cargos	Sí	Sí	No	Sí	Sí
Disputas	Sí	Sí	No	Sí	Sí
Enlaces a los archivos	Sí	Sí	No	Sí	Sí
PaymentIntents	Sí	Sí	No	Sí	Sí
SetupIntents	Sí	Sí	No	Sí	Sí
Pagos	Sí	Sí	No	Sí	Sí
Reembolsos	Sí	Sí	No	Sí	Sí
Productos	Sí	Sí	No	Sí	Sí
Precios	Sí	Sí	No	Sí	Sí
Cupones	Sí	Sí	No	Sí	Sí
Códigos de promoción	Sí	Sí	No	Sí	Sí
Códigos fiscales	No	Sí	No	Sí	No
Cuotas fiscales	Sí	Sí	No	Sí	Sí

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite Partición
Cuotas de envío	Sí	Sí	No	Sí	Sí
Sesiones	Sí	Sí	No	Sí	Sí
Notas de crédito	Sí	Sí	No	Sí	Sí
Cliente	Sí	Sí	No	Sí	Sí
Facturas	Sí	Sí	No	Sí	Sí
Elementos de la factura	Sí	Sí	No	Sí	No
Planes	Sí	Sí	No	Sí	Sí
Cuotas	Sí	Sí	No	Sí	No
Suscripciones	Sí	Sí	No	Sí	
Elementos de suscripción	No	Sí	No	Sí	No
Esquemas de suscripción	Sí	Sí	No	Sí	Sí
Cuentas	No	Sí	No	Sí	Sí
Tarifas de la aplicación	Sí	Sí	No	Sí	Sí
Especificaciones de país	No	Sí	No	Sí	No

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite Partición
Transferencias	Sí	Sí	No	Sí	Sí
Advertencias anticipadas de fraude	Sí	Sí	No	Sí	Sí
Tipos de informes	No	No	No	Sí	No

Ejemplo

```
stripe_read = glueContext.create_dynamic_frame.from_options(
    connection_type="stripe",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "coupons",
        "API_VERSION": "v1"
    }
)
```

Detalles de la entidad y del campo de Stripe

Entidad	Campo	Tipo de datos	Operadores admitidos
Saldo			
	available	Enumeración	
	connect_reserved	Enumeración	
	pendiente	Enumeración	
	livemode	Booleano	
	objeto	Cadena	

Entidad	Campo	Tipo de datos	Operadores admitidos
	instant_available	Enumeración	
	issuing	Struct	
Transacciones de saldo			
	id	Cadena	
	objeto	Cadena	
	cantidad	Entero	
	available_on	DateTime	=, >=, <=,<,>
	created	DateTime	=, >=, <=,<,>
	divisa	Cadena	
	Descripción	Cadena	
	exchange_rate	BigDecimal	
	fee	Entero	
	fee_details	Enumeración	
	net	Entero	
	reporting_category	Cadena	
	origen	Cadena	=
	status	Cadena	
	type	Cadena	=
	cross_border_classification	Cadena	

Entidad	Campo	Tipo de datos	Operadores admitidos
Cargos			
	id	Cadena	
	objeto	Cadena	
	cantidad	Entero	=, <, >
	amount_captured	Entero	
	amount_refunded	Entero	
	aplicación	Cadena	
	application_fee	Cadena	
	application_fee_amount	Entero	
	balance_transaction	Cadena	
	billing_details	Struct	
	calculated_statement_descriptor	Cadena	
	captured	Booleano	
	created	DateTime	=, >=, <=,<,>
	divisa	Cadena	
	cliente	Cadena	=
	Descripción	Cadena	
	destination	Cadena	
	dispute	Cadena	

Entidad	Campo	Tipo de datos	Operadores admitidos
	disputed	Booleano	=
	failure_balance_transaction	Cadena	
	failure_code	Cadena	
	failure_message	Cadena	
	fraud_details	Struct	
	factura	Cadena	
	livemode	Booleano	
	metadatos	Struct	
	on_behalf_of	Cadena	
	orden	Cadena	
	outcome	Struct	
	paid	Booleano	
	payment_intent	Cadena	=
	payment_method	Cadena	
	payment_method_details	Struct	
	receipt_email	Cadena	
	receipt_number	Cadena	
	receipt_url	Cadena	
	refunded	Booleano	=

Entidad	Campo	Tipo de datos	Operadores admitidos
	reembolsos	Struct	
	revisión	Cadena	
	shipping	Struct	
	origen	Struct	
	source_transfer	Cadena	
	statement_descriptor	Cadena	
	statement_descriptor_suffix	Cadena	
	status	Cadena	
	transfer	Cadena	
	transfer_data	Struct	
	transfer_group	Cadena	=
Disputas			
	id	Cadena	
	objeto	Cadena	
	cantidad	Entero	=, <, >
	balance_transaction	Cadena	
	balance_transactions	Enumeración	
	cargo	Cadena	=
	created	DateTime	=, >=, <=,<,>
	divisa	Cadena	

Entidad	Campo	Tipo de datos	Operadores admitidos
	evidence	Struct	
	evidence_details	Struct	
	is_charge_refundable	Booleano	
	livemode	Booleano	
	metadatos	Struct	
	payment_intent	Cadena	=
	razón	Cadena	=
	status	Cadena	
	payment_method_details	Struct	
Enlaces a los archivos			
	id	Cadena	
	objeto	Cadena	
	created	DateTime	=, >=, <=,<,>
	expired	Booleano	=
	expires_at	DateTime	
	archivo	Cadena	=
	livemode	Booleano	
	metadatos	Struct	
	url	Cadena	
PaymentIntents			

Entidad	Campo	Tipo de datos	Operadores admitidos
	id	Cadena	
	objeto	Cadena	
	cantidad	Entero	
	amount_capturable	Entero	
	amount_details	Struct	
	amount_received	Entero	
	aplicación	Cadena	
	application_fee_amount	Entero	
	automatic_payment_methods	Struct	
	canceled_at	DateTime	
	cancellation_reason	Cadena	
	capture_method	Cadena	
	client_secret	Cadena	
	confirmation_method	Cadena	
	created	DateTime	=, >=, <=,<,>
	divisa	Cadena	
	cliente	Cadena	=
	Descripción	Cadena	
	factura	Cadena	

Entidad	Campo	Tipo de datos	Operadores admitidos
	last_payment_error	Struct	
	latest_charge	Cadena	
	livemode	Booleano	
	metadatos	Struct	
	next_action	Struct	
	on_behalf_of	Cadena	
	payment_method	Cadena	
	payment_method_options	Struct	
	payment_method_types	Enumeración	
	payment_method_configuration_details	Struct	
	En proceso	Struct	
	receipt_email	Cadena	
	revisión	Cadena	
	setup_future_usage	Cadena	
	shipping	Struct	
	origen	Cadena	
	statement_descriptor	Cadena	
	statement_descriptor_suffix	Cadena	

Entidad	Campo	Tipo de datos	Operadores admitidos
	status	Cadena	
	transfer_data	Struct	
	transfer_group	Cadena	
SetupIntents			
	id	Cadena	
	objeto	Cadena	
	aplicación	Cadena	
	cancellation_reason	Cadena	
	client_secret	Cadena	
	created	DateTime	=, >=, <=,<,>
	cliente	Cadena	=
	Descripción	Cadena	
	flow_directions	Enumeración	
	last_setup_error	Struct	
	latest_attempt	Cadena	
	livemode	Booleano	
	mandate	Cadena	
	metadatos	Struct	
	next_action	Struct	
	on_behalf_of	Cadena	

Entidad	Campo	Tipo de datos	Operadores admitidos
	payment_method	Cadena	
	payment_method_options	Struct	
	payment_method_types	Enumeración	
	single_use_mandate	Cadena	
	status	Cadena	
	uso	Cadena	
	automatic_payment_methods	Struct	
Pagos			
	id	Cadena	
	objeto	Cadena	
	cantidad	Entero	=, <, >
	arrival_date	DateTime	=, >=, <=,<,>
	automatic	Booleano	
	balance_transaction	Cadena	
	created	DateTime	=, >=, <=,<,>
	divisa	Cadena	
	Descripción	Cadena	=
	destination	Cadena	

Entidad	Campo	Tipo de datos	Operadores admitidos
	failure_balance_transaction	Cadena	
	failure_code	Cadena	
	failure_message	Cadena	
	livemode	Booleano	
	metadatos	Struct	
	method	Cadena	
	original_payout	Cadena	
	reversed_by	Cadena	
	reconciliation_status	Cadena	
	source_type	Cadena	
	statement_descriptor	Cadena	
	status	Cadena	
	type	Cadena	
	application_fee	Cadena	
	application_fee_amount	Entero	
Reembolsos			
	id	Cadena	
	objeto	Cadena	
	cantidad	Entero	

Entidad	Campo	Tipo de datos	Operadores admitidos
	balance_transaction	Cadena	
	cargo	Cadena	=
	created	DateTime	=, >=, <=,<,>
	divisa	Cadena	
	metadatos	Struct	
	destination_details	Struct	
	payment_intent	Cadena	=
	razón	Cadena	
	receipt_number	Cadena	
	source_transfer_reversal	Cadena	
	status	Cadena	
	transfer_reversal	Cadena	
Productos			
	id	Cadena	
	objeto	Cadena	
	activa	Booleano	=
	atributos	Enumeración	
	created	DateTime	=, >=, <=,<,>
	default_price	Cadena	
	Descripción	Cadena	

Entidad	Campo	Tipo de datos	Operadores admitidos
	images	Enumeración	
	livemode	Booleano	
	metadatos	Struct	
	nombre	Cadena	
	package_dimensions	Struct	
	shippable	Booleano	
	statement_descriptor	Cadena	
	tax_code	Cadena	
	type	Cadena	=
	unit_label	Cadena	
	updated	DateTime	
	url	Cadena	
	características	Enumeración	
Precios			
	id	Cadena	
	objeto	Cadena	
	activa	Booleano	=
	billing_scheme	Cadena	
	created	DateTime	=, >=, <=,<,>
	divisa	Cadena	=

Entidad	Campo	Tipo de datos	Operadores admitidos
	custom_unit_amount	Struct	
	livemode	Booleano	
	lookup_key	Cadena	
	metadatos	Struct	
	nickname	Cadena	
	producto	Cadena	=
	recurring	Struct	
	tax_behavior	Cadena	
	tiers_mode	Cadena	
	transform_quantity	Struct	
	type	Cadena	=
	unit_amount	Entero	
	unit_amount_decimal	Cadena	
Cupones			
	Id	Cadena	
	objeto	Cadena	
	amount_off	Entero	
	created	DateTime	=, >=, <=,<,>
	divisa	Cadena	=
	Duración	Cadena	=

Entidad	Campo	Tipo de datos	Operadores admitidos
	duration_in_months	Entero	=,<,>
	livemode	Booleano	
	max_redemptions	Entero	=, <, >
	metadatos	Struct	
	nombre	Cadena	
	percent_off	Doble	=
	redeem_by	DateTime	=, >=, <=, <, >
	times_redeemed	Entero	
	válido	Booleano	
Códigos de promoción			
	Id	Cadena	
	objeto	Cadena	
	activa	Booleano	=
	code	Cadena	=
	coupon	Struct	
	created	DateTime	=,>=,<=,<,>
	cliente	Cadena	
	expires_at	DateTime	
	livemode	Booleano	
	max_redemptions	Entero	

Entidad	Campo	Tipo de datos	Operadores admitidos
	metadatos	Struct	
	restricciones	Struct	
	times_redeemed	Entero	
Códigos fiscales			
	Id	Cadena	
	objeto	Cadena	
	Descripción	Cadena	
	nombre	Cadena	
Cuotas fiscales			
	Id	Cadena	
	objeto	Cadena	
	activa	Booleano	=
	país	Cadena	
	created	DateTime	=, >=, <=, <, >
	Descripción	Cadena	
	display_name	Cadena	
	inclusive	Booleano	=
	jurisdiction	Cadena	
	jurisdiction_level	Cadena	
	livemode	Booleano	

Entidad	Campo	Tipo de datos	Operadores admitidos
	metadatos	Struct	
	percentage	Doble	
	effective_percentage	Doble	
	estado	Cadena	
	tax_type	Cadena	
Cuotas de envío			
	Id	Cadena	
	objeto	Cadena	
	activa	Booleano	=
	created	DateTime	=, >=, <=, <, >
	delivery_estimate	Struct	
	display_name	Cadena	
	fixed_amount	Struct	
	livemode	Booleano	
	metadatos	Struct	
	tax_behavior	Cadena	
	tax_code	Cadena	
	type	Cadena	
Sesiones			
	id	Cadena	

Entidad	Campo	Tipo de datos	Operadores admitidos
	objeto	Cadena	
	after_expiration	Struct	
	allow_promotion_codes	Booleano	
	amount_subtotal	Entero	
	amount_total	Entero	
	automatic_tax	Struct	
	billing_address_collection	Cadena	
	cancel_url	Cadena	
	client_reference_id	Cadena	
	consent	Struct	
	consent_collection	Struct	
	created	DateTime	=, >=, <=, <, >
	divisa	Cadena	
	custom_text	Struct	
	cliente	Cadena	
	customer_creation	Cadena	
	customer_details	Struct	
	customer_email	Cadena	
	expires_at	DateTime	

Entidad	Campo	Tipo de datos	Operadores admitidos
	factura	Cadena	
	invoice_creation	Struct	
	livemode	Booleano	
	locale	Cadena	
	metadatos	Struct	
	mode	Cadena	
	payment_intent	Cadena	=
	payment_link	Cadena	
	payment_method_collection	Cadena	
	payment_method_options	Struct	
	payment_method_types	Enumeración	
	payment_status	Cadena	
	phone_number_collection	Struct	
	recovered_from	Cadena	
	setup_intent	Cadena	
	shipping_address_collection	Struct	
	shipping_cost	Struct	

Entidad	Campo	Tipo de datos	Operadores admitidos
	shipping_details	Struct	
	shipping_options	Enumeración	
	status	Cadena	
	submit_type	Cadena	
	Suscripción	Cadena	
	success_url	Cadena	
	tax_id_collection	Struct	
	total_details	Struct	
	url	Cadena	
	ui_mode	Cadena	
Notas de crédito			
	id	Cadena	
	objeto	Cadena	
	cantidad	Entero	
	created	DateTime	=, >=, <=, <, >
	divisa	Cadena	
	cliente	Cadena	=
	customer_balance_transaction	Cadena	
	discount_amount	Entero	
	discount_amounts	Enumeración	

Entidad	Campo	Tipo de datos	Operadores admitidos
	factura	Cadena	=
	lines	Struct	
	livemode	Booleano	
	memo	Cadena	
	metadatos	Struct	
	número	Cadena	
	out_of_band_amount	Entero	
	pdf	Cadena	
	razón	Cadena	
	refund	Cadena	
	status	Cadena	
	subtotal	Entero	
	subtotal_excluding_tax	Entero	
	tax_amounts	Enumeración	
	total	Entero	
	total_excluding_tax	Entero	
	type	Cadena	
	voided_at	DateTime	
	amount_shipping	Entero	
	effective_at	DateTime	

Entidad	Campo	Tipo de datos	Operadores admitidos
	shipping_cost	Struct	
Cliente			
	id	Cadena	
	objeto	Cadena	
	dirección	Struct	
	balance	Entero	
	created	DateTime	
	divisa	Cadena	=, >=, <=, <, >
	default_source	Cadena	
	delinquent	Booleano	=
	Descripción	Cadena	
	discount	Struct	
	correo electrónico	Cadena	=
	invoice_prefix	Cadena	
	invoice_settings	Struct	
	livemode	Booleano	
	metadatos	Struct	
	nombre	Cadena	
	next_invoice_sequence	Entero	
	phone	Cadena	

Entidad	Campo	Tipo de datos	Operadores admitidos
	preferred_locales	Enumeración	
	shipping	Struct	
	tax_exempt	Cadena	
	test_clock	Cadena	
Facturas			
	id	Cadena	
	objeto	Cadena	
	account_country	Cadena	
	account_name	Cadena	
	account_tax_ids	Enumeración	
	amount_due	Entero	
	amount_paid	Entero	
	amount_remaining	Entero	
	aplicación	Cadena	
	application_fee_amount	Entero	
	attempt_count	Entero	
	attempted	Booleano	=
	auto_advance	Booleano	=
	automatic_tax	Struct	
	billing_reason	Cadena	

Entidad	Campo	Tipo de datos	Operadores admitidos
	cargo	Cadena	
	collection_method	Cadena	=
	created	DateTime	=, >=, <=, <, >
	divisa	Cadena	
	custom_fields	Enumeración	
	cliente	Cadena	=
	customer_address	Struct	
	customer_email	Cadena	
	customer_name	Cadena	
	customer_phone	Cadena	
	customer_shipping	Struct	
	customer_tax_exempt	Cadena	
	customer_tax_ids	Enumeración	
	default_payment_method	Cadena	
	default_source	Cadena	
	default_tax_rates	Enumeración	
	Descripción	Cadena	
	discount	Struct	
	discounts	Enumeración	
	due_date	DateTime	=, >=, <=, <, >

Entidad	Campo	Tipo de datos	Operadores admitidos
	ending_balance	Entero	
	footer	Cadena	
	from_invoice	Struct	
	hosted_invoice_url	Cadena	
	invoice_pdf	Cadena	
	last_finalization_error	Struct	
	latest_revision	Cadena	
	lines	Struct	
	livemode	Booleano	
	metadatos	Struct	
	next_payment_attempt	DateTime	
	número	Cadena	
	on_behalf_of	Cadena	
	paid	Booleano	=
	paid_out_of_band	Booleano	
	payment_intent	Cadena	
	payment_settings	Struct	
	period_end	DateTime	=, >=, <=, <, >
	period_start	DateTime	=, >=, <=, <, >

Entidad	Campo	Tipo de datos	Operadores admitidos
	post_payment_credit_notes_amount	Entero	
	pre_payment_credit_notes_amount	Entero	
	quote	Cadena	
	receipt_number	Cadena	
	rendering	Struct	
	rendering_options	Struct	
	starting_balance	Entero	
	statement_descriptor	Cadena	
	status	Cadena	=
	status_transitions	Struct	
	Suscripción	Cadena	
	subscription_details	Struct	
	subtotal	Entero	=, <, >
	subtotal_excluding_tax	Entero	
	tax	Entero	
	test_clock	Cadena	
	total	Entero	=, <, >
	total_discount_amounts	Enumeración	

Entidad	Campo	Tipo de datos	Operadores admitidos
	total_excluding_tax	Entero	
	total_tax_amounts	Enumeración	
	transfer_data	Struct	
	webhooks_delivered_at	DateTime	
	automatically_finalizes_at	DateTime	
	effective_at	DateTime	
	emisor	Struct	
Elementos de la factura			
	id	Cadena	
	objeto	Cadena	
	cantidad	Entero	=, <, >
	divisa	Cadena	
	cliente	Cadena	=
	date	DateTime	
	Descripción	Cadena	
	discountable	Booleano	
	discounts	Enumeración	
	factura	Cadena	=
	livemode	Booleano	

Entidad	Campo	Tipo de datos	Operadores admitidos
	metadatos	Struct	
	periodo	Struct	
	plan	Struct	
	precio	Struct	
	proration	Booleano	=
	quantity	Entero	
	Suscripción	Cadena	
	subscription_item	Cadena	
	tax_rates	Enumeración	
	test_clock	Cadena	
	unit_amount	Entero	
	unit_amount_decimal	Cadena	
Planes			
	id	Cadena	
	objeto	Cadena	
	activa	Booleano	=
	aggregate_usage	Cadena	
	cantidad	Entero	
	amount_decimal	Cadena	
	billing_scheme	Cadena	

Entidad	Campo	Tipo de datos	Operadores admitidos
	created	DateTime	=, >=, <=, <, >
	divisa	Cadena	=
	intervalo	Cadena	=
	interval_count	Entero	
	livemode	Booleano	
	metadatos	Struct	
	nickname	Cadena	
	producto	Cadena	=
	tiers_mode	Cadena	
	transform_usage	Struct	
	trial_period_days	Entero	=, <, >
	usage_type	Cadena	
	medidor	Cadena	
Cuotas			
	id	Cadena	
	objeto	Cadena	
	amount_subtotal	Entero	
	amount_total	Entero	
	aplicación	Cadena	
	application_fee_amount	Entero	

Entidad	Campo	Tipo de datos	Operadores admitidos
	application_fee_percent	Doble	
	automatic_tax	Struct	
	collection_method	Cadena	
	computed	Struct	
	created	DateTime	
	divisa	Cadena	
	cliente	Cadena	=
	default_tax_rates	Enumeración	
	Descripción	Cadena	
	discounts	Enumeración	
	expires_at	DateTime	
	footer	Cadena	
	from_quote	Struct	
	header	Cadena	
	factura	Cadena	
	invoice_settings	Struct	
	livemode	Booleano	
	metadatos	Struct	
	número	Cadena	
	on_behalf_of	Cadena	

Entidad	Campo	Tipo de datos	Operadores admitidos
	status	Cadena	=
	status_transitions	Struct	
	Suscripción	Cadena	
	subscription_data	Struct	
	subscription_schedule	Cadena	
	test_clock	Cadena	
	total_details	Struct	
	transfer_data	Struct	
Suscripciones			
	id	Cadena	
	objeto	Cadena	
	aplicación	Cadena	
	application_fee_percent	Doble	
	automatic_tax	Struct	
	billing_cycle_anchor	DateTime	
	billing_thresholds	Struct	
	cancel_at	DateTime	
	cancel_at_period_end	Booleano	
	canceled_at	DateTime	
	collection_method	Cadena	=

Entidad	Campo	Tipo de datos	Operadores admitidos
	created	DateTime	=, >=, <=,<,>
	divisa	Cadena	
	current_period_end	DateTime	=, >=, <=
	current_period_start	DateTime	=, >=, <=
	cliente	Cadena	=
	days_until_due	Entero	
	default_payment_method	Cadena	
	default_source	Cadena	
	default_tax_rates	Enumeración	
	Descripción	Cadena	
	discount	Struct	
	ended_at	DateTime	
	items	Struct	
	latest_invoice	Cadena	
	livemode	Booleano	
	metadatos	Struct	
	next_pending_invoice_item_invoice	DateTime	
	pause_collection	Struct	
	payment_settings	Struct	

Entidad	Campo	Tipo de datos	Operadores admitidos
	pending_invoice_item_interval	Struct	
	pending_setup_intent	Cadena	
	pending_update	Struct	
	plan	Struct	
	quantity	Entero	
	horario	Cadena	
	start_date	DateTime	
	status	Cadena	=
	test_clock	Cadena	
	transfer_data	Struct	
	trial_end	DateTime	
	trial_start	DateTime	
Elementos de suscripción			
	Id	Cadena	
	objeto	Cadena	
	billing_thresholds	Struct	
	created	DateTime	=, >=, <=, <, >
	metadatos	Struct	
	plan	Struct	

Entidad	Campo	Tipo de datos	Operadores admitidos
	precio	Struct	
	Suscripción	Cadena	
	tax_rates	Enumeración	
	discounts	Enumeración	
Esquemas de suscripción			
	objeto	Cadena	
	aplicación	Cadena	
	canceled_at	DateTime	
	completed_at	DateTime	
	created	DateTime	
	current_phase	Struct	
	cliente	Cadena	=
	default_settings	Struct	
	end_behavior	Cadena	
	livemode	Booleano	
	metadatos	Struct	
	phases	Enumeración	
	released_at	DateTime	
	released_subscription	Cadena	
	renewal_interval	Cadena	

Entidad	Campo	Tipo de datos	Operadores admitidos
	status	Cadena	
	Suscripción	Cadena	
	test_clock	Cadena	
Cuentas			
	details_submitted	Booleano	
	tos_acceptance	Struct	
	type	Cadena	
	metadatos	Struct	
	id	Cadena	
	objeto	Cadena	
	default_currency	Cadena	
	capacidades	Struct	
	charges_enabled	Booleano	
	ajustes	Struct	
	Requisitos	Struct	
	payouts_enabled	Booleano	
	future_requirements	Struct	
	external_accounts	Struct	
	controlador	Struct	
	país	Cadena	

Entidad	Campo	Tipo de datos	Operadores admitidos
	correo electrónico	Cadena	
	created	DateTime	=, >=, <=, <, >
	business_profile	Struct	
	business_type	Cadena	
	company	Struct	
Tarifas de la aplicación			
	id	Cadena	
	objeto	Cadena	
	inscrita	Cadena	
	cantidad	Entero	=, <, >
	amount_refunded	Entero	=, <, >
	aplicación	Cadena	
	balance_transaction	Cadena	
	cargo	Cadena	=
	created	DateTime	
	divisa	Cadena	
	livemode	Booleano	
	originating_transaction	Cadena	
	refunded	Booleano	=

Entidad	Campo	Tipo de datos	Operadores admitidos
	reembolsos	Struct	
	fee_source	Struct	
Especificaciones de país			
	id	Cadena	
	objeto	Cadena	
	default_currency	Cadena	
	supported_bank_account_currencies	Struct	
	supported_payment_currencies	Enumeración	
	supported_payment_methods	Enumeración	
	supported_transfer_countries	Enumeración	
	verification_fields	Struct	
Transferencias			
	id	Cadena	
	objeto	Cadena	
	cantidad	Entero	=, <, >
	amount_reversed	Entero	
	balance_transaction	Cadena	

Entidad	Campo	Tipo de datos	Operadores admitidos
	created	DateTime	=, >=, <=, <, >
	divisa	Cadena	=
	Descripción	Cadena	
	destination	Cadena	=
	destination_payment	Cadena	
	livemode	Booleano	
	metadatos	Struct	
	reversals	Struct	
	reversed	Booleano	
	source_transaction	Cadena	
	source_type	Cadena	
	transfer_group	Cadena	=
Advertencias anticipadas de fraude			
	id	Cadena	
	objeto	Cadena	
	actionable	Booleano	
	cargo	Cadena	=
	created	DateTime	=, >=, <=, <, >
	fraud_type	Cadena	
	livemode	Booleano	

Entidad	Campo	Tipo de datos	Operadores admitidos
	payment_intent	Cadena	=
Tipos de informes			
	id	Cadena	
	objeto	Cadena	
	data_available_end	DateTime	
	data_available_start	DateTime	
	default_columns	Enumeración	
	livemode	Booleano	
	nombre	Cadena	
	updated	DateTime	
	versión	Entero	

Consultas de partición

Puede proporcionar las opciones adicionales de Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` y `NUM_PARTITIONS` si quiere usar la simultaneidad en Spark. Con estos parámetros, la consulta original se dividiría en un número `NUM_PARTITIONS` de subconsultas que las tareas de Spark pueden ejecutar simultáneamente.

- `PARTITION_FIELD`: el nombre del campo que se usará para particionar la consulta.
- `LOWER_BOUND`: un valor de límite inferior inclusivo del campo de partición elegido.

  Para la fecha, aceptamos el formato de fecha de Spark que se usa en las consultas de Spark SQL. Ejemplo de valor válido: `"2024-07-01T00:00:00.000Z"`.
- `UPPER_BOUND`: un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`: el número de particiones.

Los detalles de compatibilidad del campo de particionamiento por entidad se muestran en la siguiente tabla.

Nombre de la entidad	Campo de partición	Tipo de datos
Transacciones de saldo	created	DateTime
Cargos	created	DateTime
Disputas	created	DateTime
Enlaces a los archivos	created	DateTime
PaymentIntents	created	DateTime
SetupIntents	created	DateTime
Pagos	created	DateTime
Reembolsos	created	DateTime
Productos	created	DateTime
Precios	created	DateTime
Cupones	created	DateTime
Códigos de promoción	created	DateTime
Cuotas fiscales	created	DateTime
Cuotas de envío	created	DateTime
Sesiones	created	DateTime
Notas de crédito	created	DateTime
Cliente	created	DateTime
Facturas	created	DateTime
Planes	created	DateTime

Nombre de la entidad	Campo de partición	Tipo de datos
Suscripciones	created	DateTime
Esquemas de suscripción	created	DateTime
Cuentas	created	DateTime
Tarifas de la aplicación	created	DateTime
Transferencias	created	DateTime
Advertencias anticipadas de fraude	created	DateTime

Ejemplo

```
stripe_read = glueContext.create_dynamic_frame.from_options(
    connection_type="stripe",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "coupons",
        "API_VERSION": "v1",
        "PARTITION_FIELD": "created"
        "LOWER_BOUND": "2024-05-01T20:55:02.000Z"
        "UPPER_BOUND": "2024-07-11T20:55:02.000Z"
        "NUM_PARTITIONS": "10"
    }
)
```

Opciones de conexión de Stripe

Las siguientes son opciones de conexión para Stripe:

- `ENTITY_NAME`(cadena): (obligatorio) se utiliza para leer y escribir. El nombre del objeto en Stripe.
- `API_VERSION`(cadena): (obligatorio) se utiliza para leer y escribir. Versión de la API de REST de Stripe que desea usar. Ejemplo: v1.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.

- FILTER_PREDICATE(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- QUERY(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.
- PARTITION_FIELD(cadena): se usa para leer. Campo que se utilizará para particionar la consulta.
- LOWER_BOUND(cadena): se usa para leer. Un valor de límite inferior inclusivo del campo de partición elegido.
- UPPER_BOUND(cadena): se usa para leer. Un valor límite superior exclusivo del campo de partición elegido.
- NUM_PARTITIONS(entero): predeterminado: 1. Se usa para leer. Número de particiones para leer.

Limitaciones

Las siguientes son limitaciones para el conector de Stripe:

- El conector solo admite la partición basada en campos.
- El conector no admite la partición basada en registros; no hay ninguna disposición para recuperar el recuento total de registros.
- El tipo de datos clave principal es una cadena, por lo que la partición basada en ID no es compatible con ningún conector.

Creación de una nueva cuenta de Stripe y configuración de la aplicación cliente

Creación de una cuenta de Stripe

1. Elija en el enlace https://dashboard.stripe.com/register.
2. Ingrese su correo electrónico, nombre completo, contraseña y seleccione Crear cuenta.
3. Después de iniciar sesión con la cuenta, verifique la cuenta; para ello, elija Abrir Gmail.
4. Para verificar la cuenta, haga clic en el enlace de verificación recibido por correo electrónico.
5. Después de hacer clic en Verificar la dirección de correo electrónico, se abrirá otra página
6. Tras hacer clic en Activar pagos para activar la cuenta, se abrirá la página Activar pagos (https://dashboard.stripe.com/welcome). Asegúrese de rellenar todos los datos válidos y, a continuación, elija el botón Continuar.

Creación de una aplicación para desarrolladores de Slack

1. Inicie sesión en Stripe.
2. Elija Desarrolladores como se muestra en el extremo superior de la imagen de abajo.
3. Elija Claves de API en Desarrolladores.
4. Elija Revelar clave de prueba para obtener las claves de la API.

Conexión a Teradata Vantage en AWS Glue Studio

AWS Glue proporciona soporte integrado para Teradata Vantage. AWS Glue Studio proporciona una interfaz visual para conectarse a Teradata, crear trabajos de integración de datos y ejecutarlos en el tiempo de ejecución de Spark sin servidor de AWS Glue Studio.

AWS Glue Studio crea una conexión unificada para Teradata Vantage. Para obtener más información, consulte Consideraciones.

Temas

- Crear una conexión Teradata Vantage
- Crear un nodo de origen de Teradata
- Crear un nodo de destino de Teradata
- Opciones avanzadas

Crear una conexión Teradata Vantage

Para conectarse a Teradata Vantage desde AWS Glue, tendrá que crear y almacenar sus credenciales de Teradata en un AWS Secrets Manager secreto y, a continuación, asociar ese secreto a una conexión de Teradata de AWS Glue.

Requisitos previos:

- Si accede a su entorno de Teradata a través de Amazon VPC, configure Amazon VPC para permitir que su trabajo de AWS Glue se comunique con el entorno de Teradata. No recomendamos acceder al entorno de Teradata a través de la Internet pública.

  En Amazon VPC, identifique o cree una VPC, una subred y un grupo de seguridad que AWS Glue utilizará al ejecutar el trabajo. Además, debe asegurarse de que Amazon VPC esté configurada

para permitir el tráfico de red entre su instancia de Teradata y esta ubicación. Su trabajo deberá establecer una conexión TCP con su puerto de cliente de Teradata. Para obtener más información sobre los puertos de Teradata, consulte la documentación de Teradata.

Según el diseño de la red, la conectividad segura de la VPC puede requerir cambios en Amazon VPC y otros servicios de red. Para obtener más información sobre la conectividad de AWS, consulte las Opciones de conectividad de AWS en la documentación de Teradata.

Para configurar una conexión de AWS Glue Teradata:

1. En la configuración de Teradata, identifique o cree un usuario y la contraseña con la que AWS Glue se conectará, *teradataUser* y *teradataPassword*. Para obtener más información, consulte la Información general de seguridad de Vantage en la documentación de Teradata.
2. En AWS Secrets Manager, cree un secreto con sus credenciales de Teradata. Para crear un secreto en Secrets Manager, siga el tutorial disponible en Crear un secreto AWS Secrets Manager en la documentación AWS Secrets Manager. Después de crear el secreto, conserve el nombre secreto, *secretName*, para el siguiente paso.

   - Al seleccionar pares clave/valor, genere un par para la clave `user` con el valor *teradataUsername*.
   - Al seleccionar pares clave/valor, genere un par para la clave `password` con el valor *teradataPassword*.
3. En la consola de AWS Glue, genere una conexión mediante los pasos que se indican en the section called “Adición de una conexión de AWS Glue”. Tras crear la conexión, conserve el nombre de la conexión, *connectionName*, para el siguiente paso.

   - Al seleccionar un tipo de conexión, seleccione Teradata.
   - Al proporcionar la URL de JDBC, proporcione la URL de su instancia. También puede codificar determinados parámetros de conexión separados por comas en la URL de JDBC. La URL debe tener el siguiente formato: `jdbc:teradata://`*teradataHostname*`/`*ParameterName*`=`*ParameterValue*`,`*ParameterName*

     Los parámetros de URL admitidos incluyen:

     - `DATABASE`— nombre de la base de datos del host a la que se accede de forma predeterminada.
     - `DBS_PORT`— el puerto de la base de datos, que se utiliza cuando se ejecuta en un puerto no estándar.

- Al seleccionar un Tipo de credencial, seleccione AWS Secrets Manager y, a continuación, establezca AWS Secret en *secretName*.

4. En las siguientes situaciones, es posible que necesite una configuración adicional:

   - Para las instancias de Teradata alojadas AWS en una VPC de Amazon
     - Deberá proporcionar la información de conexión de Amazon VPC a la conexión de AWS Glue que define sus credenciales de seguridad de Teradata. Al crear o actualizar la conexión, configure los VPC, Subred y los grupos de seguridad en Opciones de red.

Crear un nodo de origen de Teradata

Requisitos previos necesarios

- Una conexión AWS Glue Teradata Vantage, configurada con un AWS Secrets Manager secreto, como se describe en la sección anterior, the section called “Crear una conexión Teradata Vantage”.
- Permisos adecuados en el trabajo para leer el secreto utilizado por la conexión.
- Una tabla de Teradata de la que desee leer, *tableName* o consultar *targetQuery*.

Agregar un origen de datos de Teradata

Para agregar un nodo de Origen de datos: Teradata:

1. Elija la conexión para el origen de datos de Teradata. Dado que lo ha creado, debería estar disponible en el menú desplegable. Si es necesario crear una conexión, elija Crear una nueva conexión. Para obtener más información, consulte la sección the section called “Crear una conexión Teradata Vantage” anterior.

   Una vez que haya elegido una conexión, puede ver las propiedades de la conexión mediante un clic en Ver propiedades.

2. Elija una opción de origen de Teradata:

   - Elija una sola tabla: acceda a todos los datos de una sola tabla.
   - Ingresar una consulta personalizada: permite acceder a un conjunto de datos de varias tablas en función del consulta personalizada.

3. Si eligió una sola tabla, ingrese *tableName*.

Si eligió Introducir una consulta personalizada, introduzca una consulta SQL SELECT.

4. En las propiedades personalizadas de Teradata, ingrese los parámetros y valores según sea necesario.

Crear un nodo de destino de Teradata

Requisitos previos necesarios

- Una conexión AWS Glue Teradata Vantage, configurada con un AWS Secrets Manager secreto, como se describe en la sección anterior, the section called “Crear una conexión Teradata Vantage”.
- Permisos adecuados en el trabajo para leer el secreto utilizado por la conexión.
- Una tabla de Teradata a la que desearía escribir, *`tableName`*.

Agregar un destino de datos de Teradata

Para añadir un destino de datos: nodo de Teradata:

1. Elija la conexión para el origen de datos de Teradata. Dado que lo ha creado, debería estar disponible en el menú desplegable. Si es necesario crear una conexión, elija Crear conexión de Teradata. Para más información, consulte Información general sobre el uso de conectores y conexiones.

   Una vez que haya elegido una conexión, puede ver las propiedades de la conexión mediante un clic en Ver propiedades.
2. Configure el nombre de la tabla proporcionando *`tableName`*.
3. En las propiedades personalizadas de Teradata, ingrese los parámetros y valores según sea necesario.

Opciones avanzadas

Puede brindar opciones avanzadas al crear un nodo de Teradata. Estas opciones son las mismas que las disponibles cuando se programa AWS Glue para scripts de Spark.

Consulte the section called “Conexiones Teradata Vantage”.

Conexión a Twilio

Twilio proporciona herramientas de comunicación programables para realizar y recibir llamadas telefónicas, enviar y recibir mensajes de texto y llevar a cabo otras funciones de comunicación mediante las API de sus servicios web. Las API de Twilio son la base tecnológica de la plataforma de comunicaciones. Estas API están respaldadas por una capa de software que conecta y optimiza las redes de comunicación globales, lo que permite a los usuarios realizar llamadas y enviar mensajes a cualquier persona, en cualquier lugar del mundo. Como usuario de Twilio, puede conectar AWS Glue a la cuenta de Twilio. A continuación, podrá utilizar Twilio como origen de datos en los trabajos de ETL. Ejecute estos trabajos para transferir datos entre Twilio y los servicios de AWS u otras aplicaciones compatibles.

Temas

- Compatibilidad de AWS Glue con Twilio
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de Twilio
- Configuración de conexiones a Twilio
- Cómo leer de entidades de Twilio
- Opciones de conexión a Twilio
- Limitaciones y notas del conector de Twilio

Compatibilidad de AWS Glue con Twilio

AWS Glue admite Twilio de la siguiente manera:

¿Es compatible como origen?

Sí. Puede usar los trabajos de ETL de AWS Glue para consultar datos de Twilio.

¿Es compatible como destino?

No.

Versiones de la API de Twilio compatibles

Las siguientes versiones de la API de Twilio son compatibles:

- v1
- 2010-04-01

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS IAM necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si no desea utilizar el método anterior, puede utilizar las siguientes políticas de IAM administradas:

- AWSGlueServiceRole: da acceso a recursos que precisan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: otorga acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la Consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios

dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de Twilio

Antes de poder utilizar AWS Glue para transferir datos desde Twilio, debe cumplir estos requisitos:

Requisitos mínimos

Los requisitos mínimos son los siguientes:

- Tener una cuenta de Twilio con nombre de usuario y contraseña.
- La cuenta de Twilio debe estar habilitada para el acceso a la API.

Si cumple estos requisitos, estará listo para conectar AWS Glue a la cuenta de Twilio. Para conexiones típicas, no necesita hacer nada más en Twilio.

Configuración de conexiones a Twilio

Twilio admite el nombre de usuario y la contraseña para la autenticación básica. La autenticación básica es un método de autenticación simple en el que los clientes proporcionan credenciales directamente para acceder a los recursos protegidos. AWS Glue puede utilizar el nombre de usuario (SID de la cuenta) y la contraseña (token de autenticación) para autenticar las API de Twilio.

Para consultar la documentación pública de Twilio sobre el flujo de autenticación básica, consulte Autenticación básica | Twilio.

Para configurar una conexión a Twilio:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles:
   - En la autenticación básica: el secreto debe contener el secreto del consumidor de la aplicación conectada junto con el SID de la cuenta (nombre de usuario) y el token de autenticación (contraseña).

     > **Note**
     >
     > Debe crear un secreto para las conexiones en AWS Glue.

2. En AWS Glue Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:
   a. Al seleccionar un Tipo de conexión, elija Twilio.
   b. Proporcione la `Edge_Location` de la instancia de Twilio a la que se quiere conectar.
   c. Seleccione el rol de AWS IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

      JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

   d. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.
   e. Seleccione las opciones de red si quiere usar su red.
3. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.

Cómo leer de entidades de Twilio

Requisito previo

Un objeto de Twilio desde el que desea leer. Necesitará el nombre del objeto, como `SMS-Message` o `SMS-CountryPricing`.

Entidades compatibles como origen:

Entidad	Interfaz	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
SMS-Message	REST	Sí	Sí	No	Sí	Sí
SMS-CountryPricing	REST	No	No	No	Sí	No
Voice-Call	REST	Sí	Sí	No	Sí	No
Voice-Application	REST	Sí	Sí	No	Sí	No
Voice-OutgoingCallerID	REST	Sí	Sí	No	Sí	No
Voice-Queue	REST	Sí	Sí	No	Sí	No
Conversations-Conversation	REST	Sí	Sí	No	Sí	No
Conversations-User	REST	No	Sí	No	Sí	No
Conversations-Role	REST	No	Sí	No	Sí	No
Conversations-Configuration	REST	No	No	No	Sí	No
Conversations-Addr	REST	Sí	Sí	No	Sí	No

Entidad	Interfaz	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
essConfiguration						
Conversations-WebhookConfiguration	REST	No	No	No	Sí	No
Conversations-ParticipantConversation	REST	No	No	No	Sí	No
Conversations-Credential	REST	No	Sí	No	Sí	No
Conversations-ConversationService	REST	No	Sí	No	Sí	No

Ejemplo:

```
twilio_read = glueContext.create_dynamic_frame.from_options(
    connection_type="twilio",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "sms-message",
        "API_VERSION": "2010-04-01",
        "Edge_Location": "sydney.us1"
    }
```

Detalles de entidades y campos de Twilio:

Entidad	Campo	Tipo de datos:	Operadores admitidos
SMS-Message	account_sid	Cadena	N/A
	api_version	Cadena	N/A
	cuerpo	Cadena	N/A
	date_created	Fecha y hora	N/A
	date_sent	Fecha y hora	>=, <=, =
	date_updated	Fecha y hora	N/A
	direction	Cadena	N/A
	error_code	Entero	N/A
	error_message	Cadena	N/A
	desde	Entero	=
	messaging_service_sid	Cadena	N/A
	num_media	Cadena	N/A
	num_segments	Cadena	N/A
	precio	Cadena	N/A
	price_unit	Struct	N/A
	sid	Entero	N/A
	status	Cadena	N/A
	subresource_uris	Asignación	N/A
	a	Entero	=
	uri	Fecha y hora	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
SMS-CountryPricing	país	Cadena	N/A
	iso_country	Cadena	N/A
	url	Cadena	N/A
	outbound_sms_prices	Enumeración	N/A
	inbound_sms_prices	Enumeración	N/A
	price_unit	Cadena	N/A
Voice-Call	account_sid	Cadena	N/A
	anotación	Cadena	N/A
	answered_by	Cadena	N/A
	api_version	Cadena	N/A
	caller_name	Cadena	N/A
	date_created	Fecha y hora	N/A
	date_updated	Fecha y hora	N/A
	direction	Cadena	N/A
	Duración	Cadena	N/A
	end_time	Fecha y hora	>=, <=, =
	forwarded_from	Cadena	N/A
	desde	Cadena	=
	from_formatted	Cadena	N/A
	group_sid	Cadena	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	parent_call_sid	Cadena	N/A
	phone_number_sid	Cadena	N/A
	precio	Cadena	N/A
	price_unit	Cadena	N/A
	sid	Cadena	N/A
	start_time	Fecha y hora	>=, <=, =
	status	Cadena	=
	subresource_uris	Cadena	N/A
	a	Cadena	=
	to_formatted	Cadena	N/A
	trunk_sid	Cadena	N/A
	uri	Cadena	N/A
	queue_time	Cadena	N/A
Voice-Application	account_sid	Cadena	N/A
	api_version	Cadena	N/A
	date_created	Fecha y hora	N/A
	date_updated	Fecha y hora	N/A
	friendly_name	Cadena	=
	message_status_callback	Cadena	N/A
	sid	Cadena	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	sms_fallback_method	Cadena	N/A
	sms_fallback_url	Cadena	N/A
	sms_method	Cadena	N/A
	sms_status_callback	Cadena	N/A
	sms_url	Cadena	N/A
	status_callback	Cadena	N/A
	status_callback_method	Cadena	N/A
	uri	Cadena	N/A
	voice_caller_id_lookup	Booleano	N/A
	voice_fallback_method	Cadena	N/A
	voice_fallback_url	Cadena	N/A
	voice_method	Cadena	N/A
	voice_url	Cadena	N/A
public_application_connect_enabled	Booleano	N/A	
Voice-OutgoingCallerID	sid	Cadena	N/A
	date_created	Fecha y hora	N/A
	date_updated	Fecha y hora	N/A
	account_sid	Cadena	N/A
	friendly_name	Cadena	=

Entidad	Campo	Tipo de datos:	Operadores admitidos
	phone_number	Cadena	=
	uri	Cadena	N/A
Voice-Queue	date_created	Fecha y hora	N/A
	date_updated	Fecha y hora	N/A
	current_size	Entero	N/A
	friendly_name	Cadena	N/A
	uri	Cadena	N/A
	account_sid	Cadena	N/A
	average_wait_time	Entero	N/A
	sid	Cadena	N/A
	max_size	Entero	N/A
Conversations-Conversation	account_sid	Cadena	N/A
	chat_service_sid	Cadena	N/A
	messaging_service_sid	Cadena	N/A
	sid	Cadena	N/A
	friendly_name	Cadena	N/A
	unique_name	Cadena	N/A
	atributos	Cadena	N/A
	estado	Cadena	=
	date_created	Fecha y hora	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	date_updated	Fecha y hora	N/A
	temporizadores	Struct	N/A
	url	Cadena	N/A
	links	Struct	N/A
	enlaces	Struct	N/A
	start_date	Fecha y hora	=
	end_date	Fecha y hora	=
	Timers.DateInactive	Cadena	N/A
	Timers.DateClosed	Cadena	N/A
Conversations-User	sid	Cadena	N/A
	account_sid	Cadena	N/A
	chat_service_sid	Cadena	N/A
	role_sid	Cadena	N/A
	identidad	Cadena	N/A
	friendly_name	Cadena	N/A
	atributos	Cadena	N/A
	is_online	Booleano	N/A
	is_notifiable	Booleano	N/A
	date_created	Fecha y hora	N/A
	date_updated	Fecha y hora	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	url	Cadena	N/A
	links	Struct	N/A
Conversations-Role	sid	Cadena	N/A
	account_sid	Cadena	N/A
	chat_service_sid	Cadena	N/A
	friendly_name	Cadena	N/A
	type	Cadena	N/A
	permisos	Cadena	N/A
	date_created	Fecha y hora	N/A
	date_updated	Fecha y hora	N/A
	url	Cadena	N/A
Conversations-Configuration	account_sid	Largo	N/A
	default_chat_service_sid	Cadena	N/A
	default_messaging_service_sid	Cadena	N/A
	default_inactive_timer	Cadena	N/A
	default_closed_timer	Cadena	N/A
	url	Cadena	N/A
	links	Asignación	N/A
Conversations-AddressConfiguration	sid	Cadena	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	account_sid	Cadena	N/A
	type	Cadena	N/A
	dirección	Cadena	N/A
	friendly_name	Cadena	N/A
	auto_creation	Struct	N/A
	date_created	Fecha y hora	N/A
	date_updated	Fecha y hora	N/A
	url	Cadena	N/A
	address_country	Cadena	N/A
	AutoCreation.Enabled	Booleano	N/A
	AutoCreation.Type	Cadena	N/A
	AutoCreation.ConversationServiceSid	Cadena	N/A
	AutoCreation.WebhookUrl	Cadena	N/A
	AutoCreation.WebhookMethod	Cadena	N/A
	AutoCreation.WebhookFilters	Enumeración	N/A
	AutoCreation.StudioFlowSid	Cadena	N/A
	AutoCreation.StudioRetryCount	Entero	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
Conversations-WebhookConfiguration	account_sid	Cadena	N/A
	method	Cadena	N/A
	filters	Enumeración	N/A
	pre_webhook_url	Cadena	N/A
	post_webhook_url	Cadena	N/A
	destino	Cadena	N/A
	url	Cadena	N/A
Converations-ParticipantConversation	account_sid	Cadena	N/A
	chat_service_sid	Cadena	N/A
	participant_sid	Cadena	N/A
	participant_user_sid	Cadena	N/A
	participant_identity	Cadena	N/A
	participant_messaging_binding	Struct	N/A
	Conversation_sid	Cadena	N/A
	conversation_unique_name	Cadena	N/A
	conversation_friendly_name	Cadena	N/A
	conversation_attributes	Cadena	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	conversation_date_created	Fecha y hora	N/A
	conversation_date_updated	Fecha y hora	N/A
	conversation_created_by	Cadena	N/A
	conversation_state	Cadena	N/A
	conversation_timers	Struct	N/A
	links	Asignación	N/A
	dirección	Cadena	=
	identidad	Cadena	=
Conversation-Credentials	sid	Cadena	N/A
	account_sid	Cadena	N/A
	friendly_name	Cadena	N/A
	type	Cadena	N/A
	entorno de prueba	Cadena	N/A
	date_created	Fecha y hora	N/A
	dated_updated	Fecha y hora	N/A
	url	Cadena	N/A
	certificado	Cadena	N/A
	private_key	Cadena	N/A
	api_key	Cadena	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	secreta	Cadena	N/A
Conversations-ConversationService	sid	Cadena	N/A
	account_sid	Cadena	N/A
	friendly_name	Cadena	N/A
	date_created	Fecha y hora	N/A
	date_updated	Fecha y hora	N/A
	url	Cadena	N/A
	links	Asignación	N/A

Consultas de partición

Campos que admiten la partición:

En Twilio, los campos de tipo de datos DateTime admiten la partición basada en campos.

Puede proporcionar las opciones adicionales de Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` y `NUM_PARTITIONS` si quiere utilizar la simultaneidad en Spark. Con estos parámetros, la consulta original se dividiría en un número `NUM_PARTITIONS` de subconsultas que las tareas de Spark pueden ejecutar simultáneamente.

- `PARTITION_FIELD`: el nombre del campo que se utilizará para particionar la consulta.
- `LOWER_BOUND`: un valor de límite inferior inclusivo del campo de partición elegido.

  En el campo Datetime, aceptamos el formato de marca de tiempo de Spark que se utiliza en las consultas SQL de Spark.

  Ejemplos de valor válido:

  ```
  "2024-05-01T20:55:02.000Z"
  ```

- `UPPER_BOUND`: un valor límite superior exclusivo del campo de partición elegido.

- NUM_PARTITIONS: el número de particiones.

Ejemplo:

```
twilio_read = glueContext.create_dynamic_frame.from_options(
    connection_type="twilio",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "sms-message",
        "API_VERSION": "2010-04-01",
        "PARTITION_FIELD": "date_sent"
        "LOWER_BOUND": "2024-05-01T20:55:02.000Z"
        "UPPER_BOUND": "2024-06-01T20:55:02.000Z"
        "NUM_PARTITIONS": "10"
    }
```

Opciones de conexión a Twilio

Las siguientes son opciones de conexión para Twilio:

- ENTITY_NAME(cadena): (obligatorio) se usa para lectura. El nombre del objeto en Twilio.
- EDGE_LOCATION(Cadena): (obligatorio) Una ubicación periférica de Twilio válida.
- API_VERSION(cadena): (obligatorio) se usa para lectura. Versión de la API de Rest de Twilio que desea usar. Twilio admite dos versiones de la API: “v1” y “01/04/2010”.
- SELECTED_FIELDS(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- FILTER_PREDICATE(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- QUERY(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.
- PARTITION_FIELD(cadena): se usa para leer. Campo que se utilizará para particionar la consulta.
- LOWER_BOUND(cadena): se usa para leer. Un valor de límite inferior inclusivo del campo de partición elegido.
- UPPER_BOUND(cadena): se usa para leer. Un valor límite superior exclusivo del campo de partición elegido.
- NUM_PARTITIONS(entero): predeterminado: 1. Se usa para leer. Número de particiones de lectura.
- INSTANCE_URL(cadena): (obligatorio) se usa para lectura. Una URL de instancia de Twilio válida.

Limitaciones y notas del conector de Twilio

Las siguientes son limitaciones o notas para el conector de Twilio:

- No se admite la partición basada en registros, ya que no hay ninguna provisión para recuperar el recuento total de registros de Twilio.
- Los campos `date_sent`, `start_time` y `end_time` son del tipo de datos Datetime, pero al filtrarlos, solo admiten valores de fecha (no se tienen en cuenta los componentes de hora).
- El filtrado de los campos “de” o “a” solo funciona si los valores no incluyen ningún prefijo (por ejemplo, un protocolo o una etiqueta). Si hay un prefijo, no funcionará el filtrado para el campo correspondiente. Por ejemplo, si transmite “a”: “whatsapp:+14xxxxxxxxxx” como filtro, Twilio no devolverá ninguna respuesta. Tiene que transmitirlo como “a”: “+14xxxxxxxx”, y devolverá los registros si existen.
- El filtro del campo “identidad” es obligatorio al consultar la entidad `conversation-participant-conversation`.

Conexión a Vertica en AWS Glue Studio

AWS Glue proporciona soporte integrado para Vertica. AWS Glue Studio proporciona una interfaz visual para conectarse a Vertica, crear trabajos de integración de datos y ejecutarlos en el tiempo de ejecución de Spark sin servidor de AWS Glue Studio.

AWS Glue Studio crea una conexión unificada para Vertica. Para obtener más información, consulte Consideraciones.

Temas

- Crear una conexión Vertica
- Crear un nodo de origen de Vertica
- Crear un nodo de destino de Vertica
- Opciones avanzadas

Crear una conexión Vertica

Requisitos previos:

- Un bucket o una carpeta de Amazon S3 para utilizar como almacenamiento temporario al leer y escribir en la base de datos, al que hace referencia *`tempS3Path`*.

> **Note**
>
> Al utilizar Vertica en las vistas previas de los datos de los trabajos de AWS Glue, puede que los archivos temporales no se eliminen automáticamente de *tempS3Path*. Para garantizar la eliminación de los archivos temporales, finalice directamente la sesión de vista previa de datos al seleccionar Finalizar sesión en el panel Vista previa de datos. Si no puede garantizar que la sesión de vista previa de datos finalice directamente, considere configurar Amazon S3 Lifecycle para eliminar los datos antiguos. Recomendamos eliminar los datos de más de 49 horas, en función del tiempo máximo de ejecución del trabajo más un margen. Para obtener más información sobre la configuración de Amazon S3 Lifecycle, consulte Administración del ciclo de vida del almacenamiento en la documentación de Amazon S3.

- Una política de IAM con los permisos adecuados para su ruta de Amazon S3 que pueda asociar a su puesto de trabajo de AWS Glue.
- Si su instancia de Vertica está en una Amazon VPC, configure Amazon VPC para permitir que su trabajo de AWS Glue se comunique con la instancia de Vertica sin que el tráfico atraviese la Internet pública.

  En Amazon VPC, identifique o cree una VPC, una subred y un grupo de seguridad que AWS Glue utilizará al ejecutar la tarea. Además, debe asegurarse de que Amazon VPC esté configurada para permitir el tráfico de red entre su instancia de Vertica y esta ubicación. Su trabajo tendrá que establecer una conexión TCP con el puerto de cliente de Vertica (el valor predeterminado es 5433). Según el diseño de la red, esto puede requerir cambios en las reglas de los grupos de seguridad, las ACL de red, las puertas de enlace de NAT y las conexiones entre pares.

Para configurar una conexión a Vertica:

1. En AWS Secrets Manager, cree un secreto con sus credenciales de Vertica, *verticaUsername* y *verticaPassword*. Para crear un secreto en Secrets Manager, siga el tutorial disponible en Crear un secreto AWS Secrets Manager en la documentación AWS Secrets Manager. Después de crear el secreto, conserve el nombre secreto, *secretName*, para el siguiente paso.

   - Al seleccionar pares clave/valor, genere un par para la clave `user` con el valor *verticaUsername*.

- Al seleccionar pares clave/valor, genere un par para la clave `password` con el valor *`verticaPassword`*.

2. En la consola de AWS Glue, genere una conexión mediante los pasos que se indican en the section called “Adición de una conexión de AWS Glue”. Tras crear la conexión, conserve el nombre de la conexión, *`connectionName`*, para el siguiente paso.

   - Al seleccionar un tipo de conexión, seleccione Vertica.
   - Al seleccionar Vertica Host, proporcione el nombre de host de la instalación de Vertica.
   - Al seleccionar Vertica Port, proporcione el portal a través del cual está disponible su instalación de Vertica.
   - Al seleccionar un secreto AWS, proporcione un *`secretName`*.

3. En las siguientes situaciones, es posible que necesite una configuración adicional:

   - Para las instancias de Vertica alojadas en AWS en una VPC de Amazon
     - Proporcione la información de conexión de Amazon VPC a la conexión de AWS Glue que define sus credenciales de seguridad de Vertica. Al crear o actualizar la conexión, configure los VPC, Subred y los grupos de seguridad en Opciones de red.

Deberá realizar los siguientes pasos antes de ejecutar su trabajo de AWS Glue:

- Otorga permisos al rol de IAM asociado al trabajo de AWS Glue para *`tempS3Path`*.
- Otorga permiso al rol de IAM asociado al trabajo de AWS Glue para leer el *`secretName`*.

Crear un nodo de origen de Vertica

Requisitos previos necesarios

- Una conexión de catálogo de datos de tipo AWS Glue Vertica, *`connectionName`* y una ubicación temporal de Amazon S3, *`tempS3Path`*, como se describe en la sección anterior, the section called “Crear una conexión Vertica”.
- *`Una tabla de Vertica de la que le gustaría leer, tableName o consultar targetQuery`*.

Agregar un origen de datos de Vertica

Para agregar un nodo de Origen de datos: Vertica:

1. Elija la conexión para el origen de datos de Vertica. Dado que lo ha creado, debería estar disponible en el menú desplegable. Si es necesario crear una conexión, elija Crear conexión de Vertica. Para obtener más información, consulte la sección the section called “Crear una conexión Vertica” anterior.

   Una vez que haya elegido una conexión, puede ver las propiedades de la conexión mediante un clic en Ver propiedades.
2. Elija la base de datos que contiene la tabla.
3. Elija el área de ensayo en Amazon S3 e introduzca un URI de S3A en *`tempS3Path`*.
4. Elija el origen de Vertica.

   - Elija una sola tabla: acceda a todos los datos de una sola tabla.
   - Ingresar una consulta personalizada: permite acceder a un conjunto de datos de varias tablas en función del consulta personalizada.
5. Si ha elegido una sola tabla, ingrese *`tableName`* y, de manera opcional, seleccione un esquema.

   Si eligió Introducir una consulta personalizada, introduzca una consulta SQL SELECT y, si lo desea, seleccione un esquema.
6. En las propiedades personalizadas de Vertica, ingrese los parámetros y valores según sea necesario.

Crear un nodo de destino de Vertica

Requisitos previos necesarios

- Una conexión de catálogo de datos de tipo AWS Glue Vertica, *`connectionName`* y una ubicación temporal de Amazon S3, *`tempS3Path`*, como se describe en la sección anterior, the section called “Crear una conexión Vertica”.

Agregar un destino de datos de Vertica

Para añadir un nodo de Destino de datos - Vertica:

1. Elija la conexión para el origen de datos de Vertica. Dado que lo ha creado, debería estar disponible en el menú desplegable. Si es necesario crear una conexión, elija Crear conexión de Vertica. Para obtener más información, consulte la sección the section called “Crear una conexión Vertica” anterior.

   Una vez que haya elegido una conexión, puede ver las propiedades de la conexión mediante un clic en Ver propiedades.
2. Elija la base de datos que contiene la tabla.
3. Elija el área de ensayo en Amazon S3 e introduzca un URI de S3A en *tempS3Path*.
4. Introduzca ***tableName*** y, si lo desea, seleccione un esquema.
5. En las propiedades personalizadas de Vertica, ingrese los parámetros y valores según sea necesario.

Opciones avanzadas

Puede brindar opciones avanzadas al crear un nodo de Vertica. Estas opciones son las mismas que las disponibles cuando se programa AWS Glue para scripts de Spark.

Consulte the section called “Conexiones Vertica”.

Conexión a WooCommerce

WooCommerce es una solución de software flexible de código abierto creada para sitios web basados en WordPress. Se utiliza habitualmente para crear tiendas de comercio electrónico en línea. Gracias a esta solución de software, cualquiera puede convertir un sitio web convencional en una tienda en línea completamente funcional.

Temas

- Compatibilidad de AWS Glue con WooCommerce
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de WooCommerce
- Configuración de conexiones a WooCommerce
- Cómo leer de las entidades de WooCommerce

- Opciones de conexión de WooCommerce

Compatibilidad de AWS Glue con WooCommerce

AWS Glue es compatible con WooCommerce de la siguiente manera:

¿Es compatible como origen?

Sí. Puede usar los trabajos de ETL de AWS Glue para consultar datos de WooCommerce.

¿Es compatible como destino?

No.

Versiones de la API de WooCommerce compatibles

Las siguientes versiones de la API de WooCommerce son compatibles:

- v3

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS IAM necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
```

```
  ]
}
```

Si no desea utilizar el método anterior, puede utilizar las siguientes políticas de IAM administradas:

- AWSGlueServiceRole: da acceso a recursos que precisan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: otorga acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la Consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de WooCommerce

Antes de poder utilizar AWS Glue para transferir datos desde WooCommerce, deberá cumplir estos requisitos:

Requisitos mínimos

Los requisitos mínimos son los siguientes:

- Tener una cuenta de WooCommerce con una `consumerKey` y un `consumerSecret`.
- La cuenta de WooCommerce tiene acceso a la API con una licencia válida.

Si cumple estos requisitos, estará listo para conectar AWS Glue a la cuenta de WooCommerce. Para conexiones típicas, no necesita hacer nada más en WooCommerce.

Configuración de conexiones a WooCommerce

WooCommerce admite la autenticación personalizada. Para consultar la documentación pública de WooCommerce sobre la generación de las claves de API necesarias para la autorización personalizada, consulte Autenticación: Documentación de la API de REST de WooCommerce.

Para configurar una conexión a WooCommerce:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles:
   - Para una aplicación conectada administrada por el cliente, el secreto debe contener el secreto del consumidor de la aplicación conectada con `consumerKey` y `consumerSecret` como claves. Nota: Debe crear un secreto por conexión en AWS Glue.

1. En AWS Glue Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:
   a. Al seleccionar un Tipo de conexión, elija WooCommerce.
   b. Proporcione la `INSTANCE_URL` de la instancia de WooCommerce a la que se quiere conectar.
   c. Seleccione el rol de AWS IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

      JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

   d. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.
   e. Seleccione las opciones de red si quiere usar su red.
2. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.

Cómo leer de las entidades de WooCommerce

Requisito previo

Un objeto de WooCommerce desde el que desea leer. Necesitará el nombre del objeto, como cupón, pedido, producto, etc.

Entidades compatibles como origen:

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Cupón	Sí	Sí	Sí	Sí	Sí
Total de cupón	No	No	No	Sí	No
Total de clientes	No	No	No	Sí	No
Order	Sí	Sí	Sí	Sí	Sí
Total de pedido	No	No	No	Sí	No
Puerta de enlace de pago	No	No	No	Sí	No
Producto	Sí	Sí	Sí	Sí	Sí
Atributo de producto	Sí	Sí	Sí	Sí	Sí
Categoría de producto	Sí	Sí	Sí	Sí	Sí
Opinión de producto	Sí	Sí	Sí	Sí	Sí

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Clase de envío de producto	Sí	Sí	Sí	Sí	Sí
Etiqueta de producto	Sí	Sí	Sí	Sí	Sí
Variación de producto	Sí	Sí	Sí	Sí	Sí
Total de productos	No	No	No	Sí	No
Informe (lista)	No	No	No	Sí	No
Total de opiniones	No	No	No	Sí	No
Informe de ventas	Sí	No	No	Sí	No
Método de envío	No	No	No	Sí	No
Zona de envío	No	No	No	Sí	No
Ubicación de la zona de envío	No	No	No	Sí	No
Método de zona de envío	No	No	No	Sí	No
Tasa fiscal	Sí	Sí	Sí	Sí	Sí

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Clase fiscal	No	No	No	Sí	No
Informe de los más vendidos	Sí	No	No	Sí	No

Ejemplo:

```
woocommerce_read = glueContext.create_dynamic_frame.from_options(
    connection_type="glue.spark.woocommerce",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "coupon",
        "API_VERSION": "v3",
        "INSTANCE_URL": "instanceUrl"
    }
```

Detalles de entidades y campos de WooCommerce:

Entidad	Campo	Tipo de datos:	Operadores admitidos
coupon	id	Entero	N/A
	code	Cadena	EQUAL_TO
	cantidad	Cadena	N/A
	status	Cadena	N/A
	date_created	DateTime	N/A
	date_created_gmt	DateTime	N/A
	date_modified	DateTime	N/A
	date_modified_gmt	DateTime	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	discount_type	Cadena	N/A
	Descripción	Cadena	N/A
	date_expires	Cadena	N/A
	date_expires_gmt	Cadena	N/A
	usage_count	Entero	N/A
	individual_use	Booleano	N/A
	product_ids	Enumeración	N/A
	excluded_product_ids	Enumeración	N/A
	usage_limit	Entero	N/A
	usage_limit_per_user	Entero	N/A
	limit_usage_to_x_items	Entero	N/A
	free_shipping	Booleano	N/A
	product_categories	Enumeración	N/A
	excluded_product_categories	Enumeración	N/A
	exclude_sale_items	Booleano	N/A
	minimum_amount	Cadena	N/A
	maximum_amount	Cadena	N/A
	email_restrictions	Enumeración	N/A
	used_by	Enumeración	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	meta_data	Enumeración	N/A
	context	Cadena	EQUAL_TO
	buscar	Cadena	EQUAL_TO
	después	DateTime	EQUAL_TO
	antes	DateTime	EQUAL_TO
	orden	Cadena	EQUAL_TO
	orderby	Cadena	EQUAL_TO
	modified_after	DateTime	EQUAL_TO
	modified_before	DateTime	EQUAL_TO
	dates_are_gmt	Booleano	EQUAL_TO
coupon-total	URL amigable	Cadena	N/A
	nombre	Cadena	N/A
	total	Entero	N/A
customer-total	URL amigable	Cadena	N/A
	nombre	Cadena	N/A
	total	Entero	N/A
orden	id	Entero	N/A
	parent_id	Entero	N/A
	número	Cadena	N/A
	order_key	Cadena	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	created_via	Cadena	N/A
	status	Cadena	N/A
	divisa	Cadena	N/A
	versión	Cadena	N/A
	date_created	DateTime	N/A
	date_modified	DateTime	N/A
	discount_total	Cadena	N/A
	discount_tax	Cadena	N/A
	shipping_total	Cadena	N/A
	shipping_tax	Cadena	N/A
	cart_tax	Cadena	N/A
	total	Cadena	N/A
	total_tax	Cadena	N/A
	prices_include_tax	Booleano	N/A
	customer_id	Entero	N/A
	customer_ip_address	Cadena	N/A
	customer_user_agent	Cadena	N/A
	customer_note	Cadena	N/A
	facturación	Struct	N/A
	shipping	Struct	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	payment_method	Cadena	N/A
	payment_method_title	Cadena	N/A
	transaction_id	Cadena	N/A
	date_paid	DateTime	N/A
	date_completed	DateTime	N/A
	cart_hash	Cadena	N/A
	meta_data	Enumeración	N/A
	line_items	Enumeración	N/A
	tax_lines	Enumeración	N/A
	shipping_lines	Enumeración	N/A
	fee_lines	Enumeración	N/A
	coupon_lines	Enumeración	N/A
	reembolsos	Enumeración	N/A
	payment_url	Cadena	N/A
	is_editable	Booleano	N/A
	needs_payment	Booleano	N/A
	needs_processing	Booleano	N/A
	date_created_gmt	DateTime	N/A
	date_modified_gmt	DateTime	N/A
	date_completed_gmt	DateTime	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	date_paid_gmt	DateTime	N/A
	currency_symbol	Cadena	N/A
	set_paid	Booleano	N/A
	context	Cadena	EQUAL_TO
	buscar	Cadena	EQUAL_TO
	después	DateTime	EQUAL_TO
	antes	DateTime	EQUAL_TO
	orden	Cadena	EQUAL_TO
	orderby	Cadena	EQUAL_TO
	cliente	Entero	EQUAL_TO
	producto	Entero	EQUAL_TO
	dp	Entero	EQUAL_TO
	modified_before	DateTime	EQUAL_TO
	modified_after	DateTime	EQUAL_TO
	dates_are_gmt	Booleano	EQUAL_TO
order-total	URL amigable	Cadena	N/A
	nombre	Cadena	N/A
	total	Entero	N/A
payment-gateway	título	Cadena	N/A
	Descripción	Cadena	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	orden	Cadena	N/A
	enabled	Booleano	N/A
	method_title	Cadena	N/A
	method_description	Cadena	N/A
	method_supports	Enumeración	N/A
	ajustes	Cadena	N/A
	needs_setup	Booleano	N/A
	post_install_scripts	Enumeración	N/A
	settings_url	Cadena	N/A
	connection_url	Cadena	N/A
	setup_help_text	Cadena	N/A
	required_settings_keys	Enumeración	N/A
product	id	Entero	N/A
	nombre	Cadena	N/A
	type	Cadena	EQUAL_TO
	permalink	Cadena	N/A
	date_created	DateTime	N/A
	date_created_gmt	DateTime	N/A
	date_modified	DateTime	N/A
	date_modified_gmt	DateTime	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	catalog_visibility	Cadena	N/A
	Descripción	Cadena	N/A
	short_description	Cadena	N/A
	precio	Cadena	N/A
	regular_price	Cadena	N/A
	sale_price	Cadena	N/A
	date_on_sale_from	DateTime	N/A
	date_on_sale_from	DateTime	N/A
	date_on_sale_to	DateTime	N/A
	date_on_sale_to_gmt	DateTime	N/A
	price_html	Cadena	N/A
	adquirible	Booleano	N/A
	total_sales	Entero	N/A
	virtual	Booleano	N/A
	descargable	Booleano	N/A
	downloads	Enumeración	N/A
	download_limit	Entero	N/A
	download_expiry	Entero	N/A
	external_url	Cadena	N/A
	button_text	Cadena	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	tax_status	Cadena	N/A
	manage_stock	Booleano	N/A
	stock_quantity	Entero	N/A
	pedidos pendientes	Cadena	N/A
	backorders_allowed	Booleano	N/A
	en pedido pendiente	Booleano	N/A
	sold_individually	Booleano	N/A
	weight	Cadena	N/A
	dimensiones	Struct	N/A
	shipping_required	Booleano	N/A
	shipping_taxable	Booleano	N/A
	shipping_class_id	Entero	N/A
	reviews_allowed	Booleano	N/A
	average_rating	Cadena	N/A
	rating_count	Entero	N/A
	related_ids	Enumeración	N/A
	upsell_ids	Enumeración	N/A
	cross_sell_ids	Enumeración	N/A
	parent_id	Entero	N/A
	purchase_note	Cadena	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	categories	Enumeración	N/A
	etiquetas	Enumeración	N/A
	images	Enumeración	N/A
	atributos	Enumeración	N/A
	default_attributes	Enumeración	N/A
	variaciones	Enumeración	N/A
	grouped_products	Enumeración	N/A
	menu_order	Entero	N/A
	meta_data	Enumeración	N/A
	low_stock_amount	Entero	N/A
	jetpack_publicize_connections	Enumeración	N/A
	jetpack-related-posts	Enumeración	N/A
	jetpack_likes_enabled	Booleano	N/A
	jetpack_sharing_enabled	Booleano	N/A
	context	Cadena	EQUAL_TO
	buscar	Cadena	EQUAL_TO
	después	DateTime	EQUAL_TO
	antes	DateTime	EQUAL_TO
	orden	Cadena	EQUAL_TO

Entidad	Campo	Tipo de datos:	Operadores admitidos
	orderby	Cadena	EQUAL_TO
	URL amigable	Cadena	EQUAL_TO
	status	Cadena	EQUAL_TO
	sku	Cadena	EQUAL_TO
	destacado	Booleano	EQUAL_TO
	etiqueta	Cadena	EQUAL_TO
	shipping_class	Cadena	EQUAL_TO
	tax_class	Cadena	EQUAL_TO
	on_sale	Booleano	EQUAL_TO
	stock_status	Cadena	EQUAL_TO
	has_options	Booleano	N/A
	modified_after	DateTime	EQUAL_TO
	modified_before	DateTime	EQUAL_TO
	dates_are_gmt	Booleano	EQUAL_TO
	categoría	Cadena	EQUAL_TO
	atributo	Cadena	EQUAL_TO
	min_price	Cadena	EQUAL_TO
	max_price	Cadena	EQUAL_TO
product-attribute	id	Entero	N/A
	nombre	Cadena	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	URL amigable	Cadena	N/A
	type	Cadena	N/A
	order_by	Cadena	N/A
	has_archives	Booleano	N/A
	context	Cadena	EQUAL_TO
product-attribute-term	id	Entero	N/A
	nombre	Cadena	N/A
	URL amigable	Cadena	N/A
	Descripción	Cadena	N/A
	menu_order	Entero	N/A
	count	Entero	N/A
	context	Cadena	EQUAL_TO
	buscar	Cadena	EQUAL_TO
	orden	Cadena	EQUAL_TO
	orderby	Cadena	EQUAL_TO
	hide_empty	Booleano	EQUAL_TO
	parent	Entero	EQUAL_TO
	producto	Entero	EQUAL_TO
product-category	id	Entero	N/A
	nombre	Cadena	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	URL amigable	Cadena	EQUAL_TO
	Descripción	Cadena	N/A
	display	Cadena	N/A
	imagen	Struct	N/A
	menu_order	Entero	N/A
	count	Entero	N/A
	context	Cadena	EQUAL_TO
	buscar	Cadena	EQUAL_TO
	orden	Cadena	EQUAL_TO
	orderby	Cadena	EQUAL_TO
	hide_empty	Booleano	EQUAL_TO
	parent	Entero	EQUAL_TO
	producto	Entero	EQUAL_TO
product-review	id	Entero	N/A
	date_created	DateTime	N/A
	date_created_gmt	DateTime	N/A
	product_id	Entero	N/A
	product_name	Cadena	N/A
	product_permalink	Cadena	N/A
	revisión	Cadena	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	clasificación	Entero	N/A
	verified	Booleano	N/A
	autor	Cadena	N/A
	reviewer_email	Cadena	N/A
	reviewer_avatar_urls	Struct	N/A
	context	Cadena	EQUAL_TO
	buscar	Cadena	EQUAL_TO
	después	DateTime	EQUAL_TO
	antes	DateTime	EQUAL_TO
	orden	Cadena	EQUAL_TO
	orderby	Cadena	EQUAL_TO
	status	Cadena	EQUAL_TO
product-shipping-class	id	Entero	N/A
	nombre	Cadena	N/A
	URL amigable	Cadena	EQUAL_TO
	Descripción	Cadena	N/A
	count	Entero	N/A
	context	Cadena	EQUAL_TO
	buscar	Cadena	EQUAL_TO
	orden	Cadena	EQUAL_TO

Entidad	Campo	Tipo de datos:	Operadores admitidos
	orderby	Cadena	EQUAL_TO
	hide_empty	Cadena	EQUAL_TO
	producto	Entero	EQUAL_TO
product-tag	id	Entero	N/A
	nombre	Cadena	N/A
	URL amigable	Cadena	EQUAL_TO
	Descripción	Cadena	N/A
	count	Entero	N/A
	context	Cadena	EQUAL_TO
	buscar	Cadena	EQUAL_TO
	orden	Cadena	EQUAL_TO
	orderby	Cadena	EQUAL_TO
	hide_empty	Booleano	EQUAL_TO
	producto	Entero	EQUAL_TO
product-total	URL amigable	Cadena	N/A
	nombre	Cadena	N/A
	total	Entero	N/A
product-variation	id	Entero	N/A
	date_created	DateTime	N/A
	date_created_gmt	DateTime	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	date_modified	DateTime	N/A
	date_modified_gmt	DateTime	N/A
	Descripción	Cadena	N/A
	permalink	Cadena	N/A
	precio	Cadena	N/A
	regular_price	Cadena	N/A
	sale_price	Cadena	N/A
	date_on_sale_from	DateTime	N/A
	date_on_sale_from	DateTime	N/A
	date_on_sale_to	DateTime	N/A
	date_on_sale_to_gmt	DateTime	N/A
	adquirible	Booleano	N/A
	virtual	Booleano	N/A
	descargable	Booleano	N/A
	downloads	Enumeración	N/A
	download_limit	Entero	N/A
	download_expiry	Entero	N/A
	tax_status	Cadena	N/A
	manage_stock	Booleano	N/A
	stock_quantity	Entero	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	pedidos pendientes	Cadena	N/A
	backorders_allowed	Booleano	N/A
	en pedido pendiente	Booleano	N/A
	low_stock_amount	Entero	N/A
	weight	Cadena	N/A
	dimensiones	Struct	N/A
	shipping_class	Cadena	N/A
	shipping_class_id	Entero	N/A
	imagen	Struct	N/A
	atributos	Enumeración	N/A
	menu_order	Entero	N/A
	meta_data	Enumeración	N/A
	context	Cadena	EQUAL_TO
	buscar	Cadena	EQUAL_TO
	después	DateTime	EQUAL_TO
	antes	DateTime	EQUAL_TO
	orden	Cadena	EQUAL_TO
	orderby	Cadena	EQUAL_TO
	URL amigable	Cadena	EQUAL_TO
	status	Cadena	EQUAL_TO

Entidad	Campo	Tipo de datos:	Operadores admitidos
	sku	Cadena	EQUAL_TO
	tax_class	Cadena	EQUAL_TO
	on_sale	Booleano	EQUAL_TO
	min_price	Cadena	EQUAL_TO
	max_price	Cadena	EQUAL_TO
	stock_status	Cadena	EQUAL_TO
report	URL amigable	Cadena	N/A
	Descripción	Cadena	N/A
review-total	URL amigable	Cadena	N/A
	nombre	Cadena	N/A
	total	Entero	N/A
sales-report	total_sales	Cadena	N/A
	net_sales	Cadena	N/A
	average_sales	Cadena	N/A
	total_orders	Entero	N/A
	total_items	Entero	N/A
	total_tax	Cadena	N/A
	total_shipping	Cadena	N/A
	total_refunds	Entero	N/A
	total_discount	Cadena	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	totals_grouped_by	Cadena	N/A
	totales	Struct	N/A
	total_customers	Entero	N/A
	context	Cadena	EQUAL_TO
	periodo	Cadena	EQUAL_TO
	date_min	Date	EQUAL_TO
	date_max	Date	EQUAL_TO
shipping-method	id	Cadena	N/A
	título	Cadena	N/A
	Descripción	Cadena	N/A
shipping-zone	id	Entero	EQUAL_TO
	nombre	Cadena	N/A
	orden	Entero	N/A
shipping-zone-location	code	Cadena	N/A
	type	Cadena	N/A
shipping-zone-method	instance_id	Entero	N/A
	id	Entero	EQUAL_TO
	título	Cadena	N/A
	orden	Entero	N/A
	enabled	Booleano	N/A

Entidad	Campo	Tipo de datos:	Operadores admitidos
	method_id	Cadena	N/A
	method_title	Cadena	N/A
	method_description	Cadena	N/A
	ajustes	Struct	N/A
tax-class	URL amigable	Cadena	N/A
	nombre	Cadena	N/A
tax-rate	id	Entero	N/A
	país	Cadena	N/A
	estado	Cadena	N/A
	código postal	Cadena	N/A
	ciudad	Cadena	N/A
	códigos postales	Enumeración	N/A
	ciudades	Enumeración	N/A
	rate	Cadena	N/A
	nombre	Cadena	N/A
	priority	Entero	N/A
	compuesto	Booleano	N/A
	shipping	Booleano	N/A
	context	Cadena	EQUAL_TO
	orden	Cadena	EQUAL_TO

Entidad	Campo	Tipo de datos:	Operadores admitidos
	orderby	Cadena	EQUAL_TO
	class	Cadena	EQUAL_TO
top-seller-report	nombre	Cadena	N/A
	product_id	Entero	N/A
	quantity	Entero	N/A
	context	Cadena	EQUAL_TO
	periodo	Cadena	EQUAL_TO
	date_min	Date	EQUAL_TO
	date_max	Date	EQUAL_TO

> **Note**
>
> Los tipos de datos de estructura y enumeración se convierten en cadenas, y los de fecha y hora se convierten en marcas de tiempo en la respuesta de los conectores.

Consultas de partición

Partición basada en registros:

Puede proporcionar la opción adicional `NUM_PARTITIONS` de Spark si quiere usar la simultaneidad en Spark. Con estos parámetros, la consulta original se dividiría en un número `NUM_PARTITIONS` de subconsultas que las tareas de Spark pueden ejecutar simultáneamente.

En la partición basada en registros, la cantidad total de registros presentes se consulta desde la API de WooCommerce y se divide por el número proporcionado de `NUM_PARTITIONS`. A continuación, cada subconsulta obtiene simultáneamente el número de registros resultante.

- `NUM_PARTITIONS`: el número de particiones.

Las siguientes entidades admiten la partición basada en registros:

- coupon
- orden
- producto
- product-attribute
- product-attribute-term
- product-category
- product-review
- product-shipping-class
- product-tag
- product-variation
- tax-rate

Ejemplo:

```
woocommerce_read = glueContext.create_dynamic_frame.from_options(
    connection_type="glue.spark.woocommerce",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "coupon",
        "API_VERSION": "v3",
        "INSTANCE_URL": "instanceUrl"
        "NUM_PARTITIONS": "10"
    }
```

Partición basada en registros:

La consulta original se divide en un número `NUM_PARTITIONS` de subconsultas que se pueden ejecutar por tareas Spark de forma simultánea:

- `NUM_PARTITIONS`: el número de particiones.

Ejemplo:

```
WooCommerce_read = glueContext.create_dynamic_frame.from_options(
```

```
    connection_type="WooCommerce",
    connection_options={
        "connectionName": "connectionName",
        "REALMID": "12345678901234567890",
        "ENTITY_NAME": "Bill",
        "API_VERSION": "v3",
        "NUM_PARTITIONS": "10"
    }
```

Opciones de conexión de WooCommerce

Las siguientes son opciones de conexión para WooCommerce:

- `ENTITY_NAME`(cadena): (obligatorio) se usa para lectura. El nombre del objeto en WooCommerce.
- `API_VERSION`(cadena): (obligatorio) se usa para lectura. La versión de API de Rest de WooCommerce que desea utilizar.
- `REALM_ID`(cadena): un identificador que identifica a una empresa individual de WooCommerce Online a la que se envían las solicitudes.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.
- `INSTANCE_URL`(cadena): (obligatorio) una URL de instancia de WooCommerce válida con el formato: https://<instance>.wpcomstaging.com
- `NUM_PARTITIONS`(entero): predeterminado: 1. Se usa para leer. Número de particiones para leer.

Conexión a Zendesk

Zendesk es una solución de administración de centro de ayuda basada en la nube que ofrece herramientas personalizables para crear un portal de atención al cliente, una base de conocimientos y comunidades en línea.

Temas

- Compatibilidad de AWS Glue con Zendesk
- Políticas que contienen las operaciones de la API para crear y usar conexiones

- Configuración de Zendesk
- Configuración de las conexiones a Zendesk
- Lectura desde entidades de Zendesk
- Opciones de conexión a Zendesk
- Limitaciones

Compatibilidad de AWS Glue con Zendesk

AWS Glue es compatible con Zendesk de la siguiente manera:

¿Es compatible como origen?

Sí. Puede utilizar los trabajos de ETL de AWS Glue para consultar datos de Zendesk.

¿Es compatible como destino?

No.

Versiones compatibles de la API de Zendesk

Las siguientes versiones de la API de Zendesk son compatibles

- v2

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS IAM necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
```

```
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si no desea utilizar el método anterior, puede utilizar las siguientes políticas de IAM administradas:

- AWSGlueServiceRole: da acceso a recursos que precisan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: otorga acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la Consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de Zendesk

Antes de poder utilizar AWS Glue para transferir datos desde Zendesk, deberá cumplir estos requisitos:

Requisitos mínimos

Los requisitos mínimos son los siguientes:

- Tener una cuenta de Zendesk. Para obtener más información, consulte Creación de una cuenta de Zendesk.
- La cuenta de Zendesk debe estar habilitada para el acceso de la API.
- Su cuenta de Zendesk le permite instalar aplicaciones conectadas.

Si cumple estos requisitos, estará listo para conectar AWS Glue a la cuenta de Zendesk.

Creación de una cuenta de Zendesk

Para crear una cuenta de Zendesk:

1. Vaya a https://www.zendesk.com/in/register/
2. Introduzca los detalles, como su correo electrónico laboral, nombre, apellido, número de teléfono, cargo, nombre de la empresa, número de empleados de la empresa, contraseña e idioma preferido. A continuación, elija Completar la inscripción de prueba.
3. Después de que se cree la cuenta, complete el enlace de verificación que recibió para verificar su dirección de correo electrónico.
4. Una vez verificada la dirección de correo electrónico laboral, se le redirigirá a su cuenta de Zendesk. Elija la opción Comprar Zendesk para el plan de su elección. Nota: para el conector de Zendesk, se recomienda comprar el plan Suite Enterprise.

Creación de una aplicación cliente y credenciales de OAuth 2.0

Para crear una aplicación cliente y credenciales de OAuth 2.0:

1. Inicie sesión en su cuenta de Zendesk donde desea que se cree la aplicación OAuth 2.0: https://www.zendesk.com/in/login/
2. Haga clic en el ícono del engranaje. Elija el enlace Ir al centro de administración para abrir la página del centro de administración.
3. Elija Aplicaciones e integraciones en la barra lateral izquierda y seleccione API>API de Zendesk.
4. En la página de la API de Zendesk, seleccione la pestaña Clientes de OAuth.
5. Elija Añadir cliente de OAuth en el lado derecho.
6. Complete los siguientes campos para crear un cliente:
   a. Nombre de cliente: especifique un nombre para la aplicación. Este es el nombre que verán los usuarios cuando se les pida que otorguen acceso a su aplicación y cuando consulten la lista de aplicaciones de terceros que tienen acceso a su cuenta de Zendesk.
   b. Descripción: opcional. Una breve descripción de la aplicación que los usuarios verán cuando se les pida que concedan acceso a ella.
   c. Empresa: opcional. El nombre de la empresa que verán los usuarios cuando se les pida que concedan acceso a su aplicación. La información les puede ayudar a entender a quién están concediendo el acceso.

d. Logotipo: opcional. El logotipo que verán los usuarios cuando se les pida que concedan acceso a su aplicación. La imagen puede ser JPG, GIF o PNG. Para obtener mejores resultados, cargue una imagen cuadrada. Se ajustará el tamaño para adaptarlo a la página de autorización.

e. Identificador único: el campo se completa automáticamente con una versión reformateada del nombre que introdujo para la aplicación. Si lo desea, puede cambiarlo.

f. URL de redireccionamiento: introduzca la URL o las URL que Zendesk debe usar para enviar la decisión del usuario de conceder el acceso a su aplicación.

   Por ejemplo: https://us-east-1.console.aws.amazon.com/gluestudio/oauth

7. Haga clic en Guardar.
8. Cuando la página se actualice, aparecerá un nuevo campo Secreto completado previamente en la parte inferior. Es el valor “client_secret” especificado en la especificación de OAuth2. Copie el valor Secreto en su portapapeles y guárdelo en un lugar seguro. Nota: Es posible que los caracteres sobrepasen el ancho del cuadro de texto, así que asegúrese de seleccionarlos todos antes de copiarlos.
9. Haga clic en Guardar.

Configuración de las conexiones a Zendesk

El conector de Zendesk admite el tipo de concesión Código de autorización.

- Este tipo de concesión se considera un OAuth de “tres vías”, ya que se basa en redirigir a los usuarios a un servidor de autorización externo para autenticar al usuario. Se utiliza para crear conexiones a través de la consola de AWS Glue. El usuario que crea una conexión puede, de forma predeterminada, confiar en una aplicación conectada propiedad de AWS Glue (aplicación cliente administrada por AWS Glue) en la que no necesita proporcionar ninguna información relacionada con OAuth, excepto la URL de la instancia de Zendesk. La consola de AWS Glue redirigirá al usuario a Zendesk, donde deberá iniciar sesión y conceder a AWS Glue los permisos solicitados para acceder a la instancia de Zendesk.
- Aún puede optar por crear una aplicación conectada propia en Zendas y proporcionar un ID y secreto de cliente propios al crear conexiones a través de la consola de AWS Glue. En este escenario, aún se abrirá Zendesk para iniciar sesión y autorizar a AWS Glue para que acceda a los recursos.
- Este tipo de concesión da como resultado un token acceso. El token de acceso nunca caduca.

Si desea consultar la documentación pública de Zendesk sobre la creación de una aplicación conectada para el flujo Authorization Code OAuth, consulte Tokens OAuth para tipos de concesión.

Para configurar una conexión a Freshdesk:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles:
   a. Para el tipo de concesión AuthorizationCode: en el caso de una aplicación conectada administrada por el cliente, el secreto debe contener el secreto del consumidor de la aplicación conectada con la clave `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET`.
   b. Nota: Debe crear un secreto por cada conexión en AWS Glue.
2. En AWS Glue Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:
   a. Al seleccionar un Tipo de conexión, elija Zendesk.
   b. Proporcione la INSTANCE_URL del Zendesk al que se desea conectar.
   c. Proporcione el entorno de Zendesk.
   d. Seleccione el rol de AWS IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

      JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

   e. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.

f. Seleccione las opciones de red si quiere usar su red.

3. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.

Lectura desde entidades de Zendesk

Requisito previo

Un objeto de Zendesk desde el que desea leer. Necesitará el nombre del objeto, como el ticket, el usuario o el artículo, tal y como se indica en la siguiente tabla.

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Ticket	Y	Y	Y	Y	N
Usuario	Y	Y	Y	Y	N
Organización	Y	Y	Y	Y	N
Artículo	Y	Y	N	Y	N
Evento de ticket	Y	Y	N	Y	N
Evento de métrica de tickets	Y	Y	N	Y	N
Comentario de tickets	Y	Y	Y	Y	N
Campo de tickets	Y	Y	N	Y	N
Métrica de tickets	Y	Y	N	Y	N
Actividad de tickets	Y	Y	N	Y	N

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Omisión de tickets	N	Y	N	Y	N
Grupo	Y	Y	Y	Y	N
Pertenencia a grupos	N	Y	Y	Y	N
Calificación de satisfacción	Y	Y	N	Y	N
Visualización	Y	Y	Y	Y	N
Desencadenador	Y	Y	Y	Y	N
Categoría de activación	N	Y	Y	Y	N
Macro	Y	Y	Y	Y	N
Automatización	N	Y	Y	Y	N

Ejemplo:

```
Zendesk_read = glueContext.create_dynamic_frame.from_options(
    connection_type="Zendesk",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "Account",
        "API_VERSION": "v2"
    }
```

Detalles de las entidades y los campos de Zendesk:

Entidad	Campo	Tipo de datos:	Operadores admitidos	Comentarios
artículos	url	Cadena		
	id	Largo		
	author_id	Largo		
	cuerpo	Cadena		
	comments_ disabled	Booleano		
	draft	Booleano		
	edited_at	DateTime		
	html_url	Cadena		
	label_names	Enumeración		
	locale	Cadena	EQUAL_TO	
	outdated	Booleano		
	outdated_locales	Enumeración		
	permissio n_group_id	Largo		
	position	Entero		
	promoted	Booleano		
	section_id	Largo		
	source_locale	Cadena		
	nombre	Cadena		

Entidad	Campo	Tipo de datos:	Operadores admitidos	Comentarios
	título	Cadena		
	user_segment_id	Largo		
	content_tags_id	Enumeración		
	vote_count	Entero		
	vote_sum	Entero		
	created_at	DateTime		
	updated_at	DateTime	EQUAL_TO	
	label_name	Cadena	EQUAL_TO	
grupo	url	Cadena		
	id	Largo		
	is_public	Booleano		
	nombre	Cadena		
	Descripción	Cadena		
	predeterminado	Booleano		
	eliminado	Booleano		
	created_at	DateTime		
	updated_at	DateTime		
	exclude_deleted	Booleano	EQUAL_TO	
Automation	url	Cadena		
	id	Largo		

Entidad	Campo	Tipo de datos:	Operadores admitidos	Comentarios
	título	Cadena		
	activa	Booleano		
	created_at	DateTime		
	updated_at	DateTime		
	predeterminado	Booleano		
	acciones	Enumeración		
	positions	Entero		
	condiciones	Struct		
	raw_title	Cadena		
group-membership	url	Cadena		
	id	Largo		
	user_id	Largo		
	group_id	Largo		
	predeterminado	Booleano		
	created_at	DateTime		
	updated_at	DateTime		
macro	url	Cadena		
	id	Largo		
	título	Cadena		
	activa	Booleano	EQUAL_TO	

Entidad	Campo	Tipo de datos:	Operadores admitidos	Comentarios
	created_at	DateTime		
	updated_at	DateTime		
	predeterminado	Booleano		
	acciones	Enumeración		
	position	Entero		
	Descripción	Cadena		
	raw_title	Cadena		
	restricción	Struct		
	acceder	Cadena	EQUAL_TO	
	categoría	Entero	EQUAL_TO	
	group_id	Largo	EQUAL_TO	
	only_viewable	Booleano	EQUAL_TO	
organizaciones	url	Cadena		
	id	Largo		
	external_id	Cadena		
	nombre	Cadena		
	domain_names	Enumeración		
	details	Cadena		
	notas	Cadena		
	group_id	Largo		

Entidad	Campo	Tipo de datos:	Operadores admitidos	Comentarios
	shared_tickets	Booleano		
	shared_comments	Booleano		
	etiquetas	Enumeración		
	organization_fields	Struct		
	created_at	DateTime		
	updated_at	DateTime	EQUAL_TO	
	DML_STATUS	Cadena		Campo definido por el usuario que se utiliza para hacer un seguimiento del estado de creación, actualización y eliminación del registro.
satisfaction-rating	url	Cadena		
	id	Largo		
	assignee_id	Largo		
	comentario	Cadena		
	group_id	Largo		
	razón	Cadena		

Entidad	Campo	Tipo de datos:	Operadores admitidos	Comentarios
	reason_code	Entero		
	reason_id	Largo		
	requester_id	Largo		
	puntuación	Cadena	EQUAL_TO	
	ticket_id	Entero		
	created_at	DateTime		
	updated_at	DateTime	EQUAL_TO	
	start_time	DateTime	EQUAL_TO	
	end_time	DateTime	EQUAL_TO	
	DML_STATUS	Cadena		Campo definido por el usuario que se utiliza para hacer un seguimien to del estado de creación, actualización y eliminación del registro.
ticket-activity	actor	Struct		
	actor_id	Largo		
	created_at	DateTime		
	id	Largo		

Entidad	Campo	Tipo de datos:	Operadores admitidos	Comentarios
	objeto	Struct		
	destino	Struct		
	título	Cadena		
	updated_at	DateTime		
	url	Cadena		
	usuario	Struct		
	user_id	Largo		
	verb	Cadena		
	since	DateTime	EQUAL_TO	
ticket-comment	id	Largo		
	type	Cadena		
	author_id	Largo		
	cuerpo	Cadena		
	html_body	Cadena		
	plain_body	Cadena		
	público	Booleano		
	attachments	Enumeración		
	audit_id	Largo		
	via	Struct		
	created_at	DateTime		

Entidad	Campo	Tipo de datos:	Operadores admitidos	Comentarios
	metadatos	Struct		
	ticket_id	Entero	EQUAL_TO	
	include_inline_images	Booleano	EQUAL_TO	
ticket-events	id	Largo		
	ticket_id	Largo		
	marca de tiempo	Largo		
	created_at	DateTime		
	updater_id	Largo		
	child_events	Enumeración		
	via	Cadena		
	sistema	Struct		
	event_type	Cadena		
	comment_present	Booleano		
	comment_public	Booleano		
	via_reference_id	Largo		
	created_at	DateTime	EQUAL_TO	

Entidad	Campo	Tipo de datos:	Operadores admitidos	Comentarios
	DML_STATUS	Cadena		Campo definido por el usuario que se utiliza para hacer un seguimien to del estado de creación, actualización y eliminación del registro.
ticket-field	url	Cadena		
	id	Largo		
	type	Cadena		
	título	Cadena		
	raw_title	Cadena		
	Descripción	Cadena		
	raw_description	Cadena		
	position	Entero		
	activa	Booleano		
	obligatorio	Booleano		
	collapsed _for_agents	Booleano		
	regexp_fo r_validation	Cadena		

Entidad	Campo	Tipo de datos:	Operadores admitidos	Comentarios
	title_in_portal	Cadena		
	raw_title _in_portal	Cadena		
	visible_in_portal	Booleano		
	editable_ on_portal	Booleano		
	required_ in_portal	Booleano		
	etiqueta	Cadena		
	created_at	DateTime		
	updated_at	DateTime		
	removable	Booleano		
	agent_des cription	Cadena		
	custom_fi eld_options	Enumeración		
	custom_statuses	Enumeración		
	relationship_filter	Struct		
	relations hip_target_type	Cadena		
	sub_type_id	Entero		
	system_fi eld_options	Enumeración		

Entidad	Campo	Tipo de datos:	Operadores admitidos	Comentarios
	locale	Cadena	EQUAL_TO	
ticket-metric-events	id	Largo		
	hora	DateTime	EQUAL_TO	
	ticket_id	Entero		
	métrica	Cadena		
	instance_id	Entero		
	type	Cadena		
	DML_STATUS	Cadena	EQUAL_TO	Campo definido por el usuario que se utiliza para hacer un seguimien to del estado de creación, actualización y eliminación del registro.
ticket-metric	url	Cadena		
	id	Largo		
	ticket_id	Entero		
	created_at	DateTime		
	updated_at	DateTime		
	group_stations	Entero		

Entidad	Campo	Tipo de datos:	Operadores admitidos	Comentarios
	assignee_stations	Entero		
	reopens	Entero		
	replies	Entero		
	assignee_updated_at	DateTime		
	requester_updated_at	DateTime		
	initially_assigned_at	DateTime		
	assigned_at	DateTime		
	solved_at	DateTime		
	last_comment_added_at	DateTime		
	reply_time_in_minutes	Struct		
	first_resolution_time_in_minutes	Struct		
	full_resolution_time_in_minutes	Struct		
	agent_wait_time_in_minutes	Struct		

Entidad	Campo	Tipo de datos:	Operadores admitidos	Comentarios
	requester_wait_time_in_minutes	Struct		
	on_hold_time_in_seconds	Struct		
	reply_time_in_seconds	Struct		
	custom_status_updated_at	DateTime		
ticket-skip	created_at	DateTime		
	id	Largo		
	razón	Cadena		
	ticket	Struct		
	ticket_id	Entero		
	updated_at	DateTime		
	user_id	Largo		
tickets	url	Cadena		
	id	Largo		
	external_id	Cadena	EQUAL_TO	
	type	Cadena		
	subject	Cadena		
	raw_subject	Cadena		

Entidad	Campo	Tipo de datos:	Operadores admitidos	Comentarios
	Descripción	Cadena		
	priority	Cadena		
	status	Cadena		
	destinatario	Cadena		
	solicitante	Struct		
	requester_id	Largo		
	submitter_id	Largo		
	assignee_id	Largo		
	organization_id	Largo		
	group_id	Largo		
	collaborator_ids	Enumeración		
	emails_cc_ids	Enumeración		
	follower_ids	Enumeración		
	forum_topic_id	Ling		
	problem_id	Largo		
	has_incidents	Booleano		
	due_at	DateTime		
	etiquetas	Enumeración		
	via	Struct		
	custom_fields	Enumeración		

Entidad	Campo	Tipo de datos:	Operadores admitidos	Comentarios
	satisfaction_rating	Struct		
	sharing_agreement_ids	Enumeración		
	followup_ids	Enumeración		
	via_followup_source_id	Largo		
	ticket_form_id	Largo		
	brand_id	Largo		
	allow_channelback	Booleano		
	allow_attachments	Booleano		
	is_public	Booleano		
	from_messaging_channel	Booleano		
	created_at	DateTime		
	updated_at	DateTime	EQUAL_TO	
	assignee_email	Cadena		
	attribute_value_ids	Enumeración		
	collaborators	Enumeración		
	comentario	Struct		

Entidad	Campo	Tipo de datos:	Operadores admitidos	Comentarios
	custom_status_id	Largo		
	email_ccs	Struct		
	followers	Struct		
	macro_id	Largo		
	macros_ids	Enumeración		
	metadatos	Struct		
	safe_update	Booleano		
	updated_stamp	DateTime		
	via_id	Largo		
	voice_comment	Struct		
	DML_STATUS	Cadena		Campo definido por el usuario que se utiliza para hacer un seguimien to del estado de creación, actualización y eliminación del registro.
trigger-category	url	Cadena		
	id	Cadena		
	nombre	Cadena		

Entidad	Campo	Tipo de datos:	Operadores admitidos	Comentarios
	updated_at	DateTime		
	created_at	DateTime		
	position	Entero		
Desencadenador	url	Cadena		
	id	Largo		
	título	Cadena		
	activa	Booleano	EQUAL_TO	
	updated_at	DateTime		
	created_at	DateTime		
	predeterminado	Booleano		
	acciones	Enumeración		
	condiciones	Struct		
	Descripción	Cadena		
	position	Entero		
	raw_title	Cadena		
	category_id	Cadena	EQUAL_TO	
usuarios	url	Cadena		
	id	Largo		
	external_id	Cadena	EQUAL_TO	

Entidad	Campo	Tipo de datos:	Operadores admitidos	Comentarios
	correo electrónico	Cadena		
	activa	Booleano		
	alias	Cadena		
	chat_only	Booleano		
	custom_roll_id	Largo		
	roll_type	Entero		
	details	Cadena		
	last_login_at	DateTime		
	locale	Cadena		
	locale_id	Entero		
	moderator	Booleano		
	notas	Cadena		
	nombre	Cadena		
	only_private_comments	Booleano		
	organization_id	Largo		
	default_group_id	Largo		
	phone	Cadena		
	photo	Struct		

Entidad	Campo	Tipo de datos:	Operadores admitidos	Comentarios
	remote_photo_url	Cadena		
	restricted_agent	Booleano		
	rol	Cadena	EQUAL_TO	
	guardado	Booleano		
	shared_agent	Booleano		
	etiqueta	Enumeración		
	firma	Cadena		
	suspended	Booleano		
	ticket_restriction	Cadena		
	time_zone	Cadena		
	iana_time_zone			
	two_factor_auth_enabled			
	user_fields			
	verified	Booleano		
	report_csv	Booleano		
	created_at	DateTime		
	updated_at	DateTime	EQUAL_TO	
	permission_set	Largo	EQUAL_TO	

Entidad	Campo	Tipo de datos:	Operadores admitidos	Comentarios
	shared_phone_number	Booleano		
	DML_STATUS	Cadena		Campo definido por el usuario que se utiliza para hacer un seguimiento del estado de creación, actualización y eliminación del registro.
ver	url	Cadena		
	id	Largo		
	título	Cadena		
	activa	Booleano	EQUAL_TO	
	updated_at	DateTime		
	created_at	DateTime		
	predeterminado	Booleano		
	position	Entero		
	Descripción	Cadena		
	ejecución	Struct		
	restricción	Struct		
	raw_title	Cadena		

Entidad	Campo	Tipo de datos:	Operadores admitidos	Comentarios
	condiciones	Struct		
	acceder	Cadena	EQUAL_TO	
	group_id	Largo	EQUAL_TO	

> **Note**
>
> Los tipos de datos de estructura y lista se convierten en tipos de datos de cadena en respuesta al conector.

Consultas de partición

Zendesk no admite particiones.

Opciones de conexión a Zendesk

Existen las siguientes opciones para establecer conexión con Zendesk:

- `ENTITY_NAME`(cadena): (obligatorio) se usa para lectura. El nombre del objeto en Zendesk.
- `API_VERSION`(cadena): (obligatorio) se usa para lectura. Versión de la API de REST de Zendesk que desea usar. Por ejemplo: v2.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto. Por ejemplo: id, name, url, created_at
- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL. Por ejemplo: group_id = 100
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL. Por ejemplo: “SELECT id,url FROM users WHERE role=\"end-user\"”
- `PARTITION_FIELD`(cadena): se usa para leer. Campo que se utilizará para particionar la consulta. El campo predeterminado es `update_at` para las entidades que admiten la API de exportación incremental (`created_at` para `ticket-events` y `time` para `ticket-metric-events`).
- `LOWER_BOUND`(cadena): se usa para leer. Un valor de límite inferior inclusivo del campo de partición elegido.

- UPPER_BOUND(cadena): se usa para leer. Un valor límite superior exclusivo del campo de partición elegido. Opcional; el conector gestionará esta opción si no se incluye en la opción de trabajo. Valor predeterminado: 2024-05-01T20:55:02.000Z
- NUM_PARTITIONS(entero): predeterminado: 1. Se usa para leer. Número de particiones para leer. Opcional; el conector gestionará esta opción si no se incluye en la opción de trabajo. Valor predeterminado: 1.
- IMPORT_DELETED_RECORDS(cadena): predeterminado: FALSO. Se usa para leer. Para obtener los registros eliminados durante la consulta.
- ACCESS_TOKEN: token de acceso que se utilizará en la solicitud.
- INSTANCE_URL: URL de la instancia en la que el usuario quiere ejecutar las operaciones. Por ejemplo, https://{subdomain}/.zendesk.com

Limitaciones

El conector de Zendesk presenta las siguientes limitaciones:

- La paginación basada en el desplazamiento limita el número de páginas que se pueden solicitar a 100, pero no se recomienda, ya que el número total de registros que se pueden solicitar es de 10 000. Sin embargo, la paginación basada en el cursor que se implementa para el conector de Zendesk supera esta limitación. La API de Zendesk solo admite el operador de filtro EQUAL_TO.

  Debido a esta limitación, el conector de Zendesk no admite la partición.
- Para la entidad “Evento de ticket”, el límite de frecuencia es de 10 solicitudes por minuto. Al ejecutar un trabajo de ETL de AWS Glue, es posible que reciba un error 429 (demasiadas solicitudes).

Conexión a Zoho CRM

Zoho CRM actúa como un repositorio único para reunir las actividades de ventas, marketing y atención al cliente y optimizar los procesos, las políticas y las personas en una sola plataforma. Zoho CRM se puede personalizar fácilmente para satisfacer las necesidades específicas de cualquier tipo y tamaño de empresa.

La plataforma para desarrolladores de Zoho CRM ofrece la combinación perfecta de herramientas sencillas y programables para que las empresas automaticen el trabajo, integren los datos en toda la gama empresarial y creen soluciones personalizadas para la web y los dispositivos móviles.

Temas

- Compatibilidad de AWS Glue con Zoho CRM
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de Zoho CRM
- Configuración de conexiones de Zoho CRM
- Lectura de entidades de Zoho CRM
- Opciones de conexión de Zoho CRM
- Limitaciones y notas del conector de Zoho CRM

Compatibilidad de AWS Glue con Zoho CRM

AWS Glue es compatible con Zoho CRM de la siguiente manera:

¿Es compatible como origen?

Sí: sincrónica y asincrónica. Puede usar los trabajos de ETL de AWS Glue para consultar datos de Zoho CRM.

¿Es compatible como destino?

No.

Versiones de la API de Zoho CRM compatibles

Las siguientes versiones de la API de Zoho CRM son compatibles:

- v7

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS IAM necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
```

```
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si no desea utilizar el método anterior, puede utilizar las siguientes políticas de IAM administradas:

- AWSGlueServiceRole: da acceso a recursos que precisan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: otorga acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la Consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de Zoho CRM

Antes de poder utilizar AWS Glue para transferir datos desde Zoho CRM, debe cumplir estos requisitos:

Requisitos mínimos

Los requisitos mínimos son los siguientes:

- Tiene una cuenta de Zoho CRM.
- Su cuenta de Zoho CRM tiene acceso a la API.

- Tiene un cliente de API registrado en la consola de API para obtener las credenciales de OAuth.

Configuración de conexiones de Zoho CRM

El tipo de concesión determina cómo se comunica AWS Glue con Zoho CRM para solicitar el acceso a sus datos. Su elección afecta a los requisitos que debe cumplir antes de crear la conexión. Zoho CRM solo admite el tipo de concesión AUTHORIZATION_CODE para OAuth 2.0.

- Este tipo de concesión se considera un OAuth de “tres vías”, ya que se basa en redirigir a los usuarios a un servidor de autorización externo para autenticar al usuario. Se utiliza para crear conexiones a través de la consola de AWS Glue. La consola de AWS Glue redirigirá al usuario a Zoho CRM, donde deberá iniciar sesión y permitir a Glue que los permisos solicitados accedan a su instancia de Zoho CRM.
- Los usuarios aún pueden optar por crear su propia aplicación conectada en Zoho CRM y proporcionar su propio ID, URL de autenticación, URL de token y URL de instancia al crear conexiones a través de la consola de AWS Glue. En este escenario, se abrirá Zoho CRM para iniciar sesión y autorizar a AWS Glue para que acceda a sus recursos.
- Este tipo de concesión da como resultado un token de actualización y un token de acceso. El token de acceso seguirá siendo válido durante una hora y se puede actualizar automáticamente sin la interacción del usuario mediante el token de actualización.
- Para ver la documentación pública de Zoho CRM sobre la creación de una aplicación conectada para el flujo de OAuth con código de autorización, consulte Authentication.

Configuración de una conexión de Zoho CRM:

1. En AWS Glue Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:
   a. Al seleccionar un Tipo de conexión, seleccione Zoho CRM.
   b. Proporcione el elemento `INSTANCE_URL` de la instancia de Zoho CRM a la que quiere conectarse.
   c. Proporcione el ID de cliente de la aplicación cliente del usuario.
   d. Seleccione la URL de autenticación correspondiente en el menú desplegable.
   e. Seleccione la URL del token correspondiente en el menú desplegable.
   f. Seleccione el rol de AWS IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

g. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.

h. Seleccione las opciones de red si quiere usar su red.

2. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.
3. En la configuración de su trabajo de AWS Glue, proporcione `connectionName` como Conexión de red adicional.

Lectura de entidades de Zoho CRM

Requisito previo

Objetos de Zoho CRM desde los que desea leer. Necesitará el nombre del objeto.

Entidades compatibles para el origen sincrónico:

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Producto	Sí	Sí	Sí	Sí	Sí

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Cotización	Sí	Sí	Sí	Sí	Sí
Orden de compra	Sí	Sí	Sí	Sí	Sí
Solución	Sí	Sí	Sí	Sí	Sí
Llame a	Sí	Sí	Sí	Sí	Sí
Tarea	Sí	Sí	Sí	Sí	Sí
Evento	Sí	Sí	Sí	Sí	Sí
Factura	Sí	Sí	Sí	Sí	Sí
Cuenta	Sí	Sí	Sí	Sí	Sí
Contacto	Sí	Sí	Sí	Sí	Sí
Proveedor	Sí	Sí	Sí	Sí	Sí
Campaña	Sí	Sí	Sí	Sí	Sí
Acuerdo	Sí	Sí	Sí	Sí	Sí
Cliente potencial	Sí	Sí	Sí	Sí	Sí
Módulo personalizado	Sí	Sí	Sí	Sí	Sí
Pedido de ventas	Sí	Sí	Sí	Sí	Sí
Libros de precios	Sí	Sí	Sí	Sí	Sí

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Caso	Sí	Sí	Sí	Sí	Sí

Ejemplo:

```
zoho_read = glueContext.create_dynamic_frame.from_options(
    connection_type="ZOHO",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "API_VERSION": "v7",
        "INSTANCE_URL": "https://www.zohoapis.in/"
    }
```

Entidades compatibles para el origen asincrónico:

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Producto	Sí	No	No	Sí	No
Cotización	Sí	No	No	Sí	No
Orden de compra	Sí	No	No	Sí	No
Solución	Sí	No	No	Sí	No
Llame a	Sí	No	No	Sí	No
Tarea	Sí	No	No	Sí	No
Evento	Sí	No	No	Sí	No
Factura	Sí	No	No	Sí	No
Cuenta	Sí	No	No	Sí	No

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Contacto	Sí	No	No	Sí	No
Proveedor	Sí	No	No	Sí	No
Campaña	Sí	No	No	Sí	No
Acuerdo	Sí	No	No	Sí	No
Cliente potencial	Sí	No	No	Sí	No
Módulo personalizado	Sí	No	No	Sí	No
Pedido de ventas	Sí	No	No	Sí	No
Libros de precios	Sí	No	No	Sí	No
Caso	Sí	No	No	Sí	No

Ejemplo:

```
zoho_read = glueContext.create_dynamic_frame.from_options(
    connection_type="ZOHO",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "API_VERSION": "v7",
        "INSTANCE_URL": "https://www.zohoapis.in/",
        "TRANSFER_MODE": "ASYNC"
    }
```

Detalles de los campos de Zoho CRM:

Zoho CRM proporciona puntos de conexión para obtener metadatos de forma dinámica para las entidades compatibles. Por lo tanto, la compatibilidad del operador se captura según el tipo de datos.

Entidad	Tipo de datos:	Operadores admitidos
Entidades de Zoho (todas las entidades)	Entero	!=, =, <, <=, >, >=, BETWEEN
	Cadena	Like, =, !=
	BigInteger	!=, =, <, <=, >, >=, BETWEEN
	Booleano	=
	Doble	!=, =, <, <=, >, >=, BETWEEN
	BigDecimal	!=, =, <, <=, >, >=, BETWEEN
	Date	!=, =, <, <=, >, >=, BETWEEN
	DateTime	!=, =, <, <=, >, >=, BETWEEN
	Struct	N/A
	Enumeración	N/A

Consultas de partición

No se admite la partición en el modo asíncrono.

Partición basada en filtros (modo sincrónico):

Puede proporcionar las opciones adicionales de Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` y `NUM_PARTITIONS` si quiere utilizar la simultaneidad en Spark. Con estos parámetros, la consulta original se dividiría en un número `NUM_PARTITIONS` de subconsultas que las tareas de Spark pueden ejecutar simultáneamente.

- `PARTITION_FIELD`: el nombre del campo que se utilizará para particionar la consulta.
- `LOWER_BOUND`: un valor de límite inferior inclusivo del campo de partición elegido.

  En el campo Datetime, aceptamos el formato de marca de tiempo de Spark que se utiliza en las consultas SQL de Spark.

Ejemplos de valor válido:

```
"2024-09-30T01:01:01.000Z"
```

- UPPER_BOUND: un valor límite superior exclusivo del campo de partición elegido.
- NUM_PARTITIONS: el número de particiones.

Ejemplo:

```
zoho_read = glueContext.create_dynamic_frame.from_options(
    connection_type="zohocrm",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "API_VERSION": "v7",
        "PARTITION_FIELD": "Created_Time"
        "LOWER_BOUND": "2022-01-01T01:01:01.000Z"
        "UPPER_BOUND": "2024-01-01T01:01:01.000Z"
        "NUM_PARTITIONS": "10"
    }
```

Opciones de conexión de Zoho CRM

Las siguientes son opciones de conexión para Zoho CRM:

- ENTITY_NAME(cadena): (obligatorio) se usa para lectura. El nombre de su objeto en Zoho CRM.
- API_VERSION(cadena): (obligatorio) se usa para lectura. Versión de la API de REST de Zoho CRM que desea usar.
- SELECTED_FIELDS(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Columnas que desee seleccionar para el objeto.
- FILTER_PREDICATE(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- QUERY(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.
- PARTITION_FIELD(cadena): se usa para leer. Campo que se utilizará para particionar la consulta.
- LOWER_BOUND(cadena): se usa para leer. Un valor de límite inferior inclusivo del campo de partición elegido.

- `UPPER_BOUND`(cadena): se usa para leer. Un valor límite superior exclusivo del campo de partición elegido.
- `NUM_PARTITIONS`(entero): predeterminado: 1. Se usa para leer. Número de particiones para leer.
- `INSTANCE_URL`(cadena): (obligatorio) se usa para lectura. Una URL de la instancia de Zoho CRM válida.
- `TRANSFER_MODE`(Cadena): se usa para indicar si la consulta debe ejecutarse en modo asíncrono.

Limitaciones y notas del conector de Zoho CRM

Las siguientes son limitaciones o notas para el conector de Zoho CRM:

- Con la versión 7 de la API, puede obtener un máximo de 100 000 registros. Consulte la documentación de Zoho.
- En el caso de la entidad del evento, se muestra la etiqueta “Reunión”, tal y como se menciona en la documentación de Zoho.
- Funcionalidad Seleccionar todo:
  - Puede obtener un máximo de 50 campos de SaaS para las llamadas GET y POST.
  - Si desea disponer de datos para algún campo específico que no pertenezca a los primeros 50 campos, tendrá que proporcionar manualmente la lista de campos seleccionados.
  - Si se seleccionan más de 50 campos, todos los campos que superen los 50 campos se recortarán y contendrán datos nulos en Amazon S3.
  - En el caso de una expresión de filtro, si la lista de 50 campos proporcionada por el usuario no incluye “id” ni “Created_Time”, se generará una excepción personalizada para solicitar al usuario que incluya estos campos.
- Los operadores de filtro pueden variar de un campo a otro a pesar de tener el mismo tipo de datos. Por lo tanto, debe especificar manualmente un operador diferente para cualquier campo que desencadene un error en la plataforma de SaaS.
- Funcionalidad Ordenar por:
  - Los datos solo se pueden ordenar por un único campo sin una expresión de filtro, mientras que los datos se pueden ordenar por varios campos cuando se aplica una expresión de filtro.
  - Si no se especifica ningún orden de clasificación para el campo seleccionado, los datos se recuperarán en orden ascendente de forma predeterminada.
- Las regiones compatibles con el conector de Zoho CRM son EE. UU., Europa, India, Australia y Japón.

- Limitaciones de la funcionalidad de lectura asíncrona:
  - Las órdenes limitadas por y la partición no son compatibles en el modo asíncrono.
  - En el modo asíncrono podemos transferir datos de hasta 500 páginas con 200 000 registros por página.
  - Durante un intervalo de un minuto, solo se permiten 10 solicitudes de descarga. Cuando se supera el límite de descargas, el sistema devuelve un error HTTP 429 y detiene todas las solicitudes de descarga por un minuto antes de que se pueda reanudar el procesamiento.
  - Tras completar el trabajo masivo, solo podrá acceder al archivo descargable durante un período de un día. Después de eso, no podrá acceder al archivo a través de puntos de conexión.
  - Se puede proporcionar un máximo de 200 campos seleccionados a través de un punto de conexión. Si especifica más de 200 campos de selección en un punto de conexión, el sistema exportará automáticamente todos los campos disponibles para ese módulo.
  - Sin importar en qué módulos se crearon los campos externos no son compatibles con las API de lectura masiva.
  - La clasificación y las cláusulas `Group_by` no se admiten a través de este punto de conexión de la API.
  - Los valores de los campos con datos de estado confidenciales solo se recuperarán cuando la opción Restringir el acceso a los datos a través de la API en la configuración de cumplimiento esté desactivada. Si la opción está habilitada, el valor aparecerá como vacío en el resultado.
  - Límites de filtrado/criterios
    - El número máximo de criterios que pueden utilizarse en una consulta es 25.
    - No se admite el filtrado ni los criterios en los campos de texto multilínea.

Conexión a Zoom Meetings

Zoom Meetings es una plataforma de videoconferencia basada en la nube que se puede utilizar para reuniones de videoconferencia, audioconferencia, seminarios web, grabaciones de reuniones y chat en directo.

Temas

- Compatibilidad de AWS Glue con Zoom Meetings
- Políticas que contienen las operaciones de la API para crear y usar conexiones
- Configuración de Zoom Meetings
- Configuración de la aplicación cliente Zoom Meetings

- Configuración de las conexiones a Zoom Meetings
- Cómo leer de las entidades de Zoom Meetings
- Opciones de conexión a Zoom Meetings
- Limitaciones de Zoom Meetings

Compatibilidad de AWS Glue con Zoom Meetings

AWS Glue admite Zoom Meetings de la siguiente manera:

¿Es compatible como origen?

Sí. Puede usar los trabajos de ETL de AWS Glue para consultar datos de Zoom Meetings.

¿Es compatible como destino?

No.

Versiones de la API de Zoom Meetings compatibles

Las siguientes versiones de la API de Zoom Meetings son compatibles:

- v2

Políticas que contienen las operaciones de la API para crear y usar conexiones

En el siguiente ejemplo de política se describen los permisos de AWS IAM necesarios para crear y utilizar conexiones. Si va a crear un nuevo rol, cree una política que contenga lo siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListConnectionTypes",
        "glue:DescribeConnectionType",
```

```
        "glue:RefreshOAuth2Tokens",
        "glue:ListEntities",
        "glue:DescribeEntity"
      ],
      "Resource": "*"
    }
  ]
}
```

Si no desea utilizar el método anterior, puede utilizar las siguientes políticas de IAM administradas:

- AWSGlueServiceRole: da acceso a recursos que precisan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AWSGlueConsoleFullAccess: otorga acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza la Consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Esta política se suele adjuntar a los usuarios de la consola AWS Glue.

Configuración de Zoom Meetings

Antes de poder utilizar AWS Glue para transferir datos desde Zoom Meetings, deberá cumplir estos requisitos:

Requisitos mínimos

Los requisitos mínimos son los siguientes:

- Tener una cuenta de Zoom Meetings.
- La cuenta de Zoom debe estar habilitada para el acceso de API.
- Haber creado una aplicación OAuth 2 en la cuenta de Zoom Meetings. Esta integración proporciona las credenciales que AWS Glue utiliza para acceder a sus datos de forma segura cuando hace llamadas autenticadas a su cuenta. Para obtener más información, consulte the section called “Configuración de la aplicación cliente Zoom Meetings”.

Si cumple estos requisitos, estará listo para conectar AWS Glue a la cuenta de Zoom Meetings. Para conexiones típicas, no necesita hacer nada más en Zoom Meetings.

Configuración de la aplicación cliente Zoom Meetings

1. Inicie sesión en Zoom App Marketplace.
2. Elija Desarrollar > Crear aplicación.
3. Elija Aplicación general para una aplicación basada en OAuth 2.0.
4. En la página Información básica, agregue o actualice información sobre la aplicación, como el nombre de la aplicación, el modo en que se administra, las credenciales de la aplicación y la información de OAuth.
5. En la sección Seleccione cómo se administra la aplicación, confirme el modo en que desea que se administre la aplicación:
   a. Administrada por el administrador: los administradores de la cuenta agregan y administran la aplicación
   b. Administrada por el usuario: los usuarios individuales agregan y administran la aplicación. La aplicación solo tiene acceso a los datos autorizados del usuario.
6. Credenciales de la aplicación: el flujo de compilación genera automáticamente credenciales de aplicación (ID de cliente y secreto de cliente) para la aplicación.
7. En la sección Información de OAuth, configure OAuth para la aplicación.
   a. URL de redireccionamiento de OAuth (obligatorio): ingrese la URL de redirección o el punto de conexión para configurar OAuth entre la aplicación y Zoom.
   b. Utilizar URL de modo estricto (opcional)
   c. Comprobación de subdominio (opcional)
   d. Listas de permitidos de OAuth (obligatorio): agregue cualquier URL única que Zoom deba permitir como redirecciones válidas para los flujos de OAuth.
8. En la página Ámbitos, seleccione los métodos de la API de Zoom a los que la aplicación tiene permitido llamar. Los ámbitos definen qué información y capacidades están disponibles para el usuario. Seleccione los siguientes ámbitos detallados:
   - user:read:list_users:admin
   - zoom_rooms:read:list_rooms:admin
   - group:read:list_members:admin
   - group:read:administrator:admin

- group:read:list_groups:admin
- report:read:admin
- role:read:list_roles, role:read:list_roles:admin

Una vez agregados los ámbitos, seleccione Continuar y la aplicación estará lista para su uso.

Para obtener más información sobre la configuración de OAuth 2.0, consulte Integraciones (aplicaciones OAuth).

Configuración de las conexiones a Zoom Meetings

Zoom Meetings admite el tipo de concesión AUTHORIZATION_CODE para OAuth2. El tipo de concesión determina cómo AWS Glue se comunica con Zoom Meetings para solicitar el acceso a los datos.

- Este tipo de concesión se considera un OAuth de “tres vías”, ya que se basa en redirigir a los usuarios a un servidor de autorización externo para autenticar al usuario. Se utiliza para crear conexiones a través de la consola de AWS Glue. El usuario que crea una conexión debe proporcionar información relacionada con OAuth, como el ID de cliente y el secreto de cliente para la aplicación cliente de Zoom Meetings. La consola de AWS Glue redirigirá al usuario a Zoom, donde deberá iniciar sesión y conceder a AWS Glue los permisos solicitados para acceder a la instancia de Zoom Meetings.
- Los usuarios aún pueden optar por crear una aplicación conectada propia en Zoom Meetings y proporcionar un ID de cliente y un secreto de cliente propios al crear conexiones a través de la consola de AWS Glue. En este caso, aún se les redirigirá a Zoom Meetings para que inicien sesión y autoricen a AWS Glue a acceder a sus recursos.
- Este tipo de concesión da como resultado un token de actualización y un token de acceso. El token de acceso es de corta duración y se puede actualizar automáticamente sin la interacción del usuario mediante el token de actualización.
- Para obtener documentación pública de Zoom Meetings sobre la creación de una aplicación conectada para el flujo Authorization Code OAuth, consulte Uso de OAuth 2.0.

Para configurar una conexión a Zoom Meetings:

1. En AWS Secrets Manager, cree un secreto con los siguientes detalles:

a. En el caso de las aplicaciones conectadas administradas por el cliente, el secreto debe contener el secreto del consumidor de la aplicación conectada con `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET` como clave.

b. Nota: Debe crear un secreto para las conexiones en AWS Glue.

1. En AWS Glue Glue Studio, cree una conexión en Conexiones de datos según los pasos que se indican a continuación:

   a. Al seleccionar un Tipo de conexión, elija Zoom Meetings.

   b. Indique el entorno de Zoom Meetings al que se desea conectar.

   c. Seleccione el rol de AWS IAM que AWS Glue pueda asumir y que tenga permisos para las siguientes acciones:

      JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:DescribeSecret",
        "secretsmanager:GetSecretValue",
        "secretsmanager:PutSecretValue",
        "ec2:CreateNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
  ]
}
```

   d. Seleccione el `secretName` que desee usar para esta conexión en AWS Glue para colocar los tokens.

   e. Seleccione las opciones de red si quiere usar su red.

2. Conceda el rol de IAM asociado a su permiso de trabajo de AWS Glue para leer `secretName`.

Cómo leer de las entidades de Zoom Meetings

Requisito previo

Un objeto de Zoom Meetings del que desea leer. Necesitará el nombre del objeto, por ejemplo `Group` o `Zoom Rooms`.

Entidades compatibles como origen:

Entidad	Se puede filtrar	Admite límite	Admite Ordenar por	Admite Seleccionar *	Admite partición
Zoom Rooms	No	Sí	No	Sí	No
Grupo	No	No	No	Sí	No
Miembro del grupo	Sí	Sí	No	Sí	No
Administrador de grupo	No	Sí	No	Sí	No
Informe (diario)	Sí	No	No	Sí	No
Roles	No	No	No	Sí	No
Usuarios	Sí	Sí	No	Sí	No

Ejemplo:

```
zoom_read = glueContext.create_dynamic_frame.from_options(
    connection_type="zoom",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "organization",
        "API_VERSION": "v2"
    }
)
```

Detalles de entidades y campos de Zoom Meetings:

Zoom Meetings carga dinámicamente los campos disponibles bajo la entidad seleccionada. Según el tipo de datos de los campos, se admiten los operadores de filtro siguientes.

Entidad	Campo	Tipo de datos:	Operadores admitidos	
Zoom Room	status	Cadena	=	
	type	Cadena	=	
	unassigned_rooms	Booleano	=	
	location_id	Cadena	=	
	room_id	Cadena	N/A	
	activation_code	Cadena	N/A	
	id	Cadena	N/A	
	nombre	Cadena	N/A	
	tag_ids	Cadena	N/A	
	query_name	Cadena	N/A	
Informe diario	month	Date	=	
	date	Date	N/A	
	meeting_minutes	Entero	N/A	
	reuniones	Entero	N/A	
	new_users	Entero	N/A	
	participantes	Entero	N/A	
	group_id	Cadena	N/A	

Entidad	Campo	Tipo de datos:	Operadores admitidos	
Usuario	created_at	DateTime	N/A	
	departamento	Cadena	N/A	
	correo electrónico	Cadena	N/A	
	employee_unique_id	Cadena	N/A	
	first_name	Cadena	N/A	
	group_ids	Enumeración	N/A	
	host_key	Cadena	N/A	
	id	Cadena	N/A	
	im_group_ids	Cadena	N/A	
	last_client_version	Cadena	N/A	
	last_login_time	DateTime	N/A	
	last_name	Cadena	N/A	
	plan_united_type	Cadena	N/A	
	custom_attributes	Enumeración	N/A	
	pmi	BigInteger	N/A	
	role_id	Cadena	=	
	status	Cadena	=	

Entidad	Campo	Tipo de datos:	Operadores admitidos	
	timezone	Cadena	N/A	
	type	Entero	N/A	
	verified	Entero	N/A	
	user_created_at	DateTime	N/A	
	display_name	Cadena	N/A	
	phone_number	Cadena	N/A	
	idioma	Cadena	N/A	
	licencia	Cadena	=	
Grupo	id	Cadena	N/A	
	nombre	Cadena	N/A	
	total_members	Entero	N/A	
Miembro del grupo	correo electrónico	Cadena	N/A	
	first_name	Cadena	N/A	
	id	Cadena	N/A	
	last_name	Cadena	N/A	
	type	Entero	N/A	
	primary_group	Booleano	N/A	
	member_id	Cadena	N/A	
Administrador de grupo	id	Cadena	N/A	

Entidad	Campo	Tipo de datos:	Operadores admitidos	
	correo electrónico	Cadena	N/A	
	nombre	Cadena	N/A	
rol	Descripción	Cadena	N/A	
	id	Cadena	N/A	
	nombre	Cadena	N/A	
	total_members	Entero	N/A	
	type	Cadena	=	

Consultas de partición

Zoom Meetings no admite la partición basada en filtros ni la partición basada en registros.

Opciones de conexión a Zoom Meetings

A continuación se indican las opciones de conexión para Zoom Meetings:

- `ENTITY_NAME`(cadena): (obligatorio) se usa para lectura. El nombre de la entidad de Zoom Meetings. Por ejemplo, `group`.
- `API_VERSION`(cadena): (obligatorio) se usa para lectura. Versión de la API de Rest de Zoom Meetings que desea utilizar. El valor será `v2`, ya que Zoom Meetings actualmente solo admite la versión v2.
- `SELECTED_FIELDS`(lista<Cadena>): predeterminado: empty(SELECT *). Se usa para leer. Una lista separada por comas de las columnas que desea seleccionar para la entidad seleccionada.
- `FILTER_PREDICATE`(cadena): predeterminado: vacío. Se usa para leer. Debe estar en el formato de Spark SQL.
- `QUERY`(cadena): predeterminado: vacío. Se usa para leer. Consulta completa de Spark SQL.

Limitaciones de Zoom Meetings

Las siguientes son limitaciones o notas correspondientes a Zoom Meetings:

- Zoom Meetings no admite orderby.
- Zoom Meetings no admite la partición basada en filtros porque no hay ningún campo que pueda satisfacer los criterios requeridos.
- Zoom Meetings no es compatible con la partición basada en registros porque no admite el límite de paginación ni la paginación basada en desplazamiento.

Agregar una conexión JDBC con sus propios controladores JDBC

Puede utilizar su propio controlador JDBC cuando utilice una conexión JDBC. Si el controlador predeterminado utilizado por el rastreador AWS Glue no puede conectarse a una base de datos, puede utilizar su propio controlador JDBC. Por ejemplo, si desea utilizar el SHA-256 con su base de datos de Postgres y los controladores Postgres más antiguos no lo admiten, puede utilizar su propio controlador JDBC.

Orígenes de datos compatibles

Orígenes de datos compatibles	Orígenes de datos no compatibles
MySQL	Snowflake
Postgres	
Oracle	
Redshift	
SQL Server	
Aurora*	

*Se admite si se utiliza el controlador JDBC nativo. No se pueden aprovechar todas las funciones del controlador.

Agregar un controlador JDBC a una conexión JDBC

> **Note**
>
> Si decide incorporar sus versiones de controladores JDBC, los rastreadores AWS Glue consumirán recursos en trabajos AWS Glue y en los buckets de Amazon S3 para garantizar que los controladores proporcionados se ejecuten en su entorno. El uso adicional de los recursos se reflejará en su cuenta. El costo de los rastreadores AWS Glue y los trabajos se incluye en la categoría AWS Glue de facturación. Además, proporcionar su propio controlador JDBC no significa que el rastreador pueda aprovechar todas las funciones del controlador.

Agregar su propio controlador JDBC a una conexión JDBC:

1. Agregue el archivo del controlador JDBC a una ubicación de Amazon S3. Puede crear un bucket o una carpeta o utilizar un bucket o una carpeta existente.
2. En la consola AWS Glue, seleccione Conexiones en el menú de la izquierda, en el catálogo de datos y luego cree una conexión nueva.
3. Rellene los campos de las Propiedades de la conexión y elija JDBC para Tipo de conexión.
4. En Acceso a la conexión, ingrese la URL del JDBC y el nombre de la clase de controlador del JDBC: opcional. El nombre de la clase de controlador debe corresponder a un origen de datos compatible con los rastreadores AWS Glue.

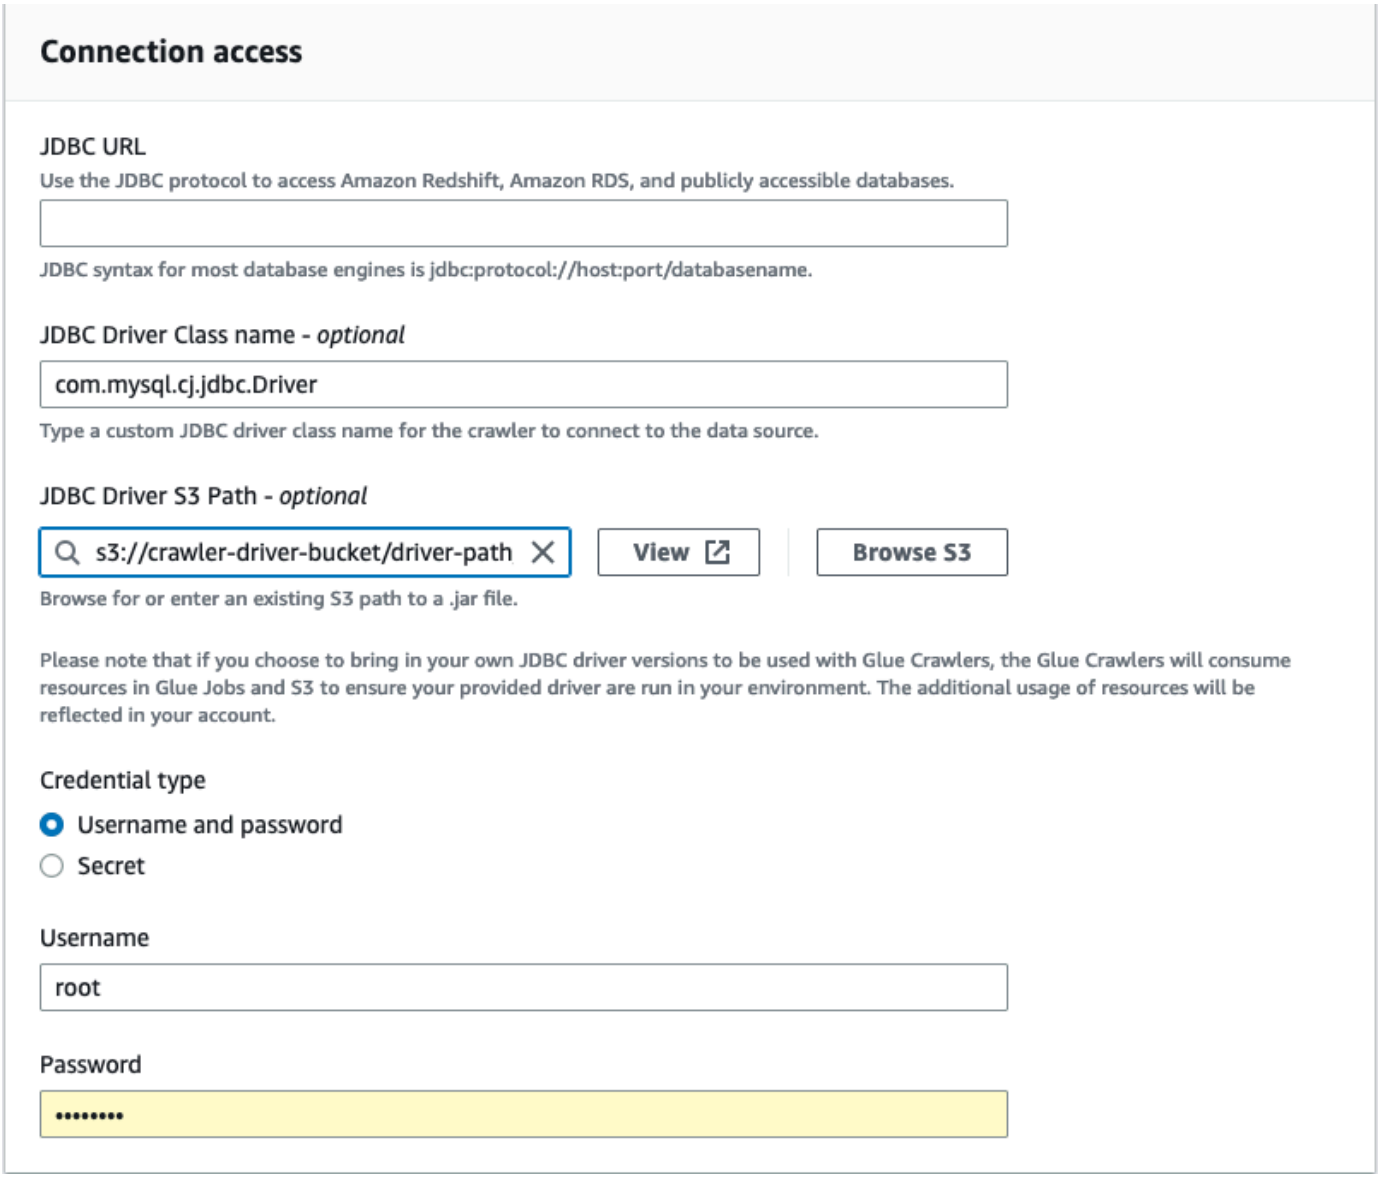

5. Elija la ruta de Amazon S3 en la que se encuentra el controlador JDBC en el campo Ruta Amazon S3 del controlador JDBC: opcional.
6. Rellene los campos correspondientes al tipo de credencial si ingresa un nombre de usuario y una contraseña o un secreto. Cuando haya terminado, elija Crear conexión.

> **Note**
>
> Las pruebas de conexiones no son compatibles en la actualidad. Al rastrear el origen de datos con un controlador JDBC que haya proporcionado, el rastreador omite este paso.

7. Agregue la conexión recién creada a un rastreador. En la consola AWS Glue, seleccione Rastreadores en el menú de la izquierda, en el Catálogo de datos y cree un rastreador nuevo.

8. En el asistente Agregar rastreadores, en el paso 2, elija Agregar un origen de datos.

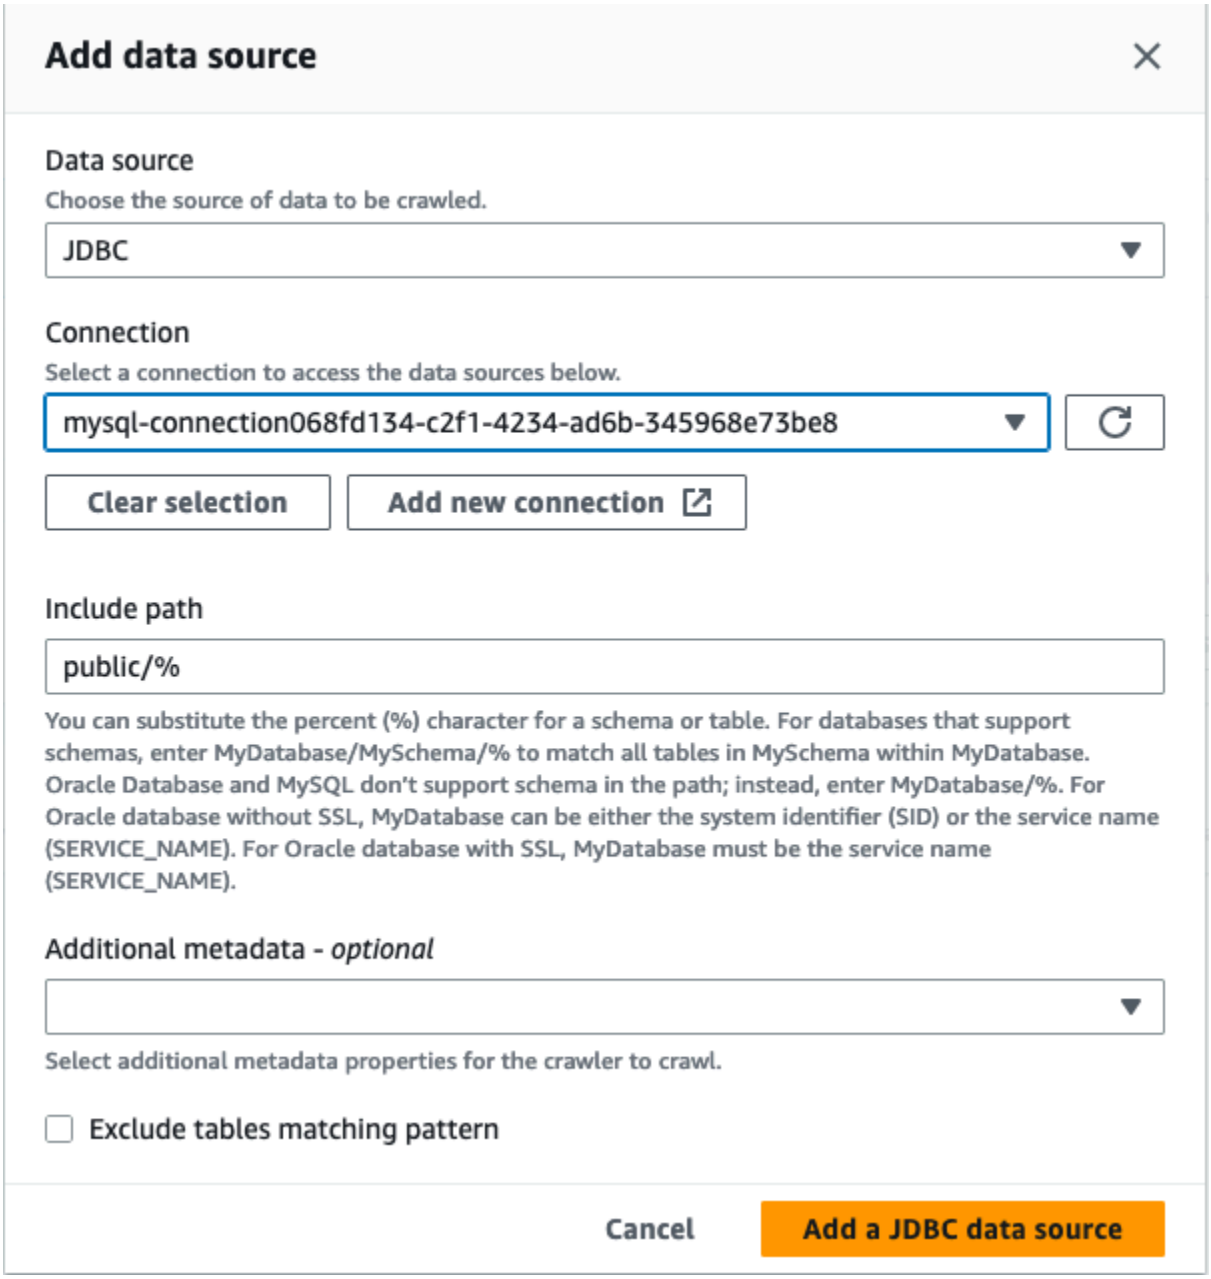

9. Elija JDBC como origen de datos y elija la conexión que se creó en los pasos anteriores. Control

10. Para utilizar su propio controlador JDBC con un rastreador AWS Glue, agregue los siguientes permisos a la función utilizada por el rastreador:

    - Conceda permisos para las siguientes acciones de trabajos: `CreateJob`, `DeleteJob`, `GetJob`, `GetJobRun`, `StartJobRun`.
    - Conceda permisos para las acciones de IAM: `iam:PassRole`

- Conceda permisos para todas las acciones de Amazon S3: `s3:DeleteObjects`, `s3:GetObject`, `s3:ListBucket`, `s3:PutObject`.
- Conceda al director de servicio acceso al bucket o carpeta en la política de IAM.

Política de IAM de ejemplo:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Sid": "VisualEditor0",
      "Effect": "Allow",
      "Action": [
        "s3:PutObject",
        "s3:GetObject",
        "s3:ListBucket",
        "s3:DeleteObject"
      ],
      "Resource": [
        "arn:aws:s3:::amzn-s3-demo-bucket/driver-parent-folder/driver.jar",
        "arn:aws:s3:::amzn-s3-demo-bucket"
      ]
    }
  ]
}
```

El rastreador de AWS Glue crea dos carpetas: _glue_job_crawler y _crawler.

Si el archivo jar del controlador se encuentra en la carpeta `s3://amzn-s3-demo-bucket/driver.jar"`, agregue los siguientes recursos:

```
"Resource": [
                "arn:aws:s3:::amzn-s3-demo-bucket/_glue_job_crawler/*",
    "arn:aws:s3:::amzn-s3-demo-bucket/_crawler/*"
            ]
```

Si el archivo jar del controlador se encuentra en la carpeta `s3://amzn-s3-demo-bucket/tmp/driver/subfolder/driver.jar"`, agregue los siguientes recursos:

```
"Resource": [
               "arn:aws:s3:::amzn-s3-demo-bucket/tmp/_glue_job_crawler/*",
    "arn:aws:s3:::amzn-s3-demo-bucket/tmp/_crawler/*"
            ]
```

11. Si utiliza una VPC, debe permitir el acceso al punto de conexión AWS Glue al crear el punto de conexión de la interfaz y agregarlo a la tabla de enrutamiento. Para obtener más información, consulte Creación de un punto de conexión de VPC para AWS Glue.
12. Si utiliza el cifrado en su catálogo de datos, cree el punto de conexión de la interfaz AWS KMS y agréguelo a la tabla de enrutamiento. Para obtener más información, consulte Crear un punto de conexión de VPC para AWS KMS.

Uso de conectores y conexiones personalizados con AWS Glue Studio

AWS Glue proporciona soporte integrado con los almacenes de datos más utilizados (como Amazon Redshift, Amazon Aurora, Microsoft SQL Server, MySQL, MongoDB y PostgreSQL) mediante conexiones JDBC. AWS Glue también permite usar controladores JDBC personalizados en sus trabajos de extracción, transformación y carga (ETL). Para los almacenes de datos no soportados de forma nativa, como las aplicaciones de software como servicio (SaaS), puede utilizar conectores.

Un conector es un paquete de códigos opcionales que ayuda a acceder a almacenes de datos en AWS Glue Studio. Puede suscribirse a varios conectores ofrecidos en AWS Marketplace.

Al crear trabajos de ETL, puede usar un almacén de datos soportado de forma nativa, un conector de AWS Marketplace, o sus propios conectores personalizados. Si utiliza un conector, primero debe crear una conexión para el conector. Una conexión contiene las propiedades necesarias para conectarse a un almacén de datos determinado. Utilice la conexión con los orígenes de datos y los destinos de datos en el trabajo de ETL. Los conectores y las conexiones funcionan en conjunto para facilitar el acceso a los almacenes de datos.

Las siguientes conexiones están disponibles al crear conexiones para conectores:

- Amazon Aurora: un motor de base de datos relacional escalable y de alto rendimiento con seguridad, copia de seguridad y restauración integradas y aceleración en memoria.
- Amazon DocumentDB: un servicio de base de datos de documentos escalable, de alta disponibilidad y totalmente gestionado que admite las API de MongoDB y SQL.
- Amazon Redshift: un servicio de base de datos de documentos escalable, de alta disponibilidad y totalmente administrado que admite las API de MongoDB y SQL.
- Azure SQL: un servicio de base de datos relacional basado en la nube de Microsoft Azure que proporciona capacidades de administración y almacenamiento de datos escalables, fiables y seguras.
- Cosmos DB: un servicio de base de datos en la nube distribuido a nivel mundial de Microsoft Azure que proporciona capacidades de consulta y almacenamiento de datos escalables y de alto rendimiento.
- Google BigQuery: almacenamiento de datos en la nube sin servidor para ejecutar consultas SQL rápidas en conjuntos de datos de gran tamaño.
- JDBC: un sistema de administración de base de datos relacional (RDBMS) que utiliza una API de Java para conectarse e interactuar con las conexiones de datos.
- Kafka: una plataforma de procesamiento de flujos de código abierto que se utiliza para el flujo de datos y la mensajería en tiempo real.
- MariaDB: una bifurcación de MySQL desarrollada por la comunidad que ofrece rendimiento, escalabilidad y características mejorados.
- MongoDB: una base de datos multiplataforma orientada a documentos que proporciona alta escalabilidad, flexibilidad y rendimiento.
- MongoDB Atlas: una oferta de base de datos como servicio (DBaaS) basada en la nube de MongoDB que simplifica la administración y el escalado de las implementaciones de MongoDB.
- Microsoft SQL Server: un sistema de administración de base de datos relacional (RDBMS) de Microsoft que proporciona sólidas capacidades de almacenamiento, análisis e informes de datos.
- Mixpanel: una plataforma de análisis que ayuda a las empresas a analizar cómo los usuarios interactúan con los sitios web, aplicaciones móviles y otros productos digitales.
- MySQL: un sistema de administración de bases de datos relacionales (RDBMS) de código abierto que se usa ampliamente en aplicaciones web y es conocido por su fiabilidad y escalabilidad.
- Red: un origen de datos de red representa un recurso o servicio accesible desde la red al que se puede acceder mediante una plataforma de integración de datos.

- OpenSearch: un origen de datos de OpenSearch es una aplicación a la que OpenSearch puede conectarse y desde la que puede ingerir datos.
- Oracle: un sistema de administración de base de datos relacional (RDBMS) de Oracle Corporation que proporciona sólidas capacidades de almacenamiento, análisis e informes de datos.
- PostgreSQL: un sistema de administración de base de datos relacional (RDBMS) de código abierto que proporciona sólidas capacidades de almacenamiento, análisis e informes de datos.
- Salesforce: Salesforce proporciona un software de gestión de relaciones con los clientes (CRM) que lo ayuda con las ventas, el servicio al cliente, el comercio electrónico y más. Si es usuario de Salesforce, puede conectar AWS Glue a su cuenta de Salesforce. A continuación, puede utilizar Salesforce como origen o destino de datos en sus trabajos de ETL. Ejecute estos trabajos para transferir datos entre Salesforce y los servicios de AWS u otras aplicaciones compatibles.
- SAP HANA: una plataforma de análisis y base de datos en memoria que proporciona un procesamiento rápido de datos, análisis avanzados e integración de datos en tiempo real.
- Snowflake: un almacén de datos basado en la nube que proporciona servicios de análisis y almacenamiento de datos escalables y de alto rendimiento.
- Teradata: un sistema de administración de base de datos relacional (RDBMS) que proporciona capacidades de almacenamiento, análisis e informes de datos de alto rendimiento.
- Vertica: almacenamiento de datos analíticos orientado a columnas diseñado para el análisis de macrodatos que ofrece un rendimiento de consultas rápido, análisis avanzados y escalabilidad.

Creación de conectores personalizados

También puede crear su propio conector y después cargar el código en AWS Glue Studio.

Los conectores personalizados están integrados en AWS Glue Studio a través de la API de tiempo de ejecución de AWS Glue Spark. El tiempo de ejecución de AWS Glue Spark le permite conectar cualquier conector que cumpla con la interfaz de Spark, Athena o JDBC. Le permite transferir cualquier opción de conexión que esté disponible con el conector personalizado.

Puede encapsular todas sus propiedades de conexión con Conexiones de AWS Glue y proporcionar el nombre de la conexión para su trabajo de ETL. La integración con las conexiones del Catálogo de datos le permite utilizar las mismas propiedades de conexión en varias llamadas en una sola aplicación Spark o entre diferentes aplicaciones.

Puede especificar opciones adicionales para la conexión. El script de trabajo que genera AWS Glue Studio contiene una entrada de `Datasource` que utiliza la conexión para conectar el conector con las opciones especificadas. Por ejemplo:

```
Datasource = glueContext.create_dynamic_frame.from_options(connection_type =
"custom.jdbc", connection_options = {"dbTable":"Account","connectionName":"my-custom-
jdbc-
connection"}, transformation_ctx = "DataSource0")
```

Para agregar un conector personalizado a AWS Glue Studio

1. Cree el código para su conector personalizado. Para obtener más información, consulte Desarrollo de conectores personalizados.
2. Agregue soporte para características de AWS Glue a su conector. Aquí hay algunos ejemplos de estas características y cómo se utilizan dentro del script de trabajo generado por AWS Glue Studio:

   - Mapeo de tipos de datos: el conector puede convertir el tipo de las columnas mientras las lee desde el almacén de datos subyacente. Por ejemplo, un `dataTypeMapping` de `{"INTEGER":"STRING"}` convierte todas las columnas de tipo `Integer` a columnas de tipo `String` al analizar los registros y construir el archivo `DynamicFrame`. Esto ayuda a los usuarios a convertir columnas en los tipos de su elección.

     ```
     DataSource0 = glueContext.create_dynamic_frame.from_options(connection_type
     = "custom.jdbc", connection_options = {"dataTypeMapping":{"INTEGER":"STRING"}",
     connectionName":"test-connection-jdbc"}, transformation_ctx = "DataSource0")
     ```

   - Partición para lecturas paralelas: AWS Glue permite leer datos paralelos desde el almacén de datos particionando los datos en una columna. Debe especificar la columna de partición, el límite inferior de partición, el límite superior de partición y el número de particiones. Esta función le permite hacer uso del paralelismo de datos y de varios ejecutores Spark asignados para la aplicación Spark.

     ```
     DataSource0 = glueContext.create_dynamic_frame.from_options(connection_type
     = "custom.jdbc", connection_options = {"upperBound":"200","numPartitions":"4",
     "partitionColumn":"id","lowerBound":"0","connectionName":"test-connection-jdbc"},
     transformation_ctx = "DataSource0")
     ```

- Usar AWS Secrets Manager para almacenar credenciales: la conexión del Catálogo de datos también puede contener un `secretId` para un secreto almacenado en AWS Secrets Manager. El secreto de AWS puede almacenar de forma segura la información de autenticación y credenciales y proporcionársela a AWS Glue en tiempo de ejecución. También puede especificar el `secretId` del script de Spark de la siguiente manera:

```
DataSource = glueContext.create_dynamic_frame.from_options(connection_type
= "custom.jdbc", connection_options = {"connectionName":"test-connection-jdbc",
 "secretId"-> "my-secret-id"}, transformation_ctx = "DataSource0")
```

- Filtrar los datos de origen con predicados de fila y proyecciones de columna: el tiempo de ejecución de AWS Glue Spark también permite a los usuarios insertar consultas SQL para filtrar datos en el origen con predicados de fila y proyecciones de columna. Esto permite que su trabajo de ETL cargue datos filtrados más rápidamente desde los almacenes de datos que admiten inserciones. Un ejemplo de consulta SQL insertada a un origen de datos JDBC es: `SELECT id, name, department FROM department WHERE id < 200.`

```
DataSource = glueContext.create_dynamic_frame.from_options(connection_type =
"custom.jdbc", connection_options = {"query":"SELECT id, name, department FROM
 department
WHERE id < 200","connectionName":"test-connection-jdbc"}, transformation_ctx =
"DataSource0")
```

- Marcadores de trabajo: AWS Glue admite la carga progresiva de datos de orígenes JDBC. AWS Glue realiza un seguimiento del último registro procesado del almacén de datos y procesa nuevos registros de datos en las siguientes ejecuciones de trabajos de ETL. Los marcadores de trabajo utilizan la clave principal como columna predeterminada para la clave de marcador, siempre que esta columna aumente o disminuya en forma secuencial. Para obtener más información acerca de los marcadores de trabajo, consulte Marcadores de trabajo en la Guía para desarrolladores de AWS Glue.

```
DataSource0 = glueContext.create_dynamic_frame.from_options(connection_type =
"custom.jdbc", connection_options = {"jobBookmarkKeys":["empno"],
 "jobBookmarkKeysSortOrder"
:"asc", "connectionName":"test-connection-jdbc"}, transformation_ctx =
 "DataSource0")
```

3. Empaquete el conector personalizado como un archivo JAR y cárguelo a Amazon S3.

4. Pruebe su conector personalizado. Para obtener más información, consulte las instrucciones en GitHub en Conectores personalizados de Glue: guía de pruebas de validación local.
5. En la consola de AWS Glue Studio, elija Connectors (Conectores) en el panel de navegación de la consola.
6. En la página Connectors (Conectores), seleccione Create custom connector (Crear conector personalizado).
7. En la página Create custom connector (Crear conector personalizado), ingrese la siguiente información:
   - La ruta a la ubicación del archivo JAR de código personalizado en Amazon S3.
   - Un nombre para el conector que utilizará AWS Glue Studio.
   - El tipo de conector, que puede ser JDBC, Spark o Athena.
   - El nombre del punto de entrada dentro del código personalizado que AWS Glue Studio invoca para utilizar el conector.
     - Para los conectores JDBC, este campo debe ser el nombre de clase del controlador JDBC.
     - En el caso de los conectores Spark, este campo debe ser el nombre de clase del origen de datos completo, o su alias, que se utiliza al cargar el origen de datos Spark con el operador de `format`.
   - (Sólo JDBC) la dirección URL base utilizada por la conexión JDBC para el almacén de datos.
   - (Opcional) descripción del conector personalizado.
8. Elija Create connector (Crear conector).
9. Desde la página Connectors (Conectores), cree una conexión que utilice este conector, tal y como se describe en Creación de conexiones para conectores.

Agregar conectores a AWS Glue Studio

Un conector es un fragmento de código que facilita la comunicación entre el almacén de datos y AWS Glue. Puede suscribirse a un conector ofrecido en AWS Marketplace o puede crear su propio conector personalizado.

Suscripción a conectores de AWS Marketplace

AWS Glue Studio facilita el agregado de conectores desde AWS Marketplace.

Para agregar un conector de AWS Marketplace a AWS Glue Studio

1. En la consola de AWS Glue Studio, elija Connectors (Conectores) en el panel de navegación de la consola.
2. En la página Connectors (Conectores), elija Go to AWS Marketplace (Ir a MKT).
3. En AWS Marketplace, Featured products (Productos destacados) elija el conector que desea usar. Puede elegir uno de los conectores destacados o utilizar la búsqueda. Puede buscar el nombre o el tipo de conector, y puede utilizar opciones para refinar los resultados de búsqueda.

   Si desea utilizar uno de los conectores destacados, elija View product (Ver producto). Si utilizó la búsqueda para localizar un conector, elija el nombre del conector.
4. En la página de producto del conector, utilice las pestañas para ver información sobre el conector. Si decide comprar este conector, elija Continue to Subscribe (Continuar con la suscripción).
5. Proporcione la información de pago y, a continuación, elija Continue to Configure (Continuar con la configuración).
6. En la página Configure this software (Configurar este software), elija el método de implementación y la versión del conector que se va a utilizar. A continuación, elija Continue to Launch (Continuar con el lanzamiento).
7. En la página Launch this software (Lanzar este software), puede revisar las Usage Instructions (Instrucciones de uso) proporcionada por el proveedor del conector. Cuando esté listo para continuar, elija Activate connection in AWS Glue Studio (Activar conexión en AWS Glue Studio).

   Después de cierto tiempo, la consola muestra la página Create marketplace connection (Crear conexión de marketplace) en AWS Glue Studio.
8. Cree una conexión que utilice este conector, tal y como se describe en Creación de conexiones para conectores.

   También puede elegir Activate connector only (Activar sólo el conector) para omitir la creación de una conexión en este momento. Debe crear una conexión en una fecha posterior antes de poder usar el conector.

Creación de conexiones para conectores

Una conexión de AWS Glue es un objeto del Catálogo de datos que almacena información de conexión para un almacén de datos determinado. Las conexiones almacenan credenciales de inicio

de sesión, cadenas de URI, información de nube privada virtual (VPC), etc. Al crear conexiones en el Catálogo de datos se ahorra el esfuerzo de tener que especificar todos los detalles de conexión cada vez que se crea un trabajo.

Para crear una conexión para un conector

1. En la consola de AWS Glue Studio, elija Conectores en el panel de navegación de la consola. En la sección Conexiones, elija Crear conexión.
2. Elija el origen de datos para la que desee crear una conexión en el paso 1 del asistente de Creación de conexiones de datos. Existen varias maneras de ver los orígenes de datos disponibles, como:

   - Filtrar los orígenes de datos disponibles seleccionando una pestaña. De forma predeterminada, está seleccionada la opción Todos los conectores.
   - Seleccione Lista para ver los orígenes de datos en forma de lista o vuelva a Cuadrícula para ver los conectores disponibles en el diseño de cuadrícula.
   - Utilice la barra de búsqueda para reducir la lista de orígenes de datos. A medida que escribe, se muestran las coincidencias de búsqueda y los orígenes que no coinciden se eliminan de la vista.

   Una vez que haya elegido el origen de datos, elija Siguiente.
3. Configure la conexión en el paso 2 del asistente.

   Ingrese los detalles de conexión. En función del tipo de conector que haya seleccionado, se le pedirá que ingrese información adicional:

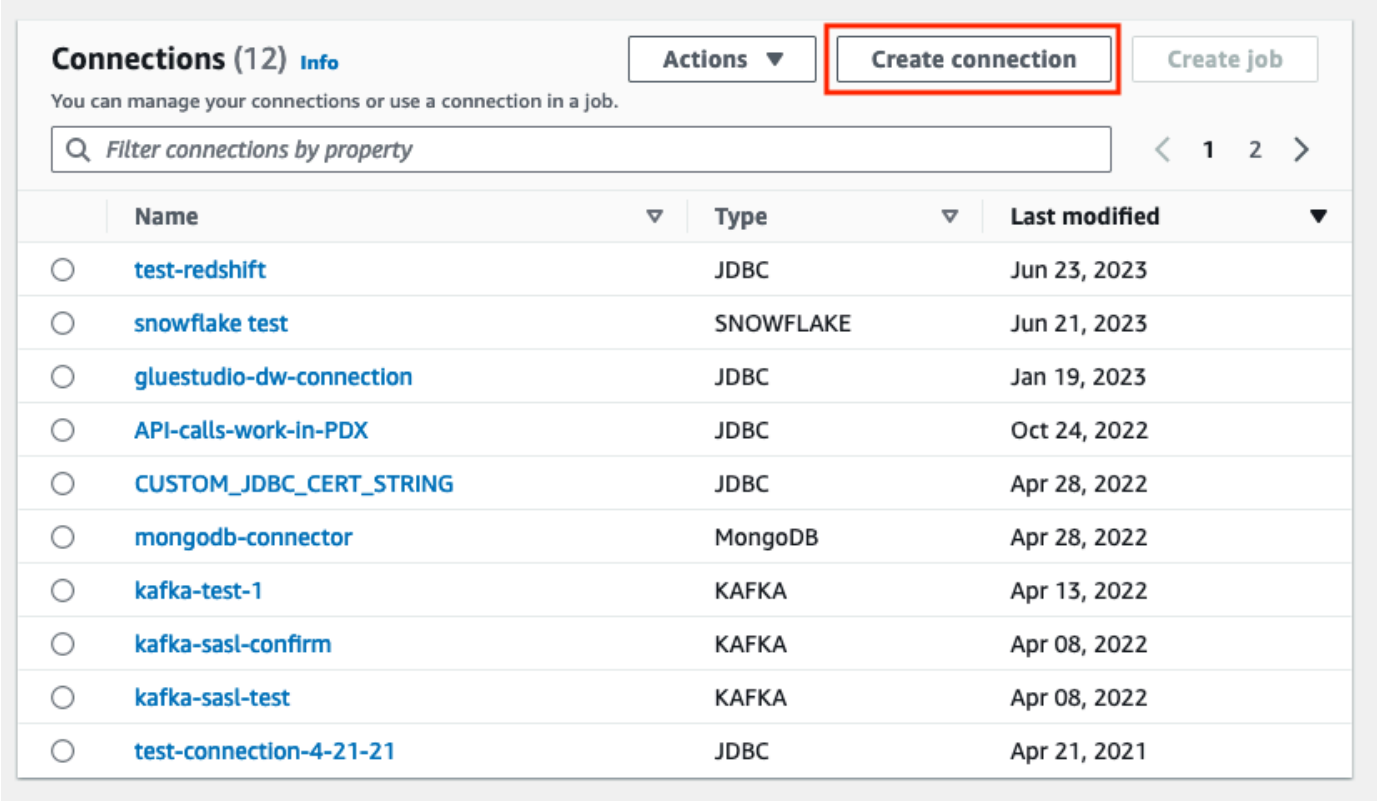

4. Elija el origen de datos para la que desee crear una conexión en el paso 1 del asistente de Creación de conexiones de datos. Existen varias maneras de ver los orígenes de datos disponibles. De forma predeterminada, verá todos los orígenes de datos disponibles en un diseño de cuadrícula. También puede:

   - Seleccione Lista para ver los orígenes de datos en forma de lista o vuelva a Cuadrícula para ver los conectores disponibles en el diseño de cuadrícula.
   - Utilice la barra de búsqueda para reducir la lista de orígenes de datos. A medida que escribe, se muestran las coincidencias de búsqueda y los orígenes que no coinciden se eliminan de la vista.

   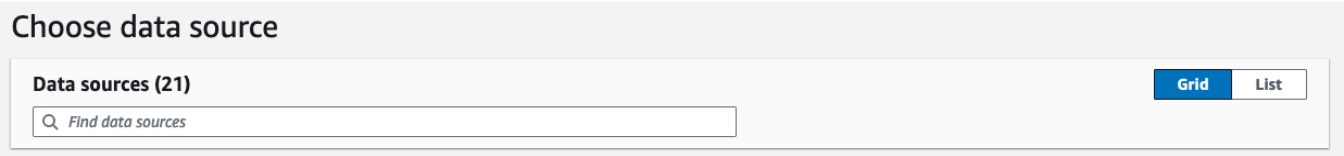

   Una vez que haya elegido el origen de datos, elija Siguiente.

5. Configure la conexión en el paso 2 del asistente.

Ingrese los detalles de conexión. En función del tipo de conector que haya seleccionado, se le pedirá que ingrese información adicional de la conexión. Esto puede incluir:

- Detalles de la conexión: estos campos cambiarán en función del origen de datos a la que se conecte. Por ejemplo, si se conecta a las bases de datos de Amazon DocumentDB, introducirá la URL de Amazon DocumentDB. Si se está conectando a Amazon Aurora, elegirá la instancia de la base de datos e ingresará el nombre de la base de datos. Los siguientes son los detalles de conexión necesarios para Amazon Aurora:

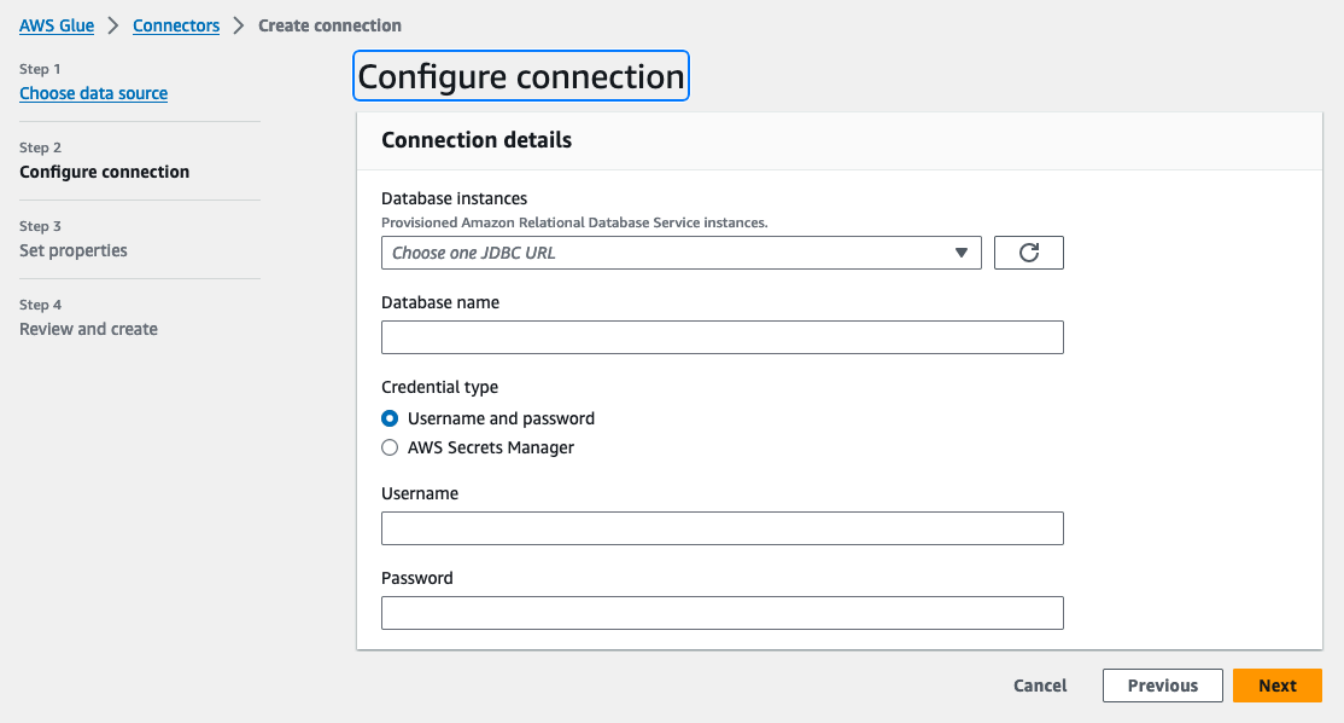

- Tipo de credencial: elija entre Nombre de usuario y contraseña o AWS Secrets Manager. Introduzca la información de autenticación solicitada.
- Para los conectores que utilizan JDBC, ingrese la información necesaria para crear la dirección URL JDBC para el almacén de datos.
- Si usa una nube privada virtual (VPC), ingrese la información de red de su VPC.

6. Establezca las propiedades de conexión en el paso 3 del asistente. Puede añadir una descripción y etiquetas como parte opcional de este paso. El nombre es obligatorio y viene rellenado previamente con un valor predeterminado. Elija Siguiente.
7. Revise el origen, los detalles y las propiedades de la conexión. Seleccione Editar para realizar cambios en cualquiera de los pasos del asistente. Cuando esté listo, elija Crear conexión.

   Elija Crear conexión.

Será dirigido a la página Conectores y el banner informativo le indicará la conexión que se creó. Ahora puede utilizar la conexión en los trabajos de AWS Glue Studio.

Creación de una conexión Kafka

Al crear una conexión Kafka, si se selecciona la opción Kafka en el menú desplegable, se mostrarán configuraciones adicionales que puede establecer:

- Detalles del clúster de Kafka
- Autenticación
- Cifrado
- Opciones de red

Configuración del clúster de Kafka

1. Elija la ubicación del clúster. Puede elegir entre un streaming administrado de Amazon para un clúster Apache Kafka (MSK o un clúster Apache Kafka administrado por el cliente. Para obtener más información sobre streaming administrado de Amazon para Apache Kafka, consulte Amazon managed streaming for Apache Kafka (MSK).

   > **Note**
   >
   > Amazon Managed Streaming for Apache Kafka solo admite métodos de autenticación TLS y SASL/SCRAM-SHA-512.

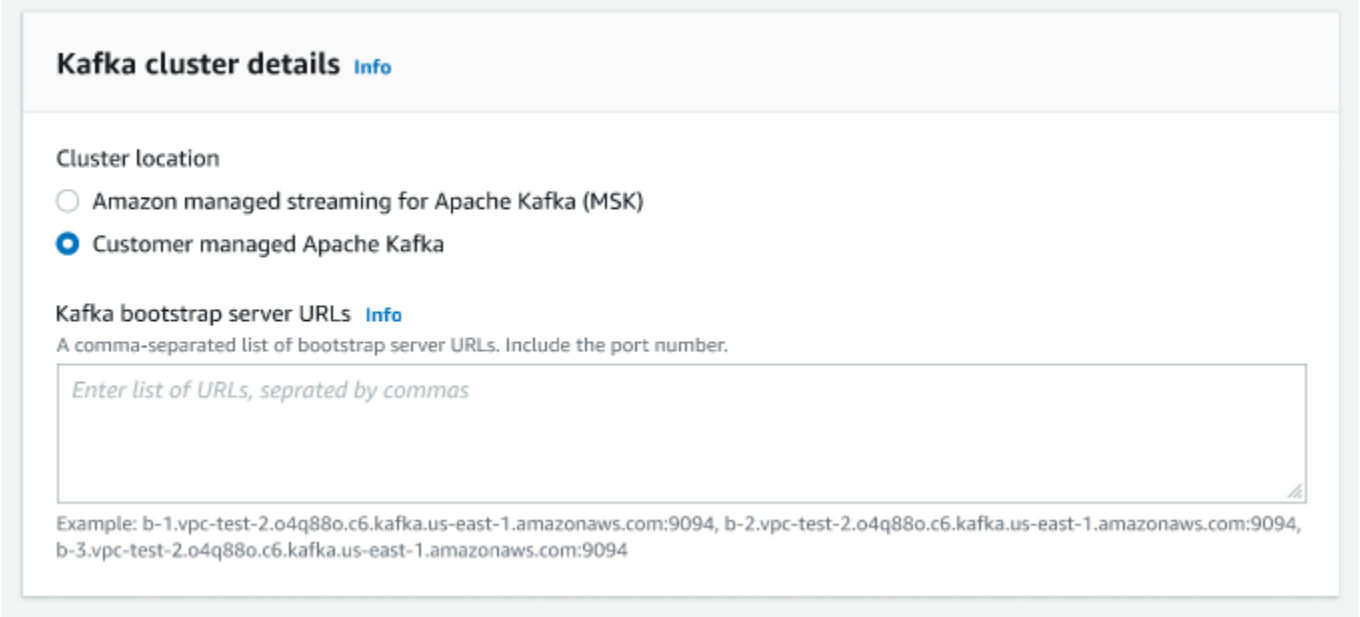

2. Ingrese las URL de sus servidores Bootstrap de Kafka. Puede ingresar más de uno separando cada servidor por una coma. Incluya el número de puerto al final de la URL agregando `:<port number>`.

   Por ejemplo: `b-1.vpc-test-2.034a88o.kafka-us-east-1.amazonaws.com:9094`

Seleccione un método de autenticación

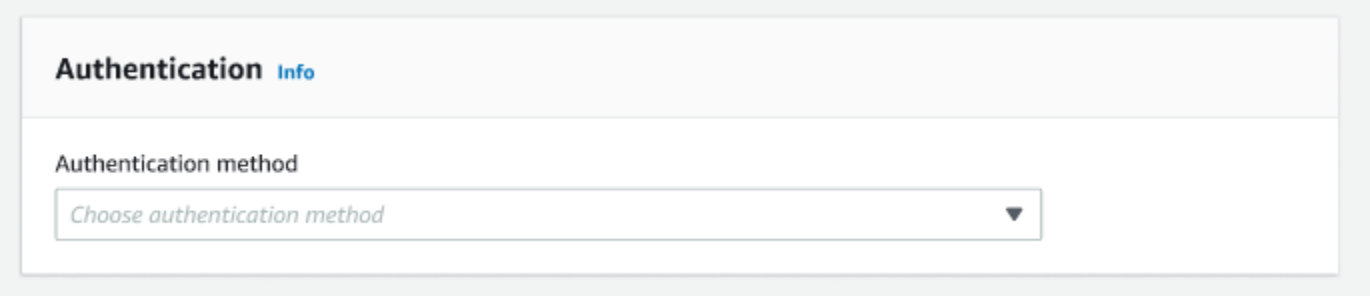

AWS Glue admite el marco de autenticación simple y capa de seguridad (SASL) para la autenticación. El esquema SASL es compatible con distintos mecanismos de autenticación; AWS Glue ofrece los protocolos SCRAM (nombre de usuario y contraseña), GSSAPI (protocolo Kerberos) y PLAIN (nombre de usuario y contraseña).

Al elegir un método de autenticación en el menú desplegable, se pueden seleccionar los siguientes métodos de autenticación de clientes:

- Ninguno: sin autenticación. Esto resulta útil si crea una conexión con fines de prueba.
- SASL/SCRAM-SHA-512: elija este método de autenticación para especificar credenciales de autenticación. Existen dos opciones disponibles:
  - Utilizar AWS Secrets Manager (recomendado): si selecciona esta opción, puede almacenar sus credenciales en AWS Secrets Manager y dejar que AWS Glue acceda a la información cuando sea necesario. Especificar el secreto donde están almacenadas las credenciales de autenticación SSL o SASL.

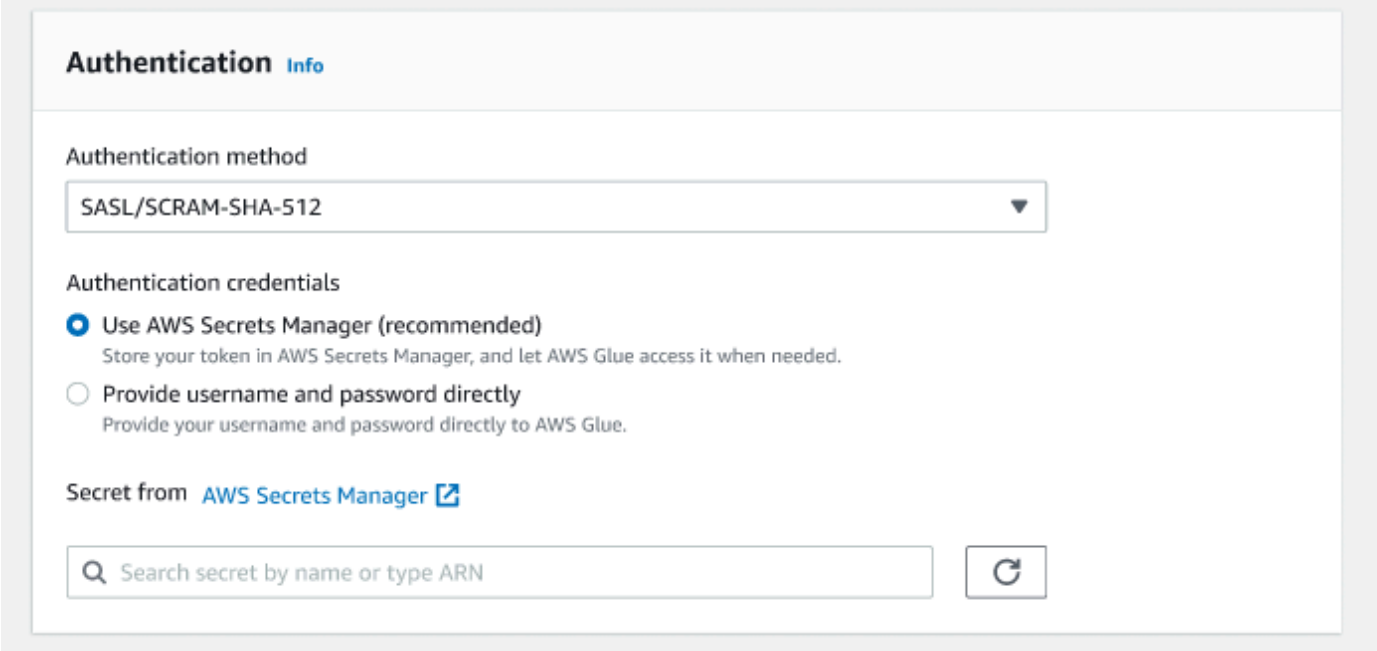

  - Brinde de manera directa un usuario y una contraseña.
- SASL/GSSAPI (Kerberos): si selecciona esta opción, puede seleccionar la ubicación del archivo keytab, el archivo krb5.conf e ingresar el nombre principal y el nombre del servicio de Kerberos. Las ubicaciones de los archivos keytab y krb5.conf deben estar en una ubicación de Simple Storage Service (Amazon S3). Dado que MSK aún no admite SASL/GSSAPI, esta opción solo está disponible para clústeres Apache Kafka administrados por el cliente. Para obtener más información, consulte MIT Kerberos Documentation: Keytab (Documentación de MIT Kerberos: Keytab).
- SASL/PLAIN: seleccione este método de autenticación para especificar las credenciales de autenticación. Existen dos opciones disponibles:
  - Utilizar AWS Secrets Manager (recomendado): si selecciona esta opción, puede almacenar sus credenciales en AWS Secrets Manager y dejar que AWS Glue acceda a la información cuando sea necesario. Especificar el secreto donde están almacenadas las credenciales de autenticación SSL o SASL.

  - Brinde de manera directa un usuario y una contraseña.
- Autenticación de cliente SSL: si selecciona esta opción, puede seleccionar la ubicación del almacén de claves del cliente Kafka navegando por Simple Storage Service (Amazon S3). Opcionalmente, puede ingresar la contraseña del almacén de claves del cliente Kafka y la contraseña de clave de cliente Kafka.

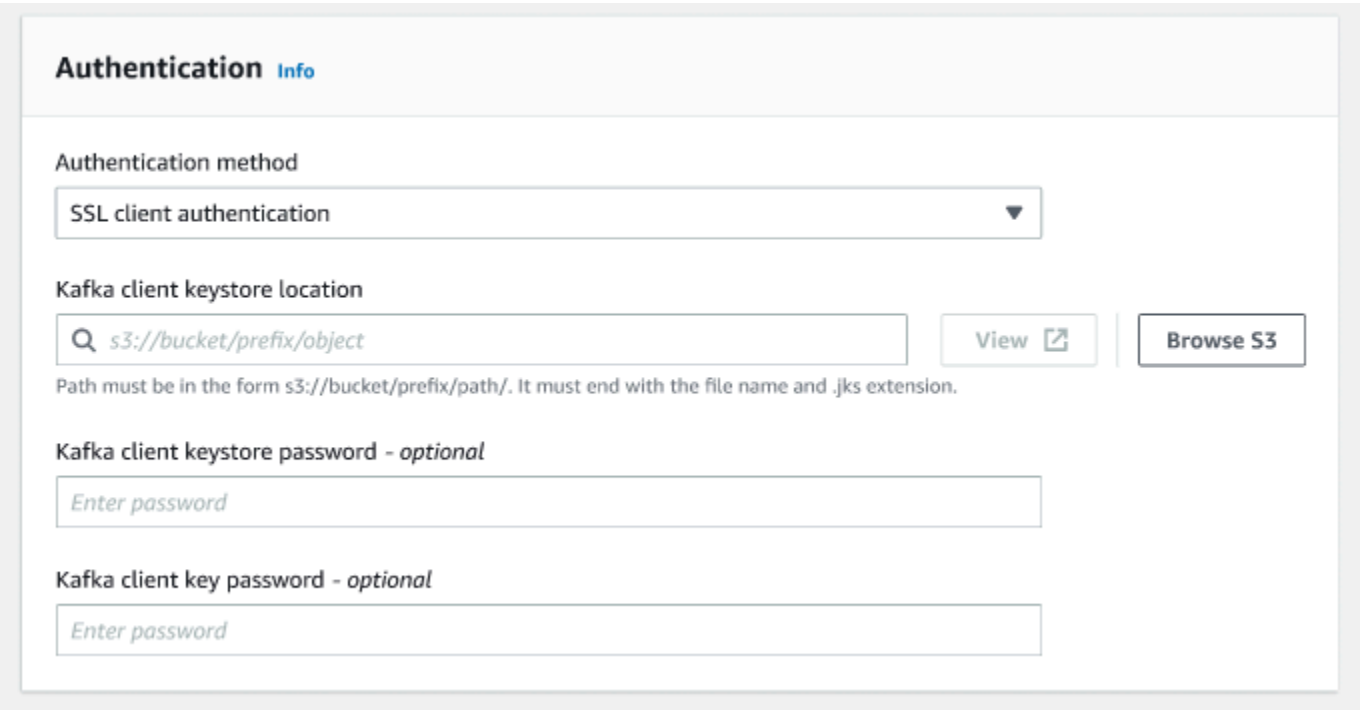

Establecimiento de la configuración de cifrado

1. Si la conexión Kafka requiere una conexión SSL, active la casilla de verificación de Require SSL connection (Requerir conexión SSL). Tenga en cuenta que la conexión fallará si no puede conectarse a través de SSL. El SSL para el cifrado es opcional y puede utilizarse con cualquier método de autenticación (como SASL/SCRAM-SHA-512, SASL/GSSAPI, SASL/PLAIN o SSL Client Authentication).

   Si el método de autenticación se establece en SSL client authentication (Autenticación de cliente SSL), esta opción se seleccionará automáticamente y se desactivará para evitar cambios.
2. (Opcional). Elija la ubicación del certificado privado de la entidad de certificación (CA). Tenga en cuenta que la ubicación de la certificación debe estar en una ubicación de S3. Elija la opción Browse (Explorar) para elegir el archivo de un bucket de S3 conectado. La ruta debe tener el

formato `s3://bucket/prefix/filename.pem`. Debe terminar con el nombre de archivo y la extensión .pem.

3. Puede optar por omitir la validación del certificado de una entidad de certificación (CA). Elija la casilla de verificación Skip validation of certificate from certificate authority (CA) (Omitir la validación del certificado de la entidad de certificación [CA]). Si esta casilla no está marcada, AWS Glue valida certificados para tres algoritmos:

   - SHA256withRSA
   - SHA384withRSA
   - SHA512withRSA

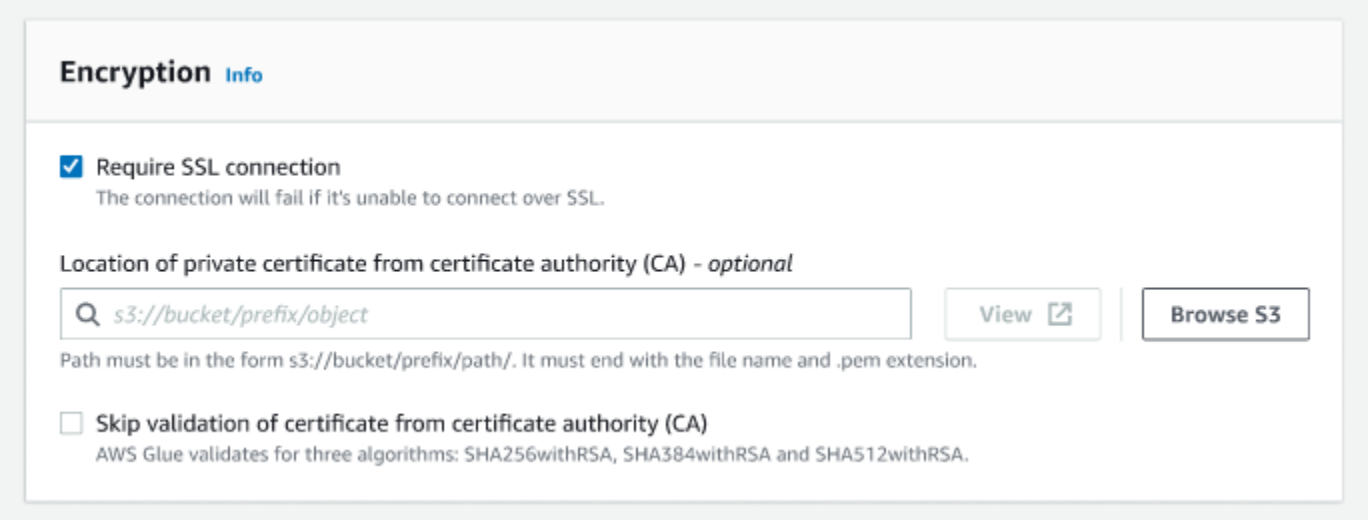

(Opcional) Opciones de red

A continuación, se indican pasos opcionales para configurar la VPC, subred y grupos de seguridad. Si el trabajo de AWS Glue debe ejecutarse en instancias de Amazon EC2 en una subred de nube virtual privada (VPC), debe proporcionar información adicional de configuración específica de la VPC.

1. Elija el nombre de la nube virtual privada (VPC) que contenga el origen de datos.
2. Elija una subred con su VPC.
3. Elija uno o más grupos de seguridad que permitan el acceso al almacén de datos de la subred VPC. Los grupos de seguridad están asociados a la ENI asociada a la subred. Debe elegir al menos un grupo de seguridad con una regla de entrada con autorreferencia para todos los puertos TCP.

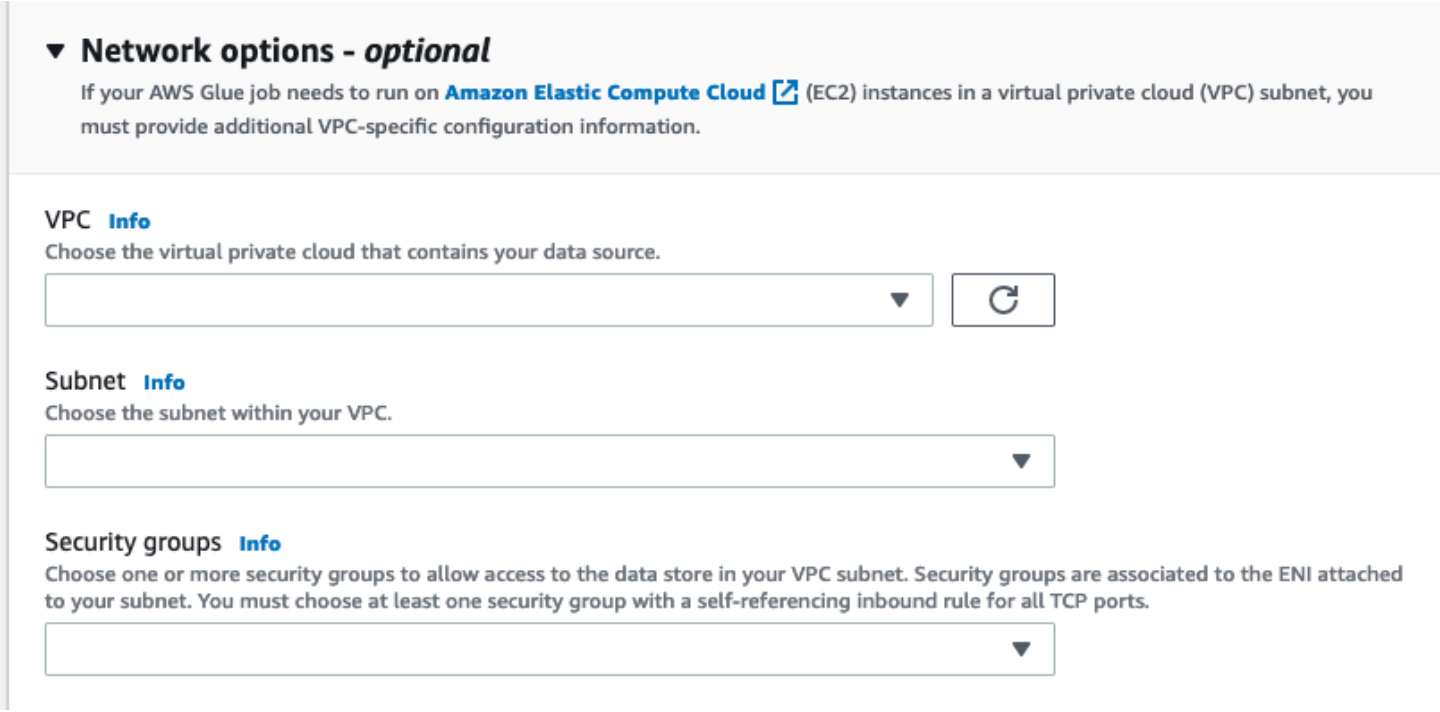

Creación de trabajos con conectores personalizados

Puede utilizar conectores y conexiones tanto para nodos de origen de datos como para nodos de destino de datos en AWS Glue Studio.

Temas

- Creación de trabajos que utilicen un conector para el origen de datos
- Configuración de las propiedades de origen para los nodos que utilizan conectores
- Configuración de las propiedades de destino para los nodos que utilizan conectores

Creación de trabajos que utilicen un conector para el origen de datos

Al crear un nuevo trabajo, puede elegir un conector para el origen de datos y los destinos de datos.

Para crear un trabajo que utilice conectores para el origen de datos o el destino de datos

1. Inicie sesión en la Consola de administración de AWS y abra la consola de AWS Glue Studio en https://console.aws.amazon.com/gluestudio/.
2. En la página Connectors (Conectores), en la lista de recursos Your connections (Sus conexiones), elija la conexión que desea usar en su trabajo y, a continuación, elija Create job (Crear el trabajo).

Como alternativa, en la página Jobs (Trabajos) de AWS Glue Studio, en Create job (Crear el trabajo), elija Source and target added to the graph (Origen y destino agregados al gráfico). En la lista desplegable Source (Origen), elija el conector personalizado que desea usar en el trabajo. También puede elegir un conector para Target (Destino).

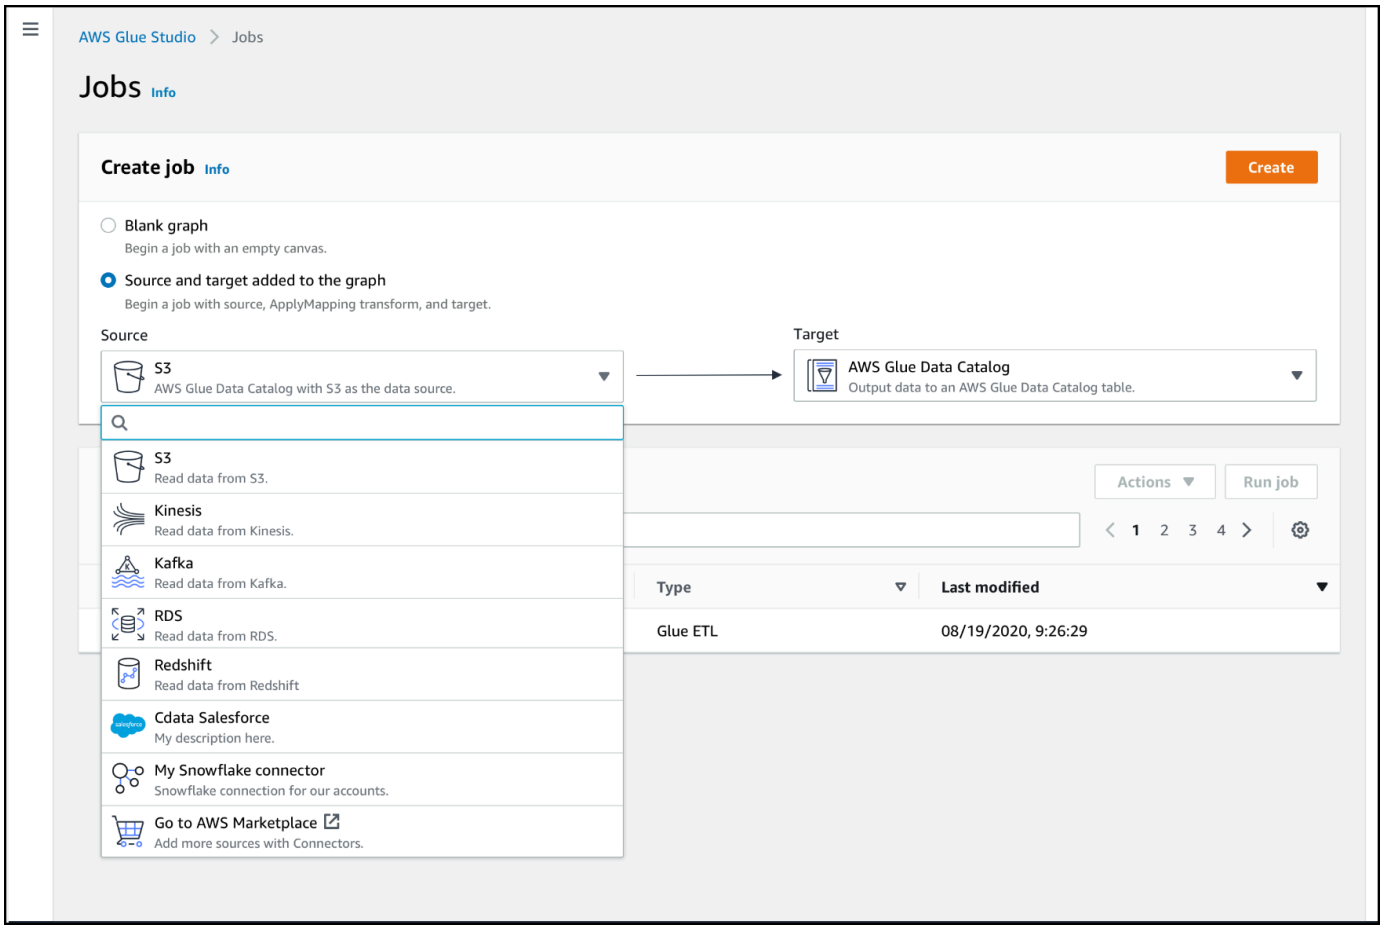

3. Elija Create (Crear) para abrir el editor visual de trabajos.
4. Configure el nodo de origen de datos, como se describe en Configuración de las propiedades de origen para los nodos que utilizan conectores.
5. Continúe creando su trabajo de ETL mediante el agregado de transformaciones, almacenes de datos adicionales y destinos de datos, como se describe en Inicio de trabajos de ETL visuales en AWS Glue Studio.
6. Personalice el entorno de ejecución del trabajo mediante la configuración de las propiedades del trabajo, como se describe en Modificar las propiedades del trabajo.
7. Guarde y ejecute el trabajo.

Configuración de las propiedades de origen para los nodos que utilizan conectores

Después de crear un trabajo que utiliza un conector para el origen de datos, el editor visual de trabajos muestra un gráfico de trabajo con un nodo de origen de datos configurado para el conector. Debe configurar las propiedades del origen de datos para ese nodo.

Para configurar las propiedades de un nodo de origen de datos que utiliza un conector

1. Elija el nodo de origen de datos del conector en el gráfico de trabajo o agregue un nodo nuevo y elija el conector para el Node type (Tipo de nodo). A continuación, en el lado derecho, en el panel de detalles del nodo, seleccione la pestaña Data source properties (Propiedades de origen de datos), si aún no está seleccionada.

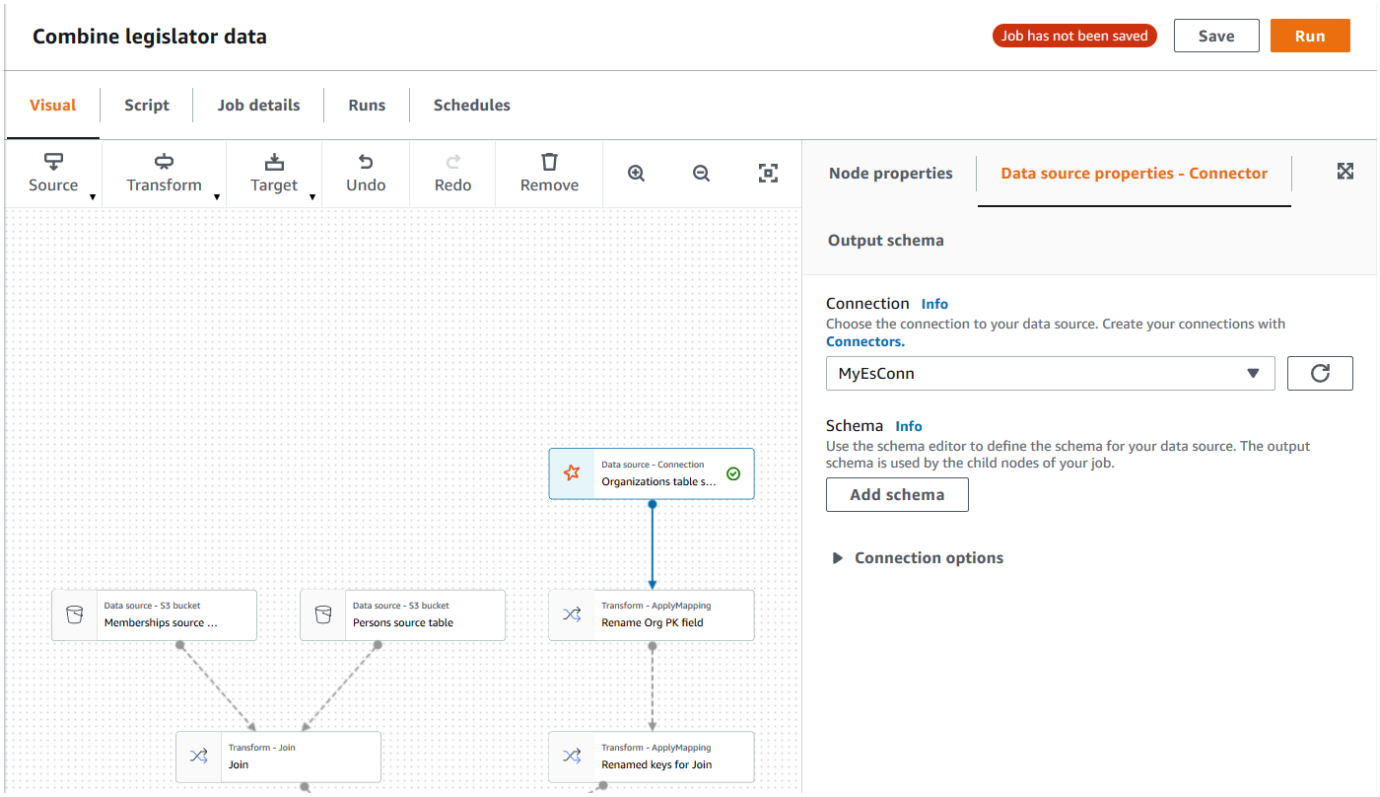

2. En la pestaña Data source properties (Propiedades de origen de datos), elija la conexión que desea utilizar para este trabajo.

   Ingrese la información adicional necesaria para cada tipo de conexión:

JDBC

- Data source input type (Tipo de entrada de origen de datos): elija proporcionar un nombre de tabla o una consulta SQL como origen de datos. En función de su elección, deberá proporcionar la siguiente información adicional:
  - Table name (Nombre de la tabla): el nombre de la tabla en el origen de datos. Si el origen de datos no utiliza el término tabla, proporcione el nombre de una estructura de datos adecuada, como se indica en la información de uso del conector personalizado (que está disponible en AWS Marketplace).
  - Filter predicate (Filtrar predicado): una cláusula de condición que se usa al leer el origen de datos, similar a `WHERE`, utilizada para recuperar un subconjunto de los datos.
  - Query code (Código de consulta): ingrese una consulta SQL que se utilizará para recuperar un conjunto de datos específico del origen de datos. Un ejemplo de una consulta SQL básica es:

    ```
    SELECT column_list FROM
                            table_name WHERE where_clause
    ```

- Schema (Esquema): ya que AWS Glue Studio utiliza la información almacenada en la conexión para tener acceso al origen de datos en lugar de recuperar información de los metadatos de una tabla del Catálogo de datos, debe proporcionar los metadatos del esquema para el origen de datos. Elija Add schema (Agregar esquema) para abrir el editor de esquemas.

  Para obtener instrucciones sobre cómo utilizar el editor de esquemas, consulte Edición de esquema para un nodo de transformación personalizado.

- Partition column (Columna de partición): (opcional) puede optar por particionar las lecturas de datos al proporcionar valores para Partition column (Columna de partición), Lower bound (Límite inferior),Upper bound (Límite superior) y Number of partitions (Número de particiones).

  Los valores `lowerBound` y `upperBound` se utilizan para decidir el intervalo de partición, no para filtrar las filas de la tabla. Todas las filas de la tabla se particionan y se devuelven.

> **Note**
>
> La partición de columnas agrega una condición de partición adicional a la consulta utilizada para leer los datos. Cuando se utiliza una consulta en lugar de un nombre de tabla, debe validar que la consulta funciona con la condición de partición especificada. Por ejemplo:
>
> - Si el formato de consulta es `"SELECT col1 FROM table1"`, pruebe la consulta al agregar una cláusula `WHERE` al final de la consulta que utiliza la columna de partición.
> - Si su formato de consulta es `"SELECT col1 FROM table1 WHERE col2=val"`, pruebe la consulta al ampliar la cláusula `WHERE` con `AND` y una expresión que utiliza la columna de partición.

- Data type casting (Conversión de tipo de datos): si el origen de datos utiliza tipos de datos que no están disponibles en JDBC, utilice esta sección para especificar cómo se debe convertir un tipo de datos del origen de datos en tipos de datos JDBC. Puede especificar hasta 50 conversiones de tipos de datos diferentes. Todas las columnas del origen de datos que utilizan el mismo tipo de datos se convierten de la misma manera.

  Por ejemplo, si tiene tres columnas en el origen de datos que utilizan el tipo de datos `Float` e indica que el tipo de datos `Float` se debe convertir al tipo de datos `String` de JDBC, las tres columnas que utilizan el tipo de datos `Float` se convierten a los tipos de datos `String`.

- Job bookmark keys (Claves de marcadores de trabajo): los marcadores de trabajo ayudan a AWS Glue a mantener la información de estado y evitar el reprocesamiento de los datos antiguos. Especifique una o más columnas como claves favoritas. AWS Glue Studio utiliza claves favoritas para realizar un seguimiento de los datos que ya se han procesado durante una ejecución anterior del trabajo de ETL. Cualquier columna que utilice para claves de marcadores personalizadas debe ser estrictamente monotónica en aumento o disminución, pero se permiten espacios.

  Si ingresa varias claves de marcadores, se combinan para formar una única clave compuesta. Una clave de marcador de trabajo compuesta no debe contener columnas duplicadas. Si no especifica ninguna clave favorita, AWS Glue Studio utiliza la clave principal como clave favorita de forma predeterminada, siempre que aumente o disminuya en forma secuencial (sin brechas). Si la tabla no tiene una clave principal,

pero la propiedad del marcador de trabajo está habilitada, debe proporcionar claves de marcadores de trabajo personalizadas. De lo contrario, la búsqueda de claves principales que se utilizarán como valor predeterminado fallará y la ejecución del trabajo fallará.

- Job bookmark keys sorting order (Orden de clasificación de claves de marcadores de trabajo): elija si los valores clave están en aumento o disminución secuencial.

Spark

- Schema (Esquema): ya que AWS Glue Studio utiliza la información almacenada en la conexión a fin de tener acceso al origen de datos en lugar de recuperar información de los metadatos de una tabla del Catálogo de datos, debe proporcionar los metadatos del esquema para el origen de datos. Elija Add schema (Agregar esquema) para abrir el editor de esquemas.

  Para obtener instrucciones sobre cómo utilizar el editor de esquemas, consulte Edición de esquema para un nodo de transformación personalizado.

- Connection options (Opciones de conexión): ingrese pares clave-valor adicionales según sea necesario para proporcionar información u opciones de conexión adicionales. Por ejemplo, puede ingresar un nombre de base de datos, un nombre de tabla, un nombre de usuario y una contraseña.

  Por ejemplo, para OpenSearch, ingrese los siguientes pares clave-valor, como se describe en the section called “ Tutorial: uso de AWS Glue Connector for Elasticsearch ”:

  - `es.net.http.auth.user` : *`username`*
  - `es.net.http.auth.pass` : *`password`*
  - `es.nodes` : `https://`*`<Elasticsearch endpoint>`*
  - `es.port` : `443`
  - `path`: *`<Elasticsearch resource>`*
  - `es.nodes.wan.only` : `true`

Para obtener un ejemplo de las opciones de conexión mínimas que se van a utilizar, consulte el script de prueba de ejemplo MinimalSparkConnectorTest.scala en GitHub, que muestra las opciones de conexión que normalmente proporcionaría en una conexión.

Athena

- Table name (Nombre de la tabla): el nombre de la tabla en el origen de datos. Si está utilizando un conector para leer los registros de Athena-CloudWatch, debe ingresar `all_log_streams` del nombre de la tabla.
- Athena schema name (Nombre del esquema Athena): elija el esquema de su origen de datos Athena que corresponde a la base de datos que contiene la tabla. Si está utilizando un conector para leer los registros de Athena-CloudWatch, debe ingresar un nombre de esquema similar a `/aws/glue/`*`name`*.
- Schema (Esquema): ya que AWS Glue Studio utiliza la información almacenada en la conexión a fin de tener acceso al origen de datos en lugar de recuperar información de los metadatos de una tabla del Catálogo de datos, debe proporcionar los metadatos del esquema para el origen de datos. Elija Add schema (Agregar esquema) para abrir el editor de esquemas.

  Para obtener instrucciones sobre cómo utilizar el editor de esquemas, consulte Edición de esquema para un nodo de transformación personalizado.
- Additional connection options (Opciones adicionales de conexión): ingrese pares clave-valor adicionales según sea necesario para proporcionar información u opciones de conexión adicionales.

Para ver un ejemplo, consulte el archivo `README.md` en https://github.com/aws-samples/aws-glue-samples/tree/master/GlueCustomConnectors/development/Athena. En los pasos de este documento, el código de muestra muestra las opciones de conexión mínimas necesarias, que son `tableName`, `schemaName` y `className`. En el ejemplo del código se especifican estas opciones como parte de la variable `optionsMap`, pero puede especificarlos para su conexión y luego usar la conexión.

3. (Opcional) después de proporcionar la información necesaria, puede ver el esquema de datos resultante para su origen de datos al seleccionar la pestaña Output schema (Esquema de salida) en el panel de detalles del nodo. Los nodos secundarios que agregue al gráfico de trabajo utilizan el esquema que se muestra en esta pestaña.
4. (Opcional) después de configurar las propiedades del nodo y del origen de datos, puede ver la previsualización del conjunto de datos para su origen de datos al seleccionar la pestaña Data preview (Previsualización de datos) en el panel de detalles del nodo. La primera vez que elija esta pestaña para cualquier nodo de trabajo, se le pedirá que proporcione un rol de IAM para

acceder a los datos. Hay un costo asociado con el uso de este recurso y la facturación comienza tan pronto como proporcione un rol de IAM.

Configuración de las propiedades de destino para los nodos que utilizan conectores

Si utiliza un conector para el tipo de destino de datos, debe configurar las propiedades del nodo de destino de datos.

Para configurar las propiedades de un nodo de destino de datos que utiliza un conector

1. Elija el nodo de destino de datos para el conector en el gráfico de trabajo. A continuación, en el lado derecho, en el panel de detalles del nodo, seleccione la pestaña Data target properties (Propiedades de destino de datos), si aún no está seleccionada.
2. En la pestaña Data target properties (Propiedades de Destino de datos), elija la conexión que se utilizará para escribir en el destino.

   Ingrese la información adicional necesaria para cada tipo de conexión:

   JDBC

   - Connection (Conexión): elija la conexión que desea utilizar con el conector. Para obtener información acerca de cómo crear una conexión, consulte Creación de conexiones para conectores.
   - Table name (Nombre de la tabla): el nombre de la tabla en el destino de datos. Si el destino de datos no utiliza el término tabla, proporcione el nombre de una estructura de datos adecuada, como se indica en la información de uso del conector personalizado (que está disponible en AWS Marketplace).
   - Batch size (Tamaño del lote) (opcional): ingrese el número de filas o registros que desea insertar en la tabla de destino en una sola operación. El valor predeterminado es 1000 filas.

   Spark

   - Connection (Conexión): elija la conexión que desea utilizar con el conector. Si no creó una conexión anteriormente, elija Create connection (Crear conexión) para crear una. Para obtener información acerca de cómo crear una conexión, consulte Creación de conexiones para conectores.

- Connection options (Opciones de conexión): ingrese pares clave-valor adicionales según sea necesario para proporcionar información u opciones de conexión adicionales. Puede ingresar un nombre de base de datos, un nombre de tabla, un nombre de usuario y una contraseña.

  Por ejemplo, para OpenSearch, ingrese los siguientes pares clave-valor, como se describe en the section called " Tutorial: uso de AWS Glue Connector for Elasticsearch ":

  - `es.net.http.auth.user` : *`username`*
  - `es.net.http.auth.pass` : *`password`*
  - `es.nodes` : `https://`*`<Elasticsearch endpoint>`*
  - `es.port` : `443`
  - `path`: *`<Elasticsearch resource>`*
  - `es.nodes.wan.only` : `true`

  Para obtener un ejemplo de las opciones de conexión mínimas que se van a utilizar, consulte el script de prueba de ejemplo MinimalSparkConnectorTest.scala en GitHub, que muestra las opciones de conexión que normalmente proporcionaría en una conexión.

3. Después de proporcionar la información necesaria, puede ver el esquema de datos resultante para su origen de datos al seleccionar la pestaña Output schema (Esquema de salida) en el panel de detalles del nodo.

Administración de conectores y conexiones

Utilice la página Conexiones en AWS Glue para administrar los conectores y las conexiones.

Temas

- Visualización de detalles del conector y la conexión
- Edición de conectores y conexiones
- Eliminación de conectores y conexiones
- Cancelar una suscripción para un conector

Visualización de detalles del conector y la conexión

Puede ver información resumida acerca de los conectores y las conexiones en las tablas de recursos Your connectors (Sus conectores) y Your connections (Sus conexiones) en la página Connectors (Conectores). Para ver la información detallada, siga estos pasos.

Para ver los detalles del conector o la conexión

1. En la consola de AWS Glue Studio, elija Connectors (Conectores) en el panel de navegación de la consola.
2. Elija el conector o la conexión para el/la que desea ver información detallada.
3. Seleccione Actions (Acciones) y luego elija View details (Ver detalles) para abrir la página de detalles de ese conector o conexión.
4. En la página de detalles, puede elegir Editar o Eliminar el conector o la conexión.
   - En el caso de los conectores, puede elegir Create connection (Crear conexión) para crear una conexión nueva que utilice el conector.
   - En el caso de las conexiones, puede elegir Create job (Crear trabajo) para crear un trabajo que utilice la conexión.

Edición de conectores y conexiones

Se utiliza la página Connectors (Conectores) para modificar la información almacenada en sus conectores y conexiones.

Para modificar un conector o una conexión

1. En la consola de AWS Glue Studio, elija Connectors (Conectores) en el panel de navegación de la consola.
2. Elija el conector o conexión que desea modificar.
3. Seleccione Acciones y, a continuación, Editar.

   También puede elegir View details (Ver detalles) y en la página de detalles del conector o la conexión, puede elegir Edit (Editar).
4. En la página Edit connector (Editar conector) o Edit connection (Editar conexión), actualice la información y, a continuación, elija Save (Guardar).

Eliminación de conectores y conexiones

Se utiliza la página Connectors (Conectores) para eliminar conectores y conexiones. Si elimina un conector, también se deben eliminar todas las conexiones que se hayan creado para ese conector.

Para quitar conectores de AWS Glue Studio

1. En la consola de AWS Glue Studio, elija Connectors (Conectores) en el panel de navegación de la consola.
2. Elija el conector o conexión que desea eliminar.
3. Elija Acciones y, a continuación, elija Eliminar.

   También puede elegir View details (Ver detalles) y en la página de detalles del conector o la conexión, puede elegir Delete (Eliminar).
4. Compruebe que desea eliminar el conector o la conexión mediante la introducción de **`Delete`** y luego elija Delete (Eliminar).

   Al eliminar un conector, también se eliminan todas las conexiones creadas para ese conector.

Los trabajos que utilicen una conexión eliminada ya no funcionarán. Puede editar los trabajos para que utilicen un almacén de datos diferente o eliminar los trabajos. Para obtener información sobre cómo eliminar un trabajo, consulte Eliminación de trabajos.

Si elimina un conector, esto no cancela la suscripción del conector en AWS Marketplace. Para cancelar una suscripción de un conector eliminado, siga las instrucciones en Cancelar una suscripción para un conector.

Cancelar una suscripción para un conector

Después de eliminar las conexiones y el conector de AWS Glue Studio, puede cancelar la suscripción en AWS Marketplace si ya no necesita el conector.

> **Note**
>
> Si cancela su suscripción a un conector, esto no elimina el conector o la conexión de su cuenta. Cualquier trabajo que utilice el conector y las conexiones relacionadas ya no podrá usar el conector y fallará.

Antes de cancelar la suscripción o volver a suscribirse a un conector desde AWS Marketplace, debe eliminar las conexiones existentes y los conectores asociados con ese producto AWS Marketplace.

Para cancelar la suscripción a un conector en AWS Marketplace

1. Inicie sesión en la consola de AWS Marketplace en https://console.aws.amazon.com/marketplace.
2. Elija Manage subscriptions (Administrar suscripciones).
3. En la página Manage subscriptions (Administrar suscripciones), elija Manage (Administrar) junto a la suscripción del conector que desea cancelar.
4. Elija Actions (Acciones) y después Cancel Subscription (Cancelar suscripción).
5. Seleccione la casilla de verificación para confirmar que las instancias en ejecución se cargan a su cuenta y, a continuación, elija Yes, cancel subscription (Sí, cancelar suscripción).

Desarrollo de conectores personalizados

Puede escribir el código que lee datos del almacén de datos o escribe datos en él y los formatea para utilizarlos con trabajos de AWS Glue Studio. Puede crear conectores para los almacenes de datos de Spark, Athena y JDBC. El código de muestra publicado en GitHub proporciona información general de las interfaces básicas que debe implementar.

Será necesario un entorno de desarrollo local para crear su código de conector. Puede usar cualquier IDE o incluso solo un editor de línea de comandos para escribir su conector. Algunos ejemplos de entornos de desarrollo incluyen los siguientes:

- Un entorno Scala local con una biblioteca AWS Glue ETL Maven local, como se describe en Desarrollo local con Scala en la Guía para desarrolladores de AWS Glue.
- IDE de IntelliJ, mediante la descarga de IDE desde https://www.jetbrains.com/idea/.

Temas

- Desarrollo de conectores Spark
- Desarrollo de conectores Athena
- Desarrollo de conectores JDBC

- Ejemplos de uso de conectores personalizados con AWS Glue Studio
- Desarrollo de conectores de AWS Glue para AWS Marketplace

Desarrollo de conectores Spark

Puede crear un conector Spark con la API Spark DataSource V2 (Spark 2.4) para leer datos.

Para crear un conector Spark personalizado

Siga los pasos en la biblioteca GitHub de AWS Glue para desarrollar conectores Spark, que se encuentra en https://github.com/aws-samples/aws-glue-samples/tree/master/GlueCustomConnectors/development/Spark/README.md.

Desarrollo de conectores Athena

Puede crear un conector de Athena para que lo utilice AWS Glue y AWS Glue Studio con la finalidad de consultar un origen de datos personalizado.

Para crear un conector Athena personalizado

Siga los pasos en la biblioteca GitHub de AWS Glue para desarrollar conectores Athena, que se encuentra en https://github.com/aws-samples/aws-glue-samples/tree/master/GlueCustomConnectors/development/Athena.

Desarrollo de conectores JDBC

Puede crear un conector que utilice JDBC para acceder a los almacenes de datos.

Para crear un conector JDBC personalizado

1. Instale las bibliotecas de tiempo de ejecución Spark de AWS Glue en su entorno de desarrollo local. Consulte las instrucciones en la biblioteca de ejemplo GitHub de AWS Glue en https://github.com/aws-samples/aws-glue-samples/tree/master/GlueCustomConnectors/development/GlueSparkRuntime/README.md.
2. Implemente el controlador JDBC que es responsable de recuperar los datos del origen de datos. Consulte la documentación de Java para Java SE 8.

   Cree un punto de entrada dentro del código que AWS Glue Studio utiliza para localizar el conector. El campo Class name (Nombre de clase) debe ser la ruta completa de su controlador JDBC.

3. Use la API `GlueContext` para leer datos con el conector. Los usuarios pueden agregar más opciones de entrada en la consola de AWS Glue Studio para configurar la conexión con el origen de datos, si es necesario. Para obtener un ejemplo de código que muestra cómo leer y escribir en una base de datos JDBC con un conector JDBC personalizado, consulte Valores personalizado y tipo de conexión AWS Marketplace.

Ejemplos de uso de conectores personalizados con AWS Glue Studio

Puede consultar los siguientes blogs para ver ejemplos de uso de conectores personalizados:

- Desarrollar, probar e implementar conectores personalizados para los almacenes de datos con AWS Glue
- Apache Hudi: Writing to Apache Hudi tables using AWS Glue Custom Connector (Escribir en tablas Apache Hudi con conectores personalizados de Glue)
- Google BigQuery: Migrar datos de Google BigQuery a Amazon S3 mediante conectores personalizados de AWS Glue
- Snowflake (JDBC): Performing data transformations using Snowflake and AWS Glue (Realizar transformaciones de datos con Snowflake y Glue)
- SingleStore: Building fast ETL using SingleStore and AWS Glue (Construir ETL rápido con SingleStore y Glue)
- Salesforce: Ingest Salesforce data into Amazon S3 using the CData JDBC custom connector with AWS Glue (Capturar datos de Salesforce en Amazon S3 mediante el conector personalizado CData JDBC con AWS Glue)
- MongoDB: Building AWS Glue Spark ETL jobs using Amazon DocumentDB (with MongoDB compatibility) and MongoDB (Crear trabajos de ETL de Glue Spark mediante Amazon DocumentDB [compatible con MongoDB] y MongoDB)
- Amazon Relational Database Service(Amazon RDS): Building AWS Glue Spark ETL jobs by bringing your own JDBC drivers for Amazon RDS (Crear trabajos de ETL de Glue Spark al incorporar sus propios controladores JDBC para Amazon RDS)
- MySQL (JDBC): https://github.com/aws-samples/aws-glue-samples/blob/master/GlueCustomConnectors/development/Spark/SparkConnectorMySQL.scala

Desarrollo de conectores de AWS Glue para AWS Marketplace

Como socio de AWS, puede crear conectores personalizados y cargarlos a AWS Marketplace para vender a clientes de AWS Glue.

El proceso para desarrollar el código del conector es el mismo que para los conectores personalizados, pero el proceso de carga y verificación del código del conector es más detallado. Consulte las instrucciones en Creación de conectores para AWS Marketplace en el sitio web de GitHub.

Restricciones para el uso de conectores y conexiones en AWS Glue Studio

Cuando se utilizan conectores personalizados o conectores de AWS Marketplace, tenga en cuenta las siguientes restricciones:

- La API TestConnection no se admite con conexiones creadas para conectores personalizados.
- El cifrado de las contraseñas de conexión del Catálogo de datos no se admite con conectores personalizados.
- No puede utilizar marcadores de trabajo si especifica un predicado de filtro para un nodo de origen de datos que utiliza un conector JDBC.
- No se admite la creación de una conexión a Marketplace fuera de la interfaz de usuario deAWS Glue Studio.

Prueba de una conexión de AWS Glue

Como práctica recomendada, antes de utilizar una conexión a AWS Glue en un trabajo de ETL, utilice la consola de AWS Glue para probar la conexión. AWS Glue utiliza los parámetros de la conexión para confirmar que puede obtener acceso al almacén de datos e informa de cualquier error. Para obtener más información acerca de las conexiones a AWS Glue, consulte Conexión a datos.

Para probar una conexión a AWS Glue

1. Inicie sesión en Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. En el panel de navegación, en Data Catalog, elija Conexiones. También puede elegir Conexiones de datos sobre el Data Catalog en el panel de navegación.

3. En Conexiones, seleccione la casilla de verificación situada junto a la conexión deseada y, a continuación, elija Acciones. En el menú desplegable, elija Probar conexión.
4. En el cuadro de diálogo Test connection (Probar conexión), seleccione un rol o elija Create IAM role (Crear rol de IAM) para ir a la consola de AWS Identity and Access Management (IAM) para crear un nuevo rol. El rol debe tener permisos en el almacén de datos.
5. Elija Confirmar.

   La prueba comienza y puede tardar varios minutos en completarse. Si la prueba no se realiza correctamente, seleccione Solucionar problemas para ver los pasos necesarios para resolver el problema.
6. Para ver los registros en CloudWatch, elija Registros. Debe tener los permisos de IAM necesarios para ver los registros. Para obtener más información, consulte Políticas (predefinidas) administradas por AWS para registros de CloudWatch en la Guía del usuario de registros de Amazon CloudWatch.

Configuración de las llamadas de AWS para que pasen a través de la VPC

El parámetro de trabajo especial `disable-proxy-v2` permite enrutar las llamadas a servicios tales como Amazon S3, CloudWatch y AWS Glue a través de la VPC. De forma predeterminada, AWS Glue usa un proxy local para enviar tráfico a través de la VPC de AWS Glue a fin de descargar scripts y bibliotecas de Amazon S3, enviar solicitudes a CloudWatch para publicar registros y métricas y enviar solicitudes a AWS Glue para acceder a catálogos de datos. Este proxy permite que el trabajo funcione con normalidad, aunque su VPC no configure una ruta adecuada a otros servicios de AWS, como Amazon S3, CloudWatch y AWS Glue. Ahora, AWS Glue ofrece un parámetro para desactivar este comportamiento. Para obtener más información, consulte Parámetros de trabajo utilizados por AWS Glue. AWS Glue seguirá utilizando el proxy local para publicar registros de CloudWatch de los trabajos de AWS Glue.

> **Note**
>
> - Esta característica es compatible con trabajos de AWS Glue en AWS Glue versión 2.0 y superior. Cuando utilice esta característica, debe asegurarse de que la VPC haya configurado una ruta a Simple Storage Service (Amazon S3) a través de un punto de conexión de VPC de servicio o NAT.

- El parámetro de trabajo obsoleto `disable-proxy` solo enruta sus llamadas a Amazon S3 para descargar scripts y bibliotecas a través de su VPC. En cambio, se recomienda utilizar el nuevo parámetro `disable-proxy-v2`.

Ejemplo de uso

Crear un trabajo de AWS Glue con `disable-proxy-v2`:

```
aws glue create-job \
    --name no-proxy-job \
    --role GlueDefaultRole \
    --command "Name=glueetl,ScriptLocation=s3://my-bucket/glue-script.py" \
    --connections Connections="traffic-monitored-connection" \
    --default-arguments '{"--disable-proxy-v2" : "true"}'
```

Conexión a un almacén de datos de JDBC en una VPC

Normalmente, estos recursos se crean dentro de Amazon Virtual Private Cloud (Amazon VPC) de forma que no se pueda tener acceso a ellos a través de la red pública de Internet. De forma predeterminada, AWS Glue no puede tener acceso a los recursos dentro de una VPC. Para que AWS Glue pueda obtener acceso a los recursos dentro de su VPC, debe proporcionar información de configuración específica de VPC adicional que incluya los ID de subred y los ID de los grupos de seguridad de la VPC. AWS Glue utiliza esta información para configurar interfaces de red elásticas que permiten que la función se conecte de forma segura a otros recursos en la VPC privada.

Cuando utilice un punto de conexión de VPC, agréguelo a su tabla de enrutamiento. Para obtener más información, consulte Creación de un punto de conexión de VPC de interfaz para AWS Glue y Requisitos previos.

Cuando utilice el cifrado en el catálogo de datos, cree el punto de conexión de la interfaz KMS y agréguelo a la tabla de enrutamiento. Para obtener más información, consulte Crear un punto de conexión de VPC para AWS KMS.

Acceso a datos de VPC mediante interfaces de red elásticas

Al conectarse AWS Glue a un almacén de datos de JDBC en una VPC, AWS Glue crea una interfaz de red elástica (con el prefijo `Glue_`) en su cuenta para obtener acceso a sus datos de VPC. No

puede eliminar esta interfaz de red siempre que se asocie a AWS Glue. Como parte de la creación de la interfaz de red elástica, AWS Glue asocia uno o varios grupos de seguridad a ella. Para permitir que AWS Glue cree la interfaz de red, los grupos de seguridad asociados al recurso deben permitir el acceso de entrada con una regla de origen. Esta regla contiene un grupo de seguridad que se asocia al recurso. Esto proporciona a la interfaz de red elástica acceso a su almacén de datos con el mismo grupo de seguridad.

Para que AWS Glue pueda comunicarse con sus componentes, especifique un grupo de seguridad con una regla de entrada con autorreferencia para todos los puertos TCP. Si crea una regla de entrada con autorreferencia, puede restringir el origen al mismo grupo de seguridad de la VPC y no abrirlo a todas las redes. Puede que el grupo de seguridad predeterminado de la VPC ya tenga una regla de entrada con autorreferencia para `ALL Traffic`.

Puede crear reglas en la consola de Amazon VPC. Para actualizar la configuración de la regla a través de la Consola de administración de AWS, vaya a la consola de VPC (https://console.aws.amazon.com/vpc/) y seleccione el grupo de seguridad adecuado. Especifique la regla de entrada para que `ALL TCP` tenga como su origen el mismo nombre de grupo de seguridad. Para obtener más información acerca de las reglas de grupos de seguridad, consulte Grupos de seguridad de su VPC.

A cada interfaz de red elástica se le asigna una dirección IP privada del intervalo de direcciones IP de las subredes especificadas. No se asigna a la interfaz de red ninguna dirección IP pública. AWS Glue requiere acceso de Internet (por ejemplo, para obtener acceso a servicios de AWS que carecen de puntos de enlace de la VPC). Puede configurar una instancia de traducción de las direcciones de red (NAT) dentro de su VPC o puede usar la gateway NAT de Amazon VPC. Para obtener más información, consulte Gateways de NAT en la Guía del usuario de Amazon VPC. No puede usar directamente una gateway de Internet asociada a su VPC como ruta en su tabla de ruteo de la subred porque eso requiere que la interfaz de red tenga direcciones IP públicas.

Los atributos de red de VPC `enableDnsHostnames` y `enableDnsSupport` deben establecerse en true. Para obtener más información, consulte Utilización de DNS con su VPC.

> **Important**
>
> No ponga su almacén de datos en una subred pública o en una subred privada que no tenga acceso a Internet. En su lugar, asóciela únicamente a subredes privadas con acceso a Internet a través de una instancia NAT o una gateway NAT de Amazon VPC.

Propiedades de la interfaz de red elástica

Para crear la interfaz de red elástica, debe proporcionar las siguientes propiedades:

VPC

El nombre de la VPC que contiene su almacén de datos.

Subred

La subred de la VPC que contiene su almacén de datos.

Grupos de seguridad

Los grupos de seguridad que están asociados con el almacén de datos. AWS Glue asocia estos grupos de seguridad con la interfaz de red elástica que se asocia a su subred de VPC. Para permitir que los componentes de AWS Glue se comuniquen y también para evitar el acceso desde otras redes, al menos un grupo de seguridad elegido debe especificar una regla de entrada con autorreferencia para todos los puertos TCP.

Para obtener información acerca de cómo administrar una VPC con Amazon Redshift, consulte Administración de clústeres en una Amazon Virtual Private Cloud (VPC).

Para obtener más información sobre la administración de una VPC con Amazon Relational Database Service (Amazon RDS), consulte Trabajar con una instancia de base de datos de Amazon RDS en una VPC.

Uso de una conexión MongoDB o MongoDB Atlas

Después de crear una conexión para MongoDB o MongoDB Atlas puede utilizarla en un trabajo de ETL. Puede crear una tabla en la AWS Glue Data Catalog y especificar la conexión de MongoDB o MongoDB Atlas para el atributo `connection` de la tabla.

AWS Glue almacena la `url` y las credenciales de la conexión en la conexión de MongoDB. Los formatos de URI de conexión son los siguientes:

- Para MongoDB: mongodb://host:port/database. El host puede ser un nombre de host, una dirección IP o un socket de dominio UNIX. Si la cadena de conexión no especifica ningún puerto, utiliza el puerto predeterminado de MongoDB, 27017.

- Para MongoDB Atlas: mongodb+srv://server.example.com/database. El host puede ser un nombre de host que corresponde a un registro SRV de DNS. El formato SRV no requiere ningún puerto y utilizará el puerto MongoDB predeterminado, 27017.

Además, se pueden especificar opciones en el script del trabajo. Para obtener más información, consulte the section called “Conexión a MongoDB”.

Rastreo de un almacén de datos de Amazon S3 mediante un punto de conexión de VPC

Es posible que quiera configurar su almacén de datos de Amazon S3 o sus tablas del Catálogo de datos respaldadas por Amazon S3 para el acceso únicamente a través de un entorno de Amazon Virtual Private Cloud (Amazon VPC), con fines de seguridad, auditoría o control. En este tema se describe cómo crear y probar una conexión con el almacén de datos de Amazon S3 o las tablas del Catálogo de datos respaldadas por Amazon S3 en un punto de conexión de VPC mediante el tipo de conexión `Network`.

Realice las siguientes tareas para ejecutar un rastreador en el almacén de datos:

- the section called “Requisitos previos”
- the section called “Crear la conexión a Amazon S3”
- the section called “Prueba de la conexión a Amazon S3”
- the section called “Creación de un rastreador para un almacén de datos de Amazon S3”
- the section called “Ejecución de un rastreador”

Requisitos previos

Verifique que ha cumplido estos requisitos previos para configurar el acceso a su almacén de datos de Amazon S3 o a sus tablas del Catálogo de datos respaldadas por Amazon S3 a través de un entorno de Amazon Virtual Private Cloud (Amazon VPC).

- Una VPC configurada. Por ejemplo: vpc-01685961063b0d84b. Para obtener más información, consulte Introducción a Amazon VPC en la Guía del usuario de Amazon VPC.
- Un punto de enlace de Amazon S3 asociado a la VPC. Por ejemplo: vpc-01685961063b0d84b. Para obtener más información, consulte Puntos de enlace para Amazon S3 en la Guía del usuario de Amazon VPC.

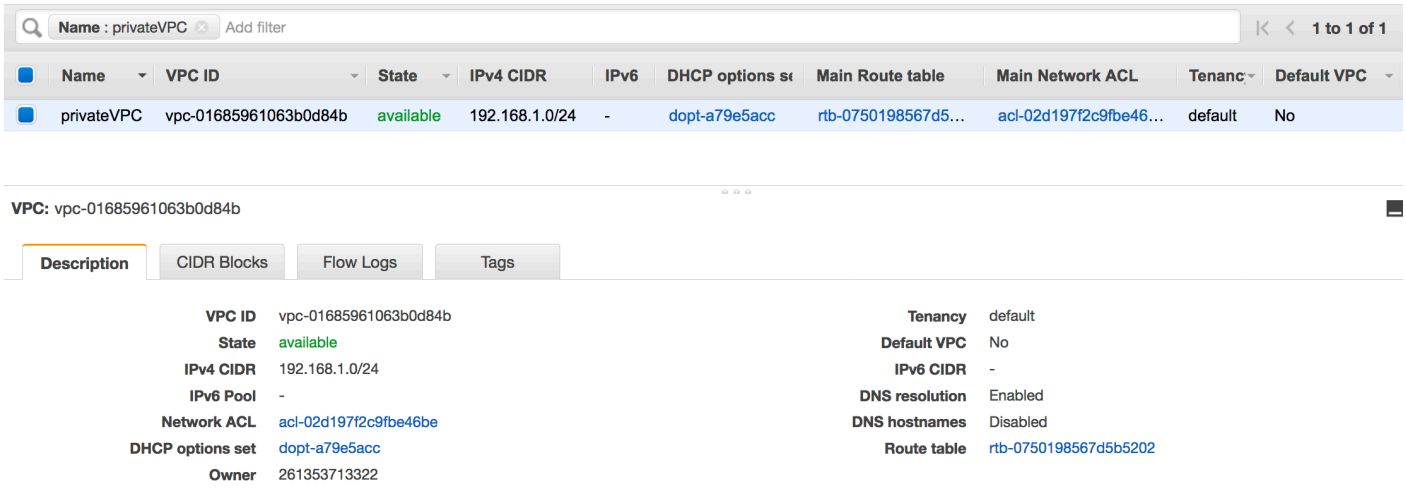

- Una entrada de ruta que apunta al punto de enlace de la VPC. Por ejemplo vpce-0ec5da4d265227786 en la tabla de enrutamiento utilizada por el punto de enlace de la VPC (vpce-0ec5da4d265227786).

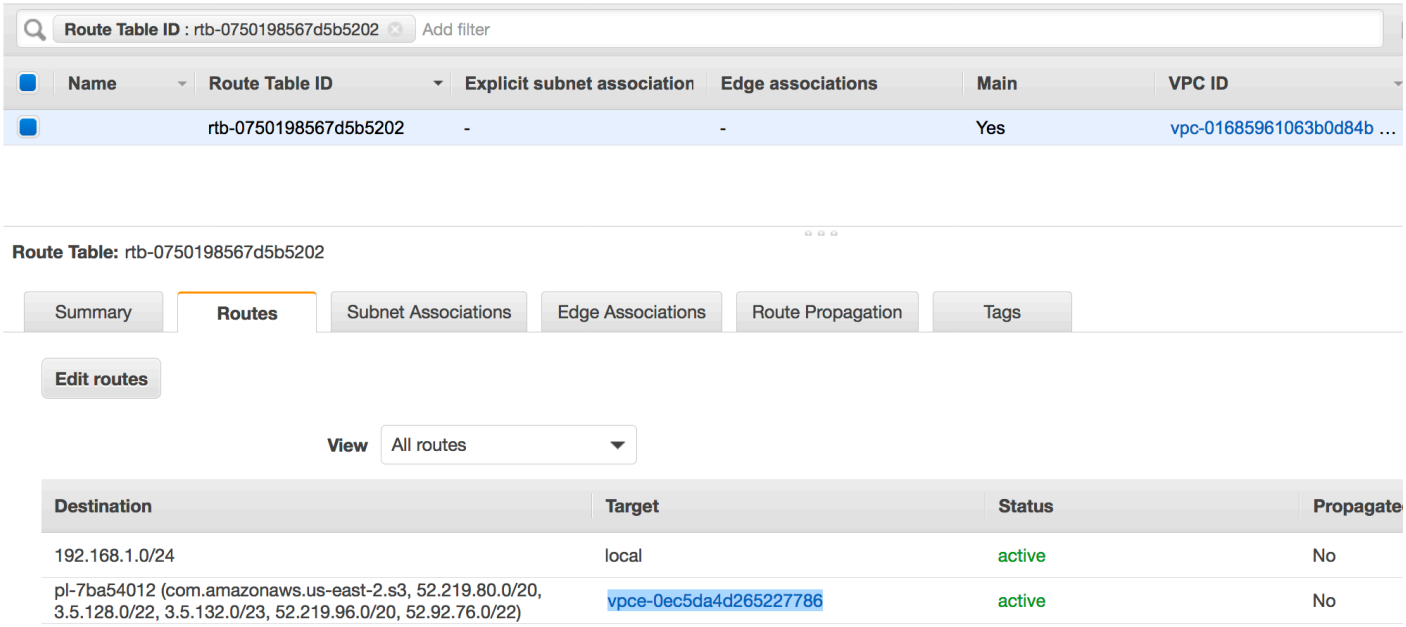

- Una ACL de red asociada a la VPC permite el tráfico.
- Un grupo de seguridad asociado a la VPC permite el tráfico.

Crear la conexión a Amazon S3

Normalmente, estos recursos se crean dentro de Amazon Virtual Private Cloud (Amazon VPC) de forma que no se pueda tener acceso a ellos a través de la red pública de Internet. De forma predeterminada, AWS Glue no puede tener acceso a los recursos dentro de una VPC. Para que

AWS Glue pueda obtener acceso a los recursos dentro de su VPC, debe proporcionar información de configuración específica de VPC adicional que incluya los ID de subred y los ID de los grupos de seguridad de la VPC. Para crear una conexión de `Network` deberá especificar la siguiente información:

- ID DE LA VPC
- Una subred dentro de la VPC
- Un grupo de seguridad

Para configurar una conexión `Network`:

1. Elija Add connection (Agregar conexión) en el panel de navegación de la consola de AWS Glue.
2. Ingrese el nombre de la conexión, elija Network (Red) como el tipo de conexión. Elija Next (Siguiente).

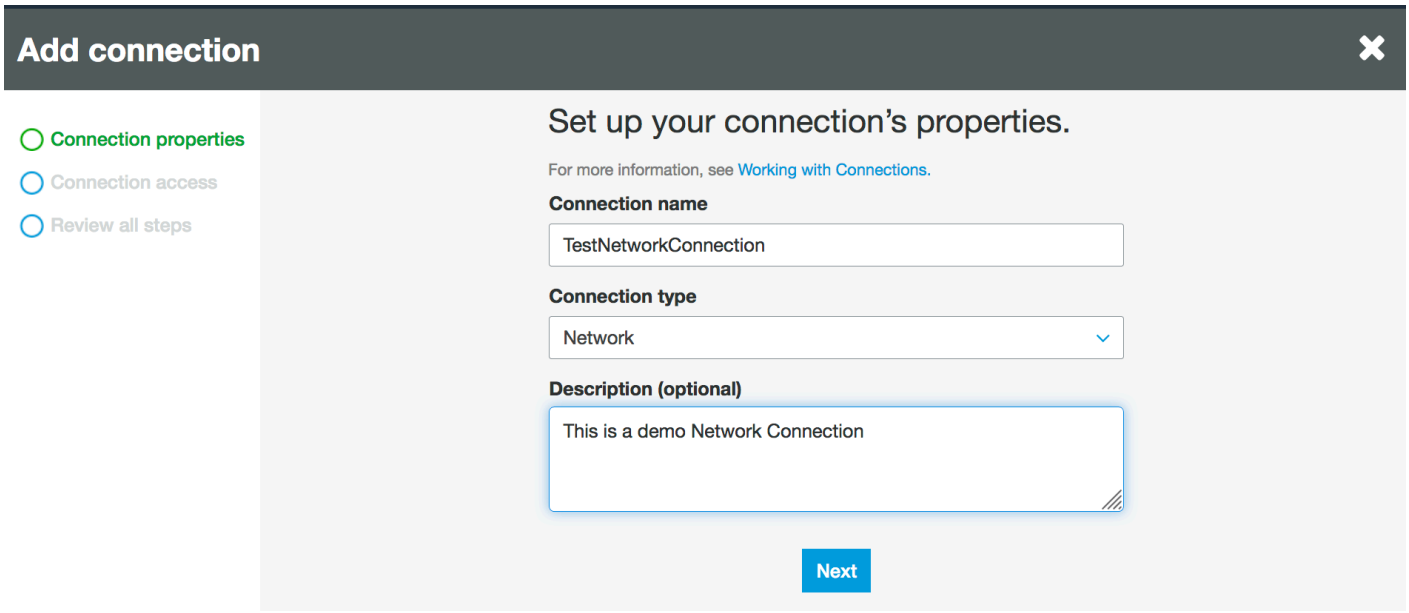

3. Configure la información de la VPC, subred y grupos de seguridad.
   - VPC: elija el nombre de la VPC que contiene su almacén de datos.
   - Subred: elija una subred en su VPC.
   - Grupos de seguridad: elija uno o más grupos de seguridad que permitan el acceso al almacén de datos de la VPC.

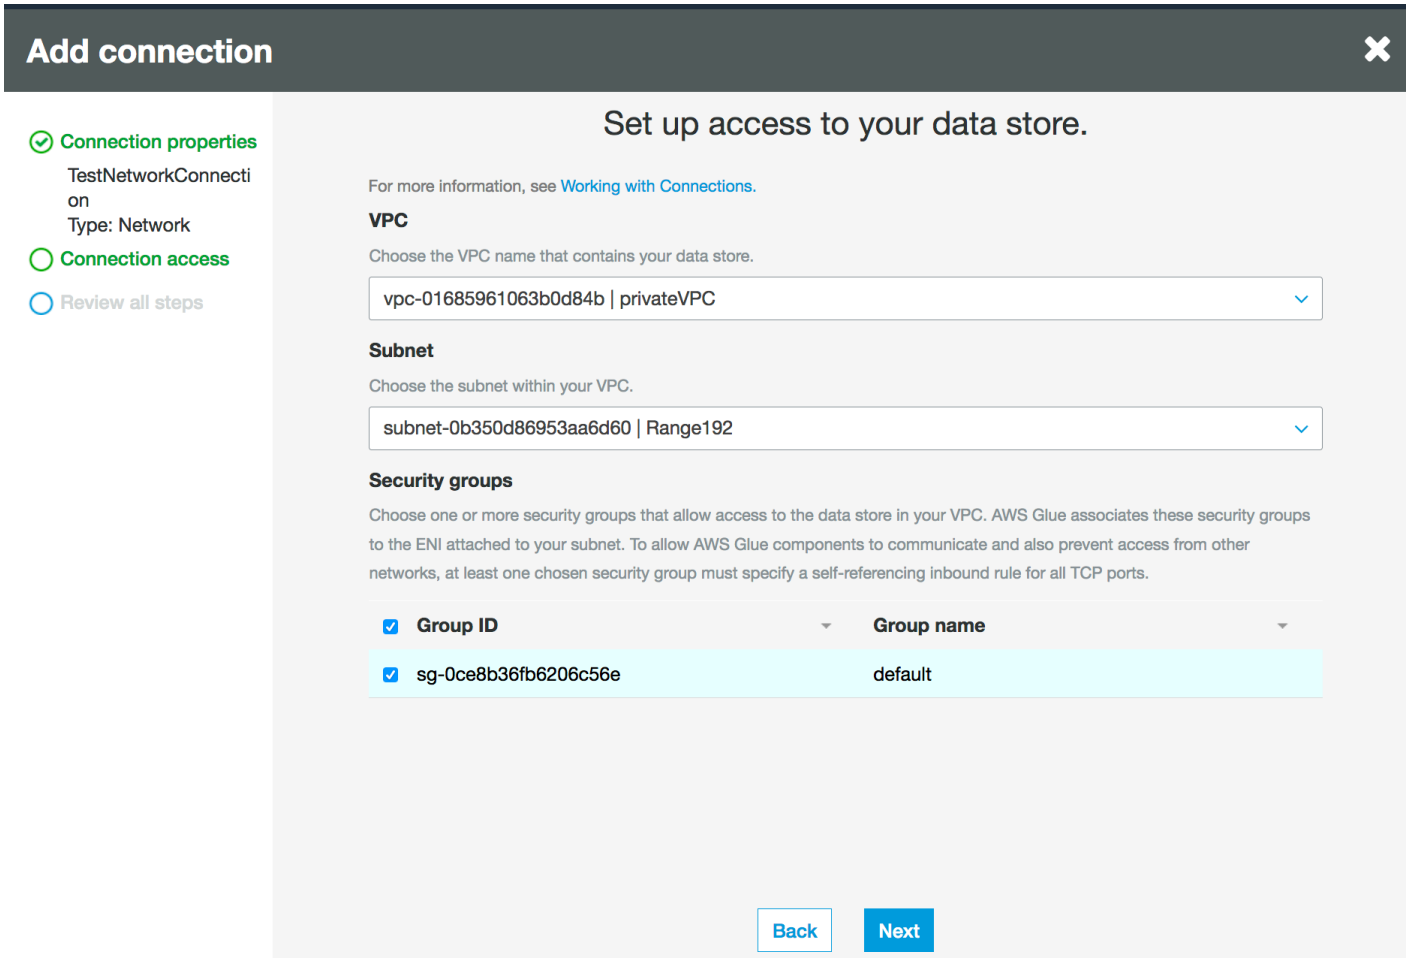

4. Elija Next (Siguiente).
5. Verifique la información de conexión y elija Finish (Finalizar).

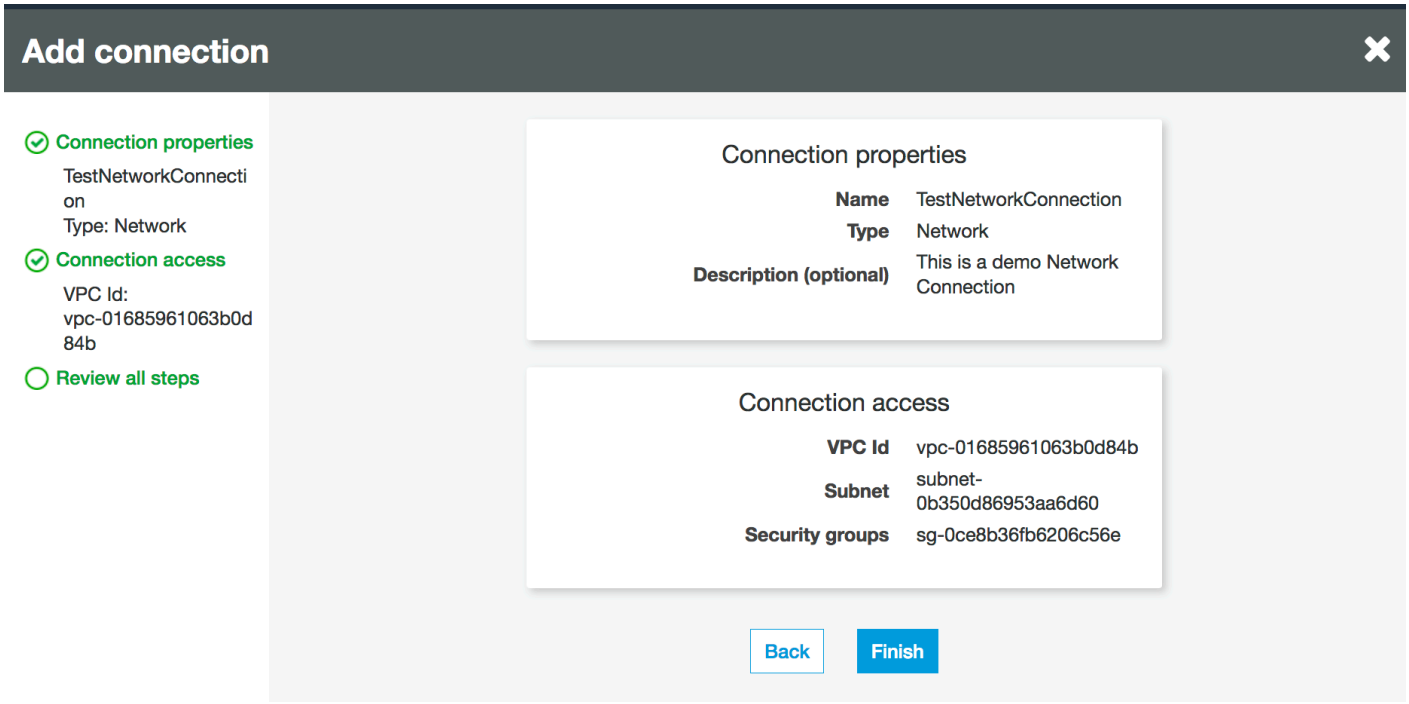

Prueba de la conexión a Amazon S3

Una vez que haya creado su conexión `Network`, puede probar la conectividad con su almacén de datos de Amazon S3 en un punto de enlace de la VPC.

Pueden producirse los siguientes errores al probar una conexión:

- INTERNET CONNECTION ERROR (ERROR DE CONEXIÓN A INTERNET): indica un problema de conexión a Internet
- INVALID BUCKET ERROR (ERROR DE BUCKET NO VÁLIDO): indica un problema con el bucket de Amazon S3
- S3 CONNECTION ERROR (ERROR DE CONEXIÓN DE S3): indica un error al conectarse a Amazon S3
- INVALID CONNECTION TYPE (TIPO DE CONEXIÓN NO VÁLIDA): indica que el tipo de conexión no tiene el valor esperado, `NETWORK`
- INVALID CONNECTION TEST TYPE (TIPO DE PRUEBA DE CONEXIÓN NO VÁLIDA): indica un problema con el tipo de prueba de conexión de red
- INVALID TARGET (DESTINO NO VÁLIDO): indica que el bucket de Amazon S3 no se ha especificado correctamente

Para probar una conexión `Network`:

1. Seleccione la conexión Network (Red) en la consola de AWS Glue.
2. Elija Test Connection (Probar conexión).
3. Elija el rol de IAM que creó en el paso anterior y especifique un bucket de Amazon S3.
4. Elija Test connection (Probar conexión) para comenzar la prueba. Puede tardar unos minutos en mostrar el resultado.

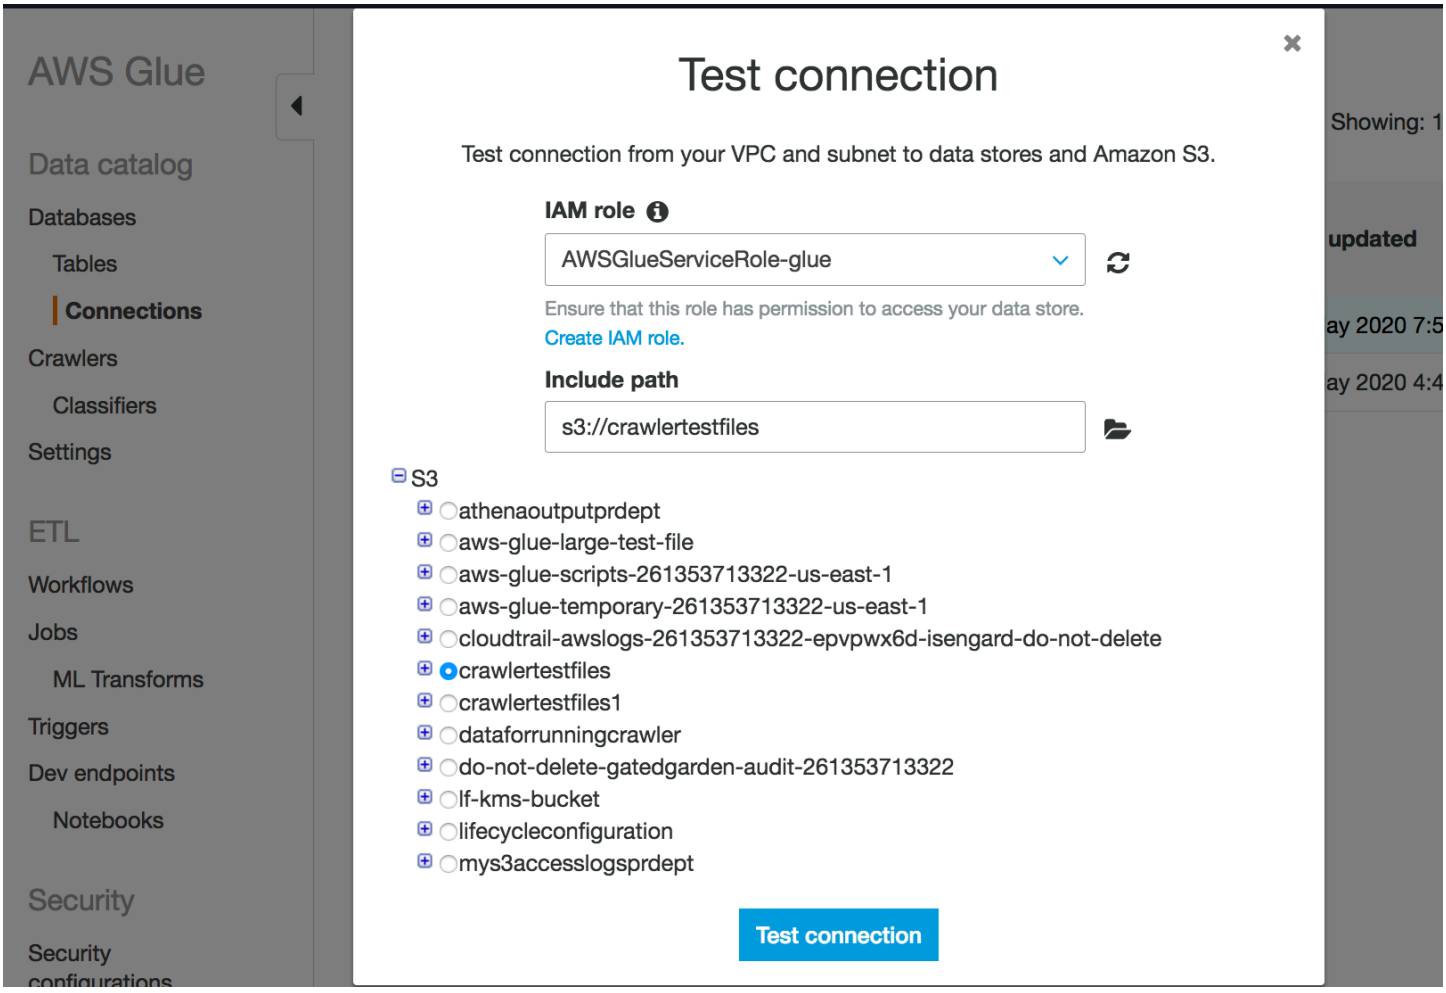

Si recibe un error, verifique lo siguiente:

- Se proporcionan los privilegios correctos para el rol seleccionado.
- Se proporciona el bucket correcto de Amazon S3.
- Los grupos de seguridad y la ACL de red permiten el tráfico entrante y saliente requerido.
- La VPC especificada está conectada a un punto de conexión de VPC de Amazon S3.

Una vez haya probado la conexión con éxito, puede crear un rastreador.

Creación de un rastreador para un almacén de datos de Amazon S3

Ahora, puede crear un rastreador que especifique la conexión `Network` que ha creado. Para obtener más información sobre cómo crear un rastreador, consulte Configuración de rastreadores.

1. En primer lugar, elija Crawlers (Rastreadores) en el panel de navegación de la consola de AWS Glue.
2. Elija Add crawler (Agregar rastreador).
3. Especifique el nombre del rastreador y elija Next (Siguiente).
4. Cuando se le solicite el origen de los datos, elija S3 y especifique el prefijo del bucket de Amazon S3 y la conexión que creó con anterioridad.

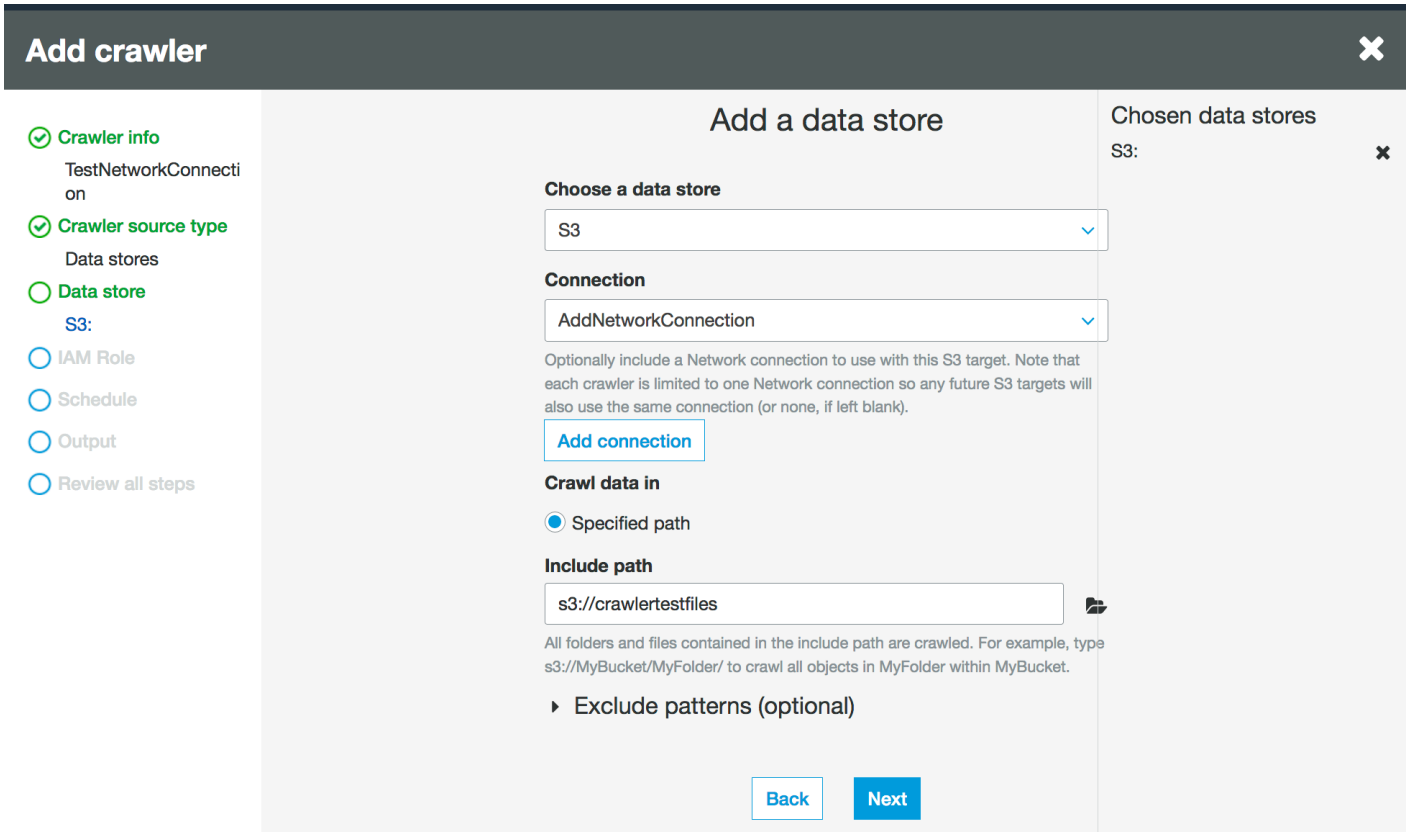

5. Si es necesario, agregue otro almacén de datos en la misma conexión de red.
6. Elija el rol de IAM. El rol de IAM debe permitir el acceso al servicio de AWS Glue y al bucket de Amazon S3. Para obtener más información, consulte the section called “Configuración de rastreadores”.

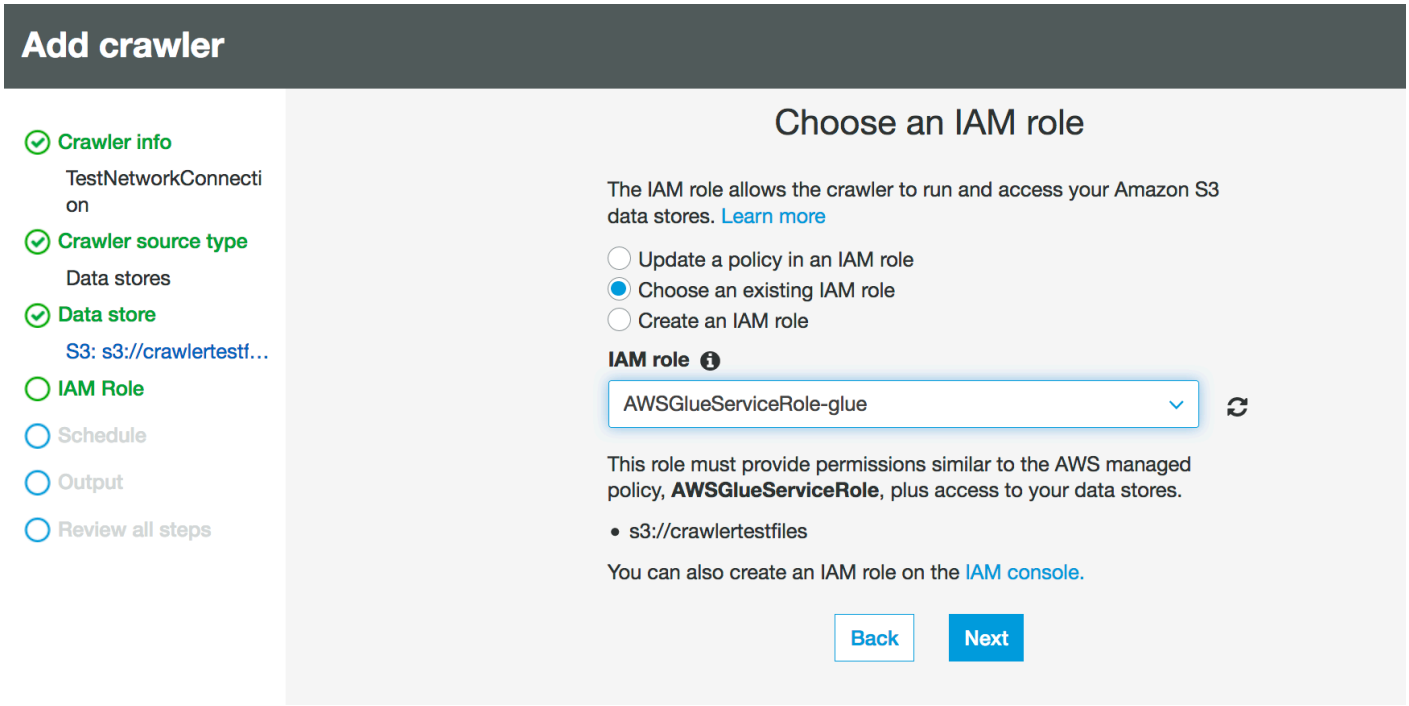

7. Definir la programación para el rastreador.
8. Elija una base de datos existente en el Catálogo de datos o cree una nueva entrada de base de datos.

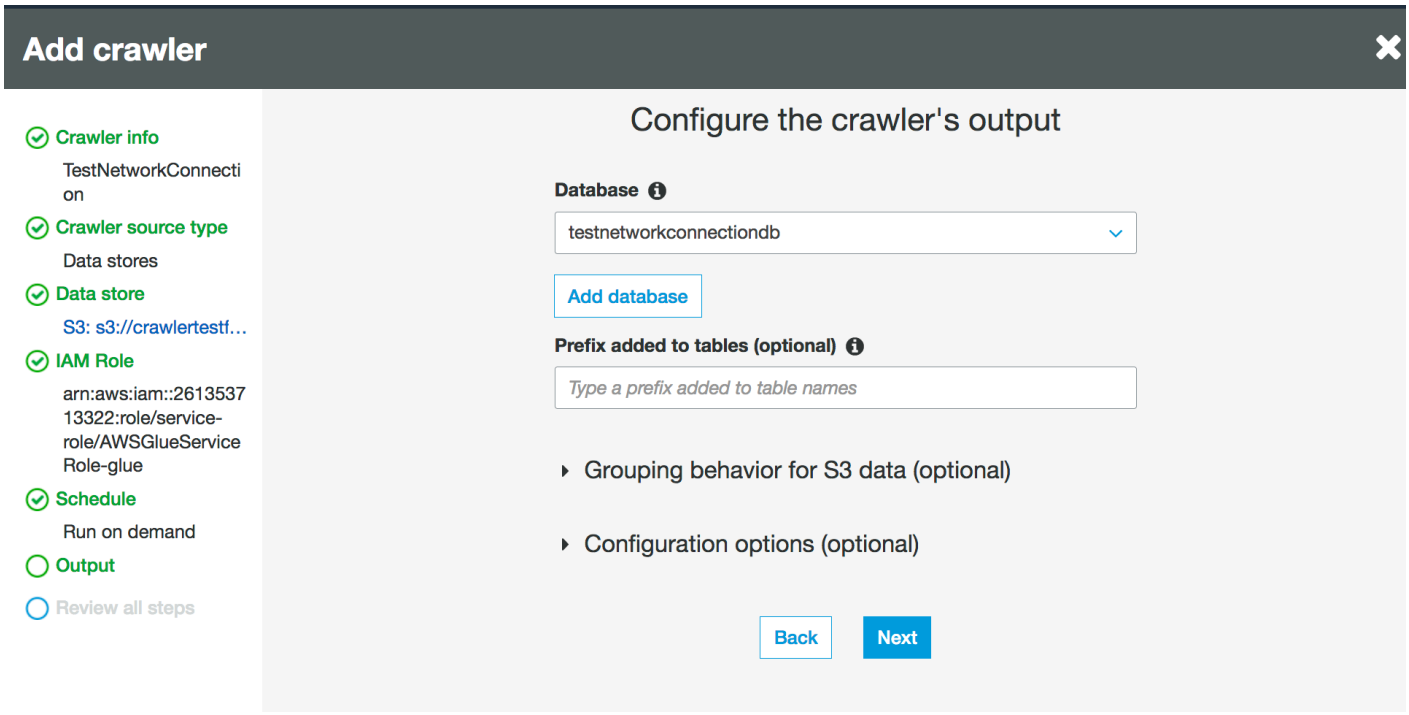

9. Finalice la configuración restante.

Creación de un rastreador para tablas del Catálogo de datos respaldadas por Amazon S3

Ahora, puede crear un rastreador que especifique la conexión `Network` que ha creado y un tipo de origen Catalog (Catálogo). Para obtener más información sobre cómo crear un rastreador, consulte Configuración de rastreadores.

1. En primer lugar, elija Crawlers (Rastreadores) en el panel de navegación de la consola de AWS Glue.
2. Elija Add crawler (Agregar rastreador).
3. Especifique el nombre del rastreador y elija Next (Siguiente).
4. Cuando se le solicite el tipo de origen del rastreador, elija Existing catalog tables (Tablas de catálogo existentes) y especifique las tablas de catálogo existentes que se van a rastrear en la lista de tablas disponibles.

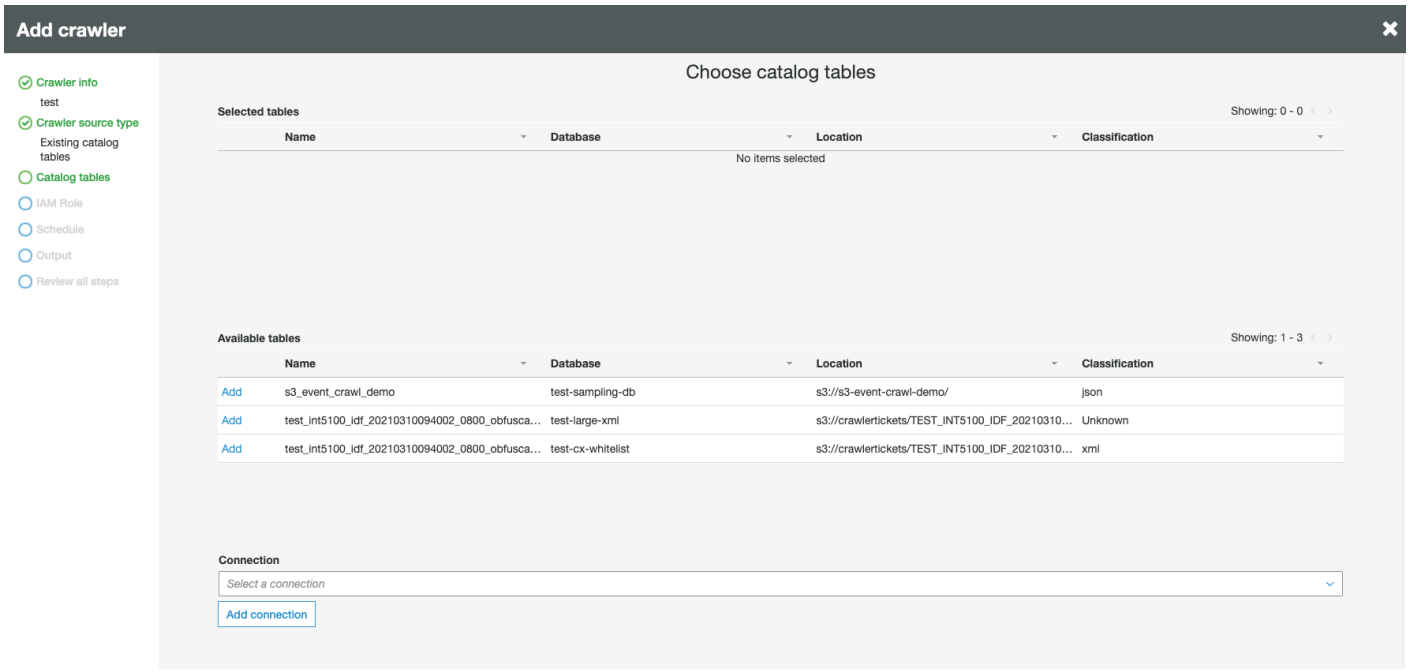

5. Elija el rol de IAM. El rol de IAM debe permitir el acceso al servicio de AWS Glue y al bucket de Amazon S3. Para obtener más información, consulte the section called “Configuración de rastreadores”.
6. Definir la programación para el rastreador.
7. Elija una base de datos existente en el Catálogo de datos o cree una nueva entrada de base de datos.
8. Finalice la configuración restante y revise los pasos.

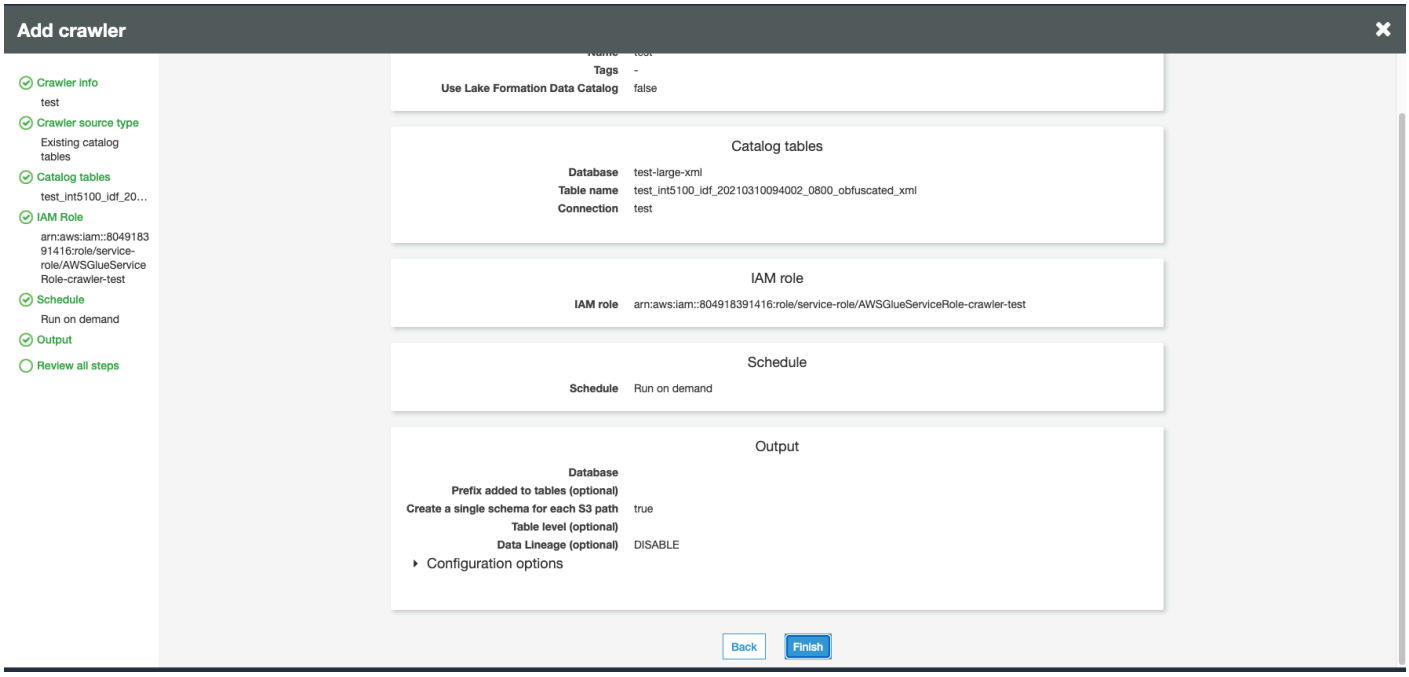

Ejecución de un rastreador

Ejecute su rastreador.

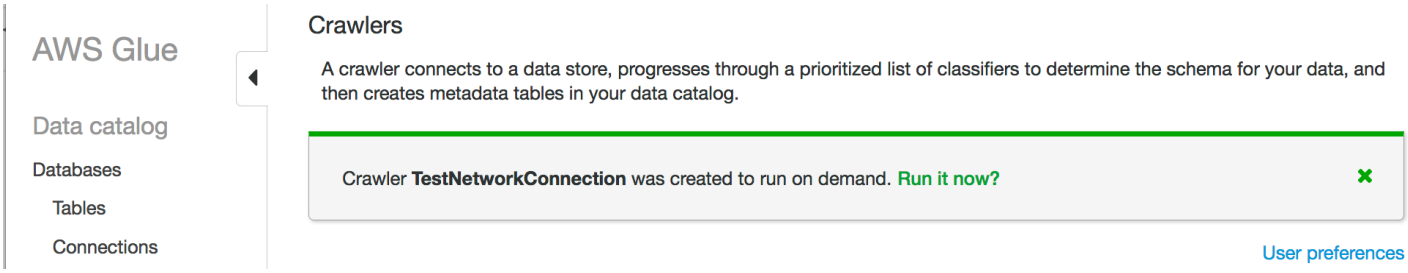

Solución de problemas

Para solucionar problemas relacionados con los buckets de Amazon S3 que utilizan una puerta de enlace de la VPC, consulte ¿Por qué no puedo conectarme a un bucket de S3 con un punto de enlace de la VPC de la gateway?

Uso de datos protegidos por AWS Lake Formation

Acceso completo a la tabla

AWS Glue admite el acceso completo a tablas (FTA) para tablas protegidas por AWS Lake Formation. Esto permite que los trabajos de ETL lean y escriban datos con permisos completos sobre las tablas.

Requisitos previos

- Roles y permisos adecuados de IAM
- AWS Lake Formation configurado para el catálogo de datos
- Tipos de tablas compatibles (Hive o Iceberg)

Consideraciones clave

Permisos necesarios

- Permiso de IAM `lakeformation:GetDataAccess`
- Tabla de permisos de AWS Lake Formation
- Permisos de acceso a los buckets de Amazon S3

Tipos de tablas admitidas

- Tablas de Hive
- Tablas de Iceberg

Limitaciones

- No es compatible con Spark Streaming
- No se puede usar simultáneamente con el control de acceso detallado
- No admite tablas Delta ni Hudi

Prácticas recomendadas

1. Verifique que los roles de IAM estén correctamente configurados antes de ejecutar el trabajo

2. Pruebe los permisos de acceso en un entorno de desarrollo
3. Supervise los registros de ejecución de trabajos para detectar problemas relacionados con permisos
4. Mantenga una documentación clara de los patrones de acceso

Solución de problemas

Entre los problemas más frecuentes se incluyen:

- Faltan permisos de IAM:
- Configuración de AWS Lake Formation incorrecta
- Problemas de compatibilidad con el tipo de tabla

Para obtener instrucciones completas de configuración y detalles, consulte Uso de AWS Lake Formation con acceso completo a tablas.

Solución de problemas de conexión en AWS Glue

Cuando un rastreador o un trabajo de AWS Glue utiliza las propiedades de conexión para obtener acceso a un almacén de datos, es posible que encuentre errores al intentar conectarse. AWS Glue utiliza direcciones IP privadas en la subred al crear interfaces de red elásticas especificadas en su nube virtual privada (VPC) y subred. Los grupos de seguridad especificados en la conexión se aplican en cada una de las interfaces de red elásticas. Compruebe que los grupos de seguridad permiten el acceso saliente y si permiten la conectividad al clúster de base de datos.

Además, Apache Spark requiere conectividad bidireccional entre los nodos del controlador y el ejecutor. Uno de los grupos de seguridad debe permitir las reglas de entrada en todos los puertos TCP. Puede impedir que se abra al mundo restringiendo el origen del grupo de seguridad en sí mismo con un grupo de seguridad de autorreferencia.

A continuación le presentamos algunas acciones que puede emprender para solucionar problemas de conexión:

- Compruebe la dirección de puerto de su conexión.
- Compruebe el nombre de usuario y la cadena de contraseña de su conexión o secreto.
- Para un almacén de datos de JDBC, compruebe que permite conexiones entrantes.

- Compruebe que se puede obtener acceso a su almacén de datos dentro de su VPC.
- Si almacena las credenciales de la conexión mediante AWS Secrets Manager, asegúrese de que su rol de IAM para AWS Glue tenga permiso para acceder a su secreto. Para obtener más información, consulte Ejemplo: Permiso para recuperar valores de secretos en la Guía del usuario de AWS Secrets Manager. En función de la configuración de la red, es posible que también tenga que crear un punto de conexión de VPC para establecer una conexión privada entre la VPC y Secrets Manager. Para obtener más información, consulte Uso de un punto de conexión de VPC de AWS Secrets Manager.

Tutorial: uso de AWS Glue Connector for Elasticsearch

Elasticsearch es un motor de búsqueda y análisis popular y de código abierto para casos de uso como análisis de registros, monitoreo de aplicaciones en tiempo real y análisis de secuencias de clics. Puede usar OpenSearch como almacén de datos para sus trabajos de extracción, transformación y carga (ETL) si configura AWS Glue Connector for Elasticsearch en AWS Glue Studio. Este conector está disponible de forma gratuita en AWS Marketplace.

> **Note**
>
> AWS Marketplace Elasticsearch Spark Connector ha quedado obsoleto. En su lugar, use AWS Glue Connector for Elasticsearch.

En este tutorial, mostraremos cómo conectarse a sus nodos de Amazon OpenSearch Service con un número mínimo de pasos.

Temas

- Requisitos previos
- Paso 1: (opcional) cree un secreto de AWS para la información del clúster de OpenSearch
- Paso 2: suscríbase al conector
- Paso 3: activar el conector en AWS Glue Studio y crear una conexión
- Paso 4: configurar un rol de IAM para el trabajo de ETL
- Paso 5: crear un trabajo que utilice la conexión OpenSearch
- Paso 6: ejecutar el trabajo

Requisitos previos

Para utilizar este tutorial, debe disponer de lo siguiente:

- Acceso a AWS Glue Studio
- Acceso a un clúster de OpenSearch en AWS Cloud
- (Opcional) acceso a AWS Secrets Manager.

Paso 1: (opcional) cree un secreto de AWS para la información del clúster de OpenSearch

Para almacenar y utilizar de forma segura su credencial de conexión, guarde su credencial en AWS Secrets Manager. La conexión utilizará más tarde en el tutorial el secreto que haya creado. Los pares clave-valor de credenciales se introducirán en AWS Glue Connector for Elasticsearch como opciones de conexión normales.

Para obtener más información acerca de los permisos mínimos, consulte Creación y administración de secretos con AWS Secrets Manager en la Guía del usuario de AWS Secrets Manager.

Para crear un secreto de AWS

1. Inicie sesión en la consola de AWS Secrets Manager.
2. En la página de introducción del servicio o en la página con la lista Secretos, elija Store a new secret (Almacenar un nuevo secreto).
3. En la página Store a new secret (Almacenar un nuevo secreto), elija Other type of secret (Otro tipo de secreto). Esta opción indica que debe proporcionar la estructura y los detalles de su secreto.
4. Agregue una Clave y un Valor para el nombre de usuario del clúster de OpenSearch. Por ejemplo:

   `es.net.http.auth.user`: *`usuario`*
5. Seleccione + Add row (+ Agregar fila) e ingrese otro par clave-valor para la contraseña. Por ejemplo:

   `es.net.http.auth.pass`: *`contraseña`*
6. Elija Siguiente.

7. Escriba un nombre secreto. Por ejemplo: my-es-secret. Si lo desea, también puede escribir una descripción.

   Registre el nombre secreto, que se utilizará más adelante en este tutorial y, a continuación, elija Next (Siguiente).
8. Elija Next (Siguiente) una vez más, y luego elija Store (Almacenar) para crear el secreto.

Siguiente paso

Paso 2: suscríbase al conector

Paso 2: suscríbase al conector

AWS Glue Connector for Elasticsearch está disponible de manera gratuita en AWS Marketplace.

Para suscribirse a AWS Glue Connector for Elasticsearch en AWS Marketplace

1. Si aún no ha configurado su cuenta de AWS para utilizar License Manager, realice lo siguiente:
   a. Abra la consola de AWS License Manager en https://console.aws.amazon.com/license-manager.
   b. Elija Create customer managed license (Crear licencia administrada por el cliente).
   c. En la ventana IAM permissions (one-time setup) [Permisos de IAM (configuración única)], elija I grant AWS License Manager the required permissions (Concedo a Amazon License Manager los permisos necesarios), y, a continuación, elija Grant premissions (Conceder permisos).

      Si no ve esta ventana, ya ha configurado los permisos necesarios.
2. Abra la consola de AWS Glue Studio en https://console.aws.amazon.com/gluestudio/.
3. En la consola de AWS Glue Studio, expanda el ícono del menú
   ( )
   y luego elija Connectors (Conectores) en el panel de navegación.
4. En la página Connectors (Conectores), elija Go to AWS Marketplace (Ir a MKT).
5. En AWS Marketplace, en la sección Buscar productos de AWS Glue Studio, ingrese AWS Glue Connector for Elasticsearch en el campo de búsqueda y, luego, presione Intro.
6. Elija el nombre del conector, AWS Glue Connector for Elasticsearch.

7. En la página de producto del conector, utilice las pestañas para ver información sobre el conector. Cuando esté listo para continuar, elija Continue to Subscribe (Continuar con la suscripción).
8. Revise los términos de uso del software. Haga clic en Accept Terms (Aceptar términos).
9. Cuando finalice el proceso de suscripción, verá una notificación: “Thank you for subscribing to this product! You can now configure your software.” (Gracias por suscribirse a este producto. Ahora puede configurar su software). Arriba del banner encontrará el botón Continue to Configuration (Continuar con la configuración). Elija Continuar con la configuración.
10. Elija la opción Fulfillment (Ejecución) en la página Configure this software (Configurar este software). Puede elegir entre AWS Glue 1.0/2.0 o AWS Glue 3.0. A continuación, elija Continue to Launch (Continuar con el lanzamiento).

Siguiente paso

Paso 3: activar el conector en AWS Glue Studio y crear una conexión

Paso 3: activar el conector en AWS Glue Studio y crear una conexión

Después de elegir, Continue to Launch (Continuar con el lanzamiento), verá la página Launch this software (Lanzar este software) en AWS Marketplace. Se crea una conexión al utilizar el vínculo para habilitar el conector en AWS Glue Studio.

Para implementar el conector y crear una conexión en AWS Glue Studio

1. En la página Launch this software (Lanzar este software) en la consola de AWS Marketplace, elija Usage Instructions (Instrucciones de uso), y luego elija el enlace en la ventana que aparece.

   Su navegador se redirige a la página Create marketplace connection (Crear conexión de marketplace) en la consola de AWS Glue Studio.
2. Escriba un nombre para la conexión. Por ejemplo: my-es-connection.
3. En la sección Connection access (Acceso a la conexión), para Connection credential type (Tipo de credenciales de conexión), elija User name and password (Nombre de usuario y contraseña).
4. En AWS secret (Secreto de AWS), especifique el nombre de su secreto. Por ejemplo: my-es-secret.
5. En la sección Network options (Opciones de red), ingrese la información de VPC para conectarse al clúster de OpenSearch.

6. Seleccione Create connection and activate connector (Crear conexión y habilitar conector).

Siguiente paso

Paso 4: configurar un rol de IAM para el trabajo de ETL

Paso 4: configurar un rol de IAM para el trabajo de ETL

Al crear el trabajo de ETL de AWS Glue, se especifica un rol de AWS Identity and Access Management (IAM) que el trabajo utilizará. El rol debe conceder acceso a todos los recursos utilizados por el trabajo, incluido Amazon S3 (para cualquier origen, destino, script, archivos de controladores y directorios temporales) y también objetos de AWS Glue Data Catalog.

El rol de IAM asumido para el trabajo de ETL de AWS Glue también debe tener acceso al secreto que se creó en la sección anterior. De forma predeterminada, el rol administrado de AWS, `AWSGlueServiceRole`, no tiene acceso al secreto. Para configurar el control de acceso para sus secretos, consulte Autenticación y control de acceso de AWS Secrets Manager y Limitación de acceso a secretos específicos.

Para configurar un rol de IAM para su trabajo de ETL

1. Configure los permisos descritos en the section called “Revisar los permisos de IAM necesarios para trabajos de ETL.”.
2. Configure los permisos adicionales necesarios al utilizar conectores con AWS Glue Studio, como se describe en the section called “Permisos necesarios para utilizar conectores”.

Siguiente paso

Paso 5: crear un trabajo que utilice la conexión OpenSearch

Paso 5: crear un trabajo que utilice la conexión OpenSearch

Después de crear un rol para su trabajo de ETL, puede crear un trabajo en AWS Glue Studio que utilice la conexión y el conector para Open Spark ElasticSearch.

Si su trabajo se ejecuta dentro de una Amazon Virtual Private Cloud (Amazon VPC), asegúrese de que la VPC esté configurada correctamente. Para obtener más información, consulte the section called “Configurar una VPC para su trabajo de ETL”.

Para crear un trabajo que utilice Elasticsearch Spark Connector

1. En AWS Glue Studio, elija Connectors (Conectores).
2. En la lista Your connections (Sus conexiones) seleccione la conexión que acaba de crear y elija Create job (Crear el trabajo).
3. En el editor visual de trabajos, elija el nodo Data source (Origen de datos). A la derecha, en la pestaña Data source properties - Connector (Propiedades del origen de datos: conector), configure información adicional para el conector.

   a. Seleccione Add schema (Agregar esquema) e ingrese el esquema del conjunto de datos en el origen de datos. Las conexiones no utilizan tablas almacenadas en Data Catalog, lo que significa que AWS Glue Studio no conoce el esquema de los datos. Debe proporcionar esta información del esquema en forma manual. Para obtener instrucciones sobre cómo utilizar el editor de esquemas, consulte the section called “Edición de esquema para un nodo de transformación personalizado”.

   b. Expanda Connection options (Opciones de conexión).

   c. Seleccione Add new option (Agregar nueva opción) e ingrese la información necesaria para el conector que no se ingresó en el secreto de AWS:

      - es.nodes: https://<OpenSearch domain endpoint>
      - es.port: 443
      - path: test
      - es.nodes.wan.only: true

      Para obtener una explicación de estas opciones de conexión, consulte: https://www.elastic.co/guide/en/elasticsearch/hadoop/current/configuration.html.

4. Agregue un nodo de destino al gráfico.

   Su destino de datos puede ser Amazon S3 o puede usar información de AWS Glue Data Catalog o un conector para escribir datos en una ubicación diferente. Por ejemplo, puede utilizar una tabla del Data Catalog para escribir en una base de datos en Amazon RDS, o puede utilizar un conector como destino de datos para escribir en almacenes de datos que no son soportados de forma nativa en AWS Glue.

   Si elige un conector para el destino de datos, debe elegir una conexión creada para ese conector. Además, si el proveedor del conector lo requiere, debe agregar opciones para

proporcionar información adicional al conector. Si utiliza una conexión que contiene información para un secreto de AWS, entonces no necesita proporcionar el nombre de usuario y la autenticación de contraseña en las opciones de conexión.

5. Si lo desea, agregue orígenes de datos adicionales y uno o más nodos de transformación como se describe en the section called “Transformación de datos con transformaciones administradas de AWS Glue”.
6. Configure las propiedades del trabajo como se describe en the section called “Modificar las propiedades del trabajo”, comenzando con el paso 3, y guarde el trabajo.

Siguiente paso

Paso 6: ejecutar el trabajo

Paso 6: ejecutar el trabajo

Después de guardar el trabajo, puede ejecutar el trabajo para realizar las operaciones de ETL.

Para ejecutar el trabajo creado para AWS Glue Connector for Elasticsearch

1. Con la consola de AWS Glue Studio, en la página del editor visual, elija Run (Ejecutar).
2. En el banner de éxito, elija Run details (Detalles de la ejecución), o puede elegir la pestaña Runs (Ejecuciones) del editor visual para ver información sobre la ejecución del trabajo.

Creación de trabajos de AWS Glue con sesiones interactivas

Los ingenieros de datos pueden crear trabajos de AWS Glue de forma más rápida y sencilla que antes mediante el uso de las sesiones interactivas en AWS Glue.

Temas

- Información general sobre las sesiones interactivas de AWS Glue
- Introducción a las sesiones interactivas de AWS Glue
- Configuración de las sesiones interactivas de AWS Glue para cuadernos de Jupyter y AWS Glue Studio
- Conversión de un script o cuaderno en un trabajo de AWS Glue
- Uso de operaciones de streaming en sesiones interactivas de AWS Glue
- Precios de las sesiones interactivas de AWS Glue
- Desarrollo y prueba de scripts de trabajos de AWS a nivel local
- Puntos de conexión de desarrollo

Información general sobre las sesiones interactivas de AWS Glue

Con las sesiones interactivas de AWS Glue, puede crear, probar y ejecutar rápidamente aplicaciones de análisis y preparación de datos. Las sesiones interactivas proporcionan una interfaz programática y visual para crear y probar scripts de extracción, transformación y carga (ETL) para la preparación de datos. Las sesiones interactivas ejecutan aplicaciones de análisis de Apache Spark y proporcionan acceso bajo demanda a un entorno en tiempo de ejecución remoto de Spark. AWS Glue administra de forma transparente Spark sin servidor para estas sesiones interactivas.

Dado que las sesiones interactivas son flexibles, puede crear y probar aplicaciones desde el entorno que elija. Puede crear sesiones interactivas y trabajar con ellas a través de AWS Command Line Interface y la API. Puede utilizar los cuadernos compatibles con Jupyter para crear y probar los scripts de su cuaderno en forma visual. Las sesiones interactivas proporcionan un kernel de Jupyter de código abierto que se integra prácticamente con cualquier entorno con el que Jupyter se integre, incluso con IDE como PyCharm, IntelliJ y VS Code. Esto le permite crear código en su entorno local y ejecutarlo sin problemas en el backend de sesiones interactivas.

Con la API de sesiones interactivas, los clientes pueden ejecutar mediante programación aplicaciones que utilizan análisis de Apache Spark sin la necesidad de administrar la infraestructura de Spark. Puede ejecutar una o varias instrucciones de Spark en una única sesión interactiva.

Por lo tanto, las sesiones interactivas proporcionan una forma más rápida, económica y flexible de crear y ejecutar aplicaciones de análisis y preparación de datos. Para aprender a utilizar las sesiones interactivas, consulte la documentación de esta sección. Comandos mágicos admitidos por AWS Glue

Limitaciones

- Los marcadores de trabajo no se admiten en las sesiones interactivas.
- No se admite la creación de trabajos de bloc de notas mediante AWS Command Line Interface.
- Los cuadernos de AWS Glue Studio no son compatibles con Scala.

Introducción a las sesiones interactivas de AWS Glue

En estas secciones, se describe cómo ejecutar sesiones interactivas de AWS Glue de forma local.

Requisitos previos para configurar las sesiones interactivas de manera local

A continuación, se indican los requisitos previos para instalar sesiones interactivas:

- Las versiones compatibles de Python son de la 3.6 a la 3.10+.
- Consulte las secciones siguientes para obtener instrucciones para macOS, Linux y Windows.
- Revise la documentación de precios de las sesiones interactivas para comprender la estructura de los costos.

Instalación de Jupyter y kernels de Jupyter de las sesiones interactivas de AWS Glue

Use lo siguiente para instalar el kernel localmente.

El comando, `install-glue-kernels`, instala la especificación de kernel de jupyter para los kernels pyspark y spark y también instala los logotipos en el directorio correcto.

```
pip3 install --upgrade jupyter boto3 aws-glue-sessions
```

```
install-glue-kernels
```

Ejecución de Jupyter

Para ejecutar el cuaderno de Jupyter, complete los siguientes pasos.

1. Para lanzar el cuaderno de Jupyter, ejecute el siguiente comando.

   ```
   jupyter notebook
   ```

2. Elija New (Nuevo) y, a continuación, elija uno de los kernels de AWS Glue para comenzar a escribir código en AWS Glue.

Configuración de credenciales de sesión y región

Instrucciones para macOS/Linux

Las sesiones interactivas de AWS Glue requieren los mismos permisos de IAM que los trabajos y los puntos de conexión de desarrollo de AWS Glue. Especifique el rol que se utiliza con las sesiones interactivas de una de estas dos formas:

1. Con los comandos mágicos `%iam_role` y `%region`
2. Con una línea adicional en `~/.aws/config`

Configuración de un rol de sesión con un comando mágico

En la primera celda, escriba `%iam_role <YourGlueServiceRole>` en la primera celda que se ejecuta.

Configuración de un rol de sesión con **`~/.aws/config`**

El rol de servicio de AWS Glue para las sesiones interactivas se puede especificar en el propio cuaderno, o bien almacenarse junto con la configuración de la AWS CLI. Si tiene un rol que utiliza normalmente con los trabajos de AWS Glue, este será ese rol. Si no tiene un rol que utilice para los trabajos de AWS Glue, siga esta guía, Configuración de permisos de IAM para AWS Glue, para configurar uno.

Para establecer este rol como rol predeterminado de las sesiones interactivas:

1. Con un editor de texto, abra `~/.aws/config`.
2. Busque el perfil que utiliza para AWS Glue. Si no utiliza un perfil, use el perfil `[Default]`.
3. Agregue una línea en el perfil para el rol que quiera utilizar, como `glue_role_arn=<AWSGlueServiceRole>`.
4. [Opcional]: Si el perfil no tiene un conjunto de regiones predeterminadas, se recomienda agregar uno con `region=us-east-1` y reemplazar `us-east-1` con la región deseada.
5. Guarde la configuración.

Para obtener más información, consulte Sesiones interactivas con IAM.

Instrucciones para Windows

Las sesiones interactivas de AWS Glue requieren los mismos permisos de IAM que los trabajos y los puntos de conexión de desarrollo de AWS Glue. Especifique el rol que se utiliza con las sesiones interactivas de una de estas dos formas:

1. Con los comandos mágicos `%iam_role` y `%region`
2. Con una línea adicional en `~/.aws/config`

Configuración de un rol de sesión con un comando mágico

En la primera celda, escriba `%iam_role <YourGlueServiceRole>` en la primera celda que se ejecuta.

Configuración de un rol de sesión con **`~/.aws/config`**

El rol de servicio de AWS Glue para las sesiones interactivas se puede especificar en el propio cuaderno, o bien almacenarse junto con la configuración de la AWS CLI. Si tiene un rol que utiliza normalmente con los trabajos de AWS Glue, este será ese rol. Si no tiene un rol que utiliza para los trabajos de AWS Glue, siga esta guía, Configuración de permisos de IAM para AWS Glue, para configurar uno.

Para establecer este rol como rol predeterminado de las sesiones interactivas:

1. Con un editor de texto, abra `~/.aws/config`.
2. Busque el perfil que utiliza para AWS Glue. Si no utiliza un perfil, use el perfil `[Default]`.
3. Agregue una línea en el perfil para el rol que quiera utilizar, como `glue_role_arn=<AWSGlueServiceRole>`.

4. [Opcional]: Si el perfil no tiene un conjunto de regiones predeterminadas, se recomienda agregar uno con `region=us-east-1` y reemplazar `us-east-1` con la región deseada.
5. Guarde la configuración.

Para obtener más información, consulte Sesiones interactivas con IAM.

Actualización desde la versión preliminar de las sesiones interactivas

El kernel se actualizó con nuevos nombres cuando se lanzó con la versión 0.27. Para limpiar las versiones preliminares de los kernels, ejecute lo siguiente desde un terminal o PowerShell.

> **Note**
>
> Si forma parte de cualquier otra versión preliminar de AWS Glue que requiera un modelo de servicio personalizado, al eliminar el kernel se eliminará también el modelo de servicio personalizado.

```
# Remove Old Glue Kernels
jupyter kernelspec remove glue_python_kernel
jupyter kernelspec remove glue_scala_kernel

# Remove Custom Model
cd ~/.aws/models
rm -rf glue/
```

Uso de las sesiones interactivas con SageMaker AI Studio

Sesiones interactivas de AWS Glue es un entorno de tiempo de ejecución bajo demanda y sin servidor de Apache Spark, el cual es utilizado por los científicos de datos para crear, probar y ejecutar de manera rápida la preparación de datos y las aplicaciones analíticas. Puede iniciar una sesión interactiva de AWS Glue al iniciar un cuaderno de Amazon SageMaker AI Studio Classic.

Para obtener más información, consulte Preparación de datos con las sesiones interactivas de AWS Glue.

Uso de las sesiones interactivas con Microsoft Visual Studio Code

Requisitos previos

- Instale las sesiones interactivas de AWS Glue y verifique que funcionan con Jupyter Notebook.
- Descargue e instale Visual Studio Code con Jupyter. Para obtener detalles, consulte Jupyter Notebook en VS Code

Para empezar con las sesiones interactivas con VSCode

1. Desactive Jupyter AutoStart en VS Code.

   En Visual Studio Code, los kernels de Jupyter se iniciarán automáticamente, lo que evitará que los comandos mágicos surtan efecto, ya que la sesión ya se habrá iniciado. Para deshabilitar el inicio automático en Windows, vaya a Archivo > Preferencias > Extensiones > Jupyter > haga clic con el botón derecho en Jupyter y, a continuación, seleccione Configuración de extensión.

   En MacOS, vaya a Código > Configuración > Extensiones > Jupyter >, haga clic con el botón derecho en Jupyter y, a continuación, seleccione Configuración de extensión.

   Desplácese hacia abajo hasta que vea Jupyter: deshabilitar el inicio automático de Jupyter. Marque la casilla “Si es verdadero, se deshabilita el inicio automático de Jupyter”. You must instead run a cell to start Jupyter” (Si es verdadero, desactiva el inicio automático de Jupyter. En su lugar, se debe ejecutar una celda para iniciar Jupyter).

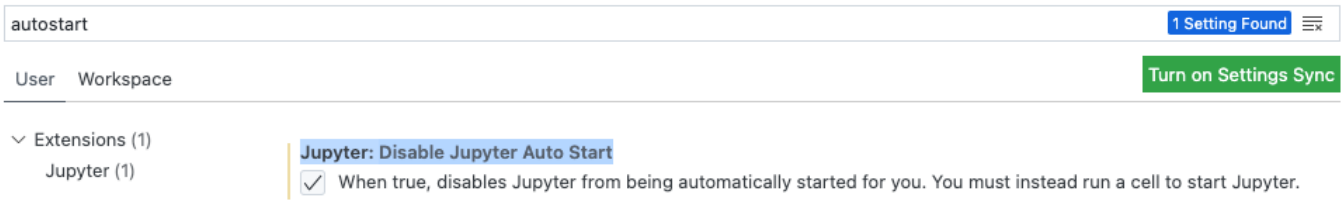

2. Vaya a File (Archivo) > New File (Nuevo archivo) > Save (Guardar) para guardar este archivo con el nombre que elija como extensión de `.ipynb`, o bien seleccione jupyter en Select a language (Seleccionar un idioma) y guarde el archivo.

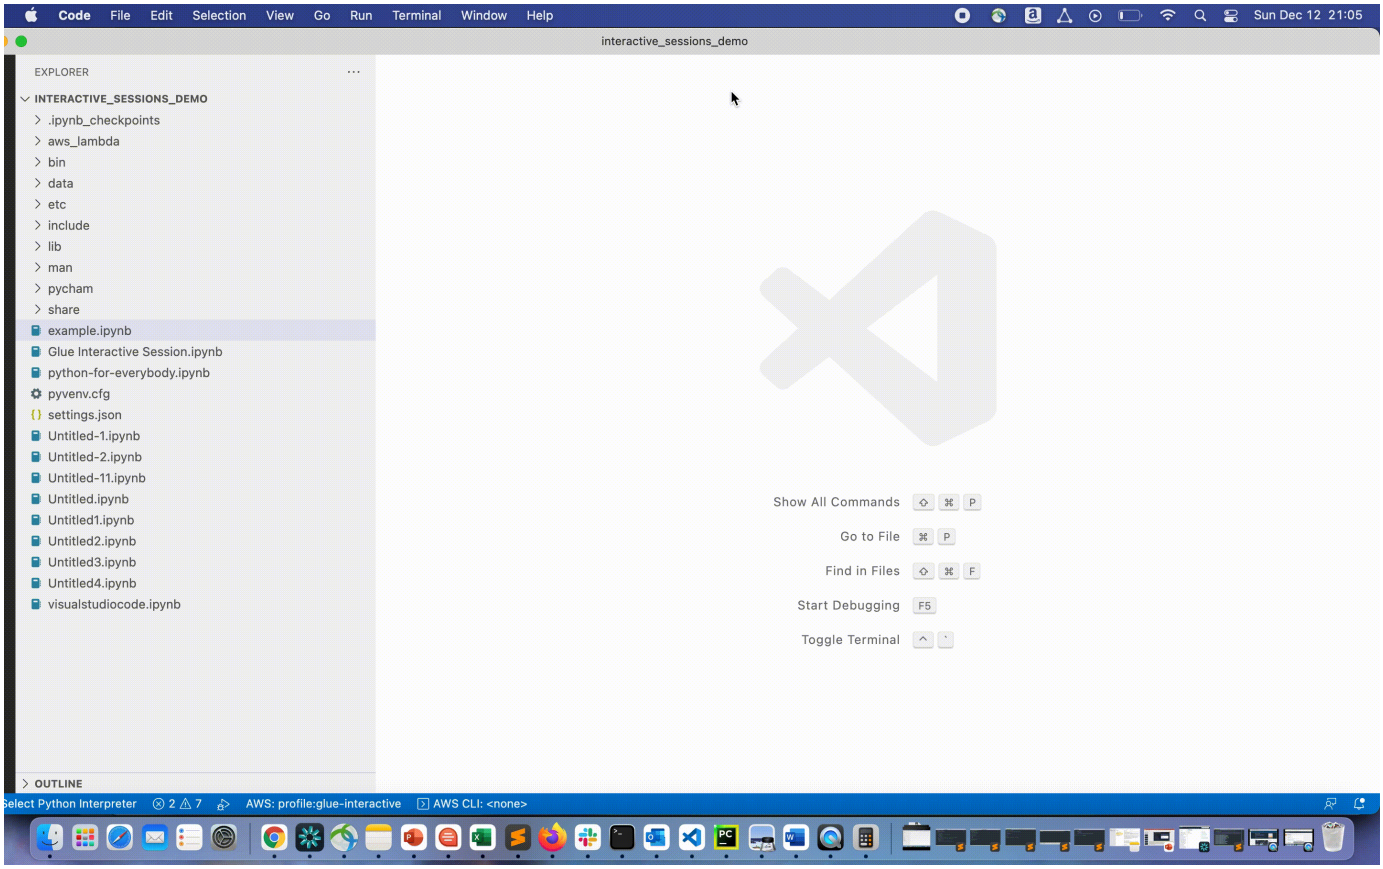

3. Haga doble clic en el archivo. Aparecerá el shell de Jupyter y se abrirá un cuaderno.

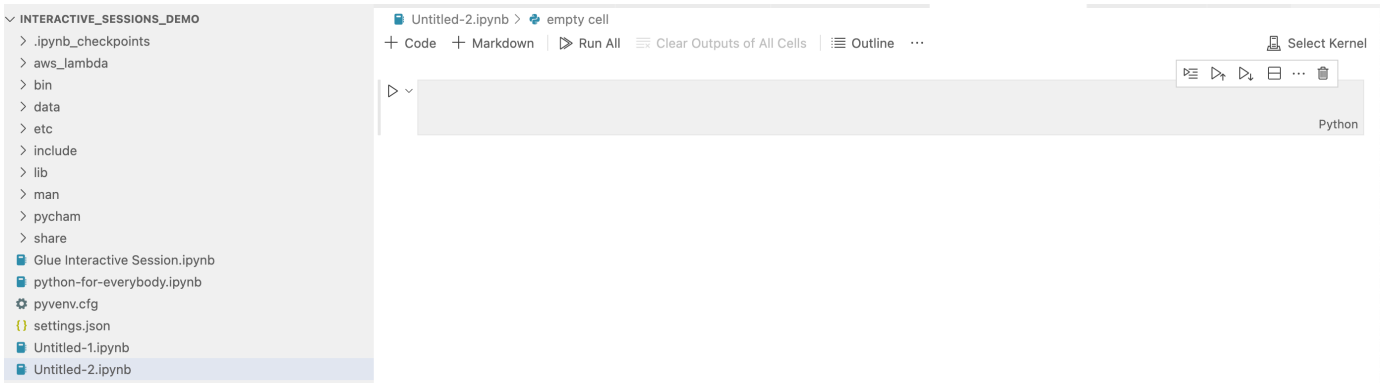

4. En Windows, cuando se crea un archivo por primera vez, de manera predeterminada no tiene seleccionado ningún kernel. Haga clic en Select Kernel (Seleccionar kernel) y se mostrará una lista de los kernels disponibles. Elija Glue PySpark.

   En MacOS, si no ve el kernel Glue PySpark, siga estos pasos:

   1. Ejecute una sesión local de Jupyter para obtener la URL.

      Por ejemplo, para lanzar el cuaderno de Jupyter, ejecute el siguiente comando.

```
jupyter notebook
```

Cuando el cuaderno se ejecute por primera vez, verá una URL similar a `http://localhost:8888/?token=3398XXXXXXXXXXXXXXX`.

Copie la dirección URL.

2. En VS Code, haga clic en el kernel actual, luego Seleccionar otro kernel... y, a continuación, seleccione Servidor de Jupyter existente.... Pegue la URL que copió en el paso anterior.

   Si recibe un mensaje de error, consulte la wiki de VS Code Jupyter.

3. Si tiene éxito, se configurará el kernel como Glue PySpark.

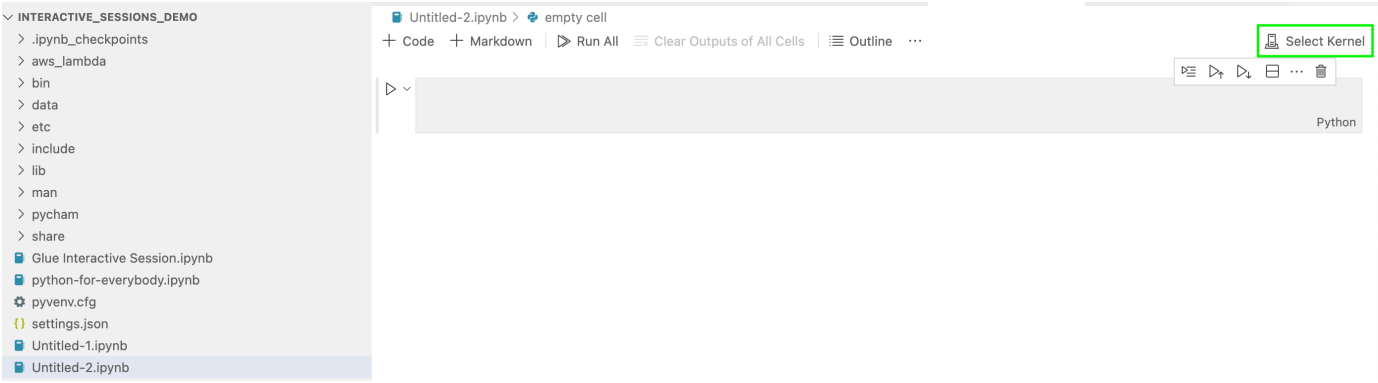

Elija el kernel Glue PySpark o Glue Spark(para Python y Scala respectivamente).

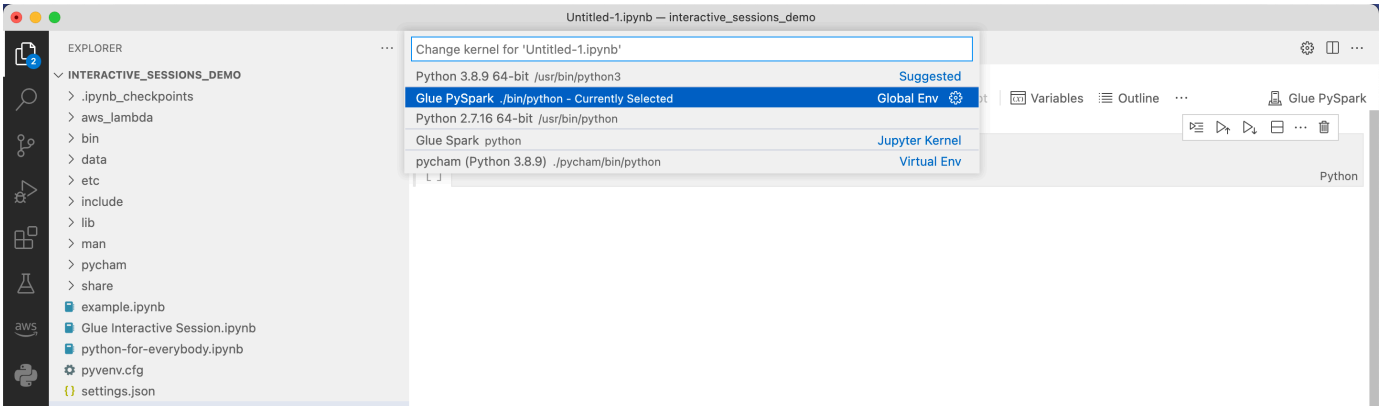

Si no aparecen los kerneles AWS Glue PySpark y AWS Glue Spark en la lista desplegable, asegúrese de que haya instalado el kernel de AWS Glue en el paso anterior, o de que la configuración `python.defaultInterpreterPath` en Visual Studio Code sea

correcta. Para obtener más información, consulte la Descripción de la configuración de python.defaultInterpreterPath.

5. Creación de uns sesión interactiva de AWS Glue. Proceda a crear una sesión del mismo modo en que lo hizo en el cuaderno de Jupyter. Especifique cualquier comando mágico en la parte superior de la primera celda y ejecute una instrucción de código.

Sesiones interactivas con IAM

En estas secciones, se describen las consideraciones de seguridad para sesiones interactivas de AWS Glue.

Temas

- Entidades principales de IAM que se utilizan con sesiones interactivas
- Configuración de una entidad principal del cliente
- Configuración de un rol de tiempo de ejecución
- Convertir la sesión en privada con TagOnCreate
- Consideraciones respecto de la política de IAM

Entidades principales de IAM que se utilizan con sesiones interactivas

Se utilizan dos entidades principales de IAM con sesiones interactivas de AWS Glue.

- Entidad principal del cliente: la entidad principal del cliente (ya sea un usuario o un rol) autoriza las operaciones de la API para sesiones interactivas de un cliente de AWS Glue configurado con las credenciales basadas en la identidad de la entidad principal. Por ejemplo, esta podría ser un rol de IAM que suele utilizarse para acceder a la consola de AWS Glue. También podría ser un rol que se haya otorgado a un usuario de IAM cuyas credenciales se utilicen para la AWS Command Line Interface, o un cliente de AWS Glue utilizado por el kernel de Jupyter de sesiones interactivas.
- Runtime role (Rol de tiempo de ejecución): el rol de tiempo de ejecución es un rol de IAM que la entidad principal del cliente pasa a las operaciones de la API de las sesiones interactivas. AWS Glue utiliza este rol para ejecutar instrucciones en la sesión. Por ejemplo, este rol podría ser el que se utiliza para ejecutar trabajos de ETL de AWS Glue.

  Para obtener más información, consulte Configuración de un rol de tiempo de ejecución.

Configuración de una entidad principal del cliente

Debe adjuntar una política de identidad a la entidad principal del cliente para permitirle llamar a la API de sesiones interactivas. Este rol debe tener el acceso `iam:PassRole` al rol de ejecución que se pasaría a la API de sesiones interactivas, como `CreateSession`. Por ejemplo, se puede adjuntar la política administrada AWSGlueConsoleFullAccess a un rol de IAM que permite a los usuarios de la cuenta con la política adjunta acceder a todas las sesiones creadas en la cuenta (como instrucción de tiempo de ejecución o instrucción de cancelación).

Si desea proteger la sesión y convertirla en privada solo para algunos roles de IAM, como aquellos asociados al usuario que creó la sesión, puede utilizar el control de autorización basado en etiquetas denominado TagOnCreate de las sesiones interactivas de AWS Glue. Para obtener más información, consulte Convertir la sesión en privada con TagOnCreate sobre cómo una política administrada de ámbito reducido basada en etiquetas de propietario puede convertir la sesión en privada con TagOnCreate. Para obtener más información sobre las políticas basadas en la identidad, consulte Políticas basadas en la identidad para AWS Glue.

Configuración de un rol de tiempo de ejecución

Se debe transferir un rol de IAM a la operación de la API CreateSession para permitir que AWS Glue asuma y ejecute instrucciones en sesiones interactivas. El rol debe tener los mismos permisos de IAM que los necesarios para ejecutar trabajos típicos de AWS Glue. Por ejemplo, puede crear un rol de servicio mediante la política AWSGlueServiceRole que permita a AWS Glue llamar a los servicios de AWS en su nombre. Si utiliza la consola de AWS Glue, se creará automáticamente un rol de servicio en su nombre o se utilizará uno existente. También puede crear su propio rol de IAM y adjuntar su propia política de IAM para conceder permisos similares.

Si desea proteger la sesión y convertirla en privada solo para el usuario de IAM que creó la sesión, puede utilizar el control de autorización basado en etiquetas denominado TagOnCreate de las sesiones interactivas de AWS Glue. Para obtener más información, consulte Convertir la sesión en privada con TagOnCreate sobre cómo una política administrada de ámbito reducido basada en etiquetas de propietario puede convertir la sesión en privada con TagOnCreate. Para obtener más información sobre políticas basadas en identidad, consulte Políticas basadas en identidades de AWS Glue. Si va a encargarse de crear el rol de ejecución desde la consola de IAM y desea que el servicio sea privado con la característica TagOnCreate, siga los pasos que se indican a continuación.

1. Cree un rol de IAM con el tipo de rol configurado como `Glue`.
2. Adjunte esta política administrada de AWS Glue: AwsGlueSessionUserRestrictedServiceRole

3. Póngale el nombre de la política AwsGlueSessionUserRestrictedServiceRole como prefijo al nombre del rol. Por ejemplo, puede crear un rol con el nombre AwsGlueSessionUserRestrictedServiceRole-myrole y adjuntarle la política administrada de AWS Glue AwsGlueSessionUserRestrictedServiceRole.
4. Adjunte una política de confianza como la siguiente para permitir que AWS Glue asuma el rol:

   JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Principal": {
        "Service": [
          "glue.amazonaws.com"
        ]
      },
      "Action": [
        "sts:AssumeRole"
      ]
    }
  ]
}
```

Para un kernel de Jupyter de sesiones interactivas, puede especificar la clave `iam_role` en el perfil de la AWS Command Line Interface. Para obtener más información, consulte Configuración de sesiones con ~/.aws/config . Si interactúa con sesiones interactivas mediante un cuaderno de AWS Glue, puede transferir el rol de ejecución en el comando mágico `%iam_role` en la primera celda que ejecute.

Convertir la sesión en privada con TagOnCreate

Las sesiones interactivas de AWS Glue son compatibles con el etiquetado y la autorización basada en etiquetas (TBAC) de las sesiones interactivas como recurso con nombre. Además con la TBAC realizada mediante las API TagResource y UntagResource, las sesiones interactivas de AWS Glue son compatibles con la característica TagOnCreate para “etiquetar” una sesión con una etiqueta determinada solo durante la creación de la sesión con la operación CreateSession. Esto también

significa que esas etiquetas se eliminarán cuando se ejecute la operación DeleteSession, también conocida como UntagOnDelete.

TagOnCreate ofrece un potente mecanismo de seguridad para convertir la sesión en privada para el creador de la sesión. Por ejemplo, se puede adjuntar una política de IAM con RequestTag “propietario” y un valor ${aws:userId} a una entidad principal de cliente (como un usuario) para permitir la creación de una sesión solo si una etiqueta de “propietario” con un valor coincidente de userId de la persona que llama se proporciona como etiqueta userId en la solicitud de CreateSession. Esta política permite que las sesiones interactivas de AWS Glue puedan crear un recurso de sesión y etiquetar la sesión con la etiqueta userId solo durante la creación de la sesión. Además, se puede limitar el acceso (como ejecutar instrucciones) a la sesión solo al creador (también conocido como etiqueta de propietario con valor ${aws:userId}) de la sesión si se adjunta una política de IAM con ResourceTag “propietario” al rol de ejecución que pasó durante la operación CreateSession.

Para facilitar el uso de la característica TagOnCreate con objeto de convertir una sesión en privada para el creador de la sesión, AWS Glue proporciona políticas administradas y roles de servicio especializados.

Si desea crear una sesión interactiva de AWS Glue mediante una entidad principal AssumeRole de IAM (es decir, mediante las credenciales suministradas asumiendo un rol de IAM) y quiere convertir la sesión en privada para el creador, entonces, utilice políticas similares a AWSGlueSessionUserRestrictedNotebookPolicy y AWSGlueSessionUserRestrictedNotebookServiceRole respectivamente. Estas políticas permiten que AWS Glue utilice ${aws:PrincipalTag} para extraer el valor de la etiqueta de propietario. Para esto es preciso pasar una etiqueta userId con el valor ${aws:userId} como SessionTag en la credencial del rol de asunción. Consulte Etiquetas de sesión de ID. Si utiliza una instancia de Amazon EC2 con un perfil de instancias que suministra la credencial y desea crear una sesión o interactuar con la sesión desde la instancia de Amazon EC2, deberá pasar una etiqueta userId con el valor ${aws:userId} como SessionTag en la credencial del rol de asunción.

Por ejemplo, si va a crear una sesión mediante una credencial de entidad principal AssumeRole de IAM y desea convertir el servicio en privado con la característica TagOnCreate, siga los pasos que se indican a continuación.

1. Cree un rol de tiempo de ejecución usted mismo desde la consola de IAM. Adjunte la política administrada de AWS Glue AwsGlueSessionUserRestrictedNotebookServiceRole, y póngale el nombre de la política AwsGlueSessionUserRestrictedNotebookServiceRole como prefijo al nombre del rol. Por ejemplo, puede crear un rol con el nombre

AwsGlueSessionUserRestrictedNotebookServiceRole-myrole y adjuntar la política administrada de AWS Glue AwsGlueSessionUserRestrictedNotebookServiceRole.

2. Adjunte una política de confianza como la que aparece a continuación para permitir que AWS Glue asuma el rol anterior.

   JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Principal": {
        "Service": [
          "glue.amazonaws.com"
        ]
      },
      "Action": [
        "sts:AssumeRole"
      ]
    }
  ]
}
```

3. Cree otro rol cuyo nombre lleve el prefijo AwsGlueSessionUserRestrictedNotebookPolicy y adjunte la política administrada de AWS Glue AwsGlueSessionUserRestrictedNotebookPolicy para convertir la sesión en privada. Además de la política administrada, adjunte la siguiente política insertada para permitir iam:PassRole para el rol que ha creado en el paso 1.

   JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "iam:PassRole"
      ],
      "Resource": [
```

```
        "arn:aws:iam::*:role/
AwsGlueSessionUserRestrictedNotebookServiceRole*"
      ],
      "Condition": {
        "StringLike": {
          "iam:PassedToService": [
            "glue.amazonaws.com"
          ]
        }
      }
    }
  ]
}
```

4. Adjunte una política de confianza como la siguiente a la IAM de AWS Glue para asumir el rol.

   JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Principal": {
        "Service": [
          "glue.amazonaws.com"
        ]
      },
      "Action": [
        "sts:AssumeRole",
        "sts:TagSession"
      ]
    }
  ]
}
```

> **Note**
>
> Opcionalmente, puede utilizar un solo rol (por ejemplo, un rol de cuaderno) y adjuntar las dos políticas administradas anteriores, AwsGlueSessionUserRestrictedNotebookServiceRole y

AwsGlueSessionUserRestrictedNotebookPolicy. Adjunte también la política insertada adicional para permitir `iam:passrole` del rol a AWS Glue. Y, finalmente, adjunte la política de confianza anterior para permitir `sts:AssumeRole` y `sts:TagSession`.

AWSGlueSessionUserRestrictedNotebookPolicy

La política AWSGlueSessionUserRestrictedNotebookPolicy proporciona acceso para crear una sesión interactiva de AWS Glue desde un cuaderno solo si se proporciona una clave de etiqueta de "propietario" y un valor que coincida con el ID de usuario de AWS de la entidad principal (usuario o rol). Para más información, consulte Dónde puede utilizar variables de política. Esta política se adjunta a la entidad principal (usuario o rol) que crea cuadernos de sesión interactiva de AWS Glue desde AWS Glue Studio. Esta política también concede suficiente acceso al cuaderno de AWS Glue Studio para interactuar con los recursos de sesión interactiva de AWS Glue Studio que se crean con el valor de etiqueta de "propietario" que coincide con el ID de usuario de AWS de la entidad principal. Esta política deniega el permiso para cambiar o eliminar la etiqueta de "propietario" de un recurso de sesión de AWS Glue después de crear la sesión.

AWSGlueSessionUserRestrictedNotebookServiceRole

AWSGlueSessionUserRestrictedNotebookServiceRole proporciona acceso suficiente al cuaderno de AWS Glue Studio para interactuar con los recursos de sesión interactiva de AWS Glue que se crean con el valor de etiqueta de "propietario" que coincide con el ID de usuario de AWS de la entidad principal (usuario o rol) del creador del cuaderno. Para obtener más información, consulte Dónde puede utilizar variables de política. Esta política de rol de servicio se adjunta al rol que se pasa como comando mágico a un cuaderno o como rol de ejecución a la API CreateSession. Esta política también permite crear una sesión interactiva de AWS Glue desde un cuaderno solo si se proporcionan una clave de etiqueta de "propietario" y un valor que coincide con el ID de usuario de AWS de la entidad principal. Esta política deniega el permiso para cambiar o eliminar la etiqueta de "propietario" de un recurso de sesión de AWS Glue después de crear la sesión. Esta política también incluye permisos para escribir y leer desde buckets de Amazon S3, escribir registros de CloudWatch, y crear y eliminar etiquetas para los recursos de Amazon EC2 que utiliza AWS Glue.

Convertir la sesión en privada con políticas de usuarios

Puede adjuntar la política AWSGlueSessionUserRestrictedPolicy a los roles de IAM adjuntos a cada uno de los usuarios de la cuenta para que solo puedan crear una sesión con una etiqueta de propietario cuyo valor coincida con su propio ${aws:userId}. En lugar de utilizar AWSGlueSessionUserRestrictedNotebookPolicy y

AWSGlueSessionUserRestrictedNotebookServiceRole, debe utilizar políticas similares a AWSGlueSessionUserRestrictedPolicy y AWSGlueSessionUserRestrictedServiceRole, respectivamente. Para obtener más información, consulte Uso de políticas basadas en identidad. Esta política reduce el ámbito de acceso a una sesión solo al creador, también conocido como ${aws:userId} del usuario que creó la sesión con la etiqueta de propietario que contiene su propio ${aws:userId}. Si ha creado el rol de ejecución por su cuenta mediante la consola de IAM de acuerdo con los pasos de Configuración de un rol de tiempo de ejecución, además de adjuntar la política administrada AwsGlueSessionUserRestrictedPolicy, adjunte también la siguiente política insertada a cada uno de los usuarios de su cuenta a fin de permitir `iam:PassRole` para el rol de ejecución que creó antes.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "iam:PassRole"
      ],
      "Resource": [
        "arn:aws:iam::*:role/AwsGlueSessionUserRestrictedServiceRole*"
      ],
      "Condition": {
        "StringLike": {
          "iam:PassedToService": [
            "glue.amazonaws.com"
          ]
        }
      }
    }
  ]
}
```

AWSGlueSessionUserRestrictedPolicy

AWSGlueSessionUserRestrictedPolicy proporciona acceso para crear una sesión interactiva de AWS Glue mediante la API CreateSession solo si se proporciona una clave de etiqueta de “propietario” y

un valor que coincida con el ID de usuario de AWS. Esta política de identidad se adjunta al usuario que invoca la API CreateSession. Esta política también permite interactuar con los recursos de sesión interactiva de AWS Glue que se crearon con una etiqueta de “propietario” y un valor que coincide con el ID de usuario de AWS. Esta política deniega el permiso para cambiar o eliminar la etiqueta de “propietario” de un recurso de sesión de AWS Glue después de crear la sesión.

AWSGlueSessionUserRestrictedServiceRole

AWSGlueSessionUserRestrictedServiceRole proporciona acceso completo a todos los recursos de AWS Glue, excepto las sesiones, y permite a los usuarios crear y utilizar solo las sesiones interactivas que tengan asociadas. Esta política también incluye otros permisos que necesita AWS Glue para administrar los recursos de Glue en otros servicios de AWS. La política también permite agregar etiquetas a recursos de AWS Glue en otros servicios de AWS.

Consideraciones respecto de la política de IAM

Las sesiones interactivas son recursos de IAM en AWS Glue. Debido a que son recursos de IAM, el acceso a una sesión y la interacción con la misma se rigen por las políticas de IAM. Según las políticas de IAM adjuntadas a una entidad principal del cliente o rol de ejecución configurado por un administrador, una entidad principal del cliente (usuario o rol) podrá crear nuevas sesiones e interactuar con las suyas y con otras.

Si un administrador ha adjuntado una política de IAM, como AWSGlueConsoleFullAccess o AWSGlueServiceRole, que permite el acceso a todos los recursos de AWS Glue en esa cuenta, las entidades principales del cliente podrán colaborar entre sí. Por ejemplo, un usuario podrá interactuar con las sesiones creadas por otros usuarios si las políticas lo permiten.

Si desea configurar una política que se adapte a sus necesidades específicas, consulte la documentación de IAM sobre la configuración de los recursos de una política. Por ejemplo, para aislar las sesiones que pertenecen a un usuario, puede usar la característica TagOnCreate compatible con las sesiones interactivas de AWS Glue. Consulte Convertir la sesión en privada con TagOnCreate .

Las sesiones interactivas permiten limitar la creación de sesiones en función de determinadas condiciones de la VPC. Consulte Políticas que controlan la configuración mediante claves de condición.

Configuración de las sesiones interactivas de AWS Glue para cuadernos de Jupyter y AWS Glue Studio

Introducción a los comandos mágicos de Jupyter

Los comandos mágicos de Jupyter son comandos que se pueden ejecutar al principio de una celda o como un cuerpo de celda completo. Los comandos mágicos comienzan por `%` en el caso de los comandos mágicos de línea, y por `%%` si son comandos mágicos de celda. Los comandos mágicos de línea como `%region` y `%connections` se pueden ejecutar con varios comandos mágicos en una celda, o bien con código incluido en el cuerpo de la celda, como en el siguiente ejemplo.

```
%region us-east-2
%connections my_rds_connection
dy_f = glue_context.create_dynamic_frame.from_catalog(database='rds_tables',
 table_name='sales_table')
```

Los comandos mágicos de celda deben utilizar toda la celda y pueden hacer que el comando abarque varias líneas. A continuación aparece un ejemplo de `%%sql`.

```
%%sql
select * from rds_tables.sales_table
```

Comandos mágicos compatibles con las sesiones interactivas de AWS Glue para Jupyter

Los siguientes son comandos mágicos que se pueden utilizar con sesiones interactivas de AWS Glue para cuadernos de Jupyter.

Comandos mágicos de las sesiones

Nombre	Tipo	Descripción
`%help`	n/a	Devuelve una lista de descripciones y tipos de entrada para todos los comandos mágicos.

Nombre	Tipo	Descripción
`%profile`	Cadena	Especifica un perfil en su configuración de AWS que se utilizará como proveedor de credenciales.
`%region`	Cadena	Especifica la Región de AWS en la que inicializar una sesión. Valor predeterminado de `~/.aws/configure`. Ejemplo:: `%region us-west-1`
`%idle_timeout`	Int	Número de minutos de inactividad tras los que se agotará el tiempo de espera de una sesión una vez que se haya ejecutado una celda. El valor predeterminado de tiempo de inactividad para las sesiones de ETL de Spark es el tiempo de espera predeterminado: 2880 minutos (48 horas). Para otros tipos de sesiones, consulte la documentación correspondiente. Ejemplo:: `%idle_timeout 3000`
`%session_id`	n/a	Devuelve el ID de la sesión en ejecución.
`%session_id_prefix`	Cadena	Defina una cadena que precederá a todos los ID de sesión con el formato [session_id_prefix]-[session_id] ([prefijo_id_sesión]-[id_sesión]). Si no se proporciona un ID de sesión, se generará un UUID aleatorio. Este comando mágico no se admite cuando se ejecuta un cuaderno de Jupyter en AWS Glue Studio. Ejemplo:: `%session_id_prefix 001`

Nombre	Tipo	Descripción
`%status`		Devuelve el estado de la sesión actual de AWS Glue, incluyendo su duración, configuración y rol o usuario ejecutante.
`%stop_session`		Detiene la sesión actual.
`%list_sessions`		Se enumeran todas las sesiones que se están ejecutando actualmente por nombre e ID.
`%session_type`	Cadena	Establece el tipo de sesión en Streaming, ETL o Ray. Ejemplo:: `%session_type Streaming`
`%glue_version`	Cadena	Versión de AWS Glue que debe utilizar esta sesión. Ejemplo:: `%glue_version 3.0`

Comandos mágicos para seleccionar los tipos de trabajo

Nombre	Tipo	Descripción
`%streaming`	Cadena	Cambia el tipo de sesión a streaming de AWS Glue.
`%etl`	Cadena	Cambia el tipo de sesión a ETL de AWS Glue.
%glue_ray	Cadena	Cambia el tipo de sesión a AWS Glue para Ray. Consulte Comandos mágicos compatibles con las sesiones interactivas de AWS Glue Ray.

Comandos mágicos de configuración de AWS Glue para Spark

El comando mágico de `%%configure` es un diccionario en formato JSON que consta de todos los parámetros de configuración para una sesión. Cada parámetro se puede especificar aquí o mediante comandos mágicos individuales.

Nombre	Tipo	Descripción
`%%configure`	Diccionario	Especifica un diccionario en formato JSON que consta de todos los parámetros de configuración para una sesión. Cada parámetro se puede especificar aquí o mediante comandos mágicos individuales. Para obtener una lista de parámetros y ejemplos de cómo utilizar `%%configure` , consulte Argumentos de comandos mágicos celulares %%configure.
`%iam_role`	Cadena	Especifica un ARN de rol de IAM con el que ejecutar la sesión. Valor predeterminado de ~/.aws/configure. Ejemplo:: `%iam_role AWSGlueServiceRole`
`%number_of_workers`	Int	Número de procesos de empleados de un worker_type definido que se asignan cuando se ejecuta un trabajo. También se debe configurar `worker_type` . El valor predeterminado de `number_of_workers` es 5. Ejemplo:: `%number_of_workers 2`
`%additional_python_modules`	Enumeración	Lista separada por comas de módulos de Python adicionales que se deben incluir en el clúster (pueden ser de PyPI o S3).

Nombre	Tipo	Descripción
		Ejemplo: : `%additional_python_modules pandas, numpy` .

Nombre	Tipo	Descripción

`%%tags`	Cadena	Agrega etiquetas a una sesión. Especifiq ue las etiquetas entre corchetes { }. Cada par de nombres de etiquetas está entre paréntesis (“”) y separado por una coma (,).
		
		`%%tags`
		`{"billing":"Data-Platform",`
		`"team":"analytics"}`
		
		Use el comando mágico `%status` para ver las etiquetas asociadas a la sesión.
		
		`%status`
		
		`Session ID: <sessionId>`
		`Status: READY`
		`Role: <example-role>`
		`CreatedOn: 2023-05-26 11:12:17.`
		`056000-07:00`
		`GlueVersion: 3.0`
		`Job Type: glueetl`
		`Tags: {'owner':'example-owner',`
		`'team':'analytics', 'billing'`
		`:'Data-Platform'}`
		`Worker Type: G.4X`
		`Number of Workers: 5`
		`Region: us-west-2`
		`Applying the following default`
		`arguments:`
		`--glue_kernel_version 0.38.0`
		`--enable-glue-datacatalog true`
		`Arguments Passed: ['--glue_`
		`kernel_version: 0.38.0', '--`
		`enable-glue-datacatalog: true']`

Nombre	Tipo	Descripción

`%%assume_role`	Diccionario	Especifique un diccionario en formato JSON o una cadena ARN de rol de IAM para crear una sesión para el acceso entre cuentas.
		
		Ejemplo con ARN:
		
		`%%assume_role`
		`{`
		`  'arn:aws:iam::XXXXXXXXXXXX:`
		`role/AWSGlueServiceRole'`
		`}`
		
		Ejemplo con credenciales:
		
		`%%assume_role`
		`{{`
		`  "aws_access_key_id" =`
		`"XXXXXXXXXXXX",`
		`  "aws_secret_access_key" =`
		`"XXXXXXXXXXXX",`
		`  "aws_session_token" =`
		`"XXXXXXXXXXXX"`
		`}}`

Argumentos de comandos mágicos celulares %%configure

El comando mágico de `%%configure` es un diccionario en formato JSON que consta de todos los parámetros de configuración para una sesión. Cada parámetro se puede especificar aquí o mediante comandos mágicos individuales. A continuación se muestran ejemplos de argumentos compatibles con el comando mágico celular `%%configure`. Utilice el prefijo `--` para los argumentos de ejecución especificados para el trabajo. Ejemplo:

```
%%configure
```

```
{
   "--user-jars-first": "true",
   "--enable-glue-datacatalog": "false"
}
```

Para obtener más información sobre los parámetros del trabajo, consulte Parámetros del flujo de trabajo.

Configuración de la sesión

Parámetro	Tipo	Descripción

`max_retries`	Int	Número máximo de reintentos permitidos para esta tarea si se genera un error.
		`%%configure`
		`{`
		`  "max_retries": "0"`
		`}`

`max_concurrent_runs`	Int	El número máximo de ejecuciones simultáneas que están permitidas para un trabajo.
		Ejemplo:
		`%%configure`
		`{`
		`  "max_concurrent_runs": "3"`
		`}`

Parámetros de la sesión

Parámetro	Tipo	Descripción

`--enable-spark-ui`	Booleano	Activa la interfaz de usuario de Spark para supervisar y depurar los trabajos de AWS Glue ETL.
		`%%configure`
		`{`
		`  "--enable-spark-ui": "true"`
		`}`

`--spark-event-logs-path`	Cadena	Especifica una ruta de Amazon S3. Al usar la característica de monitoreo de la interfaz de usuario de Spark.
		Ejemplo:
		`%%configure`
		`{`
		`  "--spark-event-logs-path":`
		`"s3://path/to/event/logs/"`
		`}`

`--script_location`	Cadena	Especifica la ruta de S3 a un script que ejecuta un flujo de trabajo.
		Ejemplo:
		`%%configure`
		`{`
		`  "script_location": "s3://new-folder-here"`
		`}`

`--SECURITY_CONFIGURATION`	Cadena	El nombre de una configuración de seguridad de AWS Glue

Parámetro	Tipo	Descripción

		Ejemplo:
		
		`%%configure`
		`{`
		`"--security_configuration": { "encryption_type": "kms", "kms_key_id": "YOUR_KMS _KEY_ARN" }`
		`}`

`--job-language`	Cadena	El lenguaje de programación del script. Acepta un valor de “scala” o “python”. El valor predeterminado es “python”.
		
		Ejemplo:
		
		`%%configure`
		`{`
		`"--job-language": "scala"`
		`}`

`--class`	Cadena	La clase de Scala que sirve de punto de entrada del script de Scala. El valor predeterminado es nulo.
		
		Ejemplo:
		
		`%%configure`
		`{`
		`"--class": "className"`
		`}`

Parámetro	Tipo	Descripción

`--user-jars-first`	Booleano	Prioriza los archivos JAR adicionales del cliente en la ruta de clases. El valor predeterminado es nulo.
		
		Ejemplo:
		
		`%%configure`
		`{`
		`  "--user-jars-first": "true"`
		`}`

`--use-postgres-driver`	Booleano	Prioriza el controlador JDBC de Postgres en la ruta de clases para evitar un conflicto con el controlador JDBC Amazon Redshift. El valor predeterminado es nulo.
		
		Ejemplo:
		
		`%%configure`
		`{`
		`  "--use-postgres-driver": "true"`
		`}`

Parámetro	Tipo	Descripción

`--extra-files`	List(cadena)	Las rutas de Amazon S3 a archivos adicionales, por ejemplo, archivos de configuración que AWS Glue copia en el directorio de trabajo del script antes de ejecutarlo.
		
		Ejemplo:
		
		`%%configure`
		`{`
		`  "--extra-files": "s3://path/to/additional/files/"`
		`}`

`--job-bookmark-option`	Cadena	Controla el comportamiento de un marcador de trabajo. Acepta los valores 'job-bookmark-enable', 'job-bookmark-disable' o 'job-bookmark-pause'. El valor predeterminado es “job-bookmark-disable”.
		
		Ejemplo:
		
		`%%configure`
		`{`
		`  "--job-bookmark-option": "job-bookmark-enable"`
		`}`

Parámetro	Tipo	Descripción

`--TempDir`	Cadena	Especifica una ruta de Amazon S3 a un bucket que se puede utilizar como directorio temporal para el trabajo. El valor predeterminado es nulo.
		
		Ejemplo:
		
		`%%configure`
		`{`
		`  "--TempDir": "s3://path/to/temp/dir"`
		`}`

`--enable-s3-parquet-optimized-committer`	Booleano	Habilita el confirmador optimizado para Amazon S3 de EMRFS de forma que puedan escribirse datos de Parquet en Amazon S3. El valor predeterminado es “verdadero”.
		
		Ejemplo:
		
		`%%configure`
		`{`
		`  "--enable-s3-parquet-optimized-committer": "false"`
		`}`

Parámetro	Tipo	Descripción

`--enable-rename-algorithm-v2`	Booleano	Establece la versión del algoritmo de cambio de nombre de EMRFS a la versión 2. El valor predeterminado es “verdadero”.
		
		Ejemplo:
		
		`%%configure`
		`{`
		`  "--enable-rename-algorithm-v2": "true"`
		`}`

`--enable-glue-datacatalog`	Booleano	Permite utilizar el Catálogo de datos de AWS Glue como metaalmacén de Apache Spark Hive.
		
		Ejemplo:
		
		`%%configure`
		`{`
		`  "--enable-glue-datacatalog": "true"`
		`}`

Parámetro	Tipo	Descripción

`--enable-metrics`	Booleano	Permite recopilar métricas para generar perfiles de trabajo en la ejecución de trabajos. La opción predeterminada es 'falso'.
		
		Ejemplo:
		
		`%%configure`
		`{`
		`  "--enable-metrics": "true"`
		`}`

`--enable-continuous-cloudwatch-log`	Booleano	Permite un registro continuo en tiempo real de los trabajos de AWS Glue. La opción predeterminada es 'falso'.
		
		Ejemplo:
		
		`%%configure`
		`{`
		`  "--enable-continuous-cloudw atch-log": "true"`
		`}`

Parámetro	Tipo	Descripción

`--enable-continuous-log-filter`	Booleano	Especifica un filtro estándar o ningún filtro al crear o editar un trabajo habilitado para el registro continuo. El valor predeterminado es “verdadero”.
		
		Ejemplo:
		
		`%%configure`
		`{`
		`  "--enable-continuous-log-filter": "true"`
		`}`

`--continuous-log-stream-prefix`	Cadena	Especifica un prefijo de flujo de registro de Amazon CloudWatch personalizado para un trabajo habilitado para el registro continuo. El valor predeterminado es nulo.
		
		Ejemplo:
		
		`%%configure`
		`{`
		`  "--continuous-log-stream-prefix": "prefix"`
		`}`

Parámetro	Tipo	Descripción

`--continuous-log-conversionPattern`	Cadena	Especifica un patrón de registro de conversión personalizado para un trabajo habilitado para el registro continuo. El valor predeterminado es nulo.
		
		Ejemplo:
		
		`%%configure`
		`{`
		`  "--continuous-log-conversionPattern": "pattern"`
		`}`

`--conf`	Cadena	Controla los parámetros de configuración de Spark. Es para casos de uso avanzados. Utilice `--conf` antes de cada parámetro. Ejemplo:
		
		`%%configure`
		`{`
		`    "--conf": "spark.hadoop.hive.metastore.glue.catalogid=123456789012 --conf hive.metastore.client.factory.class=com.amazonaws.glue.catalog.metastore.AWSGlueDataCatalogHiveClientFactory --conf hive.metastore.schema.verification=false"`
		`}`

Parámetro	Tipo	Descripción

timeout	Int	Determina el periodo máximo durante el cual debe esperar la sesión de Spark hasta que transcurra una instrucción antes de finalizarla.
		
		`%%configure`
		`{`
		`  "timeout": "30"`
		`}`

escalado automático	Booleano	Determina si se debe usar o no el escalado automático.
		
		`%%configure`
		`{`
		`  "--enable-auto-scaling": "true"`
		`}`

Comandos mágicos de trabajos de Spark (ETL y streaming)

Nombre	Tipo	Descripción
`%worker_type`	Cadena	Estándar, G.1X, G.2X, G.4X, G.8X, G.12X, G.16X, R.1X, R.2X, R.4X o R.8X. `number_of_workers` también debe configurarse. El valor predeterminado de worker_type es G.1X.
`%connections`	Enumeración	Especifica una lista separada por comas de conexiones que se utilizarán en la sesión. Ejemplo: `%connections my_rds_connection`

Nombre	Tipo	Descripción
		`dy_f = glue_context.create_dynamic_frame.from_catalog(database='rds_tables', table_name='sales_table')`
`%extra_py_files`	Enumeración	Lista separada por comas de archivos de Python adicionales de Simple Storage Service (Amazon S3).
`%extra_jars`	Enumeración	Lista separada por comas de archivos jar adicionales que se deben incluir en el clúster.
`%spark_conf`	Cadena	Especifique las configuraciones de Spark personalizadas para la sesión. Por ejemplo, `%spark_conf spark.serializer=org.apache.spark.serializer.KryoSerializer` .

Comandos mágicos para trabajos de Ray

Nombre	Tipo	Descripción
`%min_workers`	Int	La cantidad mínima de trabajadores que se asignan a un trabajo de Ray. Valor predeterminado: 1. Ejemplo:: `%min_workers 2`
`%object_memory_head`	Int	El porcentaje de memoria libre en el nodo de instancia después de un inicio en caliente. Mínimo: 0. Máximo: 100. Ejemplo:: `%object_memory_head 100`

Nombre	Tipo	Descripción
%object_memory_worker	Int	El porcentaje de memoria libre en los nodos de trabajo de la instancia después de un inicio en caliente. Mínimo: 0. Máximo: 100. Ejemplo:: `%object_memory_worker 100`

Comando mágico de acción

Nombre	Tipo	Descripción
`%%sql`	Cadena	Ejecuta código SQL. Todas las líneas después del comando mágico inicial `%%sql` se pasarán como parte del código SQL. Ejemplo:: `%%sql select * from rds_tables.sales_table`

`%matplot`	Figura de Matplotlib	Visualice sus datos con la biblioteca matplotlib.
		
		Ejemplo:
		
		`import matplotlib.pyplot as plt`
		
		`# Set X-axis and Y-axis values`
		`x = [5, 2, 8, 4, 9]`
		`y = [10, 4, 8, 5, 2]`
		
		`# Create a bar chart`
		`plt.bar(x, y)`
		
		`# Show the plot`
		`%matplot plt`

Nombre	Tipo	Descripción

`%plotly`	Figura de Plotly	Visualice sus datos con la biblioteca de plotly.
		
		Ejemplo:
		
		`import plotly.express as px`
		
		`#Create a graphical figure`
		`fig = px.line(x=["a","b","c"],`
		`y=[1,3,2], title="sample`
		`figure")`
		
		`#Show the figure`
		`%plotly fig`

Denominación de sesiones

Las sesiones interactivas de AWS Glue son recursos de AWS y requieren un nombre. Los nombres deben ser únicos para cada sesión y los administradores de IAM pueden restringirlos. Para obtener más información, consulte Sesiones interactivas con IAM. El kernel de Jupyter genera automáticamente nombres de sesión únicos para usted. No obstante, se puede poner nombre manualmente a las sesiones de dos formas:

1. Utilizando el archivo de configuración de la AWS Command Line Interface situado en `~.aws/config`. Consulte Establecimiento de la configuración de AWS con la AWS Command Line Interface.
2. Utilizando los comandos mágicos `%session_id_prefix`. Consulte Comandos mágicos compatibles con las sesiones interactivas de AWS Glue para Jupyter .

Un nombre de sesión se genera de la siguiente manera:

- Cuando se proporcionan el prefijo y session_id: el nombre de la sesión será {prefijo}-{UUID}.
- Cuando no se proporciona nada: el nombre de la sesión será {UUID}.

Ponerles prefijos a los nombres de las sesiones permite reconocerlas cuando aparecen en la AWS CLI o la consola.

Especificación de un rol de IAM para las sesiones interactivas

Debe especificar un rol de AWS Identity and Access Management (IAM) para utilizar con el código ETL de AWS Glue que ejecuta con sesiones interactivas.

El rol requiere los mismos permisos de IAM que los necesarios para ejecutar trabajos de AWS Glue. Consulte Crear un rol de IAM para AWS Glue para obtener más información sobre cómo crear un rol para trabajos y sesiones interactivas de AWS Glue.

Los roles de IAM se pueden especificar de dos formas:

- Utilizando el archivo de configuración de la AWS Command Line Interface situado en `~.aws/config`. (Recomendado) Para obtener más información, consulte Configuración de sesiones con ~/.aws/config .

  > **Note**
  >
  > Cuando se utiliza el comando mágico `%profile`, se aplica la configuración para `glue_iam_role` de ese perfil.

- Utilizando el comando mágico %iam_role. Para obtener más información, consulte Comandos mágicos compatibles con las sesiones interactivas de AWS Glue para Jupyter .

Configuración de sesiones con perfiles con nombre

Sesiones interactivas de AWS Glue utiliza las mismas credenciales que AWS Command Line Interface o boto3. Sesiones interactivas respeta y utiliza perfiles con nombre tales como la AWS CLI que se encuentra en `~/.aws/config` (Linux y MacOS) o `%USERPROFILE%\.aws\config` (Windows). Para obtener más información, consulte Uso de perfiles con nombre.

Las sesiones interactivas aprovechan los perfiles con nombre permitiendo que se especifiquen el rol de servicio y el prefijo de ID de sesión de AWS Glue en un perfil. Para configurar un rol de perfil, agregue una línea para la clave de `iam_role` o `session_id_prefix` al perfil con nombre tal y como se muestra a continuación. El `session_id_prefix` no requiere comillas. Por ejemplo, si desea agregar un `session_id_prefix`, ingrese el valor del `session_id_prefix=myprefix`.

```
[default]
region=us-east-1
aws_access_key_id=AKIAIOSFODNN7EXAMPLE
aws_secret_access_key=wJalrXUtnFEMI/K7MDENG/bPxRfiCYEXAMPLEKEY
glue_iam_role=arn:aws:iam::<AccountID>:role/<GlueServiceRole>
session_id_prefix=<prefix_for_session_names>

[user1]
region=eu-west-1
aws_access_key_id=AKIAI44QH8DHBEXAMPLE
aws_secret_access_key=je7MtGbClwBF/2Zp9Utk/h3yCo8nvbEXAMPLEKEY
glue_iam_role=arn:aws:iam::<AccountID>:role/<GlueServiceRoleUser1>
session_id_prefix=<prefix_for_session_names_for_user1>
```

Si tiene un método personalizado para generar credenciales, también puede configurar el perfil para que utilice el parámetro `credential_process` en el archivo `~/.aws/config`. Por ejemplo:

```
[profile developer]
region=us-east-1
credential_process = "/Users/Dave/generate_my_credentials.sh" --username helen
```

Puede encontrar más información sobre cómo obtener credenciales a través del parámetro `credential_process` aquí: Obtención de credenciales con un proceso externo.

Si el perfil que está utilizando no tiene configurados una región o un `iam_role`, debe especificarlos mediante los comandos mágicos `%region` y `%iam_role` en la primera celda que ejecute.

Conversión de un script o cuaderno en un trabajo de AWS Glue

Hay dos maneras de convertir un script o cuaderno en un trabajo de AWS Glue:

- Utilice nbconvert para convertir el archivo del documento de cuaderno `.ipynb` de Jupyter en un archivo `.py`. Para obtener más información, consulte nbconvert: convertir cuadernos a otros formatos.
- Cargue el archivo en cuadernos de AWS Glue Studio.
  - En la consola de AWS Glue Studio, elija Jobs (Trabajos) en el menú de navegación izquierdo.
  - En la sección Create job (Crear trabajo), elija Jupyter Notebook.

- En la sección Options (Opciones), elija Upload and edit an existing notebook (Cargar y editar un cuaderno existente).
- Seleccione Choose file (Elegir archivo) para cargar un archivo `.ipynb`.

Uso de operaciones de streaming en sesiones interactivas de AWS Glue

Cambio del tipo de sesión de streaming

Utilice el comando mágico de configuración de las sesiones interactivas de AWS Glue, `%streaming`, para definir el trabajo que vaya a ejecutar e inicializar una sesión interactiva de streaming.

Muestreo de flujo de entrada para desarrollo interactivo

Una herramienta que hemos desarrollado para contribuir a mejorar la experiencia interactiva en las sesiones interactivas de AWS Glue es la adición de un nuevo método en `GlueContext` con objeto de obtener una instantánea de un flujo de un DynamicFrame estático. `GlueContext` permite inspeccionar el flujo de trabajo, así como interactuar con él e implementarlo.

Con la instancia de la clase `GlueContext`, podrá localizar el método `getSampleStreamingDynamicFrame`. Los argumentos requeridos para este método son:

- `dataFrame`: DataFrame de Spark Streaming
- `options`: consulte las opciones disponibles a continuación

Entre las opciones disponibles se incluyen:

- windowSize: también se denomina duración de microlote. Este parámetro determinará cuánto tiempo esperará una consulta de streaming después de que se haya desencadenado el lote anterior. El valor de este parámetro debe ser inferior al de `pollingTimeInMs`.
- pollingTimeInMs: tiempo total que se ejecutará el método. Desencadenará al menos un microlote para obtener registros de muestra del flujo de entrada.
- recordPollingLimit: este parámetro ayuda a limitar el número total de registros que se sondearán en el flujo.

- (Opcional) También se puede utilizar `writeStreamFunction` para aplicar esta función personalizada a cada función de muestreo de registros. Consulte los ejemplos en Scala y Python que aparecen a continuación.

Scala

```
val sampleBatchFunction = (batchDF: DataFrame, batchId: Long) => {//Optional but
 you can replace your own forEachBatch function here}
val jsonString: String = s"""{"pollingTimeInMs": "10000", "windowSize": "5
 seconds"}"""
val dynFrame = glueContext.getSampleStreamingDynamicFrame(YOUR_STREAMING_DF,
 JsonOptions(jsonString), sampleBatchFunction)
dynFrame.show()
```

Python

```
def sample_batch_function(batch_df, batch_id):
       //Optional but you can replace your own forEachBatch function here
options = {
            "pollingTimeInMs": "10000",
            "windowSize": "5 seconds",
        }
glue_context.getSampleStreamingDynamicFrame(YOUR_STREAMING_DF, options,
 sample_batch_function)
```

> **Note**
>
> Cuando el elemento `DynFrame` que se muestrea está vacío, puede deberse a varios motivos:
>
> - El origen del streaming está configurado como “Latest” (Más reciente) y no se han ingerido datos nuevos durante el período de muestra.
> - El tiempo de sondeo no es suficiente para procesar los registros que ha ingerido. No aparecerán datos a menos que se haya procesado todo el lote.

Ejecución de aplicaciones de streaming en las sesiones interactivas

En las sesiones interactivas de AWS Glue, se puede ejecutar una aplicación de streaming de AWS Glue del mismo modo que se crearía una aplicación de streaming en la consola de AWS Glue. Dado que las sesiones interactivas se basan en sesiones, si se producen excepciones en el motor de ejecución no se detiene la sesión. Ahora ofrecemos el beneficio adicional de desarrollar una función por lotes de manera iterativa. Por ejemplo:

```
def batch_function(data_frame, batch_id):
    log.info(data_frame.count())
    invalid_method_call()
glueContext.forEachBatch(frame=streaming_df, batch_function = batch_function, options =
 {**})
```

En el ejemplo anterior, incluimos un uso no válido de un método y, a diferencia de trabajos de AWS Glue normales, que cerrarán toda la aplicación, el contexto de codificación y las definiciones del usuario se conservan por completo y la sesión sigue funcionando. No es necesario arrancar un nuevo clúster y volver a ejecutar toda la transformación anterior. Eso permite centrarse en iterar rápidamente las implementaciones de una función por lotes para obtener los resultados deseados.

Es importante tener en cuenta que Sesiones interactivas evalúa cada instrucción con una perspectiva de bloqueo, para que la sesión solo ejecute una instrucción a la vez. Dado que las consultas de streaming son continuas y nunca terminan, las sesiones con consultas de streaming activas no podrán gestionar ninguna instrucción de seguimiento a menos que se interrumpan. Puede ejecutar el comando de interrupción directamente desde Jupyter Notebook y nuestro kernel se encargará de realizar la cancelación.

Tomemos como ejemplo la siguiente secuencia de instrucciones que están esperando su ejecución:

```
Statement 1:
      val number = df.count()
      #Spark Action with deterministic result
      Result: 5

Statement 2:
      streamingQuery.start().awaitTermination()
      #Spark Streaming Query that will be executing continously
      Result: Constantly updated with each microbatch
```

```
Statement 3:
      val number2 = df.count()
      #This will not be executed as previous statement will be running indefinitely
```

Precios de las sesiones interactivas de AWS Glue

AWS cobra por las sesiones interactivas de AWS Glue en función del tiempo que la sesión está activa y la cantidad de unidades de procesamiento de datos (DPU) utilizadas. Se le cobra una tarifa por hora por la cantidad de DPU utilizadas para ejecutar sus cargas de trabajo, que se factura en incrementos de un segundo. Las sesiones interactivas de AWS Glue asignan un valor predeterminado de 5 DPU y requieren un mínimo de 2 DPU. También hay una duración mínima de facturación de 1 minuto para cada sesión interactiva. Para ver los ejemplos de tarifas y precios de AWS Glue, o para calcular los costos con la calculadora de precios de AWS, consulte Precios de AWS Glue.

Configure sus sesiones interactivas de AWS Glue

Puede utilizar comandos mágicos de Jupyter en su sesión interactiva de AWS para modificar sus parámetros de sesión y configuración. Los comandos mágicos son comandos cortos con el prefijo `%` al principio de las celdas de Jupyter, que proporcionan una forma rápida y sencilla de ayudarle a controlar su entorno. Por ejemplo, si desea cambiar el número de trabajadores asignados a su trabajo de los 5 predeterminados a 10, puede especificar `%number_of_workers 10`. Si desea configurar la sesión para que se detenga tras 10 minutos de inactividad en lugar de los 2880 predeterminados, puede especificar `%idle_timeout 10`.

Para ver la lista completa de magics de AWS disponibles, consulte Configuración de sesiones interactivas de AWS para cuadernos de Jupyter y AWS Glue Studio.

Desarrollo y prueba de scripts de trabajos de AWS a nivel local

Cuando desarrolle y pruebe sus scripts de trabajo Spark de AWS Glue, hay varias opciones disponibles:

- Consola de AWS Glue Studio
  - Visual editor (Editor visual)
  - Editor de scripts

  - Cuaderno de AWS Glue Studio
- Sesiones interactivas
  - Cuadernos de Jupyter
- Imagen de Docker
  - Desarrollo local
  - Desarrollo remoto

Puede elegir cualquiera de las opciones anteriores en función de sus requisitos.

Si prefiere no tener código o utilizar el código menos, el editor visual de AWS Glue Studio es una buena opción.

Si prefiere una experiencia de cuaderno interactiva, el cuaderno de AWS Glue Studio es una buena opción. Para obtener más información, consulte Uso de los cuadernos con AWS Glue Studio y AWS Glue. Si desea utilizar su propio entorno local, las sesiones interactivas son una buena opción. Para obtener más información, consulte Uso de las sesiones interactivas con AWS Glue.

Si prefiere la experiencia de desarrollo local o remoto, la imagen de Docker es una buena opción. Esto le permitirá desarrollar y probar el script de trabajo Spark de AWS Glue en cualquier lugar que prefiera sin tener que incurrir en costos de AWS Glue.

Si prefiere el desarrollo local sin Docker, instalar el directorio de bibliotecas ETL de AWS Glue DE forma local es una buena opción.

Desarrollo mediante AWS Glue Studio

El editor visual de AWS Glue Studio es una interfaz gráfica que facilita la creación, ejecución y supervisión de los trabajos de extracción, transformación y carga (ETL) en AWS Glue. Puede componer visualmente flujos de trabajo de transformación de datos y ejecutarlos sin problemas en el motor de ETL sin servidor basado en Apache Spark de AWS Glue. Puede inspeccionar los resultados de esquema y datos en cada paso del trabajo. Para obtener más información, consulte Guía del usuario de AWS Glue Studio.

Desarrollo mediante sesiones interactivas

Las sesiones interactivas le permiten crear y probar aplicaciones desde el entorno que elija. Para obtener más información, consulte Uso de las sesiones interactivas con AWS Glue.

Desarrolle y pruebe trabajos de AWS Glue localmente mediante una imagen de Docker.

Para una plataforma de datos lista para producción, el proceso de desarrollo y la canalización de CI/CD para trabajos de AWS Glue es un tema clave. Puede desarrollar y probar trabajos de AWS Glue de manera flexible en un contenedor de Docker. AWS Glue aloja las imágenes de Docker en Docker Hub para configurar el entorno de desarrollo con utilidades adicionales. Puede utilizar su IDE, cuaderno o REPL preferidos mediante la biblioteca de ETL de AWS Glue. En este tema, se describe cómo desarrollar y probar trabajos de versión 5.0 de AWS Glue en un contenedor de Docker mediante la utilización de una imagen de Docker.

Imágenes de Docker disponibles

Las siguientes imágenes de Docker están disponibles para AWS Glue en Amazon ECR:.

- Para la versión 5.0 de AWS Glue: `public.ecr.aws/glue/aws-glue-libs:5`
- Para la versión 4.0 AWS Glue: `public.ecr.aws/glue/aws-glue-libs:glue_libs_4.0.0_image_01`
- Para la versión 3.0 de AWS Glue: `public.ecr.aws/glue/aws-glue-libs:glue_libs_3.0.0_image_01`
- Para la versión 2.0 de AWS Glue: `public.ecr.aws/glue/aws-glue-libs:glue_libs_2.0.0_image_01`

> **Note**
>
> Las imágenes de Docker de AWS Glue son compatibles con x86_64 y arm64.

En este ejemplo, usamos `public.ecr.aws/glue/aws-glue-libs:5` y ejecutamos el contenedor en una máquina local (Mac, Windows o Linux). Esta imagen de contenedor ha sido probada para trabajos de la versión 5.0 de Spark de AWS Glue. La imagen contiene lo siguiente:

- Amazon Linux 2023
- Biblioteca de ETL de AWS Glue
- Apache Spark 3.5.4

- Bibliotecas de formato de tabla abierta: Apache Iceberg 1.7.1, Apache Hudi 0.15.0 y Delta Lake 3.3.0
- Cliente del Catálogo de datos de AWS Glue
- Conector Amazon Redshift para Apache Spark
- Conector Amazon DynamoDB para Apache Hadoop

Para configurar su contenedor, extraiga la imagen de la Galería Pública de ECR y, a continuación, ejecute el contenedor. Este tema demuestra cómo ejecutar su contenedor con los siguientes métodos, según sus requisitos:

- `spark-submit`
- Intérprete de comandos de REPL (`pyspark`)
- `pytest`
- Visual Studio Code

Requisitos previos

Antes de empezar, asegúrese de que Docker esté instalado y que el daemon Docker se esté ejecutando. Para ver las instrucciones de instalación, consulte la documentación de Docker para Mac o Linux. La máquina que ejecuta Docker aloja el contenedor de AWS Glue. Asegúrese también de tener al menos 7 GB de espacio en disco para la imagen del host que ejecuta Docker.

Para obtener más información sobre las restricciones en el momento de desarollar el código AWS Glue en forma local, consulte Restricciones de desarrollo local.

Configuración de AWS

Para habilitar llamadas a la API de AWS desde el contenedor, configure las credenciales de AWS siguiendo estos pasos. En las siguientes secciones, utilizaremos este perfil con nombre AWS.

1. Cree un perfil con el nombre AWS.
2. Abra `cmd` en Windows o en una terminal en Mac/Linux y ejecute el siguiente comando en la terminal:

```
PROFILE_NAME="<your_profile_name>"
```

En las siguientes secciones, utilizaremos este perfil con el nombre AWS.

Si está ejecutando Docker en Windows, elija el ícono de Docker (clic con el botón derecho) y elija Cambiar a contenedores Linux… antes de extraer la imagen.

Ejecute el siguiente comando para extraer la imagen de la galería pública de ECR:

```
docker pull public.ecr.aws/glue/aws-glue-libs:5
```

Ejecute el contenedor

Ahora puede ejecutar un contenedor mediante esta imagen. Puede elegir cualquiera de los siguientes según sus requisitos.

spark-submit

Puede ejecutar un script de trabajo de AWS Glue ejecutando el comando `spark-submit` en el contenedor.

1. Escriba su script y guárdelo como `sample.py` en el ejemplo siguiente y guárdelo en el directorio `/local_path_to_workspace/src/` con los siguientes comandos:

   ```
   $ WORKSPACE_LOCATION=/local_path_to_workspace
   $ SCRIPT_FILE_NAME=sample.py
   $ mkdir -p ${WORKSPACE_LOCATION}/src
   $ vim ${WORKSPACE_LOCATION}/src/${SCRIPT_FILE_NAME}
   ```

2. Estas variables se utilizan en el comando docker run que aparece a continuación. El código de ejemplo (sample.py) utilizado en el siguiente comando spark-submit se incluye en el apéndice al final de este tema.

   Ejecute el siguiente comando para ejecutar el comando `spark-submit` en el contenedor para enviar una nueva aplicación Spark:

   ```
   $ docker run -it --rm \
       -v ~/.aws:/home
       /hadoop/.aws \
       -v $WORKSPACE_LOCATION:/home/hadoop/workspace/ \
       -e AWS_PROFILE=$PROFILE_NAME \
       --name glue5_spark_submit \
       public.ecr.aws/glue/aws-glue-libs:5 \
   ```

```
    spark-submit /home/hadoop/workspace/src/$SCRIPT_FILE_NAME
```

3. (Opcionalmente) Configure `spark-submit` para que se adapte a su entorno. Por ejemplo, puede transferir sus dependencias con la configuración de `--jars`. Para obtener más información, consulte Carga dinámica de propiedades de Spark en la documentación de Spark.

Intérprete de comandos REPL (Pyspark)

Puede ejecutar el intérprete de comandos de REPL (`read-eval-print loops`) para el desarrollo interactivo. Ejecute el siguiente comando para ejecutar el comando PySpark en el contenedor e iniciar el intérprete de comandos REPL:

```
$ docker run -it --rm \
    -v ~/.aws:/home/hadoop/.aws \
    -e AWS_PROFILE=$PROFILE_NAME \
    --name glue5_pyspark \
    public.ecr.aws/glue/aws-glue-libs:5 \
    pyspark
```

Verá el siguiente resultado:

```
Python 3.11.6 (main, Jan  9 2025, 00:00:00) [GCC 11.4.1 20230605 (Red Hat 11.4.1-2)] on
 linux
Type "help", "copyright", "credits" or "license" for more information.
Setting default log level to "WARN".
To adjust logging level use sc.setLogLevel(newLevel). For SparkR, use
 setLogLevel(newLevel).
Welcome to
      ____              __
     / __/__  ___ _____/ /__
    _\ \/ _ \/ _ `/ __/  '_/
   /__ / .__/\_,_/_/ /_/\_\   version 3.5.4-amzn-0
      /_/

Using Python version 3.11.6 (main, Jan  9 2025 00:00:00)
Spark context Web UI available at None
Spark context available as 'sc' (master = local[*], app id = local-1740643079929).
SparkSession available as 'spark'.
>>>
```

Con este intérprete de comandos de REPL, puede programar y probar de forma interactiva.

Pytest

Para las pruebas unitarias, puede utilizar `pytest` para scripts de trabajo Spark de AWS Glue. Ejecute los comandos siguientes para la preparación.

```
$ WORKSPACE_LOCATION=/local_path_to_workspace
$ SCRIPT_FILE_NAME=sample.py
$ UNIT_TEST_FILE_NAME=test_sample.py
$ mkdir -p ${WORKSPACE_LOCATION}/tests
$ vim ${WORKSPACE_LOCATION}/tests/${UNIT_TEST_FILE_NAME}
```

Ejecute el siguiente comando para ejecutar `pytest` mediante `docker run`:

```
$ docker run -i --rm \
    -v ~/.aws:/home/hadoop/.aws \
    -v $WORKSPACE_LOCATION:/home/hadoop/workspace/ \
    --workdir /home/hadoop/workspace \
    -e AWS_PROFILE=$PROFILE_NAME \
    --name glue5_pytest \
    public.ecr.aws/glue/aws-glue-libs:5 \
    -c "python3 -m pytest --disable-warnings"
```

Una vez que `pytest` termine de ejecutar las pruebas unitarias, el resultado tendrá un aspecto parecido al siguiente:

```
============================= test session starts ==============================
platform linux -- Python 3.11.6, pytest-8.3.4, pluggy-1.5.0
rootdir: /home/hadoop/workspace
plugins: integration-mark-0.2.0
collected 1 item

tests/test_sample.py .                                                   [100%]

======================== 1 passed, 1 warning in 34.28s =========================
```

Configuración del contenedor para utilizar Visual Studio Code

Para configurar el contenedor con Visual Studio Code, complete los siguientes pasos:

1. Instale Visual Studio Code.
2. Instalación de Python.

3. Instalar Visual Studio Code Remote: contenedores
4. Abra la carpeta de WorkSpace en Visual Studio Code.
5. Pulse `Ctrl+Shift+P` (Windows/Linux) o `Cmd+Shift+P` (Mac).
6. Tipo: `Preferences: Open Workspace Settings (JSON)`.
7. Pulse Intro.
8. Pegue el siguiente JSON y guárdelo.

```
{
    "python.defaultInterpreterPath": "/usr/bin/python3.11",
    "python.analysis.extraPaths": [
        "/usr/lib/spark/python/lib/py4j-0.10.9.7-src.zip:/usr/lib/spark/python/:/usr/
lib/spark/python/lib/",
    ]
}
```

Para configurar el contenedor:

1. Ejecute el contenedor Docker.

```
$ docker run -it --rm \
    -v ~/.aws:/home/hadoop/.aws \
    -v $WORKSPACE_LOCATION:/home/hadoop/workspace/ \
    -e AWS_PROFILE=$PROFILE_NAME \
    --name glue5_pyspark \
    public.ecr.aws/glue/aws-glue-libs:5 \
    pyspark
```

2. Inicie Visual Studio Code.
3. Elija Remote Explorer (Explorador remoto) en el menú de la izquierda y elija `amazon/aws-glue-libs:glue_libs_4.0.0_image_01`.
4. Haga clic con el botón derecho y elija Adjuntar en la ventana actual.

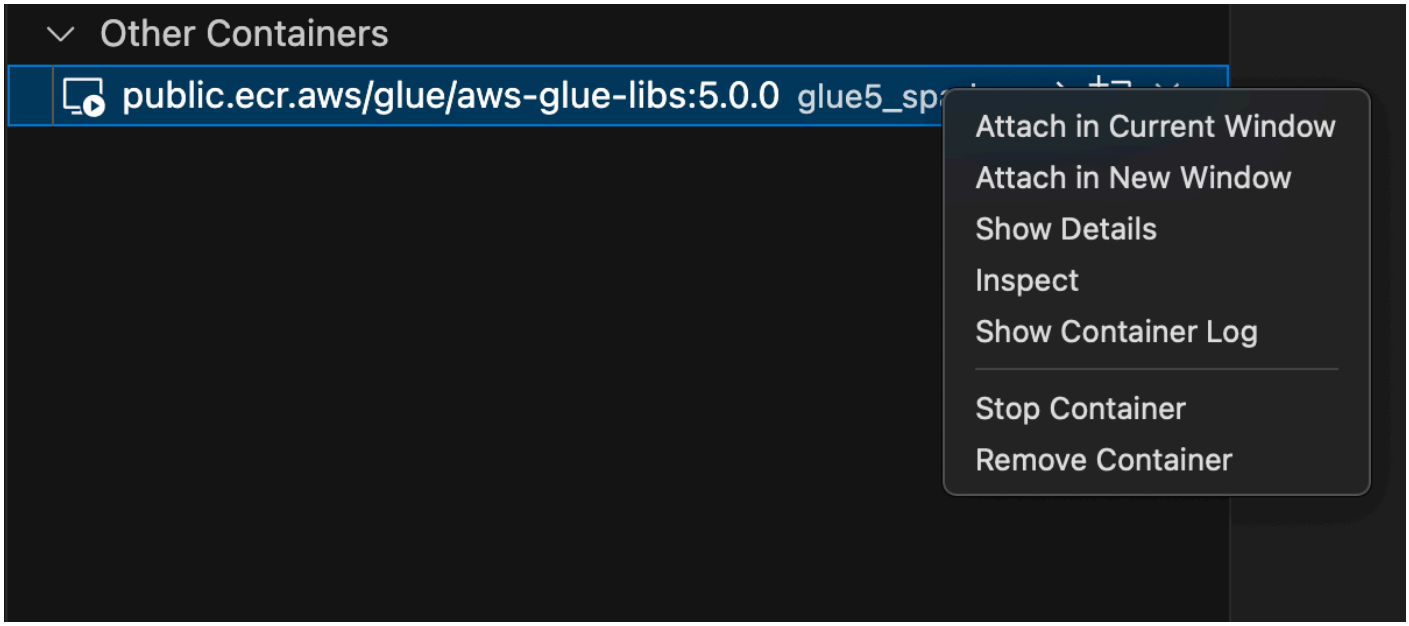

5. Si aparece el siguiente cuadro de diálogo, elija Entendido.

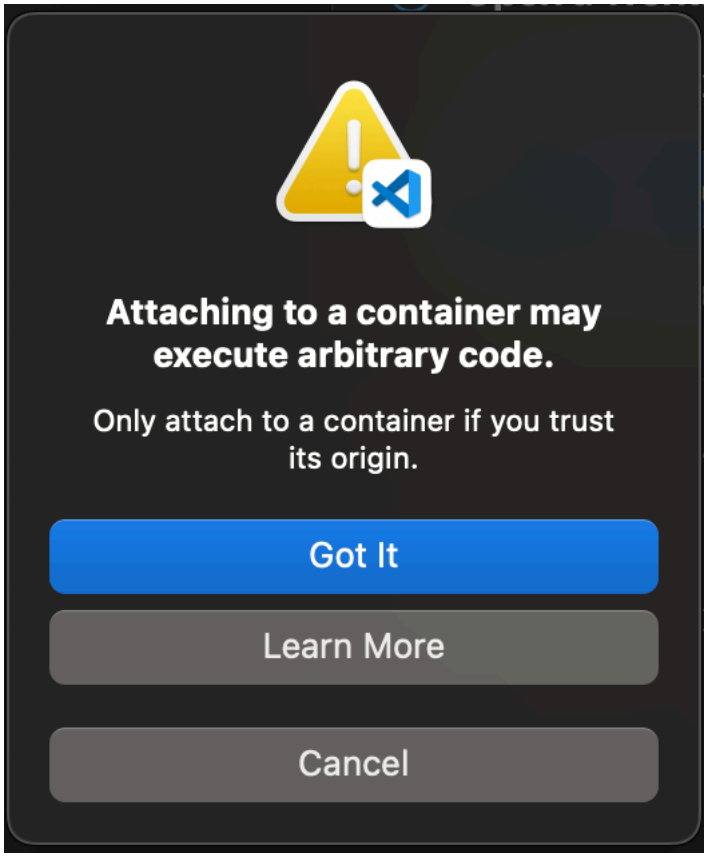

6. Abra . `/home/handoop/workspace/`.

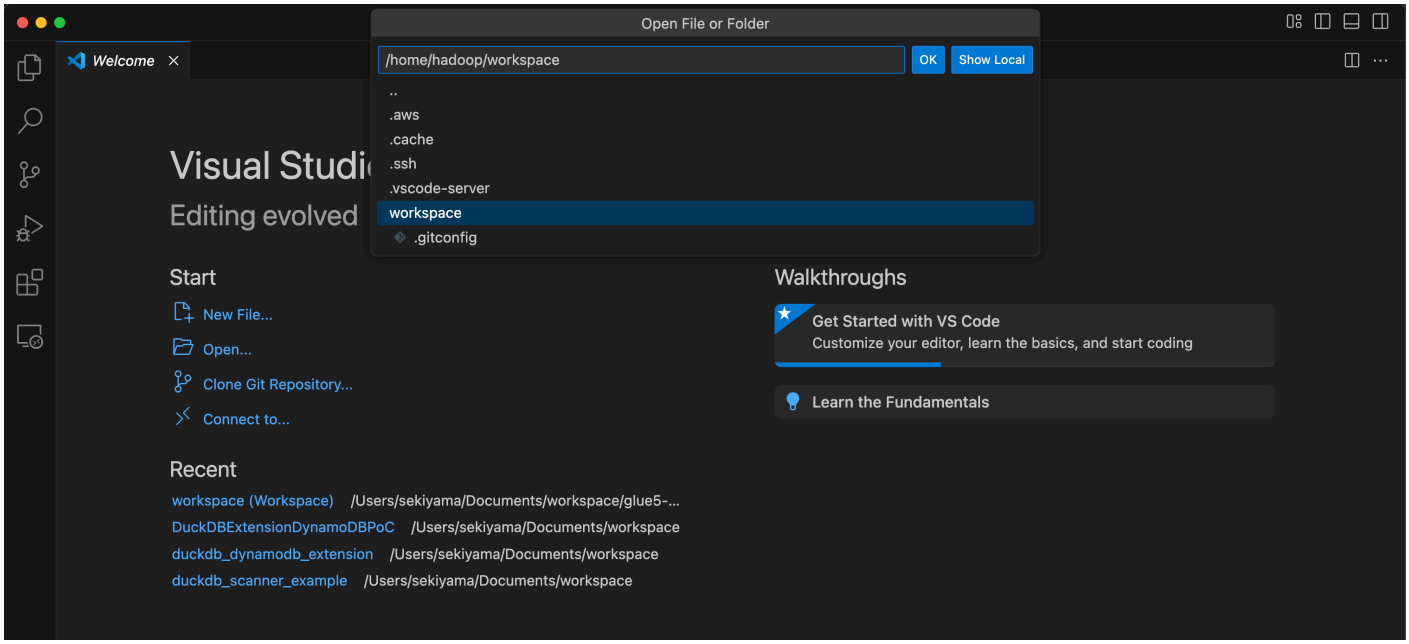

7. Cree un script de PySpark de AWS Glue y elija Ejecutar.

   Verá la ejecución correcta del script.

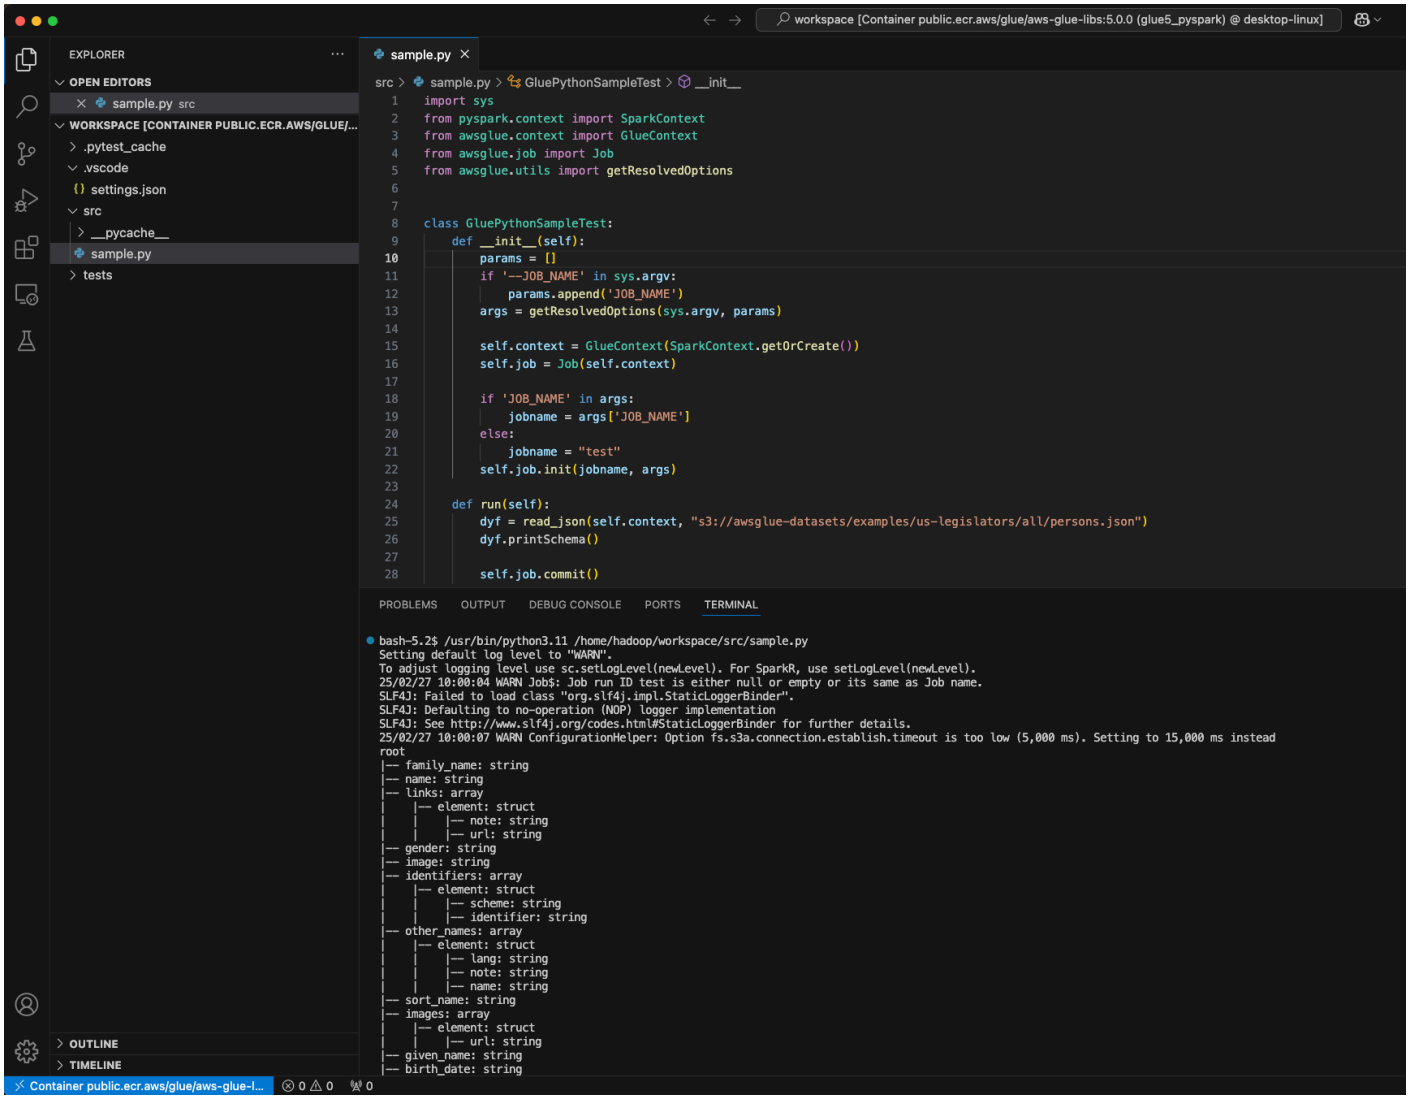

Cambios entre la imagen de Docker de AWS Glue 4.0 y de AWS Glue 5.0

Los principales cambios entre la imagen de Docker de AWS Glue 4.0 y de AWS Glue 5.0:

- En AWS Glue 5.0, hay una sola imagen de contenedor para los trabajos por lotes y los de streaming. Esto difiere de Glue 4.0, donde había una imagen para los trabajos por lotes y otra para los de streaming.
- En AWS Glue 5.0, el nombre de usuario predeterminado del contenedor es `hadoop`. En AWS Glue 4.0, el nombre de usuario predeterminado era `glue_user`.
- En AWS Glue 5.0, se han eliminado de la imagen varias bibliotecas adicionales, incluidas JupyterLab y Livy. Puede instalarlas manualmente.

- En la versión 5.0 de AWS Glue, todas las bibliotecas de Iceberg, Hudi y Delta vienen precargadas de forma predeterminada y la variable de entorno `DATALAKE_FORMATS` ya no es necesaria. Antes de la versión 4.0 de AWS Glue, la variable de entorno `DATALAKE_FORMATS` se utilizaba para especificar qué formatos de tabla específicos se debían cargar.

La lista anterior es específica de la imagen de Docker. Para obtener más información sobre las actualizaciones de la versión 5.0 de AWS Glue, consulte Introducción a la versión 5.0 de AWS Glue para Apache Spark y Migración de AWS Glue para trabajos de Spark a la versión 5.0 de AWS Glue.

Consideraciones

Tenga en cuenta que las siguientes funciones no se admiten cuando se utiliza la imagen del contenedor de AWS Glue para desarrollar scripts de trabajo de forma local.

- Marcadores de trabajo
- AWS GlueEscritora de parquet (utiliza el formato Parquet en AWS Glue)
- Transforma FillMissingValues
- Transformación FindMatches
- Lector CSV SIMD vectorizado
- La propiedad customJdbcDriverS3Path para cargar el controlador JDBC desde la ruta Amazon S3
- AWS Glue Calidad de datos de
- Detección de datos confidenciales
- Venta de credenciales basada en permisos de AWS Lake Formation

Anexo: Agregar controladores JDBC y bibliotecas Java

Para agregar un controlador JDBC que actualmente no está disponible en el contenedor, puede crear un nuevo directorio en su espacio de trabajo con los archivos JAR que necesite y montar el directorio en `/opt/spark/jars/` en el comando docker run. Los archivos JAR que se encuentran en `/opt/spark/jars/` dentro del contenedor se agregan automáticamente a Spark Classpath y estarán disponibles para su uso durante la ejecución del trabajo.

Por ejemplo, utilice el siguiente comando docker run para agregar los archivos jar del controlador JDBC al intérprete de comandos REPL de PySpark.

```
docker run -it --rm \
```

```
    -v ~/.aws:/home/hadoop/.aws \
    -v $WORKSPACE_LOCATION:/home/hadoop/workspace/ \
    -v $WORKSPACE_LOCATION/jars/:/opt/spark/jars/ \
    --workdir /home/hadoop/workspace \
    -e AWS_PROFILE=$PROFILE_NAME \
    --name glue5_jdbc \
    public.ecr.aws/glue/aws-glue-libs:5 \
    pyspark
```

Como se destaca en Consideraciones, la opción de conexión `customJdbcDriverS3Path` no se puede utilizar para importar un controlador JDBC personalizado desde Amazon S3 en imágenes de contenedores de AWS Glue.

Puntos de conexión de desarrollo

> **Note**
>
> La experiencia de consola para los puntos de conexión de desarrollo se eliminó a partir del 31 de marzo de 2023. La creación, actualización y supervisión de los puntos de conexión de desarrollo siguen estando disponibles a través de la API de puntos de conexión de desarrollo y de la CLI de AWS Glue.

Se recomienda migrar de los puntos de conexión de desarrollo a las sesiones interactivas por los motivos que se indican a continuación. Para conocer las acciones necesarias sobre cómo migrar de puntos de conexión de desarrollo a sesiones interactivas, consulte Migración de puntos de conexión de desarrollo a sesiones interactivas.

Descripción	Puntos de conexión de desarrollo	Sesiones interactivas
Compatibilidad de la versión de Glue	Compatible con las versiones 0.9 y 1.0 de AWS Glue	Compatible con las versiones 2.0 y posteriores de AWS Glue
Los puntos de conexión de desarrollo no están disponibl es en Asia-Pacífico (Yakarta)	Las sesiones interactivas no están disponibles actualmen te en la región Medio Oriente	

Descripción	Puntos de conexión de desarrollo	Sesiones interactivas
(`ap-southeast-3`), Medio Oriente (UAE) (`me-centra l-1`), Europa (España) (`eu-south-2`), Europa (Zúrich) (`eu-central-2`) ni en otras regiones nuevas que se establezcan en el futuro	(EAU) (`me-central-1`), pero es posible que estén disponibles más adelante.	
Método de acceso al clúster de Spark	Compatible con SSH, intérpret e de comandos de REPL, cuaderno de Jupyter, IDE (por ejemplo, PyCharm)	es compatible con el cuaderno de AWS Glue Studio, cuaderno de Jupyter, varios IDE (por ejemplo, Visual Studio Code, PyCharm) y cuaderno de IA de SageMaker
Tiempo de la primera consulta	Se necesitan entre 10 y 15 minutos para configurar un clúster de Spark	Puede tardar hasta 1 minuto en configurar un clúster de Spark efímero

Descripción	Puntos de conexión de desarrollo	Sesiones interactivas
Modelo de precios	AWS cobra por los puntos de conexión de desarrollo en función del momento en que se aprovisiona el punto de conexión y la cantidad de DPU. El tiempo de espera de los puntos de conexión de desarrollo no se agota. Hay una duración mínima de facturación de 10 minutos para cada punto de conexión de desarrollo aprovisionado. Además, AWS cobra por el cuaderno de Jupyter en instancias de Amazon EC2 y los cuadernos de IA de SageMaker cuando los configura con puntos de conexión de desarrollo.	AWS cobra por las sesiones interactivas en función del tiempo que la sesión está activa y de la cantidad de unidades de procesamiento de datos (DPU). Las sesiones interactivas tienen tiempos de inactividad configurables. Los cuadernos de AWS Glue Studio proporcionan una interfaz integrada para las sesiones interactivas y se ofrecen sin costo adicional . Hay una duración mínima de facturación de 1 minuto para cada sesión interactiva. Los cuadernos de AWS Glue Studio ofrecen una interfaz integrada para sesiones interactivas y se ofrecen sin costo adicional
Experiencia de consola	Solo está disponible a través de la CLI y la API	Disponible a través de la consola de AWS Glue, la CLI y las API

Migración de puntos de conexión de desarrollo a sesiones interactivas

Utilice la siguiente lista de comprobación para determinar el método adecuado para migrar de los puntos de conexión de desarrollo a las sesiones interactivas.

¿Su script depende de características específicas de la versión 0.9 o 1.0 de AWS Glue (por ejemplo, HDFS, YARN, etc.)?

Si la respuesta es sí, consulte Migrar trabajos de AWS Glue a la versión 3.0 de AWS Glue para obtener información sobre cómo migrar de Glue 0.9 o 1.0 a Glue 3.0 y versiones posteriores.

¿Qué método utiliza para acceder al punto de conexión de desarrollo?

Si utiliza este método	Haga esto
Cuaderno de IA de SageMaker, cuaderno de Jupyter o JupyterLab	Para migrar al cuaderno de AWS Glue Studio, descargue los archivos `.ipynb` en Jupyter y cree un nuevo trabajo de cuaderno de AWS Glue Studio mediante la carga del archivo `.ipynb`. También puede utilizar SageMaker AI Studio y seleccionar el kernel de AWS Glue.
Bloc de notas de Zeppelin	Para convertir el cuaderno en un cuaderno de Jupyter de forma manual, copie y pegue el código; para hacerlo de forma automática, utilice un conversor de terceros, como ze2nb. A continuación, utilice el cuaderno en el cuaderno de AWS Glue Studio o en SageMaker AI Studio.
IDE	Consulte Author AWS Glue jobs with PyCharm using AWS Glue interactive sessions o Uso de las sesiones interactivas con Microsoft Visual Studio Code.
REPL	Para instalar `aws-glue-session package` de manera local, ejecute el siguiente comando: • Para Python: `jupyter console --kernal glue_pyspark` • Para Scala: `jupyter console --kernal glue_spark`
SSH	No hay ninguna opción correspondiente en las sesiones interactivas. También puede utilizar una imagen de Docker. Para obtener más

Si utiliza este método	Haga esto
	información, consulte Desarrollo mediante una imagen de Docker.

En las siguientes secciones, se ofrece información sobre el uso de puntos de conexión de desarrollo para desarrollar trabajos en AWS Glue versión 1.0.

Temas

- Desarrollo de scripts usando puntos de conexión de desarrollo
- Administración de blocs de notas

Desarrollo de scripts usando puntos de conexión de desarrollo

> **Note**
>
> Los puntos de conexión de desarrollo solo son compatibles con versiones de AWS Glue anteriores a la 2.0. Si busca un entorno interactivo en el que pueda crear y probar scripts de ETL, utilice los Blocs de notas en AWS Glue Studio.

AWS Glue puede crear un entorno, conocido como punto de enlace de desarrollo, que puede utilizar para desarrollar y probar de forma iterativa los scripts de extracción, transformación y carga (ETL). Puede crear, editar y eliminar puntos de enlace de desarrollo mediante la consola o la API de AWS Glue.

Administración de su entorno de desarrollo

Al crear un punto de enlace de desarrollo, debe proporcionar valores de configuración para aprovisionar el entorno de desarrollo. Estos valores indican a AWS Glue cómo configurar la red para que pueda obtener acceso al punto de enlace de forma segura y que el punto de enlace pueda obtener acceso a sus almacenes de datos.

A continuación puede crear un bloc de notas que se conecte al punto de enlace y usar su bloc de notas para crear y probar su script ETL. Cuando esté satisfecho con los resultados de su proceso de desarrollo, podrá crear un flujo de trabajo de ETL que ejecute su script. Con este proceso, puede añadir funciones y depurar sus scripts de forma interactiva.

Siga los tutoriales de esta sección para aprender a utilizar su punto de enlace de desarrollo con blocs de notas.

Temas

- Flujo de trabajo de punto de conexión de desarrollo
- Cómo trabajan los puntos de conexión de desarrollo de AWS Glue con cuadernos de SageMaker
- Añadir un punto de conexión de desarrollo.
- Acceso al punto de conexión de desarrollo
- Tutorial: configuración de un cuaderno de Jupyter en JupyterLab para probar y depurar scripts ETL
- Tutorial: uso de un cuaderno de IA de SageMaker con su punto de conexión de desarrollo
- Tutorial: Utilice un REPL Shell con su punto de conexión de desarrollo
- Tutorial: Configuración de PyCharm Professional con un punto de conexión de desarrollo
- Configuración avanzada: uso compartido de puntos de conexión de desarrollo entre múltiples usuarios

Flujo de trabajo de punto de conexión de desarrollo

Para usar un punto de enlace de desarrollo de AWS Glue, puede seguir este flujo de flujo de trabajo.

1. Cree un punto de conexión de desarrollo mediante la API. El punto de enlace se lanza en una nube virtual privada (VPC) con sus grupos de seguridad definidos.
2. La API sondea el punto de conexión de desarrollo hasta que se aprovisione y esté listo para funcionar. Cuando esté listo, conéctese al punto de enlace de desarrollo utilizando uno de los siguientes métodos para crear y probar scripts AWS Glue.
   - Cree un cuaderno de IA de SageMaker en su cuenta. Para obtener más información acerca de cómo crear un blocs de notas, consulte the section called “Creación de código con cuadernos de AWS Glue Studio”.
   - Abra una ventana de terminal para conectarse directamente a un punto de enlace de desarrollo.
   - Si tiene la edición Professional del IDE de Python de PyCharm de JetBrains, conéctela a un punto de enlace de desarrollo y úsela para su desarrollo interactivo. Si inserta instrucciones `pydevd` en su script, PyCharm puede admitir puntos de interrupción remotos.
3. Cuando termine de depurar y realizar pruebas en su punto de enlace de desarrollo, puede eliminarlo.

Cómo trabajan los puntos de conexión de desarrollo de AWS Glue con cuadernos de SageMaker

Una de las formas comunes de acceder a sus puntos de enlace de desarrollo es usar Jupyter en los blocs de notas de SageMaker. El bloc de notas de Jupyter es una aplicación web de código abierto que se utiliza ampliamente en visualización, análisis, machine learning, etc. Un bloc de notas de SageMaker de AWS Glue le ofrece una experiencia de bloc de notas de Jupyter con puntos de enlace de desarrollo de AWS Glue. En el bloc de notas de SageMaker de AWS Glue, el entorno del bloc de notas de Jupyter está preconfigurado con SparkMagic, un complemento de Jupyter de código abierto para enviar trabajos de Spark a un clúster remoto de Spark. Apache Livy es un servicio que permite la interacción con un clúster de Spark remoto a través de una API REST. En el bloc de notas de SageMaker de AWS Glue, SparkMagic está configurado para invocar la API REST hacia un servidor Livy que se ejecuta en un punto de enlace de desarrollo de AWS Glue.

El siguiente flujo de texto explica cómo funciona cada componente:

Bloc de notas de SageMaker de AWS Glue: (Jupyter → SparkMagic) → (red) →punto de conexión de desarrollo de AWS Glue: (Apache Livy → Apache Spark)

Una vez que ejecute el script de Spark escrito en cada párrafo en un bloc de notas de Jupyter, el código de Spark se envía al servidor Livy a través de SparkMagic, luego se ejecuta un trabajo de Spark llamado “livy-session-n” en el clúster de Spark. Este trabajo se llama sesión de Livy. El trabajo de Spark se ejecutará mientras la sesión del bloc de notas esté activa. El trabajo de Spark finalizará cuando cierre el kernel de Jupyter desde el bloc de notas, o cuando se agote el tiempo de espera de la sesión. Se inicia un trabajo de Spark por archivo de bloc de notas (.ipynb).

Puede utilizar un único punto de enlace de desarrollo de AWS Glue con varias instancias de bloc de notas de SageMaker. Puede crear varios archivos de bloc de notas en cada instancia de bloc de notas de SageMaker. Al abrir un archivo de cada bloc de notas y ejecutar los párrafos, se inicia una sesión de Livy por archivo de bloc de notas en el clúster de Spark a través de SparkMagic. Cada sesión de Livy corresponde a un solo trabajo de Spark.

Comportamiento predeterminado de los puntos de conexión de desarrollo de AWS Glue y los cuadernos de SageMaker

Los trabajos de Spark se ejecutan en función de la configuración de Spark. Hay varias formas de establecer la configuración de Spark (por ejemplo, configuración de clúster de Spark, configuración de SparkMagic, etc.).

De forma predeterminada, Spark asigna recursos del clúster a una sesión de Livy en función de la configuración del clúster de Spark. En los puntos de desarrollo de AWS Glue, la configuración del clúster depende del tipo de empleado. A continuación, se incluye una tabla que explica las configuraciones comunes por tipo de empleado.

	Estándar	G.1 X	G.2 X
`spark.driver.memory`	5 G	10 G	20 G
`spark.executor.memory`	5 G	10 G	20 G
`spark.executor.cores`	4	8	16
`spark.dynamicAllocation.enabled`	TRUE	TRUE	TRUE

El número máximo de ejecutores de Spark se calcula automáticamente mediante una combinación de DPU (o `NumberOfWorkers`) y tipo de empleado.

	Estándar	G.1 X	G.2 X
Cantidad máxima de ejecutores de Spark	`(DPU - 1) * 2 - 1`	`(NumberOfWorkers - 1)`	`(NumberOfWorkers - 1)`

Por ejemplo, si el punto de enlace de desarrollo tiene 10 empleados y el tipo de empleado es `G.1X`, entonces tendrá 9 ejecutores de Spark y todo el clúster tendrá 90 G de memoria del ejecutor ya que cada ejecutor tendrá 10 G de memoria.

Independientemente del tipo de empleado especificado, se activará la asignación dinámica de recursos de Spark. Si un conjunto de datos es lo suficientemente grande, Spark puede asignar todos los ejecutores a una única sesión de Livy ya que `spark.dynamicAllocation.maxExecutors` no está configurado en forma predeterminada. Esto significa que otras sesiones de Livy en el mismo punto de enlace de desarrollo esperarán para lanzar nuevos ejecutores. Si el conjunto de datos es pequeño, Spark podrá asignar ejecutores a múltiples sesiones de Livy al mismo tiempo.

> **Note**
>
> Para obtener más información acerca de cómo se asignan los recursos en diferentes casos de uso y cómo se establece una configuración para modificar el comportamiento, consulte Configuración avanzada: uso compartido de puntos de conexión de desarrollo entre múltiples usuarios.

Añadir un punto de conexión de desarrollo.

Utilice puntos de enlace de desarrollo para desarrollar y probar iterativamente los scripts de extracción, transformación y carga (ETL) en AWS Glue. El trabajo con puntos de conexión de desarrollo solo está disponible a través de AWS Command Line Interface.

1. En una ventana de línea de comandos, escriba un comando similar al siguiente.

   ```
   aws glue create-dev-endpoint --endpoint-name "endpoint1" --role-arn
    "arn:aws:iam::account-id:role/role-name" --number-of-nodes "3" --glue-version
    "1.0" --arguments '{"GLUE_PYTHON_VERSION": "3"}' --region "region-name"
   ```

   Este comando especifica la versión de AWS Glue 1.0. Dado que esta versión es compatible con Python 2 y Python 3, puede utilizar el parámetro `arguments` para indicar la versión de Python deseada. Si se omite el parámetro `glue-version`, se presupone la versión de AWS Glue 0.9. Para obtener más información acerca de las versiones de AWS Glue, consulte Glue version job property.

   Para obtener información sobre parámetros de línea de comandos adicionales, consulte create-dev-endpoint en la Referencia de comandos de AWS CLI.

2. (Opcional) Escriba el siguiente comando para comprobar el estado del punto de enlace de desarrollo. Cuando el estado cambia a `READY`, el punto de enlace de desarrollo está listo para su uso.

```
aws glue get-dev-endpoint --endpoint-name "endpoint1"
```

Acceso al punto de conexión de desarrollo

Al crear un punto de enlace de desarrollo en una nube virtual privada (VPC), AWS Glue devuelve solo una dirección IP privada. El campo de dirección IP pública no se rellena. Al crear un punto de enlace de desarrollo que no pertenece a la VPC, AWS Glue devuelve solamente una dirección IP pública.

Si el punto de enlace de desarrollo tiene una dirección pública, confirme que es accesible con la clave privada SSH para el punto de enlace de desarrollo, como en el siguiente ejemplo.

```
ssh -i dev-endpoint-private-key.pem glue@public-address
```

Supongamos que el punto de enlace de desarrollo tiene una dirección privada, la subred de la VPC es direccionable desde la red pública de Internet y sus grupos de seguridad permiten el acceso de entrada desde el cliente. En este caso, siga estos pasos para adjuntar una dirección IP elástica a un punto de enlace de desarrollo para permitir el acceso desde Internet.

> **Note**
>
> Si desea utilizar direcciones IP elásticas, la subred que se está utilizando requiere una gateway de Internet asociada a través de la tabla de ruteo.

Obtener acceso a un punto de enlace de desarrollo adjuntando una dirección IP elástica

1. Abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. En el panel de navegación, elija Dev endpoints (Puntos de enlace de desarrollo), y vaya a la página de detalles del punto de enlace de desarrollo. Registre el valor de Private address (Dirección privada) para su uso en el siguiente paso.
3. Abra la consola de Amazon EC2 en https://console.aws.amazon.com/ec2/.

4. En el panel de navegación, en Network & Security (Red y seguridad), seleccione Network Interfaces (Interfaces de red).
5. Busque el valor de Private DNS (IPv4) (DNS privado, IPv4) que corresponde al valor de Private address (Dirección privada) en la página de detalles del punto de enlace de desarrollo de la consola de AWS Glue.

   Es posible que tenga que modificar las columnas que desea mostrar en su consola de Amazon EC2. Anote el valor de Network interface ID (ENI) (ID de interfaz de red) correspondiente a esta dirección (por ejemplo, `eni-12345678`.
6. En la consola de Amazon EC2, en Network & Security (Red y seguridad), elija Elastic IPs (Direcciones IP elásticas).
7. Elija Allocate new address (Asignar nueva dirección) y, a continuación, elija Allocate (Asignar) para asignar una nueva dirección IP elástica.
8. En la página Elastic IPs (IP elásticas), elija la nueva IP elástica asignada recientemente. A continuación, elija Actions (Acciones) y Associate address (Asociar dirección).
9. En la página Associate address (Asociar dirección), haga lo siguiente:

   - En Tipo de recurso, elija Interfaz de red.
   - En el campo Network interface (Interfaz de red), escriba el ID de interfaz de red (ENI) de la dirección privada.
   - Elija Asociar.
10. Confirme que la dirección IP elástica recién asociada es accesible con la clave privada SSH asociada al punto de enlace de desarrollo, como en el siguiente ejemplo.

    ```
    ssh -i dev-endpoint-private-key.pem glue@elastic-ip
    ```

    Para ver más información acerca de cómo utilizar un host bastión para obtener acceso de SSH a la dirección privada del punto de enlace de desarrollo, consulte la publicación del blog de seguridad de AWS Securely Connect to Linux Instances Running in a Private Amazon VPC (Conexión segura a instancias de Linux que se ejecutan en una VPC privada de Amazon).

Tutorial: configuración de un cuaderno de Jupyter en JupyterLab para probar y depurar scripts ETL

En este tutorial, se conecta un bloc de notas Jupyter en JupyterLab que se ejecuta en su máquina local a un punto de enlace de desarrollo. Esto se hace para poder ejecutar, depurar y probar de forma interactiva los scripts de ETL (extracción, transformación y carga) de AWS Glue antes de implementarlos. Este tutorial utiliza enrutamiento de puertos Secure Shell (SSH) para conectar su máquina local a un punto de enlace de desarrollo de AWS Glue. Para obtener más información, consulte Port forwarding (Enrutamiento de puertos) en Wikipedia.

Paso 1: instalar JupyterLab y Sparkmagic

Puede instalar JupyterLab con `conda` o `pip`. `conda` es un sistema de código abierto para la administración de paquetes y de entorno que se ejecuta en Windows, macOS y Linux. `pip` es el instalador del paquete para Python.

Si realizará la instalación en macOS, debe tener instalado Xcode para poder instalar Sparkmagic.

1. Instale JupyterLab, Sparkmagic y las extensiones relacionadas.

```
$ conda install -c conda-forge jupyterlab
$ pip install sparkmagic
$ jupyter nbextension enable --py --sys-prefix widgetsnbextension
$ jupyter labextension install @jupyter-widgets/jupyterlab-manager
```

2. Compruebe el directorio `sparkmagic` desde `Location`.

```
$ pip show sparkmagic | grep Location
Location: /Users/username/.pyenv/versions/anaconda3-5.3.1/lib/python3.7/site-
packages
```

3. Cambie su directorio al devuelto para `Location`, e instale los kernels para Scala y PySpark.

```
$ cd /Users/username/.pyenv/versions/anaconda3-5.3.1/lib/python3.7/site-packages
$ jupyter-kernelspec install sparkmagic/kernels/sparkkernel
$ jupyter-kernelspec install sparkmagic/kernels/pysparkkernel
```

4. Descargue un archivo `config` de prueba.

```
$ curl -o ~/.sparkmagic/config.json https://raw.githubusercontent.com/jupyter-
incubator/sparkmagic/master/sparkmagic/example_config.json
```

En este archivo de configuración, puede configurar los parámetros relacionados con Spark como `driverMemory` y `executorCores`.

Paso 2: inicie JupyterLab

Cuando inicia JupyterLab, su navegador web predeterminado se abre automáticamente y se muestra la URL `http://localhost:8888/lab/workspaces/{workspace_name}`.

```
$ jupyter lab
```

Paso 3: inicie el enrutamiento de puertos SSH para conectarse a su punto de conexión de desarrollo

A continuación, use el enrutamiento de puertos locales SSH para redireccionar un puerto local (aquí, 8998) al destino remoto definido por AWS Glue (`169.254.76.1:8998`).

1. Abra una ventana de terminal independiente que le proporcione acceso a SSH. En Microsoft Windows, puede usar el shell de BASH proporcionado por Git for Windows (Git para Windows) o instale Cygwin.
2. Ejecute el siguiente comando SSH, modificado de la siguiente manera:

   - Reemplace *`private-key-file-path`* por una ruta al archivo `.pem` que contiene la clave privada que se corresponde con la clave pública que usó para crear su punto de enlace de desarrollo.
   - Si redirecciona un puerto distinto de 8998, reemplace 8998 por el número de puerto que usa realmente de forma local. La dirección, `169.254.76.1:8998`, es el puerto remoto y no la modifica el usuario.
   - Reemplace *`dev-endpoint-public-dns`* por la dirección DNS pública de su punto de enlace de desarrollo. Para encontrar esta dirección, diríjase a su punto de enlace de desarrollo en la consola de AWS Glue, elija el nombre y copie la Public address (Dirección pública) que se enumera en la página Endpoint details (Detalles del punto de enlace).

   ```
   ssh -i private-key-file-path -NTL 8998:169.254.76.1:8998 glue@dev-endpoint-public-dns
   ```

   Lo más probable es que vea un mensaje de advertencia similar al siguiente:

```
The authenticity of host 'ec2-xx-xxx-xxx-xx.us-west-2.compute.amazonaws.com
 (xx.xxx.xxx.xx)'
can't be established.  ECDSA key fingerprint is SHA256:4e97875Brt+1wKzRko
+JflSnp21X7aTP3BcFnHYLEts.
Are you sure you want to continue connecting (yes/no)?
```

Ingrese **`yes`** y deje la ventana de terminal abierta mientras usa JupyterLab.

3. Compruebe que el enrutamiento de puertos SSH funciona correctamente con el punto de enlace de desarrollo.

```
$ curl localhost:8998/sessions
{"from":0,"total":0,"sessions":[]}
```

Paso 4: ejecute un fragmento de script sencillo en un párrafo del bloc de notas

Ahora su bloc de notas en JupyterLab debería funcionar con su punto de enlace de desarrollo. Escriba el siguiente fragmento de script en el bloc de notas y ejecútelo.

1. Compruebe que Spark se está ejecutando correctamente. El siguiente comando indica a Spark que calcule el 1 y luego imprima el valor.

```
spark.sql("select 1").show()
```

2. Compruebe si la integración AWS Glue Data Catalog está funcionando. En el siguiente comando se muestran las tablas del Catálogo de datos.

```
spark.sql("show tables").show()
```

3. Compruebe que un fragmento de script simple que use las bibliotecas de AWS Glue funcione.

   El script a continuación utiliza los metadatos de la tabla `persons_json` en AWS Glue Data Catalog para crear un `DynamicFrame` a partir de sus datos de ejemplo. A continuación, imprime el recuento de elementos y el esquema de estos datos.

```
import sys
from pyspark.context import SparkContext
from awsglue.context import GlueContext
```

```
# Create a Glue context
glueContext = GlueContext(SparkContext.getOrCreate())

# Create a DynamicFrame using the 'persons_json' table
persons_DyF = glueContext.create_dynamic_frame.from_catalog(database="legislators",
 table_name="persons_json")

# Print out information about *this* data
print("Count:  ", persons_DyF.count())
persons_DyF.printSchema()
```

La salida del script es la siguiente.

```
Count:  1961
root
|-- family_name: string
|-- name: string
|-- links: array
|    |-- element: struct
|    |    |-- note: string
|    |    |-- url: string
|-- gender: string
|-- image: string
|-- identifiers: array
|    |-- element: struct
|    |    |-- scheme: string
|    |    |-- identifier: string
|-- other_names: array
|    |-- element: struct
|    |    |-- note: string
|    |    |-- name: string
|    |    |-- lang: string
|-- sort_name: string
|-- images: array
|    |-- element: struct
|    |    |-- url: string
|-- given_name: string
|-- birth_date: string
|-- id: string
|-- contact_details: array
|    |-- element: struct
```

```
|    |    |-- type: string
|    |    |-- value: string
|-- death_date: string
```

Solución de problemas

- Durante la instalación de JupyterLab, si su equipo está detrás de un proxy corporativo o firewall, es posible que encuentre errores HTTP y SSL debido a perfiles de seguridad personalizados administrados por departamentos de TI corporativos.

  El siguiente es un ejemplo de un error típico que se produce cuando `conda` no puede conectarse a sus propios repositorios:

  ```
  CondaHTTPError: HTTP 000 CONNECTION FAILED for url <https://repo.anaconda.com/pkgs/
  main/win-64/current_repodata.json>
  ```

  Esto puede suceder porque su empresa puede bloquear conexiones a repositorios ampliamente utilizados en comunidades Python y JavaScript. Para obtener más información, consulte Installation Problems (Problemas de instalación) en la página web de JupyterLab.
- Si se encuentra ante un error de connection refused (conexión rechazada) al intentar conectar al punto de enlace de desarrollo, es posible que esté usando un punto de enlace de desarrollo que está desactualizado. Intente crear un nuevo punto de enlace de desarrollo y volver a conectarse.

Tutorial: uso de un cuaderno de IA de SageMaker con su punto de conexión de desarrollo

En AWS Glue, puede crear un punto de conexión de desarrollo y, a continuación, crear un cuaderno de IA de SageMaker para desarrollar sus scripts de machine learning y ETL. Un cuaderno de IA de SageMaker es una instancia de computación de machine learning completamente administrada que ejecuta la aplicación Cuaderno de Jupyter.

1. En la consola de AWS Glue, seleccione Puntos de enlace de desarrollo para ir a la lista de puntos de enlace de desarrollo.
2. Seleccione la casilla situada junto al nombre de un punto de enlace de desarrollo que desee utilizar y, en el menú Action (Acción), elija Create SageMaker notebook (Crear bloc de notas de SageMaker).

3. Rellene la página Create and configure a notebook (Crear y configurar un bloc de notas) como se indica a continuación:

   a. Escriba un nombre para el bloc de notas.

   b. En Attach to development endpoint (Asociar a un punto de enlace de desarrollo), verifique el punto de enlace de desarrollo.

   c. Elija crear un rol AWS Identity and Access Management (IAM).

      Se recomienda crear un rol. Si utiliza un rol existente, asegúrese de que tiene los permisos necesarios. Para obtener más información, consulte the section called “Paso 6: Crear una política de IAM para cuadernos de IA de SageMaker”.

   d. (Opcional) Elija una VPC, una subred y uno o varios grupos de seguridad.

   e. (Opcional) Elija una clave de cifrado de AWS Key Management Service.

   f. (Opcional) Añada etiquetas para la instancia de bloc de notas.

4. Elija Crear cuaderno. En la página Notebooks (Blocs de notas), elija el icono de actualización que aparece en la parte superior derecha y continúe hasta que el Status (Estado) aparezca como `Ready`.

5. Seleccione la casilla situada junto al nombre del bloc de notas nuevo y, a continuación, elija Open notebook (Abrir bloc de notas).

6. Cree un bloc de notas nuevo: en la página de jupyter, elija New (Nuevo) y, a continuación, seleccione Sparkmagic (PySpark).

   La pantalla que aparece debe ser similar a la siguiente:

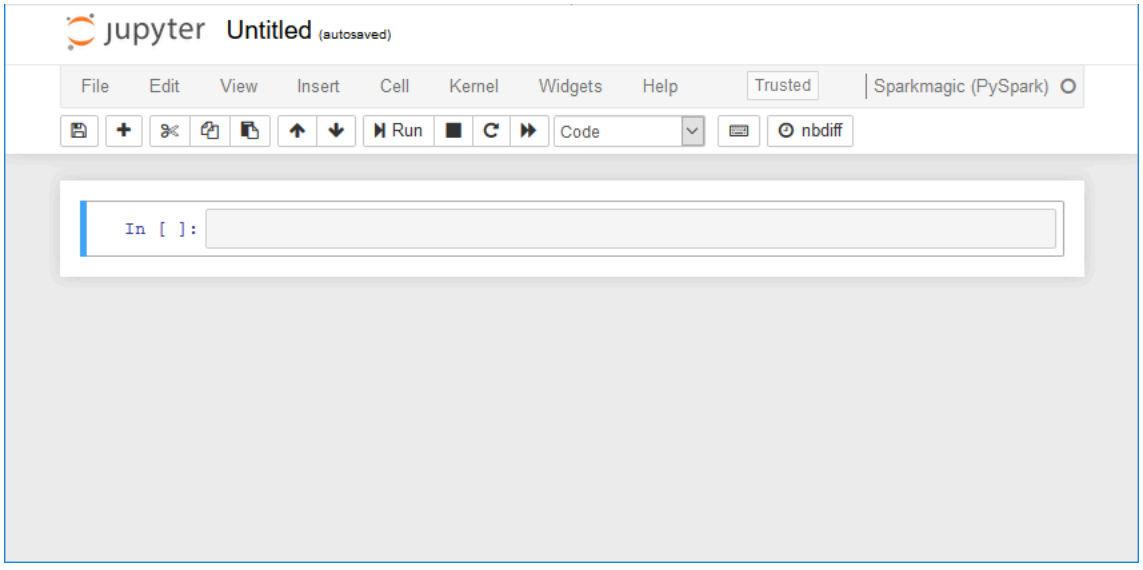

7. (Opcional) En la parte superior de la página, elija Untitled (Sin título) y asigne un nombre al bloc de notas.
8. Para iniciar una aplicación de Spark, escriba el comando siguiente en el bloc de notas y, a continuación, elija Run (Ejecutar) en la barra de herramientas.

```
spark
```

Después de un breve intervalo, debería ver la respuesta siguiente:

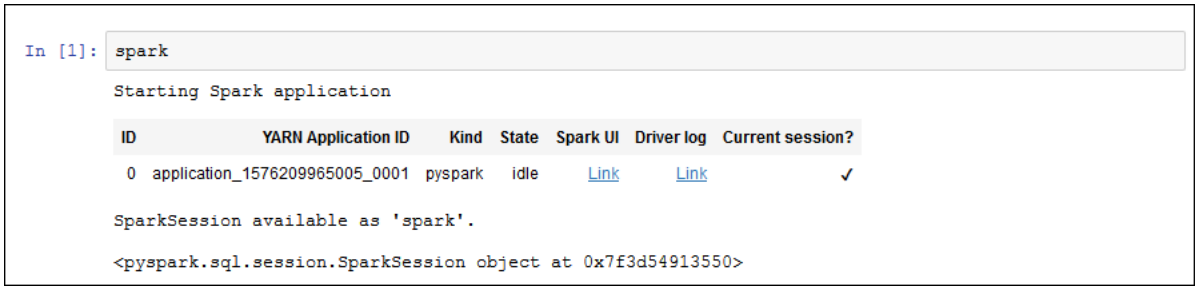

9. Cree un marco dinámico y ejecute una consulta en él: copie, pegue y ejecute el código siguiente, que genera el recuento y el esquema de la tabla `persons_json`.

```
import sys
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.transforms import *
glueContext = GlueContext(SparkContext.getOrCreate())
persons_DyF = glueContext.create_dynamic_frame.from_catalog(database="legislators",
 table_name="persons_json")
print ("Count:  ", persons_DyF.count())
persons_DyF.printSchema()
```

Tutorial: Utilice un REPL Shell con su punto de conexión de desarrollo

En AWS Glue puede crear un punto de enlace de desarrollo y, a continuación, invocar un shell REPL (bucle de lectura, evaluación e impresión) para ejecutar código de PySpark gradualmente para depurar interactivamente sus scripts de ETL antes de implementarlos.

Para usar un REPL en un punto de conexión de desarrollo, necesita tener autorización para usar SSH en el punto de conexión.

1. En el equipo local, abra una ventana de terminal que pueda ejecutar comandos SSH y pegue en ella el comando SSH editado. Ejecute el comando .

Suponiendo que aceptara la versión de AWS Glue 1.0 con Python 3 para el punto de conexión de desarrollo, el resultado será similar al siguiente:

```
Python 3.6.8 (default, Aug  2 2019, 17:42:44)
[GCC 4.8.5 20150623 (Red Hat 4.8.5-28)] on linux
Type "help", "copyright", "credits" or "license" for more information.
SLF4J: Class path contains multiple SLF4J bindings.
SLF4J: Found binding in [jar:file:/usr/share/aws/glue/etl/jars/glue-assembly.jar!/
org/slf4j/impl/StaticLoggerBinder.class]
SLF4J: Found binding in [jar:file:/usr/lib/spark/jars/slf4j-log4j12-1.7.16.jar!/
org/slf4j/impl/StaticLoggerBinder.class]
SLF4J: See http://www.slf4j.org/codes.html#multiple_bindings for an explanation.
SLF4J: Actual binding is of type [org.slf4j.impl.Log4jLoggerFactory]
Setting default log level to "WARN".
To adjust logging level use sc.setLogLevel(newLevel). For SparkR, use
 setLogLevel(newLevel).
2019-09-23 22:12:23,071 WARN  [Thread-5] yarn.Client (Logging.scala:logWarning(66))
 - Neither spark.yarn.jars nor spark.yarn.archive is set, falling back to uploading
 libraries under SPARK_HOME.
2019-09-23 22:12:26,562 WARN  [Thread-5] yarn.Client (Logging.scala:logWarning(66))
 - Same name resource file:/usr/lib/spark/python/lib/pyspark.zip added multiple
 times to distributed cache
2019-09-23 22:12:26,580 WARN  [Thread-5] yarn.Client (Logging.scala:logWarning(66))
 - Same path resource file:///usr/share/aws/glue/etl/python/PyGlue.zip added
 multiple times to distributed cache.
2019-09-23 22:12:26,581 WARN  [Thread-5] yarn.Client (Logging.scala:logWarning(66))
 - Same path resource file:///usr/lib/spark/python/lib/py4j-src.zip added multiple
 times to distributed cache.
2019-09-23 22:12:26,581 WARN  [Thread-5] yarn.Client (Logging.scala:logWarning(66))
 - Same path resource file:///usr/share/aws/glue/libs/pyspark.zip added multiple
 times to distributed cache.
Welcome to
      ____              __
     / __/__  ___ _____/ /__
    _\ \/ _ \/ _ `/ __/  '_/
   /__ / .__/\_,_/_/ /_/\_\   version 2.4.3
      /_/

Using Python version 3.6.8 (default, Aug  2 2019 17:42:44)
SparkSession available as 'spark'.
>>>
```

2. Compruebe que el shell REPL funcione correctamente escribiendo la instrucción `print(spark.version)`. Mientras esto muestre la versión de Spark, su REPL estará listo para su uso.
3. Ahora puede intentar ejecutar el siguiente script, que es sencillo, línea por línea, en el shell:

```
import sys
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.transforms import *
glueContext = GlueContext(SparkContext.getOrCreate())
persons_DyF = glueContext.create_dynamic_frame.from_catalog(database="legislators",
 table_name="persons_json")
print ("Count:  ", persons_DyF.count())
persons_DyF.printSchema()
```

Tutorial: Configuración de PyCharm Professional con un punto de conexión de desarrollo

En este tutorial, comprobará cómo conectar el IDE de Python PyCharm Professional que se ejecuta en su equipo local a un punto de enlace de desarrollo para que pueda ejecutar, depurar y probar de forma interactiva scripts de ETL (extraer, transferir y cargar) de AWS Glue antes de implementarlos. Las instrucciones y las capturas de pantalla del tutorial se basan en PyCharm Professional versión 2019.3.

Para conectarse a un punto de enlace de desarrollo de forma interactiva, debe haber instalado PyCharm Professional. Esto no podrá efectuarse con la edición gratuita.

> **Note**
>
> El tutorial utiliza Amazon S3 como origen de datos. Si desea utilizar un origen de datos JDBC en su lugar, debe ejecutar el punto de enlace de desarrollo en una nube virtual privada (VPC). Para conectarse con SSH a un punto de enlace de desarrollo en una instancia de VPC, debe crear un túnel SSH. Este tutorial no incluye instrucciones para crear túneles SSH. Para obtener información sobre el uso de SSH para conectarse a un punto de enlace de desarrollo en una VPC, consulte Securely Connect to Linux Instances Running in a Private Amazon VPC (Conexión segura a instancias de Linux que se ejecutan en una instancia de Amazon VPC privada) en el blog de seguridad de AWS.

Temas

- Conexión de PyCharm Professional a un punto de conexión de desarrollo
- Implementación del script en el punto de conexión de desarrollo
- Configuración de un intérprete remoto
- Ejecución del script en el punto de conexión de desarrollo

Conexión de PyCharm Professional a un punto de conexión de desarrollo

1. Cree un nuevo proyecto de Python puro en PyCharm y llámelo `legislators`.
2. Cree un archivo denominado `get_person_schema.py` en el proyecto con el siguiente contenido:

```
from pyspark.context import SparkContext
from awsglue.context import GlueContext


def main():
    # Create a Glue context
    glueContext = GlueContext(SparkContext.getOrCreate())

    # Create a DynamicFrame using the 'persons_json' table
    persons_DyF =
 glueContext.create_dynamic_frame.from_catalog(database="legislators",
 table_name="persons_json")

    # Print out information about this data
    print("Count:  ", persons_DyF.count())
    persons_DyF.printSchema()


if __name__ == "__main__":
    main()
```

3. Realice una de las siguientes acciones:

   - Para la versión 0.9 de AWS Glue, descargue el archivo de la biblioteca de Python de `PyGlue.zip`, AWS Glue, desde `https://s3.amazonaws.com/aws-glue-jes-prod-us-east-1-assets/etl/python/PyGlue.zip` en la ubicación que prefiera de su equipo local.

- Para la versión 1.0 y posteriores de AWS Glue, descargue el archivo de la biblioteca de Python de AWS Glue, `PyGlue.zip`, desde `https://s3.amazonaws.com/aws-glue-jes-prod-us-east-1-assets/etl-1.0/python/PyGlue.zip` en la ubicación que prefiera de su equipo local.

4. Añada `PyGlue.zip` como raíz de contenido para el proyecto en PyCharm:

   - En PyCharm, seleccione File (Archivo) y Settings (Configuración) para abrir el cuadro de diálogo Settings (Configuración). (También puede pulsar `Ctrl+Alt+S`.)
   - Amplíe el proyecto `legislators` y seleccione Project Structure (Estructura del proyecto). A continuación, en el panel derecho, seleccione + Add Content Root (+ Añadir raíz de contenido).
   - Vaya a la ubicación donde guardó `PyGlue.zip`, selecciónelo y, a continuación, seleccione Apply (Aplicar).

   La pantalla Settings (Configuración) debe asemejarse a la siguiente:

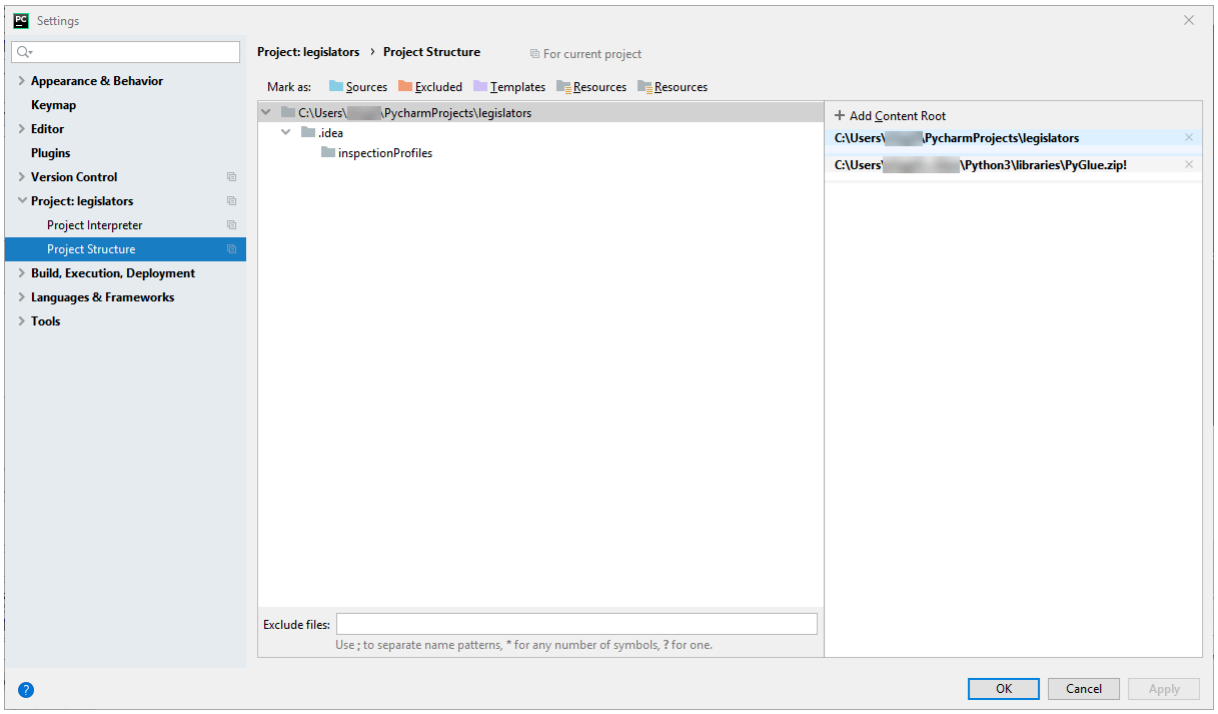

   Deje abierto el cuadro de diálogo Settings (Configuración) después de seleccionar Apply (Aplicar).

5. Configure las opciones de implementación para cargar el script local en el punto de enlace de desarrollo con SFTP (esta función solo está disponible en PyCharm Professional):

- En el cuadro de diálogo Settings (Configuración), expanda la sección Build, Execution, Deployment (Generación, ejecución, implementación). Seleccione la subsección Deployment (Implementación).
- Seleccione el icono + en la parte superior del panel central para añadir un nuevo servidor. Establezca Type (Tipo) en `SFTP` y asígnele un nombre.
- Establezca el SFTP host (Host SFTP) en la opción de Public address (Dirección pública) de su punto de enlace de desarrollo, tal y como aparece en la página de detalles. (Elija el nombre del punto de enlace de desarrollo en la consola de AWS Glue para mostrar la página de detalles). Para un punto de enlace de desarrollo que se ejecuta en una instancia de VPC, establezca el valor de SFTP host (Host SFTP) en la dirección del host y el puerto local del túnel SSH en el punto de enlace de desarrollo.
- Establezca User name (Nombre de usuario) en `glue`.
- Establezca Auth type (Tipo de autenticación) en Key pair (OpenSSH or Putty) (Par de claves (OpenSSH o Putty)). Defina Private key file (Archivo de clave privada); para ello, vaya a la ubicación donde se encuentra el archivo de clave privada del punto de enlace de desarrollo. Tenga en cuenta que PyCharm solo es compatible con los tipos de claves DSA, RSA y ECDSA OpenSSH y no acepta claves en formato privado de Putty. Puede utilizar una versión actualizada de `ssh-keygen` para generar un tipo de par de claves que acepte PyCharm, usando una sintaxis como la siguiente:

  ```
  ssh-keygen -t rsa -f <key_file_name> -C "<your_email_address>"
  ```

- Seleccione Test connection (Probar conexión) y pruebe la conexión. Si la conexión se realiza correctamente, seleccione Apply (Aplicar).

La pantalla Configuración debe asemejarse ahora a la siguiente:

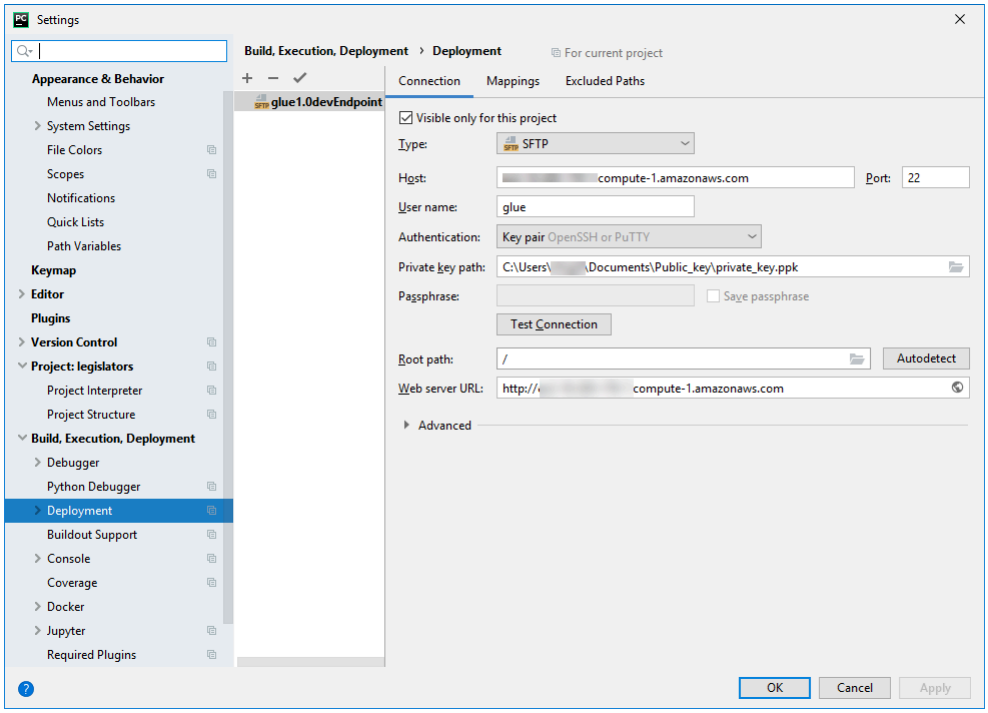

De nuevo, deje abierto el cuadro de diálogo Settings (Configuración) después de seleccionar Apply (Aplicar).

6. Asigne el directorio local a un directorio remoto para la implementación:

   - En el panel derecho de la página Deployment (Implementación), seleccione la pestaña central en la parte superior denominada Mappings (Mapeos).
   - En la columna Deployment Path (Ruta de la implementación), escriba una ruta en `/home/glue/scripts/` para la implementación de la ruta de su proyecto. Por ejemplo: `/home/glue/scripts/legislators`.
   - Seleccione Aplicar.

   La pantalla Configuración debe asemejarse ahora a la siguiente:

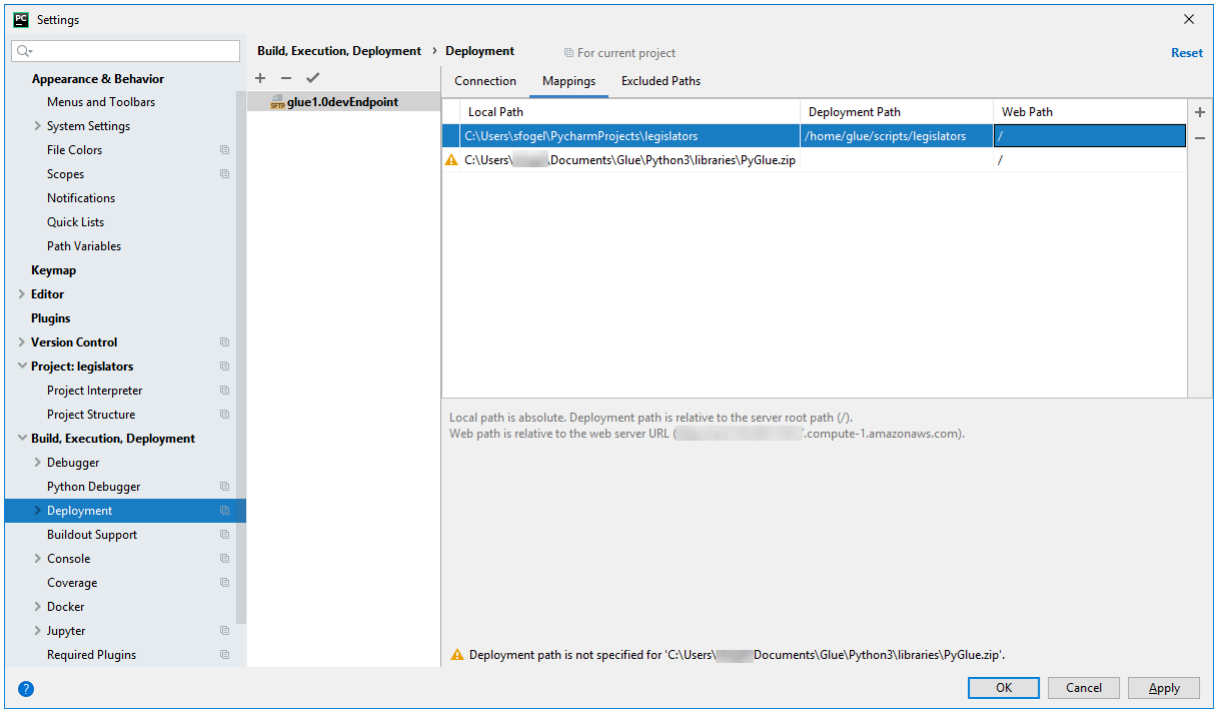

Seleccione OK (Aceptar) para cerrar el cuadro de diálogo Settings (Configuración).

Implementación del script en el punto de conexión de desarrollo

1. Elija Tools (Herramientas), Deployment (Implementación) y, a continuación, seleccione el nombre con el que ha configurado el punto de enlace de desarrollo, tal como se muestra en la imagen siguiente:

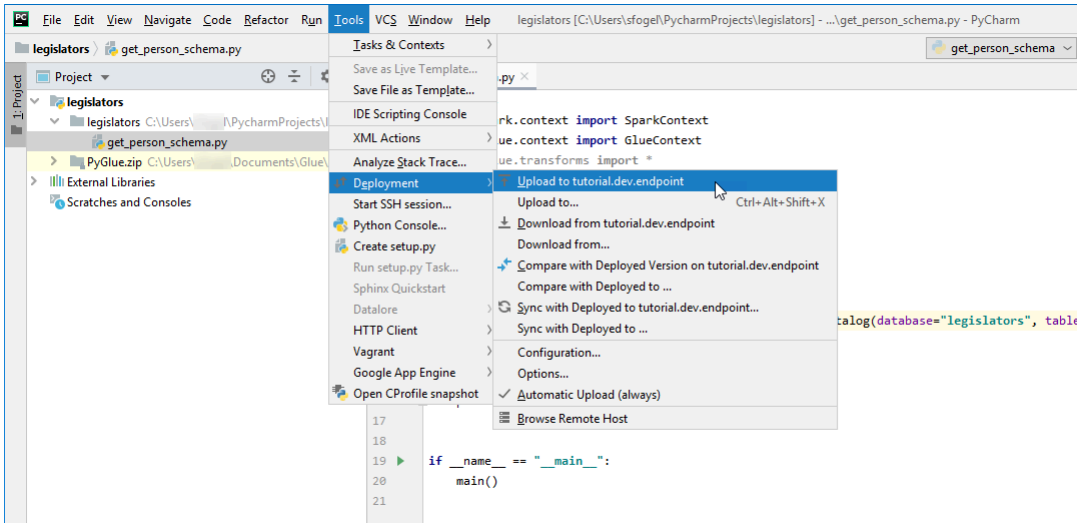

Después de implementar el script, la parte inferior de la pantalla tendrá un aspecto similar al siguiente:

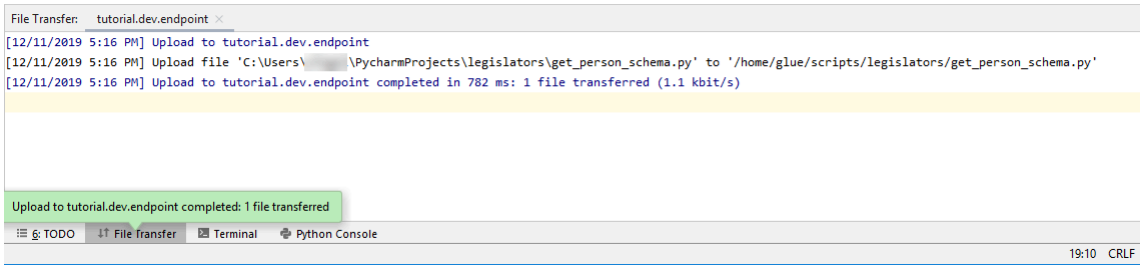

2. En la barra de menús, elija Tools (Herramientas), Deployment (Implementación), Automatic Upload (always) [Carga automática (siempre)]. Asegúrese de que aparezca una marca de verificación junto a Automatic Upload (always) [Carga automática (siempre)].

   Cuando esta opción está habilitada, PyCharm carga automáticamente los archivos modificados en el punto de enlace de desarrollo.

Configuración de un intérprete remoto

Configure PyCharm para utilizar el intérprete de Python en el punto de enlace de desarrollo.

1. En el menú File (Archivo), elija Settings (Configuración).
2. Expanda los legisladores del proyecto y elija Project Interpreter (Intérprete del proyecto).
3. Elija el icono de engranaje situado junto a la lista de Project Interpreter (Intérprete del proyecto) y, a continuación, elija Add (Agregar).
4. En el cuadro de diálogo Add Python Interpreter (Agregar intérprete de Python), en el panel izquierdo, elija SSH Interpreter (Intérprete de SSH).
5. Elija Existing server configuration (Configuración del servidor existente) y, en la lista Deployment configuration (Configuración de implementación), seleccione la configuración.

   La pantalla tendrá un aspecto similar a la imagen siguiente:

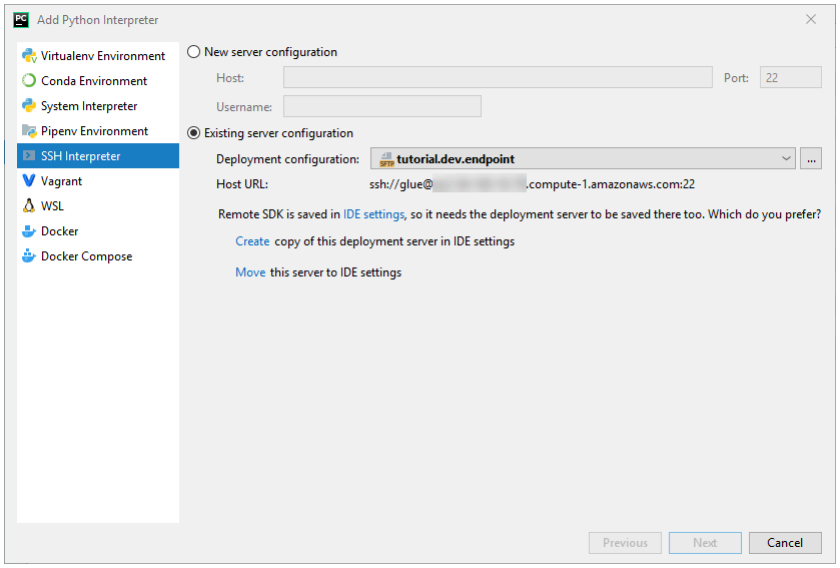

6. Elija Move this server to IDE settings (Mover este servidor a la configuración de IDE), y, a continuación, elija Next (Siguiente).
7. En el campo Interpreter (Intérprete), cambie la ruta a `/usr/bin/gluepython` si está utilizando Python 2 o a `/usr/bin/gluepython3` si está utilizando Python 3. A continuación, elija Finalizar.

Ejecución del script en el punto de conexión de desarrollo

Para ejecutar el script:

- En el panel izquierdo, haga clic con el botón derecho en el nombre del archivo y elija Run (Ejecutar) "***<nombreArchivo>***".

  Después de una serie de mensajes, la salida final debe mostrar el recuento y el esquema.

```
Count:  1961
root
|-- family_name: string
|-- name: string
|-- links: array
|    |-- element: struct
|    |    |-- note: string
|    |    |-- url: string
|-- gender: string
|-- image: string
|-- identifiers: array
|    |-- element: struct
```

```
|    |    |-- scheme: string
|    |    |-- identifier: string
|-- other_names: array
|    |-- element: struct
|    |    |-- lang: string
|    |    |-- note: string
|    |    |-- name: string
|-- sort_name: string
|-- images: array
|    |-- element: struct
|    |    |-- url: string
|-- given_name: string
|-- birth_date: string
|-- id: string
|-- contact_details: array
|    |-- element: struct
|    |    |-- type: string
|    |    |-- value: string
|-- death_date: string


Process finished with exit code 0
```

Ya ha terminado la configuración para depurar el script de forma remota en el punto de enlace de desarrollo.

Configuración avanzada: uso compartido de puntos de conexión de desarrollo entre múltiples usuarios

En esta sección se explica cómo puede aprovechar los puntos de desarrollo con los blocs de notas de SageMaker en casos de uso habituales para compartir puntos de enlace de desarrollo entre múltiples usuarios.

Configuración de tenencia única

En casos de uso de tenencia única, a fin de simplificar la experiencia del desarrollador y evitar la contención de recursos, se recomienda que cada desarrollador use su propio punto de enlace de desarrollo dimensionado para el proyecto en el que está trabajando. Esto también simplifica las decisiones relacionadas con el tipo de empleado y el recuento de DPU y las deja a discreción del desarrollador y según el proyecto en el que están trabajando.

No tendrá que ocuparse de la asignación de recursos a menos que ejecute múltiples archivos de bloc de notas en forma concurrente. Si ejecuta código en varios archivos de bloc de notas al mismo tiempo, se iniciarán múltiples sesiones de Livy en forma concurrente. Para segregar las configuraciones del clúster de Spark con el fin de ejecutar múltiples sesiones de Livy al mismo tiempo, puede seguir los pasos que se presentan en los casos de uso de multiinquilinos.

Por ejemplo, si el punto de enlace de desarrollo tiene 10 empleados y el tipo de empleado es `G.1X`, entonces tendrá 9 ejecutores de Spark y todo el clúster tendrá 90 G de memoria del ejecutor ya que cada ejecutor tendrá 10 G de memoria.

Independientemente del tipo de empleado especificado, se activará la asignación dinámica de recursos de Spark. Si un conjunto de datos es lo suficientemente grande, Spark puede asignar todos los ejecutores a una única sesión de Livy ya que `spark.dynamicAllocation.maxExecutors` no está configurado en forma predeterminada. Esto significa que otras sesiones de Livy en el mismo punto de enlace de desarrollo esperarán para lanzar nuevos ejecutores. Si el conjunto de datos es pequeño, Spark podrá asignar ejecutores a múltiples sesiones de Livy al mismo tiempo.

> **Note**
>
> Para obtener más información acerca de cómo se asignan los recursos en diferentes casos de uso y cómo se establece una configuración para modificar el comportamiento, consulte Configuración avanzada: uso compartido de puntos de conexión de desarrollo entre múltiples usuarios.

Configuración de multiinquilinos

> **Note**
>
> Tenga en cuenta que los puntos de enlace de desarrollo están destinados a emular el entorno ETL de AWS Glue como un entorno de tenencia única. Si bien el uso de multiinquilinos es posible, es un caso de uso avanzado y se recomienda que la mayoría de los usuarios mantengan un patrón de tenencia única para cada punto de enlace de desarrollo.

En casos de uso de multiinquilinos, es posible que tenga que ocuparse de la asignación de recursos. El factor clave es el número de usuarios concurrentes que usan un bloc de notas Jupyter al mismo

tiempo. Si su equipo trabaja en un flujo de trabajo de “seguir el sol” y solo hay un usuario de Jupyter en cada zona horaria, entonces el número de usuarios concurrentes es solo uno, por lo que no tendrá que preocuparse por la asignación de recursos. Sin embargo, si su bloc de notas se comparte entre varios usuarios y cada usuario envía código de forma ad-hoc, tendrá que considerar los siguientes puntos.

Para particionar los recursos del clúster de Spark entre varios usuarios, puede usar configuraciones de SparkMagic. Existen dos formas diferentes de configurar SparkMagic.

(A) Use la directiva %%configure -f

Si desea modificar la configuración por cada sesión de Livy desde el bloc de notas, puede ejecutar la directiva `%%configure -f` en el párrafo del bloc de notas.

Por ejemplo, si desea ejecutar la aplicación Spark en 5 ejecutores, puede ejecutar el siguiente comando en el párrafo del bloc de notas.

```
%%configure -f
{"numExecutors":5}
```

Luego verá solo 5 ejecutores ejecutándose para el trabajo en la interfaz de usuario de Spark.

Recomendamos limitar el número máximo de ejecutores para la asignación dinámica de recursos.

```
%%configure -f
{"conf":{"spark.dynamicAllocation.maxExecutors":"5"}}
```

(B) Modificar el archivo de configuración de SparkMagic

SparkMagic funciona con base en la API de Livy. SparkMagic crea sesiones de Livy con configuraciones como `driverMemory`, `driverCores`, `executorMemory`, `executorCores`, `numExecutors`, `conf`, etc. Estos son los factores clave que determinan la cantidad de recursos que se consumen de todo el clúster de Spark. SparkMagic le permite proporcionar un archivo de configuración para especificar los parámetros que se envían a Livy. Puede ver un archivo de configuración de ejemplo en este Repositorio GitHub.

Si desea modificar la configuración en todas las sesiones de Livy desde un bloc de notas, puede modificar `/home/ec2-user/.sparkmagic/config.json` para agregar `session_config`.

Para modificar el archivo de configuración en una instancia de bloc de notas de SageMaker, puede seguir estos pasos.

1. Abra un bloc de notas de SageMaker.
2. Abra el kernel del terminal.
3. Ejecute los siguientes comandos :

```
sh-4.2$ cd .sparkmagic
sh-4.2$ ls
config.json logs
sh-4.2$ sudo vim config.json
```

Por ejemplo, puede agregar estas líneas a `/home/ec2-user/.sparkmagic/config.json` y reiniciar el kernel de Jupyter desde el bloc de notas.

```
  "session_configs": {
    "conf": {
      "spark.dynamicAllocation.maxExecutors":"5"
    }
  },
```

Directrices y prácticas recomendadas

Para evitar este tipo de conflicto de recursos, puede usar algunos enfoques básicos como por ejemplo:

- Tener un clúster de Spark más grande al aumentar el `NumberOfWorkers` (escalar horizontalmente) y actualizar el `workerType` (escalar verticalmente)
- Asignar menos recursos por usuario (menos recursos por sesión de Livy)

Su enfoque dependerá del caso de uso. Si tiene un punto de enlace de desarrollo más grande y no hay una gran cantidad de datos, la posibilidad de un conflicto de recursos disminuirá significativamente porque Spark puede asignar recursos en función de una estrategia de asignación dinámica.

Como se describió con anterioridad, el número de ejecutores de Spark puede calcularse automáticamente con base en una combinación de DPU (o `NumberOfWorkers`) y tipo de empleado. Cada aplicación Spark lanza un controlador y varios ejecutores. Para calcular necesitará `NumberOfWorkers` = `NumberOfExecutors + 1`. La siguiente matriz explica cuánta capacidad necesita en su punto de enlace de desarrollo en función del número de usuarios concurrentes.

Número de usuarios concurrentes del bloc de notas	Número de ejecutores de Spark que desea asignar por usuario	Número total de empleados para su punto de enlace de desarrollo
3	5	18
10	5	60
50	5	300

Si desea asignar menos recursos por usuario, `spark.dynamicAllocation.maxExecutors` (o `numExecutors`) sería el parámetro más fácil de configurar como parámetro de sesión de Livy. Si establece la siguiente configuración en `/home/ec2-user/.sparkmagic/config.json`, entonces SparkMagic asignará un máximo de 5 ejecutores por sesión de Livy. Esto ayudará a segregar recursos por sesión de Livy.

```
"session_configs": {
    "conf": {
      "spark.dynamicAllocation.maxExecutors":"5"
    }
  },
```

Supongamos que hay un punto de enlace de desarrollo con 18 empleados (G-1 X) y que hay tres usuarios de bloc de notas concurrentes. Si la configuración de su sesión tiene `spark.dynamicAllocation.maxExecutors=5` entonces cada usuario puede hacer uso de un controlador y cinco ejecutores. No habrá ningún conflicto de recursos incluso cuando ejecute varios párrafos de bloc de notas al mismo tiempo.

Compensación

Con esta configuración de sesión `"spark.dynamicAllocation.maxExecutors":"5"`, podrá evitar errores de conflictos de recursos y no necesitará esperar a la asignación de recursos cuando haya accesos de usuario concurrentes. Sin embargo, incluso cuando haya muchos recursos libres (por ejemplo, no hay otros usuarios concurrentes), Spark no puede asignar más de 5 ejecutores para su sesión de Livy.

Otras notas

Es una buena práctica detener el kernel de Jupyter cuando deje de usar un bloc de notas. Esto liberará recursos y otros usuarios de bloc de notas podrán usar esos recursos inmediatamente sin esperar al vencimiento del kernel (apagado automático).

Problemas comunes

Es posible que experimentes ciertos problemas, aún cuando siga las pautas.

No se encuentra la sesión

Cuando intenta ejecutar un párrafo de bloc de notas aunque su sesión de Livy ya ha sido finalizada, verá el siguiente mensaje. Para habilitar la sesión de Livy, es necesario reiniciar el kernel de Jupyter al seleccionar Kernel > Restart (Reiniciar) en el menú Jupyter y, a continuación, vuelva a ejecutar el párrafo del bloc de notas.

```
An error was encountered:
Invalid status code '404' from http://localhost:8998/sessions/13 with error payload:
 "Session '13' not found."
```

No hay recursos suficientes de YARN

Cuando intenta ejecutar un párrafo de bloc de notas aunque su clúster de Spark no tenga suficientes recursos para iniciar una nueva sesión de Livy, verá el siguiente mensaje. En general, este problema se puede evitar si sigue las pautas; sin embargo, existe la posibilidad de que el problema surja. Para solucionar el problema, puede comprobar si hay alguna sesión de Livy activa que no sea necesaria. Si hay sesiones de Livy innecesarias, tendrá que finalizarlas para liberar los recursos del clúster. Para obtener más información, consulte la siguiente sección.

```
Warning: The Spark session does not have enough YARN resources to start.
The code failed because of a fatal error:
    Session 16 did not start up in 60 seconds..

Some things to try:
a) Make sure Spark has enough available resources for Jupyter to create a Spark
 context.
b) Contact your Jupyter administrator to make sure the Spark magics library is
 configured correctly.
c) Restart the kernel.
```

Monitoreo y depuración

En esta sección se describen las técnicas para monitorear los recursos y las sesiones.

Monitoreo y depuración de la asignación de recursos de clúster

Puede ver la interfaz de usuario de Spark para monitorear cuántos recursos se asignan por sesión de Livy y cuáles son las configuraciones efectivas de Spark mientras trabaja. Para habilitar la interfaz de usuario de Spark, consulte Habilitación de la interfaz de usuario web de Apache Spark para puntos de enlace de desarrollo.

(Opcional) si necesita una vista en tiempo real de la interfaz de usuario de Spark, puede configurar un túnel SSH en relación con el servidor de historial de Spark que se ejecuta en el clúster de Spark.

```
ssh -i <private-key.pem> -N -L 8157:<development endpoint public address>:18080
 glue@<development endpoint public address>
```

Luego, puede abrir http://localhost:8157 en su navegador para ver la interfaz de usuario de Spark.

Sesiones de Livy libres innecesarias

Revise estos procedimientos para cerrar las sesiones de Livy innecesarias desde un bloc de notas o un clúster de Spark.

(a). Finalizar sesiones de Livy desde un bloc de notas

Puede apagar el kernel en un bloc de notas de Jupyter para finalizar las sesiones de Livy innecesarias.

(b). Finalizar sesiones de Livy desde un clúster de Spark

Si hay sesiones de Livy innecesarias que todavía se están ejecutando, puede cerrar las sesiones de Livy en el clúster de Spark.

Como requisito previo para realizar este procedimiento, debe configurar la clave pública SSH para el punto de enlace de desarrollo.

Para iniciar sesión en el clúster de Spark, puede ejecutar el siguiente comando:

```
$ ssh -i <private-key.pem> glue@<development endpoint public address>
```

Puede ejecutar el siguiente comando para ver las sesiones activas de Livy:

```
$ yarn application -list
20/09/25 06:22:21 INFO client.RMProxy: Connecting to ResourceManager at
 ip-255-1-106-206.ec2.internal/172.38.106.206:8032
Total number of applications (application-types: [] and states: [SUBMITTED, ACCEPTED,
 RUNNING]):2
Application-Id Application-Name Application-Type User Queue State Final-State Progress
 Tracking-URL
application_1601003432160_0005 livy-session-4 SPARK livy default RUNNING UNDEFINED 10%
 http://ip-255-1-4-130.ec2.internal:41867
application_1601003432160_0004 livy-session-3 SPARK livy default RUNNING UNDEFINED 10%
 http://ip-255-1-179-185.ec2.internal:33727
```

Puede cerrar la sesión de Livy con el siguiente comando:

```
$ yarn application -kill application_1601003432160_0005
20/09/25 06:23:38 INFO client.RMProxy: Connecting to ResourceManager at
 ip-255-1-106-206.ec2.internal/255.1.106.206:8032
Killing application application_1601003432160_0005
20/09/25 06:23:39 INFO impl.YarnClientImpl: Killed application
 application_1601003432160_0005
```

Administración de blocs de notas

> **Note**
>
> Los puntos de conexión de desarrollo solo son compatibles con versiones de AWS Glue anteriores a la 2.0. Si busca un entorno interactivo en el que pueda crear y probar scripts de ETL, utilice los Blocs de notas en AWS Glue Studio.

Un cuaderno permite tareas de desarrollo y pruebas interactivas de sus scripts de ETL (extracción, transformación y carga) en un punto de conexión de desarrollo. AWS Glue proporciona una interfaz para cuadernos de Jupyter de IA de SageMaker. Con AWS Glue, el usuario crea y administra cuadernos de IA de SageMaker. También puede abrir cuadernos de IA de SageMaker desde la consola de AWS Glue.

Además, puede utilizar Apache Spark con IA de SageMaker en puntos de conexión de desarrollo de AWS Glue que admiten la IA de SageMaker (pero no trabajos de ETL de AWS Glue). SageMaker

Spark es una biblioteca de Apache Spark de código abierto para la IA de SageMaker. Para obtener más información, consulte Uso de Apache Spark con Amazon SageMaker.

Important

La administración de cuadernos de IA de SageMaker con los puntos de conexión de desarrollo de AWS Glue está disponible en las siguientes regiones de AWS:

Región	Código
Este de EE. UU. (Ohio)	`us-east-2`
Este de EE. UU. (Norte de Virginia)	`us-east-1`
Oeste de EE. UU. (Norte de California)	`us-west-1`
Oeste de EE. UU. (Oregón)	`us-west-2`
Asia-Pacífico (Tokio)	`ap-northeast-1`
Asia-Pacífico (Seúl)	`ap-northeast-2`
Asia-Pacífico (Mumbai)	`ap-south-1`
Asia-Pacífico (Singapur)	`ap-southeast-1`
Asia-Pacífico (Sídney)	`ap-southeast-2`
Canadá (centro)	`ca-central-1`
Europa (Fráncfort)	`eu-central-1`
Europa (Irlanda)	`eu-west-1`
Europa (Londres)	`eu-west-2`

Creación de trabajos de ETL visual

Creación de trabajos ETL visual con AWS Glue Studio

AWS Glue Studio proporciona una interfaz visual para crear, ejecutar y monitorear trabajos de extracción, transformación y carga (ETL) en AWS Glue. Un flujo de trabajo en AWS Glue es la lógica empresarial que lleva a cabo el flujo de trabajo de extracción, transformación y carga (ETL). Con AWS Glue Studio, puede componer visualmente flujos de trabajo de transformación de datos y ejecutarlos sin problemas en el motor de ETL sin servidor basado en Apache Spark de AWS Glue. Puede crear trabajos que muevan y transformen datos entre varios almacenes y flujos de datos mediante una opción de interfaz de arrastrar y soltar sin tener que aprender Spark ni escribir código.

Un trabajo de AWS Glue encapsula un script que se conecta a los datos de origen, los procesa y, a continuación, los escribe en el destino de datos. Normalmente, un trabajo ejecuta scripts de extracción, transformación y carga (ETL). Los trabajos pueden ejecutar scripts diseñados para los entornos de tiempo de ejecución de Apache Spark y Ray. Los trabajos también pueden ejecutar scripts de Python de uso general (trabajos de shell de Python). Los desencadenadores de AWS Glue pueden iniciar trabajos en función de un programa o evento, o bajo demanda. Puede monitorear las ejecuciones de trabajos para comprender las métricas de tiempo de ejecución como el estado de realización, la duración y la hora de inicio.

Puede utilizar los scripts que genera AWS Glue o puede utilizar sus propios scripts. Si se cuenta con un esquema de origen y una ubicación o esquema de destino determinados, el generador de código de AWS Glue Studio puede crear automáticamente un script de la API de Apache Spark (PySpark). Puede utilizar este script como base y editarlo para satisfacer sus objetivos.

AWS Glue puede escribir archivos de salida en varios formatos de datos. Cada tipo de trabajo puede admitir diferentes formatos de salida. En algunos formatos de datos, se pueden escribir formatos de compresión comunes.

Administración de trabajos de AWS Glue en la consola de AWS

Para ver los trabajos existentes, inicie sesión en la Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/. Después, seleccione pestaña Jobs (Trabajos) en AWS Glue. En la lista Jobs (Trabajos) se muestra la ubicación del script que se asocia a cada flujo de trabajo, cuando el flujo de trabajo se modificó por última vez, y la opción de marcador de flujo de trabajo actual.

Puede crear trabajos en la sección ETL de la consola de AWS Glue. Al crear un nuevo trabajo o después de haberlo guardado, puede utilizar AWS Glue Studio para modificar los trabajos de ETL. Puede hacerlo mediante la edición de los nodos en el editor visual o al editar el script de trabajo en modo desarrollador. También puede agregar y eliminar nodos en el editor visual para crear trabajos de ETL más complejos.

Siguientes pasos para crear un trabajo en AWS Glue Studio

Utilice el editor visual de trabajos para configurar nodos para su trabajo. Cada nodo representa una acción, como leer datos de la ubicación de origen o aplicar una transformación a los datos. Cada nodo que agregue al trabajo tiene propiedades que proporcionan información sobre la ubicación o la transformación de los datos.

Los próximos pasos para crear y administrar sus trabajos son los siguientes:

- Inicio de trabajos de ETL visuales en AWS Glue Studio
- Ver el script de trabajo
- Modificar las propiedades del trabajo
- Guardar el trabajo
- Iniciar una ejecución de trabajo
- Ver información sobre las ejecuciones de trabajos recientes
- Acceso al panel de monitoreo de trabajos

Creación de flujos de ETL visual con Amazon SageMaker

Con un flujo de trabajo de Estudio unificado de Amazon SageMaker, puede configurar y ejecutar una serie de tareas en ese entorno. Los flujos de trabajo de Estudio unificado de Amazon SageMaker usan Apache Airflow para modelar los procedimientos de procesamiento de datos y orquestar los artefactos de código de Estudio unificado de Amazon SageMaker. Para obtener más información, consulte Using workflows in Amazon SageMaker Unified Studio.

Inicio de trabajos de ETL visuales en AWS Glue Studio

Puede utilizar la interfaz visual simple en AWS Glue Studio para crear los trabajos de ETL. Se utiliza la página Jobs (Trabajos) para crear nuevos trabajos. También puede utilizar un editor de script o

bloc de notas para trabajar en forma directa con el código en el script del trabajo de ETL de AWS Glue Studio.

En la página Jobs (Trabajos), puede ver todos los trabajos que ha creado con AWS Glue Studio o AWS Glue. Puede ver, administrar y ejecutar sus trabajos en esta página.

Consulte también el tutorial del blog para ver otro ejemplo de cómo crear trabajos de ETL con AWS Glue Studio.

Empezar trabajos en AWS Glue Studio

AWS Glue permite crear un trabajo a través de una interfaz visual, un cuaderno de códigos interactivo o con un editor de guiones. Puede iniciar un trabajo al hacer clic en cualquiera de las opciones o crear uno nuevo a partir de un trabajo de muestra.

Los trabajos de muestra crean un trabajo con la herramienta que usted elija. Por ejemplo, los trabajos de muestra permiten crear un trabajo ETL visual que combine archivos CSV en una tabla de catálogos, crear un trabajo en un cuaderno de códigos interactivo con AWS Glue para Ray o AWS Glue para Spark cuando trabaje con pandas o crear un trabajo en un cuaderno de códigos interactivo con SparkSQL.

Creación de un trabajo en AWS Glue Studio desde cero

1. Inicie sesión en la Consola de administración de AWS y abra la consola de AWS Glue Studio en https://console.aws.amazon.com/gluestudio/.
2. En el panel de navegación, seleccione Trabajos ETL.
3. En la sección Crear trabajo, seleccione una opción de configuración para el trabajo.

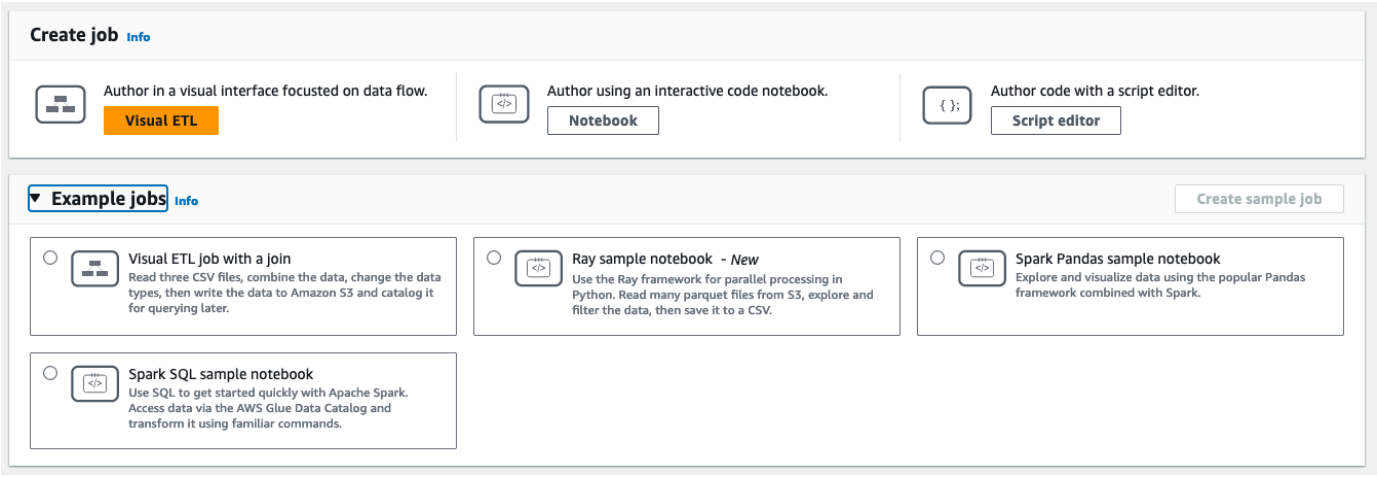

Opciones para crear un trabajo desde cero:

- Visual ETL: autor en una interfaz visual centrada en el flujo de datos
- Autor mediante cuaderno de códigos interactivo: cree trabajos de forma interactiva en una interfaz de cuaderno basada en cuadernos de Jupyter

  Cuando selecciona esta opción, debe proporcionar información adicional antes de crear una sesión de creación de un cuaderno. Para conocer más acerca de cómo especificar esta información, consulte Introducción a los cuaderno en AWS Glue Studio.
- Autor de código con un editor de guiones: para aquellos que estén familiarizados con la programación y la escritura de guiones de ETL, elija esta opción a fin de crear un nuevo trabajo ETL de Spark. Elige el motor (Python shell, Ray, Spark (Python) o Spark (Scala). A continuación, seleccione Comenzar de cero o Cargar guion para cargar un guion existente desde un archivo local. Si elige utilizar el editor de script, no puede usar el editor visual para diseñar o editar el trabajo.

  Un trabajo de Spark se ejecuta en un entorno Apache Spark administrado por AWS Glue. De forma predeterminada, los nuevos scripts están codificados en Python. Para escribir un nuevo script de Scala, consulte Creación y edición de scripts de Scala en AWS Glue Studio.

Creación de un trabajo en AWS Glue Studio a partir de un ejemplo de trabajo

Puede optar por crear un trabajo a partir de un trabajo de muestra. En Trabajos de ejemplo, seleccione un trabajo de ejemplo y, a continuación, seleccione Crear un trabajo de muestra para iniciar un trabajo de muestra. Al crear un trabajo de muestra a partir de una de las opciones, se proporciona una plantilla rápida con la que puede trabajar.

1. Inicie sesión en la Consola de administración de AWS y abra la consola de AWS Glue Studio en https://console.aws.amazon.com/gluestudio/.
2. En el panel de navegación, seleccione Trabajos ETL.
3. Seleccione una opción para crear un trabajo a partir de un trabajo de muestra:

   - Trabajo de ETL visual para unir varios orígenes: lea tres archivos CSV, combine los datos, cambie los tipos de datos y, a continuación, escriba los datos en Amazon S3 y catalóguelos para consultarlos más adelante.
   - Cuaderno Spark con Pandas: explore y visualice datos con el marco popular de Pandas combinado con Spark.

- Cuaderno Spark con SQL: use SQL para empezar rápidamente con Apache Spark. Acceda a los datos a través del catálogo de datos de AWS Glue y transfórmelos con comandos conocidos.

4. Seleccione Crear un trabajo de muestra.

Características del editor de trabajo

El editor de trabajos proporciona las siguientes características para crear y editar trabajos.

- Diagrama visual de su trabajo, con un nodo para cada tarea de trabajo: nodos de origen de datos para leer los datos; nodos de transformación para modificar los datos; nodos de destino de datos para escribir los datos.

  Puede ver y configurar las propiedades de cada nodo en el diagrama de trabajo. También puede ver el esquema y los datos de ejemplo de cada nodo en el diagrama de trabajo. Estas características ayudan a comprobar que su trabajo está modificando y transformando los datos de la manera correcta, sin tener que ejecutar el trabajo.
- Una pestaña Visualización y edición de scripts, donde puede modificar el código generado para su trabajo.
- Una pestaña Detalles del trabajo, en la que puede configurar una variedad de opciones para personalizar el entorno en el que se ejecuta el trabajo de ETL de AWS Glue.
- Una pestaña Ejecuciones, donde puede ver las ejecuciones actuales y anteriores del trabajo, ver el estado de la ejecución del trabajo y acceder a los registros de la ejecución del trabajo.
- Una pestaña de calidad de datos, donde puede aplicar reglas de calidad de datos a su trabajo.
- Una pestaña Programaciones, en la que puede configurar la hora de inicio del trabajo o configurar ejecuciones de trabajos recurrentes.
- Una pestaña de Control de versiones, donde puede configurar un servicio de Git para usarlo en el trabajo.

Uso de previsualizaciones de esquema en el editor visual de trabajos

Mientras crea o edita su trabajo, puede usar la pestaña Esquema de salida para ver el esquema de sus datos.

Antes de ver el esquema, el editor de trabajos necesita permisos para acceder al origen de datos. Puede especificar un rol de IAM en la pestaña Detalles del trabajo del editor o en la pestaña

Esquema de salida para un nodo. Si el rol de IAM tiene todos los permisos necesarios para acceder al origen de datos, puede ver el esquema en la pestaña Esquema de salida para un nodo.

Uso de previsualizaciones de datos en el editor visual de trabajos

Las previsualizaciones de datos ayudan a crear y probar su trabajo con una muestra de sus datos, sin tener que ejecutarlo varias veces. Al utilizar la vista previa de datos, puede:

- Probar un rol de IAM para asegurarse de que tiene acceso a sus orígenes de datos o destinos de datos.
- Comprobar que la transformación está modificando los datos de la forma deseada. Por ejemplo, si utiliza una transformación de filtro, puede asegurarse de que el filtro está seleccionando el subconjunto correcto de datos.
- Comprobar sus datos. Si el conjunto de datos contiene columnas con valores de varios tipos, la previsualización de datos muestra una lista de tuplas para estas columnas. Cada tupla contiene el tipo de datos y su valor.

> **Note**
>
> Si utiliza una sesión de vista previa de datos y un nodo de código o SQL personalizado, la sesión de vista previa de datos ejecutará el SQL o el bloque de código tal cual está para todo el conjunto de datos.

Mientras crea o edita el trabajo, puede usar la pestaña Previsualización de datos debajo del lienzo del trabajo para ver una muestra de sus datos. Se iniciará automáticamente una nueva sesión de vista previa de datos cuando el rol ya esté configurado en el trabajo o cuando se haya configurado un rol de IAM predeterminado en la cuenta. Si un rol no se ha configurado previamente, puede iniciar una sesión seleccionándolo.

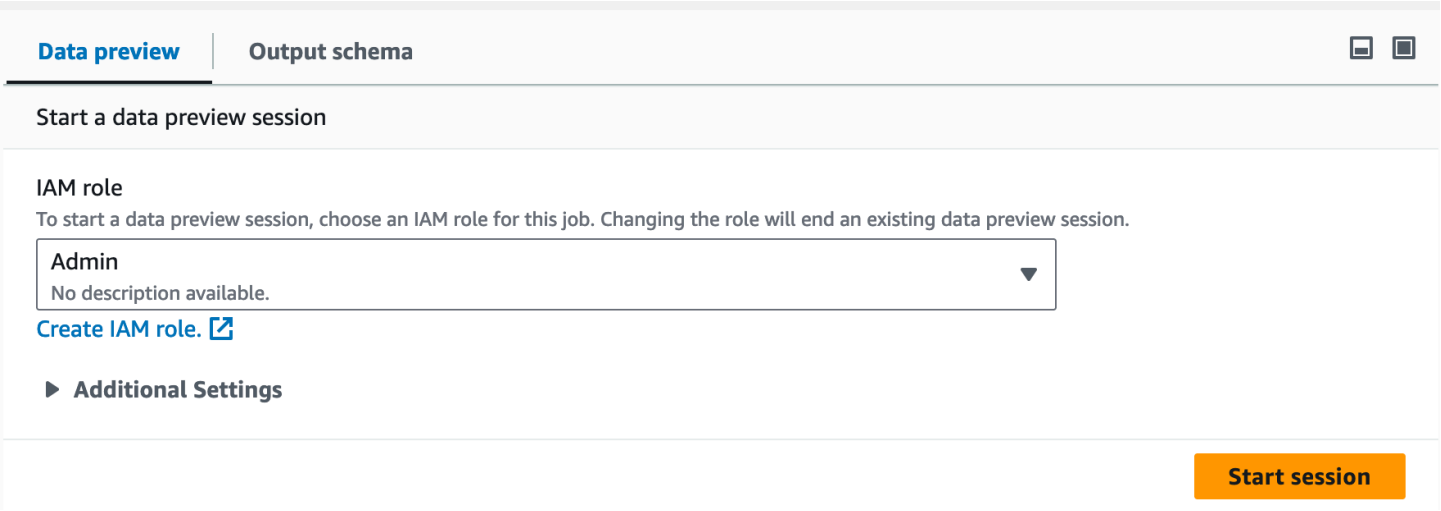

> **Note**
>
> El rol que elija para la sesión de vista previa de datos también se usará para el trabajo.

Para ver el estado y el progreso de la sesión, así como los detalles de la sesión, haga clic en el icono de información.

Cuando la sesión esté lista, AWS Glue Studio cargará los datos del nodo que seleccionó. Puede ver el porcentaje completado a medida que avanza.

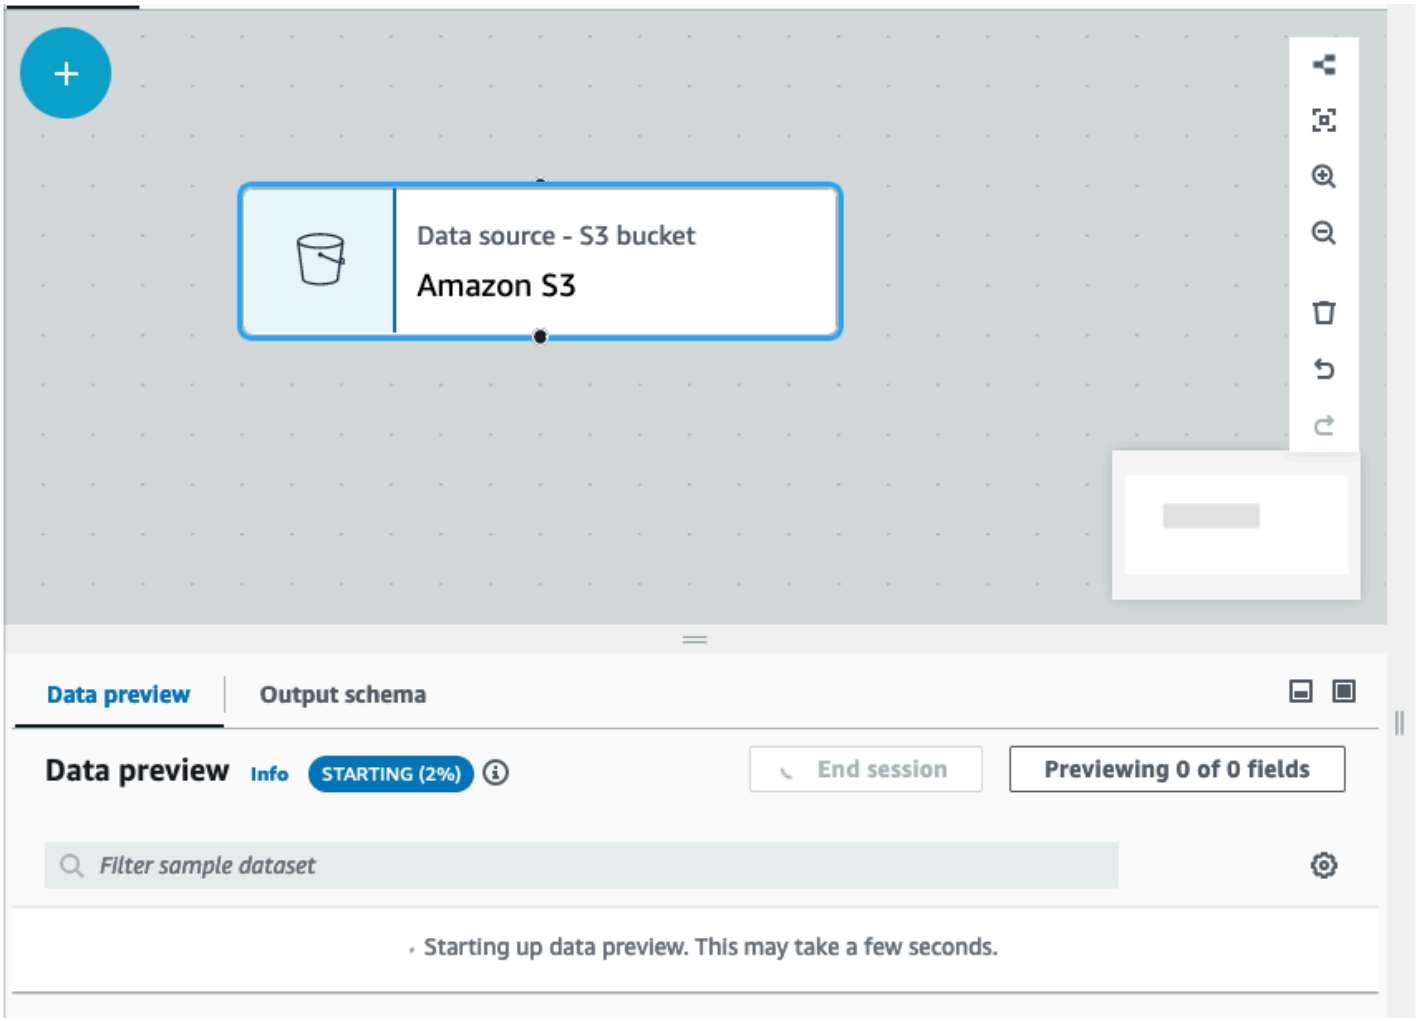

A medida que vaya creando su trabajo visual, AWS Glue Studio actualizará automáticamente el esquema del nodo seleccionado cuando active la opción Deducir el esquema de la sesión en la pestaña Esquema de salida.

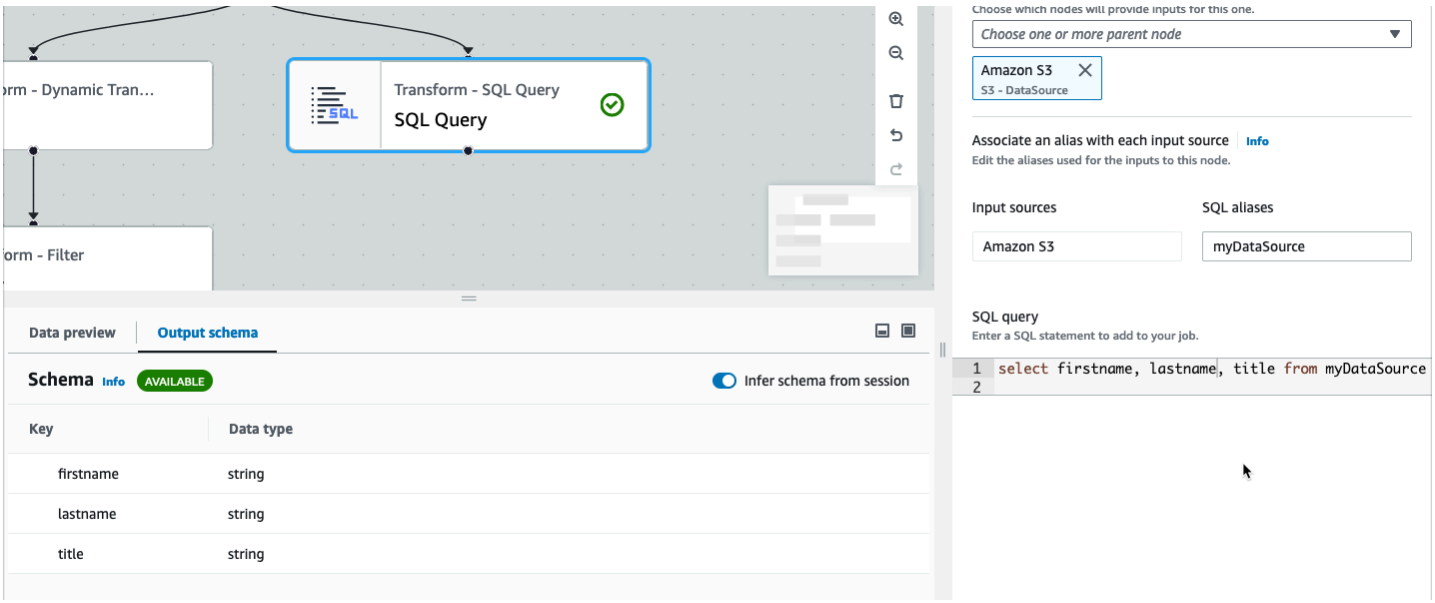

Para configurar sus preferencias de vista previa de datos:

Elija el ícono de configuración (un símbolo de engranaje) para configurar sus preferencias para las previsualizaciones de datos. Esta configuración se aplica a todos los nodos del diagrama de trabajo. Puede hacer lo siguiente:

- Elija ajustar el texto de una línea a la siguiente. Esta opción está habilitada de forma predeterminada
- Cambie el número de filas (200 por defecto)
- Elija a un rol de IAM o cree un rol de IAM si es necesario
- Elija iniciar automáticamente una nueva sesión al crear un trabajo. Esto aprovisiona una nueva sesión interactiva al crear trabajos. Esta configuración se aplica en el nivel de la cuenta. Una vez configurada, se aplicará a todos los usuarios de su cuenta al editar cualquier trabajo.
- Elija la opción de inferir automáticamente el esquema. Se deducirán automáticamente los esquemas de salida para el nodo seleccionado
- Elija importar bibliotecas de AWS Glue automáticamente. Esto resulta útil, ya que evitará que la vista previa de los datos reinicie nuevas sesiones al añadir nuevas transformaciones que requieran el reinicio de la sesión

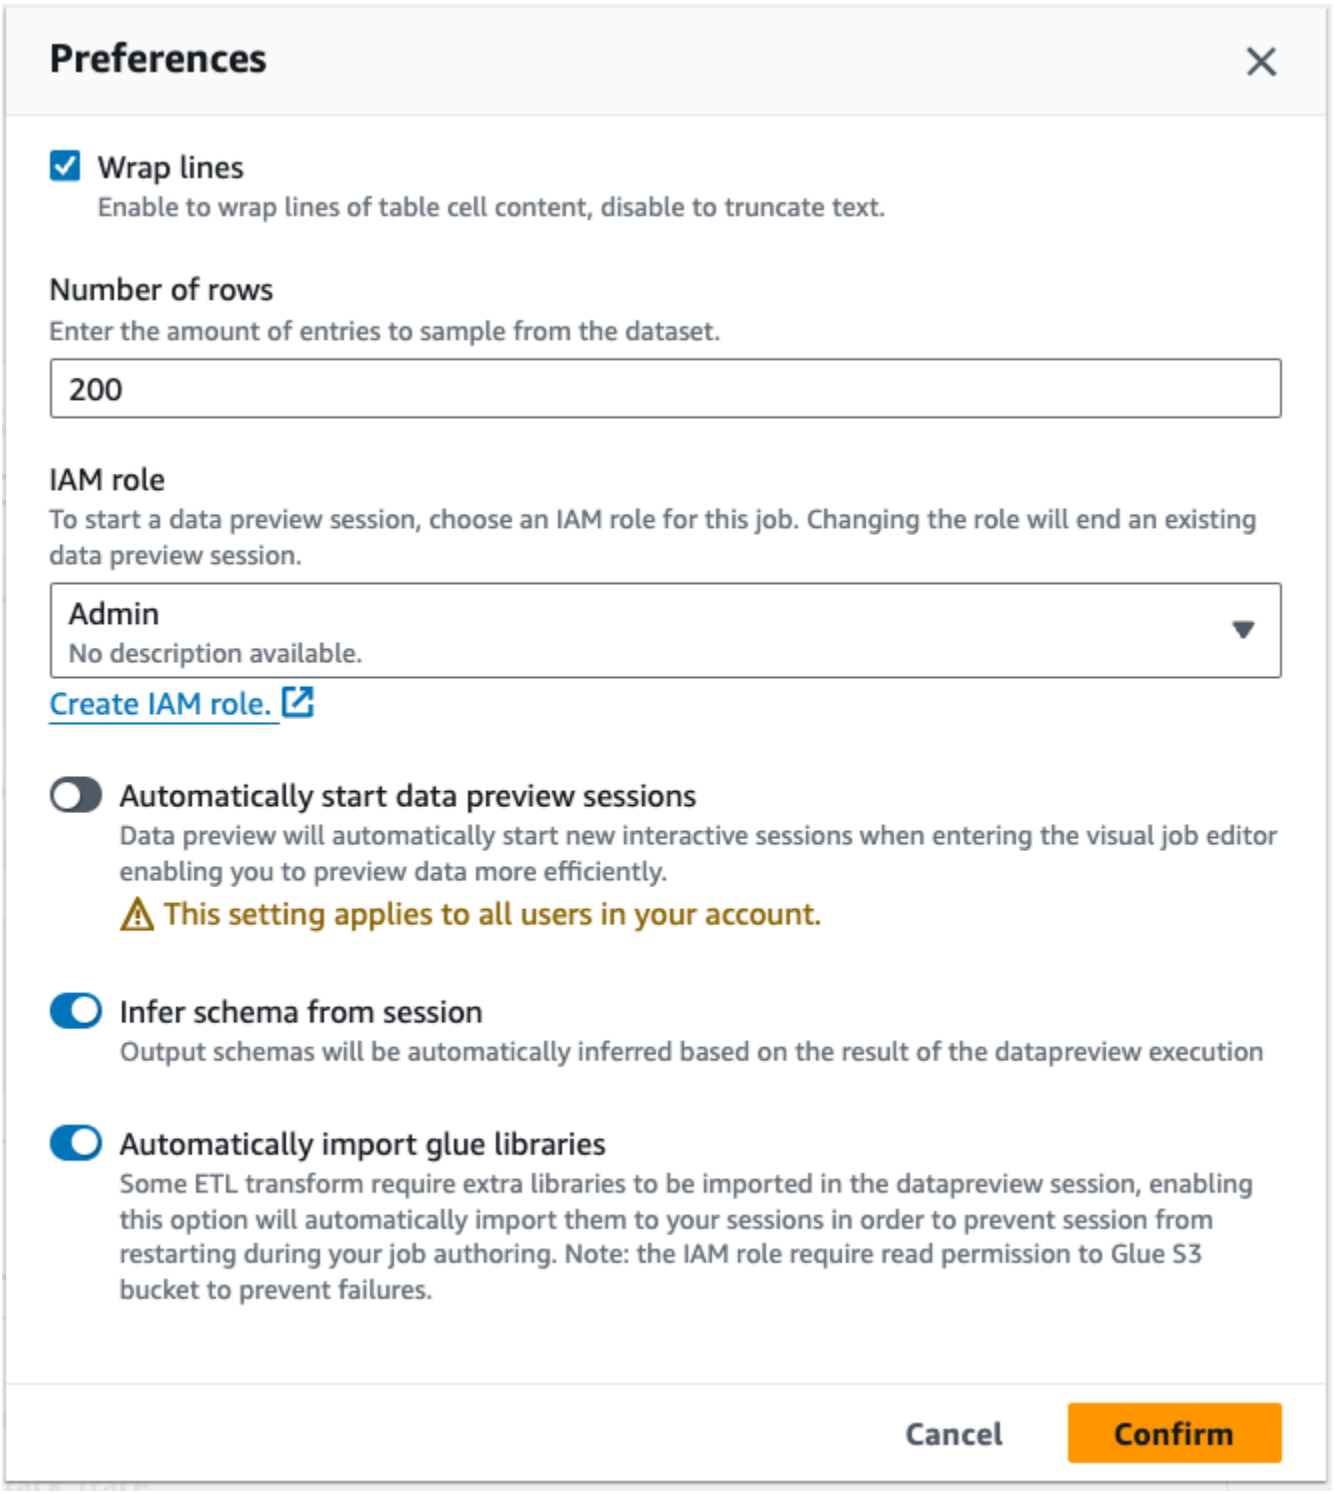

Las funciones adicionales incluyen la capacidad de:

- Elija el boton Previsualización de x de y campos para seleccionar las columnas (campos) que ds esea previsualizar. Al obtener una previsualización de los datos utilizando la configuración

predeterminada, el editor de trabajos muestra las primeras cinco columnas del conjunto de datos. Puede cambiar esto para mostrar todos o ninguno (no recomendado).

- Desplazarse por la ventana de previsualización de datos en forma horizontal como vertical.
- Utilice el botón de maximizar para expandir la pestaña de Previsualización de datos y superponerla sobre el gráfico del trabajo para ver mejor los datos y las estructuras de datos. Del mismo modo, utilice el botón de minimizar para minimizar la pestaña de previsualización de datos. También puede agarrar el panel de control y arrastrarlo hacia arriba para expandir la pestaña de Previsualización de datos.

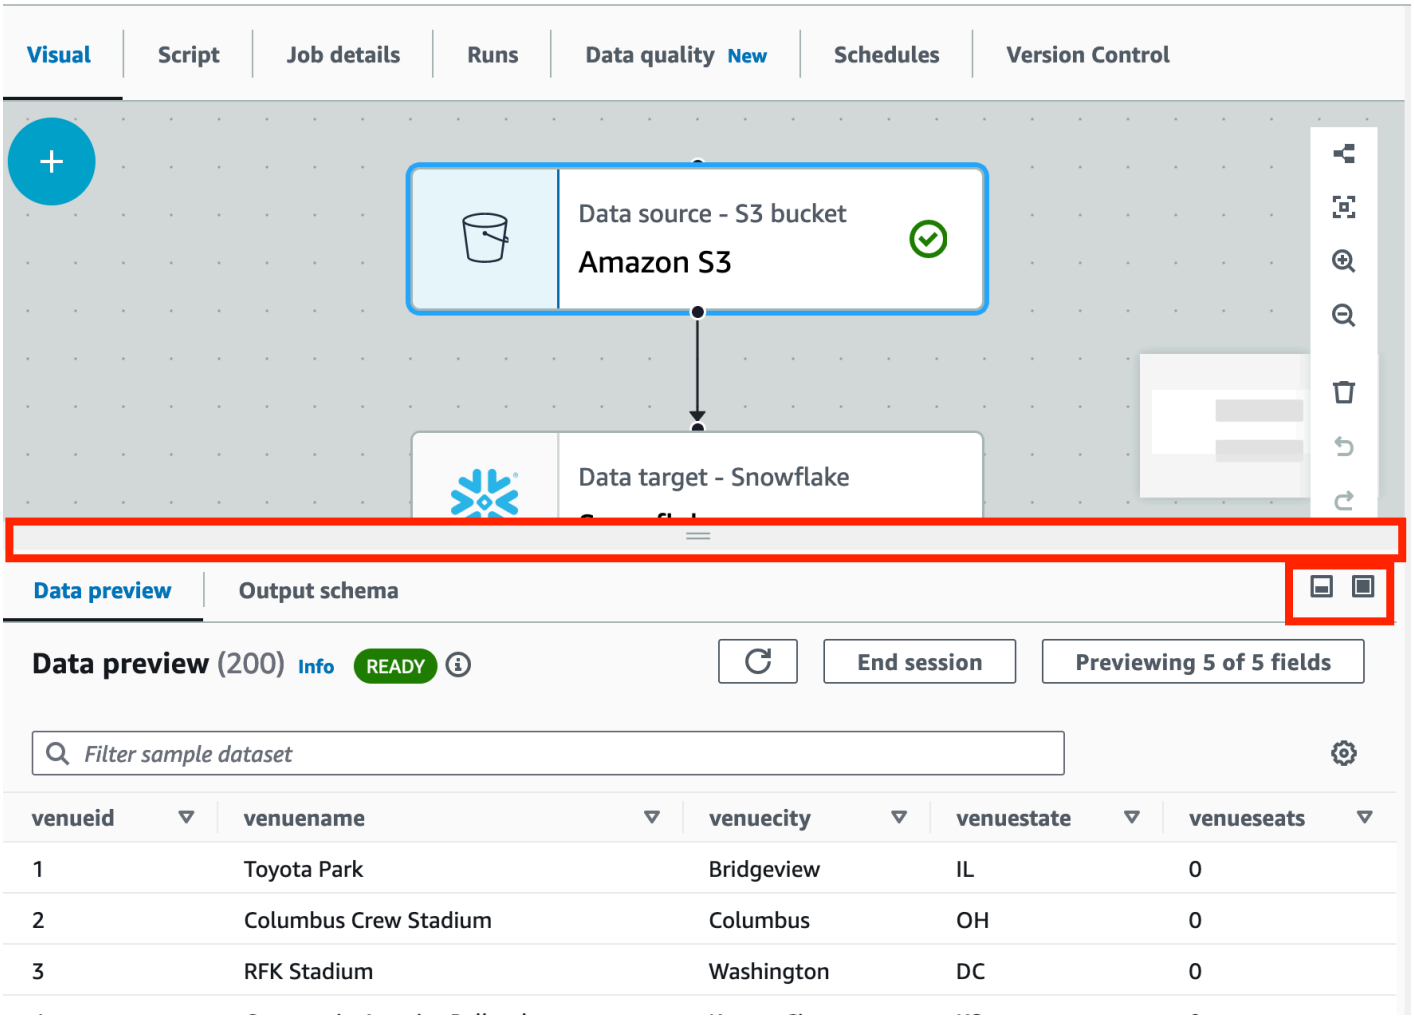

- Utilice Finalizar sesión para detener la vista previa de los datos. Al detener la sesión, puede elegir un nuevo rol de IAM y establecer ajustes adicionales (como activar o desactivar los ajustes para iniciar automáticamente una nueva sesión, deducir un esquema o importar bibliotecas AWS Glue e iniciar la sesión de nuevo).

Restricciones al usar previsualizaciones de datos

Si utiliza las previsualizaciones de datos, podría encontrarse con las siguientes restricciones o limitaciones.

- La primera vez que elija la pestaña Previsualización de datos, deberá elegir un rol de IAM. Este rol debe tener los permisos correspondientes para acceder a los datos y otros recursos necesarios para crear las previsualizaciones de datos.
- Después de proporcionar un rol de IAM, tarda un tiempo antes de que los datos estén disponibles para su visualización. Para conjuntos de datos con menos de 1 GB de datos, puede tardar hasta un minuto. Si tiene un conjunto de datos grande, debe usar particiones para mejorar el tiempo de carga. La carga de datos directamente desde Amazon S3 ofrece el mejor rendimiento.
- Si tiene un conjunto de datos muy grande y tarda más de 15 minutos en consultar los datos para la previsualización de datos, se agotará el tiempo de espera de la solicitud. Las vistas previas de datos tienen un tiempo de espera de inactividad de 30 minutos. Para aliviar este problema, reduzca el tamaño del conjunto de datos que previsualizará.
- De forma predeterminada, verá las primeras 50 columnas en la pestaña Previsualización de datos. Si las columnas no tienen valores de datos, recibirá un mensaje que indicará que no hay datos para mostrar. Puede aumentar el número de filas muestreadas o seleccionar columnas diferentes para ver los valores de los datos.
- Actualmente, las previsualizaciones de datos no se soportan para orígenes de datos de streaming ni para orígenes de datos que utilizan conectores personalizados.
- Los errores en un nodo afectan a todo el trabajo. Si un nodo tiene un error con las previsualizaciones de datos, el error aparecerá en todos los nodos hasta que lo corrija.
- Si cambia un origen de datos para el trabajo, es posible que sea necesario actualizar los nodos secundarios de ese origen de datos para que coincidan con el nuevo esquema. Por ejemplo, si tiene un nodo ApplyMapping que modifica una columna y la columna no existe en el origen de datos de reemplazo, deberá actualizar el nodo de transformación ApplyMapping.
- Si ve la pestaña Previsualización de datos de un nodo de transformación de consulta SQL y la consulta SQL utiliza un nombre de campo incorrecto, la pestaña Previsualización de datos muestra un error.

Generación de código de script

Cuando se utiliza el editor visual para crear un trabajo, el código ETL se genera de forma automática. AWS Glue Studio crea un script de trabajo funcional y completo y lo guarda en una ubicación de Amazon S3.

Hay dos formas de código generadas por AWS Glue Studio: la versión original o clásica y una versión más nueva y optimizada. De forma predeterminada, el nuevo generador de código se utiliza para crear el script de trabajo. Puede generar un script de trabajo mediante el generador de código clásico en la pestaña Script al seleccionar el botón de alternar Generar script clásico.

Algunas de las diferencias en la nueva versión del código generado incluyen:

- Ya no se agregan bloques de comentarios grandes al script
- Las estructuras de salida del código utilizan el nombre de nodo que especifica en el editor visual. En el script de clase, las estructuras de salida se denominan tan solo `DataSource0`, `DataSource1`, `Transform0`, `Transform1`, `DataSink0`, `DataSink1` y así sucesivamente.
- Los comandos largos se dividen en varias líneas para eliminar la necesidad de desplazarse por la página a fin de ver todo el comando.

Nuevas características en AWS Glue Studio requieren la nueva versión de generación de código y no funcionará con el script de código clásico. Se le pide que actualice estos trabajos cuando intente ejecutarlos.

Transformación de datos con transformaciones administradas de AWS Glue

AWS Glue Studio ofrece dos tipos de transformaciones:

- Transformaciones nativas de AWS Glue: disponibles para todos los usuarios y administradas por AWS Glue.
- Transformaciones visuales personalizadas: le permiten cargar sus propias transformaciones para usarlas en AWS Glue Studio

Nodos de transformación de datos administrados por AWS Glue

AWS Glue Studio proporciona un conjunto de transformaciones integradas que puede utilizar para procesar los datos. Sus datos pasan de un nodo en el diagrama de trabajo a otro en una estructura

de datos denominada `DynamicFrame`, que es una extensión de un `DataFrame` de Apache Spark SQL.

En el diagrama rellenado previamente para un trabajo, entre el origen de datos y los nodos de destino de datos se encuentra el nodo de transformación Cambiar esquema. Puede configurar este nodo de transformación para modificar los datos o puede utilizar transformaciones adicionales.

AWS Glue Studio dispone de las siguientes transformaciones integradas:

- ChangeSchema: asigne claves de propiedad de datos en el origen de datos a claves de propiedad de datos en el destino de datos. Puede cambiar el nombre de las claves, modificar los tipos de datos de las claves y elegir las claves que desea descartar del conjunto de datos.
- SelectFields (Seleccionar campos): elija las claves de propiedad de datos que desee conservar.
- DropFields (Descartar campos): elija las claves de propiedad de datos que desee descartar.
- RenameField (Renombrar campos): cambie el nombre de una sola clave de propiedad de datos.
- Spigot: escriba muestras de los datos en un bucket de Amazon S3.
- Join (Combinar): combine dos conjuntos de datos en uno mediante una frase de comparación en las claves de propiedad de datos especificadas. Puede utilizar combinaciones interna, externa, izquierda, derecha, semicombinación izquierda y anticombinación izquierda.
- Unión: combine filas de más de un origen de datos que tengan el mismo esquema.
- SplitFields (Dividir campos): divida claves de propiedad de datos en dos `DynamicFrames`. La salida es una recopilación de `DynamicFrames`: uno con las claves de propiedad de datos seleccionadas y el otro con las claves de propiedad de datos restantes.
- SelectFromCollection (Seleccionar desde recopilación): elija un `DynamicFrame` de una recopilación de `DynamicFrames`. La salida es el `DynamicFrame` seleccionado.
- FillMissingValues (Completar valores faltantes): para localizar registros en el conjunto de datos que tienen valores faltantes y agregar un nuevo campo con un valor sugerido determinado por imputación
- Filter (Filtro): divida un conjunto de datos en dos, en función de una condición de filtro.
- Eliminar campos nulos: elimina columnas del conjunto de datos si todos los valores de la columna son ‘nulos’.
- Eliminar duplicados: elimina las filas del origen de datos. Para ello, elija hacer coincidir filas enteras o especificar claves.
- SQL: ingrese el código SparkSQL en un campo de entrada de texto para utilizar una consulta SQL a fin de transformar los datos. La salida es un único `DynamicFrame`.

- Agregación: realiza un cálculo (como el promedio, la suma, el mínimo o el máximo) en los campos y filas seleccionados y crea un nuevo campo con los valores calculados recientes.
- Aplanar: extrae los campos dentro de las estructuras en los campos de nivel superior.
- UUID: agrega una columna con un Identificador único universal (UUID) para cada fila.
- Identificador: agrega una columna con un identificador numérico para cada fila.
- Para agregar una marca temporal: convierta una columna al tipo de marca temporal.
- Formato de marca temporal: convierte una columna de marca temporal en una cadena formateada.
- Transformación de Enrutador condicional: aplique múltiples condiciones a los datos entrantes. Cada fila de los datos entrantes se evalúa mediante una condición de filtro de grupo y se procesa en su grupo correspondiente.
- Transformación de concatenar columnas: cree una nueva columna de cadena. Para ello, utilice los valores de otras columnas con un espaciador opcional.
- Transformación de cadena dividida: divida una cadena en una matriz de tokens. Para ello, utilice una expresión regular para definir cómo se realiza la división.
- Transformación de matriz a columnas: extraiga algunos o todos los elementos de una columna de tipo matriz en nuevas columnas.
- Agregar la transformación de marca de tiempo actual: marque las filas con la hora a la que se procesaron los datos. Esto resulta útil para fines de auditoría o para realizar un seguimiento de la latencia en la canalización de datos.
- Transformación de filas dinámicas en columnas: agregue una columna numérica. Para ello, rote los valores únicos en las columnas seleccionadas para convertirlas en columnas nuevas. Si se seleccionan varias columnas, los valores se concatenan para dar nombre a las nuevas columnas.
- Transformación de columnas a filas: convierta columnas en valores de nuevas columnas. Para ello, genere una fila para cada valor único.
- Transformación de procesamiento de equilibrio automático: redistribuya mejor los datos entre los trabajadores. Esto es útil cuando los datos están desequilibrados o cuando provienen del origen y no permiten un procesamiento paralelo suficiente.
- Transformación de columnas derivadas: defina una nueva columna basándose en una fórmula matemática o expresión SQL en la que pueda utilizar otras columnas de los datos, así como constantes y literales.
- Transformación de búsqueda: agregue columnas de una tabla de catálogo definida cuando las claves coincidan con las columnas de búsqueda definidas en los datos.

- Transformación de matriz o mapa en filas: extraiga valores de una estructura anidada en filas individuales que sean más fáciles de manipular.
- Transformación de coincidencia de registros: invoque una transformación de clasificación de datos de machine learning de Record Matching existente.
- Transformación de eliminar filas nulas: elimine del conjunto de datos las filas que tengan todas las columnas nulas o vacías.
- Transformación de analizar columnas JSON: analice una columna de cadena que contenga datos de JSON y conviértala en una columna de estructura o matriz, en función de si el JSON es un objeto o una matriz, respectivamente.
- Transformación de extraer la ruta JSON: extraiga nuevas columnas de una columna de cadena JSON.
- Extraer fragmentos de cadenas de una expresión regular: extraiga fragmentos de cadenas mediante una expresión regular y cree una nueva columna a partir de ella o varias columnas si utiliza grupos de expresiones regulares.
- Custom transform (Transformación personalizada): ingrese un código en un campo de entrada de texto para utilizar transformaciones personalizadas. La salida es una recopilación de `DynamicFrames`.

Uso de una receta de preparación de datos en AWS Glue Studio

La transformación de la receta de preparación de datos le permite crear una receta de preparación de datos desde cero mediante una interfaz de creación con estilo de cuadrícula interactiva. También le permite importar una receta de AWS Glue DataBrew existente y luego editarla en AWS Glue Studio.

El nodo Receta de preparación de datos está disponible en el panel de Recursos. Puede conectar el nodo Receta de preparación de datos a otro nodo del flujo de trabajo visual, ya sea un nodo de origen de datos u otro nodo de transformación. Tras elegir una receta de AWS Glue DataBrew y una versión, los pasos aplicados en la receta aparecen visibles en la pestaña de propiedades del nodo.

Requisitos previos

- Si va a importar una receta de AWS Glue DataBrew, debe tener los permisos de IAM necesarios, tal y como se describe en Importación de una receta de AWS Glue DataBrew en AWS Glue Studio.
- Debe crearse una sesión de vista previa de datos.

Limitaciones

- Las recetas de AWS Glue DataBrew solo se admiten en las regiones comerciales de DataBrew.
- No todas las recetas de AWS Glue DataBrew son compatibles con AWS Glue. Algunas recetas no se podrán ejecutar en AWS Glue Studio.
  - No se admiten recetas con transformaciones `UNION` y `JOIN`. Sin embargo, AWS Glue Studio ya cuenta con los nodos de transformación "Join" y "Union", que se pueden utilizar antes o después de un nodo de receta de preparación de datos.
- Los nodos de Receta de preparación de datos son compatibles con los trabajos que comiencen con la versión 4.0 de AWS Glue. Esta versión se seleccionará automáticamente después de agregar un nodo Receta de preparación de datos al trabajo.
- Los nodos de Receta de preparación de datos requieren Python. Esto se establece automáticamente cuando se agrega el nodo de Receta de preparación de datos al trabajo.
- Al agregar un nuevo nodo de receta de preparación de datos al gráfico visual, se reiniciará automáticamente la sesión de vista previa de datos con las bibliotecas correctas para usar el nodo de receta de preparación de datos.
- No se admiten las siguientes transformaciones para la importación o edición en un nodo de receta de preparación de datos: `GROUP_BY`, `PIVOT`, `UNPIVOT` y `TRANSPOSE`.

Características adicionales

Cuando haya seleccionado la transformación de la receta de preparación de datos, podrá realizar acciones adicionales después de elegir Crear receta.

- Agregar paso: puede agregar pasos adicionales a una receta según sea necesario seleccionando el icono de agregar paso o utilizar la barra de herramientas del panel de vista previa seleccionando una acción.

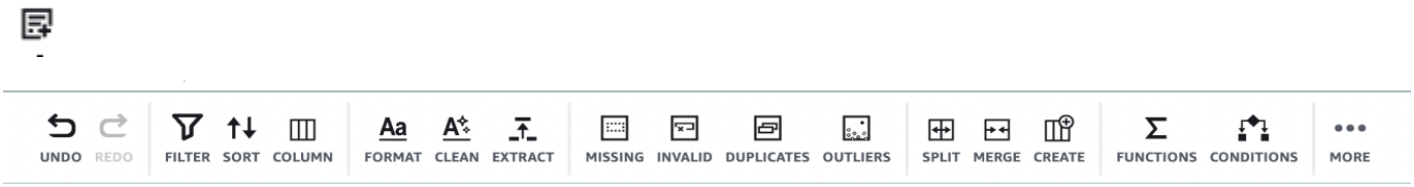

- Importar receta: seleccione Más y luego Importar receta para usarla en el trabajo de AWS Glue Studio.

- Descargar como YAML: seleccione Más y luego Descargar como YAML para descargar la receta y guardarla fuera de AWS Glue Studio.
- Descargar como JSON: seleccione Más y luego Descargar como JSON para descargar la receta y guardarla fuera de AWS Glue Studio.
- Deshacer y rehacer los pasos de la receta: puede deshacer y rehacer los pasos de la receta en el panel de vista previa cuando trabaje con los datos de la cuadrícula.

Creación y ejecución de recetas de preparación de datos en un trabajo de AWS Glue de ETL visual

En este escenario, puede crear recetas de preparación de datos sin tener que crearlas primero en DataBrew. Antes de empezar a crear recetas, debe:

- Tener una sesión de vista previa de datos activa en ejecución. Cuando la sesión de vista previa de datos esté LISTA, la opción Crear receta se activará y podrá empezar a crear o editar la receta.

- Asegúrese de que la opción Importar automáticamente bibliotecas de Glue esté habilitada.

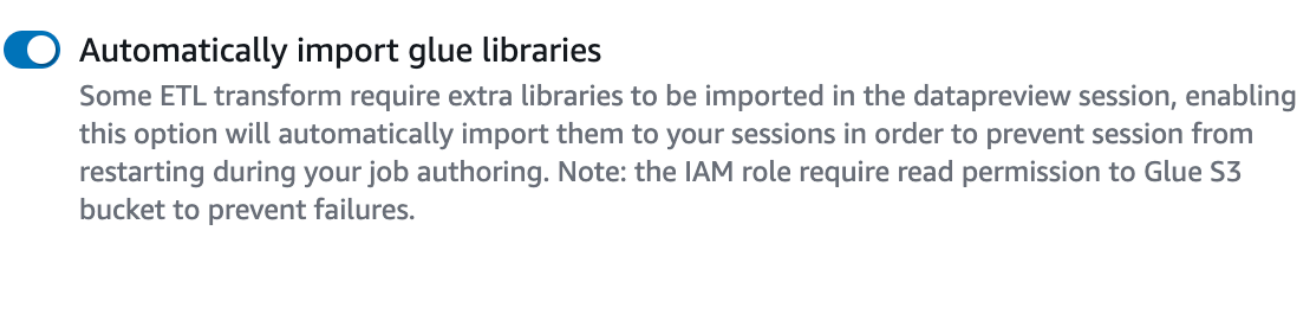

  Para ello, seleccione el icono con forma de engranaje en el panel de vista previa de datos.

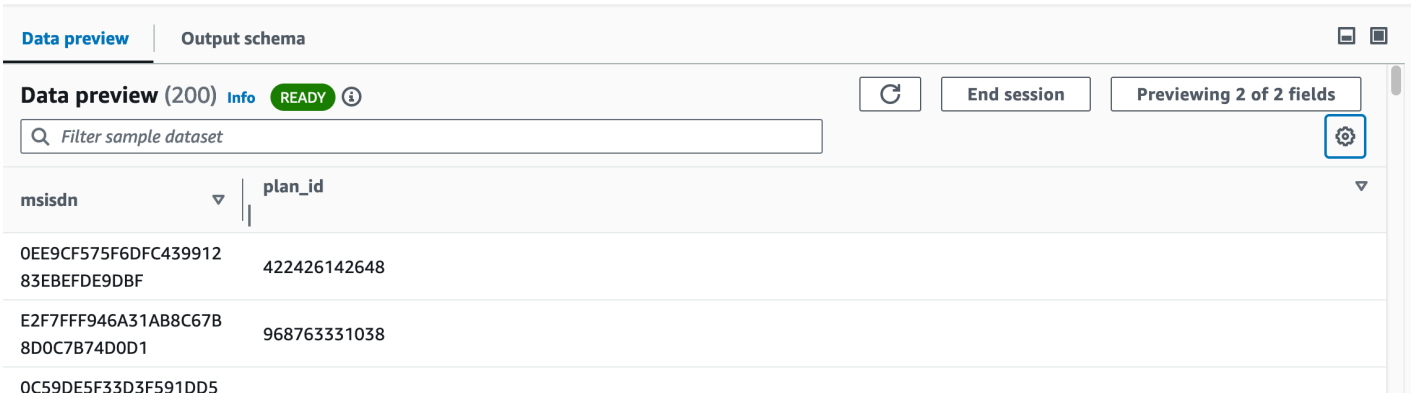

Creación de una receta de preparación de datos en AWS Glue Studio:

1. Agregue la transformación de la receta de preparación de datos a su lienzo de trabajo. La transformación debe estar conectada a un nodo principal del origen de datos. Al agregar el nodo de la receta de preparación de datos, el nodo se reiniciará con las bibliotecas adecuadas y verá que se está preparando el marco de datos.

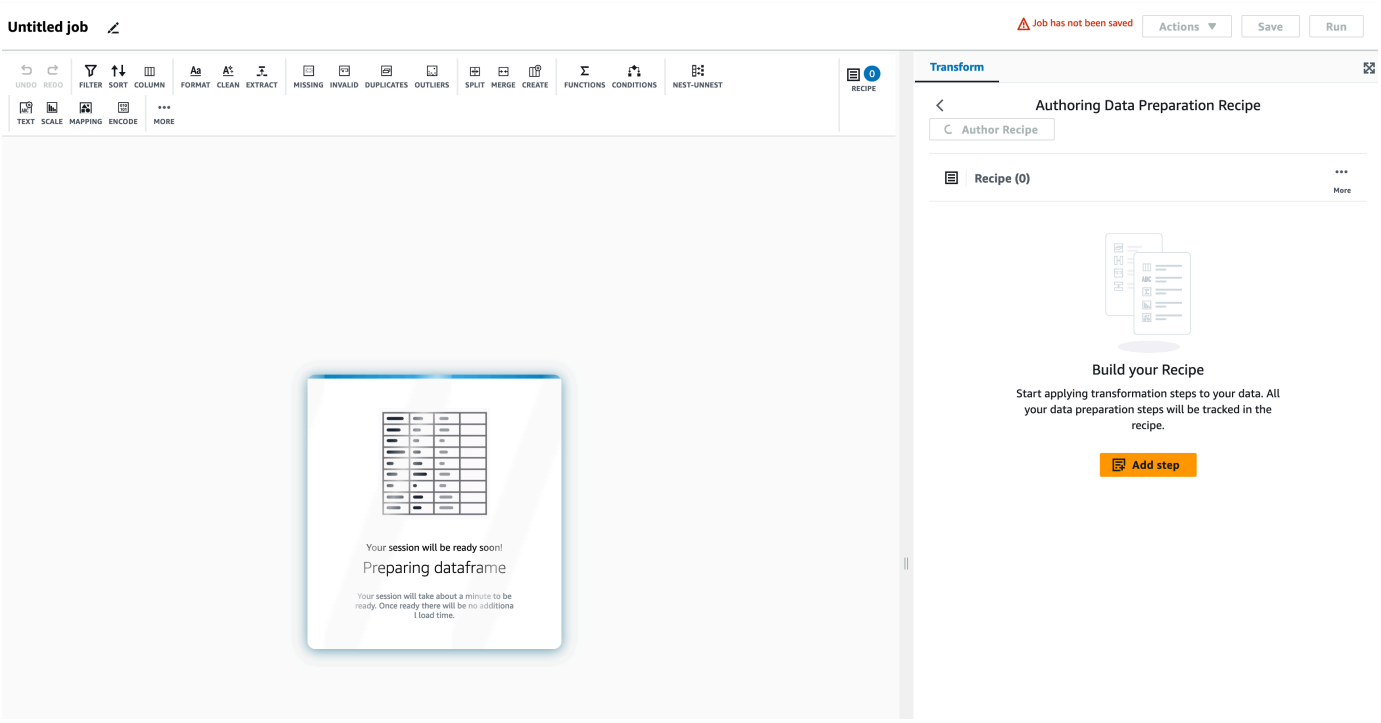

2. Una vez que la sesión de vista previa de datos esté lista, los datos con los pasos aplicados anteriormente aparecerán en la parte inferior de la pantalla.
3. Elija Crear receta. Esto le permitirá empezar una nueva receta en AWS Glue Studio.

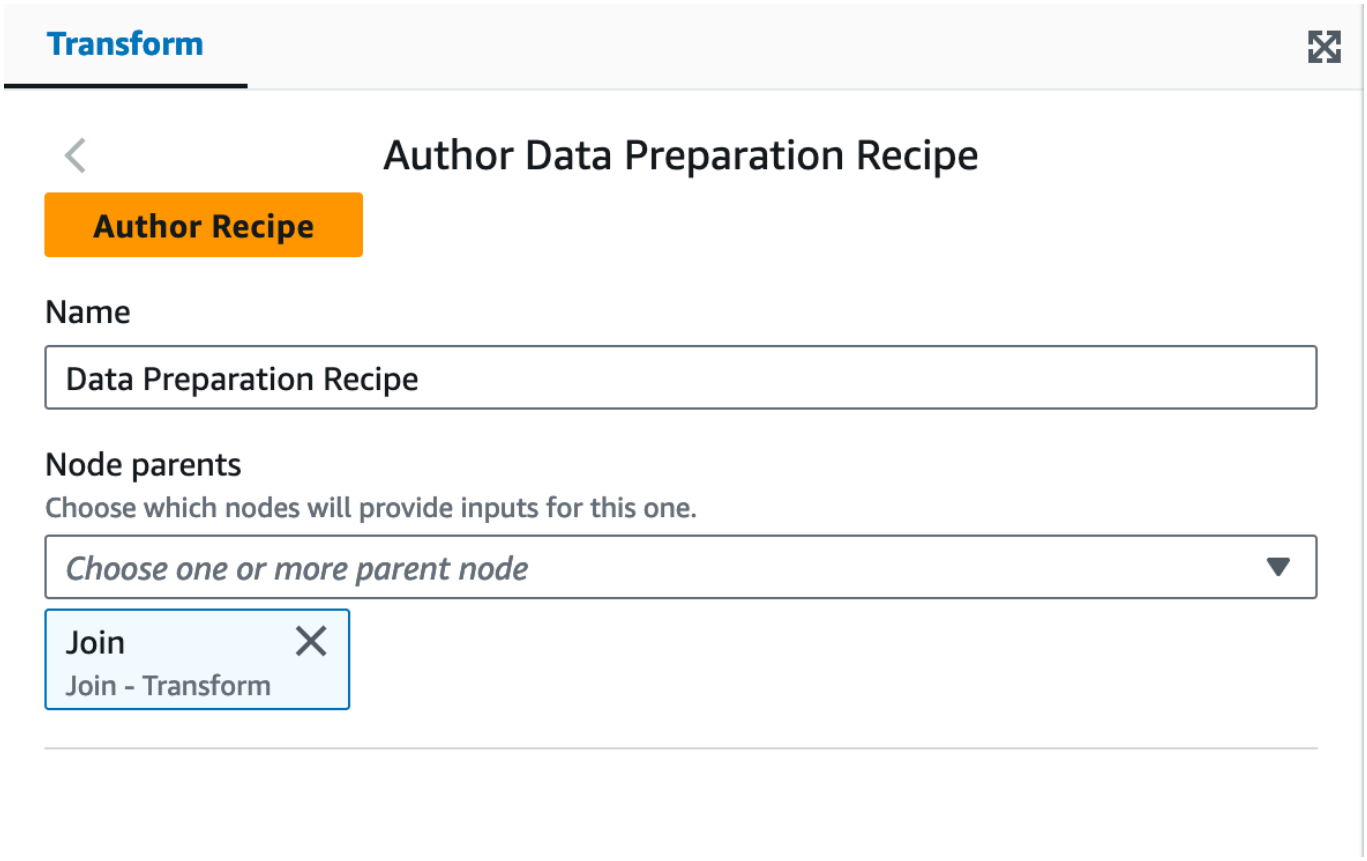

4. En el panel Transformar, situado a la derecha del lienzo de trabajo, ingrese un nombre para la receta de preparación de datos.
5. En el lado izquierdo, el lienzo se sustituirá por una vista de cuadrícula de los datos. A la derecha, el panel Transformar cambiará para mostrarle los pasos de la receta. Seleccione Agregar paso para agregar el primer paso a la receta.

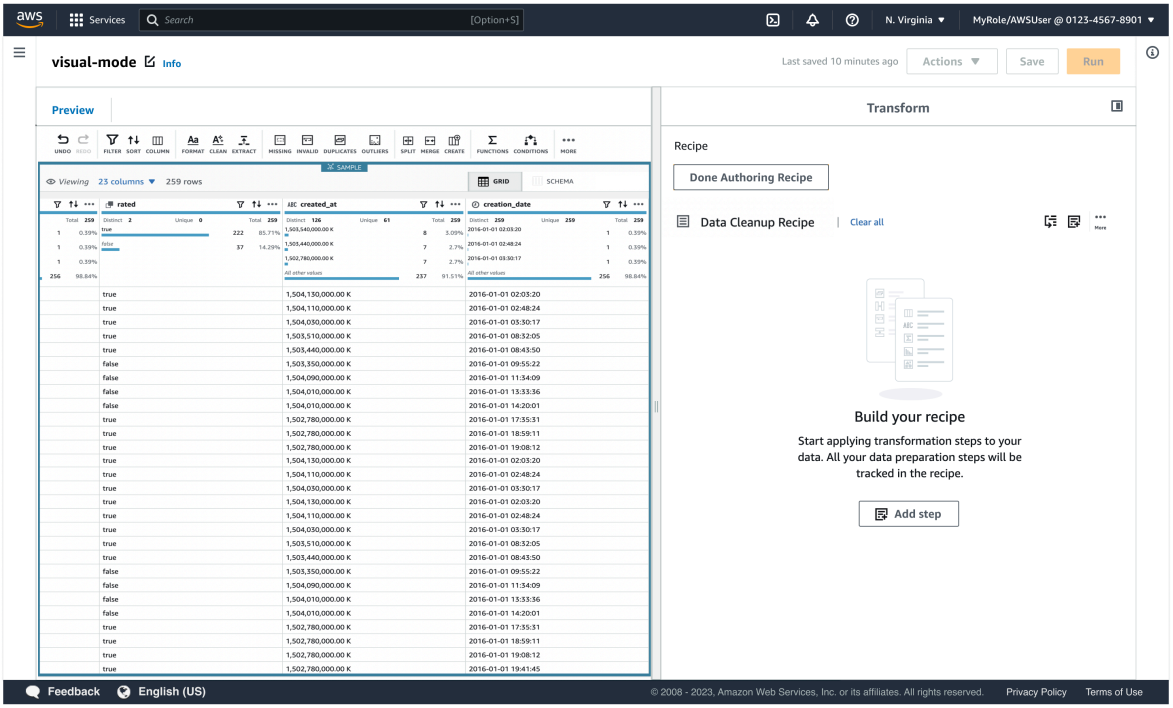

6. En el panel Transformar, puede elegir ordenar, realizar una acción en la columna y filtrar los valores. Por ejemplo, elija Cambiar el nombre de la columna.

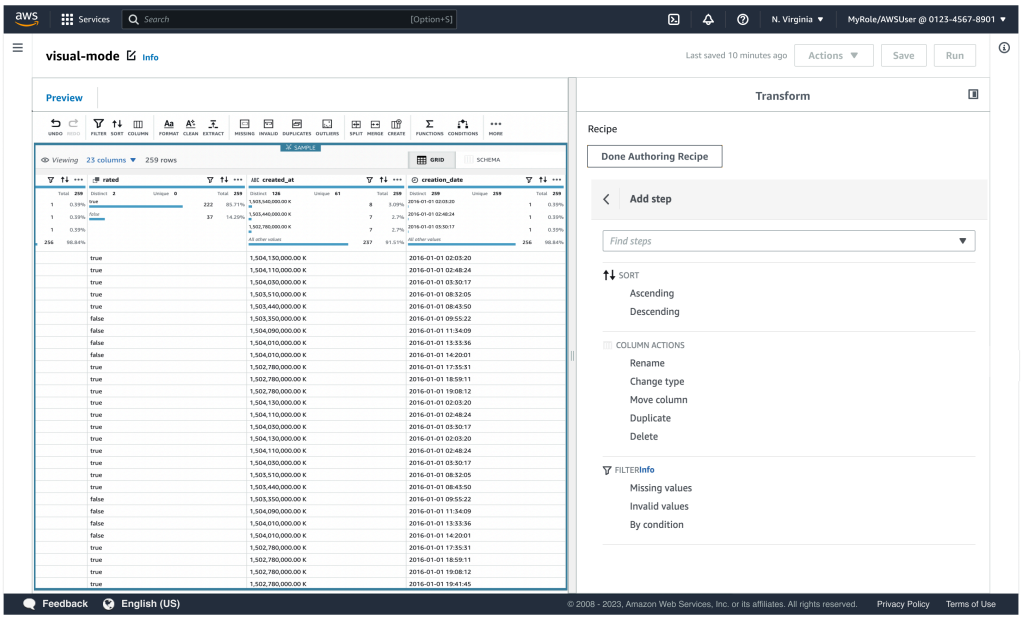

7. En el panel Transformar de la derecha, las opciones para cambiar el nombre de una columna permiten elegir la columna de origen a la que se va a cambiar el nombre e ingresar el nombre de la nueva columna. Una vez que lo haya hecho, elija Aplicar.

   Puede previsualizar cada paso, deshacer un paso y reordenar los pasos, así como utilizar cualquiera de los iconos de acción, como Filtrar, Ordenar, Dividir, Combinar, etc. Al realizar acciones en la cuadrícula de datos, los pasos se agregan a la receta en el panel Transformar.

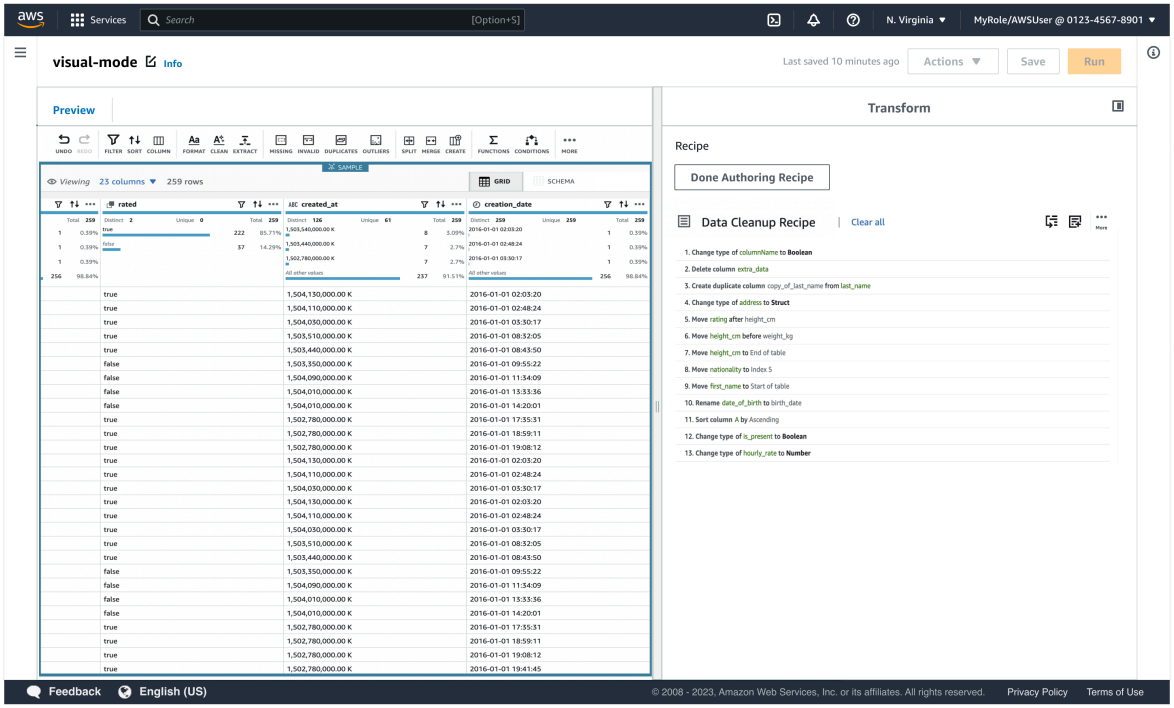

Si necesita hacer algún cambio, puede hacerlo en el panel de vista previa y así previsualizar el resultado de cada paso, deshacer un paso y reordenar los pasos. Por ejemplo:

- Deshacer o rehacer un paso: para deshacer un paso, seleccione el icono de Deshacer. Puede repetir un paso seleccionando el icono de Rehacer.

- Reordenar el paso: cuando reordene un paso, AWS Glue Studio validará cada paso y le avisará si el paso no es válido.

8. Cuando haya aplicado un paso, el panel Transformar le mostrará todos los pasos de la receta. Puede borrar todos los pasos para volver a empezar, agregar más pasos seleccionando el icono de agregar o elegir Finalizar la creación de la receta.

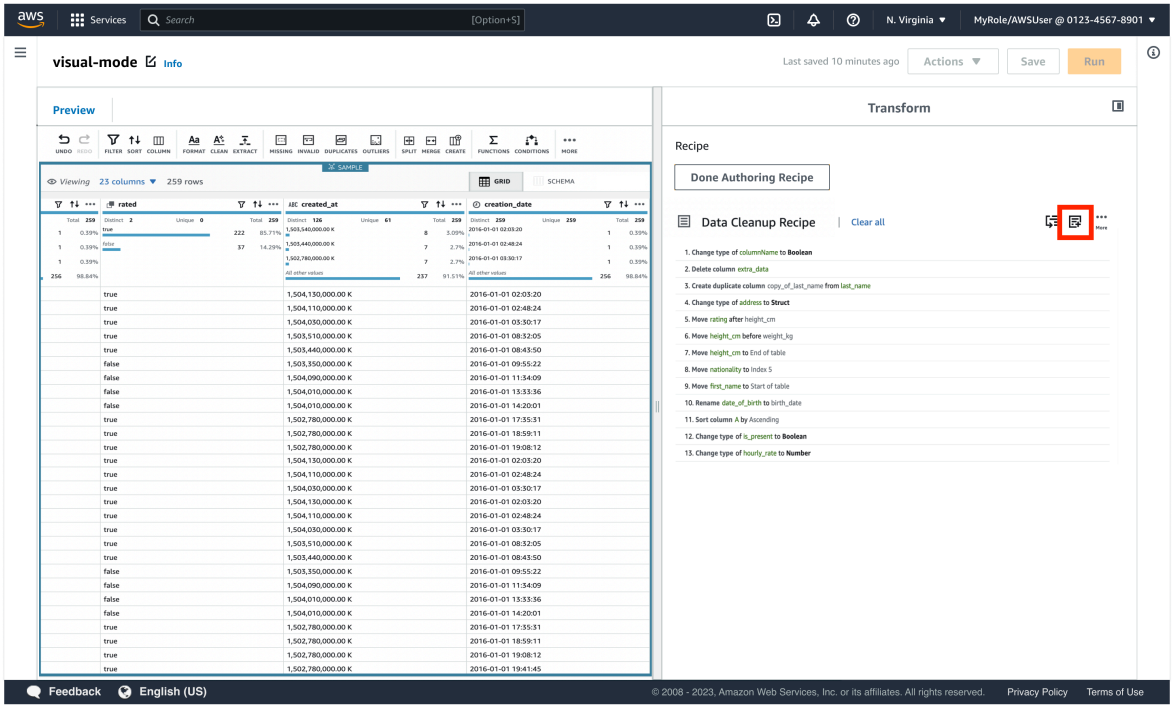

9. Seleccione Guardar en la parte superior derecha de la pantalla. Los pasos de la receta no se guardarán hasta que guarde el trabajo.

Importación de una receta de AWS Glue DataBrew en AWS Glue Studio

En AWS Glue DataBrew, una receta es un conjunto de pasos de transformación de datos. Las recetas de AWS Glue DataBrew indican cómo transformar los datos que ya se han leído y no describen dónde y cómo leer datos, ni cómo y dónde escribirlos. Esto se configura en los nodos de origen y destino en AWS Glue Studio. Para obtener más información sobre las recetas, consulte Creación y uso de recetas de AWS Glue DataBrew.

Para usar recetas de AWS Glue DataBrew en AWS Glue Studio, comience por crear recetas en AWS Glue DataBrew. Puede omitir este paso si ya dispone de las recetas que desea utilizar.

Permisos de IAM para AWS Glue DataBrew

En este tema se proporciona información para ayudarle a comprender las acciones y los recursos que un administrador de IAM puede utilizar en una política de AWS Identity and Access Management (IAM) para la transformación de la receta de preparación de datos.

Para obtener información adicional sobre la seguridad en AWS Glue, consulte Gestión de acceso.

> **Note**
>
> En la siguiente tabla, se enumeran los permisos que necesita un usuario para importar una receta de AWS Glue DataBrew existente.

Acciones de transformación de recetas de preparación de datos

Acción	Descripción
`databrew:ListRecipes`	Concede permiso para recuperar las recetas de AWS Glue DataBrew.
`databrew:ListRecipeVersions`	Concede permiso para recuperar las versiones de una receta de AWS Glue DataBrew.
`databrew:DescribeRecipe`	Concede permiso para recuperar la descripción de una receta de AWS Glue DataBrew.

El rol que utilice para acceder a esta funcionalidad debe tener una política que permita varias acciones de AWS Glue DataBrew. Para ello, puede utilizar la política `AWSGlueConsoleFullAccess` que incluye las acciones necesarias o agregar la siguiente política integrada a su rol:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
```

```
      "Effect": "Allow",
      "Action": [
        "databrew:ListRecipes",
        "databrew:ListRecipeVersions",
        "databrew:DescribeRecipe"
      ],
      "Resource": [
        "*"
      ]
    }
  ]
}
```

Para utilizar la transformación de la receta de preparación de datos, debe agregar la acción de `IAM:PassRole` a la política de permisos.

Permisos necesarios adicionales

Acción	Descripción
`iam:PassRole`	Otorga permiso a IAM para que el usuario pueda pasar las funciones aprobadas.

Sin estos permisos, se produce el siguiente error:

```
"errorCode": "AccessDenied"
"errorMessage": "User: arn:aws:sts::account_id:assumed-role/AWSGlueServiceRole is not
authorized to perform: iam:PassRole on resource: arn:aws:iam::account_id:role/service-
role/AWSGlueServiceRole
because no identity-based policy allows the iam:PassRole action"
```

Importación de una receta de AWS Glue DataBrew

Importación de una receta de AWS Glue DataBrew y utilización en AWS Glue Studio:

Si ya tiene un nodo de receta de preparación de datos y quiere editar los pasos de la receta directamente en AWS Glue Studio, tendrá que importar los pasos de la receta a su trabajo de AWS Glue Studio.

1. Inicie un trabajo de AWS Glue en AWS Glue Studio con un origen de datos.
2. Agregue el nodo Receta de preparación de datos al lienzo de trabajo.

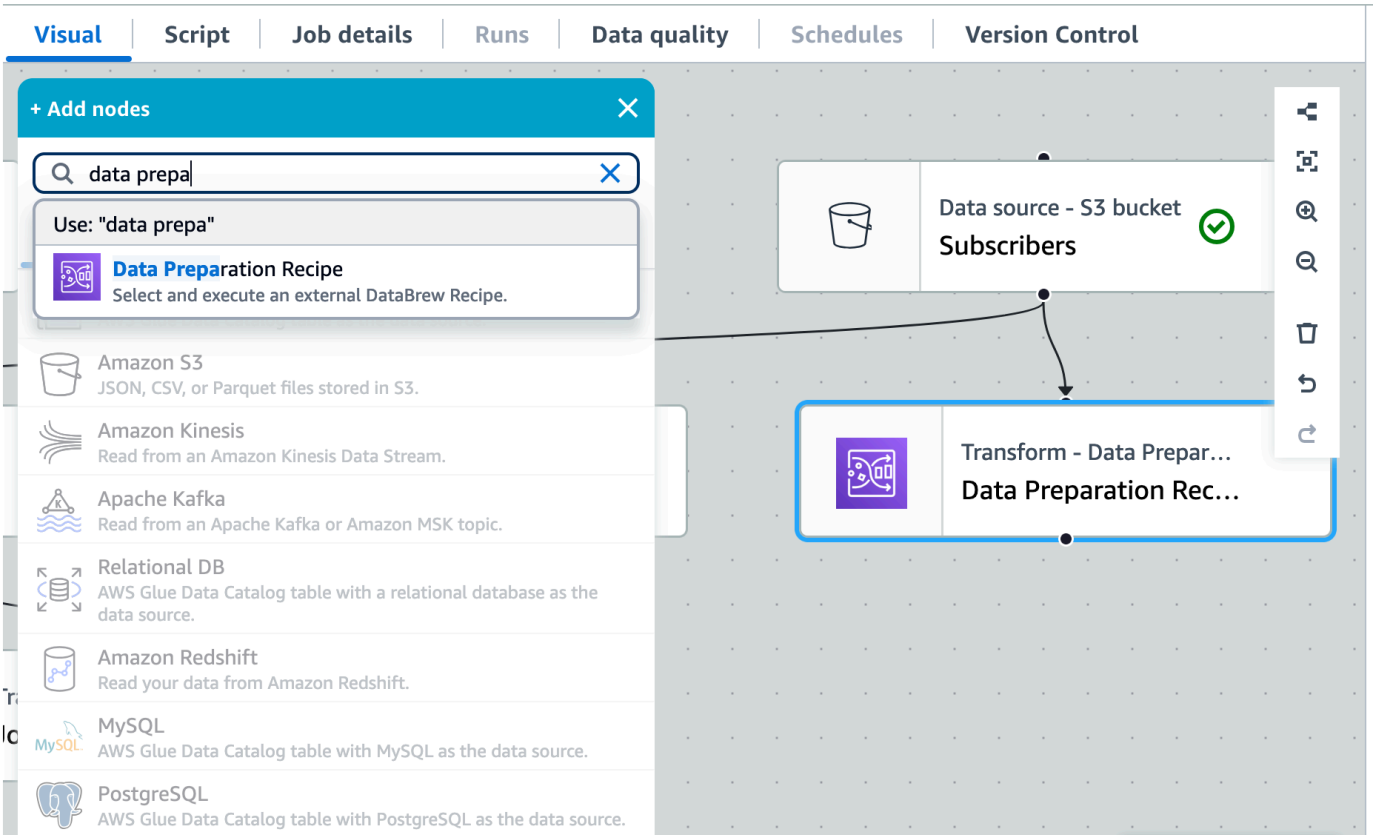

3. En el panel Transformar, escriba un nombre para la receta.
4. Para elegir uno o más nodos principales, seleccione los nodos disponibles en el lienzo en la lista desplegable.
5. Elija Crear receta. Si Crear receta está en gris, no estará disponible hasta que se hayan seleccionado los nodos principales y se haya completado una sesión de vista previa de datos.

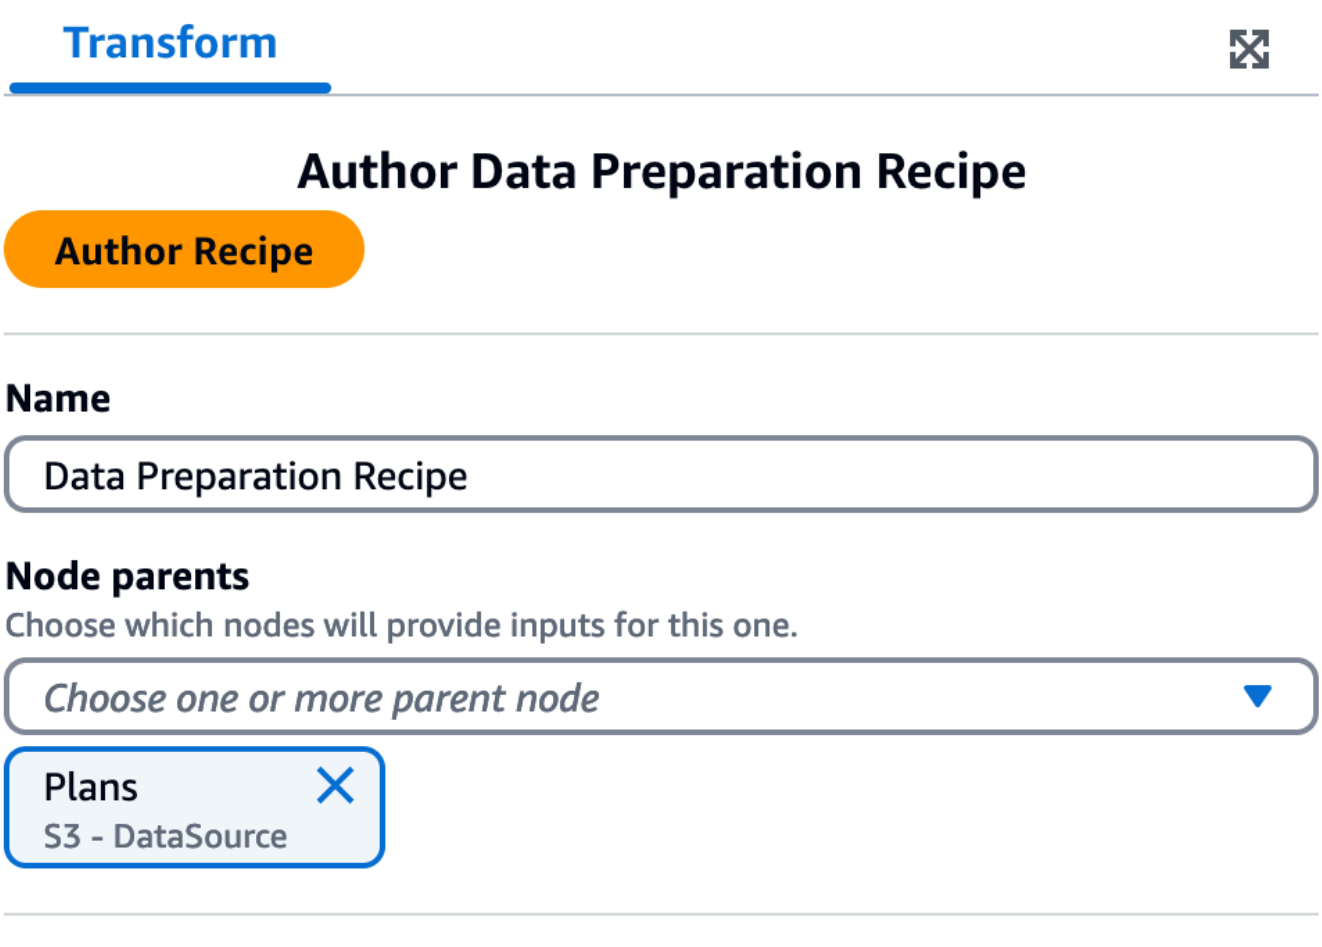

6. El marco de datos se carga y muestra información detallada sobre los datos de origen.

   Seleccione el icono de más acciones y elija Importar receta.

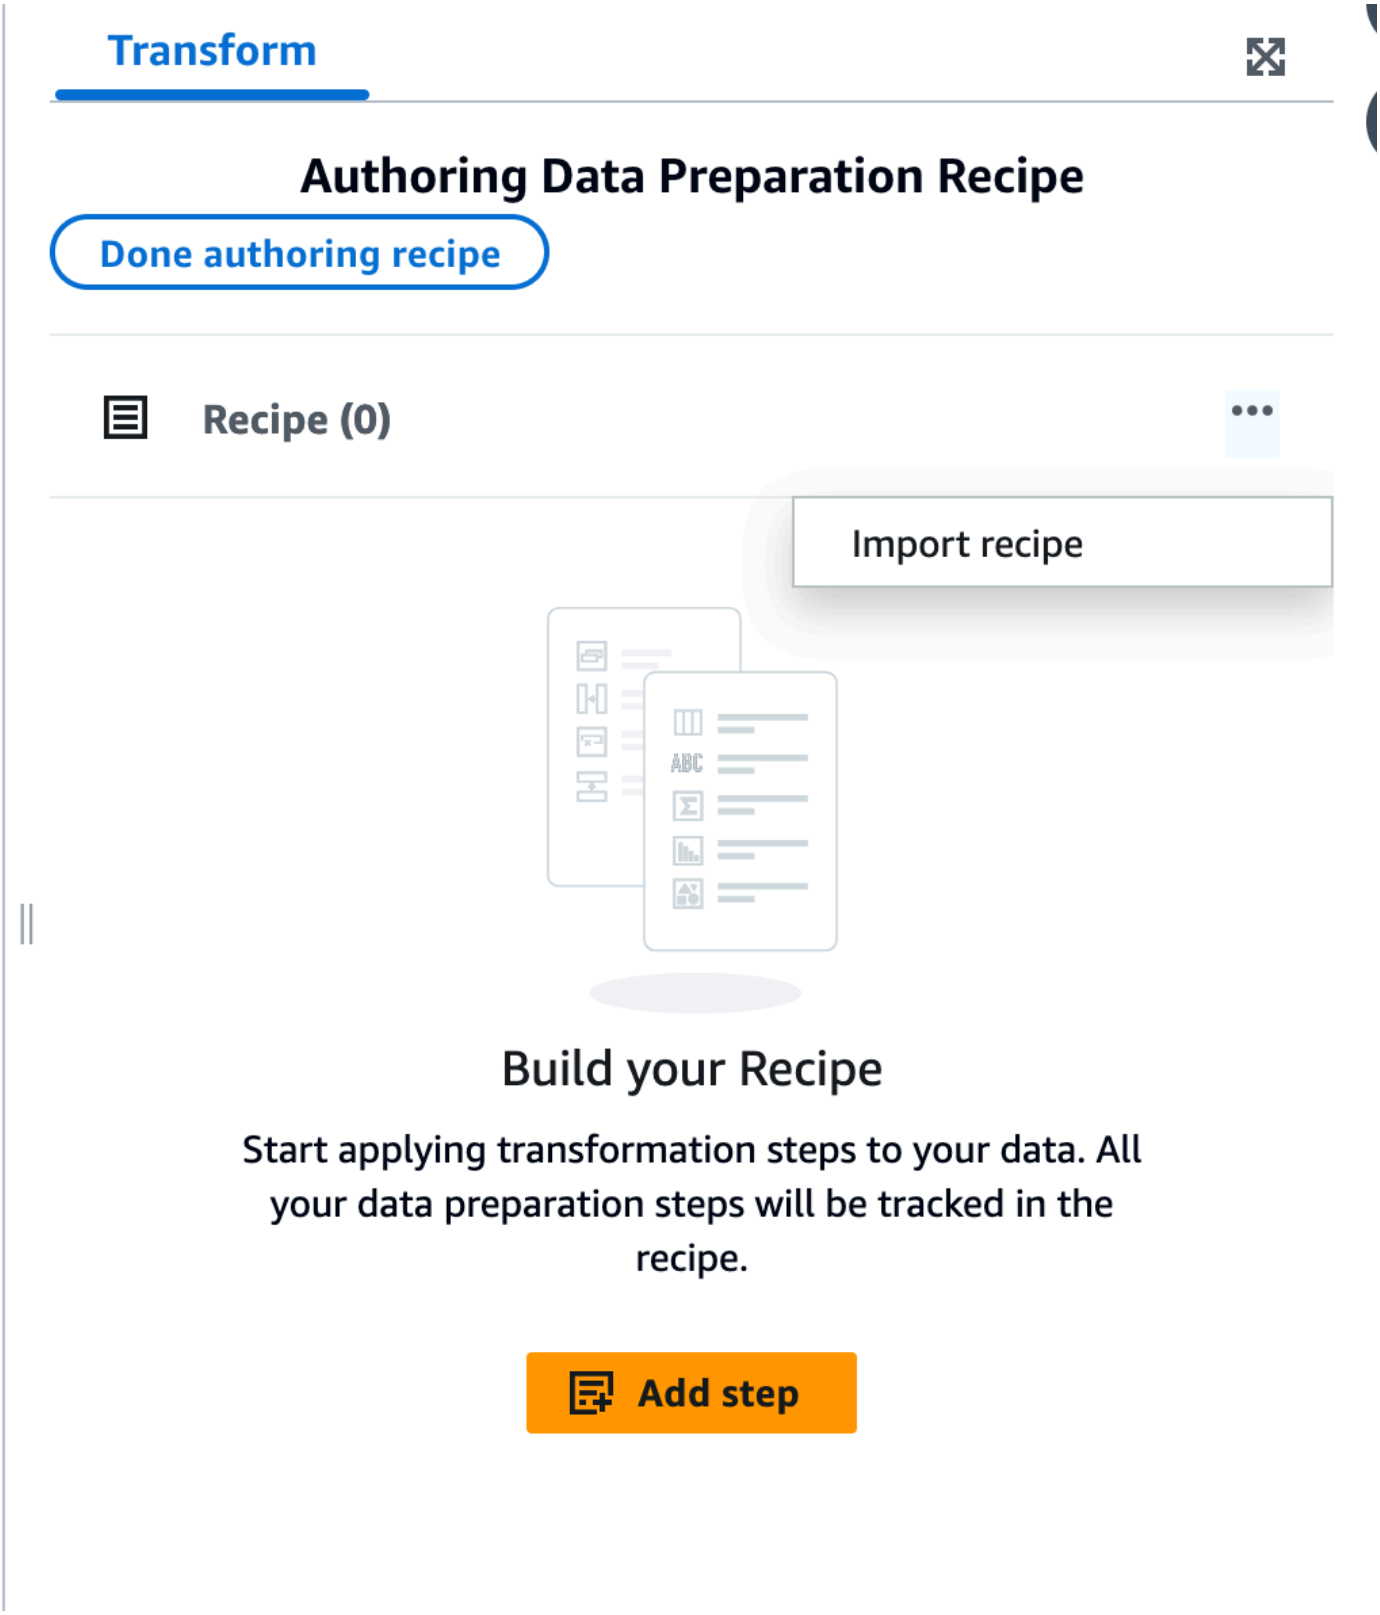

7. Use el asistente de importación de recetas para completar los pasos. En el paso 1, busque su receta, selecciónela y elija Siguiente.

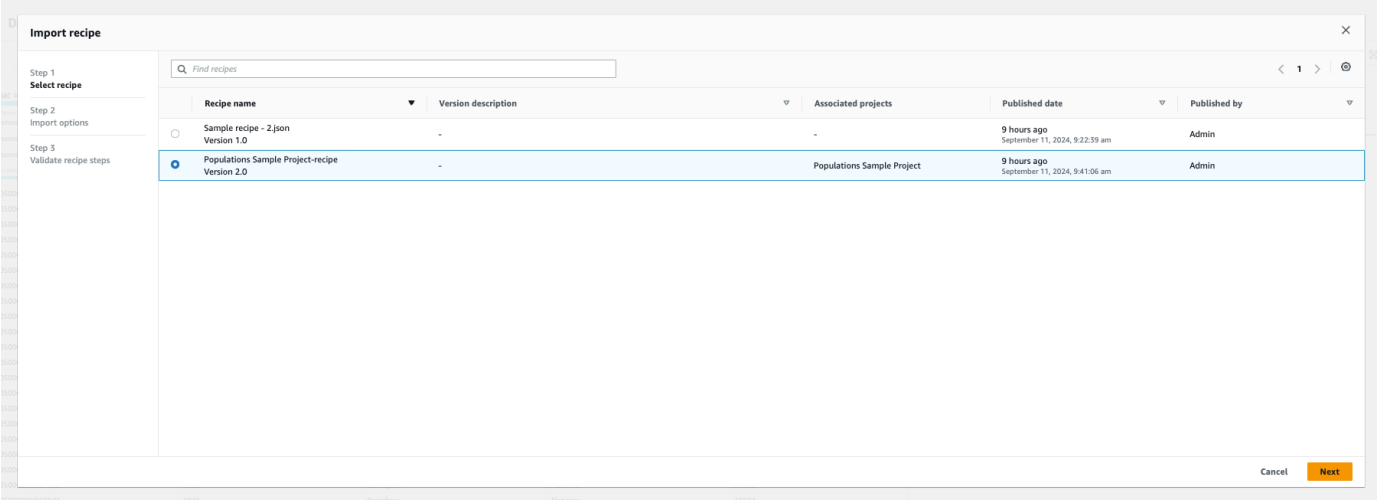

8. En el paso 2, elija sus opciones de importación. Puede agregar una nueva receta a una receta existente o sobrescribir una receta existente. Elija Siguiente.

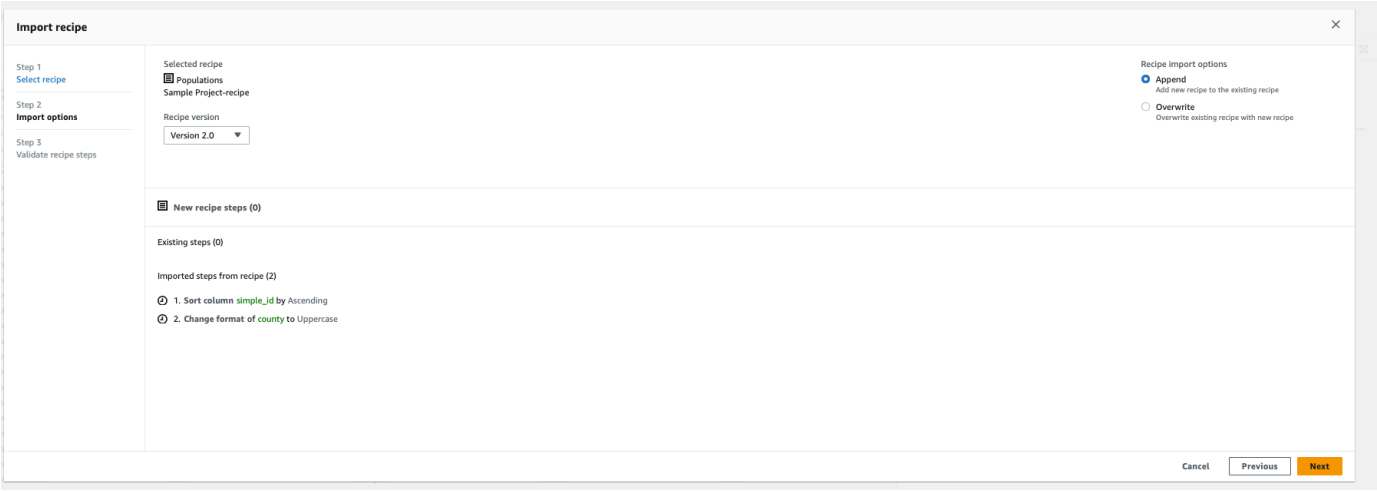

9. En el paso 3, valide los pasos de la receta. Una vez que haya importado la receta de AWS Glue DataBrew, podrá editarla directamente en AWS Glue Studio.

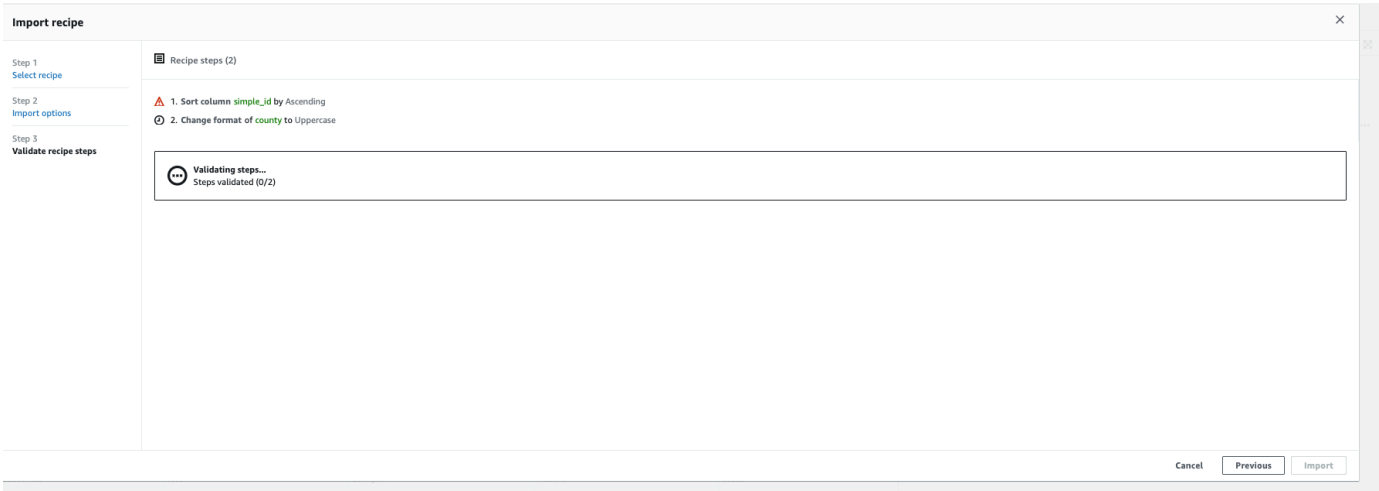

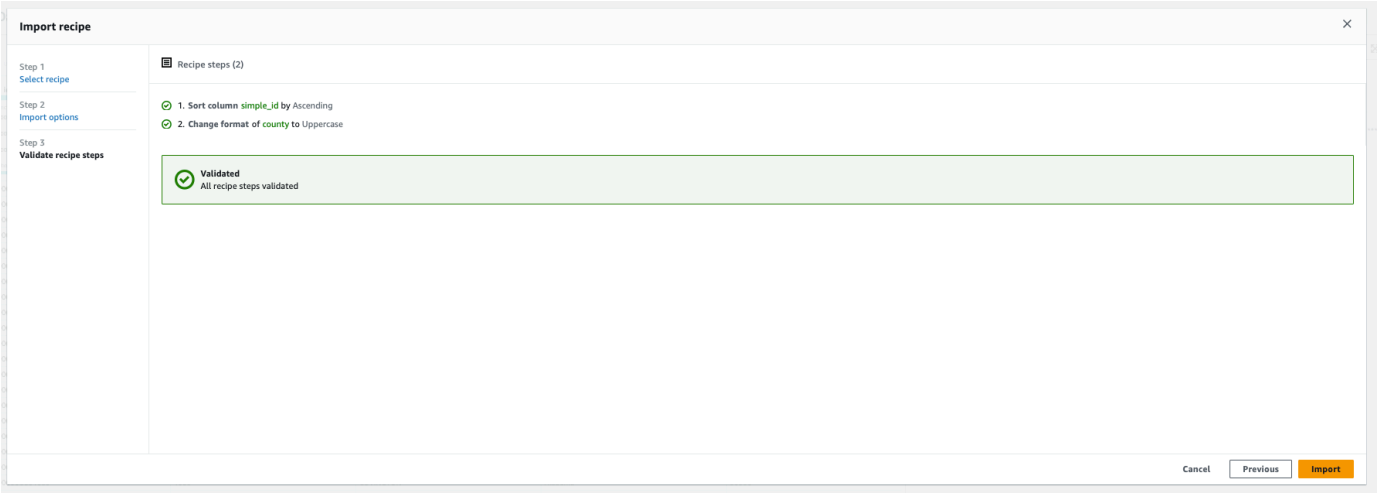

10. Después de esto, los pasos se importarán como parte del trabajo de AWS Glue. Realice los cambios de configuración necesarios en la pestaña Detalles del trabajo, como asignarle un nombre al trabajo y ajustar la capacidad asignada según sea necesario. Seleccione Guardar para guardar el trabajo y la receta.

    > **Note**
    >
    > JOIN, UNION, GROUP_BY, PIVOT, UNPIVOT y TRANSPOSE no son compatibles con la importación de recetas ni estarán disponibles en el modo de creación de recetas.

11. Opcionalmente, puede terminar de crear el trabajo agregando otros nodos de transformación según sea necesario y agregando los nodos de destino de datos.

    Si reordena los pasos después de importar una receta, AWS Glue realiza una validación de esos pasos. Por ejemplo, si cambiara el nombre de una columna y, a continuación, la eliminara, y moviera el paso de eliminación a la parte superior, el paso de cambio de nombre no sería válido. A continuación, puede editar los pasos para corregir el error de validación.

Migración desde AWS Glue DataBrew a AWS Glue Studio

Si tiene recetas en AWS Glue DataBrew, use la siguiente lista de verificación para migrar sus recetas a AWS Glue Studio.

Si desea...	Haga esto
Permitir que los usuarios recuperen recetas de AWS Glue DataBrew, versiones de recetas y descripciones de recetas.	Agregue permisos de IAM a una política que le permita a su rol acceder a las acciones necesarias. Consulte Permisos de IAM para AWS Glue DataBrew.
Importar una receta de AWS Glue DataBrew existente a AWS Glue Studio.	Siga los pasos de Importación de una receta de AWS Glue DataBrew.
Importar una receta con JOIN y UNION.	No se admiten recetas con transformaciones UNION ni JOIN. Use las transformaciones Join y Union en AWS Glue Studio antes o después de un nodo de receta de preparación de datos.

Uso de Cambiar esquema para reasignar claves de propiedades de datos

Una transformación Cambiar esquema vuelve a mapear las claves de propiedad de datos de origen en la configuración deseada para los datos de destino. En un nodo de transformación de Cambiar esquema, puede:

- Cambiar el nombre de varias claves de propiedad de datos.
- Cambiar el tipo de datos de las claves de propiedad de datos, si se soporta el nuevo tipo de datos y existe una ruta de transformación entre los dos tipos de datos.
- Elegir un subconjunto de claves de propiedad de datos al indicar las claves de propiedad de datos que desea descartar.

Puede agregar nodos Cambiar esquema adicionales al diagrama de trabajo según sea necesario, por ejemplo, para modificar orígenes de datos adicionales o luego de una transformación Join.

Uso de Cambiar esquema con un tipo de datos decimal

Cuando se utiliza la transformación Cambiar esquema con un tipo de datos decimal, la transformación Cambiar esquema modifica la precisión al valor predeterminado de (10,2). Para modificarlo y establecer la precisión para su caso de uso, puede usar la transformación Consulta SQL y moldear las columnas con una precisión específica.

Por ejemplo, si tiene una columna de entrada llamada “DecimalCol” de tipo Decimal y desea reasignarla a una columna de salida llamada “OutputDecimalCol” con una precisión específica de (18,6), debería:

1. Agregar una transformación Consulta SQL posterior a la transformación Cambiar esquema.
2. En la transformación Consulta SQL, utilice una consulta SQL para convertir la columna reasignada con la precisión deseada. La consulta SQL debería tener el siguiente aspecto:

   ```
   SELECT col1, col2, CAST(DecimalCol AS DECIMAL(18,6)) AS OutputDecimalCol
   FROM __THIS__
   ```

   En la consulta SQL anterior:

   - “col1” y “col2” son otras columnas de sus datos que desea revisar sin modificarlas.
   - “DecimalCol” es el nombre de la columna original de los datos de entrada.
   - “CAST(DecimalCol AS DECIMAL(18,6))” convierte “DecimalCol” en un tipo decimal con una precisión de 18 dígitos y 6 decimales.
   - “AS OutputDecimalCol” cambia el nombre de la columna convertida a “OutputDecimalCol”.

Al utilizar la transformación Consulta SQL, puede anular la precisión predeterminada establecida por la transformación Cambiar esquema y convertir explícitamente las columnas decimales con la precisión deseada. Este enfoque le permite aprovechar la transformación Cambiar esquema para cambiar el nombre y reestructurar los datos y, al mismo tiempo, administrar los requisitos de precisión de las columnas decimales durante la posterior transformación Consulta SQL.

Agregación de un nodo de transformación Cambiar esquema al diagrama de trabajo

> **Note**
>
> La transformación Cambiar esquema no distingue mayúsculas de minúsculas.

Para agregar un nodo de transformación de Cambiar esquema al diagrama de trabajo

1. (Opcional) abra el panel de recursos y elija Change Schema para agregar una nueva transformación al diagrama de trabajo, si es necesario.

2. En la pestaña Propiedades del nodo, ingrese un nombre para el nodo en el diagrama de trabajo. Si todavía no está seleccionado un nodo principal, elija un nodo de la lista Node parents (Nodos principales) para utilizar como origen de entrada para la transformación.
3. Elija la pestaña Transformación en el panel de detalles del nodo.
4. Modifique el esquema de entrada:
   - Para cambiar el nombre de una clave de propiedad de datos, escriba el nuevo nombre de la clave en el campo Target key (Clave de destino).
   - Para cambiar el tipo de datos de una clave de propiedad de datos, elija el tipo de datos nuevo para la clave de la lista Data type (Tipo de datos).
   - Para eliminar una clave de propiedad de datos del esquema de destino, seleccione la casilla Drop (Descartar) para esa clave.
5. (Opcional) después de configurar las propiedades del nodo de transformación, puede ver el esquema de datos para sus datos al seleccionar la pestaña Output schema (Esquema de salida) en el panel de detalles del nodo. La primera vez que elija esta pestaña para cualquier nodo de trabajo, se le pedirá que proporcione un rol de IAM para acceder a los datos. Si no ha especificado un rol de IAM en Job details (Detalles del trabajo), se le pedirá que ingrese un rol de IAM aquí.
6. (Opcional) después de configurar las propiedades del nodo y las propiedades de transformación, puede obtener una previsualización del conjunto de datos modificado si selecciona la opción Data preview (Previsualización de datos) en el panel de detalles del nodo. La primera vez que elija esta pestaña para cualquier nodo de trabajo, se le pedirá que proporcione un rol de IAM para acceder a los datos. Hay un costo asociado con el uso de este recurso y la facturación comienza tan pronto como proporcione un rol de IAM.

Uso de Eliminar duplicados

La transformación Eliminar duplicados elimina las filas del origen de datos ofreciéndole dos opciones. Puede eliminar la fila duplicada que sea completamente igual o elegir los campos que desee que coincidan y eliminar solo las filas en función de los campos que haya elegido.

Por ejemplo, en este conjunto de datos, tiene filas duplicadas en las que todos los valores de algunas filas son exactamente iguales a los de otra fila y algunos de los valores de las filas son iguales o diferentes.

Fila	Nombre	Correo electrónico	Edad	Estado	Nota
1	Alegría	alegría@gmail	33	NY	
2	Tim	tim@gmail	45	OH	
3	Rosa	rosa@gmail	23	NJ	
4	Tim	tim@gmail	42	OH	
5	Rosa	rosa@gmail	23	NJ	
6	Tim	tim@gmail	42	OH	se trata de una fila duplicada y coincide completamente con todos los valores de la fila #4
7	Rosa	rosa@gmail	23	NJ	Se trata de una fila duplicada y coincide completamente con todos los valores de la fila #5

Si opta por hacer coincidir filas enteras, las filas 6 y 7 se eliminarán del conjunto de datos. El conjunto de datos ahora es el siguiente:

Fila	Nombre	Correo electrónico	Edad	Estado
1	Alegría	alegría@gmail	33	NY
2	Tim	tim@gmail	45	OH
3	Rosa	rosa@gmail	23	NJ
4	Tim	tim@gmail	42	OH
5	Rosa	rosa@gmail	23	NJ

Si opta por especificar las claves, puede optar por eliminar las filas que coincidan con las palabras “nombre” y “correo electrónico”. Esto permite controlar mejor qué es una “fila duplicada” para el conjunto de datos. Al especificar “nombre” y “correo electrónico”, el conjunto de datos ahora es el siguiente:

Fila	Nombre	Correo electrónico	Edad	Estado
1	Alegría	alegría@gmail	33	NY
2	Tim	tim@gmail	45	OH
3	Rosa	rosa@gmail	23	NJ

Algunas cosas a tener en cuenta:

- Para que las filas se reconozcan como duplicadas, los valores distinguen entre mayúsculas y minúsculas. Todos los valores de las filas deben tener las mismas mayúsculas y minúsculas; esto se aplica a cualquier opción que elija (hacer coincidir filas enteras o Especificar claves).
- Todos los valores se leen como cadenas.
- La transformación Eliminar duplicados utiliza el comando dropDuplicates de Spark.
- Cuando se utiliza la transformación Eliminar duplicados, la primera fila se mantiene y las demás filas se eliminan.

- La transformación Eliminar duplicados no cambia el esquema del marco de datos. Si decide especificar claves, todos los campos se mantienen en el marco de datos resultante.

Uso de SelectFields (Seleccionar campos) para eliminar la mayoría de las claves de propiedad de datos

Puede crear un subconjunto de claves de propiedad de datos a partir del conjunto de datos mediante la transformación Seleccionar campos. Indique qué claves de propiedad de datos desea conservar y el resto se eliminan del conjunto de datos.

> **Note**
>
> La transformación Seleccionar campos distingue entre mayúsculas y minúsculas. Use ApplyMapping (Aplicar mapeo) si necesita una forma que no distinga entre mayúsculas y minúsculas para seleccionar campos.

Para agregar un nodo de transformación Seleccionar campos al diagrama de trabajo

1. (Opcional) abra el panel de recursos y elija SelectFields para agregar una nueva transformación al diagrama de trabajo, si es necesario.
2. En la pestaña Node properties (Propiedades del nodo), ingrese un nombre para el nodo en el diagrama de trabajo. Si todavía no se ha seleccionado un nodo principal, elija un nodo de la lista Node parents (Nodos principales) para utilizar como origen de entrada para la transformación.
3. Elija la pestaña Transform (Transformación) en el panel de detalles del nodo.
4. En el encabezado SelectFields (Seleccionar campos) elija las claves de propiedad de datos en el conjunto de datos que desea conservar. Las claves de propiedad de datos no seleccionadas se descartan del conjunto de datos.

   También puede seleccionar la casilla junto al encabezado de la columna Field (Campo) para elegir automáticamente todas las claves de propiedad de datos en el conjunto de datos. Luego, puede anular la selección de claves de propiedad de datos individuales para eliminarlas del conjunto de datos.
5. (Opcional) después de configurar las propiedades del nodo de transformación, puede ver el esquema de datos para sus datos al seleccionar la pestaña Output schema (Esquema de salida) en el panel de detalles del nodo. La primera vez que elija esta pestaña para cualquier

nodo de trabajo, se le pedirá que proporcione un rol de IAM para acceder a los datos. Si no ha especificado un rol de IAM en Job details (Detalles del trabajo), se le pedirá que ingrese un rol de IAM aquí.

6. (Opcional) después de configurar las propiedades del nodo y las propiedades de transformación, puede obtener una previsualización del conjunto de datos modificado si selecciona la opción Data preview (Previsualización de datos) en el panel de detalles del nodo. La primera vez que elija esta pestaña para cualquier nodo de trabajo, se le pedirá que proporcione un rol de IAM para acceder a los datos. Hay un costo asociado con el uso de este recurso y la facturación comienza tan pronto como proporcione un rol de IAM.

Uso de DropFields (Descartar campos) para mantener la mayoría de las claves de propiedad

Puede crear un subconjunto de claves de propiedad de datos a partir del conjunto de datos mediante la transformación Descartar campos. Indique qué claves de propiedad de datos desea eliminar del conjunto de datos y el resto de las claves se conservan.

> **Note**
>
> La transformación Descartar campos distingue entre mayúsculas y minúsculas. Use Cambiar esquema si necesita una forma insensible a mayúsculas y minúsculas para seleccionar campos.

Para agregar un nodo de transformación Descartar campos al diagrama de trabajo

1. (Opcional) abra el panel de recursos y elija DropFields para agregar una nueva transformación al diagrama de trabajo, si es necesario.
2. En la pestaña Node properties (Propiedades del nodo), ingrese un nombre para el nodo en el diagrama de trabajo. Si todavía no se ha seleccionado un nodo principal, elija un nodo de la lista Node parents (Nodos principales) para utilizar como origen de entrada para la transformación.
3. Elija la pestaña Transform (Transformación) en el panel de detalles del nodo.
4. En el encabezado DropFields (Descartar campos), elija las claves de propiedad de datos que desea descartar del origen de datos.

   También puede seleccionar la casilla junto al encabezado de la columna Field (Campo) para elegir automáticamente todas las claves de propiedad de datos en el conjunto de datos. Luego,

puede anular la selección de claves de propiedad de datos individuales para que se conserven en el conjunto de datos.

5. (Opcional) después de configurar las propiedades del nodo de transformación, puede ver el esquema de datos para sus datos al seleccionar la pestaña Output schema (Esquema de salida) en el panel de detalles del nodo. La primera vez que elija esta pestaña para cualquier nodo de trabajo, se le pedirá que proporcione un rol de IAM para acceder a los datos. Si no ha especificado un rol de IAM en Job details (Detalles del trabajo), se le pedirá que ingrese un rol de IAM aquí.
6. (Opcional) después de configurar las propiedades del nodo y las propiedades de transformación, puede obtener una previsualización del conjunto de datos modificado si selecciona la opción Data preview (Previsualización de datos) en el panel de detalles del nodo. La primera vez que elija esta pestaña para cualquier nodo de trabajo, se le pedirá que proporcione un rol de IAM para acceder a los datos. Hay un costo asociado con el uso de este recurso y la facturación comienza tan pronto como proporcione un rol de IAM.

Cambio de nombre de un campo en el conjunto de datos

Puede utilizar la transformación RenameField (Renombrar campo) para cambiar el nombre de una clave de propiedad individual en el conjunto de datos.

> **Note**
>
> La transformación Renombrar campo distingue entre mayúsculas y minúsculas. Use ApplyMapping (Aplicar mapeo) si necesita una transformación que no distinga entre mayúsculas y minúsculas.

> **Tip**
>
> Si utiliza la transformación Cambiar Esquema, puede cambiar el nombre de varias claves de propiedad de datos en el conjunto de datos con una única transformación.

Para agregar un nodo de transformación Renombrar campo al diagrama de trabajo

1. (Opcional) abra el panel de recursos y elija RenameField para agregar una nueva transformación al diagrama de trabajo, si es necesario.

2. En la pestaña Node properties (Propiedades del nodo), ingrese un nombre para el nodo en el diagrama de trabajo. Si todavía no se ha seleccionado un nodo principal, elija un nodo de la lista Node parents (Nodos principales) para utilizar como origen de entrada para la transformación.
3. Elija la pestaña Transform (Transformación).
4. En el encabezado Data field (Campo de datos), elija una clave de propiedad de los datos de origen y, a continuación, escriba un nuevo nombre en el cuadro New field name (Nombre de campo nuevo).
5. (Opcional) después de configurar las propiedades del nodo de transformación, puede ver el esquema de datos para sus datos al seleccionar la pestaña Output schema (Esquema de salida) en el panel de detalles del nodo. La primera vez que elija esta pestaña para cualquier nodo de trabajo, se le pedirá que proporcione un rol de IAM para acceder a los datos. Si no ha especificado un rol de IAM en Job details (Detalles del trabajo), se le pedirá que ingrese un rol de IAM aquí.
6. (Opcional) después de configurar las propiedades del nodo y las propiedades de transformación, puede obtener una previsualización del conjunto de datos modificado si selecciona la opción Data preview (Previsualización de datos) en el panel de detalles del nodo. La primera vez que elija esta pestaña para cualquier nodo de trabajo, se le pedirá que proporcione un rol de IAM para acceder a los datos. Hay un costo asociado con el uso de este recurso y la facturación comienza tan pronto como proporcione un rol de IAM.

Uso de Spigot para tomar muestras del conjunto de datos

Para probar las transformaciones realizadas por el trabajo, es posible que desee obtener una muestra de los datos para comprobar que la transformación funciona según lo previsto. La transformación Spigot escribe un subconjunto de registros del conjunto de datos en un archivo JSON en un bucket de Amazon S3. El método de muestreo de datos puede ser un número especificado de registros del principio del archivo o un factor de probabilidad utilizado para elegir los registros.

Para agregar un nodo de transformación Spigot al diagrama de trabajo

1. (Opcional) abra el panel de recursos y elija Spigot para agregar una nueva transformación al diagrama de trabajo, si es necesario.
2. En la pestaña Node properties (Propiedades del nodo), ingrese un nombre para el nodo en el diagrama de trabajo. Si todavía no se ha seleccionado un nodo principal, elija un nodo de la lista Node parents (Nodos principales) para utilizar como origen de entrada para la transformación.
3. Elija la pestaña Transform (Transformación) en el panel de detalles del nodo.

4. Escriba una ruta de Amazon S3 o elija Browse S3 (Examinar S3) para elegir una ubicación en Amazon S3. Esta es la ubicación donde el trabajo escribe el archivo JSON que contiene la muestra de datos.
5. Ingrese la información para el método de muestreo. Puede especificar un valor para Number of records (Número de registros) que se escribirá desde el principio del conjunto de datos y un Probability threshold (Umbral de probabilidad) (que se ingresa como un valor decimal con un valor máximo de 1) para seleccionar cualquier registro determinado.

   Por ejemplo, para escribir los primeros 50 registros del conjunto de datos, debe establecer Number of records en 50 y Probability threshold en 1 (100 %).

Combinación de conjuntos de datos

La transformación Join (Combinación) le permite combinar dos conjuntos de datos en uno. Especifique los nombres de clave en el esquema de cada conjunto de datos que desea comparar. El `DynamicFrame` de salida contiene las filas donde las claves cumplen la condición de combinación. Las filas de cada conjunto de datos que cumplen con la condición de combinación se combinan en una sola fila en el `DynamicFrame` de salida que contiene todas las columnas encontradas en cualquiera de los conjuntos de datos.

Para agregar un nodo de transformación de combinación al diagrama de trabajo

1. Si sólo hay un origen de datos disponible, debe agregar un nuevo nodo de origen de datos al diagrama de trabajo.
2. Elija uno de los nodos de origen para la combinación. Abra el panel de recursos y, a continuación, elija Unir para agregar una nueva transformación al diagrama de trabajo.
3. En la pestaña Node properties (Propiedades del nodo), ingrese un nombre para el nodo en el diagrama de trabajo.
4. En la pestaña Node properties (Propiedades del nodo), en el encabezado Node parents (Nodos principales), agregue un nodo principal para que haya dos conjuntos de datos que proporcionen entradas para la combinación. El principal puede ser un nodo de origen de datos o un nodo de transformación.

> **Note**
>
> Una combinación sólo puede tener dos nodos principales.

5. Elija la pestaña Transform (Transformación).

   Si aparece un mensaje que indica que hay nombres de clave conflictivos, puede:

   - Seleccionar Resolve it (Resolver) para agregar automáticamente un nodo de transformación ApplyMapping (Aplicar mapeo) en el diagrama de trabajo. El nodo Aplicar mapeo agrega un prefijo a cualquier clave del conjunto de datos que tenga el mismo nombre que una clave del otro conjunto de datos. Por ejemplo, si utiliza el valor predeterminado de **`right`**, cualquier clave en el conjunto de datos derecho que tenga el mismo nombre que una clave en el conjunto de datos izquierdo cambiará de nombre a `(right)`*`key name`*.
   - Agregue manualmente un nodo de transformación con anterioridad en el diagrama de trabajo para eliminar o cambiar el nombre de las claves en conflicto.

6. Elija el tipo de combinación en la lista Join type (Tipo de combinación).

   - Inner join (Combinación interna): devuelve una fila con columnas de ambos conjuntos de datos para cada coincidencia basada en la condición de combinación. Las filas que no satisfacen la condición de combinación no se devuelven.
   - Left join (Combinación izquierda): todas las filas del conjunto de datos izquierdo y solo las filas del conjunto de datos derecho que satisfacen la condición de combinación.
   - Right join (Combinación derecha): todas las filas del conjunto de datos derecho y solo las filas del conjunto de datos izquierdo que satisfacen la condición de combinación.
   - Outer join (Combinación externa): todas las filas de ambos conjuntos de datos.
   - Left semi join (Semicombinación izquierda): todas las filas del conjunto de datos izquierdo que tienen una coincidencia en el conjunto de datos derecho en función de la condición de combinación.
   - Left anti join (Anticombinación izquierda): todas las filas del conjunto de datos izquierdo que no tienen una coincidencia en el conjunto de datos derecho en función de la condición de combinación.

7. En la pestaña Transform (Transformación), en el encabezado Join conditions (Condiciones de combinación), elija Add condition (Agregar condición). Elija una clave de propiedad de cada conjunto de datos para comparar. Las claves de propiedad en el lado izquierdo del operador de comparación se conocen como el conjunto de datos izquierdo y las claves de propiedad de la derecha se denominan conjunto de datos derecho.

   Para condiciones de combinación más complejas, puede agregar claves coincidentes adicionales al seleccionar Add condition (Agregar condición) más de una vez.

Si agrega una condición por accidente, puede elegir el ícono de eliminación
( )
para eliminarla.

8. (Opcional) después de configurar las propiedades del nodo de transformación, puede ver el esquema de datos para sus datos al seleccionar la pestaña Output schema (Esquema de salida) en el panel de detalles del nodo. La primera vez que elija esta pestaña para cualquier nodo de trabajo, se le pedirá que proporcione un rol de IAM para acceder a los datos. Si no ha especificado un rol de IAM en Job details (Detalles del trabajo), se le pedirá que ingrese un rol de IAM aquí.
9. (Opcional) después de configurar las propiedades del nodo y las propiedades de transformación, puede obtener una previsualización del conjunto de datos modificado si selecciona la opción Data preview (Previsualización de datos) en el panel de detalles del nodo. La primera vez que elija esta pestaña para cualquier nodo de trabajo, se le pedirá que proporcione un rol de IAM para acceder a los datos. Hay un costo asociado con el uso de este recurso y la facturación comienza tan pronto como proporcione un rol de IAM.

Para obtener un ejemplo del esquema de salida de combinación, considere una combinación entre dos conjuntos de datos con las siguientes claves de propiedad:

```
Left: {id, dept, hire_date, salary, employment_status}
Right: {id, first_name, last_name, hire_date, title}
```

La combinación está configurada para que coincida en las claves `id` y `hire_date` mediante el operador de comparación =.

Debido a que ambos conjuntos de datos contienen claves `id` y `hire_date`, debe elegir Resolve it (Resolver) para agregar automáticamente el prefijo **`right`** a las claves del conjunto de datos correcto.

Las claves en el esquema de salida serían:

```
{id, dept, hire_date, salary, employment_status,
(right)id, first_name, last_name, (right)hire_date, title}
```

Uso de Unión para combinar filas

El nodo de transformación Unión se utiliza cuando se desean combinar filas de más de un origen de datos que tienen el mismo esquema.

Existen dos tipos de transformaciones de Unión:

1. ALL: al aplicar ALL, la unión resultante no elimina filas duplicadas.
2. DISTINCT: al aplicar DISTINTO, la unión resultante elimina las filas duplicadas.

Uniones versus Combinaciones

Se usa Union para combinar filas. Se utiliza Combinar para combinar columnas.

Uso de la transformación Unión en el lienzo de Visual ETL

1. Agregue más de un origen de datos para realizar una transformación de unión. Para agregar un origen de datos, abra el panel de recursos y, a continuación, elija el origen de datos en la pestaña Fuentes. Antes de usar la transformación de Unión, debe asegurarse de que todos los orígenes de datos involucradas en la unión tengan el mismo esquema y estructura.
2. Si tiene al menos dos orígenes de datos que desee combinar mediante la transformación Unión, cree la transformación Unión al agregarla al lienzo. Abre el panel de recursos en el lienzo y busca “Unión”. También puedes elegir la pestaña Transformaciones del panel de recursos y desplazarte hacia abajo hasta encontrar la transformación de Unión y, a continuación, elegir Unión.
3. Seleccione el nodo Unión en el lienzo de trabajo. En la ventana de propiedades del nodo, elija los nodos principales para conectarse a la transformación de Unión.
4. AWS Glue comprueba la compatibilidad para garantizar que la transformación de Unión se pueda aplicar a todas los orígenes de datos. Si el esquema de los orígenes de datos es el mismo, se permitirá la operación. Si los orígenes de datos no tienen el mismo esquema, aparece un mensaje de error no válido: “Los esquemas de entrada de esta unión no son los mismos. Considere la posibilidad de utilizar ApplyMapping para que coincida con los esquemas”. Para solucionar este problema, selecciona utilizar ApplyMapping.
5. Seleccione el tipo de Unión.
    1. Todas: de forma predeterminada, se selecciona el tipo de unión Todas; esto resultará en filas duplicadas si las hay en la combinación de datos.
    2. Distinto: elija Distinto si desea eliminar las filas duplicadas de la combinación de datos resultante.

Uso de SplitFields (Dividir campos) para dividir un conjunto de datos en dos

La transformación SplitFields (Dividir campos) le permite elegir algunas de las claves de propiedad de datos en el conjunto de datos de entrada para ponerlas en un conjunto de datos y colocar las claves no seleccionadas en otro conjunto de datos independiente. La salida de esta transformación es una recopilación de `DynamicFrames`.

> **Note**
>
> Debe utilizar la transformación SelectFromCollection (Seleccionar desde la recopilación) para convertir la recopilación de `DynamicFrames` en un solo `DynamicFrame` antes de enviar la salida a una ubicación de destino.

La transformación Dividir campos distingue entre mayúsculas y minúsculas. Agregue una transformación ApplyMapping (Aplicar mapeo)como nodo principal si necesita nombres de clave de propiedad que no distingan entre mayúsculas y minúsculas.

Para agregar un nodo de transformación Dividir campos al diagrama de trabajo

1. (Opcional) abra el panel de recursos y elija SplitFields para agregar una nueva transformación al diagrama de trabajo, si es necesario.
2. En la pestaña Node properties (Propiedades del nodo), ingrese un nombre para el nodo en el diagrama de trabajo. Si todavía no se ha seleccionado un nodo principal, elija un nodo de la lista Node parents (Nodos principales) para utilizar como origen de entrada para la transformación.
3. Elija la pestaña Transform (Transformación).
4. Elija las claves de propiedad que desea poner en el primer conjunto de datos. Las claves que no elija se colocan en el segundo conjunto de datos.
5. (Opcional) después de configurar las propiedades del nodo de transformación, puede ver el esquema de datos para sus datos al seleccionar la pestaña Output schema (Esquema de salida) en el panel de detalles del nodo. La primera vez que elija esta pestaña para cualquier nodo de trabajo, se le pedirá que proporcione un rol de IAM para acceder a los datos. Si no ha especificado un rol de IAM en Job details (Detalles del trabajo), se le pedirá que ingrese un rol de IAM aquí.
6. (Opcional) después de configurar las propiedades del nodo y las propiedades de transformación, puede obtener una previsualización del conjunto de datos modificado si selecciona la opción Data preview (Previsualización de datos) en el panel de detalles del nodo. La primera vez que

elija esta pestaña para cualquier nodo de trabajo, se le pedirá que proporcione un rol de IAM para acceder a los datos. Hay un costo asociado con el uso de este recurso y la facturación comienza tan pronto como proporcione un rol de IAM.

7. Configure un nodo de transformación SelectFromCollection (Seleccionar desde la recopilación) para procesar los conjuntos de datos resultantes.

Información general de la transformación SelectFromCollection

Algunas transformaciones tienen múltiples conjuntos de datos como salida en lugar de un único conjunto de datos, por ejemplo, Dividir campos. La transformación Seleccionar desde recopilación selecciona un conjunto de datos (`DynamicFrame`) desde una recopilación de conjuntos de datos (una matriz de `DynamicFrames`). El resultado de la transformación es el `DynamicFrame` seleccionado.

Debe utilizar esta transformación después de utilizar una transformación que crea una recopilación de `DynamicFrames`, por ejemplo:

- Transformaciones de código personalizado
- SplitFields

Si no agrega un nodo de transformación Seleccionar desde recopilación a su diagrama de trabajo después de cualquiera de estas transformaciones, su trabajo arrojará error.

El nodo principal de esta transformación debe ser un nodo que devuelve una recopilación de `DynamicFrames`. Si elige un nodo principal para este nodo de transformación que devuelve un único `DynamicFrame`, como una transformación Combinación, su trabajo arroja un error.

Del mismo modo, si usa un nodo Seleccionar desde recopilación en el diagrama de trabajo como nodo principal de una transformación que espera un único `DynamicFrame` como entrada, su trabajo arroja un error.

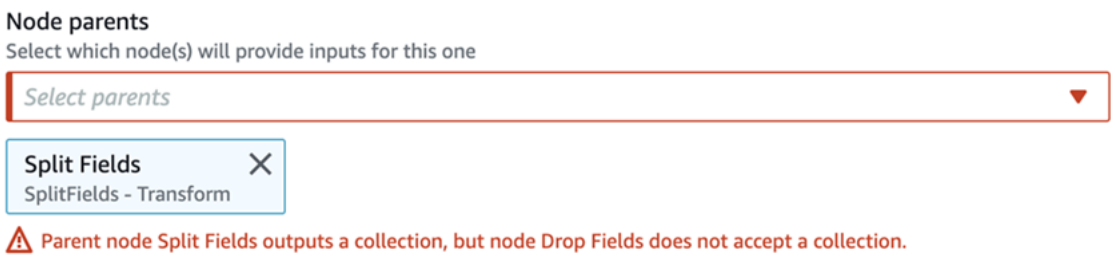

Uso de SelectFromCollection (Seleccionar desde la recopilación) para elegir qué conjunto de datos desea mantener

Use la transformación Seleccionar desde recopilación para convertir una recopilación de `DynamicFrames` en un solo `DynamicFrame`.

Para agregar un nodo de transformación Seleccionar desde recopilación al diagrama de trabajo

1. (Opcional) abra el panel de recursos y elija SelectFromCollection para agregar una nueva transformación al diagrama de trabajo, si es necesario.
2. En la pestaña Node properties (Propiedades del nodo), ingrese un nombre para el nodo en el diagrama de trabajo. Si todavía no se ha seleccionado un nodo principal, elija un nodo de la lista Node parents (Nodos principales) para utilizar como origen de entrada para la transformación.
3. Elija la pestaña Transform (Transformación).
4. En el encabezado Frame index (Índice del marco), elija el número de índice de la matriz que corresponde al `DynamicFrame` que desea seleccionar de la recopilación de `DynamicFrames`.

   Por ejemplo, si el nodo principal de esta transformación es Dividir campos, podrá ver el esquema para cada `DynamicFrame` en la pestaña Output schema (Esquema de salida) del nodo. Si desea mantener el `DynamicFrame` asociado al esquema para Output 2 (Salida 2), debería seleccionar **1** para el valor de Frame index (Índice del marco), que es el segundo valor de la lista.

   Solo el `DynamicFrame` que elija se incluye en la salida.
5. (Opcional) después de configurar las propiedades del nodo de transformación, puede ver el esquema de datos para sus datos al seleccionar la pestaña Output schema (Esquema de salida) en el panel de detalles del nodo. La primera vez que elija esta pestaña para cualquier nodo de trabajo, se le pedirá que proporcione un rol de IAM para acceder a los datos. Si no ha especificado un rol de IAM en Job details (Detalles del trabajo), se le pedirá que ingrese un rol de IAM aquí.
6. (Opcional) después de configurar las propiedades del nodo y las propiedades de transformación, puede obtener una previsualización del conjunto de datos modificado si selecciona la opción Data preview (Previsualización de datos) en el panel de detalles del nodo. La primera vez que elija esta pestaña para cualquier nodo de trabajo, se le pedirá que proporcione un rol de IAM para acceder a los datos. Hay un costo asociado con el uso de este recurso y la facturación comienza tan pronto como proporcione un rol de IAM.

Buscar y rellenar valores faltantes en un conjunto de datos

Puede utilizar la transformación FillMissingValues (Completar valores faltantes) para localizar registros en el conjunto de datos que tienen valores faltantes y agregar un nuevo campo con un valor determinado por imputación. El conjunto de datos de entrada se utiliza para brindar formación al modelo de machine learning (ML) que determina cuál debe ser el valor que falta. Si utiliza conjuntos de datos progresivos, cada conjunto progresivo se utiliza como datos de formación para el modelo de ML, por lo que es posible que los resultados no sean tan precisos.

Para utilizar un nodo de transformación FillMissingValues (Completar valores faltantes) en el diagrama de trabajo

1. (Opcional) abra el panel de recursos y elija FillMissingValues para agregar una nueva transformación al diagrama de trabajo, si es necesario.
2. En la pestaña Node properties (Propiedades del nodo), ingrese un nombre para el nodo en el diagrama de trabajo. Si todavía no está seleccionado un nodo principal, elija un nodo de la lista Node parents (Nodos principales) para utilizar como origen de entrada para la transformación.
3. Elija la pestaña Transform (Transformación).
4. Para Data field (Campo de datos), elija el nombre de columna o campo de los datos de origen que desea analizar para detectar los valores que faltan.
5. (Opcional) en el campo New field name (Nombre de campo nuevo), ingrese un nombre para el campo agregado a cada registro que contendrá el valor de reemplazo estimado para el campo analizado. Si el campo analizado no tiene un valor faltante, el valor del campo analizado se copia en el nuevo campo.

   Si no especifica un nombre para el campo nuevo, el nombre predeterminado es el nombre de la columna analizada con `_filled`asociado. Por ejemplo, si ingresa **`Age`** para el Data field (Campo de datos) y no especifica un valor para New field name (Nombre de campo nuevo), se agrega un nombre de campo nuevo **`Age_filled`** a cada registro.
6. (Opcional) después de configurar las propiedades del nodo de transformación, puede ver el esquema de datos para sus datos al seleccionar la pestaña Output schema (Esquema de salida) en el panel de detalles del nodo. La primera vez que elija esta pestaña para cualquier nodo de trabajo, se le pedirá que proporcione un rol de IAM para acceder a los datos. Si no ha especificado un rol de IAM en Job details (Detalles del trabajo), se le pedirá que ingrese un rol de IAM aquí.
7. (Opcional) después de configurar las propiedades del nodo y las propiedades de transformación, puede obtener una previsualización del conjunto de datos modificado si selecciona la opción

Data preview (Previsualización de datos) en el panel de detalles del nodo. La primera vez que elija esta pestaña para cualquier nodo de trabajo, se le pedirá que proporcione un rol de IAM para acceder a los datos. Hay un costo asociado con el uso de este recurso y la facturación comienza tan pronto como proporcione un rol de IAM.

Filtrado de claves dentro de un conjunto de datos

Use la transformación Filter (Filtro) para crear un nuevo conjunto de datos al filtrar los registros del conjunto de datos de entrada en función de una expresión regular. Las filas que no satisfacen la condición del filtro se eliminan de la salida.

- Para los tipos de datos de cadena, puede filtrar filas en las que el valor de clave coincida con una cadena especificada.
- Para los tipos de datos numéricos, puede filtrar filas mediante la comparación del valor clave con un valor especificado a través de los operadores de comparación <, >, =, !=, <= y >=.

Si especifica varias condiciones de filtro, los resultados se combinan mediante un operador AND de forma predeterminada, pero puede elegir OR en su lugar.

La transformación Filtro distingue entre mayúsculas y minúsculas. Agregue una transformación ApplyMapping (Aplicar mapeo)como nodo principal si necesita nombres de clave de propiedad que no distingan entre mayúsculas y minúsculas.

Para agregar un nodo de transformación de filtro al diagrama de trabajo

1. (Opcional) abra el panel de recursos y elija Filtro para agregar una nueva transformación al diagrama de trabajo, si es necesario.
2. En la pestaña Node properties (Propiedades del nodo), ingrese un nombre para el nodo en el diagrama de trabajo. Si todavía no se ha seleccionado un nodo principal, elija un nodo de la lista Node parents (Nodos principales) para utilizar como origen de entrada para la transformación.
3. Elija la pestaña Transform (Transformación).
4. Elija Global AND (Global Y) o Global OR (Global O). Esto determina cómo se combinan distintas condiciones de filtro. Todas las condiciones se combinan mediante operaciones AND o OR. Si solo tiene una sola condición de filtro, puede elegir entre cualquiera de las dos.
5. Elija el botón Add condition (Agregar condición) en la sección Filter condition (Condición de filtro) para agregar una condición de filtro.

En el campo Key (Clave), elija un nombre de clave de propiedad a partir del conjunto de datos. En el campo Operation (Operación) elija el operador de comparación. En el campo Value (Valor), ingrese el valor de comparación. Estas son algunas ejemplos de condiciones de filtro:

- `year >= 2018`
- `State matches 'CA*'`

Cuando filtra los valores de cadena, asegúrese de que el valor de comparación utiliza un formato de expresión regular que coincida con el lenguaje de script seleccionado en las propiedades del trabajo (Python o Scala).

6. Agregue condiciones de filtro adicionales, según sea necesario.
7. (Opcional) después de configurar las propiedades del nodo de transformación, puede ver el esquema de datos para sus datos al seleccionar la pestaña Output schema (Esquema de salida) en el panel de detalles del nodo. La primera vez que elija esta pestaña para cualquier nodo de trabajo, se le pedirá que proporcione un rol de IAM para acceder a los datos. Si no ha especificado un rol de IAM en Job details (Detalles del trabajo), se le pedirá que ingrese un rol de IAM aquí.
8. (Opcional) después de configurar las propiedades del nodo y las propiedades de transformación, puede obtener una previsualización del conjunto de datos modificado si selecciona la opción Data preview (Previsualización de datos) en el panel de detalles del nodo. La primera vez que elija esta pestaña para cualquier nodo de trabajo, se le pedirá que proporcione un rol de IAM para acceder a los datos. Hay un costo asociado con el uso de este recurso y la facturación comienza tan pronto como proporcione un rol de IAM.

Uso de DropNullFields para eliminar campos con valores nulos

Utilice la transformación DropNullFields para eliminar campos del conjunto de datos si todos los valores son ‘nulos’. De forma predeterminada, AWS Glue Studio reconocerá objetos nulos, pero algunos valores, como cadenas vacías, cadenas que son “nulas”, los enteros -1 u otros marcadores de posición, como ceros, no se reconocen de manera automática como nulos.

Para utilizar DropNullFields

1. Agregue un nodo DropNullFields al diagrama de trabajo.

2. En la pestaña Node properties (Propiedades del nodo), elija valores adicionales que representen un valor nulo. Puede elegir seleccionar todos los valores o ninguno:

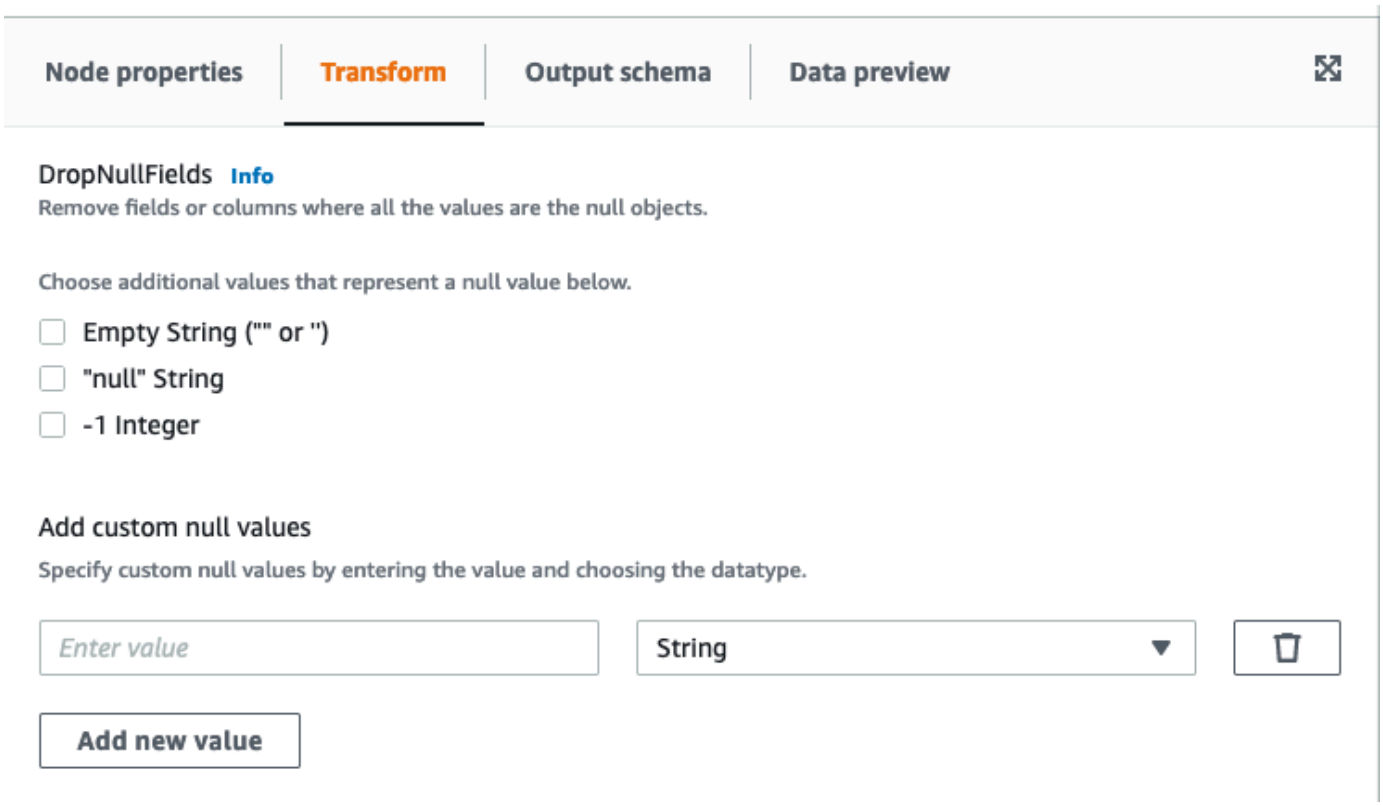

   - Cadena vacía (“” o “): los campos que contienen cadenas vacías se eliminarán
   - “cadena null”: los campos que contienen la cadena con la palabra ‘null’ se eliminarán
   - entero -1: los campos que contienen un entero -1 (uno negativo) se eliminarán
3. Si es necesario, también puede especificar valores nulos personalizados. Son valores nulos que pueden ser exclusivos de su conjunto de datos. Para agregar un valor nulo personalizado, elija Add new value (Agregar un nuevo valor).
4. Ingrese el valor nulo personalizado. Por ejemplo, puede ser cero o cualquier valor que se utilice para representar un valor nulo en el conjunto de datos.
5. Elija el tipo de datos en el campo desplegable. Los tipos de datos pueden ser String o Integer.

> **Note**
>
> Los valores nulos personalizados y los tipos de datos deben coincidir con exactitud para que los campos se reconozcan como valores nulos y se eliminen. Las coincidencias

parciales en las que solo coincide el valor nulo personalizado, pero el tipo de datos no lo hace, no provocarán que los campos se eliminen.

Uso de una consulta SQL para transformar datos

Puede usar una transformación SQL para escribir su propia transformación en forma de consulta SQL.

Un nodo de transformación SQL puede tener varios conjuntos de datos como entradas, pero solo produce un único conjunto de datos como salida. Contiene un campo de texto, donde se introduce la consulta de Apache SparkSQL. Puede asignar alias a cada conjunto de datos utilizado como entrada, para ayudar simplemente a la consulta SQL. Para obtener más información acerca de la sintaxis SQL, consulte documentación de Spark SQL.

> **Note**
>
> Si utiliza una transformación de Spark SQL con un origen de datos ubicado en una VPC, agregue un punto de enlace de desarrollo de la VPC de AWS Glue a la VPC que contenga el origen de datos. Para obtener más información acerca de la configuración de puntos de enlace de desarrollo, consulte Agregar un punto de enlace de desarrollo, Configuración del entorno para puntos de enlace de desarrollo y Acceso al punto de enlace de desarrollo en la Guía para desarrolladores de AWS Glue.

Para agregar un nodo de transformación SQL al diagrama de trabajo

1. (Opcional) agregue un nodo de transformación al diagrama de trabajo, de ser necesario. Seleccione SQL Query para el tipo de nodo.

   > **Note**
   >
   > Si utiliza una sesión de vista previa de datos y un nodo de código o SQL personalizado, la sesión de vista previa de datos ejecutará el SQL o el bloque de código tal cual está para todo el conjunto de datos.

2. En la pestaña Node properties (Propiedades del nodo), ingrese un nombre para el nodo en el diagrama de trabajo. Si todavía no se ha seleccionado un nodo principal, o si desea varias

entradas para la transformación SQL, elija un nodo en la lista Node parents (Nodos principales) que se utilizará como origen de entrada para la transformación. Agregue nodos principales adicionales según sea necesario.

3. Elija la pestaña Transform (Transformación) en el panel de detalles del nodo.
4. Los conjuntos de datos de origen para la consulta SQL se identifican mediante los nombres especificados en el campo Name (Nombre) para cada nodo. Si no desea utilizar estos nombres o si los nombres no son adecuados para una consulta SQL, puede asociar un nombre a cada conjunto de datos. La consola proporciona alias predeterminados, como `MyDataSource`.

   Por ejemplo, si un nodo principal para el nodo de transformación SQL se denomina `Rename Org PK field`, puede asociar el nombre `org_table` con este conjunto de datos. Este alias se puede utilizar en la consulta SQL en lugar del nombre del nodo.
5. En el campo de entrada de texto bajo el encabezado Code block (Bloque de código), pegue o escriba la consulta SQL. El campo de texto muestra resaltado de sintaxis SQL y sugerencias de palabras clave.
6. Con el nodo de transformación SQL seleccionado, elija la opción Output schema (Esquema de salida) y, a continuación, elija Edit (Editar). Proporcione las columnas y los tipos de datos que describen los campos de salida de la consulta SQL.

   Especifique el esquema mediante las siguientes acciones en la sección Output schema (Esquema de salida) de la página:

   - Para cambiar el nombre de una columna, coloque el cursor en el cuadro de texto Key (Clave) para la columna [también conocido como field (campo) o property key (clave de propiedad)] e ingrese el nuevo nombre.
   - Para cambiar el tipo de datos de una columna, seleccione el nuevo tipo de datos para la columna en la lista desplegable.
   - Para agregar una nueva columna de nivel superior al esquema, elija la opción Overflow (Desbordamiento)
     ( )
     y, a continuación, elija Add root key (Agregar clave raíz). Se agregan nuevas columnas en la parte superior del esquema.
   - Para eliminar una columna del esquema, elija el ícono de eliminación
     ( )
     en el extremo derecho del nombre de la clave.

7. Cuando termine de especificar el esquema de salida, elija Apply (Aplicar) para guardar los cambios y salir del editor de esquemas. Si no desea guardar los cambios, elija Cancel (Cancelar) para editar el editor de esquemas.
8. (Opcional) después de configurar las propiedades del nodo y las propiedades de transformación, puede obtener una previsualización del conjunto de datos modificado si selecciona la opción Data preview (Previsualización de datos) en el panel de detalles del nodo. La primera vez que elija esta pestaña para cualquier nodo de trabajo, se le pedirá que proporcione un rol de IAM para acceder a los datos. Hay un costo asociado con el uso de este recurso y la facturación comienza tan pronto como proporcione un rol de IAM.

Uso de Agregar para realizar cálculos resumidos en campos seleccionados

Para utilizar la transformación agregada

1. Agregue el nodo agregado al diagrama de trabajos.
2. En la pestaña Node properties (Propiedades del nodo), elija los campos para agruparlos al seleccionar el campo desplegable (opcional). Puede seleccionar más de un campo a la vez o buscar un nombre de campo al escribir en la barra de búsqueda.

   Cuando se seleccionan los campos, se muestran el nombre y el tipo de datos. Para eliminar un campo, seleccione ‘X’.

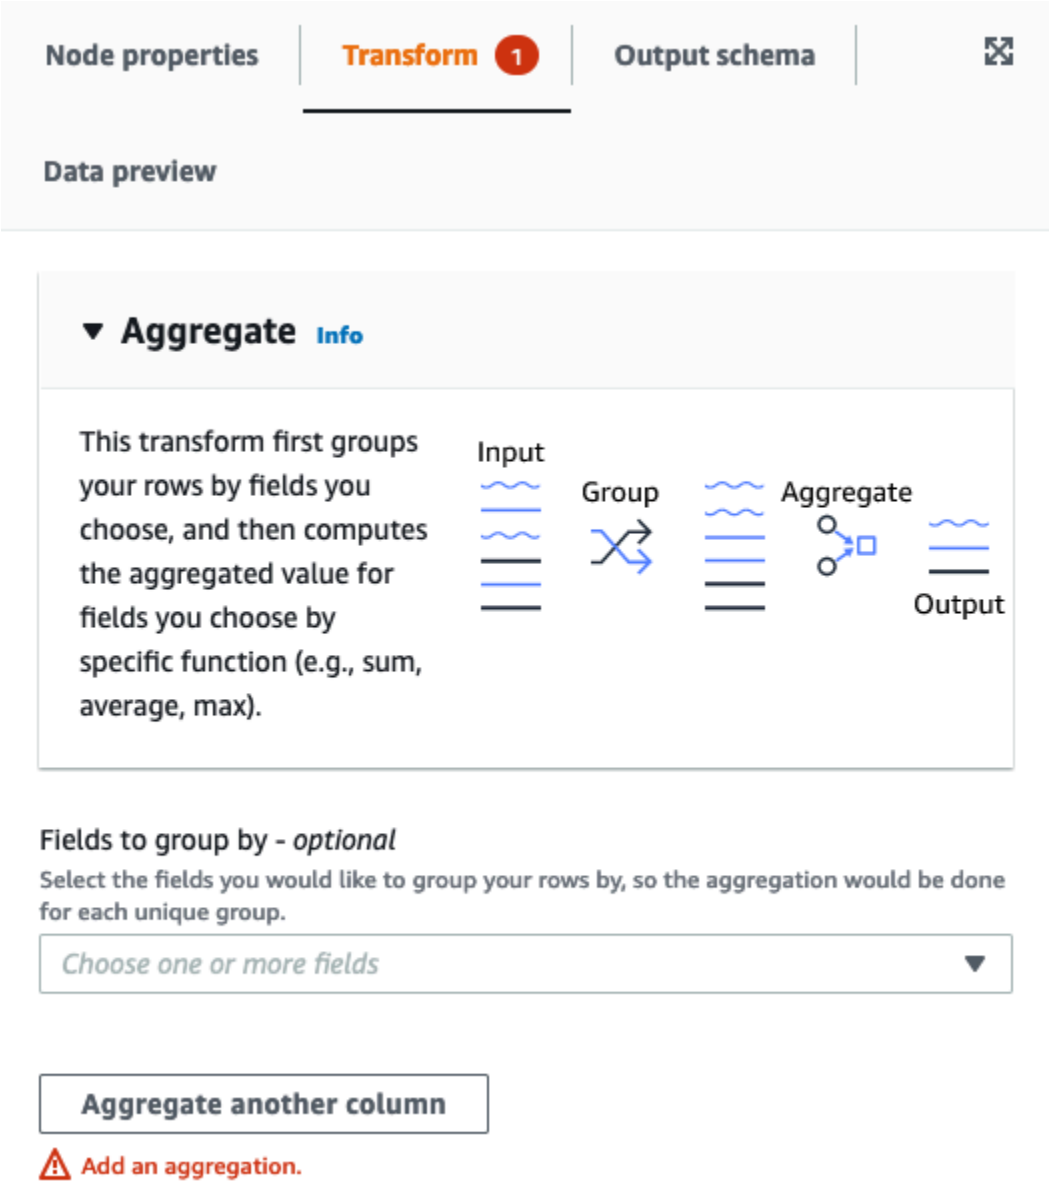

3. Elija Aggregate another column (Agregar otra columna). Es necesario seleccionar al menos un campo.

4. Elija un campo en el Field to aggretate (Campo a agregar) desplegable.

5. Elija la función de agregación que desea aplicar al campo elegido:

   - avg: calcula el promedio
   - countDistinct: calcula el número de valores únicos no nulos
   - count: calcula el número de valores no nulos
   - first: devuelve el primer valor que satisface los criterios “agrupar por”
   - last: devuelve el último valor que satisface los criterios “agrupar por”
   - kurtosis: calcula la nitidez del pico de una curva de distribución de frecuencias
   - max: devuelve el valor más alto que satisface los criterios “agrupar por”
   - min: devuelve el valor más bajo que satisface los criterios “agrupar por”
   - sesgo: medida de la asimetría de la distribución de probabilidad de una distribución normal
   - stddev_pop: calcula la desviación estándar de la población y devuelve la raíz cuadrada de la variación de la población
   - sum: la suma de todos los valores en el grupo
   - sumDistinct: la suma de distintos valores en el grupo
   - var_samp: la variación de la muestra del grupo (ignora los valores nulos)
   - var_pop: la variación de la población del grupo (ignora los valores nulos)

Aplanamiento de estructuras anidadas

Aplana los campos de las estructuras anidadas en los datos para que se conviertan en campos de nivel superior. Los nuevos campos se denominan con el nombre del campo precedido de los nombres de los campos de la estructura que lo integran, separados por puntos.

Por ejemplo, si los datos tienen un campo de tipo de estructura llamado “phone_numbers”, que entre otros campos tiene uno del tipo “Struct” denominado “home_phone” con dos campos: “country_code” y “number”. Una vez aplanados, estos dos campos pasarán a ser campos de nivel superior denominados: “phone_numbers.home_phone.country_code” y “phone_numbers.home_phone.number”, respectivamente.

Para agregar un nodo de transformación de Aplanado al diagrama de trabajo

1. Abra el panel de recursos y elija la pestaña Transformación y, a continuación, Flatten para agregar una nueva transformación al diagrama de trabajo. También puede utilizar la barra de

búsqueda a través del ingreso de “Flatten” y, a continuación, hacer clic en el nodo Flatten. El nodo seleccionado en el momento de agregar el nodo será el nodo principal.

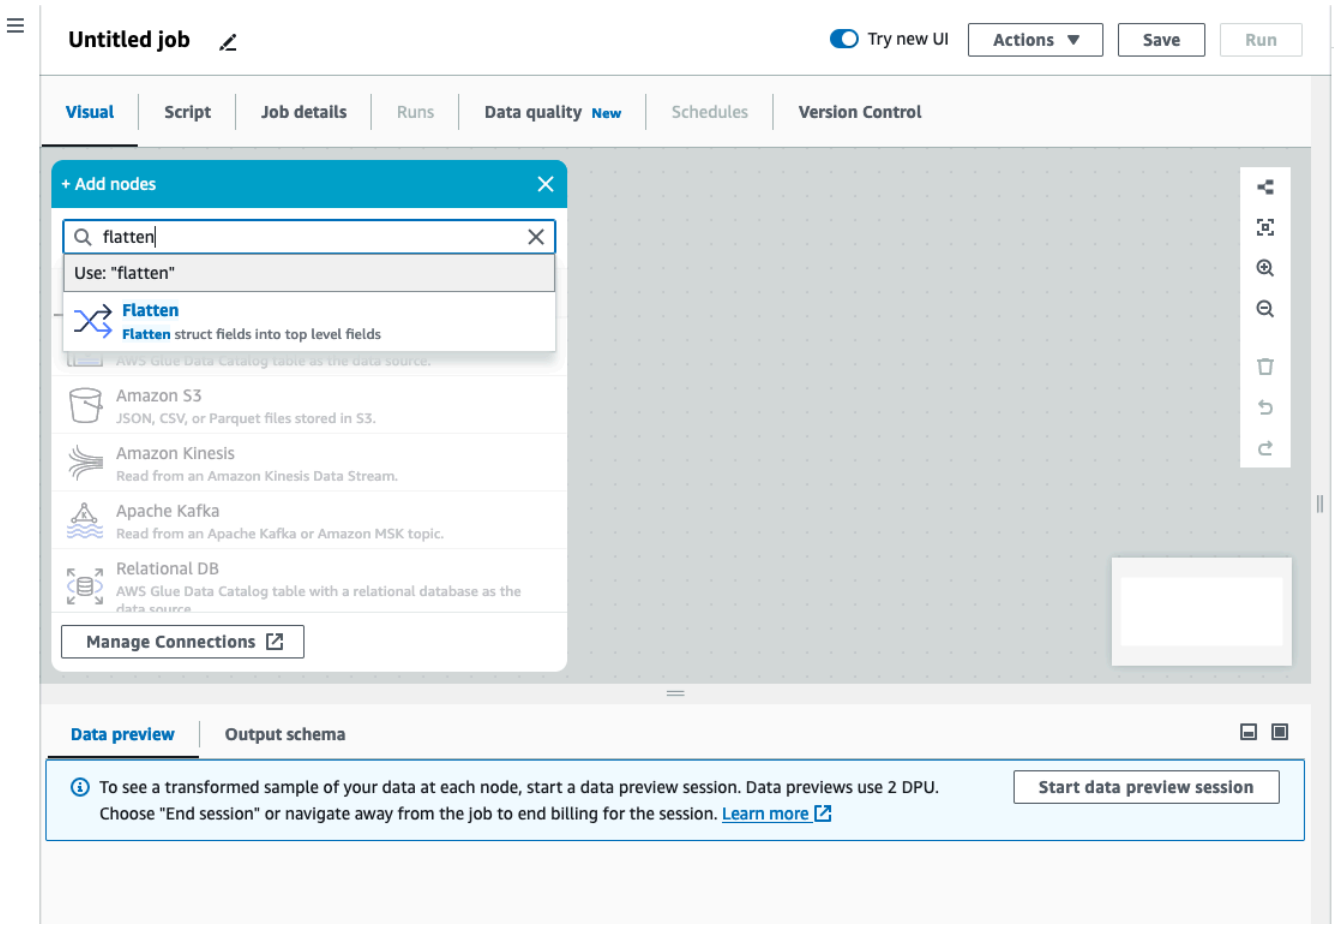

2. (Opcional) En la pestaña Propiedades del nodo, puede ingresar un nombre para el nodo en el diagrama de trabajo. Si todavía no se ha seleccionado un nodo principal, elija un nodo de la lista Node parents (Nodos principales) para utilizar como origen de entrada para la transformación.
3. (Opcional) En la pestaña Transformación, puede limitar el nivel máximo de anidamiento para aplanar. Por ejemplo, si establece ese valor en 1 significa que solo se aplanarán las estructuras de nivel superior. Si se establece el máximo en 2, se aplanarán el nivel superior y las estructuras que se encuentran justo debajo de este.

Agregar una columna UUID

Al agregar una columna UUID (Identificador único universal), se le asignará una cadena única de 36 caracteres a cada fila.

Para agregar un nodo de transformación de UUID en el diagrama de trabajo

1. Abra el panel de recursos y, luego, elija UUID para agregar una nueva transformación al diagrama de trabajo. El nodo seleccionado en el momento de agregar el nodo será el nodo principal.
2. (Opcional) En la pestaña Propiedades del nodo, puede ingresar un nombre para el nodo en el diagrama de trabajo. Si todavía no se ha seleccionado un nodo principal, elija un nodo de la lista Node parents (Nodos principales) para utilizar como origen de entrada para la transformación.
3. (Opcional) En la pestaña Transformación, puede personalizar el nombre de la nueva columna. De forma predeterminada, se denominará “uuid”.

Agregar una columna de identificador

Asigne un identificador numérico para cada fila del conjunto de datos.

Para agregar un nodo de transformación de Identificador en el diagrama de trabajo

1. Abra el panel de recursos y, luego, elija Identificador para agregar una nueva transformación al diagrama de trabajo. El nodo seleccionado en el momento de agregar el nodo será el nodo principal.
2. (Opcional) En la pestaña Propiedades del nodo, puede ingresar un nombre para el nodo en el diagrama de trabajo. Si todavía no se ha seleccionado un nodo principal, elija un nodo de la lista Node parents (Nodos principales) para utilizar como origen de entrada para la transformación.
3. (Opcional) En la pestaña Transformación, puede personalizar el nombre de la nueva columna. De forma predeterminada, se llamará “id”.
4. (Opcional) Si el trabajo procesa y almacena los datos de forma incremental, debe evitar que se vuelvan a utilizar los mismos id entre las ejecuciones del trabajo.

   En la pestaña Transformación, marque la opción de la casilla de verificación único. Incluirá la marca temporal del trabajo en el identificador, lo que lo hará único entre varias ejecuciones. Para permitir el número mayor, la columna, en lugar tipo long, será un decimal.

Convertir una columna al tipo de marca temporal

Puede utilizar la transformación marca temporal para cambiar el tipo de datos de una columna numérica o de cadena a una de marca temporal, de modo que pueda almacenarse con ese tipo de datos o aplicarse a otras transformaciones que requieran una marca temporal.

Para agregar un nodo de transformación de marca temporal al diagrama de trabajo

1. Abra el panel Recursos y, luego, elija Marca temporal para agregar una nueva transformación al diagrama de trabajo. El nodo seleccionado en el momento de agregar el nodo será el nodo principal.
2. (Opcional) En la pestaña Propiedades del nodo, puede ingresar un nombre para el nodo en el diagrama de trabajo. Si todavía no se ha seleccionado un nodo principal, elija un nodo de la lista Node parents (Nodos principales) para utilizar como origen de entrada para la transformación.
3. En la pestaña Transformación, introduzca el nombre de la columna que se va a convertir.
4. En la pestaña Transformación, defina cómo analizar la columna seleccionada mediante la elección del tipo.

   Si el valor es un número, se puede expresar en segundos (marca temporal de Unix/Python), milisegundos o microsegundos, elija la opción correspondiente.

   Si el valor es una cadena con formato, elija el tipo “iso”, la cadena debe ajustarse a una de las variantes del formato ISO, por ejemplo: “2022-11-02T14:40:59.915Z”.

   Si desconoce el tipo en este momento o si diferentes filas utilizan tipos diferentes, puede elegir la opción “detección automática” y el sistema hará su mejor estimación, con un pequeño costo en el rendimiento.
5. (Opcional) En la pestaña Transformación, en lugar de convertir la columna seleccionada, puede crear una nueva y conservar la original al asignar un nombre para la nueva columna.

Convertir una columna con marca temporal en una cadena con formato

Formatee una columna de marca temporal en una cadena basada en un patrón. Puede utilizar Formatear marca temporal para obtener la fecha y la hora como una cadena con el formato deseado. Puede definir el formato con la Sintaxis de fecha de Spark, así como la mayoría de los Códigos de fecha de Python.

Por ejemplo, si quiere que la cadena de fecha tenga el formato “2023-01-01 00:00”, puede definir dicho formato con la sintaxis de Spark como “yyyy-MM-dd HH:mm” o los códigos de fecha equivalentes de Python como “%Y-%m-%d %H:%M”

Para agregar un nodo de transformación de formateo de marca temporal al diagrama de trabajo

1. Abra el panel de recursos y, a continuación, elija Formatear marca temporal para agregar una nueva transformación al diagrama de trabajo. El nodo seleccionado en el momento de agregar el nodo será el nodo principal.
2. (Opcional) En la pestaña Propiedades del nodo, puede ingresar un nombre para el nodo en el diagrama de trabajo. Si todavía no se ha seleccionado un nodo principal, elija un nodo de la lista Node parents (Nodos principales) para utilizar como origen de entrada para la transformación.
3. En la pestaña Transformación, introduzca el nombre de la columna que se va a convertir.
4. En la pestaña Transformación, introduzca el patrón de Formato de marca temporal que desea utilizar, expresado mediante la sintaxis de fecha de Spark o los códigos de fecha de Python.
5. (Opcional) En la pestaña Transformación, en lugar de convertir la columna seleccionada, puede crear una nueva y conservar la original al asignar un nombre para la nueva columna.

Creación de una transformación de Enrutador condicional

La transformación del Enrutador condicional permite aplicar múltiples condiciones a los datos entrantes. Cada fila de los datos entrantes se evalúa mediante una condición de filtro de grupo y se procesa en su grupo correspondiente. Si una fila cumple con más de una condición de filtro de grupo, la transformación pasa la fila a varios grupos. Si una fila no cumple con ninguna condición, se puede eliminar o enrutar a un grupo de salida predeterminado.

Esta transformación es similar a la transformación de filtro, pero es útil para los usuarios que desean probar los mismos datos de entrada en múltiples condiciones.

Para agregar una transformación de Enrutador condicional:

1. Elija un nodo en el que realizará la transformación de enrutador condicional. Puede ser un nodo de origen o una transformación distinta.
2. Elija Acción y, a continuación, utilice la barra de búsqueda para buscar y elegir “Enrutador condicional”. Se agrega una transformación de Enrutador condicional junto con dos nodos de salida. Un nodo de salida, “Grupo predeterminado”, contiene registros que no cumplen ninguna de las condiciones definidas en los otros nodos de salida. El grupo predeterminado no se puede editar.

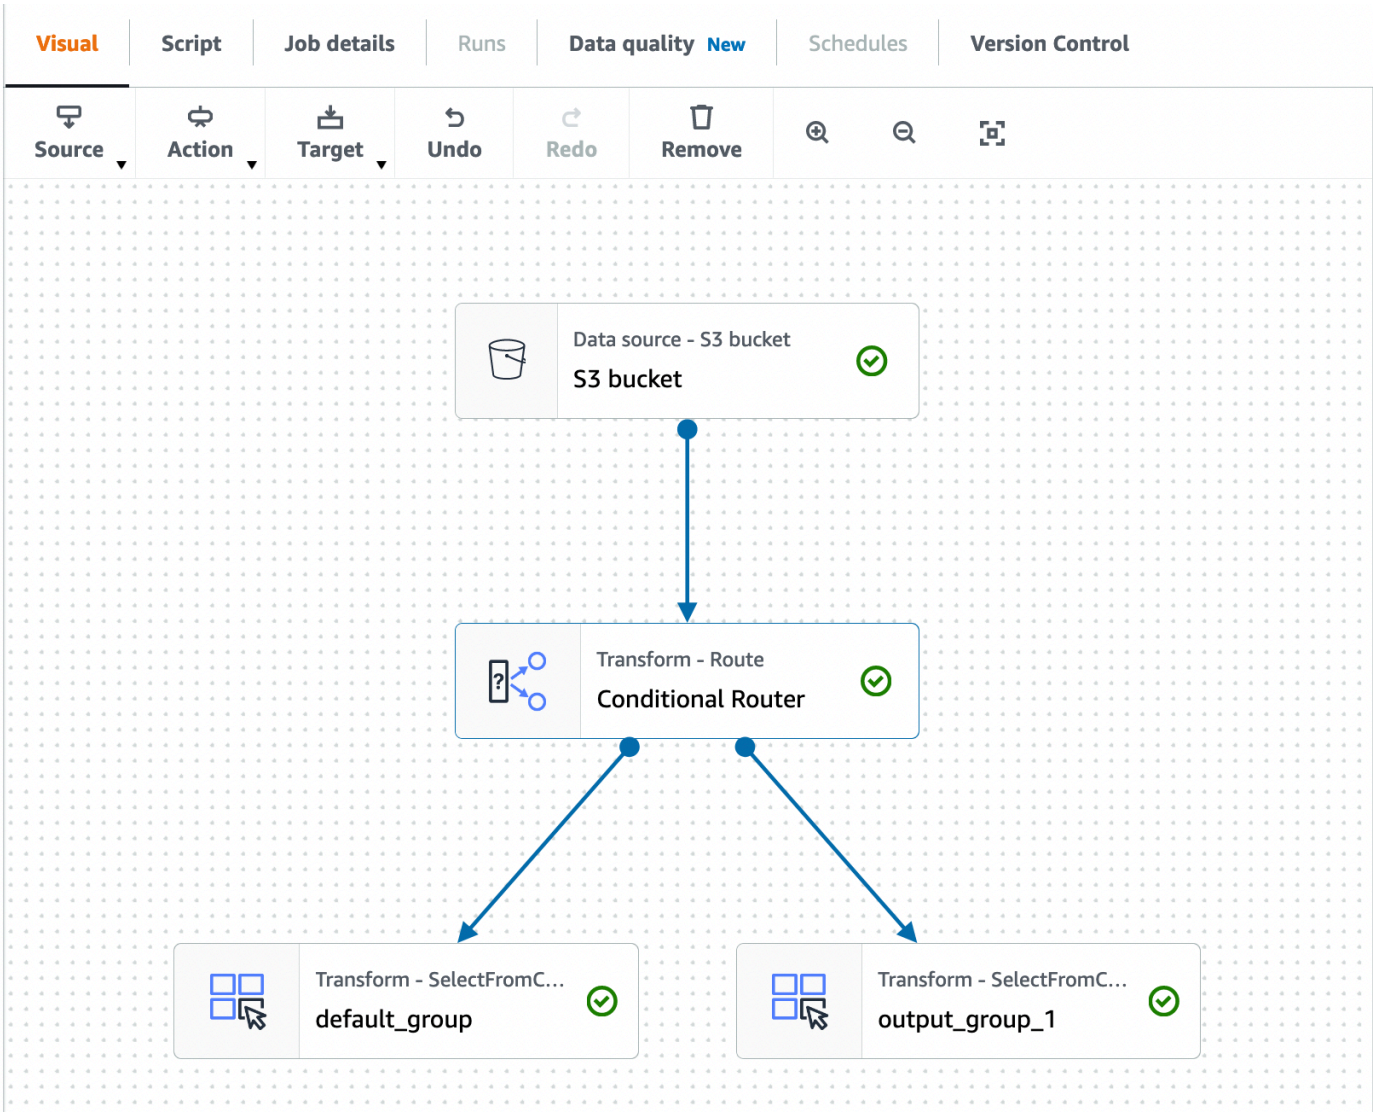

Puede agregar grupos de salida adicionales si selecciona Agregar grupo. Puede asignar un nombre a cada grupo de resultado y agregar condiciones de filtro y un operador lógico.

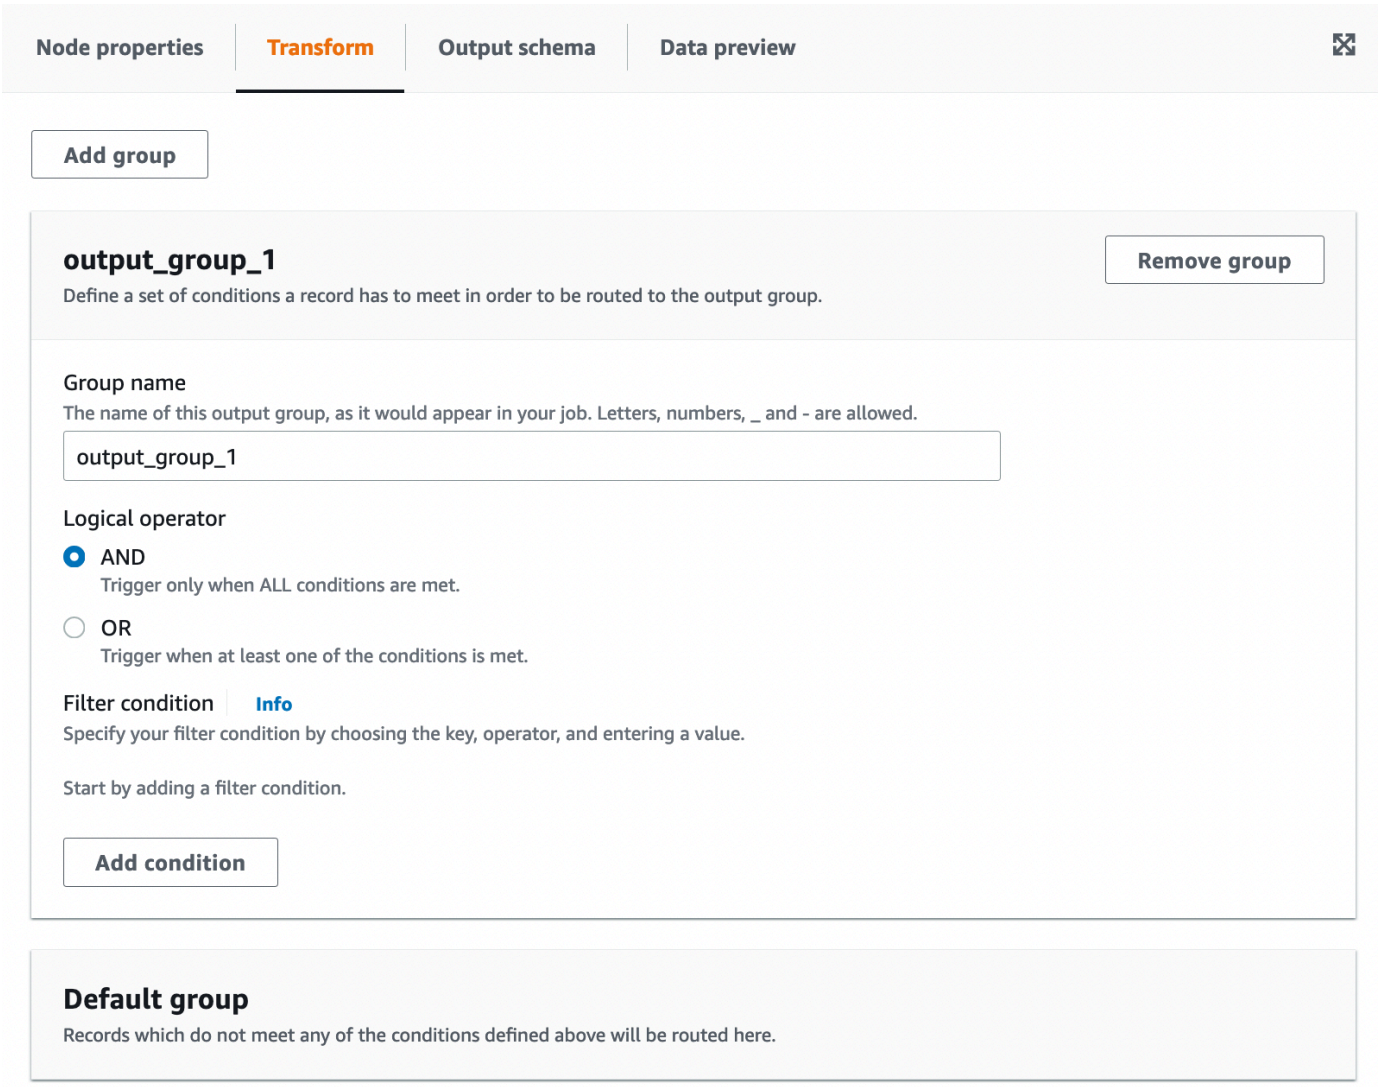

3. Cambie el nombre del grupo de salida al introducir un nombre nuevo para el grupo. AWS Glue Studio asignará de forma automática un nombre a los grupos (por ejemplo, “output_group_1”).
4. Elija un operador lógico (AND, OR) y agregue una Condición de filtro mediante la especificación de la Clave, la Operación y el Valor. Los operadores lógicos permiten implementar más de una condición de filtro y aplicar el operador lógico en cada condición de filtro que especifique.

   Cuando especifique la clave, puede elegir entre las claves disponibles en el esquema. Luego, puede elegir la operación disponible según el tipo de clave que seleccionó. Por ejemplo, si el tipo de clave es “cadena”, la operación disponible para elegir es “coincidencias”.

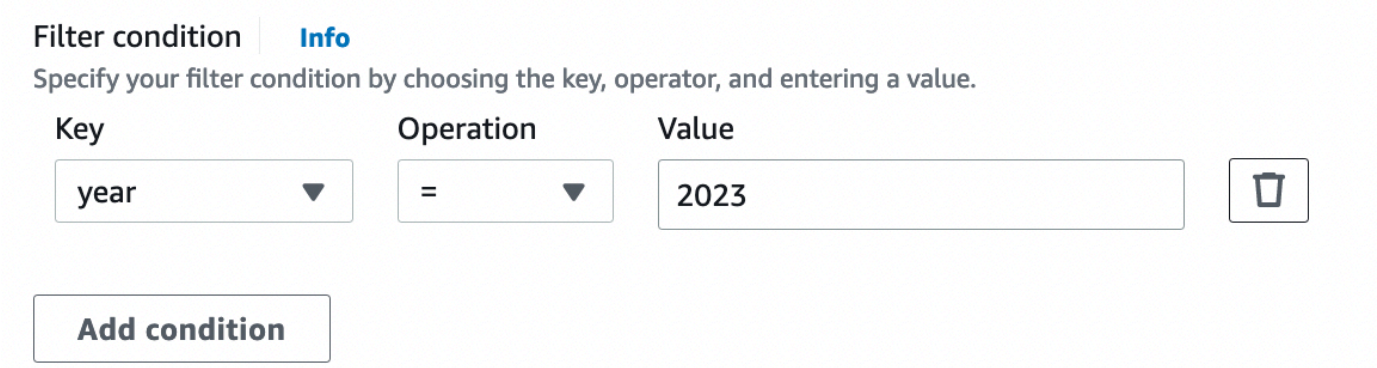

5. Ingrese el valor en el campo Valor. Elija Agregar condición para agregar condiciones de filtro adicionales. Para eliminar las condiciones de filtro, elija el icono de la papelera.

Uso de la transformación Concatenar columnas para agregar columnas

La transformación de concatenar permite crear una nueva columna de cadena mediante la utilización de los valores de otras columnas con un espaciador opcional. Por ejemplo, si definimos una columna concatenada “date” como la concatenación de “año”, “mes” y “día” (en ese orden) con “-” como espaciador, obtendremos:

day	month	year	date
01	01	2020	2020-01-01
02	01	2020	2020-01-02
03	01	2020	2020-01-03
04	01	2020	2020-01-04

Para agregar una transformación de Concatenar:

1. Abre el panel de recursos. A continuación, elija Concatenar columnas para agregar una nueva transformación al diagrama de trabajo. El nodo seleccionado en el momento de agregar el nodo será el nodo principal.
2. (Opcional) En la pestaña Propiedades del nodo, puede ingresar un nombre para el nodo en el diagrama de trabajo. Si todavía no se ha seleccionado un nodo principal, elija un nodo de la lista Nodos principales para utilizar como origen de entrada para la transformación.

3. En la pestaña Transformación, ingrese el nombre de la columna que contendrá la cadena concatenada, así como las columnas que se concatenarán. El orden en el que selecciones las columnas en el menú desplegable será el orden en que se usen.

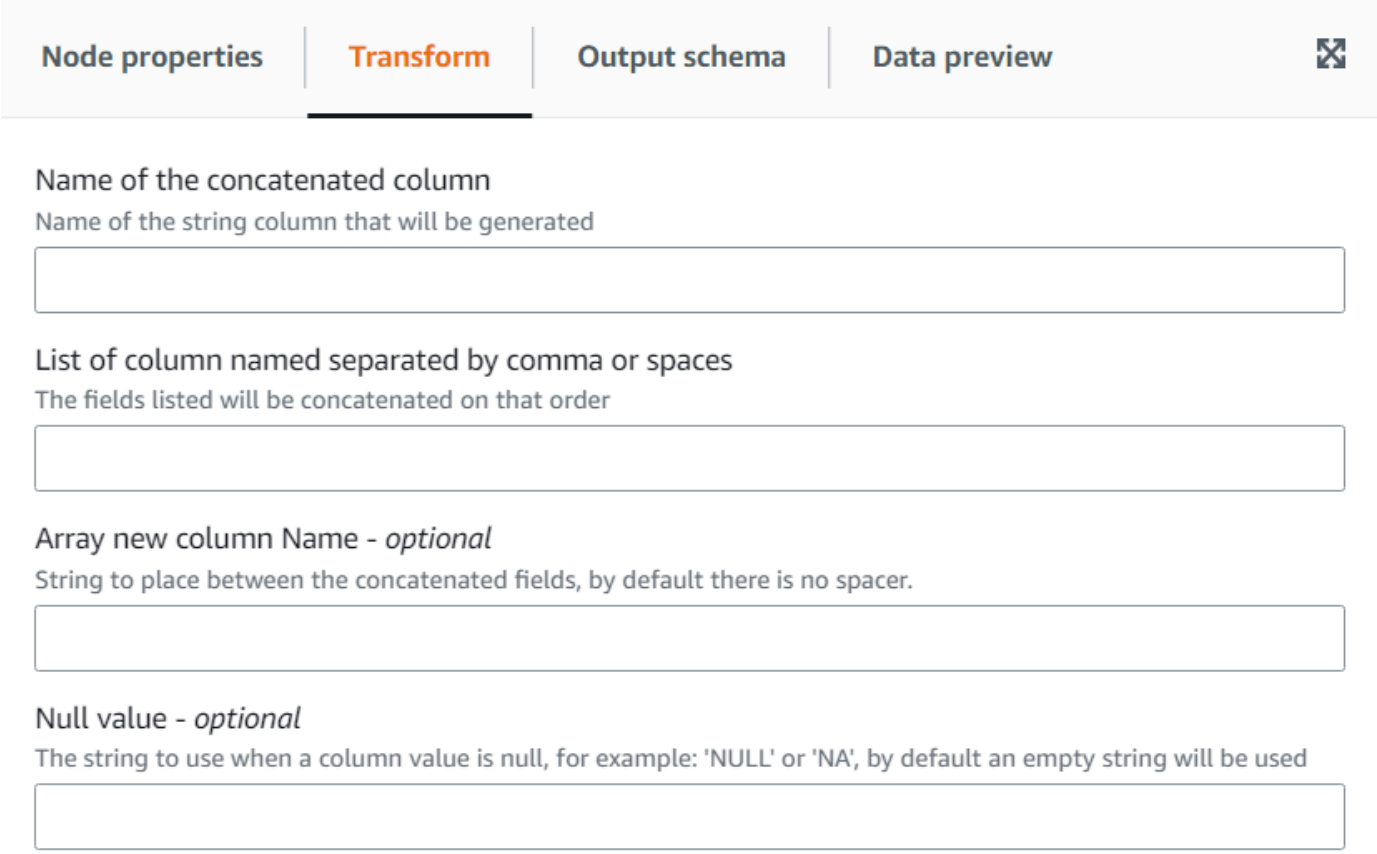

4. Espaciador (opcional): introduce una cadena para colocarla entre los campos concatenados. No hay un espaciador predeterminado.
5. Valor nulo (opcional): ingrese una cadena para utilizarla cuando el valor de una columna sea nulo. De forma predeterminada, en los casos en que las columnas tienen el valor “NULO” o “NA”, se utiliza una cadena vacía.

Uso de la transformación de cadena dividida para dividir una columna de cadena

La transformación de cadena dividida permite dividir una cadena en una matriz de símbolos mediante una expresión regular para definir cómo se realiza la división. Luego, puede mantener la columna como un tipo de matriz o aplicar una transformación de matriz a columnas después de esta, para extraer los valores de la matriz en los campos de nivel superior, suponiendo que cada token tenga un significado que conozcamos de antemano. Además, si el orden de los símbolos es irrelevante (por ejemplo, un conjunto de categorías), puedes usar la transformación Expansión para generar una fila independiente para cada valor.

Por ejemplo, se puede dividir la columna “categorías” mediante una coma como patrón para agregar una columna “categories_arr”.

product_id	categories	categories_arr
1	deportes, invierno	[deportes, invierno]
2	jardín, herramientas	[jardín, herramientas]
3	video juegos	[video juegos]
4	juego, juego de mesa, social	[juego, juego de mesa, social]

Para agregar una transformación de cadena dividida, realice lo siguiente:

1. Abra el panel de recursos y, luego, elija Cadena dividida para agregar una nueva transformación al diagrama de trabajo. El nodo seleccionado en el momento de agregar el nodo será el nodo principal.
2. (Opcional) En la pestaña Propiedades del nodo, puede ingresar un nombre para el nodo en el diagrama de trabajo. Si todavía no se ha seleccionado un nodo principal, elija un nodo de la lista Nodos principales para utilizar como origen de entrada para la transformación.
3. En la pestaña Transformación, elija la columna que desee dividir e ingrese el patrón que se utilizará para dividir la cadena. En la mayoría de los casos, solo tiene que ingresar los caracteres, a menos que tengan un significado especial como expresión regular y deban ocultarse. Los caracteres que hay que ocultar son: `\.[]{}()<>*+-=!?^$|` mediante la adición de una barra invertida delante del carácter. Por ejemplo, si desea separarlos por un punto ('.'), debe ingresar `\.`. Sin embargo, una coma no tiene un significado especial y se puede especificar tal cual: `,`.

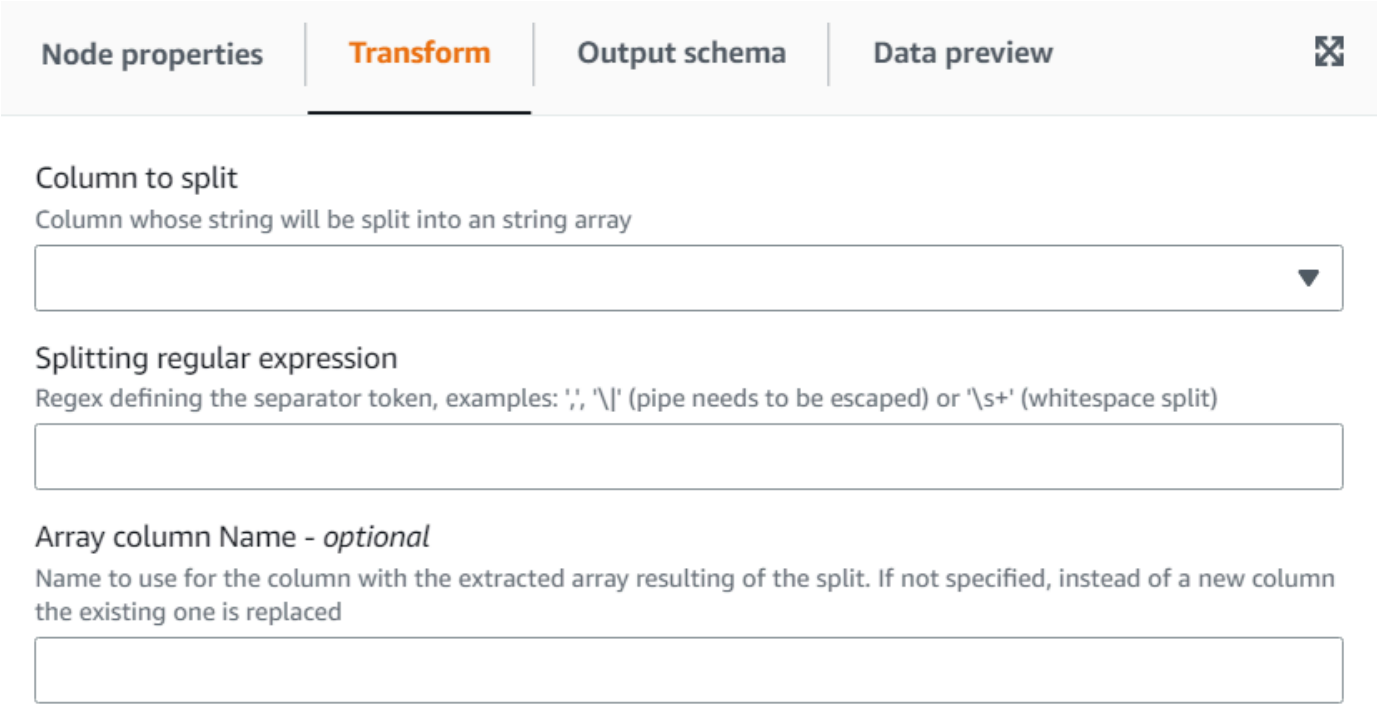

4. (Opcional) Si desea conservar la columna de cadena original, puede ingresar un nombre para una nueva columna de matriz, de manera que se mantenga tanto la columna de cadena original como la nueva columna de matriz tokenizada.

Uso de la transformación de Matriz a columnas para extraer los elementos de una matriz en columnas de nivel superior

La transformación de Matriz a columnas permite extraer algunos o todos los elementos de una columna de tipo matriz en nuevas columnas. La transformación llenará las nuevas columnas tanto como sea posible si la matriz tiene valores suficientes para extraerlos y, opcionalmente, tomará los elementos en las posiciones especificadas.

Por ejemplo, si tiene una columna de matriz llamada “subred”, que fue el resultado de aplicar la transformación “cadena dividida” en una subred ip v4, puede extraer la primera y la cuarta posición en las nuevas columnas “first_octect” y “forth_octect”. El resultado de la transformación en este ejemplo sería (observe que las dos últimas filas tienen matrices más cortas de lo esperado):

subred	first_octect	fourth_octect
[54, 240, 197, 238]	54	238

subred	first_octect	fourth_octect
[192, 168, 0, 1]	192	1
[192, 168]	192	
[]		

Para agregar una transformación de Matriz a columnas:

1. Abra el panel de recursos y elija Matriz a columnas para agregar una nueva transformación al diagrama de trabajo. El nodo seleccionado en el momento de agregar el nodo será el nodo principal.
2. (Opcional) En la pestaña Propiedades del nodo, puede ingresar un nombre para el nodo en el diagrama de trabajo. Si todavía no se ha seleccionado un nodo principal, elija un nodo de la lista Nodos principales para utilizar como origen de entrada para la transformación.
3. En la pestaña Transformación, elija la columna de matriz a extraer e ingrese la lista de columnas nuevas para los tokens extraídos.

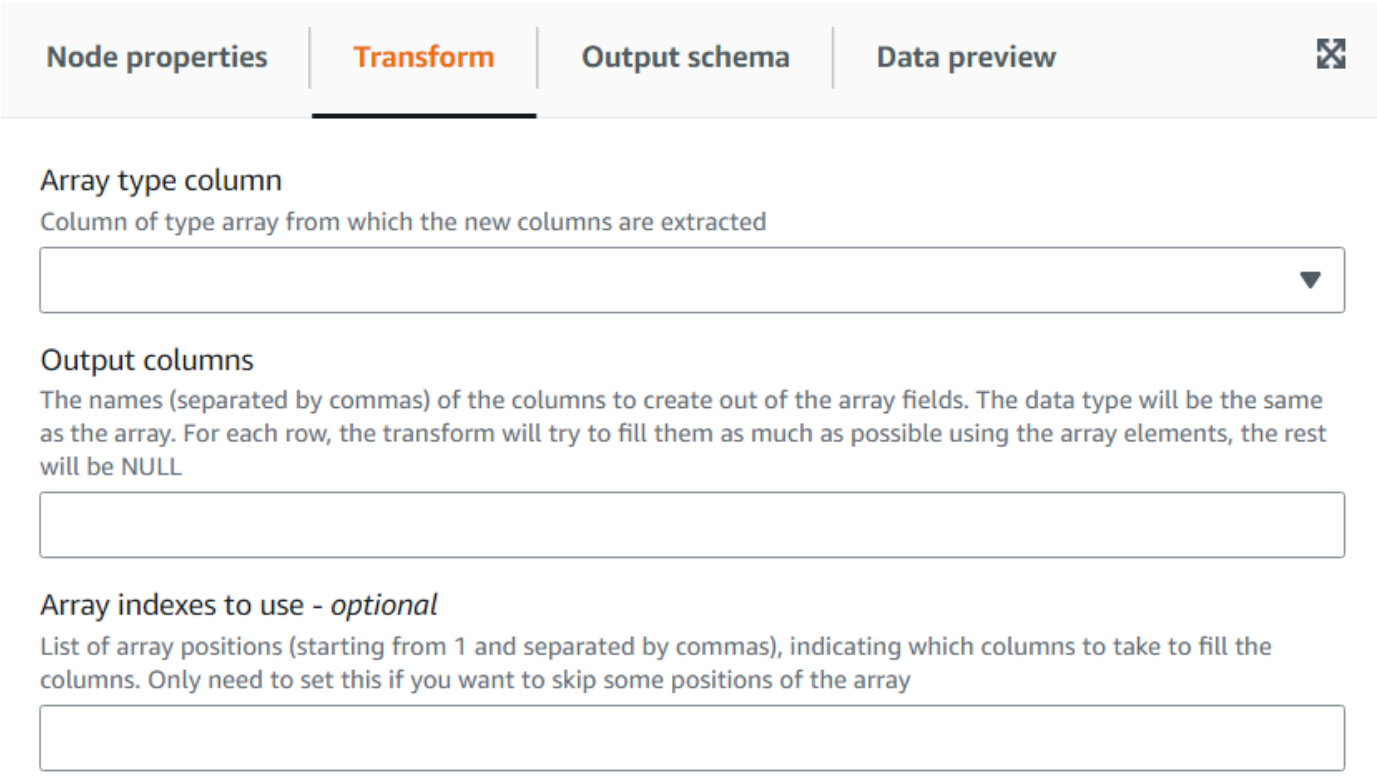

4. (Opcional) Si no desea utilizar los tokens de la matriz para asignarlos a las columnas, puede especificar los índices que se utilizarán, que se asignarán a la lista de columnas en el mismo orden especificado. Por ejemplo, si las columnas de salida son “columna1, columna2, columna3” y los índices “4, 1, 3”, el cuarto elemento de la matriz irá a la columna1, el primero a la columna2 y el tercero a la columna3 (si la matriz es más corta que el número de índice, se establecerá un valor NULO).

Uso de la transformación Agregar marca de tiempo actual

La transformación Agregar marca de tiempo actual permite marcar las filas con la hora en la que se procesaron los datos. Esto resulta útil para fines de auditoría o para realizar un seguimiento de la latencia en la canalización de datos. Puede agregar esta nueva columna como un tipo de datos de marca de tiempo o una cadena formateada.

Para agregar una transformación de tipo Add Current Timestamp:

1. Abra el panel de recursos y, a continuación, elija Agregar marca de tiempo actual para agregar una nueva transformación al diagrama de trabajo. El nodo seleccionado en el momento de agregar el nodo será el nodo principal.
2. (Opcional) En la pestaña Propiedades del nodo, puede ingresar un nombre para el nodo en el diagrama de trabajo. Si todavía no se ha seleccionado un nodo principal, elija un nodo de la lista Nodos principales para utilizar como origen de entrada para la transformación.

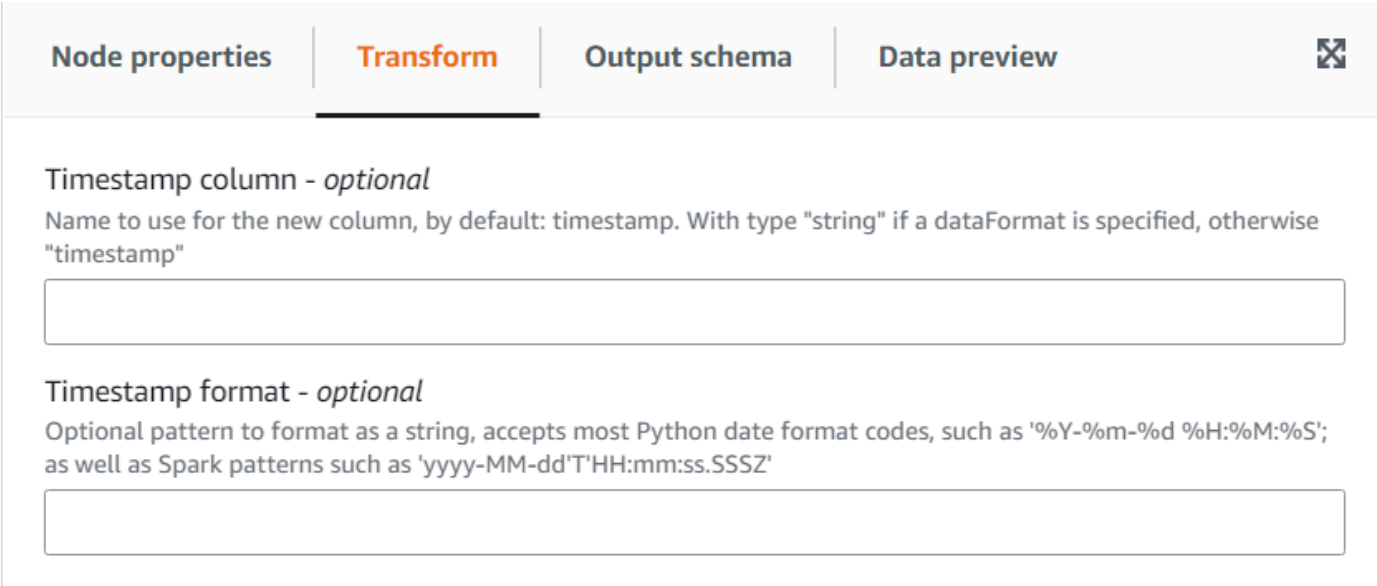

3. (Opcional) En la pestaña Transformación, ingrese un nombre personalizado para la nueva columna y un formato si prefiere que la columna sea una cadena de fecha con formato.

Uso de la transformación de rotar filas a columnas

La transformación filas dinámicas a columnas permite agregar una columna numérica mediante la rotación de valores únicos en las columnas seleccionadas para convertirlas en nuevas columnas (si se seleccionan varias columnas, los valores se concatenan para dar nombre a las nuevas columnas). De esta forma, las filas se consolidan y hay más columnas con agregaciones parciales para cada valor único. Por ejemplo, si tiene este conjunto de datos de ventas por mes y país (ordenado para que sea más fácil de ilustrar):

year	month	país	importe
2020	Ene	uk	32
2020	Ene	de	42
2020	Ene	us	64
2020	Feb	uk	67
2020	Feb	de	4
2020	Feb	de	7
2020	Feb	us	6
2020	Feb	us	12
2020	Ene	us	90

Si cambia el importe y el país como columnas de agregación, se crean nuevas columnas a partir de la columna del país original. En la siguiente tabla, tiene nuevas columnas para de, uk y us en lugar de la columna de país.

year	month	de	uk	us
2020	Ene	42	32	64
2020	Ene	11	67	18

year	month	de	uk	us
2021	Ene			90

Si, por el contrario, desea cambiar el mes y el condado, obtendrá una columna para cada combinación de los valores de esas columnas:

year	Jan_DE	Jan_uk	Jan_us	Feb_de	Feb_UK	Feb_US
2020	42	32	64	11	67	18
2021			90			

Para agregar una transformación de filas dinámicas a columnas, realice lo siguiente:

1. Abra el panel de recursos y, luego, elija Filas dinámicas a columnas para agregar una nueva transformación al diagrama de trabajo. El nodo seleccionado en el momento de agregar el nodo será el nodo principal.
2. (Opcional) En la pestaña Propiedades del nodo, puede ingresar un nombre para el nodo en el diagrama de trabajo. Si todavía no se ha seleccionado un nodo principal, elija un nodo de la lista Nodos principales para utilizar como origen de entrada para la transformación.
3. En la pestaña Transformación, elija la columna numérica que se agregará para generar los valores de las nuevas columnas, la función de agregación que desee aplicar y las columnas para convertir sus valores únicos en columnas nuevas.

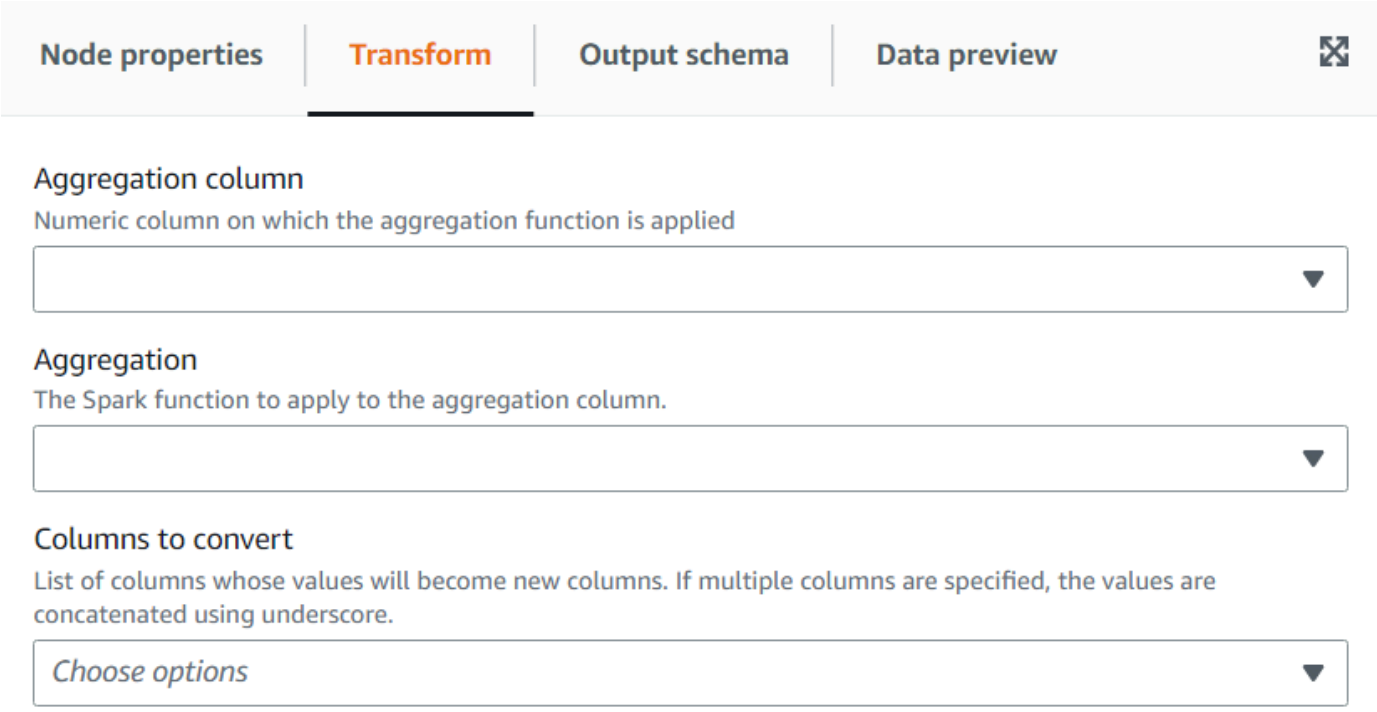

Uso de la transformación de anulación de rotación de columnas a filas

La transformación Anular rotación permite convertir columnas en valores de nuevas columnas, lo que genera una fila para cada valor único. Si bien es lo opuesto a rotar, se debe tener en cuenta que no es equivalente, ya que no puede separar filas con valores idénticos que se hayan agregado ni dividir combinaciones en las columnas originales (se puede hacerlo más adelante mediante una transformación dividida). Por ejemplo, si tiene la siguiente carga:

year	month	de	uk	us
2020	Ene	42	32	64
2020	Feb	11	67	18
2021	Ene			90

Se puede anular la rotación de las columnas “de”, “uk” y “us” y convertirlas en una columna “país” con el valor “importe” y obtener lo siguiente (ordenado aquí a modo ilustrativo):

year	month	país	importe
2020	Ene	uk	32
2020	Ene	de	42
2020	Ene	us	64
2020	Feb	uk	67
2020	Feb	de	11
2020	Feb	us	18
2021	Ene	us	90

Observe que las columnas que tienen un valor NULO (“de” y “uk” de enero de 2021) no se generan de forma predeterminada. Puede activar esa opción para obtener:

year	month	país	importe
2020	Ene	uk	32
2020	Ene	de	42
2020	Ene	us	64
2020	Feb	uk	67
2020	Feb	de	11
2020	Feb	us	18
2021	Ene	us	90
2021	Ene	de	
2021	Ene	uk	

Para agregar una transformación de anulación de rotación de columnas a filas, realice lo siguiente:

1. Abra el panel de recursos y, luego, elija Anular rotación de columnas en filas para agregar una nueva transformación al diagrama de trabajo. El nodo seleccionado en el momento de agregar el nodo será el nodo principal.
2. (Opcional) En la pestaña Propiedades del nodo, puede ingresar un nombre para el nodo en el diagrama de trabajo. Si todavía no se ha seleccionado un nodo principal, elija un nodo de la lista Nodos principales para utilizar como origen de entrada para la transformación.
3. En la pestaña Transformación, ingrese las nuevas columnas que se van a crear para que contengan los nombres y valores de las columnas seleccionadas para anular la rotación.

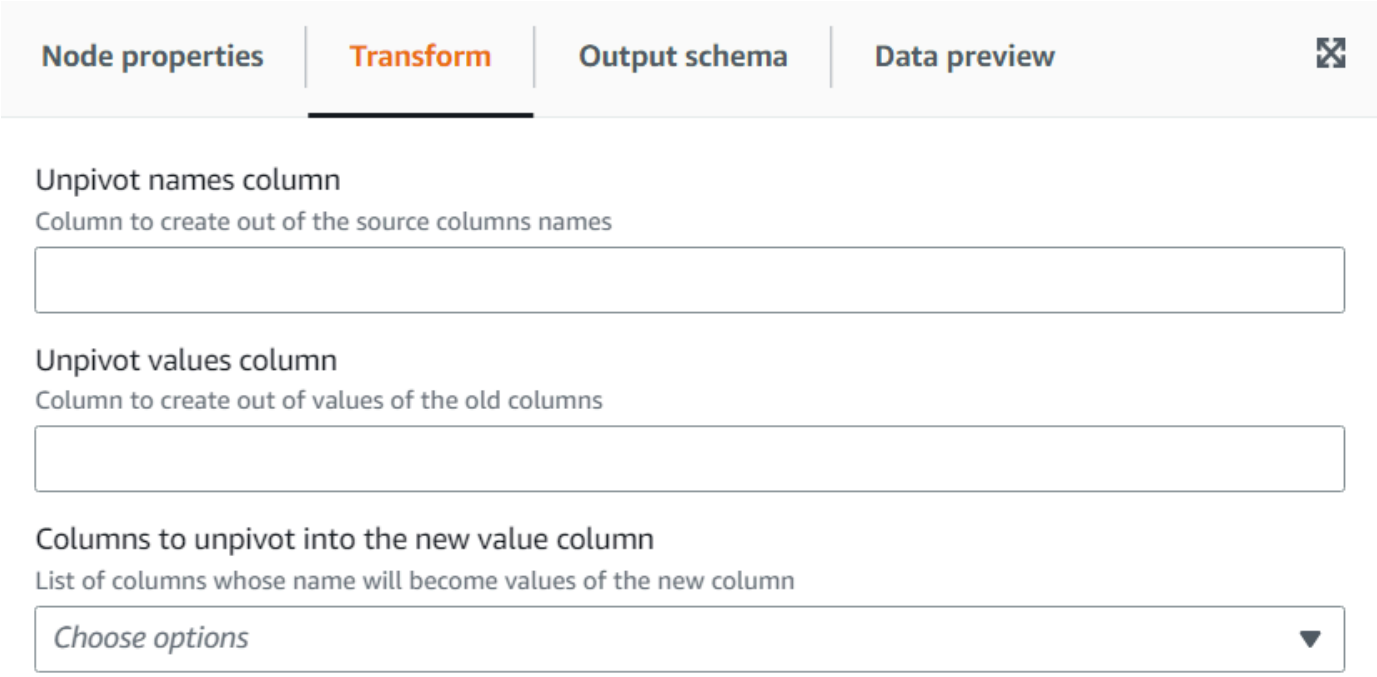

Uso de la transformación de Procesamiento de autobalance para optimizar el tiempo de ejecución

La transformación de Procesamiento de autobalance redistribuye los datos entre los trabajadores para mejorar el rendimiento. Esto ayuda en los casos en que los datos están desequilibrados o, tal como provienen del origen, no permiten un procesamiento paralelo suficiente. Esto es común cuando el origen está comprimido con gzip o es JDBC. La redistribución de los datos tiene un costo de rendimiento modesto, por lo que es posible que la optimización no siempre compense ese esfuerzo si los datos ya estaban bien equilibrados. En la imagen inferior, la transformación utiliza la repartición de Apache Spark para reasignar datos de forma aleatoria entre un número de particiones óptimo

para la capacidad del clúster. Para los usuarios avanzados, es posible ingresar varias particiones de forma manual. Además, se puede utilizar para optimizar la escritura de tablas particionadas al reorganizar los datos en función de columnas específicas. Esto da como resultado archivos de salida más consolidados.

1. Abra el panel de recursos y, a continuación, elija Procesamiento de autobalance para agregar una nueva transformación al diagrama de trabajo. El nodo seleccionado en el momento de agregar el nodo será el nodo principal.
2. (Opcional) En la pestaña Propiedades del nodo, puede ingresar un nombre para el nodo en el diagrama de trabajo. Si todavía no se ha seleccionado un nodo principal, elija un nodo de la lista Nodos principales para utilizar como origen de entrada para la transformación.
3. (Opcional) En la pestaña Transformación, puede ingresar varias particiones. En general, se recomienda dejar que el sistema decida este valor; sin embargo, puede ajustar el multiplicador o ingresar un valor específico si necesita controlarlo. Si va a guardar los datos particionados por columnas, puede elegir las mismas columnas como columnas de repartición. De esta forma, minimizará la cantidad de archivos en cada partición y evitará tener muchos archivos por partición, lo que dificultaría el rendimiento de las herramientas que consultan esos datos.

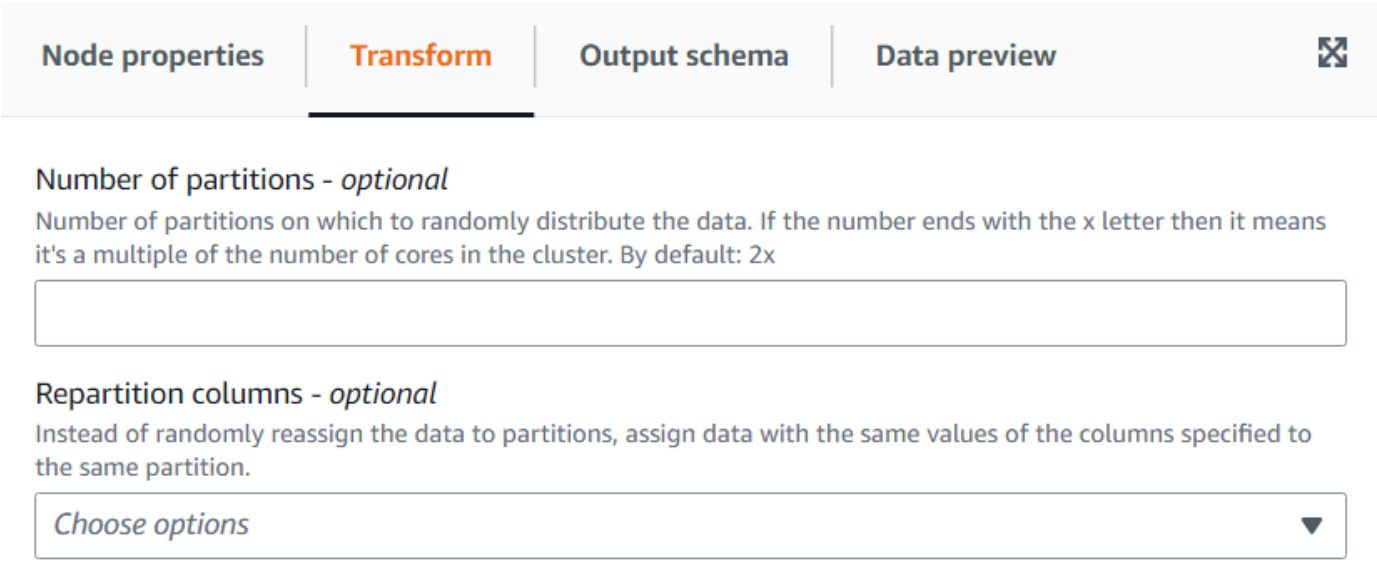

Uso de la transformación de columna derivada para combinar otras columnas

La transformación de Columna derivada permite definir una nueva columna basada en una fórmula matemática o expresión SQL en la que puede utilizar otras columnas de los datos, así como

constantes y literales. Por ejemplo, para obtener una columna de “porcentaje” a partir de las columnas “éxito” y “recuento”, puede ingresar la expresión SQL: “éxito * 100 / recuento || ‘%’”.

Ejemplo de resultado:

success	count	percentage
14	100	14 %
6	20	3 %
3	40	7,5 %

Para agregar una transformación de columna derivada:

1. Abra el panel de recursos y, a continuación, elija Columna derivada para agregar una nueva transformación al diagrama de trabajo. El nodo seleccionado en el momento de agregar el nodo será el nodo principal.
2. (Opcional) En la pestaña Propiedades del nodo, puede ingresar un nombre para el nodo en el diagrama de trabajo. Si todavía no se ha seleccionado un nodo principal, elija un nodo de la lista Nodos principales para utilizar como origen de entrada para la transformación.
3. En la pestaña Transformación, ingrese el nombre de la columna y la expresión de su contenido.

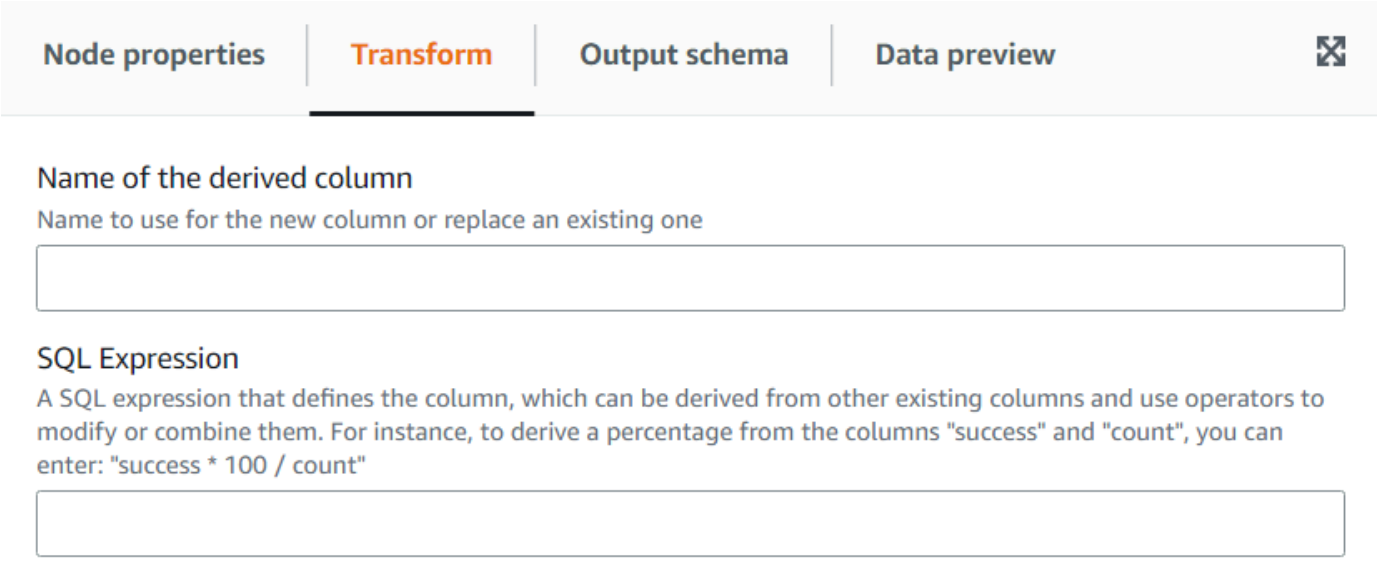

Uso de la transformación de búsqueda para agregar datos coincidentes de una tabla de catálogo

La transformación de búsqueda permite agregar columnas de una tabla de catálogo definida cuando las claves coinciden con las columnas de búsqueda definidas en los datos. Esto equivale a hacer una unión exterior izquierda entre los datos y la tabla de consulta al usar como condición columnas coincidentes.

Para agregar una transformación de búsqueda, realice lo siguiente:

1. Abra el panel de recursos y, luego, elija Búsqueda para agregar una nueva transformación al diagrama de trabajo. El nodo seleccionado en el momento de agregar el nodo será el nodo principal.
2. (Opcional) En la pestaña Propiedades del nodo, puede ingresar un nombre para el nodo en el diagrama de trabajo. Si todavía no se ha seleccionado un nodo principal, elija un nodo de la lista Nodos principales para utilizar como origen de entrada para la transformación.
3. En la pestaña Transformación, ingrese el nombre completo de la tabla de catálogo que desee utilizar para realizar las búsquedas. Por ejemplo, si la base de datos es “mydb” y la tabla es “mytable”, ingrese “mydb.mytable”. A continuación, ingrese los criterios para buscar una coincidencia en la tabla de consulta, si la clave de búsqueda está compuesta. Ingrese la lista de columnas clave separadas por comas. Si una o más de las columnas clave no tienen el mismo nombre, se debe definir el mapeo de coincidencias.

   Por ejemplo, si las columnas de datos son “user_id” y “region” y en la tabla de usuarios las columnas correspondientes se denominan “id” y “region”, en el campo Columnas que deben coincidir, ingrese: “user_id=id, region”. Puede usar region=region, pero no es necesario, ya que son lo mismo.
4. Por último, ingrese las columnas que desee extraer de la fila correspondiente en la tabla de consulta para incorporarlas a los datos. Si no se encontró ninguna coincidencia, dichas columnas se establecerán en CERO.

> **Note**
>
> Debajo de la transformación de búsqueda, se utiliza una unión a la izquierda para ser eficiente. Si la tabla de búsqueda tiene una clave compuesta, asegúrese de que las columnas que deben coincidir estén configuradas para que coincidan con todas las columnas clave, de modo que solo pueda producirse una coincidencia. De lo contrario,

coincidirán varias filas de búsqueda y, como resultado, se agregarán filas adicionales para cada una de esas coincidencias.

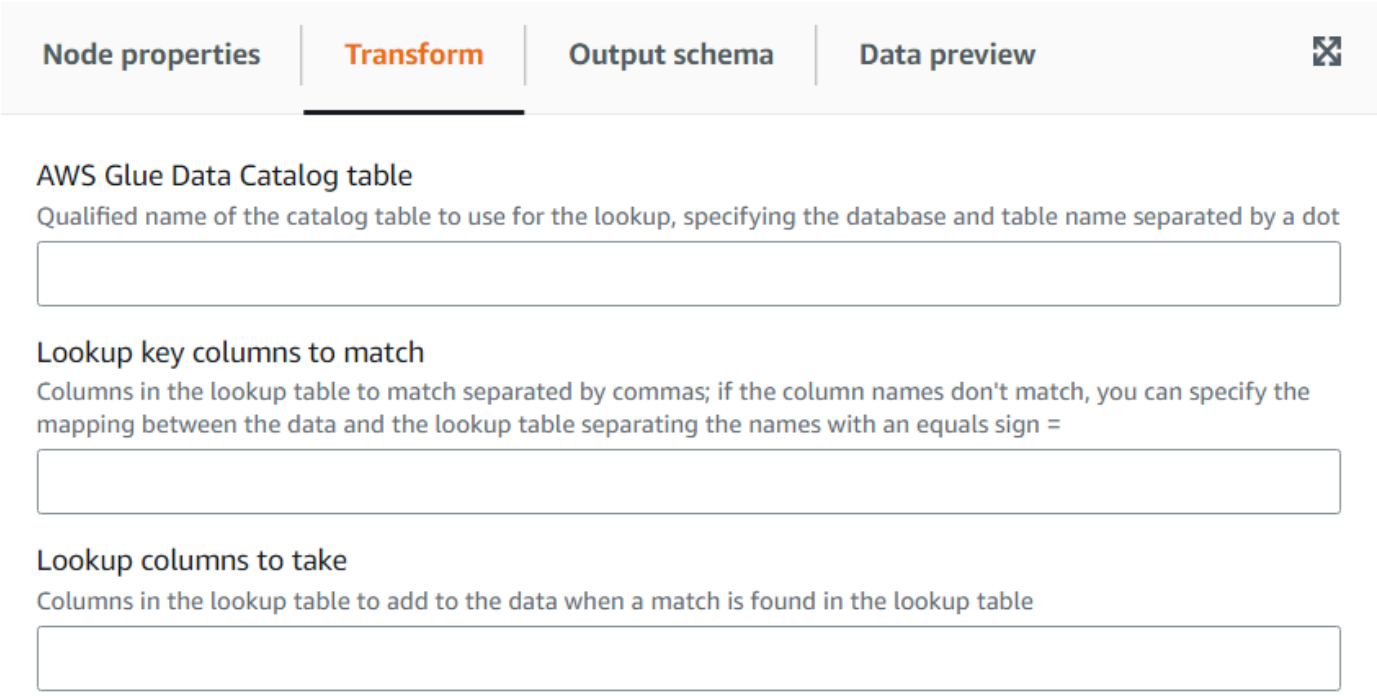

Uso de la transformación Desglosar matriz o Mapa en filas

La transformación Desglosar permite extraer valores de una estructura anidada en filas individuales que son más fáciles de manipular. En el caso de una matriz, la transformación generará una fila para cada valor de la matriz, mediante la replicación de los valores de las demás columnas de la fila. En el caso de un mapa, la transformación generará una fila para cada entrada con la clave y el valor como columnas más cualquier otra columna de la fila.

Por ejemplo, si tenemos este conjunto de datos que tiene una columna de matriz llamada “categorías” con varios valores.

product_id	categoría
1	[deportes, invierno]
2	[jardín, herramientas]

product_id	categoría
3	[video juegos]
4	[juego, juego de mesa, social]
5	[]

Si desglosas la columna de “categorías” en una columna con el mismo nombre, la anularás. Puede seleccionar si desea incluir los valores NULO para obtener lo siguiente (ordenados con fines ilustrativos):

product_id	categoría
1	deportes/
1	invierno
2	jardín
2	herramienta
3	video juegos
4	partido
4	juego de mesa
4	social
5	

Para agregar una transformación de Desglosar matriz o Mapa en filas:

1. Abra el panel de recursos y, a continuación, elija Desglosar matriz o Mapa en filas para agregar una nueva transformación al diagrama de trabajo. El nodo seleccionado en el momento de agregar el nodo será el nodo principal.

2. (Opcional) En la pestaña Propiedades del nodo, puede ingresar un nombre para el nodo en el diagrama de trabajo. Si todavía no se ha seleccionado un nodo principal, elija un nodo de la lista Nodos principales para utilizar como origen de entrada para la transformación.
3. En la pestaña Transformación, elija la columna que desee desglosar (debe ser de tipo matriz o mapa). A continuación, ingrese un nombre para la columna para los elementos de la matriz o los nombres de las columnas para las claves y los valores si va a descomponer un mapa.
4. (Opcional) En la pestaña Transformación, de forma predeterminada, si la columna que se va a desglosar es NULA o tiene una estructura vacía, se omitirá en el conjunto de datos desglosado. Si desea conservar la fila (con las nuevas columnas como NULAS), active la casilla “Incluir valores NULOS”.

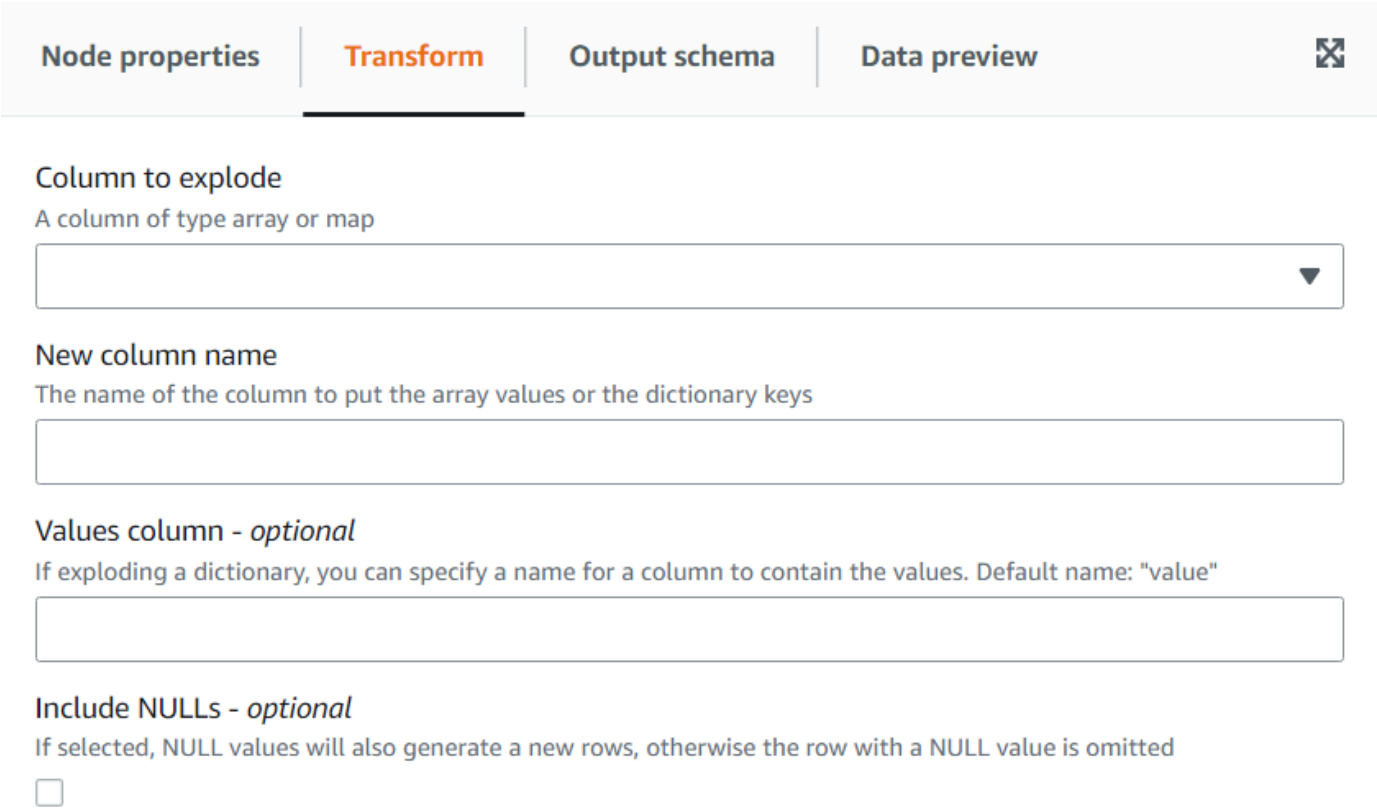

Uso de la transformación de registro de coincidencias para invocar una transformación de clasificación de datos existente

Esta transformación invoca una transformación de clasificación de datos de machine learning de registro de coincidencias existente.

La transformación evalúa los datos actuales y los compara con el modelo entrenado en función de las etiquetas. Se agrega una columna “match_id” para asignar cada fila a un grupo de elementos que

se consideran equivalentes según el entrenamiento del algoritmo. Para obtener más información, consulte Registro de coincidencias con Lake Formation FindMatches.

> **Note**
>
> La versión AWS Glue utilizada en el trabajo visual debe coincidir con la versión que AWS Glue se utilizó para crear la transformación de registro de coincidencias.

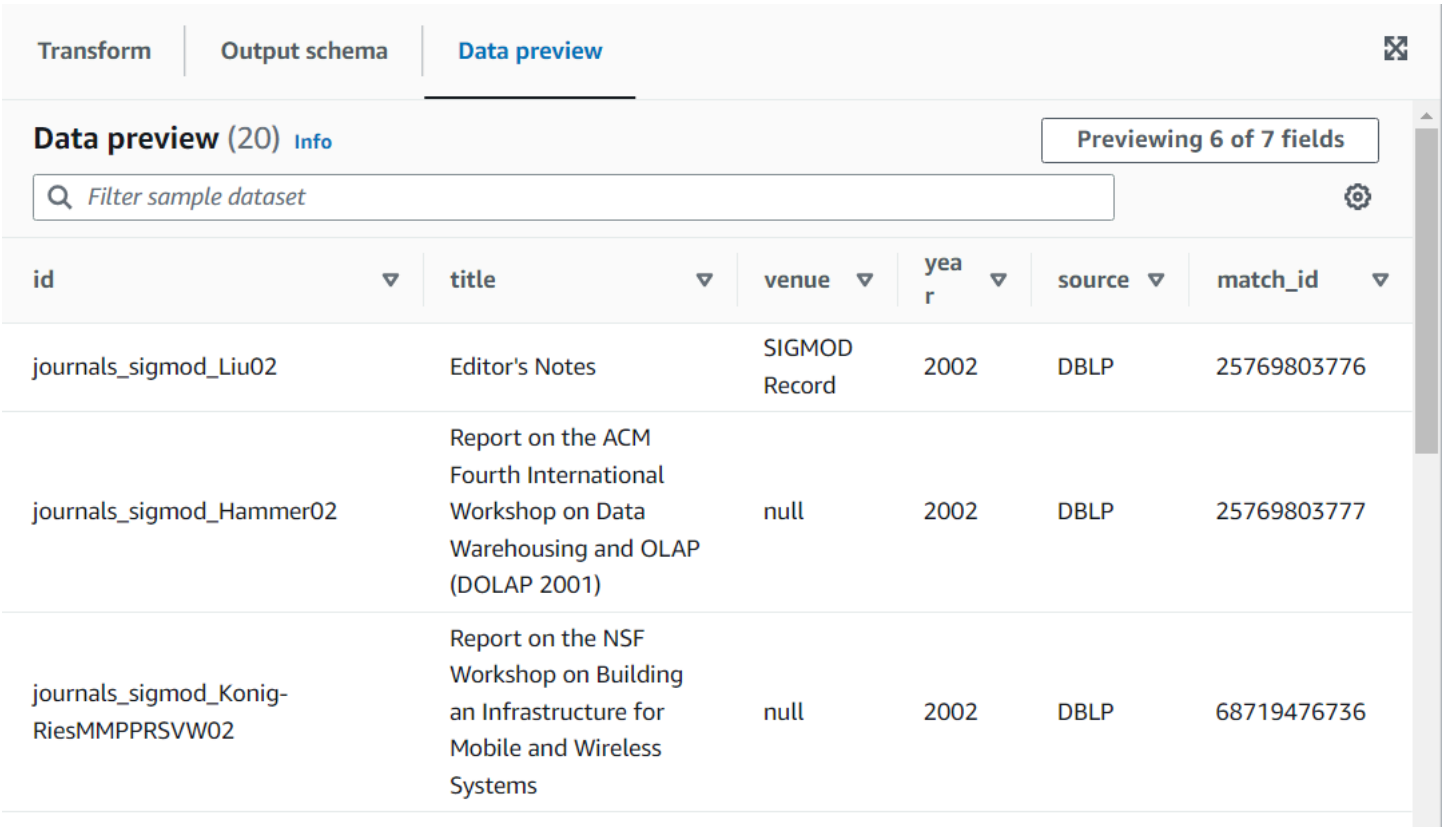

Para agregar un nodo de transformación de registro de coincidencias al diagrama de trabajo

1. Abra el panel de recursos y, luego, elija Registro de coincidencias para agregar una nueva transformación al diagrama de trabajo. El nodo seleccionado en el momento de agregar el nodo será el nodo principal.
2. (Opcional) En la pestaña propiedades del nodo, puede ingresar un nombre para el nodo en el diagrama de trabajo. Si todavía no está seleccionado un nodo principal, elija un nodo de la lista Node parents (Nodos principales) para utilizar como origen de entrada para la transformación.
3. En la pestaña Transformación, ingrese el ID obtenido de la página de transformaciones de machine learning:

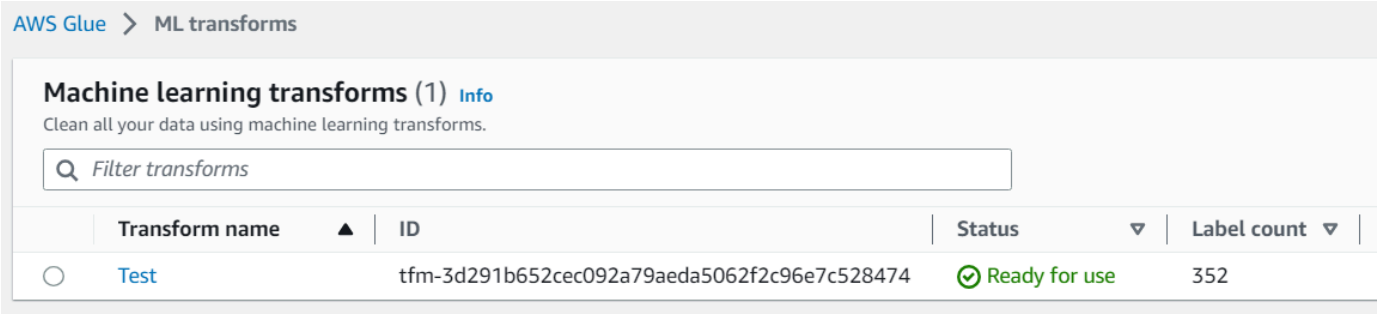

4. (Opcional) En la pestaña Transformación, se puede marcar la opción para agregar las puntuaciones de confianza. A costa de un cálculo extra, el modelo estimará una puntuación de confianza para cada partido como una columna adicional.

Eliminación de filas nulas

Esta transformación elimina del conjunto de datos las filas que tienen todas las columnas como nulas. Además, se puede ampliar este criterio para incluir campos vacíos, a fin de mantener las filas en las que al menos una columna no esté vacía.

Para agregar un nodo de transformación de eliminación de filas nulas campo al diagrama de trabajo

1. Abra el panel de recursos y, luego, elija Eliminar filas nulas para agregar una nueva transformación al diagrama de trabajo. El nodo seleccionado en el momento de agregar el nodo será el nodo principal.
2. (Opcional) En la pestaña propiedades del nodo, puede ingresar un nombre para el nodo en el diagrama de trabajo. Si todavía no está seleccionado un nodo principal, elija un nodo de la lista Node parents (Nodos principales) para utilizar como origen de entrada para la transformación.
3. (Opcional) En la pestaña Transformación, active la opción Extendida si desea que las filas no solo no sean nulas, sino que tampoco estén vacías, de forma que las cadenas, matrices o mapas vacíos se considerarán nulos a los efectos de esta transformación.

Análisis de una columna de cadena que contiene datos JSON

Esta transformación analiza una columna de cadena que contiene datos JSON y la convierte en una estructura o una columna de matriz, en función de si el JSON es un objeto o una matriz, respectivamente. Si lo desea, puede conservar tanto la columna analizada como la original.

El esquema JSON se puede proporcionar o deducir (en el caso de los objetos de JSON), con un muestreo opcional.

Para agregar un nodo de transformación de columnas JSON de análisis al diagrama de trabajo

1. Abra el panel de recursos y, luego, elija Analizar columna JSON para agregar una nueva transformación al diagrama de trabajo. El nodo seleccionado en el momento de agregar el nodo será el nodo principal.
2. (Opcional) En la pestaña propiedades del nodo, puede ingresar un nombre para el nodo en el diagrama de trabajo. Si todavía no está seleccionado un nodo principal, elija un nodo de la lista Node parents (Nodos principales) para utilizar como origen de entrada para la transformación.
3. En la pestaña Transformación, selecciona la columna que contiene la cadena JSON.
4. (Opcional) En la pestaña Transformación, ingrese el esquema que siguen los datos de JSON con la sintaxis SQL, por ejemplo: “field1 STRING, field2 INT” en el caso de un objeto o “ARRAY<STRING>” en el caso de una matriz.

   Si se trata de una matriz, se requiere el esquema, pero en el caso de un objeto, si no se especifica el esquema, se deducirá a partir de los datos. Para reducir el impacto de inferir el esquema (especialmente en un conjunto de datos grande), puede evitar leer los datos completos dos veces. Para ello, ingrese una proporción de muestras que se utilizará para inferir el esquema. Si el valor es inferior a 1, se utiliza la proporción correspondiente de muestras aleatorias para deducir el esquema. Si los datos son fiables y el objeto es concordante entre las filas, se puede utilizar una proporción pequeña como 0,1 para mejorar el rendimiento.
5. (Opcional) En la pestaña Transformación, se puede ingresar un nombre de columna nuevo si desea conservar tanto la columna de cadena original como la columna analizada.

Extracción de una ruta JSON

Esta transformación extrae nuevas columnas de una columna de cadena JSON. Esta transformación resulta útil cuando solo se necesitan unos pocos elementos de datos y no se desea importar todo el contenido de JSON al esquema de la tabla.

Para agregar un nodo de transformación de Extracción de Ruta JSON al diagrama de trabajo

1. Abra el panel de recursos y, a continuación, elija Extracción de ruta JSON para agregar una nueva transformación al diagrama de trabajo. El nodo seleccionado en el momento de agregar el nodo será el nodo principal.
2. (Opcional) En la pestaña propiedades del nodo, puede ingresar un nombre para el nodo en el diagrama de trabajo. Si todavía no está seleccionado un nodo principal, elija un nodo de la lista Node parents (Nodos principales) para utilizar como origen de entrada para la transformación.

3. En la pestaña Transformación, selecciona la columna que contiene la cadena JSON. Ingrese una o más expresiones de ruta JSON separadas por comas, cada una de las cuales haga referencia a cómo extraer un valor de la matriz o el objeto JSON. Por ejemplo, si la columna JSON contiene un objeto con las propiedades “prop_1” y “prop2”, puede extraer ambos al especificar los nombres “prop_1, prop_2”.

   Si el campo JSON tiene caracteres especiales, por ejemplo, para extraer la propiedad de este JSON `{"a. a": 1}`, puede usar la ruta `$['a. a']`. La excepción es la coma porque está reservada para separar rutas. A continuación, ingrese los nombres de columna correspondientes para cada ruta, separados por comas.

4. (Opcional) En la pestaña Transformación, puedes marcar la casilla para eliminar la columna JSON una vez extraída. Esto tiene sentido si no necesitas el resto de los datos JSON una vez extraídas las partes que necesitas.

Extracción de fragmentos de cadenas mediante una expresión regular

Esta transformación extrae fragmentos de cadenas mediante una expresión regular y crea una nueva columna a partir de ella o varias columnas si se utilizan grupos de expresiones regulares.

Para agregar un nodo de transformación de extractor de expresiones regulares al diagrama de trabajo:

1. Abra el panel de recursos y, luego, elija Extractor de expresiones regulares para agregar una nueva transformación al diagrama de trabajo. El nodo seleccionado en el momento de agregar el nodo será el nodo principal.
2. (Opcional) En la pestaña propiedades del nodo, puede ingresar un nombre para el nodo en el diagrama de trabajo. Si todavía no está seleccionado un nodo principal, elija un nodo de la lista Node parents (Nodos principales) para utilizar como origen de entrada para la transformación.
3. En la pestaña Transformación, ingrese la expresión regular y la columna en la que se debe aplicar. Luego, ingrese el nombre de la nueva columna en la que desee almacenar la cadena correspondiente. La nueva columna será nula solo si la columna de origen es nula; si la expresión regular no coincide, la columna estará vacía.

   Si la expresión regular usa grupos, habrá un nombre de columna correspondiente separado por una coma, pero puede omitir los grupos al dejar el nombre de la columna vacío.

Por ejemplo, si tiene una columna “fecha de compra” con una cadena que utiliza formatos de fecha ISO largos y cortos, querrá extraer el año, el mes, el día y la hora, cuando estén disponibles. Tenga en cuenta que el grupo de horas es opcional; de lo contrario, en las filas donde no esté disponible, todos los grupos extraídos serían cadenas vacías (ya que la expresión regular no coincide). En este caso, no queremos que el grupo haga que la hora sea opcional, sino la interna, por lo que dejamos el nombre en blanco y no se extrae (ese grupo incluiría el carácter T).

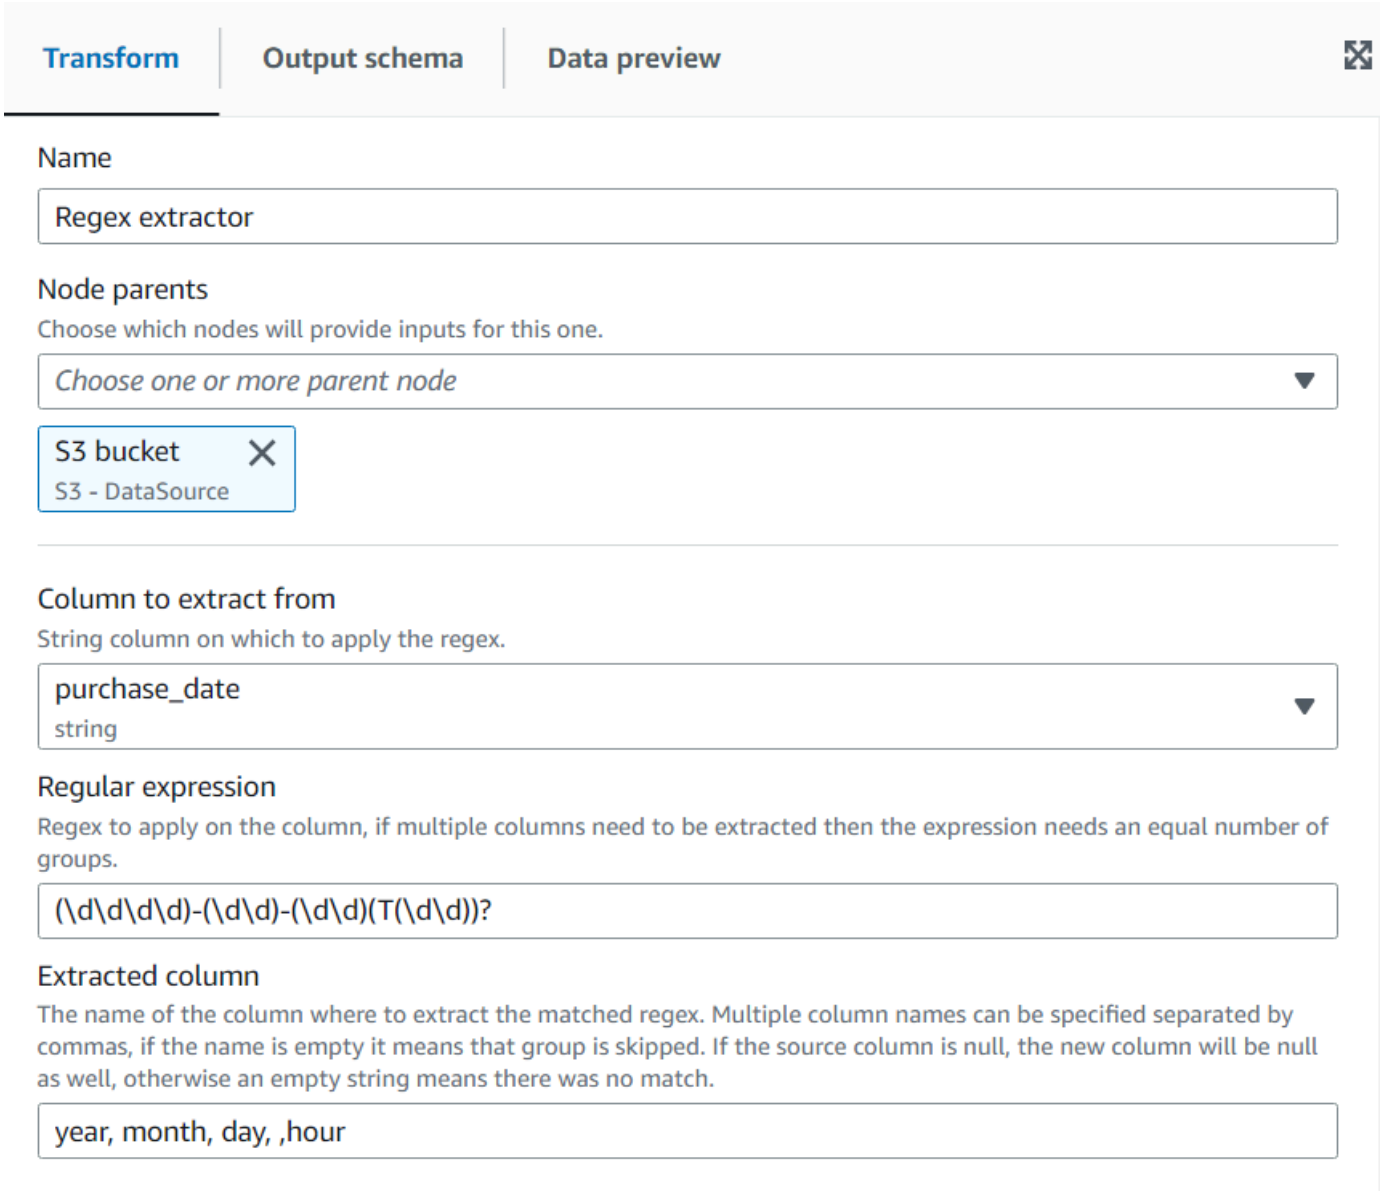

Como resultado, se obtiene la vista previa de los datos:

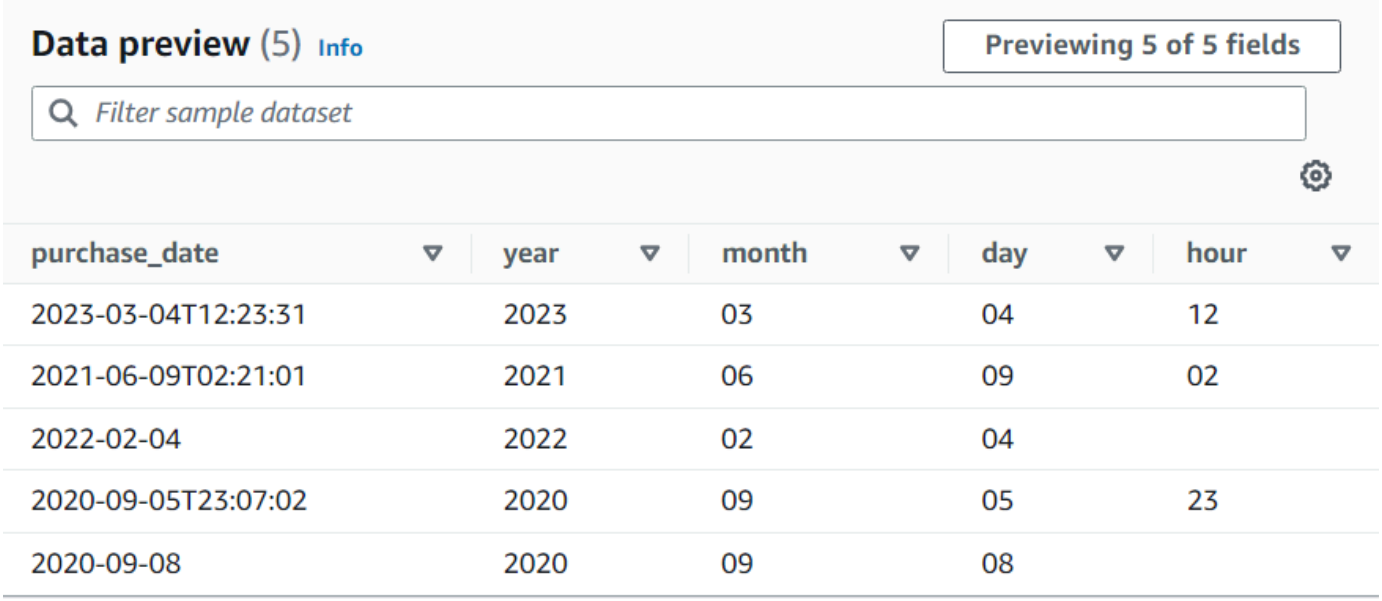

Crear una transformación personalizada

Si necesita realizar transformaciones más complicadas en sus datos o desea agregar claves de propiedad de datos al conjunto de datos, puede agregar una transformación Custom code (Código personalizado) al diagrama de trabajo. El nodo Custom code (Código personalizado) permite introducir un script que realiza la transformación.

Cuando utilice el código personalizado, debe utilizar un editor de esquemas para indicar los cambios realizados en la salida a través del código personalizado. Cuando edita el esquema, puede realizar las siguientes acciones:

- Agregar o eliminar claves de propiedades de datos
- Cambiar el tipo de datos de las claves de propiedad de datos
- Cambiar el nombre de las claves de propiedad de datos
- Reestructurar una clave de propiedad anidada

Debe utilizar una transformación SelectFromCollection (Seleccionar desde la recopilación) para elegir un único `DynamicFrame` del resultado del nodo de transformación personalizado antes de enviar la salida a una ubicación de destino.

Utilice las siguientes tareas para agregar un nodo de transformación personalizado al diagrama de trabajo.

Agregar un nodo de transformación de código personalizado al diagrama de trabajo

Para agregar un nodo de transformación personalizado al diagrama de trabajo

1. (Opcional) abra el panel de recursos y elija Custom transform para agregar una nueva transformación al diagrama de trabajo, si es necesario.
2. En la pestaña Node properties (Propiedades del nodo), ingrese un nombre para el nodo en el diagrama de trabajo. Si todavía no se ha seleccionado un nodo principal, o si desea varias entradas para la transformación personalizada, elija un nodo en la lista Node parents (Nodos principales) que se utilizará como origen de entrada para la transformación.

Introducción de código para el nodo de transformación personalizado

Puede escribir o copiar el código en un campo de entrada. El trabajo utiliza este código para realizar la transformación de datos. Puede proporcionar un fragmento de código en Python o Scala. El código debe tener uno o varios `DynamicFrames` como entrada y devuelve una recopilación de `DynamicFrames`.

Para escribir el script para un nodo de transformación personalizado

1. Con el nodo de transformación personalizado seleccionado en el diagrama de trabajo, elija la pestaña Transform (Transformación).
2. En el campo de entrada de texto en el encabezado Code block (Bloque de código), pegue o escriba el código para la transformación. El código que utilice debe coincidir con el lenguaje especificado para el trabajo en la pestaña Job details (Detalles del trabajo).

   Al hacer referencia a los nodos de entrada en el código, AWS Glue Studio nombra los `DynamicFrames` que devuelven los nodos del diagrama de trabajo de manera secuencial en función del orden de creación. Utilice uno de los siguientes métodos de nomenclatura en el código:

   - Generación de código clásico: utilice nombres funcionales para hacer referencia a los nodos del diagrama de trabajo.
     - Nodo de origen de datos: `DataSource0`, `DataSource1`, `DataSource2`, etc.
     - Nodos de transformación: `Transform0`, `Transform1`, `Transform2`, etc.
   - Nueva generación de código: utilice el nombre especificado en la pestaña Node properties (Propiedades del nodo) de un nodo, anexado con '`_node1`', '`_node2`', y así sucesivamente.

Por ejemplo, `S3bucket_node1`, `ApplyMapping_node2`, `S3bucket_node2`, `MyCustomNodeName_node1`.

Para obtener más información acerca del nuevo generador de código, consulte Generación de código de script.

Los siguientes ejemplos muestran el formato del código que se va a introducir en el cuadro de código:

Python

En el siguiente ejemplo se toma el primer `DynamicFrame` recibido, se convierte en un valor de `DataFrame` para aplicar el método de filtro nativo (se mantienen solo los registros que tienen más de 1000 votos), luego se convierte nuevamente en un `DynamicFrame` antes de que se devuelva.

```
def FilterHighVoteCounts (glueContext, dfc) -> DynamicFrameCollection:
    df = dfc.select(list(dfc.keys())[0]).toDF()
    df_filtered = df.filter(df["vote_count"] > 1000)
    dyf_filtered = DynamicFrame.fromDF(df_filtered, glueContext, "filter_votes")
    return(DynamicFrameCollection({"CustomTransform0": dyf_filtered}, glueContext))
```

Scala

En el siguiente ejemplo se toma el primer `DynamicFrame` recibido, se convierte en un valor de `DataFrame` para aplicar el método de filtro nativo (se mantienen solo los registros que tienen más de 1000 votos), luego se convierte nuevamente en un `DynamicFrame` antes de que se devuelva.

```
object FilterHighVoteCounts {
  def execute(glueContext : GlueContext, input : Seq[DynamicFrame]) :
 Seq[DynamicFrame] = {
    val frame = input(0).toDF()
    val filtered = DynamicFrame(frame.filter(frame("vote_count") > 1000),
 glueContext)
    Seq(filtered)
  }
}
```

Edición de esquema para un nodo de transformación personalizado

Cuando utiliza un nodo de transformación personalizado, AWS Glue Studio no puede inferir automáticamente los esquemas de salida creados por la transformación. Utilice el editor de esquemas para describir los cambios de esquema implementados por el código de transformación personalizado.

Un nodo de código personalizado puede tener cualquier número de nodos principales, cada uno de los cuales proporciona un `DynamicFrame` como entrada para su código personalizado. Un nodo de código personalizado devuelve una recopilación de `DynamicFrames`. Cada `DynamicFrame` que se utiliza como entrada tiene asociado un esquema. Debe agregar un esquema que describa cada `DynamicFrame` devuelto por el nodo de código personalizado.

> **Note**
>
> Cuando configura su propio esquema en una transformación personalizada, AWS Glue Studio no hereda esquemas de nodos anteriors. Para actualizar el esquema, seleccione el nodo de transformación personalizada y, a continuación, elija la pestaña Data preview (Vista previa de datos). Una vez generada la vista previa, elija 'Use Preview Schema' (Usar esquema de vista previa). A continuación, el esquema será reemplazado por el esquema utilizando los datos de vista previa.

Para editar los esquemas de un nodo de transformación personalizado

1. Con el nodo de transformación personalizado seleccionado en el diagrama de trabajo, elija la pestaña Output schema (Esquema de salida), en el panel de detalles del nodo.
2. Seleccione Edit (Editar) para realizar cambios al esquema.

   Si tiene claves de propiedad de datos anidadas, como una matriz u objeto, puede elegir el ícono Expand-Rows (Expandir filas) ( ) en la parte superior derecha del panel de cada esquema para expandir la lista de claves de propiedades de datos secundarias. Después de seleccionarlo, el ícono cambia a Collapse-Rows (Contraer filas) ( ), que puede elegir para contraer la lista de claves de propiedad secundarias.

3. Modifique el esquema mediante las siguientes acciones en la sección situada en la parte derecha de la página:

   - Para cambiar el nombre de una clave de propiedad, coloque el cursor en el cuadro de texto Key (Clave) para la clave de propiedad y, a continuación, escriba el nuevo nombre.
   - Para cambiar el tipo de datos de una clave de propiedad, utilice la lista para elegir un nuevo tipo de datos para la clave de propiedad.
   - Para agregar una nueva clave de propiedad de nivel superior al esquema, elija el ícono Overflow (Desbordamiento) (⋯) a la izquierda del botón Cancel (Cancelar) y luego elija Add root key (Agregar clave raíz).
   - Para agregar una clave de propiedad secundaria al esquema, elija el ícono Add-Key (Agrega clave) asociado a la clave principal. Escriba un nombre para la clave secundaria y elija el tipo de datos.
   - Para eliminar una clave de propiedad del esquema, elija el ícono Remove (Eliminar) (🗑) en el extremo derecho del nombre de la clave.

4. Si su código de transformación personalizado utiliza múltiples `DynamicFrames`, puede agregar esquemas de salida adicionales.

   - Para agregar un esquema nuevo, vacío, elija la opción Overflow (Desbordamiento) (⋯) y, a continuación, elija Add output schema (Agregar esquema de salida).
   - Para copiar un esquema existente en un nuevo esquema de salida, asegúrese de que el esquema que desea copiar se muestra en el selector de esquema. Elija el ícono Overflow (Desbordamiento) (⋯) y, a continuación, elija Duplicate (Duplicar).

   Si desea eliminar un esquema de salida, asegúrese de que el esquema que desea copiar se muestra en el selector de esquema. Elija el ícono Overflow (Desbordamiento) (⋯) y, a continuación, elija Delete (Eliminar).

5. Agregue nuevas claves raíz al nuevo esquema o edite las claves duplicadas.
6. Cuando modifique los esquemas de salida, elija el botón Apply (Aplicar) para guardar los cambios y salir del editor de esquemas.

   Si no desea guardar los cambios, elija Cancel (Cancelar).

Configurar la salida de transformación personalizada

Una transformación de código personalizado devuelve una recopilación de `DynamicFrames`, aún cuando haya solo un `DynamicFrame` en el conjunto de resultados.

Para procesar la salida desde un nodo de transformación personalizado

1. Agregue un nodo de transformación SelectFromCollection (Seleccionar desde la recopilación), que tenga el nodo de transformación personalizado como su nodo principal. Actualice esta transformación para indicar qué conjunto de datos desea utilizar. Para obtener más información, consulte Uso de SelectFromCollection (Seleccionar desde la recopilación) para elegir qué conjunto de datos desea mantener.
2. Agregue una transformación Seleccionar desde recopilación adicional al diagrama de trabajo si desea utilizar `DynamicFrames` adicionales, producidos por el nodo de transformación personalizado.

   Considere un escenario en el que agrega un nodo de transformación personalizado para dividir un conjunto de datos de vuelo en varios conjuntos de datos, pero duplica algunas de las claves de propiedad de identificación en cada esquema de salida, como la fecha de vuelo o el número de vuelo. Agregue un nodo de transformación Seleccionar desde la recopilación para cada esquema de salida, con el nodo de transformación personalizado como su nodo principal.
3. (Opcional) a continuación, puede usar cada nodo de transformación Seleccionar desde la recopilación como entrada para otros nodos del trabajo, o como nodo principal para un nodo de destino de datos.

Transformación de datos con transformaciones visuales personalizadas

Las transformaciones visuales personalizadas permiten crear transformaciones y ponerlas a disposición de los usuarios para que las utilicen en trabajos de AWS Glue Studio. Las transformaciones visuales personalizadas permiten a los desarrolladores de ETL, que tal vez no

estén familiarizados con la codificación, buscar y utilizar una biblioteca de transformaciones cada vez mayor mediante la interfaz de AWS Glue Studio.

Puede crear una transformación visual personalizada y, a continuación, subirla a Amazon S3 para que esté disponible para su uso a través del editor visual en AWS Glue Studio para ocuparse de estos trabajos.

Temas

- Introducción a las transformaciones visuales personalizadas
- Paso 1. Crear un archivo de configuración JSON
- Paso 2. Implementar la lógica de transformación
- Paso 3. Validar y solucionar los problemas de las transformaciones visuales personalizadas en AWS Glue Studio
- Paso 4. Actualizar las transformaciones visuales personalizadas según sea necesario
- Paso 5. Usar transformaciones visuales personalizadas en AWS Glue Studio
- Ejemplos de uso
- Ejemplos de scripts visuales personalizados
- Video

Introducción a las transformaciones visuales personalizadas

Para crear una transformación visual personalizada, siga estos pasos.

- Paso 1. Crear un archivo de configuración JSON
- Paso 2. Implementar la lógica de transformación
- Paso 3. Validar la transformación visual personalizada
- Paso 4. Actualizar la transformación visual personalizada según sea necesario
- Paso 5. Utilizar la transformación visual personalizada en AWS Glue Studio

Para empezar, configure el bucket de Amazon S3 y continúe con el Paso 1. Crear un archivo de configuración JSON.

Requisitos previos

Las transformaciones proporcionadas por los clientes residen en una cuenta de AWS de cliente. Esa cuenta es la propietaria de las transformaciones y, por lo tanto, tiene todos los permisos para verlas (buscarlas y usarlas), editarlas o eliminarlas.

Para utilizar una transformación personalizada en AWS Glue Studio, tendrá que crear y subir dos archivos al bucket de activos de Amazon S3 de esa cuenta de AWS:

- Archivo Python: contiene la función de transformación
- Archivo JSON: describe la transformación. También se conoce como el archivo de configuración que se requiere para definir la transformación.

Para emparejar los archivos, utilice el mismo nombre para ambos. Por ejemplo:

- myTransform.json
- myTransform.py

Si lo desea, puede dar a una transformación visual personalizada un icono personalizado al proporcionar un archivo SVG que contenga el icono. Para emparejar los archivos, utilice el mismo nombre para el icono:

- myTransform.svg

AWS Glue Studio los combinará automáticamente mediante los nombres de archivo correspondientes. Los nombres de los archivos no pueden ser los mismos para los módulos existentes.

Convención recomendada para el nombre del archivo de transformación

AWS Glue Studio importará el archivo como un módulo (por ejemplo, `import myTransform`) en el script del trabajo. Por lo tanto, el nombre del archivo debe seguir las mismas reglas de nomenclatura establecidas para los nombres de variables de Python (identificadores). En concreto, deben empezar por una letra o un guion bajo y estar compuestos en su totalidad por letras, dígitos o guiones bajos.

> **Note**
>
> Asegúrese de que el nombre del archivo de transformación no entre en conflicto con los módulos de Python cargados existentes (por ejemplo, `sys, array, copy`, etc.) para evitar problemas inesperados en tiempo de ejecución.

Configuración del bucket de Amazon S3

Las transformaciones que cree se almacenan en Amazon S3 y son propiedad de su cuenta de AWS. Para crear nuevas transformaciones visuales personalizadas, basta con que suba archivos (json y py) a la carpeta de activos de Amazon S3, en la que se almacenan actualmente los scripts de todos los trabajos (por ejemplo, `s3://aws-glue-assets-<accountid>-<region>/transforms`). Si utiliza un icono personalizado, cárguelo también. De forma predeterminada, AWS Glue Studio leerá todos los archivos. json de la carpeta /transforms en el mismo bucket de S3.

Paso 1. Crear un archivo de configuración JSON

Se necesita un archivo de configuración JSON para definir y describir la transformación visual personalizada. A continuación se indica el esquema para el archivo de configuración.

Estructura del archivo JSON

Campos

- `name: string`: (obligatorio) nombre del sistema de transformación utilizado para identificar las transformaciones. Siga las mismas reglas de nomenclatura establecidas para los nombres de variables de Python (identificadores). En concreto, deben empezar por una letra o un guion bajo y estar compuestos en su totalidad por letras, dígitos o guiones bajos.
- `displayName: string`: (opcional) nombre de la transformación que se muestra en el editor de trabajos visuales de AWS Glue Studio. Si no se especifica ningún valor de `displayName`, el valor de `name` se usa como nombre de la transformación en AWS Glue Studio.
- `description: string`: (opcional) la descripción de la transformación se muestra en AWS Glue Studio y se puede buscar.
- `functionName: string`: (obligatorio) el nombre de la función de Python se utiliza para identificar la función que se va a invocar en el script de Python.
- `path: string`: (opcional) la ruta completa de Amazon S3 al archivo de origen de Python. Si no se especifica, AWS Glue utiliza la coincidencia de nombres de archivo para emparejar

los archivos .json y .py. Por ejemplo, el nombre del archivo JSON (`myTransform.json`) se emparejará con el archivo Python (`myTransform.py`) en la misma ubicación de Amazon S3.

- `parameters: Array of TransformParameter object`: (opcional) la lista de parámetros que se va a mostrar al configurarlos en el editor visual de AWS Glue Studio.

Campos de TransformParameters

- `name: string`: (obligatorio) el nombre del parámetro que se pasará a la función de Python como argumento con nombre en el script del trabajo. Siga las mismas reglas de nomenclatura establecidas para los nombres de variables de Python (identificadores). En concreto, deben empezar por una letra o un guion bajo y estar compuestos en su totalidad por letras, dígitos o guiones bajos.
- `displayName: string`: (opcional) nombre de la transformación que se muestra en el editor de trabajos visuales de AWS Glue Studio. Si no se especifica ningún valor de `displayName`, el valor de `name` se usa como nombre de la transformación en AWS Glue Studio.
- `type: string`: (obligatorio) el tipo de parámetro que acepta los tipos de datos comunes de Python. Valores válidos: “str” | “int” | “float” | “list” | “bool”.
- `isOptional: boolean`: (opcional) determina si el parámetro es opcional. De forma predeterminada, todos los parámetros son obligatorios.
- `description: string`: (opcional) la descripción se muestra en AWS Glue Studio para ayudar al usuario a configurar el parámetro de transformación.
- `validationType: string`: (opcional) define la forma en que se valida este parámetro. Actualmente, solo admite expresiones regulares. De forma predeterminada, el tipo de validación se establece en `RegularExpression`.
- `validationRule: string`: (opcional) expresión regular que se utiliza para validar la entrada del formulario antes de enviarlo cuando `validationType` se establece en `RegularExpression`. La sintaxis de las expresiones regulares debe ser compatible con las especificaciones de RegExp de ECMAScript.
- `validationMessage: string`: (opcional) el mensaje que se mostrará cuando se produzca un error en la validación.
- `listOptions: An array of TransformParameterListOption object` O un `string` o el valor de cadena 'columna': (opcional) opciones para mostrar en el control de UI Seleccionar o Selección múltiple. Acepta una lista de valores separados por comas o un objeto JSON fuertemente tipado de tipo `TransformParameterListOption`. También puede rellenar

dinámicamente la lista de columnas del esquema del nodo principal al especificar el valor de cadena “column”.

- `listType: string`: (opcional) se definen los tipos de opciones para type = “list”. Valores válidos: “str” | “int” | “float” | “list” | “bool”. Tipo de parámetro que acepta los tipos de datos comunes de Python.

Campos de TransformParameterListOption

- `value: string | int | float | bool`: (obligatorio) valor de la opción.
- `label: string`: (opcional) etiqueta de la opción que se muestra en el menú desplegable de selección.

Parámetros de transformación en AWS Glue Studio

De forma predeterminada, los parámetros son obligatorios a menos que se marquen como `isOptional` en el archivo .json. En AWS Glue Studio, los parámetros se muestran en la pestaña Transform (Transformación). En el ejemplo se muestran parámetros definidos por el usuario, como Email Address (Dirección de correo electrónico), Phone Number (Número de teléfono), Your age (Su edad), Your gender (Su sexo) y Your origin country (Su país de origen).

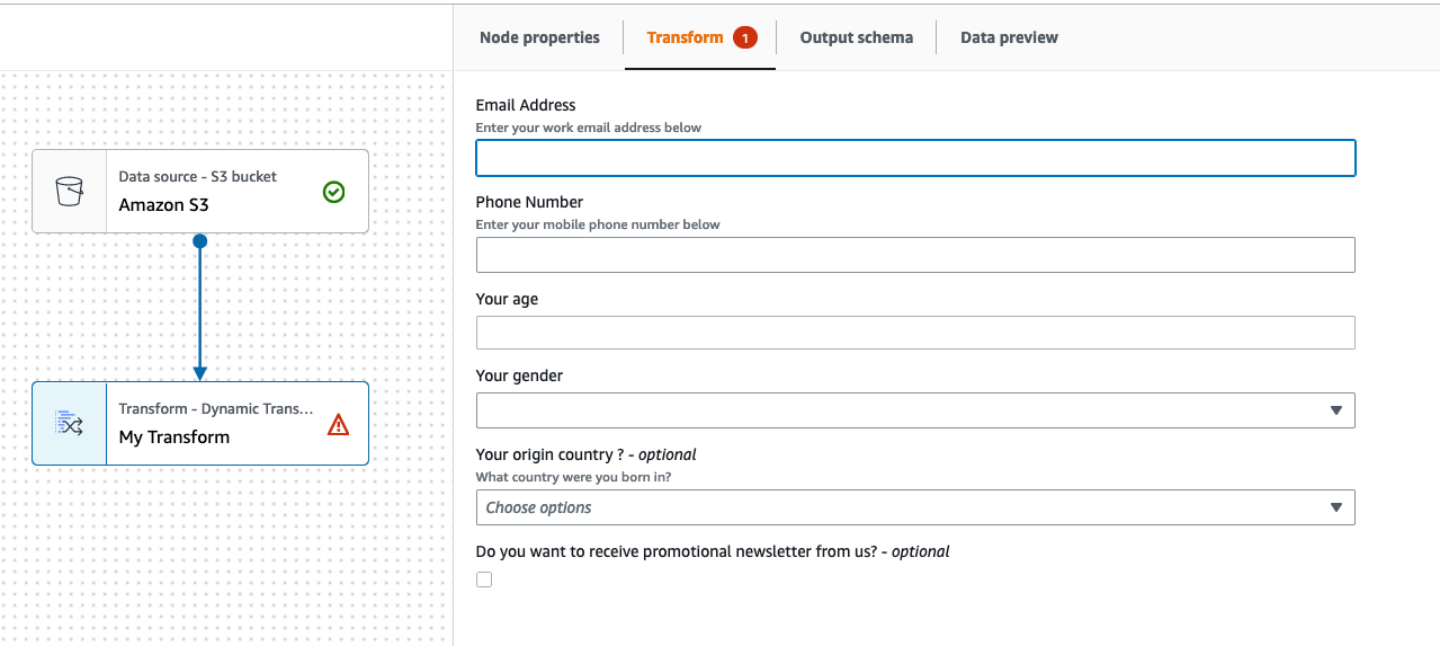

Puede aplicar algunas validaciones en AWS Glue Studio mediante expresiones regulares en el archivo json; para ello, especifique el parámetro `validationRule` y un mensaje de validación en `validationMessage`.

```
    "validationRule": "^\\(?(\\d{3})\\)?[- ]?(\\d{3})[- ]?(\\d{4})$",
    "validationMessage": "Please enter a valid US number"
```

> **Note**
>
> Como la validación se lleva a cabo en el navegador, la sintaxis de la expresión regular debe ser compatible con las especificaciones de RegExp de ECMAScript. La sintaxis de Python no es compatible con estas expresiones regulares.

Al agregar la validación, se impedirá al usuario guardar el trabajo con una entrada de usuario incorrecta. AWS Glue Studio muestra el mensaje de validación, tal como se muestra en el ejemplo:

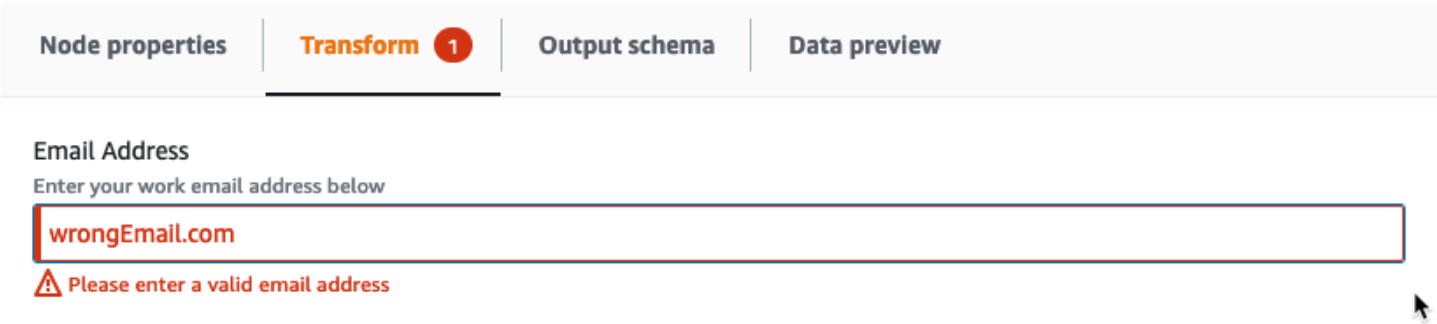

Los parámetros se muestran en AWS Glue Studio en función de la configuración de los parámetros.

- Se muestra un campo de entrada de texto cuando el valor de `type` es uno de los siguientes: `str`, `int` o `float`. Por ejemplo, en la captura de pantalla se muestran los campos de entrada para los parámetros “Dirección de correo electrónico” y “Su edad”.

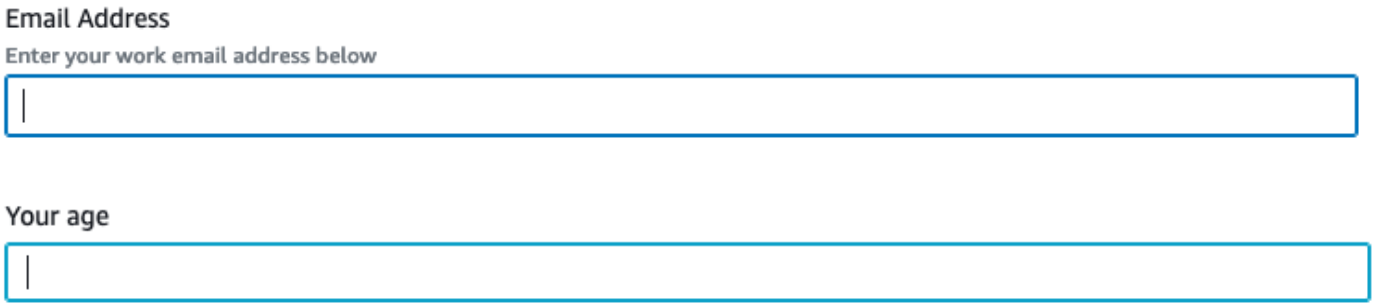

- Cuando el valor de `type` es `bool`, se muestra una casilla de verificación.

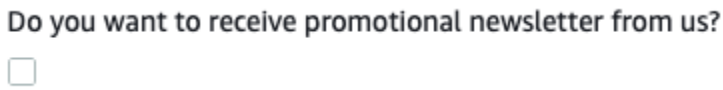

- Cuando el valor de `type` es `str` y se proporciona `listOptions`, se muestra una lista de selección única.

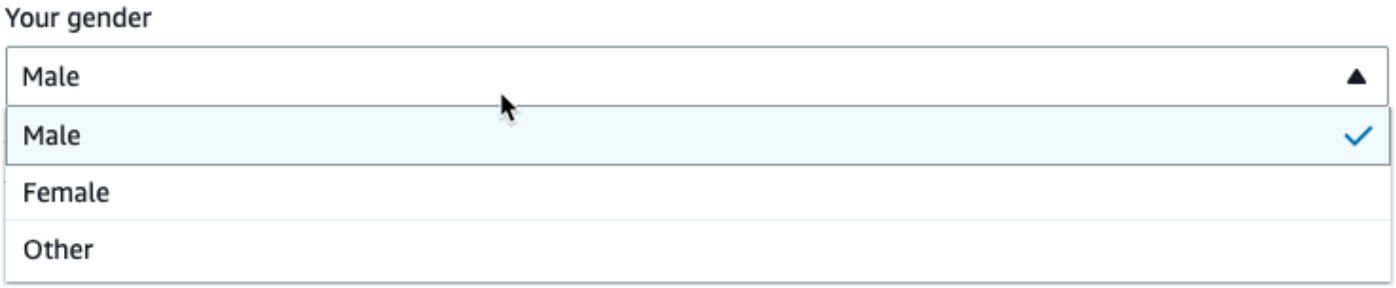

- Cuando el valor de `type` es `list` y se proporcionan `listOptions` y `listType`, se muestra una lista de selección múltiple.

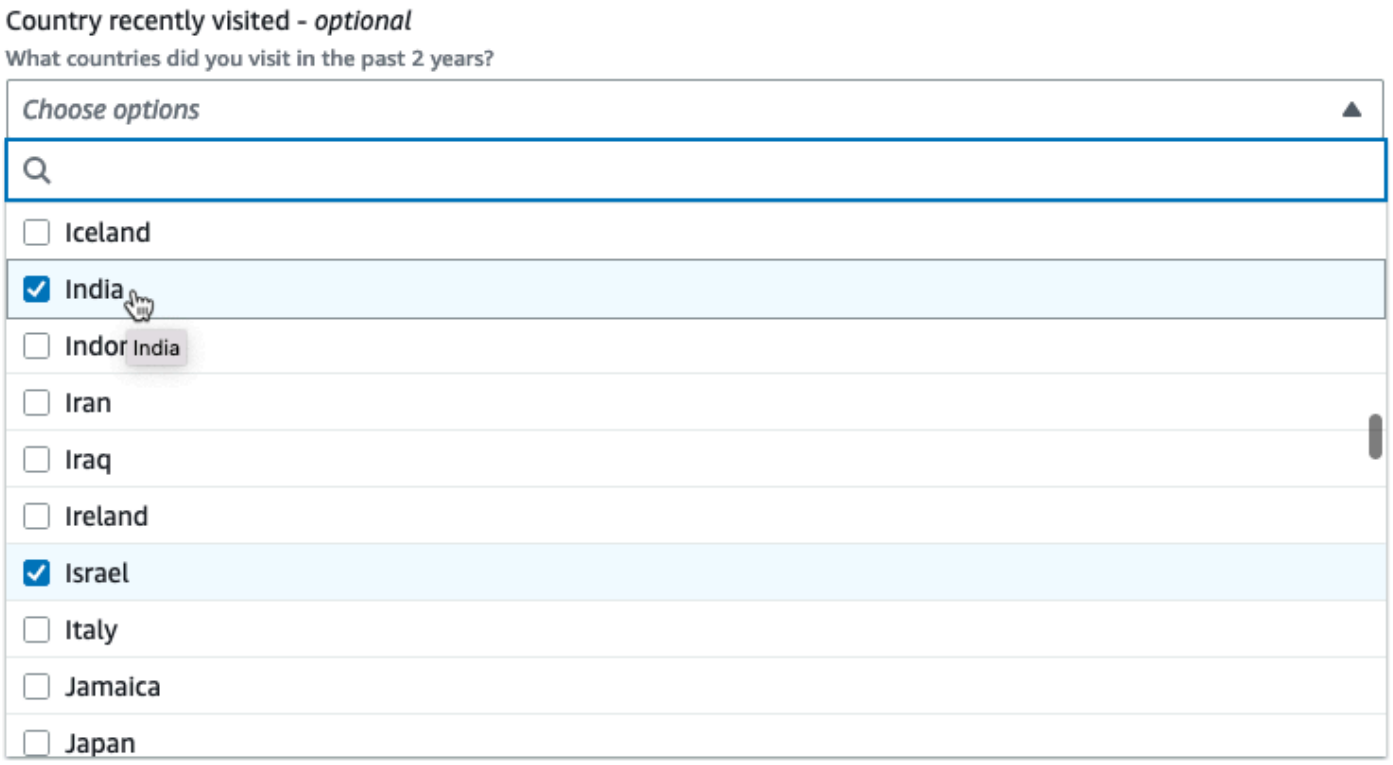

Mostrar un selector de columnas como parámetro

Si la configuración requiere que el usuario elija una columna del esquema, puede mostrar un selector de columnas para que el usuario no tenga que escribir el nombre de la columna. Al configurar el campo `listOptions` como “columna”, AWS Glue Studio muestra dinámicamente un selector de columnas basado en el esquema de salida del nodo principal. AWS Glue Studio puede mostrar un selector de una o varias columnas.

En este ejemplo se usa el esquema:

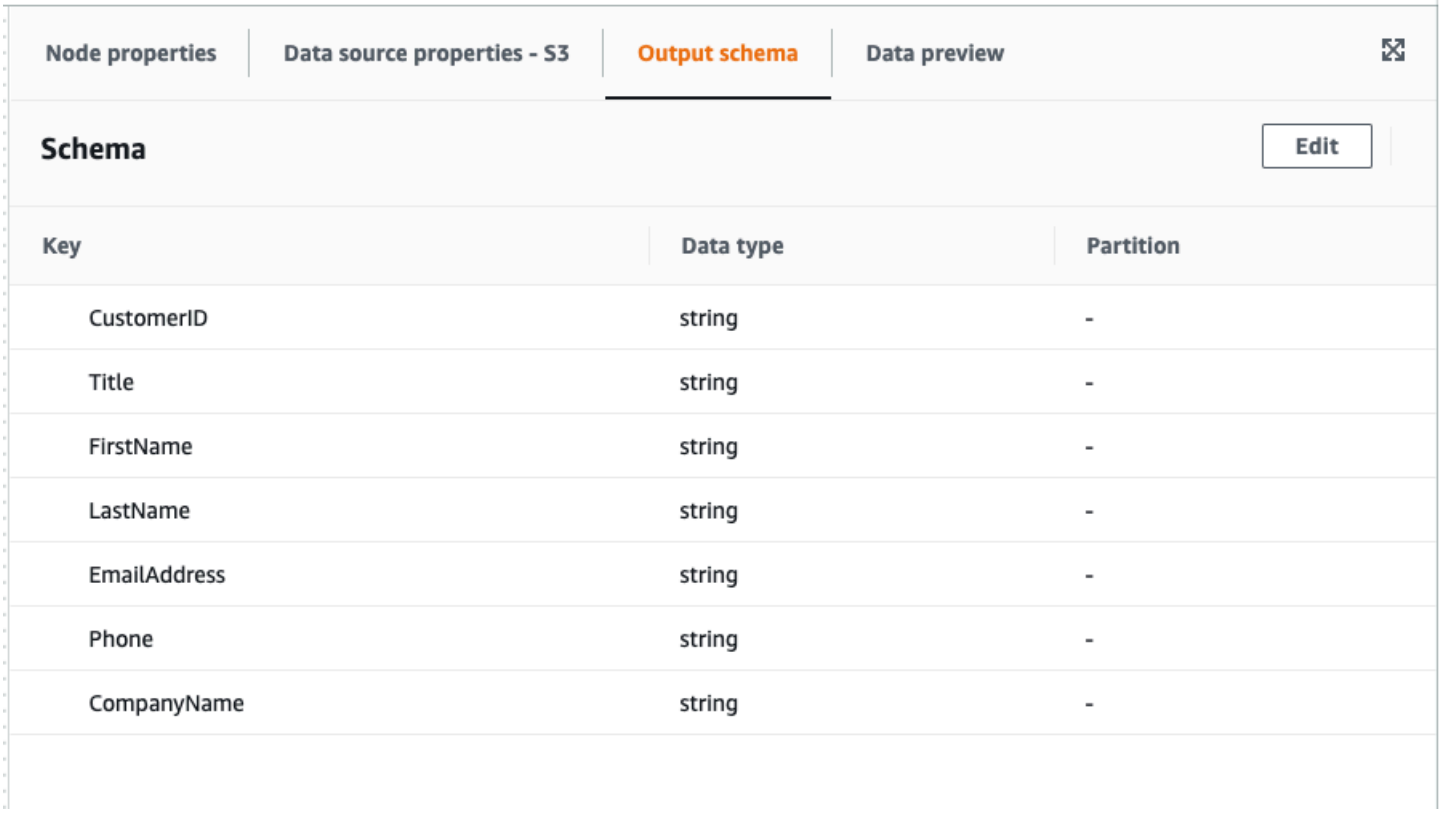

Para definir el parámetro de transformación visual personalizada para que muestre una sola columna:

1. En el archivo JSON, para el objeto `parameters`, establece el valor `listOptions` en “columna”. Esto permite al usuario elegir una columna de una lista de selección de AWS Glue Studio.

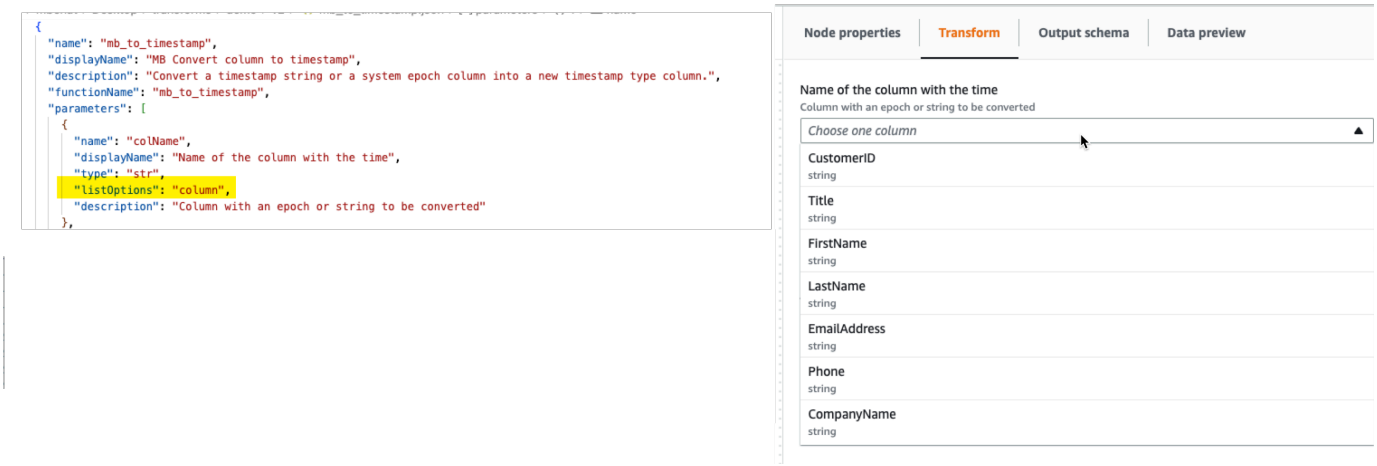

2. También puede permitir la selección de varias columnas al definir el parámetro de la siguiente manera:

   - `listOptions: "column"`
   - `type: "list"`

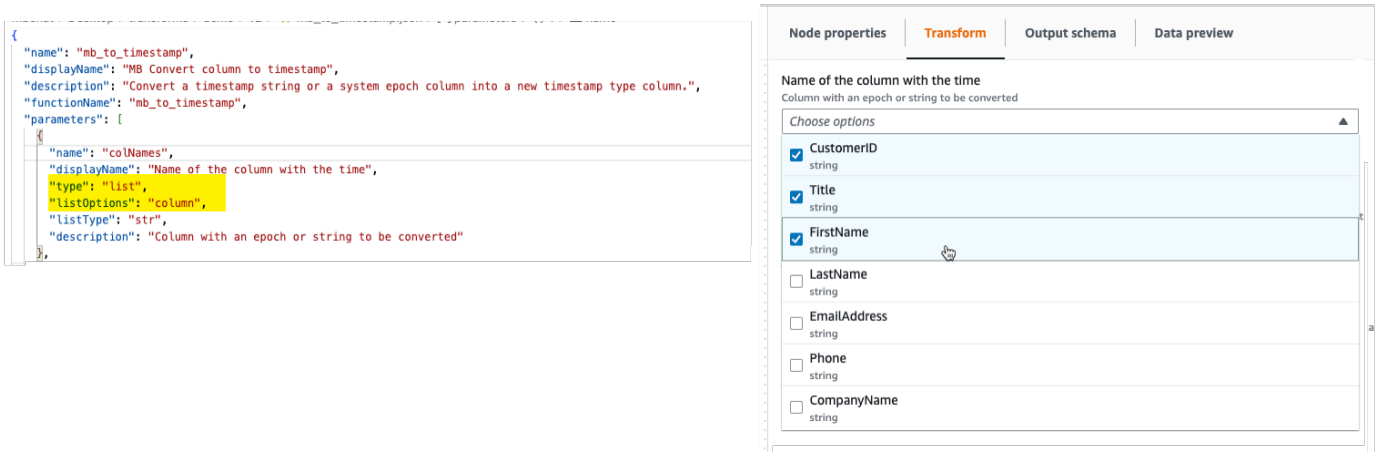

Paso 2. Implementar la lógica de transformación

> **Note**
>
> Las transformaciones visuales personalizadas solo admiten scripts de Python. No se admite Scala.

Para agregar el código que implementa la función definida mediante el archivo de configuración .json, se recomienda colocar el archivo de Python en la misma ubicación que el archivo .json, con el mismo nombre, pero con la extensión ".py". AWS Glue Studio empareja automáticamente los archivos .json y .py para que no tenga que especificar la ruta del archivo Python en el archivo de configuración.

En el archivo de Python, agregue la función declarada, con los parámetros con nombre configurados y regístrela para que se pueda utilizar en `DynamicFrame`. A continuación, se muestra un ejemplo de un archivo de Python:

```
from awsglue import DynamicFrame

# self refers to the DynamicFrame to transform,
# the parameter names must match the ones defined in the config
# if it's optional, need to provide a default value
def myTransform(self, email, phone, age=None, gender="",
                      country="", promotion=False):
   resulting_dynf = # do some transformation on self
   return resulting_dynf

DynamicFrame.myTransform = myTransform
```

Se recomienda utilizar un cuaderno de AWS Glue para desarrollar y probar el código de Python de la forma más rápida. Consulte Introducción a los cuadernos en AWS Glue Studio

Para ilustrar cómo implementar la lógica de transformación, la transformación visual personalizada del ejemplo siguiente es una transformación para filtrar los datos entrantes y conservar solo los datos relacionados con un estado concreto de EE. UU. El archivo .json contiene el parámetro para `functionName` como `custom_filter_state` y dos argumentos ("state" y "colName" con el tipo "str").

El archivo .json de configuración de ejemplo es el siguiente:

```
{
"name": "custom_filter_state",
"displayName": "Filter State",
"description": "A simple example to filter the data to keep only the state indicated.",
"functionName": "custom_filter_state",
"parameters": [
   {
```

```
    "name": "colName",
    "displayName": "Column name",
    "type": "str",
    "description": "Name of the column in the data that holds the state postal code"
   },
   {
    "name": "state",
    "displayName": "State postal code",
    "type": "str",
    "description": "The postal code of the state whole rows to keep"
   }
  ]
}
```

Implementación del script complementario en Python

1. Inicie un cuaderno de AWS Glue y ejecute la celda inicial proporcionada para iniciar la sesión. Al ejecutar la celda inicial, se crean los componentes básicos necesarios.
2. Cree una función que filtre tal y como se describe en el ejemplo y regístrela en `DynamicFrame`. Copie el código siguiente y péguelo en una celda del cuaderno de AWS Glue.

   ```
   from awsglue import DynamicFrame

   def custom_filter_state(self, colName, state):
       return self.filter(lambda row: row[colName] == state)

   DynamicFrame.custom_filter_state = custom_filter_state
   ```

3. Cree o cargue datos de muestra para probar el código en la misma celda o en una nueva. Si agrega los datos de muestra en una celda nueva, no olvide ejecutar la celda. Por ejemplo:

   ```
   # A few of rows of sample data to test
   data_sample = [
       {"state": "CA", "count": 4},
       {"state": "NY", "count": 2},
       {"state": "WA", "count": 3}
   ]
   df1 = glueContext.sparkSession.sparkContext.parallelize(data_sample).toDF()
   dynf1 = DynamicFrame.fromDF(df1, glueContext, None)
   ```

4. Haga pruebas para validar “custom_filter_state” con distintos argumentos:

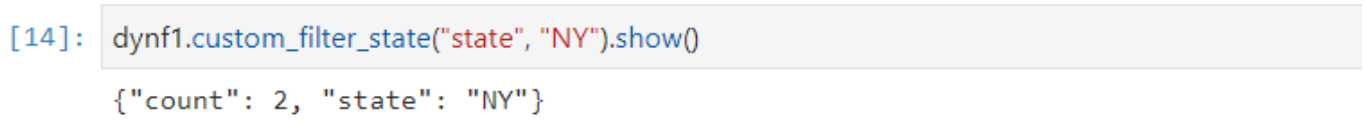

5. Tras ejecutar varias pruebas, guarde el código con la extensión .py y asigne un nombre al archivo .py que refleje el nombre del archivo .json. Los archivos .py y .json deben estar en la carpeta de la misma transformación.

   Copie el siguiente código, péguelo en un archivo y cámbiele el nombre con una extensión de archivo .py.

```
from awsglue import DynamicFrame

def custom_filter_state(self, colName, state):
    return self.filter(lambda row: row[colName] == state)

DynamicFrame.custom_filter_state = custom_filter_state
```

6. En AWS Glue Studio, abra un trabajo visual y agregue la transformación al trabajo; para ello, selecciónela en la lista Transforms (Transformaciones) disponibles.

   Para reutilizar esta transformación en el código de un script de Python, agregue la ruta de Amazon S3 al archivo .py en el trabajo, en “Referenced files path” (Ruta de archivos a la que se hace referencia), y en el script. Por último, importe el nombre del archivo de Python (sin la extensión); para ello, agréguelo a la parte superior del archivo. Por ejemplo: `import` <nombre del archivo (sin la extensión)>

Paso 3. Validar y solucionar los problemas de las transformaciones visuales personalizadas en AWS Glue Studio

AWS Glue Studio valida el archivo de configuración JSON antes de cargar las transformaciones visuales personalizadas en AWS Glue Studio. La validación incluye lo siguiente:

- Presencia de campos obligatorios

- Validación de formato JSON
- Parámetros incorrectos o no válidos
- Presencia de los archivos .py y .json en la misma ruta de Amazon S3
- Coincidencia de los nombres de los archivos .py y .json

Si la validación se lleva a cabo correctamente, la transformación aparece en la lista Actions (Acciones) disponibles del editor visual. Si se ha proporcionado un icono personalizado, debería estar visible junto a la Acción.

Si se produce un error durante la validación, AWS Glue Studio no carga la transformación visual personalizada.

Paso 4. Actualizar las transformaciones visuales personalizadas según sea necesario

Una vez creado y utilizado, el script de la transformación se puede actualizar siempre que la transformación siga la definición JSON correspondiente:

- El nombre utilizado durante la asignación a DynamicFrame debe coincidir con el valor de `functionName` de JSON.
- Los argumentos de la función deben definirse en el archivo JSON tal y como se describe en Paso 1. Crear un archivo de configuración JSON .
- La ruta de Amazon S3 del archivo de Python no puede cambiar, ya que los trabajos dependen directamente de ella.

> **Note**
>
> Si es necesario llevara a cabo alguna actualización, asegúrese de que el script y el archivo .json se actualicen de forma coherente y que todos los trabajos visuales se vuelvan a guardar correctamente con la nueva transformación. Si los trabajos visuales no se guardan después de llevar a cabo las actualizaciones, estas no se aplicarán ni validarán. Si se cambia el nombre del archivo de script de Python o no se coloca junto al archivo .json, debe especificar la ruta completa en el archivo .json.

Icono personalizado

Si determina que el icono predeterminado de la acción no la distingue visualmente como parte de sus flujos de trabajo, puede proporcionar un icono personalizado, como se describe en the section called " Introducción a las transformaciones visuales personalizadas ". Puede actualizar el icono mediante la actualización del SVG correspondiente alojado en Amazon S3.

Para obtener mejores resultados, diseñe la imagen para que se vea a 32 x 32 píxeles según las pautas del sistema de diseño de Cloudscape. Para obtener más información sobre las pautas de Cloudscape, consulte la documentación de Cloudscape

Paso 5. Usar transformaciones visuales personalizadas en AWS Glue Studio

Para utilizar una transformación visual personalizada en AWS Glue Studio, suba los archivos de origen y configuración y, a continuación, seleccione la transformación en el menú Action (Acción). Todos los parámetros que necesiten valores o entrada están disponibles en la pestaña Transform (Transformación).

1. Suba los dos archivos (el archivo de origen de Python y el archivo de configuración JSON) a la carpeta de activos de Amazon S3 en la que se almacenan los scripts del trabajo. De forma predeterminada, AWS Glue extrae todos los archivos JSON de la carpeta /transforms del mismo bucket de Amazon S3.
2. En el menú Action (Acción), seleccione la transformación visual personalizada. Se nombra con el valor de `displayName` de la transformación o el nombre que especificó en el archivo de configuración .json.
3. Ingrese valores para los parámetros configurados en el archivo de configuración.

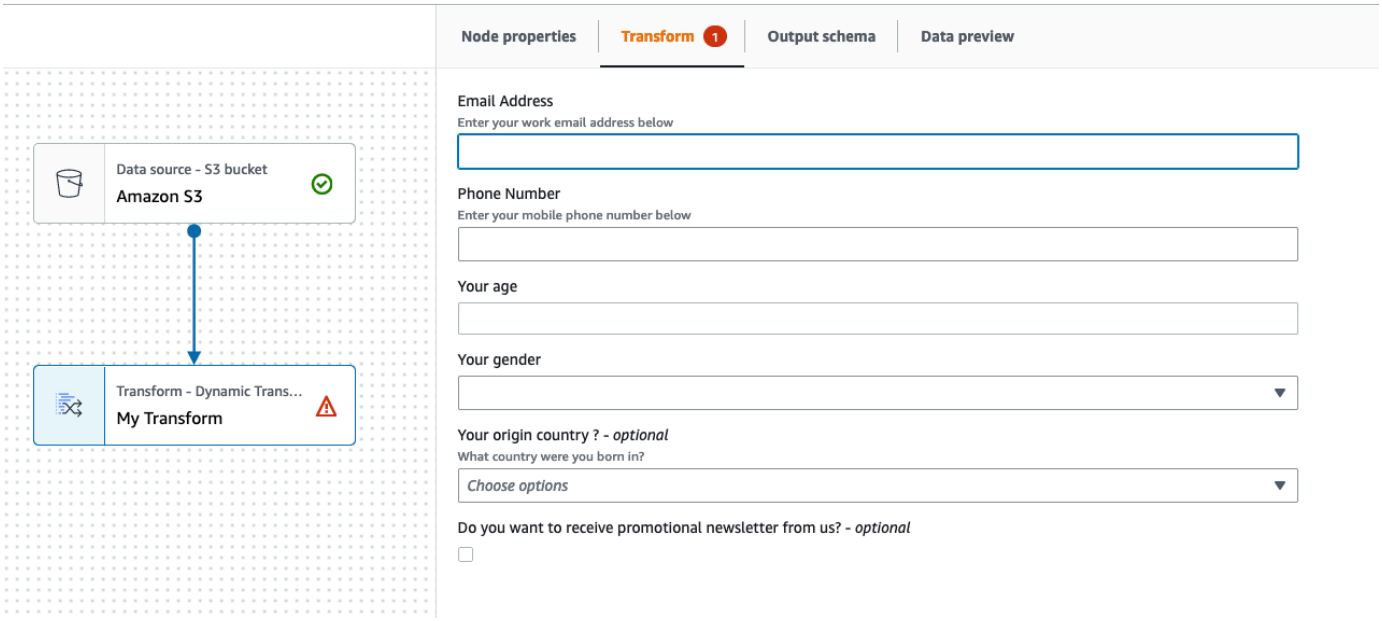

Ejemplos de uso

A continuación se incluye es un ejemplo de todos los parámetros posibles en un archivo de configuración .json.

```
{
  "name": "MyTransform",
  "displayName": "My Transform",
  "description": "This transform description will be displayed in UI",
  "functionName": "myTransform",
  "parameters": [
      {
      "name": "email",
      "displayName": "Email Address",
      "type": "str",
      "description": "Enter your work email address below",
      "validationType": "RegularExpression",
      "validationRule": "^\\w+([\\.-]?\\w+)*@\\w+([\\.-]?\\w+)*(\\.\\w{2,3})+$",
      "validationMessage": "Please enter a valid email address"
    },
    {
      "name": "phone",
      "displayName": "Phone Number",
      "type": "str",
      "description": "Enter your mobile phone number below",
      "validationRule": "^\\(?(\\d{3})\\)?[- ]?(\\d{3})[- ]?(\\d{4})$",
      "validationMessage": "Please enter a valid US number"
    },
    {
      "name": "age",
      "displayName": "Your age",
      "type": "int",
      "isOptional": true
    },
    {
      "name": "gender",
      "displayName": "Your gender",
      "type": "str",
      "listOptions": [
            {"label": "Male", "value": "male"},
            {"label": "Female", "value": "female"},
            {"label": "Other", "value": "other"}
        ],
```

```
      "isOptional": true
    },
    {
      "name": "country",
      "displayName": "Your origin country ?",
      "type": "list",
      "listOptions": "Afghanistan,Albania,Algeria,American
 Samoa,Andorra,Angola,Anguilla,Antarctica,Antigua and
 Barbuda,Argentina,Armenia,Aruba,Australia,Austria,Azerbaijan,Bahamas,Bahrain,Bangladesh,Barbad
 and Herzegovina,Botswana,Bouvet Island,Brazil,British Indian Ocean Territory,Brunei
 Darussalam,Bulgaria,Burkina Faso,Burundi,Cambodia,Cameroon,Canada,Cape
 Verde,Cayman Islands,Central African Republic,Chad,Chile,China,Christmas
 Island,Cocos (Keeling Islands),Colombia,Comoros,Congo,Cook Islands,Costa
 Rica,Cote D'Ivoire (Ivory Coast),Croatia (Hrvatska,Cuba,Cyprus,Czech
 Republic,Denmark,Djibouti,Dominica,Dominican Republic,East Timor,Ecuador,Egypt,El
 Salvador,Equatorial Guinea,Eritrea,Estonia,Ethiopia,Falkland Islands (Malvinas),Faroe
 Islands,Fiji,Finland,France,France,Metropolitan,French Guiana,French Polynesia,French
 Southern
 Territories,Gabon,Gambia,Georgia,Germany,Ghana,Gibraltar,Greece,Greenland,Grenada,Guadeloupe,G
Bissau,Guyana,Haiti,Heard and McDonald Islands,Honduras,Hong
 Kong,Hungary,Iceland,India,Indonesia,Iran,Iraq,Ireland,Israel,Italy,Jamaica,Japan,Jordan,Kazak
 (North),Korea
 (South),Kuwait,Kyrgyzstan,Laos,Latvia,Lebanon,Lesotho,Liberia,Libya,Liechtenstein,Lithuania,Lu
 Islands,Martinique,Mauritania,Mauritius,Mayotte,Mexico,Micronesia,Moldova,Monaco,Mongolia,Mont
 Antilles,New Caledonia,New Zealand,Nicaragua,Niger,Nigeria,Niue,Norfolk
 Island,Northern Mariana Islands,Norway,Oman,Pakistan,Palau,Panama,Papua
 New Guinea,Paraguay,Peru,Philippines,Pitcairn,Poland,Portugal,Puerto
 Rico,Qatar,Reunion,Romania,Russian Federation,Rwanda,Saint Kitts and Nevis,Saint
 Lucia,Saint Vincent and The Grenadines,Samoa,San Marino,Sao Tome and Principe,Saudi
 Arabia,Senegal,Seychelles,Sierra Leone,Singapore,Slovak Republic,Slovenia,Solomon
 Islands,Somalia,South Africa,S. Georgia and S. Sandwich Isls.,Spain,Sri
 Lanka,St. Helena,St. Pierre and Miquelon,Sudan,Suriname,Svalbard and Jan Mayen
 Islands,Swaziland,Sweden,Switzerland,Syria,Tajikistan,Tanzania,Thailand,Togo,Tokelau,Tonga,Tri
 and Tobago,Tunisia,Turkey,Turkmenistan,Turks and Caicos
 Islands,Tuvalu,Uganda,Ukraine,United Arab Emirates,United Kingdom
 (Britain / UK),United States of America (USA),US Minor Outlying
 Islands,Uruguay,Uzbekistan,Vanuatu,Vatican City State (Holy See),Venezuela,Viet
 Nam,Virgin Islands (British),Virgin Islands (US),Wallis and Futuna Islands,Western
 Sahara,Yemen,Yugoslavia,Zaire,Zambia,Zimbabwe",
      "description": "What country were you born in?",
      "listType": "str",
      "isOptional": true
    },
    {
```

```
      "name": "promotion",
      "displayName": "Do you want to receive promotional newsletter from us?",
      "type": "bool",
      "isOptional": true
    }
  ]
}
```

Ejemplos de scripts visuales personalizados

En los siguientes ejemplos, se llevan a cabo transformaciones equivalentes. Sin embargo, el segundo ejemplo (SparkSQL) es el más limpio y eficiente, seguido de la UDF de Pandas y, finalmente, las asignaciones de nivel bajo del primer ejemplo. El siguiente ejemplo es un ejemplo completo de una transformación sencilla para agregar dos columnas:

```
from awsglue import DynamicFrame

# You can have other auxiliary variables, functions or classes on this file, it won't
 affect the runtime
def record_sum(rec, col1, col2, resultCol):
    rec[resultCol] = rec[col1] + rec[col2]
    return rec


# The number and name of arguments must match the definition on json config file
# (expect self which is the current DynamicFrame to transform
# If an argument is optional, you need to define a default value here
#  (resultCol in this example is an optional argument)
def custom_add_columns(self, col1, col2, resultCol="result"):
    # The mapping will alter the columns order, which could be important
    fields = [field.name for field in self.schema()]
    if resultCol not in fields:
        # If it's a new column put it at the end
        fields.append(resultCol)
    return self.map(lambda record: record_sum(record, col1, col2,
 resultCol)).select_fields(paths=fields)


# The name we assign on DynamicFrame must match the configured "functionName"
DynamicFrame.custom_add_columns = custom_add_columns
```

El siguiente ejemplo es una transformación equivalente que aprovecha la API de SparkSQL.

```
from awsglue import DynamicFrame

# The number and name of arguments must match the definition on json config file
# (expect self which is the current DynamicFrame to transform
# If an argument is optional, you need to define a default value here
#  (resultCol in this example is an optional argument)
def custom_add_columns(self, col1, col2, resultCol="result"):
    df = self.toDF()
    return DynamicFrame.fromDF(
        df.withColumn(resultCol, df[col1] + df[col2]) # This is the conversion logic
        , self.glue_ctx, self.name)


# The name we assign on DynamicFrame must match the configured "functionName"
DynamicFrame.custom_add_columns = custom_add_columns
```

En el siguiente ejemplo, se usa las mismas transformaciones, pero con una UDF de Pandas, que es más eficiente que usar una UDF simple. Para obtener más información sobre cómo escribir UDF de Pandas, consulte la documentación de Apache Spark SQL.

```
from awsglue import DynamicFrame
import pandas as pd
from pyspark.sql.functions import pandas_udf

# The number and name of arguments must match the definition on json config file
# (expect self which is the current DynamicFrame to transform
# If an argument is optional, you need to define a default value here
#  (resultCol in this example is an optional argument)
def custom_add_columns(self, col1, col2, resultCol="result"):
    @pandas_udf("integer")  # We need to declare the type of the result column
    def add_columns(value1: pd.Series, value2: pd.Series) # pd.Series:
        return value1 + value2

    df = self.toDF()
    return DynamicFrame.fromDF(
        df.withColumn(resultCol, add_columns(col1, col2)) # This is the conversion
 logic
        , self.glue_ctx, self.name)

# The name we assign on DynamicFrame must match the configured "functionName"
```

```
DynamicFrame.custom_add_columns = custom_add_columns
```

Video

En el siguiente video, se ofrece una introducción a las transformaciones visuales personalizadas y se muestra cómo usarlas.

Uso de marcos de lagos de datos con AWS Glue Studio

Descripción general

Los marcos de lago de datos de código abierto simplifican el procesamiento progresivo de datos para los archivos almacenados en lagos de datos creados en Amazon S3. La versión 3.0 y versiones posteriores de AWS Glue admiten los siguientes marcos de almacenamiento de lagos de datos de código abierto:

- Apache Hudi
- Linux Foundation Delta Lake
- Apache Iceberg

A partir de la versión de AWS Glue 4.0, AWS Glue proporciona compatibilidad nativa con estos marcos para que pueda leer y escribir los datos que almacene en Amazon S3 de una manera consistente entre transacciones. No es necesario instalar ningún conector independiente ni completar pasos de configuración adicionales para utilizar estos marcos en trabajos de AWS Glue.

Los marcos de lagos de datos se pueden utilizar como origen o destino en AWS Glue Studio a través de trabajos del editor de scripts de Spark. Para obtener más información sobre el uso de Apache Hudi, Apache Iceberg y Delta Lake, consulte Uso de marcos de lagos de datos con trabajos de ETL de AWS Glue.

Creación de formatos de tabla abiertos a partir de un origen de streaming de AWS Glue

Los trabajos ETL en streaming de AWS Glue consumen continuamente datos de los orígenes de streaming, los limpian y transforman durante el tránsito y los ponen a disposición para su análisis en cuestión de segundos.

AWS ofrece una amplia selección de servicios para satisfacer sus necesidades. Un servicio de replicación de bases de datos, como AWS Database Migration Service, puede replicar los datos de sus sistemas de origen a Amazon S3, que normalmente aloja la capa de almacenamiento del lago de datos. Si bien es sencillo aplicar las actualizaciones en un sistema de administración de base de datos relacional (RDBMS) que respalda una aplicación de origen en línea, es difícil aplicar este proceso de CDC en sus lagos de datos. Los marcos de administración de datos de código abierto simplifican el procesamiento progresivo de datos y el desarrollo de canalizaciones de datos, y son una buena opción para resolver este problema.

Para obtener más información, consulte:

- Cree un lago de datos transaccional casi en tiempo real basado en Apache Hudi mediante AWS Glue Streaming
- Crear un lago de datos de Apache Iceberg en tiempo real alineado con el RGPD

Uso del marco de Hudi en AWS Glue Studio

Cuando crea o edita un trabajo, AWS Glue Studio agrega automáticamente las bibliotecas de Hudi correspondientes en su nombre según la versión de AWS Glue que utilice. Para obtener más información, consulte Uso del marco de Hudi en AWS Glue.

Uso del marco de Apache Hudi en los orígenes de datos del Catálogo de datos

Para agregar un formato de origen de datos de Hudi a un trabajo, haga lo siguiente:

1. En el menú Origen, seleccione Catálogo de datos de AWS Glue Studio.
2. En la pestaña Propiedades del origen de datos, elija una base de datos y una tabla.
3. AWS Glue Studio muestra el tipo de formato como Apache Hudi y la dirección URL de Amazon S3.

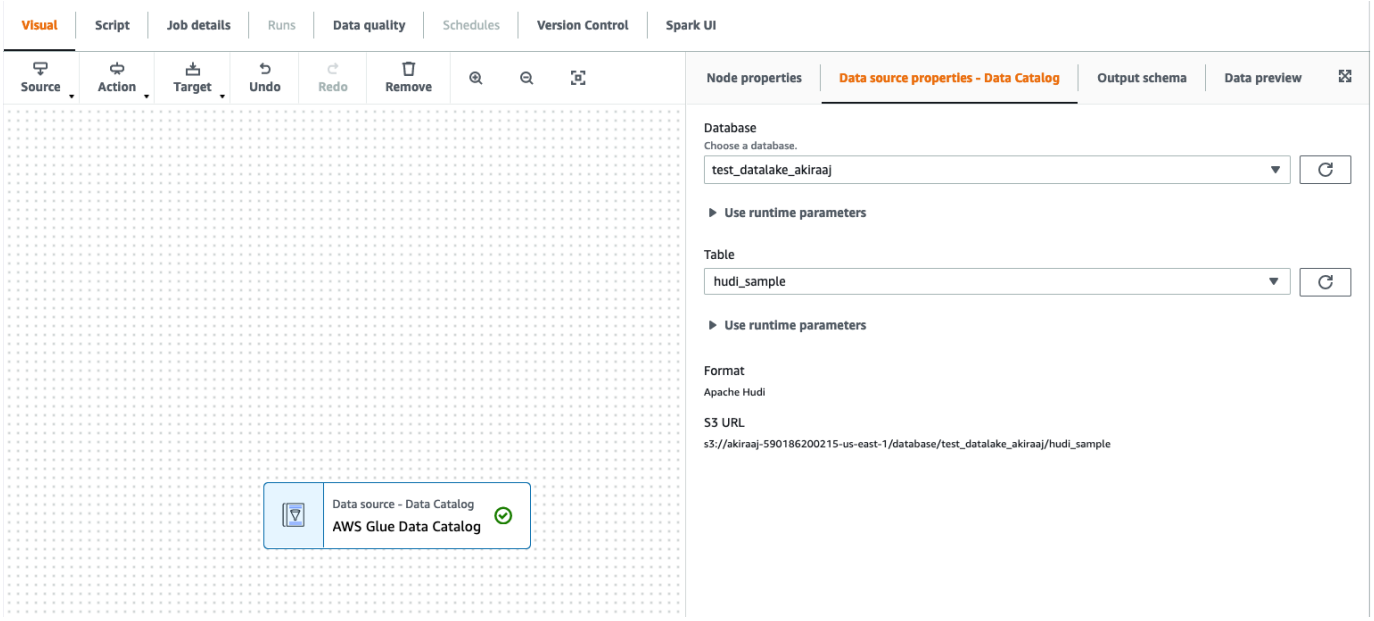

Uso del marco de Hudi en orígenes de datos de Amazon S3

1. En el menú Origen, elija Amazon S3.
2. Si elige la tabla del Catálogo de datos como el tipo de origen de Amazon S3, elija una base de datos y una tabla.
3. AWS Glue Studio muestra el formato como Apache Hudi y la dirección URL de Amazon S3.
4. Si elige la ubicación de Amazon S3 como el Tipo de origen de Amazon S3, elija la dirección URL de Amazon S3 haciendo clic en Examinar Amazon S3.
5. En Formato de datos, seleccione Apache Hudi.

> **Note**
>
> Si AWS Glue Studio no puede deducir el esquema de la carpeta o el archivo de Amazon S3 que ha seleccionado, elija Opciones adicionales para seleccionar una nueva carpeta o archivo.
> En Opciones adicionales, elija una de las siguientes opciones en Inferencia del esquema:
>
> - Permitir que AWS Glue Studio elija automáticamente un archivo de muestra: AWS Glue Studio elegirá un archivo de muestra en la ubicación de Amazon S3 para poder deducir el esquema. En el campo Archivo de muestra seleccionado de manera automática, puede ver el archivo que se seleccionó automáticamente.

- Elegir un archivo de muestra de Amazon S3: elija el archivo de Amazon S3 que va a utilizar haciendo clic en Examinar Amazon S3.

6. Haga clic en Deducir esquema. A continuación, puede ver el esquema de salida haciendo clic en la pestaña Esquema de salida.
7. Elija Opciones adicionales para introducir un par clave-valor.

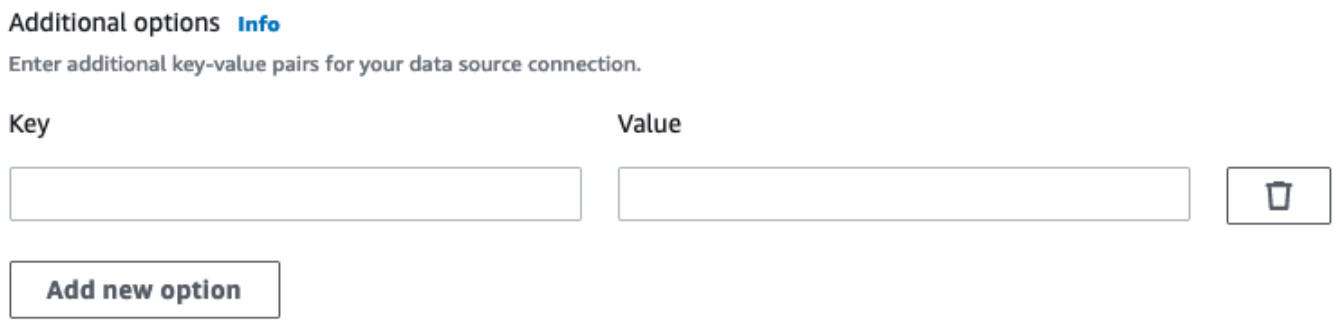

Uso del marco de Apache Hudi en los destinos de datos

Uso del marco de Apache Hudi en los destinos de datos del Catálogo de datos

1. En el menú Destino, seleccione Catálogo de datos de AWS Glue Studio.
2. En la pestaña Propiedades del origen de datos, elija una base de datos y una tabla.
3. AWS Glue Studio muestra el tipo de formato como Apache Hudi y la dirección URL de Amazon S3.

Uso del marco de Apache Hudi en los destinos de datos de Amazon S3

Introduzca valores o seleccione una de las opciones disponibles para configurar el formato Apache Hudi. Para obtener más información sobre Apache Hudi, consulte la Documentación de Apache Hudi.

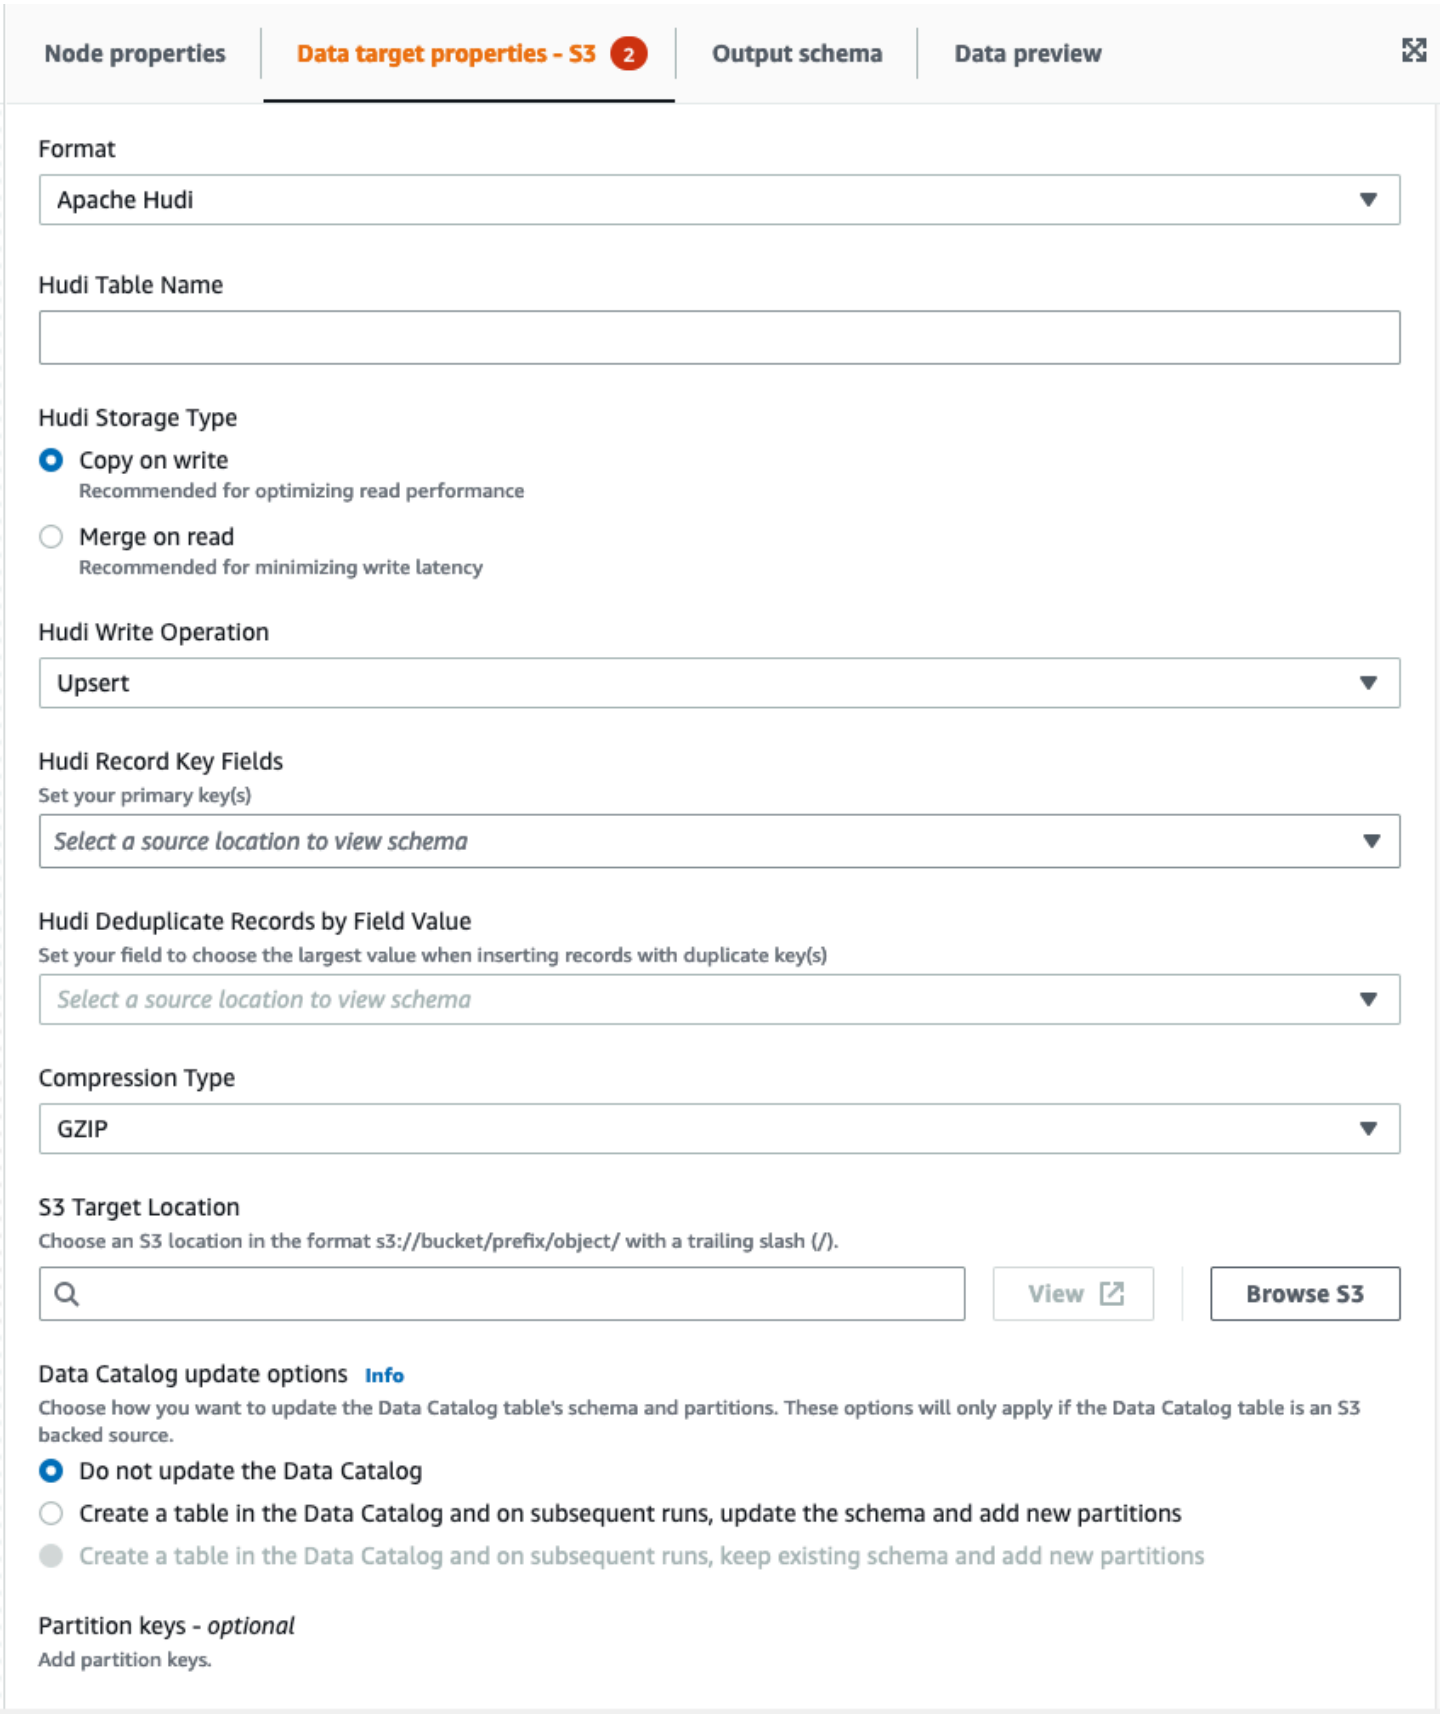
Node properties
Data target properties - S3 2
Output schema
Data preview
Format
Apache Hudi
Hudi Table Name
Hudi Storage Type
Copy on write
Recommended for optimizing read performance
Merge on read
Recommended for minimizing write latency
Hudi Write Operation
Upsert
Hudi Record Key Fields
Set your primary key(s)
Select a source location to view schema
Hudi Deduplicate Records by Field Value
Set your field to choose the largest value when inserting records with duplicate key(s)
Select a source location to view schema
Compression Type
GZIP
S3 Target Location
Choose an S3 location in the format s3://bucket/prefix/object/ with a trailing slash (/).
View
Browse S3
Data Catalog update options Info
Choose how you want to update the Data Catalog table's schema and partitions. These options will only apply if the Data Catalog table is an S3 backed source.
Do not update the Data Catalog
Create a table in the Data Catalog and on subsequent runs, update the schema and add new partitions
Create a table in the Data Catalog and on subsequent runs, keep existing schema and add new partitions
Partition keys - optional
Add partition keys.

- Nombre de la tabla de Hudi: este es el nombre de su tabla de Hudi.
- Tipo de almacenamiento de Hudi: elija entre dos opciones.
  - Copiar durante la escritura: se recomienda esta opción para optimizar el rendimiento de lectura. Este es el tipo de almacenamiento predeterminado de Hudi. Cada actualización crea una versión nueva de los archivos durante la escritura.
  - Combinar durante la lectura: se recomienda esta opción para minimizar la latencia de escritura. Las actualizaciones se registran en archivos delta basados en filas y se compactan según sea necesario para crear nuevas versiones de los archivos en columnas.
- Operación de escritura de Hudi: elija entre las siguientes opciones.
  - Upsert: esta es la operación predeterminada en la que los registros de entrada se etiquetan primero como inserciones o actualizaciones al consultar el índice. Se recomienda para la actualización de los datos existentes.
  - Insert: esta operación inserta registros, pero no comprueba si hay registros existentes, lo que puede generar duplicados.
  - Bulk Insert: esta operación inserta registros y se recomienda para grandes cantidades de datos.
- Campos de clave de registro de Hudi: utilice la barra de búsqueda para ubicar y elegir las claves de registro principales. Los registros en Hudi se identifican mediante una clave principal, que representa la combinación de una clave de registro y una ruta de partición a la que pertenece el registro.
- Campo de combinación previa de Hudi: este es el campo que se utiliza en la combinación previa antes de escribir realmente. Cuando dos registros tienen el mismo valor para la clave, AWS Glue Studio selecciona el que tiene el valor más alto para el campo de combinación previa. Establezca un campo con un valor incremental (por ejemplo, updated_at).
- Tipo de compresión: elija una de las opciones de tipo de compresión; sin comprimir, GZIP, LZO o Snappy.
- Ubicación de destino de Amazon S3: para elegir la ubicación de destino de Amazon S3, haga clic en Examinar S3.
- Opciones de actualización del Catálogo de datos: elija entre siguientes opciones.
  - Do not update the Data Catalog (No actualizar el Catálogo de datos): (predeterminado) seleccione esta opción si no desea que el trabajo actualice el Catálogo de datos, incluso si el esquema cambia o se agregan nuevas particiones.
  - Crear una tabla en el Catálogo de datos y en las ejecuciones posteriores, actualizar el esquema y agregar nuevas particiones: si elige esta opción, el trabajo crea la tabla en el Catálogo de datos durante la primera ejecución del trabajo. En las ejecuciones de trabajos posteriores, el

trabajo actualiza la tabla del Catálogo de datos si cambia el esquema o se agregan nuevas particiones.

También debe seleccionar una base de datos en el Catálogo de datos e introducir un nombre de tabla.

- Create a table in the Data Catalog and on subsequent runs, keep existing schema and add new partitions (Crear una tabla en el Catálogo de datos y en ejecuciones posteriores, mantener el esquema existente y agregar nuevas particiones): si elige esta opción, el trabajo crea la tabla en el Catálogo de datos durante la primera ejecución del trabajo. En las ejecuciones de trabajos posteriores, el trabajo actualiza la tabla del Catálogo de datos solo para agregar nuevas particiones.

  También debe seleccionar una base de datos en el Catálogo de datos e introducir un nombre de tabla.

- Partition keys (Claves de partición): elija qué columnas utilizar como claves de partición en la salida. Para agregar más claves de partición, elija Add a partition key (Agregar una clave de partición).
- Opciones adicionales: introduzca un par clave-valor según sea necesario.

Generación de código a través de AWS Glue Studio

Cuando se guarda el trabajo, los siguientes parámetros se agregan al trabajo si se detecta un origen o un destino de Hudi:

- `--datalake-formats`: una lista independiente de los formatos de lagos de datos detectados en el trabajo visual (ya sea eligiendo un “Formato” directamente o seleccionando una tabla del catálogo que cuenta con el respaldo de un lago de datos indirectamente).
- `--conf` : se genera en función del valor de `--datalake-formats`. Por ejemplo, si el valor de `--datalake-formats` es “hudi”, AWS Glue genera un valor de `spark.serializer=org.apache.spark.serializer.KryoSerializer –conf spark.sql.hive.convertMetastoreParquet=false` para este parámetro.

Anulación de bibliotecas proporcionadas por AWS Glue

Para usar una versión de Hudi no compatible con AWS Glue, puede especificar sus propios archivos JAR de la biblioteca de Hudi. Para usar su propio archivo JAR, haga lo siguiente:

- Utilice el parámetro de trabajo `--extra-jars`. Por ejemplo, `'--extra-jars': 's3pathtojarfile.jar'`. Para obtener más información, consulte Parámetros de los trabajos de AWS Glue.
- No incluya `hudi` como valor para el parámetro de trabajo `--datalake-formats`. Al introducir una cadena en blanco como valor, se asegura de que AWS Glue no le proporcione automáticamente ninguna biblioteca de lagos de datos. Para obtener más información, consulte Uso del marco de Hudi en AWS Glue.

Uso del marco de Delta Lake en AWS Glue Studio

Uso del marco de Delta Lake en los orígenes de datos

Uso del marco de Delta Lake en los orígenes de datos de Amazon S3

1. En el menú Origen, elija Amazon S3.
2. Si elige la tabla del Catálogo de datos como el tipo de origen de Amazon S3, elija una base de datos y una tabla.
3. AWS Glue Studio muestra el formato como Delta Lake y la dirección URL de Amazon S3.
4. Elija Opciones adicionales para introducir un par clave-valor. Por ejemplo, un par clave-valor podría ser el siguiente: clave: timestampAsOf y valor: 2023-02-24 14:16:18.

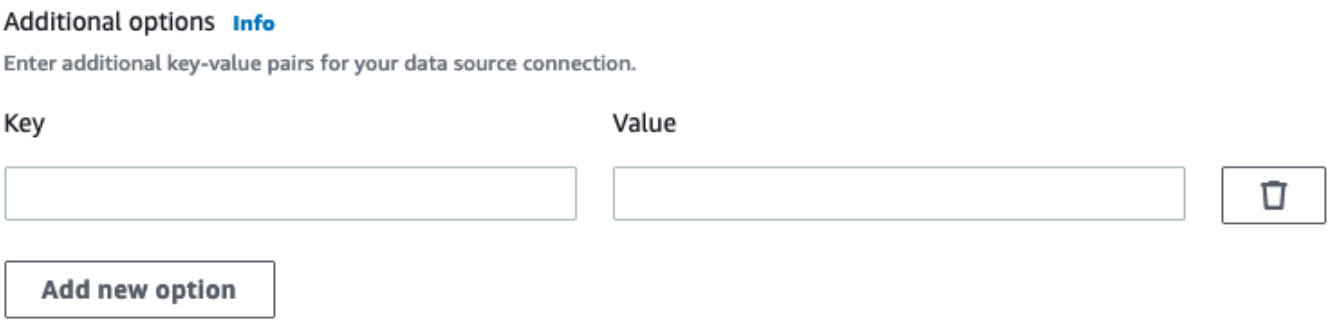

5. Si elige la ubicación de Amazon S3 como el Tipo de origen de Amazon S3, elija la dirección URL de Amazon S3 haciendo clic en Examinar Amazon S3.
6. En Formato de datos, elija Delta Lake.

> **Note**
>
> Si AWS Glue Studio no puede deducir el esquema de la carpeta o el archivo de Amazon S3 que ha seleccionado, elija Opciones adicionales para seleccionar una nueva carpeta o archivo.
> En Opciones adicionales, elija una de las siguientes opciones en Inferencia del esquema:
>
> - Permitir que AWS Glue Studio elija automáticamente un archivo de muestra: AWS Glue Studio elegirá un archivo de muestra en la ubicación de Amazon S3 para poder deducir el esquema. En el campo Archivo de muestra seleccionado de manera automática, puede ver el archivo que se seleccionó automáticamente.
> - Elegir un archivo de muestra de Amazon S3: elija el archivo de Amazon S3 que va a utilizar haciendo clic en Examinar Amazon S3.

7. Haga clic en Deducir esquema. A continuación, puede ver el esquema de salida haciendo clic en la pestaña Esquema de salida.

Uso del marco de Delta Lake en los orígenes de datos del Catálogo de datos

1. En el menú Origen, seleccione Catálogo de datos de AWS Glue Studio.
2. En la pestaña Propiedades del origen de datos, elija una base de datos y una tabla.
3. AWS Glue Studio muestra el tipo de formato como Delta Lake y la dirección URL de Amazon S3.

> **Note**
>
> Si su origen de Delta Lake aún no está registrado como tabla del Catálogo de datos AWS Glue, tiene dos opciones:
>
> 1. Cree un rastreador de AWS Glue para el almacén de datos de Delta Lake. Para obtener más información, consulte Cómo especificar opciones de configuración para un almacén de datos de Delta Lake.
> 2. Use un origen de datos de Amazon S3 para seleccionar su origen de datos de Delta Lake. Consulte Uso del marco de Delta Lake en los orígenes de datos de Amazon S3 .

Uso de formatos de Delta Lake en los destinos de datos

Uso de formatos de Delta Lake en los destinos de datos del Catálogo de datos

1. En el menú Destino, seleccione Catálogo de datos de AWS Glue Studio.
2. En la pestaña Propiedades del origen de datos, elija una base de datos y una tabla.
3. AWS Glue Studio muestra el tipo de formato como Delta Lake y la dirección URL de Amazon S3.

Uso de formatos de Delta Lake en los orígenes de datos de Amazon S3

Introduzca valores o seleccione una de las opciones disponibles para configurar el formato de Delta Lake.

- Tipo de compresión: elija una de las opciones de tipo de compresión; sin comprimir o Snappy.
- Ubicación de destino de Amazon S3: para elegir la ubicación de destino de Amazon S3, haga clic en Examinar S3.
- Opciones de actualización del Catálogo de datos: en el editor visual de Glue Studio, no se admite la actualización del Catálogo de datos para este formato.
  - Do not update the Data Catalog (No actualizar el Catálogo de datos): (predeterminado) seleccione esta opción si no desea que el trabajo actualice el Catálogo de datos, incluso si el esquema cambia o se agregan nuevas particiones.
  - Para actualizar el Catálogo de datos después de la ejecución del trabajo de AWS Glue, ejecute o programe un rastreador de AWS Glue. Para obtener más información, consulte Cómo especificar opciones de configuración para un almacén de datos de Delta Lake.
- Claves de partición: elija qué columnas utilizar como claves de partición en la salida. Para agregar más claves de partición, elija Agregar una clave de partición.
- Puede elegir Opciones adicionales para introducir un par clave-valor. Por ejemplo, un par clave-valor podría ser el siguiente: clave: timestampAsOf y valor: 2023-02-24 14:16:18.

Uso del marco Apache Iceberg en AWS Glue Studio

Uso del marco de Apache Iceberg en los destinos de datos

Uso del marco de Apache Iceberg en los destinos de datos del Catálogo de datos

1. En el menú Destino, seleccione Catálogo de datos de AWS Glue Studio.

2. En la pestaña Propiedades del origen de datos, elija una base de datos y una tabla.
3. AWS Glue Studio muestra el tipo de formato como Apache Iceberg y la dirección URL de Amazon S3.

Uso del marco de Apache Iceberg en los destinos de datos de Amazon S3

Ingrese valores o seleccione una de las opciones disponibles para configurar el formato Apache Iceberg.

- Formato: elija Apache Iceberg en el menú desplegable.
- Ubicación de destino de Amazon S3: para elegir la ubicación de destino de Amazon S3, haga clic en Examinar S3.
- Opciones de actualización del Catálogo de datos: cree una tabla en el Catálogo de datos y en las ejecuciones posteriores, mantenga el esquema existente y agregue nuevas particiones. Debe estar seleccionado para continuar. Para escribir una nueva tabla Iceberg con AWS Glue requiere que Data Catalog esté configurado como catálogo para la tabla de Iceberg. Para actualizar una tabla de Iceberg existente que se haya registrado en Data Catalog, elija Data Catalog como destino.
  - Base de datos: elija la base de datos de Data Catalog.
  - Table name: escriba un nombre único para la tabla. Los nombres de las tablas de Apache Iceberg deben estar en minúsculas. Utilice guiones bajos si es necesario, ya que no se permiten espacios. Por ejemplo, “data_lake_format_tables”.

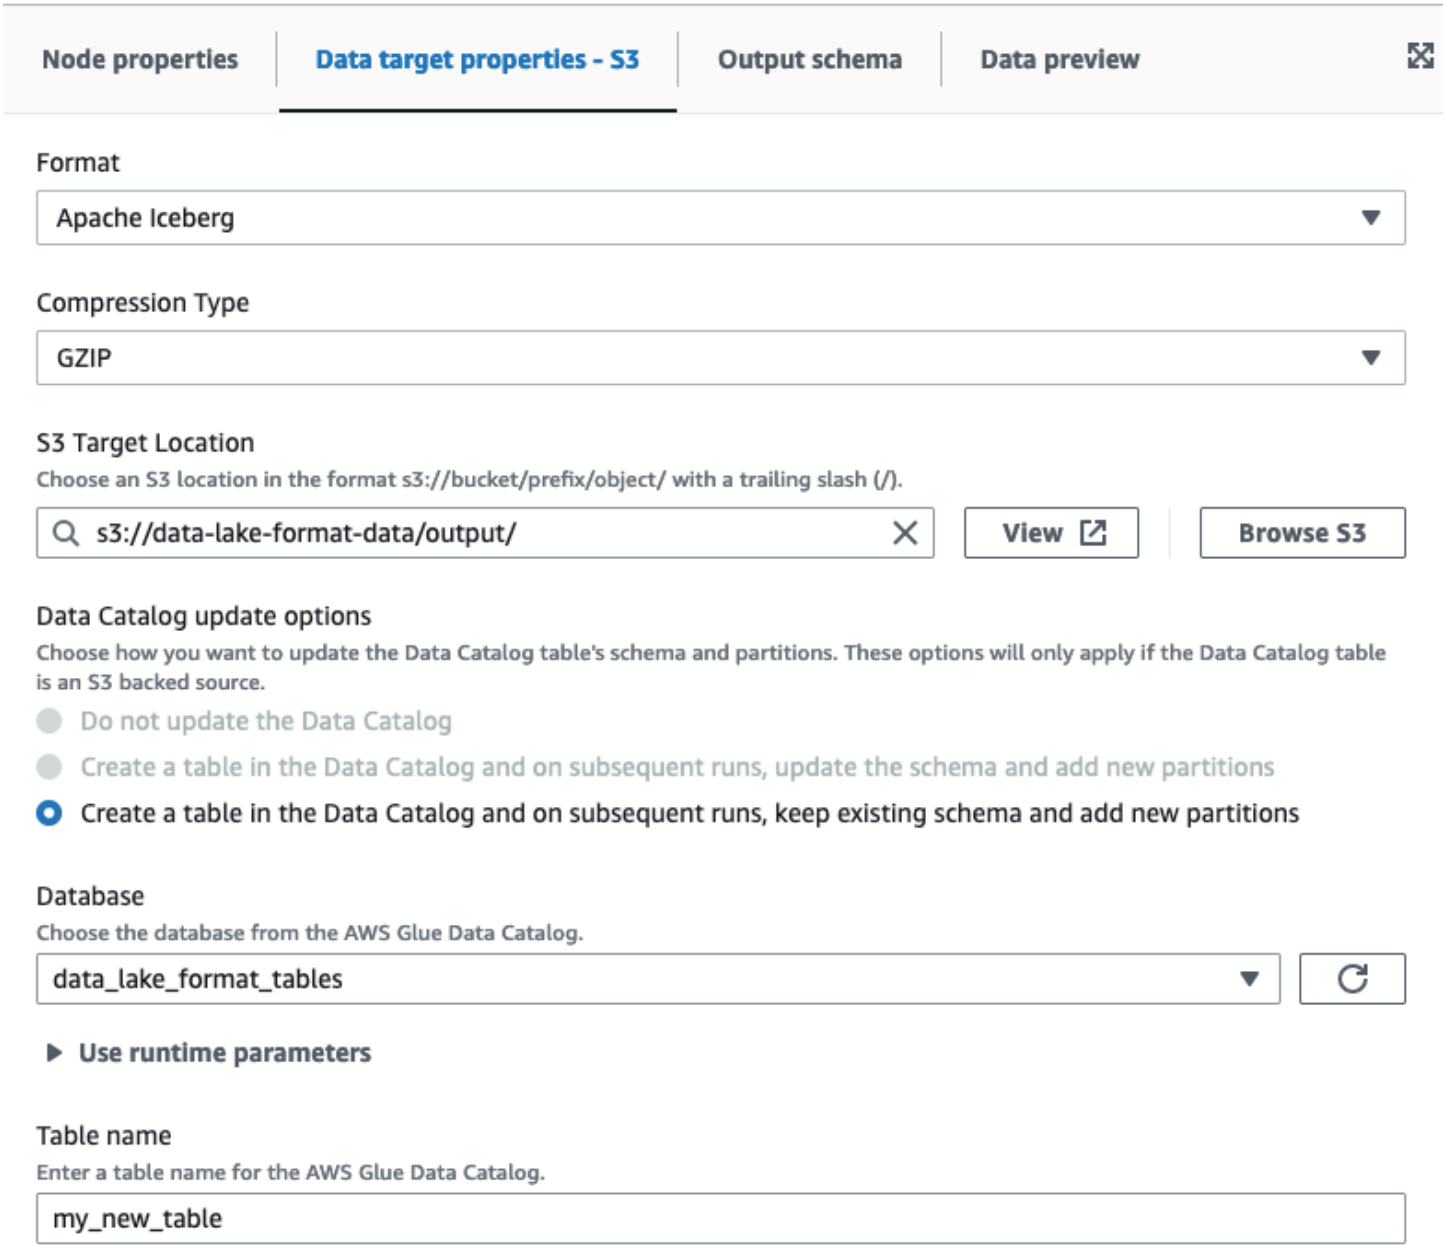

Uso del marco de Apache Iceberg en los orígenes de datos de Amazon S3

Uso del marco de Apache Iceberg en los orígenes de datos del Catálogo de datos

1. En el menú Origen, seleccione Catálogo de datos de AWS Glue Studio.
2. En la pestaña Propiedades del origen de datos, elija una base de datos y una tabla.
3. AWS Glue Studio muestra el tipo de formato como Apache Iceberg y la dirección URL de Amazon S3.

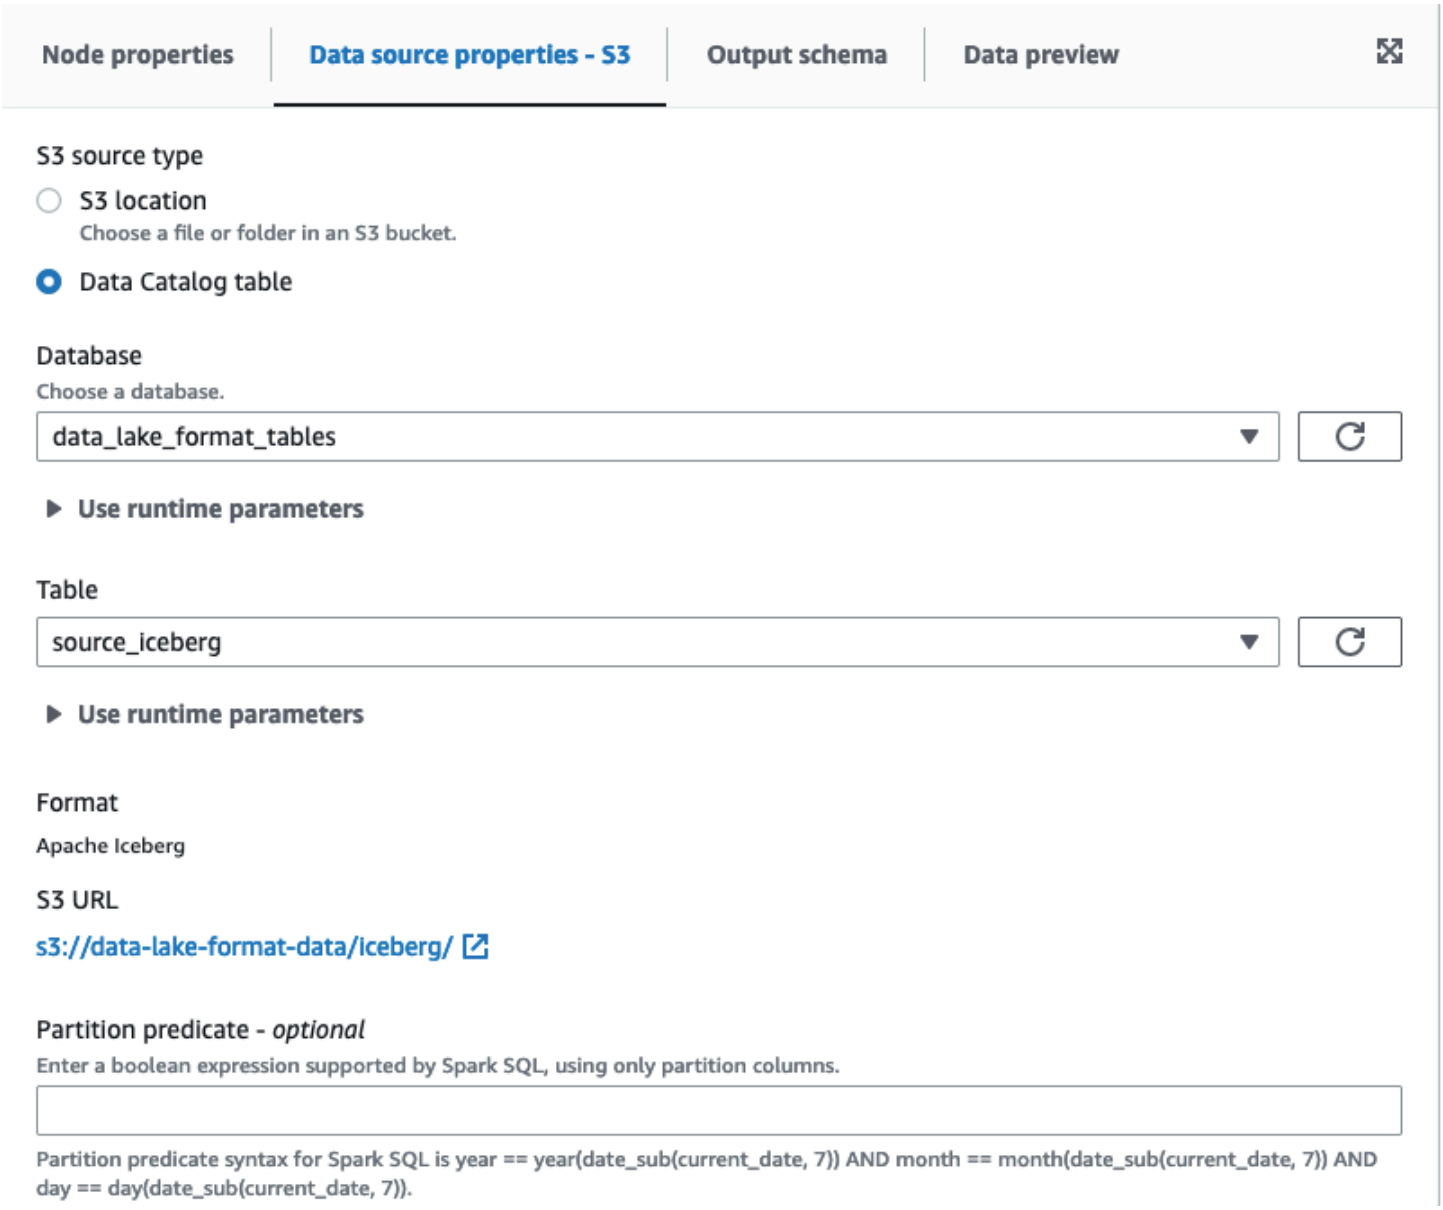

Uso del marco de Apache Iceberg en los orígenes de datos de Amazon S3

Apache Iceberg no está disponible como opción de datos para los nodos de origen de Amazon S3 en AWS Glue Studio.

Conexión con orígenes de datos mediante trabajos de ETL visuales

Al crear un nuevo trabajo, puede usar conexiones para conectarse a datos cuando edite trabajos de ETL visuales en AWS Glue. Para ello, puede agregar nodos de origen que usen conectores para leer datos y nodos de destino para especificar la ubicación para escribir datos.

Temas

- Modificar las propiedades de un nodo de origen de datos
- Uso de tablas del Catálogo de datos para el origen de datos
- Uso de un conector para el origen de datos
- Uso de archivos en Amazon S3 para el origen de datos
- Uso de un origen de datos de streaming
- Referencias

Modificar las propiedades de un nodo de origen de datos

Para especificar las propiedades del origen de datos, elija primero un nodo de origen de datos en el diagrama de trabajo. A continuación, en el lado derecho del panel de detalles del nodo, configure las propiedades del nodo.

Para modificar las propiedades de un nodo de origen de datos

1. Vaya al editor visual para acceder a un trabajo nuevo o guardado.
2. Elija un nodo de origen de datos en el diagrama de trabajo.
3. Elija la pestaña Node properties (Propiedades del nodo) en el panel de detalles del nodo y escriba la siguiente información:
   - Name (Nombre): (opcional) ingrese un nombre para asociar al nodo en el diagrama de trabajo. Este nombre debe ser único entre todos los nodos de este trabajo.
   - Node type (Tipo de nodo): el tipo de nodo determina la acción que realiza el nodo. En la lista de opciones para Node type (Tipo de nodo), elija uno de los valores enumerados en el encabezado Data source (Origen de datos).
4. Configuración de la información de Data source properties (Propiedades de origen de datos). Para obtener más información, consulte las siguientes secciones:
   - Uso de tablas del Catálogo de datos para el origen de datos
   - Uso de un conector para el origen de datos
   - Uso de archivos en Amazon S3 para el origen de datos
   - Uso de un origen de datos de streaming
5. (Opcional) después de configurar las propiedades del nodo y del origen de datos, puede ver el esquema de datos para su origen de datos al seleccionar la pestaña Output schema (Esquema de salida) en el panel de detalles del nodo. La primera vez que elija esta pestaña para cualquier

nodo de trabajo, se le pedirá que proporcione un rol de IAM para acceder a los datos. Si no ha especificado un rol de IAM en Job details (Detalles del trabajo), se le pedirá que ingrese un rol de IAM aquí.

6. (Opcional) después de configurar las propiedades del nodo y del origen de datos, puede ver la previsualización del conjunto de datos para su origen de datos al seleccionar la pestaña Data preview (Previsualización de datos) en el panel de detalles del nodo. La primera vez que elija esta pestaña para cualquier nodo de trabajo, se le pedirá que proporcione un rol de IAM para acceder a los datos. Hay un costo asociado con el uso de este recurso y la facturación comienza tan pronto como proporcione un rol de IAM.

Uso de tablas del Catálogo de datos para el origen de datos

En todos los orígenes de datos, excepto Amazon S3 y los conectores, debe existir una tabla en el AWS Glue Data Catalog para el tipo de fuente que elija. AWS Glue no crea la tabla del Catálogo de datos.

Para configurar un nodo de origen de datos en función de una tabla del Catálogo de datos

1. Vaya al editor visual para acceder a un trabajo nuevo o guardado.
2. Elija un nodo de origen de datos en el diagrama de trabajo.
3. Elija la pestaña Data source properties (Propiedades de origen de datos) y, a continuación, escriba la información siguiente:

   - S3 source type (Tipo de origen S3): (solo para orígenes de datos de Amazon S3) elija la opción Select a Catalog table (Seleccionar una tabla del catálogo) para utilizar una tabla del AWS Glue Data Catalog existente.
   - Database (Base de datos): elija la base de datos del Catálogo de datos que contiene la tabla de origen que desea utilizar para este trabajo. Puede utilizar el campo de búsqueda para buscar una base de datos por su nombre.
   - Table (Tabla): elija la tabla asociada a los datos de origen de la lista. Esta tabla ya debe existir en AWS Glue Data Catalog. Puede utilizar el campo de búsqueda para buscar una tabla por su nombre.
   - Partition predicate (Predicado de partición): (sólo para orígenes de datos de Amazon S3) ingrese una expresión booleana basada en Spark SQL que incluya sólo las columnas de partición. Por ejemplo: `"(year=='2020' and month=='04')"`

- Temporary directory (Directorio temporal): (sólo para orígenes de datos de Amazon Redshift) ingrese una ruta de acceso para la ubicación de un directorio de trabajo en Amazon S3 donde su trabajo de ETL puede escribir resultados intermedios temporales.
- Role associated with the cluster (Rol asociado al clúster): (sólo para orígenes de datos de Amazon Redshift) ingrese un rol para que utilice su trabajo de ETL que contenga permisos para clústeres de Amazon Redshift. Para obtener más información, consulte the section called “Permisos de origen de datos y destino de datos”.

Uso de un conector para el origen de datos

Si selecciona un conector para el Node type (Tipo de nodo), siga las instrucciones en Creación de trabajos con conectores personalizados para finalizar la configuración de las propiedades del origen de datos.

Uso de archivos en Amazon S3 para el origen de datos

Si elige Amazon S3 como origen de datos, puede elegir entre lo siguiente:

- Una base de datos y una tabla del Catálogo de datos.
- Un bucket, carpeta o archivo en Amazon S3.

Si utiliza un bucket de Amazon S3 como origen de datos, AWS Glue detecta el esquema de los datos en la ubicación especificada desde uno de los archivos o al utilizar el archivo especificado como archivo de muestra. La detección de esquemas se produce cuando se utiliza el botón Infer schema (Inferir esquema). Si cambia la ubicación de Amazon S3 o el archivo de ejemplo, debe elegir Infer schema (Inferir esquema) una vez más, para realizar la detección de esquemas utilizando la nueva información.

Para configurar un nodo de origen de datos que lea directamente desde archivos en Amazon S3

1. Vaya al editor visual para acceder a un trabajo nuevo o guardado.
2. Elija un nodo de origen de datos en el diagrama de trabajo para un origen de Amazon S3.
3. Elija la pestaña Data source properties (Propiedades de origen de datos) y, a continuación, escriba la información siguiente:

    - S3 source type (Tipo de origen de S3): (solo para orígenes de datos de Amazon S3) elija la opción S3 location (Ubicación de S3).

- S3 URL (URL de S3): ingrese la ruta de acceso al bucket, carpeta o archivo de Amazon S3 que contiene los datos de su trabajo. Puede elegir Browse S3 (Examinar S3) para seleccionar la ruta de acceso entre las ubicaciones disponibles para su cuenta.
- Recursive (Acción recursiva): elija esta opción si desea que AWS Glue lea datos de archivos en carpetas secundarias en la ubicación de S3.

  Si las carpetas secundarias contienen datos particionados, AWS Glue no agrega ninguna información de partición especificada en los nombres de carpeta al Catálogo de datos. Por ejemplo, considere la siguientes carpetas en Amazon S3:

  ```
  S3://sales/year=2019/month=Jan/day=1
  S3://sales/year=2019/month=Jan/day=2
  ```

  Si elige Recursive (Acción recursiva) y selecciona la carpeta `sales` como la ubicación de S3, AWS Glue lee los datos en todas las carpetas secundarias, pero no crea particiones por año, mes o día.
- Data format (Formato de datos): elija el formato en el que se almacenan los datos. Puede elegir JSON, CSV o Parquet. El valor que seleccione indica al trabajo de AWS Glue cómo leer los datos del archivo de origen.

  > **Note**
  >
  > Si no selecciona el formato correcto para los datos, AWS Glue puede inferir bien el esquema, pero el trabajo no podrá analizar los datos del archivo de origen en forma correcta.

  Puede introducir opciones de configuración adicionales, en función del formato que elija.

  - JSON (JavaScript Object Notation)
    - JsonPath: ingrese una ruta de JSON que apunte a un objeto que se usa para definir un esquema de tabla. Las expresiones de la ruta JSON siempre hacen referencia a una estructura JSON de la misma manera que la expresión XPath se utiliza en combinación con un documento XML. El “root member object (objeto miembro raíz)” en la ruta JSON siempre se conoce como $, incluso si es un objeto o matriz. La ruta de JSON se puede escribir en la notación de puntos o la notación de corchete.

Para obtener más información acerca de las rutas JSON, consulte JsonPath en el sitio web GitHub.

- Records in source files can span multiple lines (Los registros en los archivos de origen pueden abarcar varias líneas): elija esta opción si un solo registro puede abarcar varias líneas en el archivo CSV.

- CSV (valores separados por comas)
  - Delimiter (Delimitador): escriba un carácter para indicar qué elemento va a separar cada entrada de columna en la fila, por ejemplo, `;` o `,`.
  - Escape character (Carácter de escape): escriba un carácter que se utilice como carácter de escape. Este carácter indica que el carácter que sigue inmediatamente al carácter de escape debe tomarse en forma literal y no debe interpretarse como un delimitador.
  - Quote characters (Caracteres de cita): ingrese el carácter que se utiliza para agrupar cadenas separadas en un solo valor. Por ejemplo, debería elegir Double quote (") [Comilla doble (“)] si tiene valores como `"This is a single value"` en su archivo CSV.
  - Records in source files can span multiple lines (Los registros en los archivos de origen pueden abarcar varias líneas): elija esta opción si un solo registro puede abarcar varias líneas en el archivo CSV.
  - First line of source file contains column headers (La primera línea del archivo de origen contiene encabezados de columna): elija esta opción si la primera fila del archivo CSV contiene encabezados de columna en lugar de datos.
- Parquet (almacenamiento en columna de Apache Parquet)

  No hay ajustes adicionales que configurar para los datos almacenados en formato Parquet.
- Apache Hudi

  No hay ajustes adicionales que configurar para los datos almacenados en formato Apache Hudi.
- Delta Lake

  No hay ajustes adicionales que configurar para los datos almacenados en formato Delta Lake.
- Excel

  No hay ajustes adicionales que configurar para los datos almacenados en formato Excel.

- Partition predicate (Predicado de partición): para particionar los datos que se leen desde el origen de datos, ingrese una expresión booleana basada en Spark SQL que incluya sólo las columnas de partición. Por ejemplo: `"(year=='2020' and month=='04')"`
- Advanced options (Opciones avanzadas): expanda esta sección si desea que AWS Glue detecte el esquema de los datos en función de un archivo específico.
  - Schema inference (Inferencia de esquema): elija la opción Choose a sample file from S3 (Elegir un archivo de ejemplo desde S3) si desea utilizar un archivo específico en lugar de permitir que AWS Glue elija un archivo. La inferencia de esquemas no está disponible para el origen de Excel.
  - Auto-sampled file (Archivo de ejemplo automático): ingrese la ruta de acceso al archivo en Amazon S3 que se utilizará para inferir el esquema.

  Si está editando un nodo de origen de datos y cambia el archivo de ejemplo seleccionado, elija Reload schema (Volver a cargar esquema) para detectar el esquema mediante el nuevo archivo de ejemplo.

4. Elija el botón Infer schema (Inferir esquema) para detectar el esquema a partir de los archivos de origen en Amazon S3. Si cambia la ubicación de Amazon S3 o el archivo de ejemplo, debe elegir Infer schema (Inferir esquema) una vez más, para inferir el esquema con la nueva información.

Uso de un origen de datos de streaming

Puede crear trabajos de extracción, transformación y carga (ETL) de streaming que se ejecuten en forma continua y consuman datos de orígenes de streaming en Amazon Kinesis Data Streams, Apache Kafka y Amazon Managed Streaming for Apache Kafka (Amazon MSK).

Para configurar las propiedades de un origen de datos de streaming

1. Vaya al editor visual de gráficos para acceder a un trabajo nuevo o guardado.
2. Elija un nodo de origen de datos en el gráfico para Kafka o Kinesis Data Streams.
3. Elija la pestaña Data source properties (Propiedades de origen de datos) y, a continuación, escriba la información siguiente:

   Kinesis

   - Kinesis source type (Tipo de origen de Kinesis): elija la opción Stream details (Detalles de la transmisión) para utilizar el acceso directo a la fuente de streaming o elegir Data Catalog

table (Tabla del Catálogo de datos) a fin de utilizar la información almacenada allí en su lugar.

Si elige Stream details (Detalles de la transmisión), especifique la siguiente información adicional.

- Ubicación del flujo de datos: elija si el flujo se encuentra asociado al usuario actual o si se encuentra asociado a otro usuario.
- Region (Región): elija la Región de AWS donde existe la transmisión. Esta información se utiliza con la finalidad de crear el ARN para acceder a la secuencia de datos.
- Stream ARN (Transmisión de ARN): ingrese el nombre de recurso de Amazon (ARN) para Kinesis Data Stream. Si la transmisión se encuentra en la cuenta corriente, puede elegir el nombre de la secuencia en la lista desplegable. Puede utilizar el campo de búsqueda para buscar una secuencia de datos de datos por su nombre o ARN.
- Data format (Formato de los datos): elija el formato utilizado por la secuencia de datos de la lista.

  AWS Glue detecta de forma automática el esquema de los datos de streaming.

Si elige Data Catalog table (Tabla del Catálogo de datos), especifique la siguiente información adicional.

- Database (Base de datos): (opcional) elija la base de datos en el Catálogo de datos de AWS Glue que contenga la tabla asociada al origen de datos de streaming. Puede utilizar el campo de búsqueda para buscar una base de datos por su nombre.
- Table (Tabla): (opcional) elija la tabla asociada a los datos de origen de la lista. Esta tabla ya debe existir en el Catálogo de datos de AWS Glue. Puede utilizar el campo de búsqueda para buscar una tabla por su nombre.
- Detect schema (Detectar esquemas): elija esta opción para que AWS Glue detecte el esquema a partir de los datos de streaming, en lugar de almacenar la información del esquema en una tabla del Catálogo de datos. Esta opción se habilita automáticamente si elige la opción Stream details (Detalles de la transmisión).

- Starting position (Posición inicial): de forma predeterminada, el trabajo de ETL utiliza la opción Earliest (La primera), lo que significa que lee los datos desde el registro más antiguo disponible en la transmisión. En su lugar, puede elegir Latest (El último), lo que indica que el trabajo de ETL debería empezar a leer justo después del registro más reciente en la transmisión.

- Window size (Tamaño de ventana): de forma predeterminada, su trabajo de ETL procesa y escribe datos en ventanas de 100 segundos. Esto permite que los datos se procesen de forma eficiente y permite que las agregaciones se realicen en los datos que llegan más tarde de lo previsto. Puede modificar este tamaño de ventana para aumentar la puntualidad o la precisión de agregación.

  Los trabajos de streaming de AWS Glue utilizan puntos de control en lugar de marcadores de trabajo para realizar un seguimiento de los datos leídos.
- Advanced connection options (Opciones avanzadas de conexión): expanda esta sección para agregar pares de valor de clave a fin de especificar opciones de conexión adicionales. Para obtener más información acerca de las opciones que puede especificar aquí, consulte "connectionType": "kinesis" en la Guía para desarrolladores de AWS Glue.

Kafka

- Apache Kafka source (Fuente de Apache Kafka): elija la opción Stream details (Detalles de la transmisión) para utilizar el acceso directo a la fuente de streaming o elegir Data Catalog table (Tabla del Catálogo de datos) a fin de utilizar la información almacenada allí en su lugar.

  Si elige Data Catalog table (Tabla del Catálogo de datos), especifique la siguiente información adicional.

  - Database (Base de datos): (opcional) elija la base de datos en el Catálogo de datos de AWS Glue que contenga la tabla asociada al origen de datos de streaming. Puede utilizar el campo de búsqueda para buscar una base de datos por su nombre.
  - Table (Tabla): (opcional) elija la tabla asociada a los datos de origen de la lista. Esta tabla ya debe existir en el Catálogo de datos de AWS Glue. Puede utilizar el campo de búsqueda para buscar una tabla por su nombre.
  - Detect schema (Detectar esquemas): elija esta opción para que AWS Glue detecte el esquema a partir de los datos de streaming, en lugar de almacenar la información del esquema en una tabla del Catálogo de datos. Esta opción se habilita automáticamente si elige la opción Stream details (Detalles de la transmisión).

  Si elige Stream details (Detalles de la transmisión), especifique la siguiente información adicional.

    - Connection name (Nombre de la conexión): elija la conexión de AWS Glue que contiene la información de acceso y autenticación para la secuencia de datos de Kafka. Debe utilizar una conexión con los orígenes de datos de streaming de Kafka. Si no existe una conexión, puede utilizar la consola de AWS Glue a fin de crear una conexión para la secuencia de datos de Kafka.
    - Topic name (Nombre del tema): ingrese el nombre del tema en el que se va a leer.
    - Data format (Formato de los datos): elija el formato que desea utilizar al leer datos de la secuencia de eventos de Kafka.
- Starting position (Posición inicial): de forma predeterminada, el trabajo de ETL utiliza la opción Earliest (La primera), lo que significa que lee los datos desde el registro más antiguo disponible en la transmisión. En su lugar, puede elegir Latest (El último), lo que indica que el trabajo de ETL debería empezar a leer justo después del registro más reciente en la transmisión.
- Window size (Tamaño de ventana): de forma predeterminada, su trabajo de ETL procesa y escribe datos en ventanas de 100 segundos. Esto permite que los datos se procesen de forma eficiente y permite que las agregaciones se realicen en los datos que llegan más tarde de lo previsto. Puede modificar este tamaño de ventana para aumentar la puntualidad o la precisión de agregación.

  Los trabajos de streaming de AWS Glue utilizan puntos de control en lugar de marcadores de trabajo para realizar un seguimiento de los datos leídos.
- Advanced connection options (Opciones avanzadas de conexión): expanda esta sección para agregar pares de valor de clave a fin de especificar opciones de conexión adicionales. Para obtener más información acerca de las opciones que puede especificar aquí, consulte "connectionType": "kafka" en la Guía para desarrolladores de AWS Glue.

> **Note**
>
> Las previsualizaciones de datos no se soportan actualmente para los orígenes de datos de streaming.

Referencias

prácticas recomendadas

- Cree una canalización de servicios de ETL para cargar datos de forma incremental desde Amazon S3 hasta utilizar Amazon Redshift en AWS Glue

Programación de ETL

- Tipos de conexión y opciones para ETL en AWS Glue
- Valores connectionType de JDBC
- Opciones avanzadas para mover datos hacia y desde Amazon Redshift

Configuración de nodos de destino de datos

El destino de datos es donde el trabajo escribe los datos transformados.

Información general de las opciones de destino de datos

Su destino de datos (también denominado receptor de datos) puede ser uno de los siguientes:

- S3: el trabajo escribe los datos en un archivo en la ubicación de Amazon S3 que elija y en el formato que especifique.

  Si configura columnas de partición para el destino de datos, el trabajo escribe el conjunto de datos en Amazon S3 en directorios en función de la clave de partición.
- AWS Glue Data Catalog: el trabajo utiliza la información asociada a la tabla del Catálogo de datos para escribir los datos de salida en una ubicación de destino.

  Puede crear la tabla en forma manual o con el rastreador. También puede utilizar plantillas de AWS CloudFormation para crear tablas en el Catálogo de datos.
- Conector: un conector es un fragmento de código que facilita la comunicación entre el almacén de datos y AWS Glue. El trabajo utiliza el conector y la conexión asociada para escribir los datos de salida en una ubicación de destino. Puede suscribirse a un conector ofrecido en AWS Marketplace o puede crear su propio conector personalizado. Para obtener más información, consulte Agregar conectores a AWS Glue Studio.

Puede elegir actualizar el Catálogo de datos cuando su trabajo escriba en un destino de datos de Amazon S3. En lugar de requerir que un rastreador actualice el Catálogo de datos cuando cambian el esquema o las particiones, esta opción facilita la actualización de las tablas. Esta opción simplifica el proceso de hacer que los datos estén disponibles para análisis mediante el agregado opcional de

nuevas tablas al Catálogo de datos, la actualización de particiones de tabla y del esquema de las tablas directamente desde el trabajo.

Edición del nodo de destino de datos

El destino de datos es donde el trabajo escribe los datos transformados.

Para agregar o configurar un nodo de destino de datos en el diagrama de trabajo

1. (Opcional) si necesita agregar un nodo de destino, elija Target (Destino) en la barra de herramientas situada en la parte superior del editor visual y elija S3 o Glue Data Catalog (Catálogo de datos de Glue).

   - Si elige S3 para el destino, el trabajo escribe el conjunto de datos en uno o más archivos en la ubicación de Amazon S3 que especifique.
   - Si elige AWS Glue Data Catalog para el destino, el trabajo escribe en una ubicación descrita por la tabla seleccionada en el Catálogo de datos.
2. Elija un nodo de destino de datos en el diagrama de trabajo. Al elegir un nodo, aparece el panel de detalles del nodo en el lado derecho de la página.
3. Elija la pestaña Node properties (Propiedades del nodo) y, a continuación, escriba la información siguiente:

   - Name (Nombre): ingrese un nombre para asociar al nodo en el diagrama de trabajo.
   - Node type (Tipo de nodo): ya se debe haber seleccionado un valor, pero podrá modificarlo según sea necesario.
   - Node parents (Nodo principales): el nodo principal es el nodo del diagrama de trabajo que proporciona los datos de salida que desea escribir en la ubicación de destino. Para un diagrama de trabajo previamente completado, el nodo de destino ya debe tener seleccionado el nodo principal. Si no se muestra ningún nodo principal, elija un nodo principal de la lista.

     Un nodo de destino tiene un nodo principal único.
4. Configure la información de Data source properties (Propiedades de origen de datos). Para obtener más información, consulte las siguientes secciones:

   - Uso de Amazon S3 para el destino de datos
   - Uso de tablas del Catálogo de datos para el destino de datos
   - Uso de un conector para el destino de datos

5. (Opcional) después de configurar las propiedades del nodo de destino de datos, puede ver el esquema de salida para sus datos al seleccionar la pestaña Output schema (Esquema de salida) en el panel de detalles del nodo. La primera vez que elija esta pestaña para cualquier nodo de trabajo, se le pedirá que proporcione un rol de IAM para acceder a los datos. Si no ha especificado un rol de IAM en Job details (Detalles del trabajo), se le pedirá que ingrese un rol de IAM aquí.

Uso de Amazon S3 para el destino de datos

En todos los orígenes de datos, excepto Amazon S3 y los conectores, debe existir una tabla en el AWS Glue Data Catalog para el tipo de fuente que elija. AWS Glue Studio no crea la tabla del Catálogo de datos.

Para configurar un nodo de destino de datos que escriba en Amazon S3

1. Vaya al editor visual para acceder a un trabajo nuevo o guardado.
2. Elija un nodo de origen de datos en el diagrama de trabajo.
3. Elija la pestaña Data source properties (Propiedades de origen de datos) y, a continuación, escriba la información siguiente:

   - Format (Formato): elija un formato de la lista. Los tipos de formato disponibles para los resultados de datos son:
     - JSON: notación de objetos JavaScript.
     - CSV: valores separados por comas.
     - Avro: Apache Avro JSON binario.
     - Parquet: un tipo personalizado de escritor de Parquet, optimizado para `DynamicFrames` como el formato de datos. En lugar de requerir un esquema precalculado para los datos, calcula y modifica el esquema dinámicamente.
     - ORC: formato Apache Optimized Row Columnar (ORC).
     - Apache Hudi: un marco de almacenamiento de lago de datos de código abierto que simplifica el procesamiento progresivo de datos y el desarrollo de canalizaciones de datos.
     - Apache Iceberg: proporciona un formato de tabla de alto rendimiento que funciona igual que una tabla SQL.
     - Delta Lake: es un marco de almacenamiento de lago de datos de código abierto para hacer transacciones de ACID, escalar el manejo de metadatos y unificar la transmisión y el procesamiento de datos por lotes.

- XML: lenguaje de marcado extensible (XML).
- Tableau Hyper: tecnología de motor de datos en memoria de Tableau.

Para obtener más información sobre estas opciones de formato, consulte Opciones de formato para las entradas y salidas de ETL en AWS Glue en la Guía para desarrolladores de AWS Glue.

- Tipo de compresión: puede optar por comprimir los datos de manera opcional mediante el tipo de archivos `CSV`, `JSON` o `Parquet`. El valor predeterminado es no compresión, o None (Ninguno).

Tipo de archivo	Compresiones
JSON/CSV/XML	GZIP, BZIP2, BROTLI, DEFLATE, LZ4, Snappy
Parquet	Snappy, LZ4, LZO, BROTLI, GZIP
ORC	Snappy, ZLIB, sin comprimir, LZO
Avro	GZIP, BZIP2, BROTLI, DEFLATE, LZ4, Snappy
Delta Lake	GZIP, BZIP2, BROTLI, DEFLATE, LZ4, Snappy
Apache Hudi	GZIP, LZO, Snappy
Apache Iceberg	GZIP, LZO, Snappy
Tableau Hyper	Ninguno

- S3 Target Location (Ubicación de destino de S3): el bucket y la ubicación de Amazon S3 para la salida de datos. Puede elegir la opción Browse S3 (Examinar S3) para ver los depósitos de Amazon S3 a los que tiene acceso y elegir uno como destino.
- Opciones de actualización del Catálogo de datos
  - Do not update the Data Catalog (No actualizar el Catálogo de datos): (predeterminado) seleccione esta opción si no desea que el trabajo actualice el Catálogo de datos, incluso si el esquema cambia o se agregan nuevas particiones.

- Create a table in the Data Catalog and on subsequent runs, update the schema and add new partitions (Crear una tabla en el Catálogo de datos y en ejecuciones posteriores, actualizar el esquema y agregar nuevas particiones): si elige esta opción, el trabajo crea la tabla en el Catálogo de datos durante la primera ejecución del trabajo. En las ejecuciones de trabajos posteriores, el trabajo actualiza la tabla del Catálogo de datos si cambia el esquema o se agregan nuevas particiones.

  También debe seleccionar una base de datos en el Catálogo de datos e introducir un nombre de tabla.
- Create a table in the Data Catalog and on subsequent runs, keep existing schema and add new partitions (Crear una tabla en el Catálogo de datos y en ejecuciones posteriores, mantener el esquema existente y agregar nuevas particiones): si elige esta opción, el trabajo crea la tabla en el Catálogo de datos durante la primera ejecución del trabajo. En las ejecuciones de trabajos posteriores, el trabajo actualiza la tabla del Catálogo de datos solo para agregar nuevas particiones.

  También debe seleccionar una base de datos en el Catálogo de datos e introducir un nombre de tabla.

- Particionamiento de archivos: elija el tipo de particionamiento en el que desea guardar la salida.
  - Generación automática de archivos (recomendado): este es el valor predeterminado para el número de archivos generados.
  - Salida de varios archivos: especifique el número de archivos de salida que desea. Para un rendimiento óptimo, utilice el valor predeterminado de número de archivos generados automáticamente.
- Partition keys (Claves de partición): elija qué columnas utilizar como claves de partición en la salida. Para agregar más claves de partición, elija Add a partition key (Agregar una clave de partición).

El particionamiento de archivos no es compatible con Tableau Hyper como formato de destino.

Uso de tablas del Catálogo de datos para el destino de datos

En todos los orígenes de datos, excepto Amazon S3 y los conectores, debe existir una tabla en el AWS Glue Data Catalog para el tipo de destino que elija. AWS Glue Studio no crea la tabla del Catálogo de datos.

Para configurar las propiedades de datos de un destino que utiliza una tabla del Catálogo de datos

1. Vaya al editor visual para acceder a un trabajo nuevo o guardado.
2. Elija un nodo de destino de datos en el diagrama de trabajo.
3. Elija la pestaña Data target properties (Propiedades de destino de datos) y, a continuación, escriba la información siguiente:

   - Database (Base de datos): elija la base de datos que contiene la tabla que desea utilizar como destino a partir de la lista. Esta base de datos ya debe existir en el Catálogo de datos.
   - Table (Tabla): elija la tabla que define el esquema de los datos de salida a partir de la lista. Esta tabla ya debe existir en el Catálogo de datos.

     Una tabla del Catálogo de datos está formada por los nombres de las columnas, las definiciones de tipos de datos, la información de partición y otros metadatos acerca de un conjunto de datos de destino. Su trabajo escribe a una ubicación descrita en esta tabla en el Catálogo de datos.

     Para obtener más información acerca de cómo crear tablas en el Catálogo de datos, consulte Definición de tablas en el Catálogo de datos en la Guía para desarrolladores de AWS Glue.
   - Opciones de actualización del Catálogo de datos
     - Do not change table definition (No cambiar la definición de la tabla): (predeterminado) seleccione esta opción si no desea que el trabajo actualice el Catálogo de datos, incluso si el esquema cambia o se agregan nuevas particiones.
     - Update schema and add new partitions (Actualizar esquema y agregar nuevas particiones): si elige esta opción, el trabajo actualiza la tabla del Catálogo de datos si cambia el esquema o se agregan nuevas particiones.
     - Keep existing schema and add new partitions (Mantener el esquema existente y agregar nuevas particiones): si elige esta opción, el trabajo actualiza la tabla del Catálogo de datos solo para agregar nuevas particiones.
     - Partition keys (Claves de partición): elija qué columnas utilizar como claves de partición en la salida. Para agregar más claves de partición, elija Add a partition key (Agregar una clave de partición).

Uso de un conector para el destino de datos

Si selecciona un conector para el Node type (Tipo de nodo), siga las instrucciones en Creación de trabajos con conectores personalizados para finalizar la configuración de las propiedades del destino de datos.

Edición o carga de un script de trabajo

Utilice el editor visual de AWS Glue Studio para editar el script de trabajo o cargar el propio.

Puede utilizar el editor visual para editar nodos de trabajo sólo si estos se crearon con AWS Glue Studio. Si el trabajo se creó con la consola de AWS Glue, a través de comandos de la API, o con la interfaz de línea de comandos (CLI), puede utilizar el editor de scripts en AWS Glue Studio para editar el script, los parámetros y la programación del trabajo. También puede editar el script para un trabajo creado en AWS Glue Studio mediante la conversión del trabajo a modo de sólo script.

Para editar el script de trabajo o cargar su propio script

1. Si crea un nuevo trabajo, en la página Jobs (Trabajos), seleccione la opción Spark script editor (Editor de scripts de Spark) para crear un trabajo de Spark o elija la opción Python Shell script editor (Editor de scripts de shell de Python) para crear un trabajo de shell de Python. Puede escribir un nuevo script o cargar un script existente. Si elige Spark script editor (Editor de scripts de Spark), puede escribir o cargar un script de Scala o Python. Si elige Python Shell script editor (Editor de scripts de shell de Python), solo puede escribir o cargar un script de Python.

   Después de elegir la opción para crear un nuevo trabajo, en la sección Options (Opciones) que aparece, puede optar por comenzar con un script de inicio (Create a new script with boilerplate code (Crear un nuevo script con código reutilizable), o puede cargar un archivo local para utilizarlo como script de trabajo.

   Si elige Spark script editor (Editor de scripts de Spark), puede cargar archivos de script de Scala o Python. Los scripts de Scala deben tener la extensión de archivo `.scala`. Los scripts de Python deben reconocerse como archivos de tipo Python. Si elige Python Shell script editor (Editor de scripts de shell de Python), solo puede cargar archivos de script de Python.

   Cuando termine de tomar sus decisiones, elija Create (Crear) para crear el trabajo y abrir el editor visual.
2. Diríjase al editor visual de trabajos para el trabajo nuevo o guardado y, a continuación, elija la pestaña Script.

3. Si no creó un nuevo trabajo con una de las opciones del editor de script y nunca ha editado el script para un trabajo existente, la pestaña Script muestra el encabezado Script (Locked) [Script (bloqueado)]. Esto significa que el editor de scripts está en modo de solo lectura. Seleccione Edit script (Editar script) para desbloquear el script para su edición.

   Para poder editar el script, AWS Glue Studio convierte el trabajo de visual a de sólo script. Si desbloquea el script para editarlo, no podrá utilizar el editor visual para este trabajo después de guardarlo.

   En la ventana de confirmación, elija Confirm (Confirmar) para continuar o Cancel (Cancelar) para mantener el trabajo disponible para la edición visual.

   Si elige Confirm (Confirmar), la pestaña Visual ya no aparecerá en el editor. Puede utilizar AWS Glue Studio para modificar el script mediante el editor de script, modificar los detalles o la programación del trabajo o ver las ejecuciones de trabajos.

   > **Note**
   >
   > La conversión a un trabajo de sólo script solo será permanente una vez que guarde el trabajo. Si actualiza la página web de la consola o cierra el trabajo antes de guardarlo y vuelve a abrirlo en el editor visual, podrá editar los nodos individuales en el editor visual.

4. Edite el script según sea necesario.

   Cuando haya terminado de editar el script, elija Save (Guardar) para guardar el trabajo y convertir el trabajo de visual a sólo script de forma permanente.

5. (Opcional) Puede descargar el script desde la consola de AWS Glue Studio mediante el botón Download (Descargar) en la pestaña Script. Al seleccionar este botón, se abre una nueva ventana del navegador, que muestra el script desde su ubicación en Amazon S3. Los parámetros Script filename (Nombre de archivo del script) y Script path (Ruta del script) en la pestaña Job details (Detalles del trabajo) determinan el nombre y la ubicación del archivo de script en Amazon S3.

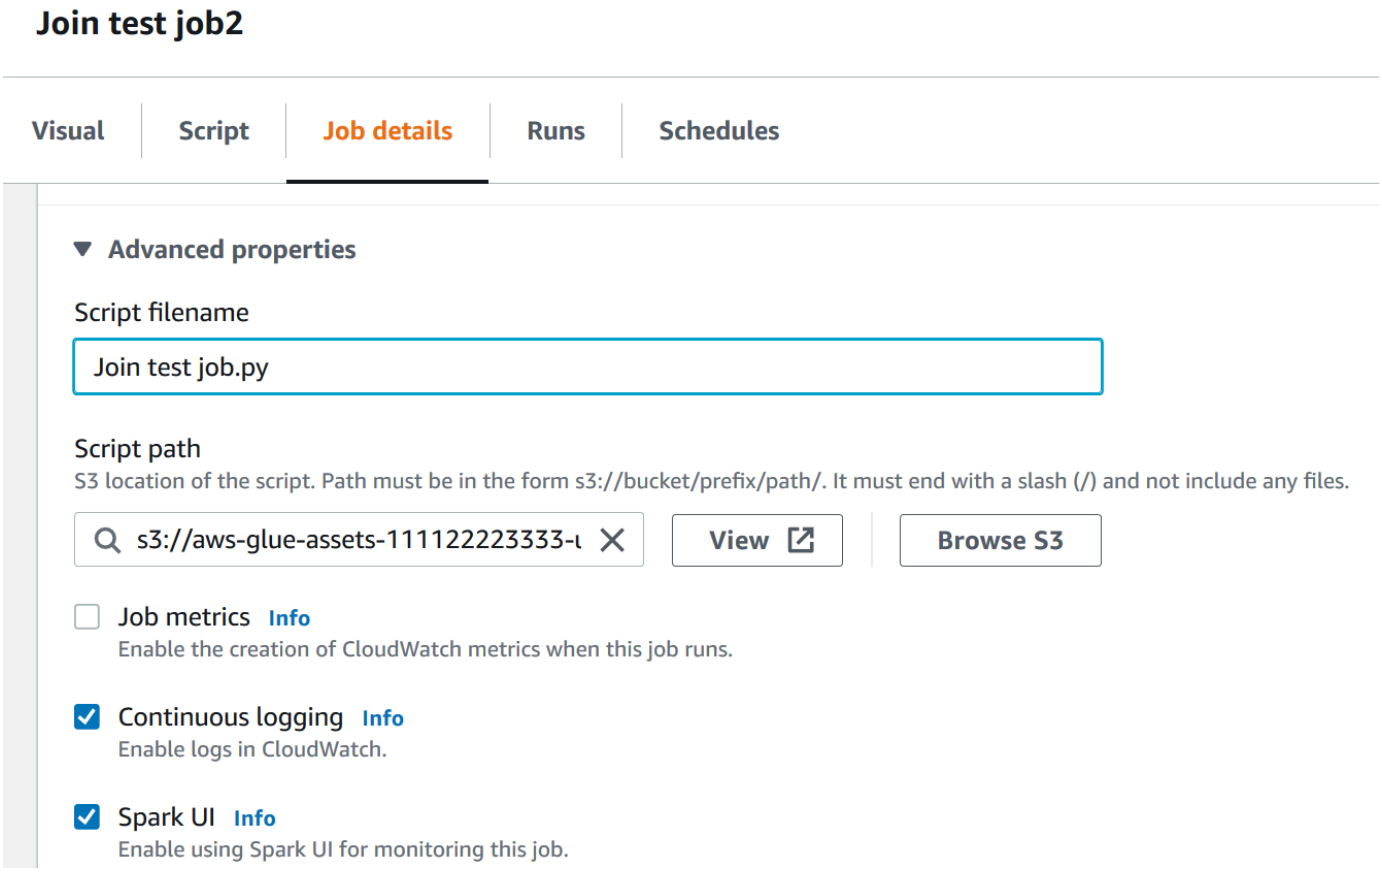

Cuando guarda el trabajo, AWS Glue guarda el script de trabajo en la ubicación especificada por estos campos. Si modifica el archivo de script en esta ubicación dentro de Amazon S3, AWS Glue Studio cargará el script modificado la próxima vez que edite el trabajo.

Creación y edición de scripts de Scala en AWS Glue Studio

Cuando elige el editor de script para crear un trabajo, de forma predeterminada, el lenguaje de programación de trabajo se establece en `Python 3`. Si elige escribir un nuevo script en lugar de cargarlo, AWS Glue Studio inicia un nuevo script con texto reutilizable escrito en Python. Si desea escribir un script de Scala en su lugar, primero debe configurar el editor de script para que utilice Scala.

> **Note**
>
> Si elige Scala como lenguaje de programación para el trabajo y utiliza el editor visual para diseñar su trabajo, el script de trabajo generado se escribe en Scala y no es necesario realizar más acciones.

Para escribir un nuevo script de Scala en AWS Glue Studio

1. Cree un nuevo trabajo mediante la opción Spark script editor (Editor de scripts de Spark).
2. En Options (Opciones), elija Create a new script with boilerplate code (Crear un nuevo script con código reutilizable).
3. Elija la pestaña Job details (Detalles del trabajo) y configure el Languaje (Lenguaje) a `Scala` (en lugar de `Python 3`).

   > **Note**
   >
   > La propiedad Type (Tipo) para el trabajo se configura automáticamente en `Spark` cuando elije la opción Spark script editor (Editor de scripts de Spark) para crear un trabajo.

4. Elija la pestaña Script.
5. Elimine el texto reutilizable de Python. Puede reemplazarlo con el siguiente texto reutilizable de Scala.

```
import com.amazonaws.services.glue.{DynamicRecord, GlueContext}
import org.apache.spark.SparkContext
import com.amazonaws.services.glue.util.JsonOptions
import com.amazonaws.services.glue.util.GlueArgParser
import com.amazonaws.services.glue.util.Job

object MyScript {
  def main(args: Array[String]): Unit = {
    val sc: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(sc)

    }
}
```

6. Escriba su script de trabajo de Scala en el editor. Agregue declaraciones `import` adicionales, según sea necesario.

Creación y edición de trabajos de shell de Python en AWS Glue Studio

Cuando elige el editor de scripts de shell de Python para crear un trabajo, puede cargar un script de Python existente o escribir uno nuevo. Si elige escribir un nuevo script, se agrega código reutilizable al nuevo script de trabajo de Python.

Para crear un nuevo trabajo de shell de Python

Consulte las instrucciones en Empezar trabajos en AWS Glue Studio.

Las propiedades de trabajo que se soportan para los trabajos de shell de Python no son las mismas que las soportadas para los trabajos de Spark. La siguiente lista describe los cambios en los parámetros de trabajo disponibles para los trabajos de shell de Python en la pestaña Job details (Detalles del trabajo).

- La propiedad Type (Tipo) para el trabajo se establece automáticamente en `Python Shell` y no se puede cambiar.
- En lugar de Language (Lenguaje), hay una propiedad Python version (Versión de Python) para el trabajo. Actualmente, los trabajos de shell de Python creados en AWS Glue Studio utilizan Python 3.6.
- La propiedad Glue version (Versión de Glue) no está disponible, ya que no se aplica a trabajos de shell de Python.
- En lugar de Worker type (Tipo de empleado) y Number of workers (Número de empleados), se muestra una propiedad Data processing units (Unidades de procesamiento de datos). Esta propiedad de trabajo determina cuántas unidades de procesamiento de datos (DPU) consume el shell de Python al ejecutar el trabajo.
- La propiedad Job bookmark (Marcador de trabajo) no está disponible, porque no se soporta para trabajos de shell de Python.
- En Advanced properties (Propiedades avanzadas), las siguientes propiedades no están disponibles para trabajos de shell de Python.
  - Métricas de trabajo
  - Registro continuo
  - Spark UI (Interfaz de usuario de Spark) y Spark UI logs path (Ruta de los registros de la interfaz de usuario de Spark)
  - Dependent jars path (Ruta de archivos JAR dependientes), en el encabezado Libraries (Bibliotecas)

Cambio de los nodos principales de un nodo en el diagrama de trabajo

Puede cambiar los elementos principales de un nodo para mover nodos dentro del diagrama de trabajo o para cambiar un origen de datos para un nodo.

Para cambiar el nodo principal

1. Elija el nodo del diagrama de trabajo que desee modificar.
2. En el panel de detalles del nodo, en la pestaña Node properties (Propiedades del nodo), en el encabezado Node parents (Nodos principales) elimine el nodo principal actual.
3. Elija un nuevo nodo principal de la lista.
4. Modifique las demás propiedades del nodo según sea necesario para que coincida con el nodo principal recién seleccionado.

Si modificó un nodo por error, puede utilizar el botón Undo (Deshacer) de la barra de herramientas para revertir la acción.

Eliminación de nodos del diagrama de trabajo

Al realizar trabajos con Visual ETL, puede quitar los nodos del lienzo sin la necesidad de volver a agregar o de reestructurar ningún nodo que esté conectado al nodo quitado.

En el siguiente ejemplo, puede ir a Trabajos de ETL > Visual ETL y, luego, en Ejemplos de trabajos, seleccionar Trabajo de Visual ETL para unir varios orígenes. Seleccione Crear ejemplo de trabajo para crear un trabajo y siga los pasos que se detallan a continuación.

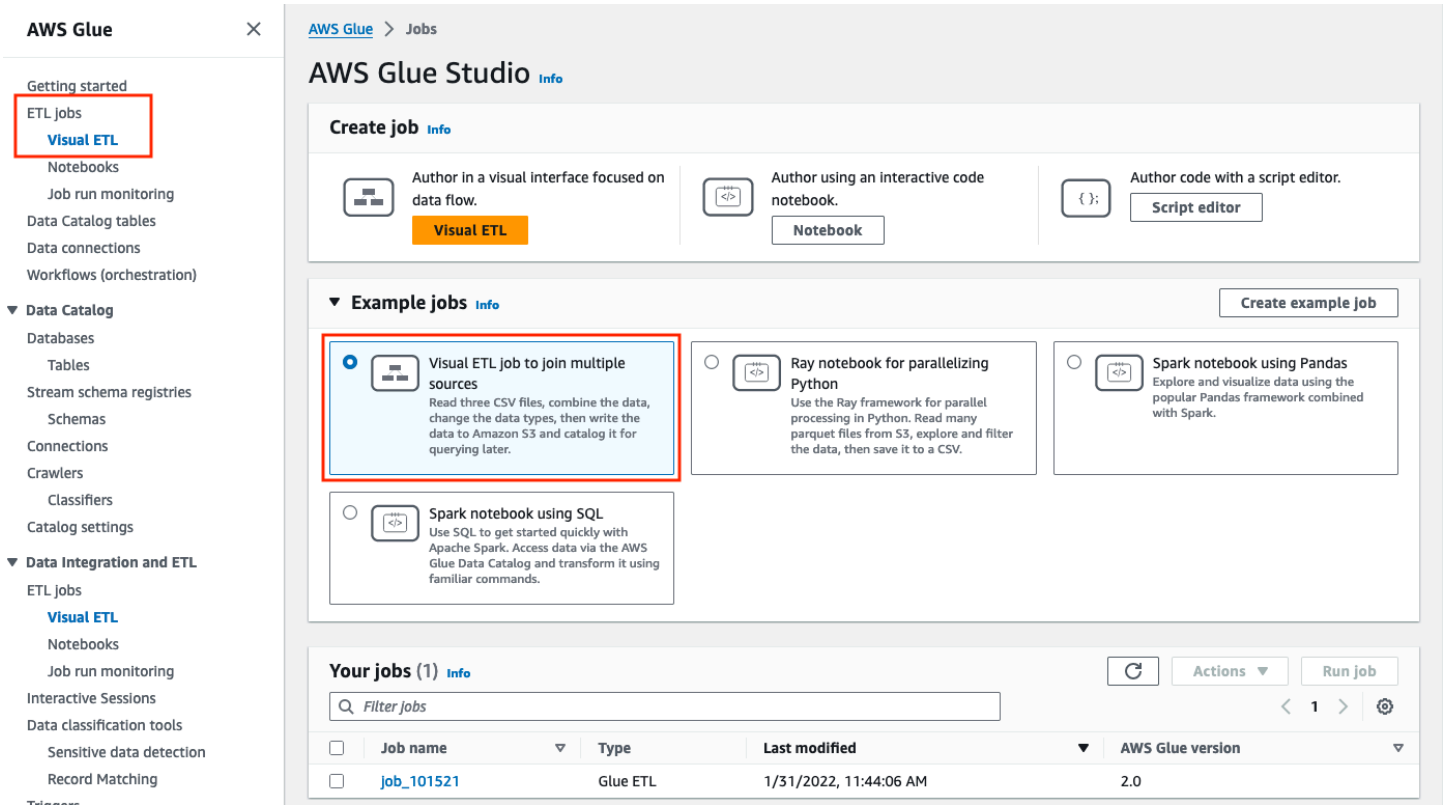

Eliminación de un nodo del lienzo

1. Desde la consola de AWS Glue, seleccione Visual ETL en el menú de navegación y seleccione el trabajo existente. El lienzo de trabajo mostrará el trabajo de ejemplo como se muestra a continuación.

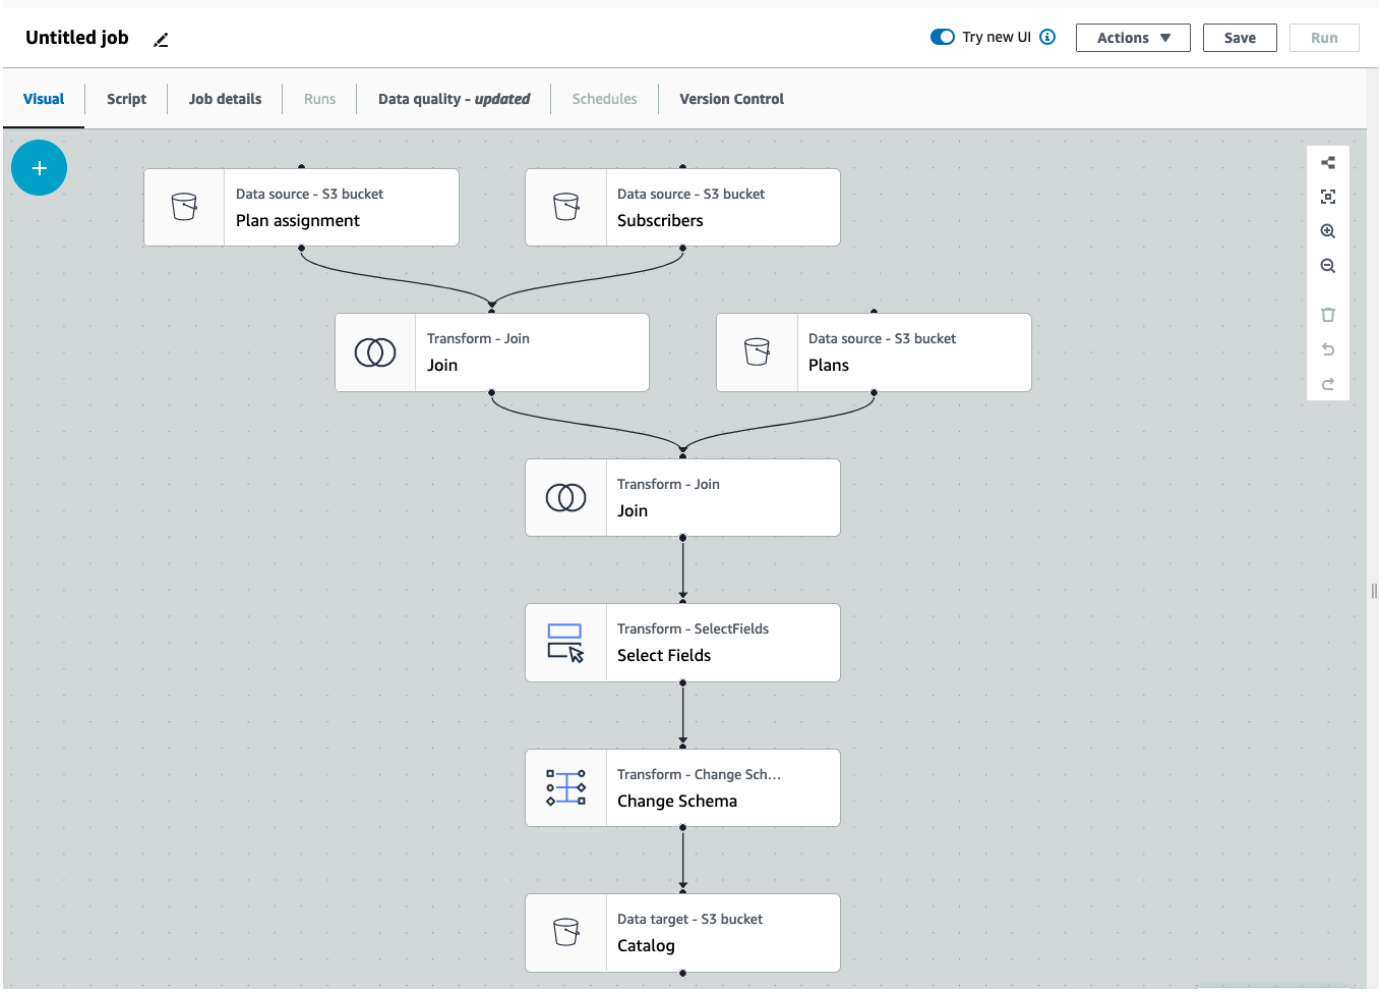

2. Seleccione el nodo que desee quitar. El lienzo hará un acercamiento al nodo. En la barra de herramientas del lado derecho del lienzo, seleccione el ícono Papelera. Así se quitará el nodo y cualquier nodo conectado a ese nodo ocupará su lugar en el flujo de trabajo. En este ejemplo, se eliminó el primer nodo Unión del lienzo.

   Si se elimina un nodo del flujo de trabajo, AWS Glue reorganizará los nodos para que su organización no resulte en un flujo de trabajo no válido. Es posible que necesite corregir la configuración del nodo.

   En el ejemplo, se quitó el nodo Unión que se encontraba debajo del nodo Suscriptores. Como resultado, el nodo de origen Planes se movió al nivel superior y sigue conectado al nodo secundario Unión. El nodo Unión ahora necesita configuración adicional, ya que Unión requiere dos nodos de origen principales con las tablas seleccionadas. En la pestaña Transformar, que se encuentra en el lado derecho del lienzo, se muestran los requisitos que faltan en Condiciones de unión.

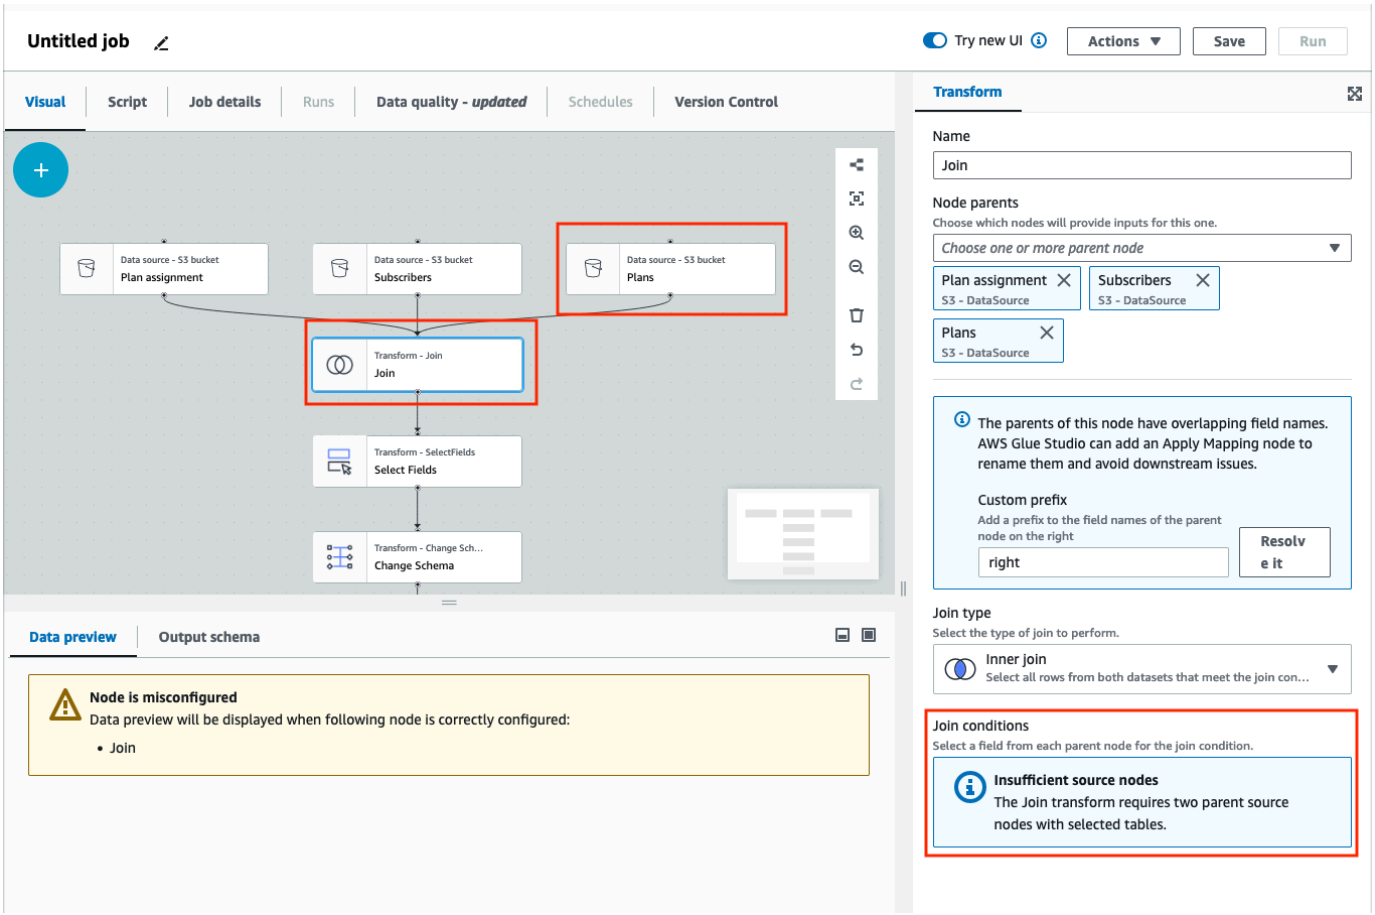

3. Elimine el segundo nodo Unión y el nodo Seleccionar campos. Al eliminar estos nodos, el flujo de trabajo se verá como se muestra a continuación.

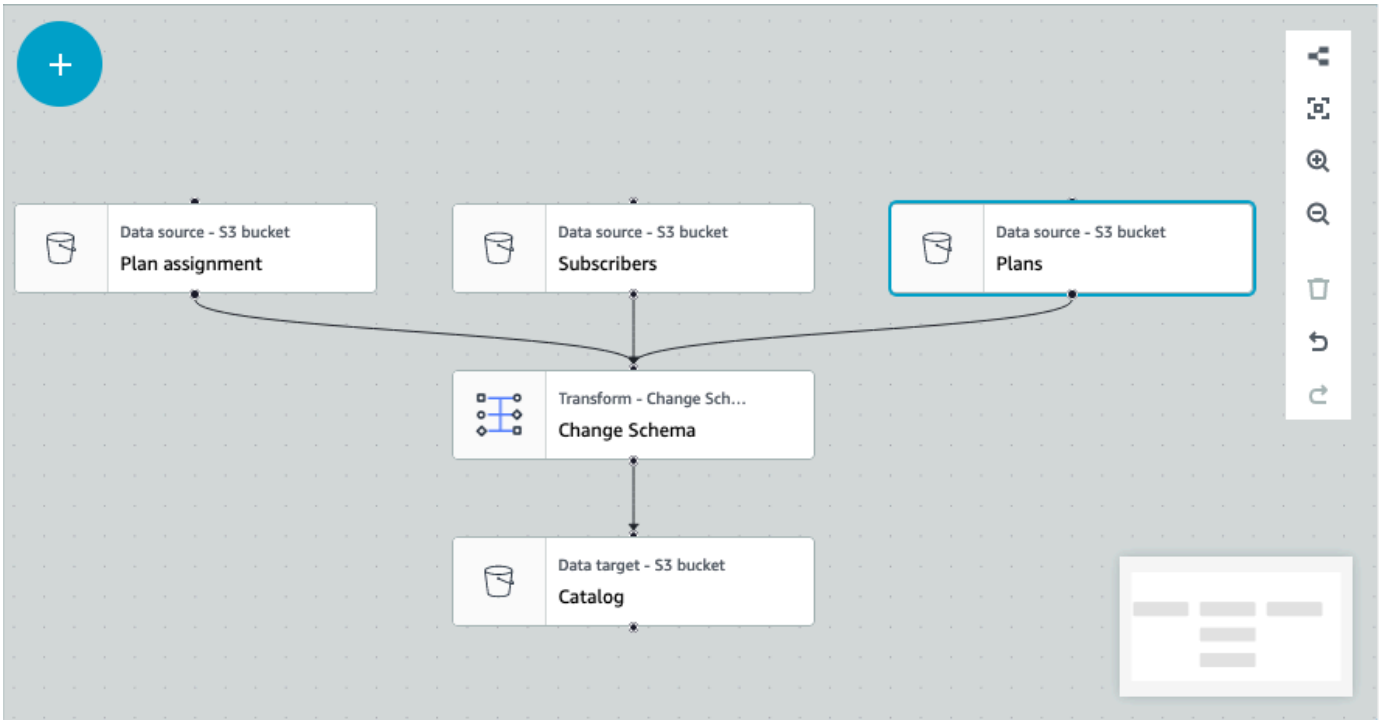

4. Para modificar las conexiones de los nodos, haga clic en el controlador del nodo y arrastre la conexión a un nodo nuevo. Esto le permitirá eliminar los nodos y reorganizar los nodos en un flujo lógico. En el ejemplo, la flecha roja indica cómo crear una nueva conexión al hacer clic en el controlador del nodo Planes y arrastrar la conexión al nodo Unión.

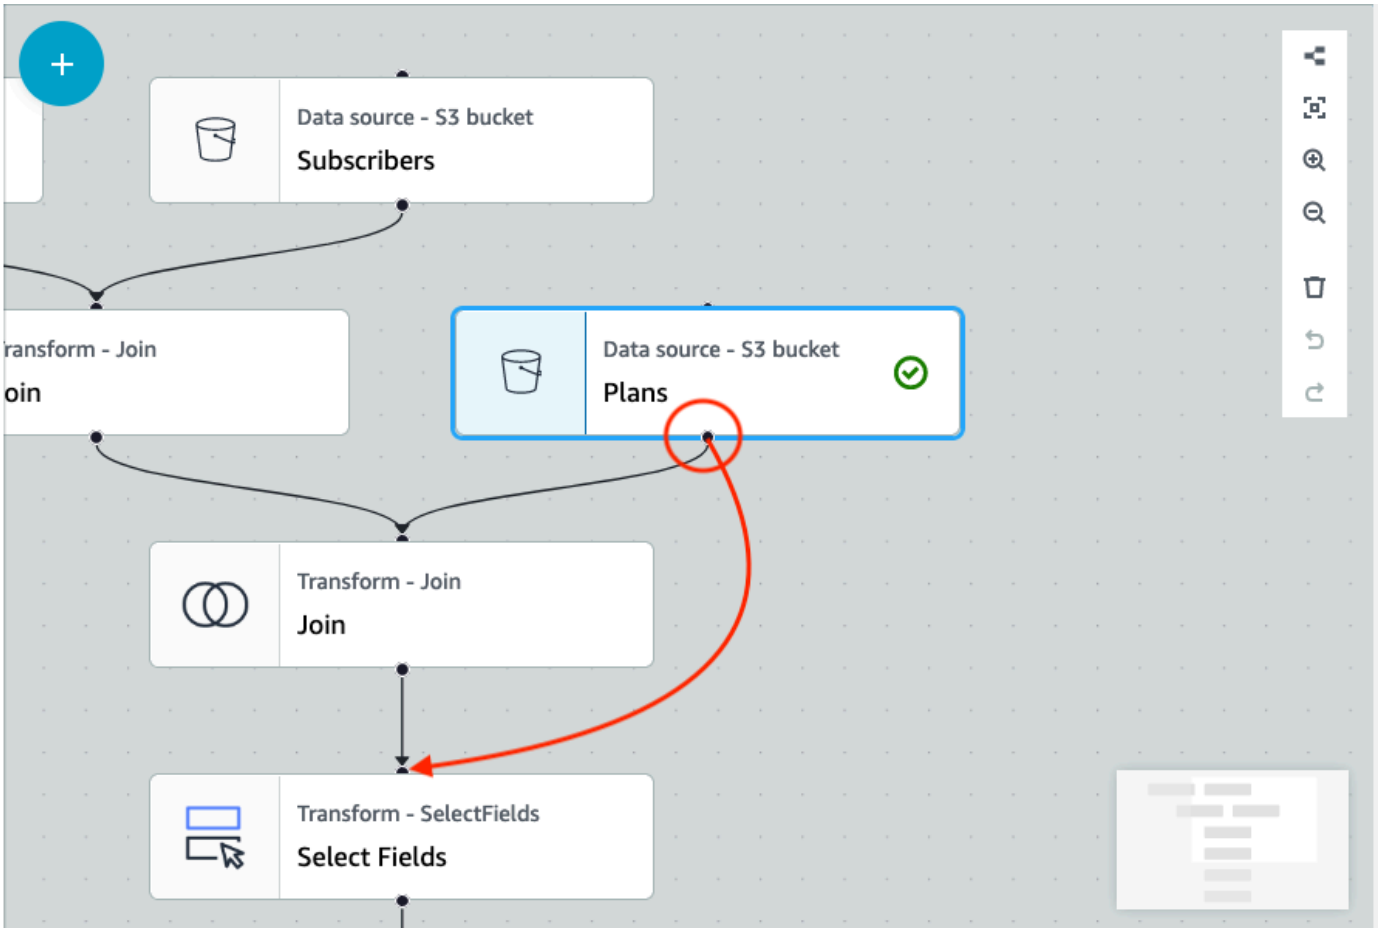

5. Si necesita deshacer alguna acción, seleccione el ícono Deshacer justo por debajo del ícono Papelera en la barra de herramientas que se encuentra en el costado derecho del lienzo.

Añadir parámetros de origen y destino al nodo AWS Glue del Catálogo de datos

AWS Glue Studio permite parametrizar trabajos visuales. Dado que los nombres de las tablas de catálogo en el entorno de producción y desarrollo pueden ser diferentes, puede definir y seleccionar los parámetros de tiempo de ejecución para las bases de datos y tablas que se ejecutarán cuando se ejecute el trabajo.

La parametrización del trabajo permite parametrizar los orígenes y destinos, y guardar esos parámetros en el trabajo cuando se utiliza el nodo AWS Glue del Catálogo de datos. Al especificar los orígenes y destinos como parámetros, se habilita la reutilización de los trabajos, especialmente cuando se utiliza el mismo trabajo en varios entornos. Esto es útil para promover el código en los entornos de implementación, ya que le ahorra tiempo y esfuerzo en la administración de los orígenes

y destinos. Además, los parámetros personalizados que especifique anularán cualquier argumento predeterminado para ejecuciones específicas de trabajos de AWS Glue.

Para añadir parámetros de origen y destino

Aunque use el nodo AWS Glue del Catálogo de datos como origen o destino, igualmente puede definir los parámetros de tiempo de ejecución en la sección Propiedades avanzadas en la pestaña Detalles del trabajo.

1. Elija el nodo AWS Glue del Catálogo de datos como nodo de origen o nodo de destino.
2. Elija la pestaña Detalles del trabajo.
3. Elija Propiedades avanzadas.
4. En la sección Parámetros del trabajo, introduzca un valor clave. Por ejemplo, `--db.source` sería el parámetro de un origen de base de datos. Puede introducir cualquier nombre para la clave, siempre y cuando el nombre de esta vaya seguido de un "guión".

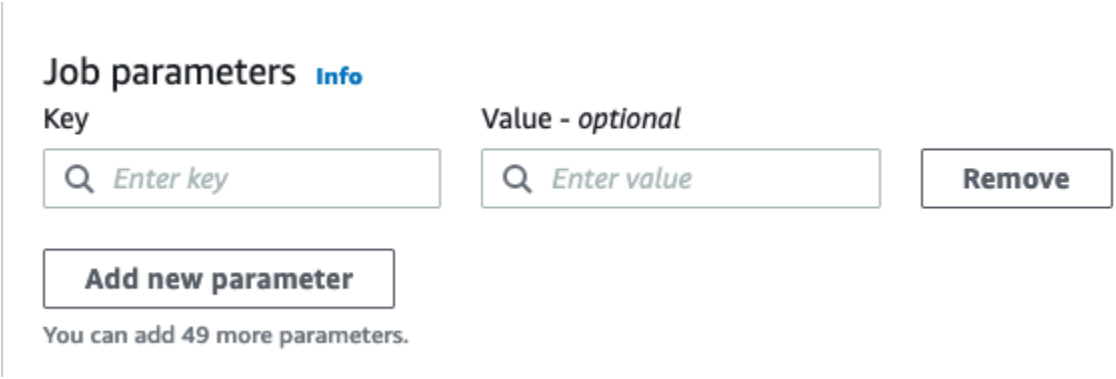

5. Especifique el valor. Por ejemplo, `databasename` sería el valor de la base de datos que se parametriza.
6. Elija Agregar parámetro si quiere agregar más parámetros. Se permite un máximo de 50 parámetros. Una vez definido el par de valor clave, puede utilizar el parámetro en el nodo del Catálogo de datos de AWS Glue.

Para seleccionar un parámetro de tiempo de ejecución

> **Note**
>
> El proceso de selección de los parámetros de ejecución para las bases de datos y tablas es el mismo tanto si el nodo AWS Glue del Catálogo de datos es el origen como el destino.

1. Elija el nodo AWS Glue del Catálogo de datos como nodo de origen o nodo de destino.
2. En la pestaña Propiedades del origen de datos - Catálogo de datos, en Base de datos, seleccione Utilizar parámetros en tiempo de ejecución.

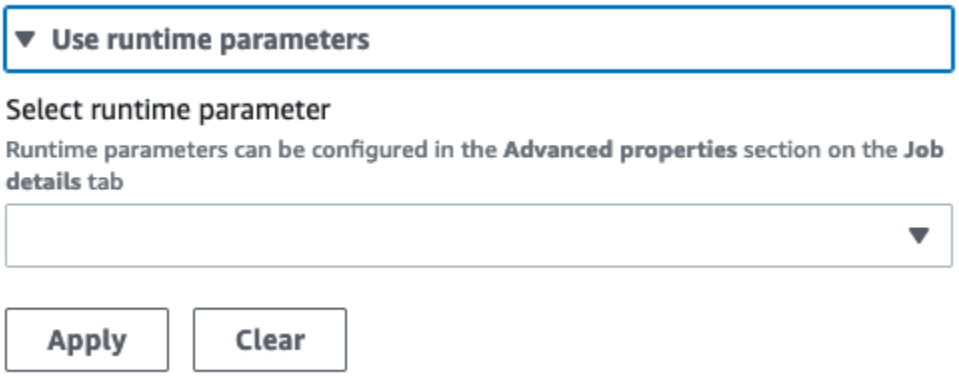

3. Elija un parámetro en el menú desplegable. Por ejemplo, cuando seleccione un parámetro definido para una base de datos de origen, la base de datos aparecerá automáticamente en el menú desplegable de la base de datos cuando seleccione Aplicar.
4. En la sección Tabla, elija un parámetro que ya haya definido como tabla de origen. Cuando elige Aplicar, la tabla se rellena automáticamente como la tabla que se va a utilizar.
5. Cuando guarde y ejecute el trabajo, AWS Glue Studio hará referencia a los parámetros seleccionados durante la ejecución del trabajo.

Uso de los sistemas de control de versiones de Git en AWS Glue

> **Note**
>
> Los cuadernos actualmente no son compatibles con el control de versiones en AWS Glue Studio. Sin embargo, el control de versiones es compatible con los scripts de trabajo y trabajos de ETL visuales en AWS Glue.

Si tiene repositorios remotos y quiere administrar los trabajos de AWS Glue mediante sus repositorios, puede usar AWS Glue Studio o AWS CLI para sincronizar los cambios en los repositorios y trabajos en AWS Glue. Cuando sincroniza los cambios de esta manera, llevará el trabajo desde AWS Glue Studio al repositorio o lo extraerá del repositorio a AWS Glue Studio.

Con la integración de Git en AWS Glue Studio, puede:

- Se integra con los sistemas de control de versiones de Git como AWS CodeCommit, GitHub, GitLab y Bitbucket
- Edite trabajos de AWS Glue en AWS Glue Studio si usa trabajos visuales o trabajos de script y los sincroniza con un repositorio
- Parametrice los orígenes y objetivos en los trabajos
- Extraiga trabajos de un repositorio y edítelos en AWS Glue Studio
- Pruebe los trabajos extrayéndolos de las sucursales o enviándolos a estas mediante los flujos de trabajo de varias sucursales en AWS Glue Studio
- Descargue archivos de un repositorio y suba trabajos a AWS Glue Studio para la creación de trabajo entre cuentas
- Utilice la herramienta de automatización de su elección (por ejemplo, Jenkins, AWS CodeDeploy, etc.)

En este video, se muestra cómo puede integrar AWS Glue con Git y crear una canalización de código continua y colaborativa.

Permisos de IAM

Asegúrese de que el trabajo tenga uno de los siguientes permisos de IAM. Para más información sobre cómo configurar los permisos de IAM, consulte Configurar permisos de IAM para AWS Glue Studio.

- `AWSGlueServiceRole`
- `AWSGlueConsoleFullAccess`

Como mínimo, se necesitan las siguientes acciones para la integración de Git:

- `glue:UpdateJobFromSourceControl`: para poder actualizar AWS Glue con un trabajo presente en un sistema de control de versiones
- `glue:UpdateSourceControlFromJob`: para poder actualizar el sistema de control de versiones con un trabajo almacenado en AWS Glue
- `s3:GetObject`: para poder recuperar el script del trabajo mientras se pasa al sistema de control de versiones
- `s3:PutObject`: para poder actualizar el script al extraer un trabajo desde un sistema de control de código de origen

Requisitos previos

Para enviar los trabajos a un repositorio de control de código fuente, necesitará:

- un repositorio que ya haya sido creado por su administrador
- una rama del repositorio
- un token de acceso personal (en el caso de Bitbucket, se trata del token de acceso al repositorio)
- nombre de usuario del propietario del repositorio
- establecer permisos en el repositorio para que AWS Glue Studio pueda leer y escribir en el repositorio
  - GitLab: configure el alcance del token en api, read_repository y write_repository
  - Bitbucket: establezca los permisos para:
    - Pertenencia al espacio de trabajo: leer y escribir
    - Proyectos: escribir, administrador, leer
    - Repositorios: leer, escribir, administrador, eliminar

> **Note**
>
> Cuando se utiliza AWS CodeCommit, no se necesita el token de acceso personal ni el propietario del repositorio. Consulte Introducción a Git y AWS CodeCommit.

Uso de trabajos del repositorio de control de código de origen en AWS Glue Studio

Para extraer un trabajo del repositorio de control de código de origen que no se encuentra en AWS Glue Studio y que usa ese trabajo en AWS Glue Studio, los requisitos previos dependerán del tipo de trabajo.

Para un trabajo visual:

- necesita una carpeta y un archivo JSON de la definición del trabajo que coincida con el nombre del trabajo

  Por ejemplo, consulte la definición de trabajo a continuación. La rama del repositorio debe contener una ruta `my-visual-job/my-visual-job.json` donde tanto la carpeta como el archivo JSON coincidan con el nombre del trabajo

```
{
  "name" : "my-visual-job",
  "description" : "",
  "role" : "arn:aws:iam::aws_account_id:role/Rolename",
  "command" : {
    "name" : "glueetl",
    "scriptLocation" : "s3://foldername/scripts/my-visual-job.py",
    "pythonVersion" : "3"
  },
  "codeGenConfigurationNodes" : "{\"node-nodeID\":{\"S3CsvSource\":
{\"AdditionalOptions\":{\"EnableSamplePath\":false,\"SamplePath\":\"s3://notebook-
test-input/netflix_titles.csv\"},\"Escaper\":\"\",\"Exclusions\":[],\"Name\":\"Amazon
 S3\",\"OptimizePerformance\":false,\"OutputSchemas\":[{\"Columns\":[{\"Name\":
\"show_id\",\"Type\":\"string\"},{\"Name\":\"type\",\"Type\":\"string\"},{\"Name\":
\"title\",\"Type\":\"choice\"},{\"Name\":\"director\",\"Type\":\"string\"},{\"Name\":
\"cast\",\"Type\":\"string\"},{\"Name\":\"country\",\"Type\":\"string\"},{\"Name\":
\"date_added\",\"Type\":\"string\"},{\"Name\":\"release_year\",\"Type\":\"bigint\"},
{\"Name\":\"rating\",\"Type\":\"string\"},{\"Name\":\"duration\",\"Type\":\"string
\"},{\"Name\":\"listed_in\",\"Type\":\"string\"},{\"Name\":\"description\",\"Type
\":\"string\"}]}],\"Paths\":[\"s3://dalamgir-notebook-test-input/netflix_titles.csv
\"],\"QuoteChar\":\"quote\",\"Recurse\":true,\"Separator\":\"comma\",\"WithHeader
\":true}}}"
}
```

Para un trabajo de script:

- necesita una carpeta, un archivo JSON de la definición del trabajo y el script
- la carpeta y el archivo JSON deben coincidir con el nombre del trabajo. El nombre del script debe coincidir con el valor de `scriptLocation` en la definición del trabajo junto con la extensión del archivo

  Por ejemplo, en la definición de trabajo que aparece a continuación, la rama del repositorio debe contener una ruta `my-script-job/my-script-job.json` y `my-script-job/my-script-job.py`. El nombre del script debe coincidir con el nombre que aparece en el valor `scriptLocation`, incluida la extensión del script

```
{
  "name" : "my-script-job",
  "description" : "",
```

```
  "role" : "arn:aws:iam::aws_account_id:role/Rolename",
  "command" : {
    "name" : "glueetl",
    "scriptLocation" : "s3://foldername/scripts/my-script-job.py",
    "pythonVersion" : "3"
  }
}
```

Limitaciones

- En la actualidad, AWS Glue no es compatible con las extracciones ni los envíos a GitLab-Groups.

Conectar repositorios de control de versiones con AWS Glue

Puede introducir los detalles de su repositorio de control de versiones y administrarlos en la pestaña Control de versiones en el editor de trabajo de AWS Glue Studio. Para integrarlo con su repositorio de Git, debe conectarse al repositorio cada vez que inicie sesión en AWS Glue Studio.

Para conectar un sistema de control de versiones de Git:

1. En AWS Glue Studio, comience un nuevo trabajo y elija la pestaña Control de versiones.

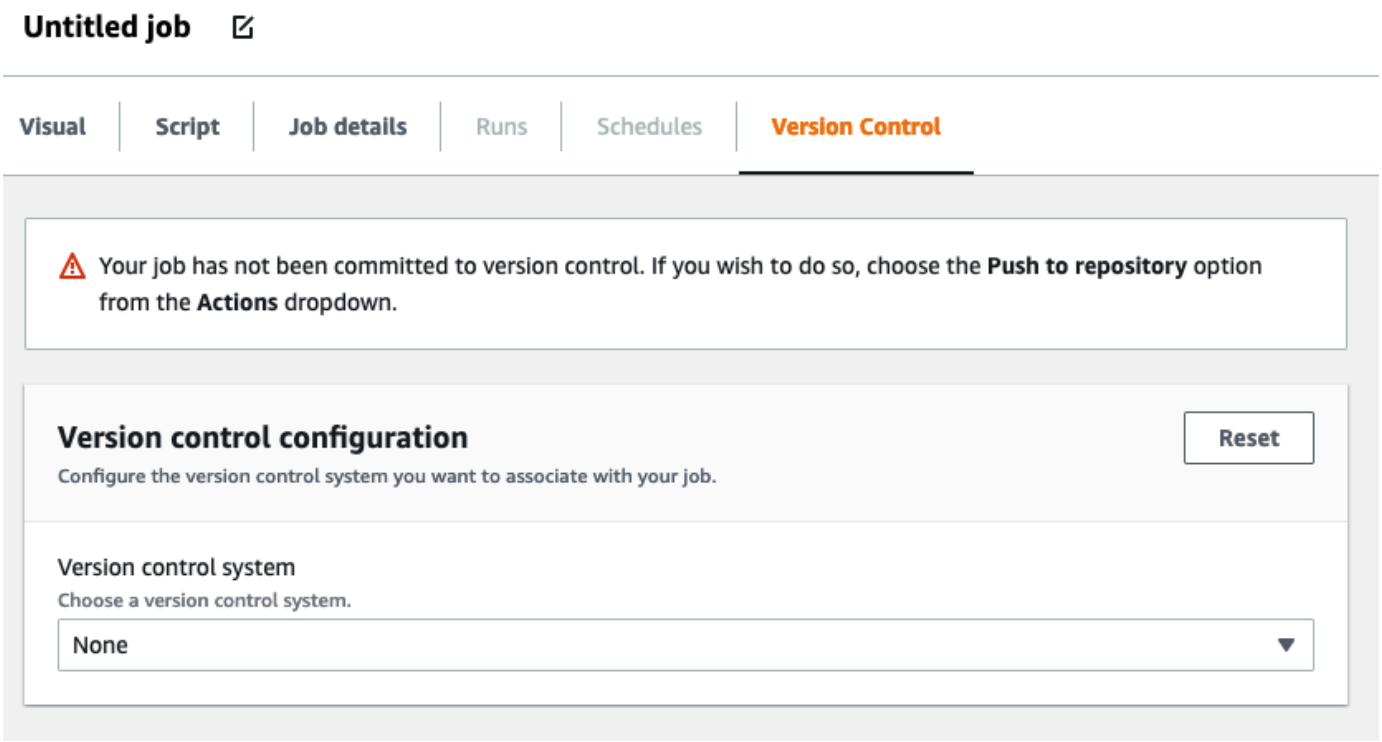

2. En el Sistema de control de versiones, elija el servicio Git entre las opciones disponibles mediante un clic en el menú desplegable.

   - AWS CodeCommit
   - GitHub
   - GitLab
   - Bitbucket

3. En función del sistema de control de versiones Git que elija, tendrá que completar diferentes campos.

   Para AWS CodeCommit:

   Complete la configuración del repositorio seleccionando el repositorio y la rama para su trabajo:

   - Repositorio: si ha configurado repositorios en AWS CodeCommit, seleccione el repositorio en el menú desplegable. Los repositorios se rellenarán automáticamente en la lista
   - Rama: seleccione la rama en el menú desplegable
   - Carpeta: opcional: escriba el nombre de la carpeta en la que quiere guardar el trabajo. Si se deja vacía, se crea automáticamente una carpeta. El nombre de la carpeta es el nombre del trabajo de forma predeterminada.

   Para GitHub:

   Complete la configuración de GitHub con los campos:

   - Token de acceso: este es el token que proporciona el repositorio de GitHub. Para más información sobre los tokens de acceso personal, consulte Documentos de GitHub
   - Propietario del repositorio: es el propietario del repositorio de GitHub.

   Complete la configuración del repositorio con la selección de este y la rama de GitHub.

   - Repositorio: si ha configurado repositorios en GitHub, seleccione el repositorio en el menú desplegable. Los repositorios se rellenarán automáticamente en la lista
   - Rama: seleccione la rama en el menú desplegable

- Carpeta: opcional: escriba el nombre de la carpeta en la que quiere guardar el trabajo. Si se deja vacía, se crea automáticamente una carpeta. El nombre de la carpeta es el nombre del trabajo de forma predeterminada.

Para GitLab:

> **Note**
>
> En la actualidad, AWS Glue no es compatible con las extracciones ni los envíos a GitLab-Groups.

- Token de acceso: este es el token que proporciona el repositorio de GitLab. Para más información sobre los tokens de acceso personal, consulte Tokens de acceso personal de GitLab
- Propietario del repositorio: es el propietario del repositorio de GitLab.

Complete la configuración del repositorio con la selección de este y la rama de GitLab.

- Repositorio: si ha configurado repositorios en GitLab, seleccione el repositorio en el menú desplegable. Los repositorios se rellenarán automáticamente en la lista
- Rama: seleccione la rama en el menú desplegable
- Carpeta: opcional: escriba el nombre de la carpeta en la que quiere guardar el trabajo. Si se deja vacía, se crea automáticamente una carpeta. El nombre de la carpeta es el nombre del trabajo de forma predeterminada.

Para Bitbucket:

- Contraseña de la aplicación: Bitbucket no utiliza tokens de acceso a repositorios, sino contraseñas de aplicaciones. Para obtener más información sobre las contraseñas de aplicaciones, consulte Contraseñas de aplicaciones.
- Propietario del repositorio: es el propietario del repositorio de Bitbucket. En Bitbucket, el propietario es el creador del repositorio.

Seleccione el espacio de trabajo, el repositorio, la rama y la carpeta desde Bitbucket para completar la configuración del repositorio.

- Espacio de trabajo: si tiene espacios de trabajo configurados en Bitbucket, seleccione el espacio de trabajo en el menú desplegable. Los espacios de trabajo se rellenan automáticamente
- Repositorio: si ha configurado repositorios en Bitbucket, seleccione el repositorio en el menú desplegable. Los repositorios se rellenan automáticamente
- Rama: seleccione la rama en el menú desplegable. Las ramas se rellenan automáticamente
- Carpeta: opcional: escriba el nombre de la carpeta en la que quiere guardar el trabajo. Si se deja vacío, se creará automáticamente una carpeta con el nombre del trabajo.

4. Seleccione Guardar en la parte superior del trabajo de AWS Glue Studio

Envío de trabajos de AWS Glue al repositorio de origen

Una vez que haya introducido los detalles de su sistema de control de versiones, puede editar los trabajos en AWS Glue Studio y empujar los trabajos a su repositorio de origen. Si no está familiarizado con los conceptos de Git, como empujar y tirar, consulta este tutorial sobre Introducción a Git y AWS CodeCommit.

Para enviar su trabajo a un repositorio, debe introducir los detalles de su sistema de control de versiones y guardar el trabajo.

1. En el trabajo AWS Glue Studio, elija Acciones. Esto abrirá opciones de menú adicionales.

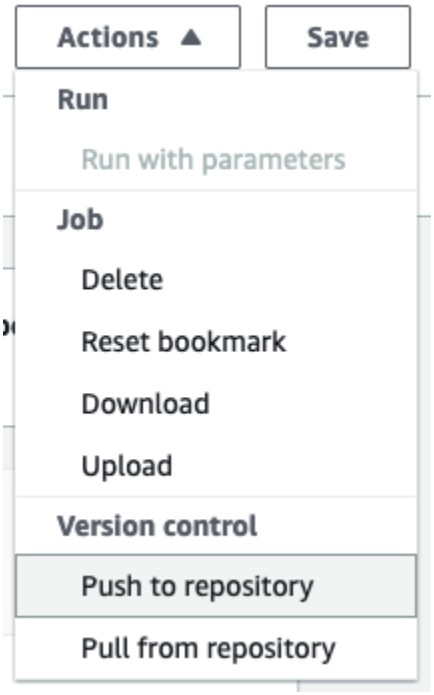

2. Elija Insertar en el repositorio.

   Esta acción guardará el trabajo. Cuando se pasa al repositorio, AWS Glue Studio empuja el último cambio guardado. Si el mismo usuario u otro usuario modificó el trabajo en el repositorio y no está sincronizado con el trabajo en AWS Glue Studio, el trabajo del repositorio se sobrescribe con el trabajo guardado en AWS Glue Studio cuando se empuja el trabajo desde AWS Glue Studio.

3. Elija Confirmar para completar la acción. Esto crea una nueva confirmación en el repositorio. Si está utilizando AWS CodeCommit, un mensaje de confirmación mostrará un enlace a la última confirmación en AWS CodeCommit.

Sacar trabajos de AWS Glue del repositorio de origen

Una vez que haya introducido los detalles de su repositorio de Git en la pestaña Control de versiones, también puede extraer trabajos de su repositorio y editarlos en AWS Glue Studio.

1. En el trabajo de AWS Glue Studio, elija Acciones. Esto abrirá opciones de menú adicionales.

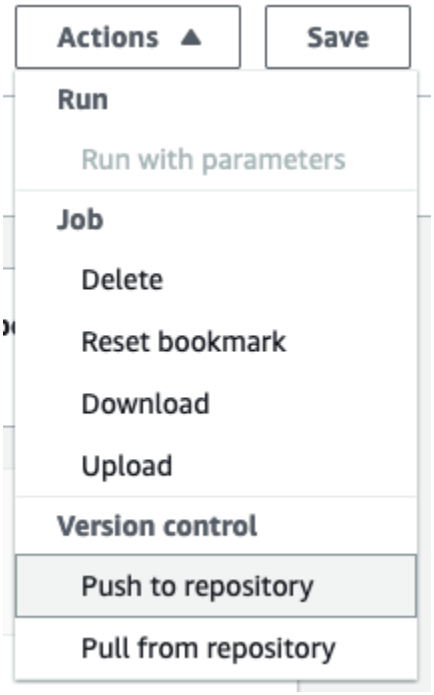

2. Elija Extraer del repositorio.
3. Elija Confirmar. Esto toma la confirmación más reciente del repositorio y actualiza el trabajo en AWS Glue Studio.
4. Edite su trabajo en AWS Glue Studio. Si realiza cambios, puede sincronizar su trabajo con el repositorio al elegir Insertar en el repositorio desde el menú desplegable Acciones.

Creación de código con cuadernos de AWS Glue Studio

Los ingenieros de datos pueden crear trabajos de AWS Glue de forma más rápida y sencilla que antes mediante el uso de la interfaz de cuaderno interactiva en AWS Glue Studio o sesiones interactivas en AWS Glue.

Limitaciones

- Los cuadernos de AWS Glue Studio no son compatibles con Scala.

Temas

- Información general sobre el uso de cuaderno
- Creación de un trabajo de ETL mediante cuaderno en AWS Glue Studio
- Componentes del editor de cuaderno

- Cómo guardar el cuaderno y el script de trabajo
- Administración de las sesiones de cuaderno
- Uso de Amazon Q Developer con libretas AWS Glue Studio

Información general sobre el uso de cuaderno

AWS Glue Studio permite crear trabajos de forma interactiva en una interfaz de cuaderno basada en cuadernos de Jupyter. A través de los cuaderno en AWS Glue Studio, es posible editar scripts de trabajos y el código de integración de datos y ver el resultado sin que sea necesario ejecutar un trabajo completo. También es posible agregar un marcado y guardar cuaderno como archivos .ipynb y scripts de trabajo. Puede iniciar un cuaderno sin instalar software en forma local ni administrar servidores. Una vez que esté satisfecho con el código, AWS Glue Studio puede convertir el cuaderno en un trabajo de Glue con solo hacer clic en un botón.

Algunos de los beneficios de utilizar cuaderno son:

- No hay clúster que aprovisionar o administrar
- No hay que pagar por clústeres inactivos
- No se requiere una configuración inicial
- No se requiere instalación de cuadernos de Jupyter
- Mismo tiempo de ejecución y plataforma que ETL de AWS Glue

Al iniciar un cuaderno a través de AWS Glue Studio, todos los pasos de configuración ya han sido completados para que, apenas después de unos segundos, pueda explorar los datos y comenzar a desarrollar el script de trabajo. AWS Glue Studio configura un cuaderno de Jupyter con el kernel de Jupyter de AWS Glue. No es necesario configurar VPC, conexiones de red ni puntos de conexión de desarrollo para utilizar este cuaderno.

Para crear trabajos mediante la interfaz de cuaderno:

- Configure los permisos de IAM necesarios.
- Inicie una sesión de cuaderno para crear un trabajo.
- Escriba código en las celdas en el cuaderno.
- Ejecute y pruebe el código para ver el resultado.
- Guarde el trabajo.

Una vez guardado, el cuaderno es un trabajo completo de AWS Glue. Puede administrar todos los aspectos del trabajo, tales como la programación de ejecuciones de trabajos, la configuración de parámetros del trabajo y la visualización del historial de ejecuciones de trabajos justo al lado del cuaderno.

Creación de un trabajo de ETL mediante cuaderno en AWS Glue Studio

Para empezar a utilizar los cuaderno en la consola de AWS Glue Studio

1. Adjunte políticas de AWS Identity and Access Management al usuario de AWS Glue Studio y cree un rol de IAM para el trabajo y cuaderno de ETL.
2. Configure una seguridad adicional de IAM para cuadernos, como se describe en Concesión de permisos para el rol de IAM.
3. Abra la consola de AWS Glue Studio en https://console.aws.amazon.com/gluestudio/.

   > **Note**
   >
   > Compruebe que el navegador no bloquea las cookies de terceros. Cualquier navegador que bloquee las cookies de terceros, ya sea de manera predeterminada o porque el usuario lo haya configurado así, impedirá que se inicien los cuadernos. Para obtener más información sobre cómo administrar las cookies, consulte:

   - Chrome
   - Firefox
   - Safari
4. Elija el icono Jobs (Trabajos) en el menú de navegación de la izquierda.
5. Elija Jupyter notebook (Cuaderno de Jupyter) y, luego, elija Create (Crear) para iniciar una nueva sesión de cuaderno.
6. En la página Create job in Jupyter notebook (Crear trabajo en cuaderno de Jupyter), proporcione el nombre del trabajo y elija qué rol de IAM desea utilizar. Seleccione Crear tarea.

   Tras un breve momento, aparece el editor de cuaderno.
7. Después de agregar el código, debe ejecutar la celda para iniciar una sesión. La celda se puede ejecutar de varias formas:

   - Pulse el botón de reproducción.

- Use un método abreviado de teclado:
  - En MacOS, Command (Comando) + Enter (Intro) para ejecutar la celda.
  - En Windows, Shift + Enter (Intro) para ejecutar la celda.

  Para obtener información sobre cómo escribir código mediante una interfaz de cuaderno de Jupyter, consulte The Jupyter Notebook User Documentation (Documentación del usuario de cuaderno de Jupyter).

8. Para probar el script, ejecute el script completo o celdas individuales. Cualquier salida de comando se mostrará en el área situada debajo de la celda.
9. Una vez que haya terminado de desarrollar el cuaderno, puede guardar el trabajo y luego ejecutarlo. Encontrará el script en la pestaña Script. Cualquier comando mágico que haya agregado al cuaderno se eliminará y no se guardará como parte del script del trabajo de AWS Glue generado. AWS Glue Studio agregará automáticamente un `job.commit()` al final del script generado desde el contenido del cuaderno.

   Para obtener más información sobre cómo ejecutar un trabajo, consulte Iniciar una ejecución de trabajo.

Componentes del editor de cuaderno

La interfaz del editor de cuaderno tiene las siguientes secciones principales.

- Interfaz de cuaderno (panel principal) y barra de herramientas
- Pestañas de edición de trabajo

Editor de cuaderno

El editor de cuaderno de AWS Glue Studio se basa en la aplicación de cuaderno de Jupyter. La interfaz de cuaderno de AWS Glue Studio es similar a la provista por Bloc de notas de Jupyter, la cual se describe en la sección Notebook user interface (Interfaz de usuario de cuaderno). El cuaderno utilizado por las sesiones interactivas es un cuaderno de Jupyter.

Aunque el cuaderno de AWS Glue Studio es similar a cuaderno de Jupyter, difiere en algunos aspectos clave:

- en la actualidad, el cuaderno de AWS Glue Studio no puede instalar extensiones
- no se pueden utilizar varias pestañas; existe una relación 1:1 entre un trabajo y un cuaderno
- el cuaderno de AWS Glue Studio no tiene el mismo menú de archivos principales que existe en los cuadernos de Jupyter
- actualmente, el cuaderno de AWS Glue Studio solo se ejecuta con el kernel de AWS Glue. Tenga en cuenta que no puede actualizar el kernel por su cuenta.

pestañas de edición de trabajo de AWS Glue Studio

Las pestañas que utiliza para interactuar con el trabajo de ETL se encuentran en la parte superior de la página del cuaderno. Son similares a las pestañas que aparecen en el editor visual de trabajos de AWS Glue Studio y realizan las mismas acciones.

- Notebook (Cuaderno): utilice esta pestaña para ver el script de trabajo mediante la interfaz del cuaderno.
- Job details (Detalles del trabajo): configure el entorno y las propiedades de las ejecuciones de trabajos.
- Runs (Ejecuciones): permite ver información sobre las ejecuciones anteriores de este trabajo.
- Schedules (Cronograma): configure un cronograma para ejecutar su trabajo en momentos específicos.

Cómo guardar el cuaderno y el script de trabajo

Puede guardar el cuaderno y el script de trabajo que esté creando en cualquier momento. Simplemente elija el botón Save (Guardar) en la esquina superior derecha, igual que si estuviera en el editor visual o de script.

Cuando elige Save (Guardar), el archivo de cuaderno se guarda en las ubicaciones predeterminadas:

- De forma predeterminada, el script de trabajo se guarda en la ubicación de Amazon S3 indicada en la pestaña Job Details (Detalles del trabajo), en Advanced properties (Propiedades avanzadas), en la propiedad de detalles del trabajo Script path (Ruta de script). Los scripts de trabajo se guardan en una subcarpeta llamada `Scripts`.
- De forma predeterminada, el archivo de cuaderno (`.ipynb`) se guarda en la ubicación de Amazon S3 indicada en la pestaña Job Details (Detalles del trabajo), en Advanced Properties (Propiedades

avanzadas), en Script path (Ruta de script) en los detalles del trabajo. Los archivos del cuaderno se guardan en una subcarpeta llamada`Notebooks`.

> **Note**
>
> Al guardar el trabajo, el script de trabajo contiene solo las celdas de código del cuaderno. Las celdas y las magias de Markdown no se incluyen en el script de trabajo. Sin embargo, el archivo `.ipynb` contendrá cualquier markdown y magia.

Después de guardar el trabajo, puede ejecutarlo mediante el script que creó en el cuaderno.

Administración de las sesiones de cuaderno

Los cuaderno en AWS Glue Studio se basan en la característica de sesiones interactivas de AWS Glue. El uso de sesiones interactivas conlleva un costo. Para ayudar a administrar los costos, puede monitorear las sesiones creadas para su cuenta y ajustar la configuración predeterminada de todas las sesiones.

Cambio del tiempo de espera predeterminado de todas las sesiones de cuaderno

De manera predeterminada, el cuaderno de AWS Glue Studio aprovisionado agota el tiempo de espera al cabo de 12 horas si se inicia y no se ejecuta ninguna celda. No lleva asociado ningún coste y el tiempo de espera no se puede configurar.

Una vez que se ejecuta una celda, se inicia una sesión interactiva. Esta sesión tiene un tiempo de espera predeterminado de 48 horas. Este tiempo de espera se puede configurar ejecutando un comando mágico `%idle_timeout` antes de ejecutar una celda.

Para modificar el tiempo de espera de sesión predeterminado para los cuaderno en AWS Glue Studio

1. En el cuaderno, ingrese el comando mágico `%idle_timeout` en una celda y especifique el valor de tiempo de espera en minutos.
2. Por ejemplo: `%idle_timeout 15` cambiará el tiempo de espera predeterminado a 15 minutos. Si la sesión no se utiliza en 15 minutos, se detiene automáticamente.

Instalación de módulos adicionales de Python

Si desea instalar módulos adicionales a su sesión mediante pip, puede hacerlo con `%additional_python_modules` para agregarlos a la sesión:

```
%additional_python_modules awswrangler, s3://amzn-s3-demo-bucket/mymodule.whl
```

Todos los argumentos para additional_python_modules se pasan a `pip3 install -m <>`.

Para ver la lista de los módulos de Python disponibles, consulte Uso de bibliotecas Python con AWS Glue.

Cambio de la configuración de AWS Glue

Se pueden utilizar comandos mágicos para controlar los valores de configuración de los trabajos de AWS Glue. Si desea cambiar el valor de configuración de un trabajo, debe utilizar el comando mágico adecuado en el cuaderno. Consulte Comandos mágicos compatibles con las sesiones interactivas de AWS Glue para Jupyter.

> **Note**
>
> Ya no está disponible la función de anular las propiedades de una sesión en ejecución. Si desea cambiar las configuraciones de la sesión, debe detenerla, establecer las nuevas configuraciones y, a continuación, iniciar una nueva sesión.

AWS Glue admite varios tipos de empleados. Puede configurar el tipo de empleado con `%worker_type`. Por ejemplo: `%worker_type G.2X` . Los tipos de trabajadores disponibles son G.1X, G.2X, G.4X, G.8X, G.12X, G.16X, R.1X, R.2X, R.4X y R.8X. El valor predeterminado es G.1X.

También puede especificar el número de empleados con `%number_of_workers`. Por ejemplo, para especificar 40 empleados: `%number_of_workers 40`.

Para obtener más información, consulte Defining Job Properties (Definición de las propiedades del trabajo).

Cómo detener una sesión de cuaderno

Para detener una sesión de cuaderno, utilice el comando mágico `%stop_session`.

Si se aleja del cuaderno en la consola de AWS, recibirá un mensaje de advertencia en el que podrá elegir detener la sesión.

Uso de Amazon Q Developer con libretas AWS Glue Studio

AWS Glue Studio permite crear trabajos de forma interactiva en una interfaz de cuaderno basada en cuadernos de Jupyter. El uso de Amazon Q Developer mejora la experiencia de creación en los cuadernos de AWS Glue Studio.

La extensión Amazon Q Developer permite escribir código al generar recomendaciones de código y sugerir mejoras relacionadas con los problemas de código. Amazon Q Developer es compatible con Python y Scala, los dos lenguajes que se utilizan para codificar scripts de ETL para los trabajos de Spark en cuadernos de AWS Glue Studio.

¿Qué es Amazon Q Developer?

Amazon Q Developer es un servicio basado en machine learning que ayuda a mejorar la productividad de los desarrolladores. Amazon Q Developer logra esto mediante la generación de recomendaciones de código basadas en los comentarios de los desarrolladores en lenguaje natural y el código en el IDE. El servicio se integra con JupyterLab, Studio de Amazon SageMaker AI, instancias de cuadernos de Amazon SageMaker AI y otros entornos de desarrollo integrados (IDE).

Para obtener más información, consulte Uso de Amazon Q Developer con AWS Glue Studio.

Estados de ejecución de tareas de AWS Glue en la consola

Puede ver el estado de un trabajo de extracción, transformación y carga (ETL) de AWS Glue mientras se está ejecutando o después de su detención. Puede ver el estado mediante la consola de AWS Glue.

Acceso al panel de monitoreo de trabajos

Para acceder al panel de supervisión de trabajos, seleccione el enlace Supervisión de ejecución de trabajos en el panel de navegación de AWS Glue debajo de Trabajos de ETL.

Información general del panel de monitoreo de trabajos

El panel de monitoreo de trabajos proporciona un resumen general de las ejecuciones de trabajos, con totales para los trabajos con un estado de En ejecución, Cancelado, Éxito o Error. Los mosaicos

adicionales proporcionan la tasa general de éxito de ejecución del trabajo, el uso estimado de DPU para los trabajos, un desglose de los recuentos de estado del trabajo por tipo de trabajo, tipo de empleado y día.

Los gráficos de los mosaicos son interactivos. Puede elegir cualquier bloque de un gráfico para ejecutar un filtro que muestre sólo esos trabajos en la tabla Ejecuciones de trabajo de la parte inferior de la página.

Puede cambiar el intervalo de fechas de la información mostrada en esta página mediante el selector Intervalo de fechas. Al cambiar el intervalo de fechas, los mosaicos de información se ajustan para mostrar los valores según la cantidad especificada de días antes de la fecha actual. También puede utilizar un intervalo de fechas específico si elige Personalizado desde el selector de intervalo de fechas.

Vista de las ejecuciones de trabajo

> **Note**
>
> El historial de ejecución de trabajos está disponible durante 90 días para su flujo de trabajo y ejecución de trabajos.

La lista de recursos Ejecuciones de trabajo muestra los trabajos para el intervalo de fechas especificado y los filtros.

Puede filtrar los trabajos según criterios adicionales, como el estado, el tipo de empleado, el tipo de trabajo y el nombre del trabajo. En el cuadro de filtro situado en la parte superior de la tabla, puede introducir el texto que desea utilizar como filtro. Los resultados de la tabla se actualizan con filas que contienen texto coincidente a medida que se escribe el texto.

Puede ver un subconjunto de los trabajos cuando selecciona elementos de los gráficos del panel de monitoreo de trabajos. Por ejemplo, si elige el número de trabajos en ejecución en el mosaico Resumen de ejecuciones de trabajo, la lista Ejecuciones de trabajo muestra sólo los trabajos que actualmente tienen un estado de `Running`. Si elige una de las barras del gráfico de barras Desglose por tipo de empleado, solo se muestran las ejecuciones de trabajos con el tipo y el estado de empleado coincidentes en la lista Ejecuciones de trabajo.

La lista de recursos Ejecuciones de trabajo muestra los detalles del trabajo. Puede ordenar las filas de la tabla si elige un encabezado de columna. Esta tabla contiene la siguiente información:

Propiedad	Descripción
Nombre de trabajo	El nombre del trabajo.
Tipo	El tipo del entorno de trabajo: • Glue ETL: se ejecuta en un entorno Apache Spark administrado por AWS Glue. • Glue Streaming: se ejecuta en un entorno Apache Spark y realiza ETL en flujos de datos. • Shell de Python: ejecuta scripts de Python como intérprete de comandos.
Hora de inicio	La fecha y la hora en que se inició la ejecución de este flujo de trabajo.
Hora de finalización	La fecha y la hora en que se completó la ejecución de este trabajo.
Estado de ejecución	El estado actual de la ejecución de flujo de trabajo. Los valores pueden ser: • `STARTING` • `RUNNING` • `STOPPING` • `STOPPED` • `SUCCEEDED` • `FAILED` • `TIMEOUT`
Tiempo de ejecución	El periodo de tiempo que la ejecución de flujo de trabajo consumió recursos.
Capacidad	El número de unidades de procesamiento de datos (DPU) de AWS Glue asignadas a esta ejecución de trabajo. Para obtener más

Propiedad	Descripción
	información acerca de la planificación de capacidad, consulte Monitoreo para planificar la capacidad de DPU en la Guía para desarrolladores de AWS Glue.

Propiedad	Descripción
Tipo de empleado	El tipo de empleado predefinido que se asigna cuando se ejecuta un trabajo. Los valores pueden ser `G.1X`, `G.2X`, `G.4X` o `G.8X`. • **`G.1X`**: al elegir este tipo, también debe proporcionar un valor para Número de empleados. Cada trabajador se asigna a 1 DPU (4 vCPU, 16 GB de memoria) con un disco de 84 GB (aproximadamente 34 GB libres). Le recomendamos este tipo de proceso de trabajo para trabajos con un uso intensivo de la memoria. Esta es la opción predeterminada de Tipo de empleado para trabajos de AWS Glue versión 2.0 o posterior . • **`G.2X`**: al elegir este tipo, también debe proporcionar un valor para Number of workers (Número de empleados). Cada trabajador se asigna a 2 DPU (8 vCPU, 32 GB de memoria) con un disco de 128 GB (aproximadamente 77 GB libres). Recomendamos este tipo de empleado para trabajos con una utilización intensiva de la memoria y trabajos que ejecuten transform aciones de machine learning. • **`G.4X`**: al elegir este tipo, también debe proporcionar un valor para Número de empleados. Cada trabajador se asigna a 4 DPU (16 vCPU, 64 GB de memoria) con un disco de 256 GB (aproximadamente 235 GB libres). Recomendamos este tipo de trabajador para los trabajos cuyas cargas de trabajo contengan las transformaciones, agregaciones, uniones y consultas más

Propiedad	Descripción
	exigentes. Este tipo de trabajador solo está disponible para los trabajos de Spark ETL de la versión 3.0 de AWS Glue o posterior es en las siguientes regiones de AWS: Este de EE. UU. (Ohio), Este de EE. UU. (Norte de Virginia), Oeste de EE. UU. (Oregón), Asia Pacífico (Singapur), Asia Pacífico (Sídney), Asia Pacífico (Tokio), Canadá (centro), Europa (Fráncfort), Europa (Irlanda) y Europa (Estocolmo). • **`G.8X`**: al elegir este tipo, también debe proporcionar un valor para Número de empleados. Cada trabajador se asigna a 8 DPU (32 vCPU, 128 GB de memoria) con un disco de 512 GB (aproximadamente 487 GB libres). Recomendamos este tipo de trabajador para los trabajos cuyas cargas de trabajo contengan las transformaciones, agregaciones, uniones y consultas más exigentes. Este tipo de trabajador solo está disponible para los trabajos ETL de Spark de la versión 3.0 de AWS Glue o posteriores, en las mismas regiones de AWS compatibles con el tipo de trabajador `G.4X`.
Horas de DPU	El número estimado de DPU utilizadas para la ejecución de trabajo. Una DPU es una medida relativa de la potencia de procesamiento. Las DPU se utilizan para determinar el costo de ejecutar su trabajo. Para obtener más informaci ón, consulte la página de precios de AWS Glue.

Puede elegir cualquier ejecución de trabajo de la lista y ver información adicional. Elija una ejecución de trabajo y luego realice una de las operaciones siguientes:

- Elija el menú Acciones y la opción Ver trabajo para ver el trabajo en el editor visual.
- Elija el menú Acciones y la opción Detener ejecución para detener la ejecución actual del trabajo.
- Elija el botón Ver registros de CloudWatch para ver los registros de ejecución de trabajo para ese trabajo.
- Elija Ver detalles para ver la página de detalles de ejecución de trabajo.

Visualización de los registros de ejecución de trabajo

Puede ver los registros de trabajo de diversas formas:

- En la página Monitoreo, en la tabla Ejecuciones de trabajo, elija una ejecución de trabajo y, a continuación, elija Ver registros de CloudWatch.
- En el editor visual de trabajos, en la pestaña Ejecuciones para un trabajo, elija los hipervínculos para ver los registros:
  - Registros: enlaces a los registros de trabajo de Apache Spark escritos cuando se habilita el registro continuo para una ejecución de trabajo. Este enlace lo dirige a los registros de Amazon CloudWatch en el grupo de registros `/aws-glue/jobs/logs-v2`. De forma predeterminada, los registros excluyen los mensajes de registro de latido de Apache Hadoop YARN no útiles y de ejecutor o controlador de Apache Spark. Para obtener más información acerca del registro continuo, consulte Registro continuo para trabajos de AWS Glue en la Guía para desarrolladores de AWS Glue.
  - Registros de errores: enlaza con los registros escritos en `stderr` para esta ejecución de trabajo. Este enlace lo dirige a los registros de Amazon CloudWatch en el grupo de registros `/aws-glue/jobs/error`. Puede utilizar estos registros para ver detalles acerca de los errores que se encontraron durante la ejecución del trabajo.
  - Registros de salida: enlaza con los registros escritos en `stdout` para esta ejecución de trabajo. Este enlace lo dirige a los registros de Amazon CloudWatch en el grupo de registros `/aws-glue/jobs/output`. Puede utilizar esto registros para ver todos los detalles acerca de las tablas que se crearon en el AWS Glue Data Catalog y los errores que se encontraron.

Visualización de los detalles de una ejecución de trabajo

Puede elegir un trabajo de la lista Ejecuciones de trabajo en la página Monitoreo y, a continuación, elegir Ver detalles de la ejecución para ver información detallada sobre esa ejecución del trabajo.

La información que se muestra en la página detalles de ejecución de trabajo incluye lo siguiente:

Propiedad	Descripción
Nombre de trabajo	El nombre del trabajo.
Estado de ejecución	El estado actual de la ejecución de flujo de trabajo. Los valores pueden ser: • `STARTING` • `RUNNING` • `STOPPING` • `STOPPED` • `SUCCEEDED` • `FAILED` • `TIMEOUT`
Versión de Glue	La versión de AWS Glue utilizada por la ejecución del trabajo.
Intento reciente	El número de intentos de reintento automático para esta ejecución de trabajo.
Hora de inicio	La fecha y la hora en que se inició la ejecución de este flujo de trabajo.
Hora de finalización	La fecha y la hora en que se completó la ejecución de este trabajo.
Hora de inicio	El tiempo empleado en la preparación para ejecutar el trabajo.

Propiedad	Descripción
Hora de ejecución	El tiempo empleado en la ejecución del script de trabajo.
Nombre del disparador	El nombre del desencadenador asociado con el trabajo.
Hora de la última modificación	La fecha en la que se modificó el trabajo por última vez.
Configuración de seguridad	La configuración de seguridad del trabajo, que incluye configuraciones de cifrado de Amazon S3, cifrado de CloudWatch y cifrado de marcadores de trabajo.
Tiempo de espera	El valor del umbral de tiempo de espera de ejecución del trabajo.
Capacidad asignada	El número de unidades de procesamiento de datos (DPU) de AWS Glue asignadas a esta ejecución de trabajo. Para obtener más información acerca de la planificación de capacidad, consulte Monitoreo para planificar la capacidad de DPU en la Guía para desarroll adores de AWS Glue.
Capacidad máxima	La capacidad máxima disponible para la ejecución del trabajo.
Número de procesos de trabajo	El número de empleados utilizados para la ejecución del trabajo.

Propiedad	Descripción
Tipo de empleado	Tipo de empleados predefinidos asignados para la ejecución del trabajo. Los valores pueden ser `G.1X` o `G.2X`. • **`G.1X`**: al elegir este tipo, también debe proporcionar un valor para Número de empleados. Cada proceso de trabajo se asocia a una DPU (4 vCPU, 16 GB de memoria, disco de 64 GB) y proporciona un ejecutor por proceso de trabajo. Le recomendamos este tipo de proceso de trabajo para trabajos con un uso intensivo de la memoria. Esta es la opción predeterminada de Tipo de empleado para trabajos de AWS Glue versión 2.0 o posterior. • **`G.2X`**: al elegir este tipo, también debe proporcionar un valor para Number of workers (Número de empleados). Cada trabajo se asocia a 2 DPU (8 vCPU, 32 GB de memoria, disco de 128 GB) y proporciona un ejecutor por proceso de trabajo. Recomendamos este tipo de empleado para trabajos con una utilización intensiva de la memoria y trabajos que ejecuten transformaciones de machine learning.
Registros	Un enlace a los registros de trabajo para el registro continuo (`/aws-glue/jobs/logs-v2`).
Registros de salida	Un enlace a los archivos de registro de salida del trabajo (`/aws-glue/jobs/output`).
Registros de errores	Un enlace a los archivos de registro de error del trabajo (`/aws-glue/jobs/error`).

También puede ver los siguientes elementos adicionales, que también están disponibles al consultar la información de las ejecuciones de trabajos recientes. Para obtener más información, consulte the section called “Ver información sobre las ejecuciones de trabajos recientes”.

- Argumentos de entrada
- Registros continuos
- Métricas: puede ver visualizaciones de métricas básicas. Para obtener más información sobre las métricas incluidas, consulte the section called “Visualización de métricas de Amazon CloudWatch para una ejecución de trabajo de Spark”.
- Interfaz de usuario de Spark: puede visualizar los registros de Spark para su trabajo en la interfaz de usuario de Spark. Para obtener más información acerca de cómo usar la interfaz de usuario de Spark Web, consulte the section called “Monitorización con la interfaz de usuario de Spark”. Habilite esta característica; para ello, siga el procedimiento que se describe en the section called “Habilitación de la interfaz de usuario de Spark para trabajos”.

Visualización de métricas de Amazon CloudWatch para una ejecución de trabajo de Spark

En la página de detalles de una ejecución de trabajo, debajo de la sección Detalles de ejecución, puede consultar las métricas de trabajo. AWS Glue Studio las envía a Amazon CloudWatch para cada ejecución de trabajo.

AWS Glue notifica las métricas a Amazon CloudWatch cada 30 segundos. Las métricas de AWS Glue representan valores delta que se obtienen de los valores notificados con anterioridad. Si procede, los paneles de métricas acumulan (suman) los valores de 30 segundos para obtener un valor para el último minuto en su totalidad. Sin embargo, las métricas de Apache Spark que AWS Glue transfiere a Amazon CloudWatch, suelen ser valores absolutos que representan el estado actual en el momento en que se notifican.

> **Note**
>
> Debe configurar su cuenta para acceder a Amazon CloudWatch.

Las métricas proporcionan información sobre la ejecución de trabajo, como:

- Movimiento de datos de ETL: número de bytes leídos o escritos en Amazon S3.

- Perfil de la memoria: montón utilizado: el número de bytes de memoria utilizados por el montón de máquina virtual Java (JVM).
- Perfil de la memoria: uso del montón: la fracción de memoria (escala: 0-1), mostrada como porcentaje, utilizada por el montón de JVM.
- Carga de CPU: la fracción de carga del sistema de CPU usada (escala: 0-1), mostrada como porcentaje.

Visualización de métricas de Amazon CloudWatch para una ejecución de trabajo de Ray

En la página de detalles de una ejecución de trabajo, debajo de la sección Detalles de ejecución, puede consultar las métricas de trabajo. AWS Glue Studio las envía a Amazon CloudWatch para cada ejecución de trabajo.

AWS Glue notifica las métricas a Amazon CloudWatch cada 30 segundos. Las métricas de AWS Glue representan valores delta que se obtienen de los valores notificados con anterioridad. Si procede, los paneles de métricas acumulan (suman) los valores de 30 segundos para obtener un valor para el último minuto en su totalidad. Sin embargo, las métricas de Apache Spark que AWS Glue transfiere a Amazon CloudWatch, suelen ser valores absolutos que representan el estado actual en el momento en que se notifican.

> **Note**
>
> Debe configurar su cuenta para acceder a Amazon CloudWatch, tal y como se describe en .

En los trabajos de Ray, puede ver los siguientes gráficos de métricas agregadas. Con ellos, puede crear un perfil del clúster y sus tareas y acceder a información detallada sobre cada nodo. Los datos de serie temporal que respaldan estos gráficos están disponibles en CloudWatch para el análisis posterior.

Perfil de la tarea: estado de la tarea

Muestra el número de tareas de Ray en el sistema. El ciclo de vida de cada tarea tiene su propia serie temporal.

Perfil de la tarea: nombre de la tarea

Muestra el número de tareas de Ray en el sistema. Solo se muestran las tareas pendientes y activas. A cada tipo de tarea (por su nombre) se asigna su propia serie temporal.

Perfil de clúster: CPU en uso

Muestra el número de núcleos de CPU que se utilizan. A cada nodo se asigna su propia serie temporal. Los nodos se identifican mediante direcciones IP, que son efímeras y solo se utilizan para identificación.

Perfil de clúster: uso de memoria del almacén de objetos

Muestra el uso de memoria por parte de la caché de objetos de Ray. A cada ubicación de memoria (memoria física, almacenada en caché en el disco y volcada a Amazon S3) recibe su propia serie temporal. El almacén de objetos administra el almacenamiento de datos en todos los nodos del clúster. Para obtener más información, consulte Objetos en la documentación de Ray.

Perfil de clúster: recuento de nodos

Muestra la cantidad de nodos aprovisionados para el clúster.

Detalle del nodo: uso de la CPU

Muestra el uso de la CPU en cada nodo como porcentaje. Cada serie muestra un porcentaje agregado del uso de la CPU en todos los núcleos del nodo.

Detalle del nodo: uso de memoria

Muestra el uso de memoria (en GB) en cada nodo. Cada serie muestra la memoria agregada entre todos los procesos del nodo, incluidas las tareas de Ray y el proceso de almacenamiento de Plasma. Esto no reflejará los objetos almacenados en el disco o volcados a Amazon S3.

Detalle del nodo: uso del disco

Muestra el uso del disco (en GB) en cada nodo.

Detalle del nodo: velocidad de E/S del disco

Muestra las E/S del disco (en kB/s) en cada nodo.

Detalle del nodo: rendimiento de E/S de red

Muestra las E/S de red (en kB/s) en cada nodo.

Detalle del nodo: uso de la CPU por el componente de Ray

Muestra el uso de la CPU en fracciones de un núcleo. A cada componente de Ray en cada nodo se asigna su propia serie temporal.

Detalle del nodo: uso de la memoria por el componente de Ray

Muestra el uso de memoria en GiB. A cada componente de Ray en cada nodo se asigna su propia serie temporal.

Detectar y procesar información confidencial

La transformación Detectar PII identifica la información de identificación personal (PII) en su origen de datos. Usted elige la entidad PII que desea identificar, cómo desea que se escaneen los datos y qué hacer con la entidad PII identificada por la transformación Detectar PII.

La transformación Detectar PII proporciona la capacidad de detectar, enmascarar o eliminar entidades definidas por el usuario o predefinidas por AWS. Esto permite aumentar la conformidad y reducir la responsabilidad. Por ejemplo, es posible que desee asegurarse de que no exista información de identificación personal en los datos que pueda leerse, y que desee enmascarar números de la seguridad social con una cadena fija (por ejemplo, xxx-xx-xxxx), números de teléfono o direcciones.

Para trabajar con datos confidenciales fuera de AWS Glue Studio, consulte Usar la detección de datos confidenciales fuera de AWS Glue Studio

Temas

- Elegir cómo desea que se escaneen los datos
- Elección de las entidades de PII que se desea detectar
- Especificar el nivel de sensibilidad de detección
- Elegir qué hacer con los datos de PII identificados
- Agregar anulaciones de acciones detalladas

Elegir cómo desea que se escaneen los datos

Cuando escanea su conjunto de datos en busca de datos confidenciales, como información de identificación personal (PII), puede elegir detectar la PII en cada fila o detectar las columnas que contienen datos de PII.

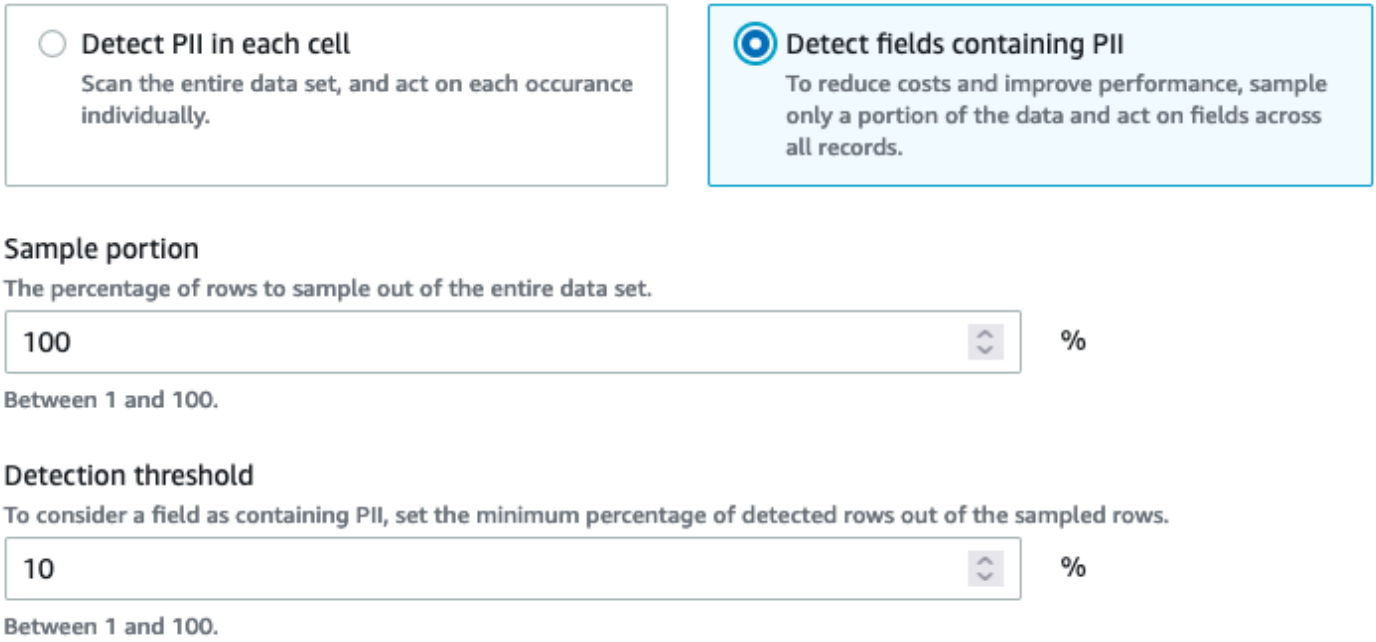

Cuando elige Detectar PII en cada celda, elige escanear todas las filas del origen de datos. Se trata de un análisis exhaustivo para garantizar que se identifiquen las entidades de PII.

Cuando elige Detectar campos que contienen PII, elige escanear una muestra de filas en busca de entidades de PII. Esta es una forma de mantener bajos los costos y los recursos, al mismo tiempo que se identifican los campos en los que se encuentran las entidades de PII.

Cuando elige detectar campos que contienen PII, puede reducir los costos y mejorar el rendimiento mediante muestras de una parte de las filas. La elección de esta opción permitirá que especifique opciones adicionales:

- Porción de muestra: permite especificar el porcentaje de filas que se van a mostrar. Por ejemplo, si ingresa ‘50’, especifica que desea el 50 por ciento de las filas escaneadas para la entidad PII.
- Umbrales de detección: permite especificar el porcentaje de filas que contienen la entidad PII para identificar que toda la columna tiene la entidad PII. Por ejemplo, si ingresa ‘10’, especifica que el número de la entidad PII, teléfono EE. UU., en las filas escaneadas debe ser del 10 por ciento o superior para que el campo se identifique como la entidad PII, teléfono EE. UU. Si el porcentaje de filas que contienen la entidad PII es inferior al 10 por ciento, ese campo no se etiquetará por tener la entidad PII, teléfono EE. UU., en él.

Elección de las entidades de PII que se desea detectar

Si ha seleccionado Detectar PII en cada celda, puede elegir entre tres opciones:

- Todos los patrones de PII disponibles: esto incluye las entidades de AWS.
- Seleccionar categorías: si selecciona las categorías, los patrones de PII incluirán automáticamente los patrones de las categorías seleccionadas.
- Seleccionar patrones específicos: solo se detectarán los patrones que seleccione.

Para obtener una lista completa de los tipos de datos confidenciales administrados, consulte Tipos de datos administrados.

Elegir entre todos los patrones de PII disponibles

Si elige Todos los patrones de PII disponibles, seleccione entidades predefinidas por AWS. Puede seleccionar una entidad, varias o todas ellas.

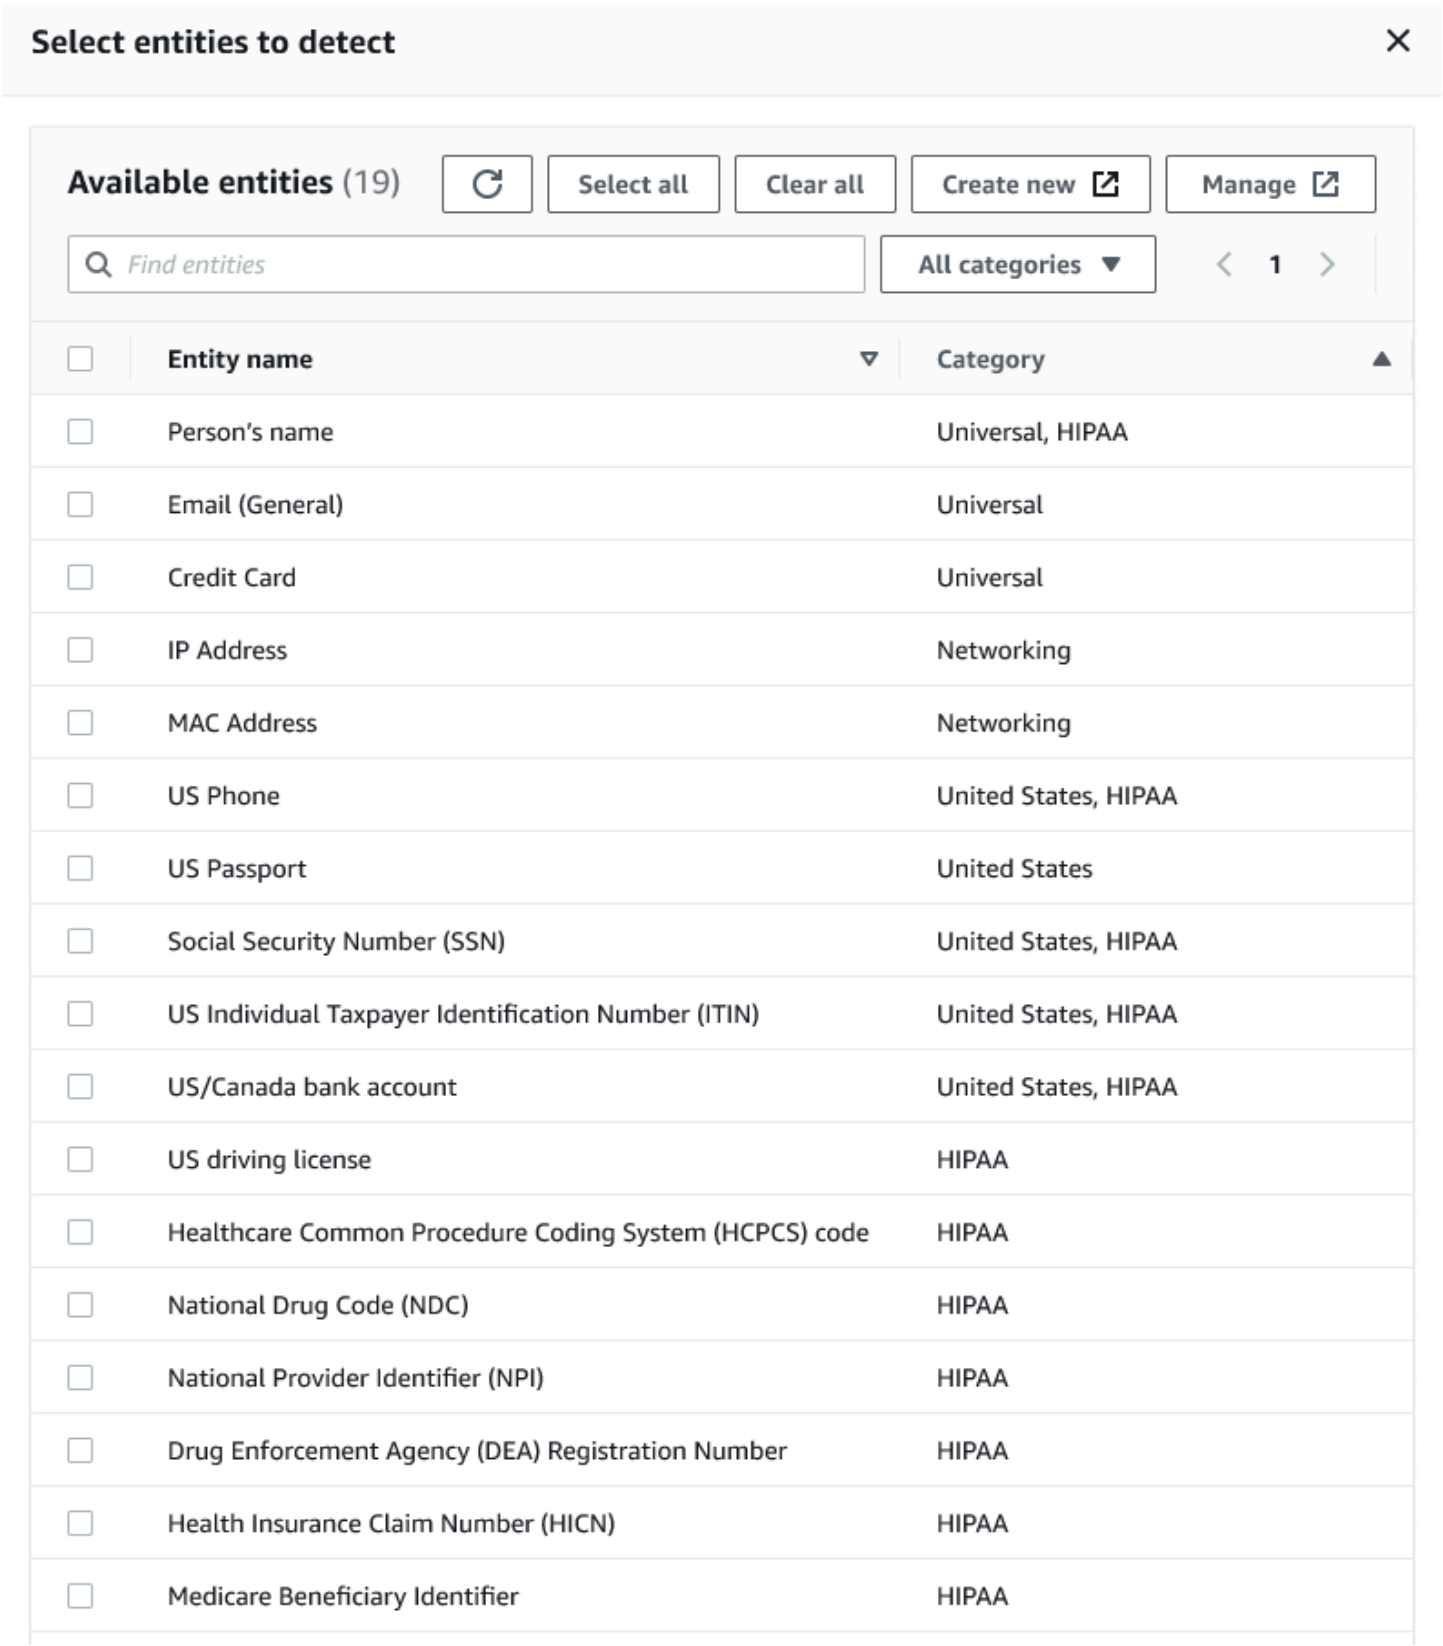
Select entities to detect
Available entities (19)
Select all
Clear all
Create new
Manage
Find entities
All categories
1
Entity name
Category
Person's name
Universal, HIPAA
Email (General)
Universal
Credit Card
Universal
IP Address
Networking
MAC Address
Networking
US Phone
United States, HIPAA
US Passport
United States
Social Security Number (SSN)
United States, HIPAA
US Individual Taxpayer Identification Number (ITIN)
United States, HIPAA
US/Canada bank account
United States, HIPAA
US driving license
HIPAA
Healthcare Common Procedure Coding System (HCPCS) code
HIPAA
National Drug Code (NDC)
HIPAA
National Provider Identifier (NPI)
HIPAA
Drug Enforcement Agency (DEA) Registration Number
HIPAA
Health Insurance Claim Number (HICN)
HIPAA
Medicare Beneficiary Identifier
HIPAA

Seleccionar categorías

Si ha elegido Seleccionar categorías como patrones de PII que se deben detectar, puede elegir entre las opciones del menú desplegable. Tenga en cuenta que algunas entidades pueden pertenecer a más de una categoría. Por ejemplo, Nombre de la persona es una entidad que pertenece a las categorías Universal y HIPAA.

- Universal (ejemplos: correo electrónico, tarjeta de crédito)
- HIPAA (ejemplos: licencia de conducir de EE. UU., código del sistema de codificación de procedimientos comunes de atención médica [HCPCS])
- Redes (ejemplos: dirección IP, dirección MAC)
- Argentina
- Australia
- Austria
- Bélgica
- Bosnia
- Bulgaria
- Canadá
- Chile
- Colombia
- Croacia
- Chipre
- Chequia
- Dinamarca
- Estonia
- Finlandia
- Francia
- Alemania
- Grecia
- Hungría
- Irlanda

- Corea
- Japón
- México
- Países Bajos
- Nueva Zelanda
- Noruega
- Portugal
- Rumanía
- Singapur
- Eslovaquia
- Eslovenia
- España
- Suecia
- Suiza
- Turquía
- Ucrania
- Estados Unidos
- Reino Unido
- Venezuela

Seleccionar patrones específicos

Si elige Seleccionar patrones específicos como patrones de PII que se deben detectar, puede buscar o examinar una lista de patrones que ya haya creado, o bien crear un nuevo patrón de entidad de detección.

En los siguientes pasos se describe la creación de un nuevo patrón personalizado para detectar información confidencial. Creará el patrón personalizado al ingresar un nombre para dicho patrón, agregará una expresión regular y, opcionalmente, definirá palabras de contexto.

1. Para crear un nuevo patrón, haga clic en el botón Crear nuevo.

2. En la página Crear entidad de detección, ingrese el nombre de la entidad y una expresión regular. La expresión regular (regex) es lo que AWS Glue utilizará para buscar coincidencias de entidades.
3. Haga clic en Validar. Si la validación se realiza correctamente, aparecerá un mensaje de confirmación que indica que la cadena es una expresión regular válida. Si la validación no se realiza correctamente, aparecerá un mensaje que indica que la cadena no se ajusta al formato adecuado ni a los caracteres, los operadores o las construcciones aceptados.
4. Puede optar por agregar palabras contextuales además de la expresión regular. Las palabras contextuales pueden aumentar la probabilidad de coincidencia. Pueden resultar útiles en los casos en que los nombres de los campos no ofrezcan información descriptiva sobre la entidad. Por ejemplo, los números de la seguridad social pueden denominarse "NSS" o "SS". Agregar estas palabras contextuales puede ayudar a encontrar una coincidencia de la entidad.
5. Haga clic en Crear para crear la entidad de detección. Todas las entidades creadas son visibles en la consola de AWS Glue Studio. Haga clic en Entidades de detección en el menú de navegación de la izquierda.

   Puede editar, eliminar o crear entidades de detección desde la página Entidades de detección. También puede buscar un patrón mediante el campo de búsqueda.

Especificar el nivel de sensibilidad de detección

Puede establecer el nivel de sensibilidad al utilizar la detección de datos confidenciales.

- Alto: (predeterminado) detecta más entidades para los casos de uso que requieren un mayor nivel de sensibilidad. Todos los trabajos de AWS Glue creados después de noviembre de 2023 se activan automáticamente en esta configuración.
- Bajo: detecta menos entidades y reduce los falsos positivos.

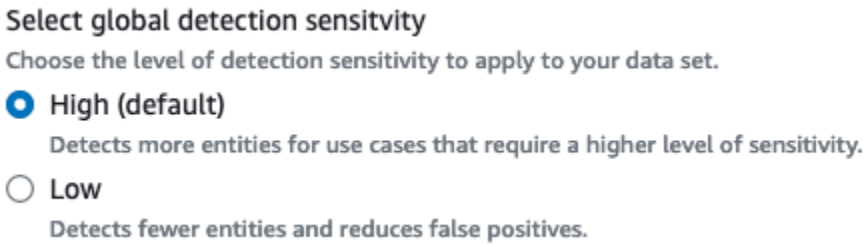

Elegir qué hacer con los datos de PII identificados

Si optó por detectar PII en todo el origen de datos, puede elegir una acción global a aplicar:

- Enriquecer los datos con los resultados de detección: si eligió Detectar PII en cada celda, puede almacenar las entidades detectadas en una nueva columna.
- Texto detectado de redacción: puede reemplazar el valor de PII detectado por una cadena que especifique en el campo opcional Reemplazo de entrada de texto. Si no se especifica ninguna cadena, la entidad PII detectada se sustituye por '*******'.
- Texto detectado de redacción: puede reemplazar parte del valor de PII detectado por una cadena que elija. Hay dos opciones posibles: dejar los extremos desenmascarados o enmascararlos proporcionando un patrón de expresiones regulares explícito. Esta característica todavía no está disponible en AWS Glue 2.0.
- Aplicar hash criptográfico: puede pasar el valor de PII detectado a una función de hash criptográfico SHA-256 y reemplazar el valor por la salida de la función.

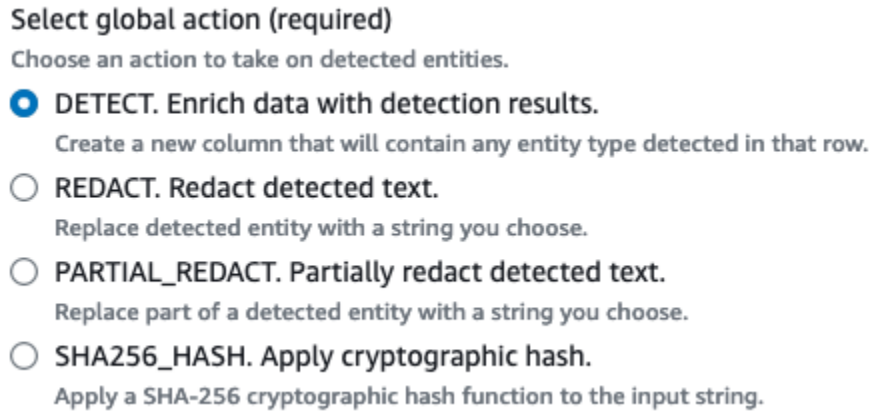

Diferencias entre AWS Glue las versiones 2.0 y 3.0+

Los trabajos AWS Glue 2.0 devolverán un nuevo DataFrame con la información de PII detectada para cada columna en una columna adicional. Cualquier redacción o trabajo hash está visible dentro del guion de AWS Glue en la pestaña visual.

Los trabajos de AWS Glue 3.0 y 4.0 devolverán un nuevo DataFrame con esta misma columna complementaria. Hay una nueva clave para "actionUsed" y puede ser una de las siguientes: `DETECT`, `REDACT`, `PARTIAL_REDACT` o `SHA256_HASH`. Si se selecciona una acción de enmascaramiento, el DataFrame devolverá datos con el enmascaramiento de datos confidenciales.

Agregar anulaciones de acciones detalladas

Se pueden añadir ajustes adicionales de detección y acción a la tabla de anulaciones de acciones detalladas. Esto le permite:

- Incluir o excluir determinadas columnas de la detección: un esquema inferido en el origen de datos rellenará la tabla con las columnas disponibles.
- Especifique ajustes específicos que sean más detallados que mediante acciones globales. Por ejemplo, puede especificar distintos ajustes de texto de redacción para distintos tipos de entidades.
- Especifique una acción diferente a la acción global: si desea aplicar una acción diferente a un tipo de datos confidenciales diferente, puede hacerlo aquí. Tenga en cuenta que no se pueden usar dos acciones de edición in situ diferentes (redacción y codificación) en la misma columna, pero siempre se puede usar la función de detección.

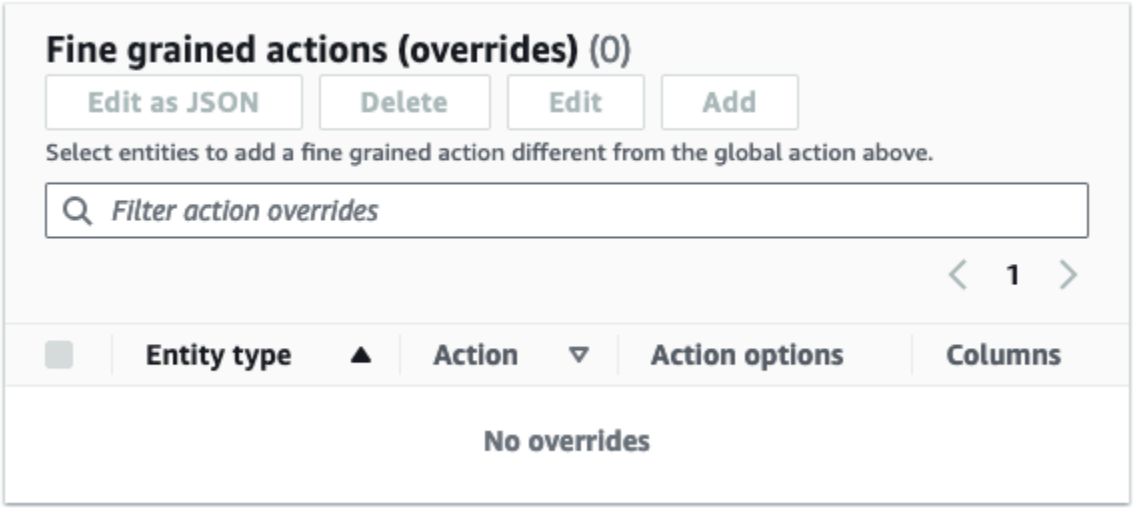

Administración de trabajos de ETL con AWS Glue Studio

Puede usar la interfaz gráfica simple en AWS Glue Studio para administrar los trabajos de ETL. En el menú de navegación, seleccione Trabajos para ver la página Trabajos. En esta página, puede ver todos los trabajos que ha creado con AWS Glue Studio o con la consola de AWS Glue. Puede ver, administrar y ejecutar sus trabajos en esta página.

También puede realizar las siguientes acciones:

- Iniciar una ejecución de trabajo
- Programar ejecuciones de trabajo
- Administrar programaciones de trabajo
- Detener ejecuciones de trabajo
- Ver los trabajos
- Ver información sobre las ejecuciones de trabajos recientes
- Ver el script de trabajo
- Modificar las propiedades del trabajo
- Guardar el trabajo
- Clonación de un trabajo
- Eliminación de trabajos

Iniciar una ejecución de trabajo

En AWS Glue Studio, puede ejecutar los trabajos bajo demanda. Un trabajo puede ejecutarse varias veces y cada vez que ejecute el trabajo, AWS Glue recopila información sobre las actividades y el rendimiento del trabajo. Esta información se conoce como una ejecución de trabajo y se identifica mediante un ID de ejecución de trabajo.

Puede iniciar una ejecución de trabajo de las siguientes maneras en AWS Glue Studio:

- En la página Trabajos, elija el trabajo que desea iniciar y, luego, elija el botón Ejecutar trabajo.
- Si está viendo un trabajo en el editor visual y el trabajo se ha guardado, puede elegir el botón Ejecución para iniciar una ejecución de trabajo.

Para obtener más información acerca de las ejecuciones de trabajos, consulte Uso de trabajos en la consola de AWS Glue en la Guía para desarrolladores de AWS Glue.

Programar ejecuciones de trabajo

En AWS Glue Studio, puede crear una programación para que los trabajos se ejecuten en momentos específicos. Puede especificar restricciones, como la cantidad de veces que desea que se ejecute un trabajo, qué días de la semana se ejecutarán y a qué hora. Estas restricciones se basan en `cron` y tienen las mismas limitaciones que `cron`. Por ejemplo, si decide ejecutar su trabajo el día 31 de cada mes, tenga en cuenta que algunos meses no tienen 31 días. Para obtener más información acerca de `cron`, consulte Expresiones Cron en la Guía para desarrolladores de AWS Glue.

Para ejecutar trabajos de acuerdo con una programación

1. Utilice uno de los métodos siguientes para crear una programación de trabajo:
   - En la página Trabajos elija el trabajo para el que desea crear una programación, elija Acciones y, a continuación, elija Programar trabajo.
   - Si está viendo un trabajo en el editor visual y el trabajo se ha guardado, elija la pestaña Programaciones. A continuación, elija Crear programación.
2. En la página Programar ejecución de trabajo, escriba la siguiente información:
   - Nombre: ingrese un nombre para su programación de trabajo.
   - Frecuencia: ingrese la frecuencia para la programación de trabajo. Puede elegir entre las siguientes opciones:
     - Por hora: el trabajo se ejecutará cada hora, comenzando en un minuto específico. Puede especificar el Minuto de la hora que debe ejecutarse el trabajo. De forma predeterminada, cuando elige por hora, el trabajo se ejecuta al comenzar la hora (minuto 0).
     - Por día: el trabajo se ejecutará todos los días, comenzando a la hora indicada. Puede especificar el Minuto de la que hora en la que debe ejecutarse el trabajo y la Hora de inicio para el trabajo. Las horas se especifican con un reloj de 23 horas, en el que se utilizan los números de 13 a 23 para las horas de la tarde. Los valores predeterminados para minuto y hora son 0, lo que significa que si selecciona Por día, el trabajo se ejecutará a medianoche de manera predeterminada.
     - Por semana: el trabajo se ejecutará cada semana en uno o más días. Además de la misma configuración descrita anteriormente para Por día, puede elegir los días de la semana en los que se ejecutará el trabajo. Puede elegir uno o más días.
     - Por mes: el trabajo se ejecutará todos los meses en un día específico. Además de la misma configuración descrita anteriormente para Por día, puede elegir el día del mes en el que se ejecutará el trabajo. Especifique el día como un valor numérico del 1 al 31. Si selecciona

un día que no existe en un mes, por ejemplo, el 30 de febrero, entonces el trabajo no se ejecuta ese mes.

- Personalizado: ingrese una expresión para la programación del trabajo mediante la sintaxis de `cron`. Las expresiones Cron le permiten crear programaciones más complejas, como el último día del mes (en lugar de un día específico del mes) o cada tres meses los días 7 y 21 del mes.

  Consulte Expresiones Cron en la Guía para desarrolladores de AWS Glue

- Descripción: de forma opcional, puede especificar una descripción para la programación de trabajos. Si planea utilizar la misma programación para múltiples trabajos, incluir una descripción facilita determinar las tareas de una programación del trabajo.

3. Elija Crear programación para guardar la programación de trabajos.
4. Después de crear la programación, aparece un mensaje de éxito en la parte superior de la página de la consola. Puede elegir Detalles del trabajo en este banner para ver los detalles del trabajo. Esto abre la página del editor visual de trabajos, con la pestaña Programaciones seleccionada.

Administrar programaciones de trabajo

Después de crear programaciones para un trabajo, puede abrir el trabajo en el editor visual y elegir la pestaña Programaciones para administrar las programaciones.

En la pestaña Programaciones en el editor visual, puede llevar a cabo las siguientes tareas:

- Crear una nueva programación.

  Elija Crear programación y, a continuación, ingrese la información de su programación tal y como se describe en the section called “Programar ejecuciones de trabajo”.

- Edición de una programación existente.

  Elija la programación que desea editar y, a continuación, elija Acción y luego Editar programación. Cuando elija editar una programación existente, Frecuencia aparece como Personalizado, y la programación se muestra como una expresión `cron`. Puede modificar la expresión `cron`, o especificar una nueva programación mediante el botón Frecuencia. Cuando termine de realizar los cambios, elija Actualizar programación.

- Pausar una programación activa.

Elija una programación activa y, a continuación, elija Acción, y luego Pausar programación. La programación se desactiva en forma instantánea. Elija el botón actualizar (recargar) para ver el estado actualizado de la programación de trabajos.

- Reanudar una programación en pausa.

  Elija una programación desactivada y, a continuación, elija Acción, y luego Reanudar programación. La programación se activa en forma instantánea. Elija el botón actualizar (recargar) para ver el estado actualizado de la programación de trabajos.

- Eliminar una programación.

  Elija la programación que desea eliminar y, a continuación, elija Acción y luego Eliminar programación. La programación se elimina en forma instantánea. Elija el botón actualizar (recargar) para ver la programación de trabajo actualizada. La programación mostrará un estado de Eliminación hasta que se haya eliminado por completo.

Detener ejecuciones de trabajo

Puede detener un trabajo antes de que haya completado su ejecución. Puede elegir esta opción si sabe que el trabajo no está configurado correctamente o si el trabajo tarda demasiado en completarse.

En la página Monitoreo, en la lista Ejecuciones de trabajo, elija el trabajo que desea detener, elija Acciones y, a continuación, elija Detener ejecución.

Ver los trabajos

Puede ver todos sus trabajos en la página Trabajos. Puede acceder a esta página al seleccionar Trabajos en el panel de navegación.

En la página Trabajos, puede ver todos los trabajos que se crearon en su cuenta. La lista Sus trabajos muestra el nombre del trabajo, su tipo, el estado de la última ejecución de ese trabajo y las fechas en las que se creó y modificó por última vez el trabajo. Puede elegir el nombre de un trabajo para ver información detallada de ese trabajo.

También puede utilizar el panel Monitoreo para ver todos los trabajos. Puede acceder al panel al elegir Monitoreo en el panel de navegación.

Personalizar la visualización del trabajo

Puede personalizar la forma en que se muestran los trabajos en la sección Sus trabajos en la página Trabajos. Además, puede escribir texto en el campo de texto de búsqueda para mostrar sólo los trabajos con un nombre que contenga ese texto.

Si elige el ícono de configuración

en la sección Sus trabajos, puede personalizar cómo AWS Glue Studio muestra la información en la tabla. Puede elegir ajustar las líneas de texto en la pantalla, cambiar el número de trabajos mostrados en la página y especificar qué columnas mostrar.

Ver información sobre las ejecuciones de trabajos recientes

Un trabajo puede ejecutarse varias veces a medida que se agregan nuevos datos en la ubicación de origen. Cada vez que se ejecuta un trabajo, se le asigna un ID único y se recopila información sobre esa ejecución. Puede utilizar los siguientes métodos para ver esta información:

- Elija la pestaña Ejecuciones del editor visual para ver la información de ejecución del trabajo que se muestra actualmente.

  En la pestaña Ejecuciones (página Ejecuciones de trabajo recientes), se incluye una tarjeta para cada trabajo ejecutado. La información que se muestra en la pestaña Ejecuciones incluye lo siguiente:
  - ID de ejecución del trabajo
  - La cantidad de intentos de ejecución de este trabajo
  - Estado de la ejecución del trabajo
  - Hora de inicio y finalización de la ejecución del trabajo
  - El tiempo de ejecución para la ejecución del trabajo
  - Un enlace a los archivos de registro del trabajo
  - Un enlace a los archivos de registro de error del trabajo
  - Error devuelto por trabajos fallidos
- Puede seleccionar una ejecución del trabajo para ver información adicional, que incluya lo siguiente:
  - Argumentos de entrada
  - Registros continuos

- Métricas: puede ver visualizaciones de métricas básicas. Para obtener más información sobre las métricas incluidas, consulte the section called “Visualización de métricas de Amazon CloudWatch para una ejecución de trabajo de Spark”.
- Interfaz de usuario de Spark: puede visualizar los registros de Spark para su trabajo en la interfaz de usuario de Spark. Para obtener más información acerca de cómo usar la interfaz de usuario de Spark Web, consulte the section called “Monitorización con la interfaz de usuario de Spark”. Habilite esta característica; para ello, siga el procedimiento que se describe en the section called “Habilitación de la interfaz de usuario de Spark para trabajos”.

Puede seleccionar Ver detalles para ver información similar en la página de detalles de la ejecución del trabajo. Como alternativa, puede ir a la página de detalles de la ejecución del trabajo a través de la página Supervisión. En el panel de navegación, seleccione Monitoreo. Desplácese hacia abajo en la lista Ejecuciones de trabajo. Elija el trabajo y, a continuación, elija Ver detalles de ejecución. Los contenidos se describen en Visualización de los detalles de una ejecución de trabajo.

Para obtener más información acerca de los registros de trabajo, consulte Visualización de los registros de ejecución de trabajo.

Ver el script de trabajo

Después de proporcionar información para todos los nodos del trabajo, AWS Glue Studio genera un script que el trabajo utiliza para leer los datos de la fuente, transformarlos y escribirlos en la ubicación de destino. Si guarda el trabajo, puede ver este script en cualquier momento.

Para ver el script generado para su trabajo

1. En el panel de navegación, elija Trabajos.
2. En la página Trabajos, en la lista Sus trabajos elija el nombre del trabajo que desea revisar. Como alternativa, puede seleccionar un trabajo en la lista, elegir la opción Acciones y, a continuación, elegir Editar trabajo.
3. En la página del editor visual, elija la pestaña Script en la parte superior para ver el script de trabajo.

   Si desea editar el script de trabajo, consulte Guía de programación de AWS Glue.

Modificar las propiedades del trabajo

Los nodos del diagrama de trabajo definen las acciones que realiza el trabajo, pero también se pueden configurar varias propiedades para el trabajo. Estas propiedades determinan el entorno en el que se ejecuta el trabajo, los recursos que utiliza, la configuración de umbral, la configuración de seguridad, etc.

Para personalizar el entorno de ejecución del trabajo

1. En el panel de navegación, elija Jobs (Trabajos).
2. En la página Jobs (Trabajos), en la lista Your jobs (Sus trabajos) elija el nombre del trabajo que desea revisar.
3. En la página del editor visual, elija la pestaña Detalles del trabajo en la parte superior del panel de edición del trabajo.
4. Modifique las propiedades del trabajo, según sea necesario.

   Para obtener más información acerca de las propiedades de trabajo, consulte Definición de las propiedades del trabajo en la Guía para desarrolladores de AWS Glue.
5. Expanda la sección Propiedades avanzadas si necesita especificar estas propiedades adicionales del trabajo:

   - Nombre del archivo de script: el nombre del archivo que almacena el script de trabajo en Amazon S3.
   - Ruta del script: ubicación de Amazon S3 donde se almacena el script de trabajo.
   - Métricas de trabajo: (no disponible para trabajos de intérprete de comandos de Python) activa la creación de métricas de Amazon CloudWatch cuando se ejecuta este trabajo.
   - Registro continuo: (no disponible para trabajos de intérprete de comandos de Python) activa el registro continuo en CloudWatch, para que los registros estén disponibles para su visualización antes de que finalice el trabajo.
   - Interfaz de usuario de Spark y Ruta de registros de la interfaz de usuario de Spark: (no disponible para trabajos de intérprete de comandos de Python) activa el uso de la interfaz de usuario de Spark para supervisar este trabajo y especifica la ubicación de los registros de la interfaz de usuario de Spark.
   - Concurrencia máxima: establece el número máximo de ejecuciones concurrentes que están permitidas para este trabajo.

- Ruta temporal: la ubicación de un directorio de trabajo en Amazon S3 donde los resultados intermedios temporales se escriben cuando AWS Glue ejecuta el script de trabajo.
- Umbral de notificación de retraso (minutos): especifica un umbral de retraso para el trabajo. Si el trabajo se ejecuta durante un tiempo más largo que el especificado por el umbral, entonces, AWS Glue envía una notificación de retraso para el trabajo a CloudWatch.
- Configuración de seguridad y Cifrado en el lado del servidor: utilice estos campos para elegir las opciones de cifrado para el trabajo.
- Utilizar Glue Data Catalog como metaalmacén de Hive: elija esta opción si desea utilizar AWS Glue Data Catalog como una alternativa a Apache Hive Metastore.
- Conexión de red adicional: para un origen de datos en una VPC, puede especificar una conexión de tipo `Network`, a fin de garantizar que su trabajo acceda a sus datos a través de la VPC.
- Ruta de la biblioteca Python, Ruta de archivos JAR dependientes (no disponible para trabajos de intérprete de comandos de Python), o Ruta de archivos referenciados: utilice estos campos para especificar la ubicación de los archivos adicionales que el trabajo utiliza cuando ejecuta el script.
- Parámetros del trabajo: puede agregar un conjunto de pares de clave-valor que se transfieren como parámetros con denominación al script de trabajo. En las llamadas de Python a AWS Glue API, es mejor transferir los parámetros explícitamente por nombre. Para obtener más información sobre el uso de parámetros en un script de trabajo, consulte Transferencia y acceso a los parámetros de Python en AWS Glue en la Guía para desarrolladores de AWS Glue.
- Etiquetas: puede agregar etiquetas al trabajo para que le resulte más fácil organizarlos e identificarlos.

6. Después de modificar las propiedades del trabajo, guarde el trabajo.

Almacenar archivos de mezclas aleatorias de Spark en Amazon S3

Algunos trabajos de ETL requieren leer y combinar información de diversas particiones, por ejemplo, cuando se utiliza una transformación de combinación. Esta operación se conoce como mezclado aleatorio. Durante una mezcla aleatoria, los datos se escriben en el disco y se transfieren a través de la red. Con AWS Glue, versión 3.0, puede configurar Amazon S3 como ubicación de almacenamiento para estos archivos. AWS Glue proporciona un administrador de mezclas aleatorias que escribe y lee archivos de mezcla aleatoria desde y hacia Amazon S3. La escritura y la lectura de archivos de mezcla aleatoria de Amazon S3 es más lenta (entre un 5 % y un 20 %) en comparación con el disco

local (o Amazon EBS, que está muy optimizado para Amazon EC2). No obstante, Amazon S3 ofrece capacidad de almacenamiento ilimitada, por lo que no tiene que preocuparse por errores de "No `space left on device`" al ejecutar su trabajo.

Para configurar su trabajo de modo que utilice Amazon S3 para archivos de mezcla aleatoria

1. En la página Trabajos, en la lista Sus trabajos elija el nombre del trabajo que desea modificar.
2. En la página del editor visual, elija la pestaña Job details (Detalles del trabajo) en la parte superior del panel de edición del trabajo.

   Desplácese hasta la sección Parámetros del trabajo.
3. Especifique los siguientes pares clave-valor.

   - `--write-shuffle-files-to-s3` — `true`

     Este es el parámetro principal que configura el administrador de mezclas aleatorias en AWS Glue para utilizar los buckets de Amazon S3 para escribir y leer datos aleatorios. Este parámetro tiene un valor predeterminado de `false`.
   - (Optional) `--write-shuffle-spills-to-s3`: `true`

     Este parámetro le permite descargar archivos de desbordamiento en buckets de Amazon S3, lo que proporciona resistencia adicional a su trabajo de Spark en AWS Glue. Esto solo es necesario para cargas de trabajo grandes que provocan grandes desbordamientos al disco. Este parámetro tiene un valor predeterminado de `false`.
   - (Optional) `--conf spark.shuffle.glue.s3ShuffleBucket`: `S3://<shuffle-bucket>`

     Este parámetro especifica el bucket de Amazon S3 que se utilizará al escribir los archivos de mezcla aleatoria. Si no establece este parámetro, la ubicación es la carpeta `shuffle-data` en la ubicación especificada para Ruta temporal (`--TempDir`).

     > **Note**
     >
     > Asegúrese de que la ubicación del bucket de mezcla aleatoria esté en la misma Región de AWS en la que se ejecuta el trabajo.
     > Además, el servicio de mezcla aleatoria no limpia los archivos después de que el trabajo termine de ejecutarse, por lo que debe configurar las políticas de ciclo de vida de almacenamiento de Amazon S3 en la ubicación del bucket de mezcla

aleatoria. Para obtener más información, consulte Administración del ciclo de vida de almacenamiento en la Guía del usuario de Amazon S3.

Guardar el trabajo

Se muestra un globo de color rojo: El trabajo no se ha guardado, a la izquierda del botón Guardar hasta que guarde el trabajo.

Para guardar el trabajo

1. Proporcione toda la información necesaria en las pestañas Visual y Detalles del trabajo.
2. Seleccione el botón Guardar.

   Después de guardar el trabajo, el globo “no guardado” cambia para mostrar la hora y la fecha en que se guardó el trabajo por última vez.

Si sale de AWS Glue Studio antes de guardar el trabajo, la próxima vez que inicie sesión en AWS Glue Studio, aparecerá una notificación. La notificación indica que hay un trabajo sin guardar y pregunta si desea restaurarlo. Si decide restaurar el trabajo, podrá continuar editándolo.

Solución de errores al guardar un trabajo

Si elige el botón Guardar, pero a su trabajo le falta información necesaria, aparecerá un globo rojo en la pestaña donde falta la información. El número en el globo indica cuántos campos faltantes se detectaron.

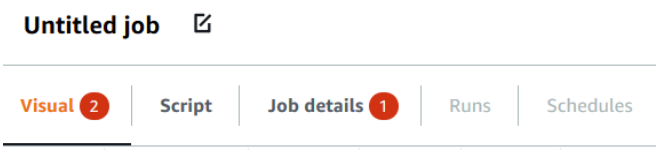

- Si un nodo del editor visual no está configurado correctamente, la pestaña Visual muestra un globo rojo y el nodo con el error muestra un símbolo de advertencia ⚠.

  1. Elija el nodo. En el panel de detalles del nodo, aparece un globo rojo en la pestaña donde se encuentra la información faltante o incorrecta.

2. Elija la pestaña del panel de detalles del nodo que muestra un globo rojo y, a continuación, busque los campos problemáticos, que están resaltados. Un mensaje de error debajo de los campos proporciona información adicional sobre el problema.

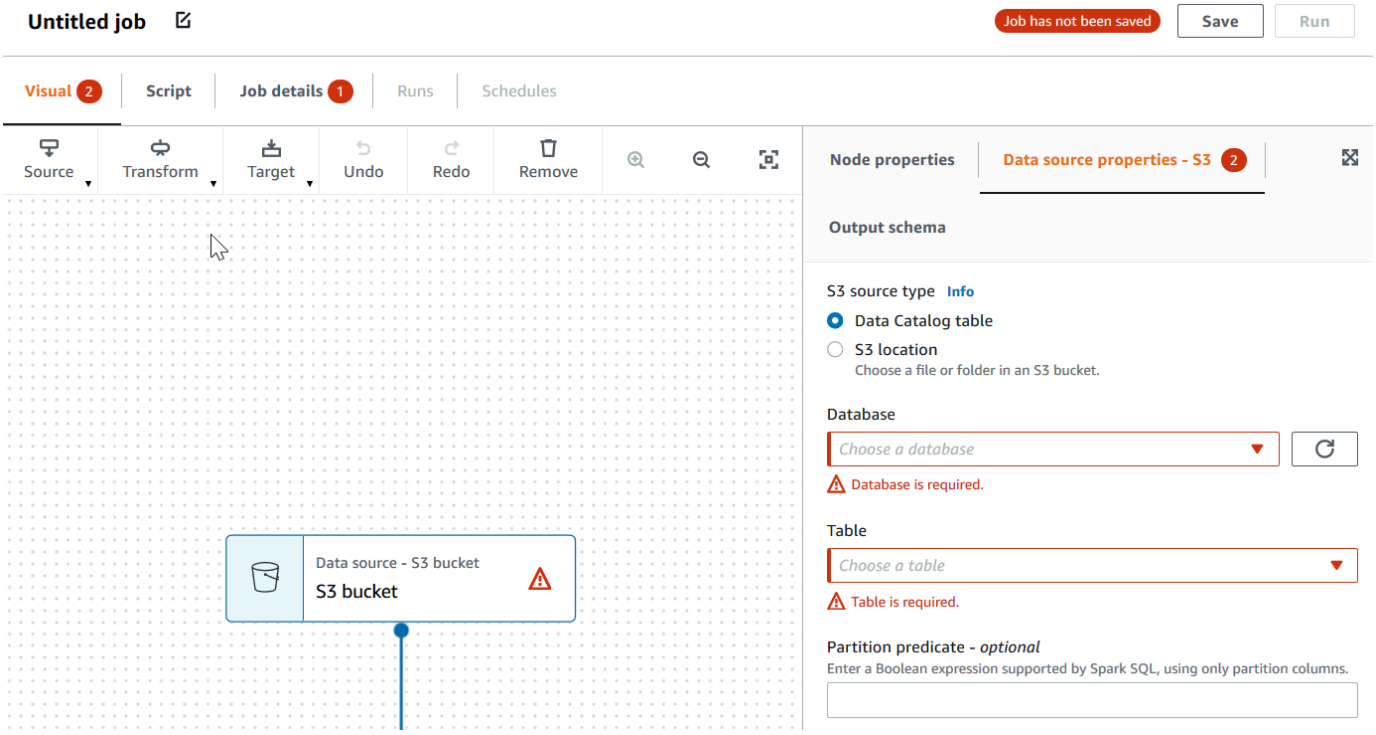

- Si hay un problema con las propiedades del trabajo, la pestaña Detalles del trabajo muestra un globo rojo. Elija esa pestaña y busque los campos problemáticos, que están resaltados. Los mensajes de error debajo de los campos proporcionan información adicional acerca del problema.

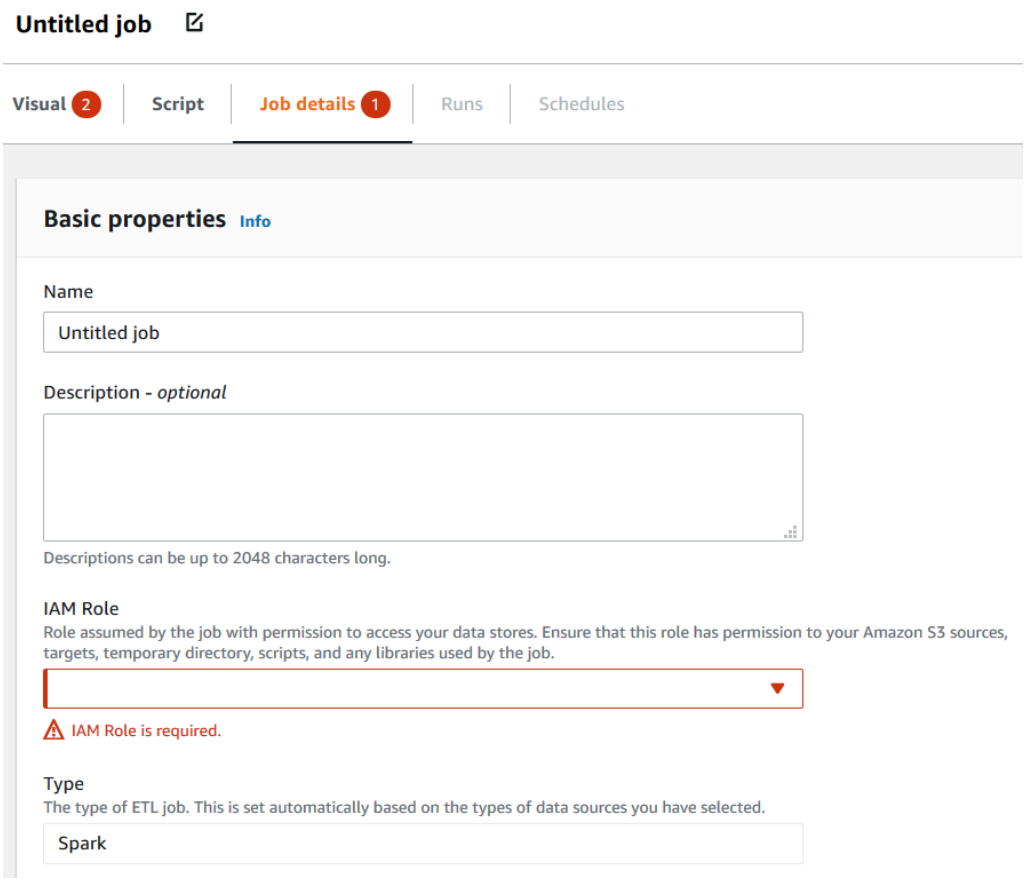

Clonación de un trabajo

Puede utilizar la acción Clonar trabajo para copiar un trabajo existente en un nuevo trabajo.

Para crear un nuevo trabajo al copiar un trabajo existente

1. En la página Trabajos, en la lista Sus trabajos elija el trabajo que desea duplicar.
2. En el menú Acciones, seleccione Clonar trabajo.
3. Ingrese un nombre para el nuevo trabajo. A continuación, puede guardar o editar el trabajo.

Eliminación de trabajos

Puede eliminar trabajos que ya no son necesarios. Puede eliminar uno o más trabajos en una sola operación.

Para eliminar trabajos de AWS Glue Studio

1. En la página Trabajos, en la lista Sus trabajos elija el trabajo que desea eliminar.
2. En el menú Acciones, elija Eliminar trabajo.
3. Verifique que desea eliminar el trabajo, ingrese **`delete`**.

También puede eliminar un trabajo guardado cuando esté viendo la pestaña Detalles del trabajo de ese trabajo en el editor visual.

Trabajar con tareas en AWS Glue

En las siguientes secciones, se ofrece información acerca de los trabajos de ETL y Ray en AWS Glue.

Temas

- AWS GlueVersiones de
- Trabajar con trabajos de Spark en AWS Glue
- Trabajar con tareas de Ray en AWS Glue
- Configuración de las propiedades de trabajos del intérprete de comandos de Python en AWS Glue
- Supervisión de AWS Glue

AWS GlueVersiones de

Puede configurar el parámetro de versión de AWS Glue al agregar o actualizar un trabajo. La versión de AWS Glue determina las versiones de Apache Spark y Python que admite AWS Glue. La versión de Python indica la versión admitida para trabajos de tipo Spark. En la siguiente tabla se muestran las versiones de AWS Glue disponibles, las versiones de Spark y Python correspondientes y otros cambios en la funcionalidad.

Puede utilizar las actualizaciones con IA generativa para Apache Spark para actualizar sus tareas de ETL de Glue desde versiones anteriores de Glue (≥ 2.0) a la versión más reciente de Glue.

AWS GlueVersiones de

AWS GlueVersión	Versiones de entorno de tiempo de ejecución compatibles	Versión de Java compatible	Cambios en la funcionalidad
AWS Glue 5.1	• Spark 3.5.6 • Python 3.11 • Scala 2.12.18	Java 17	Además de la actualización del motor de Spark, esta versión de AWS Glue incorpora optimizaciones y mejoras

AWS GlueVersión	Versiones de entorno de tiempo de ejecución compatibles	Versión de Java compatible	Cambios en la funcionalidad
			integradas, como las siguientes: • Los formatos de tabla abierta (OTF) se actualizaron a Hudi 1.0.2, Iceberg 1.10.0 y Delta Lake 3.3.2. • Formato Iceberg versión 3.0 • Acceso completo a tablas de Hudi (FTA) con lecturas y escrituras • Operaciones DDL/DML de control de acceso detallado nativo de Spark (FGAC) en tablas de Hive, Iceberg y Delta Lake registradas en Lake Formation. • Contexto de auditoría para las llamadas a la API de Glue y Lake Formation en los registros de CloudTrail.

AWS GlueVersión	Versiones de entorno de tiempo de ejecución compatibles	Versión de Java compatible	Cambios en la funcionalidad
			• Compatibilidad con vistas materializadas de Iceberg

AWS GlueVersión	Versiones de entorno de tiempo de ejecución compatibles	Versión de Java compatible	Cambios en la funcionalidad
AWS Glue 5.0	• Spark 3.5.4 • Python 3.11 • Scala 2.12.18	Java 17	Además de las actualizaciones del marco, existen optimizaciones y actualizaciones integradas en la versión AWS Glue, como por ejemplo: • Compatibilidad con Amazon SageMaker Unified Studio. • Compatibilidad con Amazon SageMaker Lakehouse • Los formatos de tabla abierta (OTF) se actualizaron a Hudi 0.15.0, Iceberg 1.7.1 y Delta Lake 3.3.0 • Control de acceso detallado nativo de Spark mediante Lake Formation. • Compatibilidad con Concesion es de acceso a Amazon S3

AWS GlueVersión	Versiones de entorno de tiempo de ejecución compatibles	Versión de Java compatible	Cambios en la funcionalidad
			• Compatibilidad de `requirements.txt` para instalar bibliotecas de Python adicionales • Compatibilidad del linaje de datos en Amazon DataZone • Compatibilidad con buckets de tabla de Amazon S3 • Compatibilidad con vistas multidialecto del Catálogo de datos de AWS Glue Limitaciones A continuación, se indican las limitaciones con AWS Glue 5.0: • Glue Dynamic Frame/el control de acceso a nivel de tabla basado en `GlueContext` con permisos de AWS Lake Formation

AWS GlueVersión	Versiones de entorno de tiempo de ejecución compatibles	Versión de Java compatible	Cambios en la funcionalidad
			compatible con Glue 4.0 y las versiones anteriores no es compatible con Glue 5.0. En Glue 5.0, se utiliza el nuevo control de acceso detallado (FGAC) nativo de Spark. Para obtener más información sobre cómo migrar a la versión 5.0 de AWS Glue, consulte Migración de trabajos de Spark para AWS Glue a la versión 5.0 de AWS Glue.

AWS GlueVersión	Versiones de entorno de tiempo de ejecución compatibles	Versión de Java compatible	Cambios en la funcionalidad

AWS Glue 4.0	Versiones del entorno Spark
	• Spark 3.3.0
	• Python 3.10
		Java 8	AWS Glue 4.0 tiene varias optimizaciones y actualizaciones integradas en esta versión de AWS Glue, como las siguientes:
			• Muchas actualizaciones de funcionalidad de Spark, de Spark 3.1 a Spark 3.3:
			  • Varias mejoras de funcionalidad cuando se combina con Pandas. Para obtener más información, consulte What's New in Spark 3.3 (Novedades de Spark 3.3).
			  • Optimizaciones adicionales desarrolladas en Amazon EMR.
			  • Actualización del sistema de archivos EMR (EMRFS) 2.53.

AWS GlueVersión	Versiones de entorno de tiempo de ejecución compatibles	Versión de Java compatible	Cambios en la funcionalidad
			• Migración a Log4j 2 desde Log4j 1.x • Varias actualizaciones de módulos de Python desde AWS Glue 3.0, como una versión actualizada de Boto. • Actualización de varios conectores, incluido el conector predeterminado de Amazon Redshift. Consulte Apéndice C: actualizaciones del conector. • Actualización de varios controladores JDBC. Consulte Apéndice B: actualizaciones de controladores JDBC. • Actualización con un nuevo conector de Amazon Redshift y un controlador JDBC. • Compatibilidad nativa con marcos

AWS GlueVersión	Versiones de entorno de tiempo de ejecución compatibles	Versión de Java compatible	Cambios en la funcionalidad
			de lagos de datos de código abierto con Apache Hudi, Delta Lake y Apache Iceberg. • Compatibilidad nativa con el complemento Cloud Shuffle Storage basado en Amazon S3 (un complemento de Apache Spark) a fin de usar Amazon S3 para la mezcla aleatoria y la capacidad de almacenamiento elástica. Limitaciones A continuación, se indican las limitaciones con AWS Glue 4.0: • AWS Glue Las transformaciones de información de identificación personal (PII) y machine learning de aún no están

AWS GlueVersión	Versiones de entorno de tiempo de ejecución compatibles	Versión de Java compatible	Cambios en la funcionalidad
			disponibles en AWS Glue 4.0. Para obtener más información sobre cómo migrar a la versión 4.0 de AWS Glue, consulte Migración de trabajos de AWS Glue para Spark a la versión 4.0 de AWS Glue.

AWS GlueVersión	Versiones de entorno de tiempo de ejecución compatibles	Versión de Java compatible	Cambios en la funcionalidad
	Versiones del entorno Ray • Ray 2.4.0 Python 3.9	N/A	Cree y ejecute aplicaciones Python distribuidas con AWS Glue para Ray. • Soporta la distribución de datos Ray-2.4.0 (`ray[data]`) con Python 3.9. Para obtener más información sobre esta versión de Ray, consulte Ray-2.4.0 en el repositorio de Ray en GitHub. • Admite la instalación de bibliotecas Python adicionales en el entorno de tiempo de ejecución `Ray2.4`. Para obtener más información, consulte the section called “Módulos de Python adicionales para trabajos de Ray”. • Integra los registros y las métricas de

AWS GlueVersión	Versiones de entorno de tiempo de ejecución compatibles	Versión de Java compatible	Cambios en la funcionalidad
			los trabajos de Ray con Amazon CloudWatch. Para obtener más información, consulte the section called “Solución de errores de Ray” y the section called “Métricas de trabajo de Ray”. • Agrega y visualiza las métricas de los trabajos de Ray en AWS Glue Studio cada página de ejecución de trabajos. • Admite la distribución de archivos en cada directorio de trabajo del clúster, el volcado de objetos del almacén de objetos de Ray a Amazon S3 y el control de la cantidad mínima de nodos de trabajo asignados al trabajo de Ray. Para obtener

AWS GlueVersión	Versiones de entorno de tiempo de ejecución compatibles	Versión de Java compatible	Cambios en la funcionalidad
			más información, consulte the section called “Parámetros de los trabajos de Ray”. Limitaciones de los trabajos de Ray en AWS Glue 4.0 • Las sesiones interactivas de AWS Glue para Ray permanecen en la vista preliminar de esta versión. • La integración de AWS Glue para Ray con Amazon VPC no está disponible actualmente. No se podrá acceder a los recursos de una VPC en AWS sin una ruta pública. Para obtener más información acerca del uso de AWS Glue con Amazon VPC, consulte the section called “Configuración de

AWS GlueVersión	Versiones de entorno de tiempo de ejecución compatibles	Versión de Java compatible	Cambios en la funcionalidad
			puntos de conexión de la VPC de tipo interfaz (AWS PrivateLink) para AWS Glue ”. • AWS Glue para Ray está disponibl e en el Este de EE. UU. (Norte de Virginia), Este de EE. UU. (Ohio), Oeste de EE. UU. (Oregón), Asia Pacífico (Tokio) y Europa (Irlanda).

AWS GlueVersión	Versiones de entorno de tiempo de ejecución compatibles	Versión de Java compatible	Cambios en la funcionalidad
AWS Glue 3.0	• Spark 3.1.1 • Python 3.7	Java 8	Además de la actualización del motor Spark a 3.0, esta versión de AWS Glue ofrece optimizaciones y actualizaciones integradas, como por ejemplo: • Construye la biblioteca de ETL de AWS Glue respecto de Spark 3.0, que es una mejora importante para Spark. • 3.0 soporta los trabajos de streaming. AWS Glue 3.0. • Incluye nuevas optimizaciones de tiempo de ejecución de AWS Glue Spark para rendimiento y fiabilidad: • Procesamiento columnar en memoria más rápido basado en Apache Arrow

AWS GlueVersión	Versiones de entorno de tiempo de ejecución compatibles	Versión de Java compatible	Cambios en la funcionalidad
			para leer datos CSV. • Ejecución basada en SIMD para lecturas vectorizadas con datos CSV. • La actualización de Spark también incluye optimizaciones adicionales desarrolladas en Amazon EMR. • EMRFS actualizado de 2.38 a 2.46, lo que permite nuevas funciones y correcciones de errores para el acceso a Amazon S3. • Se actualizaron varias dependencias necesarias para la nueva versión de Spark. • Controladores JDBC actualizados para nuestros orígenes de datos

AWS GlueVersión	Versiones de entorno de tiempo de ejecución compatibles	Versión de Java compatible	Cambios en la funcionalidad
			soportados de forma nativa. Limitaciones A continuación se indican las limitaciones con AWS Glue 3.0: • AWS Glue Las transformaciones de machine learning de aún no están disponibles en AWS Glue 3.0. • Algunos conectores de Spark personalizados no funcionan con AWS Glue 3.0 si dependen de Spark 2.4 y no son compatibles con Spark 3.1.

AWS GlueVersión	Versiones de entorno de tiempo de ejecución compatibles	Versión de Java compatible	Cambios en la funcionalidad
AWS Glue 2.0 (fin de soporte el 1 de abril de 1, 2026)	• Spark 2.4.3 • Python 3.7	N/A	Además de las características proporcionadas en la versión 1.0 de AWS Glue, la versión 2.0 de AWS Glue también ofrece lo siguiente: • Una infraestructura actualizada para ejecutar trabajos de ETL de Apache Spark en AWS Glue con tiempos de inicio reducidos. • El registro predeterminado es ahora en tiempo real, con flujos separados para controladores y ejecutores, y salidas y errores. • Soporte para especificar módulos de Python adicionales o diferentes versiones al nivel de trabajo.

AWS GlueVersión	Versiones de entorno de tiempo de ejecución compatibles	Versión de Java compatible	Cambios en la funcionalidad
			Note La versión 2.0 de AWS Glue difiere de la versión 1.0 de AWS Glue para algunas dependencias y versiones debido a cambios arquitectónicos subyacentes. Valide los trabajos de AWS Glue antes de migrar a versiones de AWS Glue posteriores.

AWS GlueVersión	Versiones de entorno de tiempo de ejecución compatibles	Versión de Java compatible	Cambios en la funcionalidad
AWS Glue 1.0 (fin de soporte el 1 de abril de 1, 2026)	• Spark 2.4.3 • Python 2.7 • Python 3.6	N/A	Puede mantener marcadores de trabajo para formatos Parquet y ORC en trabajos de ETL de AWS Glue (con AWS Glue versión 1.0). Anteriormente, solo podía marcar formatos de origen de Amazon S3 comunes, como JSON, CSV, Apache Avro y XML en trabajos de ETL de AWS Glue. Si configura opciones de formato para las entradas y salidas de ETL, puede especific ar que se utilice el formato del lector/es critor de Apache Avro 1.8 para poder leer y escribir tipos lógicos de Avro (con AWS Glue versión 1.0). Anteriormente, solo se admitía el formato del lector/escritor de la versión 1.7 de Avro.

AWS GlueVersión	Versiones de entorno de tiempo de ejecución compatibles	Versión de Java compatible	Cambios en la funcionalidad
			El tipo de conexión de DynamoDB admite una opción de escritura (con la versión 1.0 de AWS Glue). Limitaciones A continuación, se indican las limitaciones con AWS Glue 1.0: • Las versiones 0.9 y 1.0 de AWS Glue no estarán disponibles en Asia Pacífico (Yakarta) (`ap-southeast-3`), Oriente Medio (EAU) (`me-central-1`) ni en otras regiones nuevas en el futuro.

AWS GlueVersión	Versiones de entorno de tiempo de ejecución compatibles	Versión de Java compatible	Cambios en la funcionalidad
AWS Glue 0.9 (fin de soporte el 1 de abril de 1, 2026)	• Spark 2.2.1 • Python 2.7	N/A	Los trabajos que se crearon sin especificar una versión de AWS Glue se han establecido de forma predeterminada en AWS Glue 0.9. Limitaciones A continuación, se indican las limitaciones con AWS Glue 0.9: • Las versiones 0.9 y 1.0 de AWS Glue no estarán disponibles en Asia Pacífico (Yakarta) (`ap-southeast-3`), Oriente Medio (EAU) (`me-central-1`) ni en otras regiones nuevas en el futuro.

> **Note**
>
> Las siguientes versiones de Glue son compatibles con estas versiones de PythonShell:
>
> • PythonShell v3.6 es compatible con la versión 1.0 de Glue.
>
> • PythonShell v3.9 es compatible con la versión 3.0 de Glue.

Además, los puntos de conexión de desarrollo solo son compatibles con las versiones 1.0 y 0.9 de Glue.

Política de compatibilidad de versiones de AWS Glue

AWS Glue es un servicio de integración de datos sin servidor que facilita la detección, preparación y combinación de datos para el análisis, machine learning y desarrollo de aplicaciones. Un trabajo de AWS Glue contiene la lógica empresarial que realiza el trabajo de integración de datos en AWS Glue. Existen dos tipos de trabajos en AWS Glue: Spark (por lotes y streaming), Ray e intérprete de comandos de Python. Al definir un trabajo, debe especificar la versión de AWS Glue que configura las versiones en el entorno en tiempo de ejecución de Spark, Ray o Python subyacente. Por ejemplo: un trabajo de AWS Glue de la versión 5.0 de Spark admite Spark 3.5.4 y Python 3.11.

Política de soporte

Las versiones de AWS Glue se crean a partir de una combinación de sistema operativo, lenguaje de programación y bibliotecas de software que están sujetos a actualizaciones de mantenimiento y seguridad. La política de compatibilidad de la versión de AWS Glue consiste en finalizar la compatibilidad de una versión cuando algún componente importante de la versión llegue al final del soporte comunitario a largo plazo (LTS) y las actualizaciones de seguridad ya no estén disponibles. La política de soporte de versiones de AWS Glue incluye los siguientes estados:

Fin del soporte (EOS): cuando una versión de AWS Glue llega al EOS:

- AWS Glue dejará de aplicar parches de seguridad u otras actualizaciones a las versiones en EOS.
- Los trabajos de AWS Glue en versiones en EOS no son aptos para soporte técnico.
- AWS Glue puede no cumplir con los SLA cuando los trabajos se ejecuten en versiones en EOS.

Fin de vida útil (EOL): cuando una versión de AWS Glue alcanza su EOL:

- Ya no puede crear nuevos trabajos o sesiones interactivas de AWS Glue en versiones en EOL.
- Ya no puede iniciar ejecuciones de trabajos en estas versiones de AWS Glue.
- AWS Glue detendrá las ejecuciones de trabajos existentes y las sesiones interactivas en versiones en EOL.
- Las versiones en EOL se eliminarán de los SDK y las API de AWS Glue.

Las siguientes versiones de AWS Glue han llegado al fin del soporte y dejarán de estar disponibles después de la fecha de fin de vida útil. Los cambios en el estado de soporte de una versión comienzan a la medianoche (zona horaria del Pacífico) en la fecha especificada.

Tipo	Versión de Glue	Fin del soporte	Fin de vida útil
Spark	Versión de Glue 0.9 (Spark 2.2, Scala 2, Python 2)	1/6/2022	1/4/2026
Spark	Versión de Glue 1.0 (Spark 2.4, Python 2)	1/6/2022	1/4/2026
Spark	Versión de Glue 1.0 (Spark 2.4, Scala 2, Python 3)	30/9/2022	1/4/2026
Spark	Versión de Glue 2.0 (Spark 2.4, Python 3)	31/1/2024	1/4/2026
Tipo	Versión de Python	Fin del soporte	Fin de vida útil
Shell de Python	Python 2 (AWS Glue versión 1.0)	1/6/2022	1/4/2026
Shell de Python	PythonShell 3.6 (versión de Glue 1.0)	31/3/2026	N/D
Tipo	Versión del bloc de notas	Fin del soporte	Fin de vida útil
Punto de enlace de desarrollo	Bloc de notas de Zeppelin	30/9/2022	N/D

> **Note**
>
> No podrá crear nuevos trabajos de AWS Glue Python Shell 3.6 una vez que finalice el soporte el 31 de marzo de 2026, pero podrá seguir actualizando y ejecutando los trabajos

existentes. Sin embargo, los trabajos que se ejecutan en versiones discontinuadas ya no cuentan con el respaldo del soporte técnico. AWS Glue no hará revisiones de seguridad ni otras actualizaciones de las versiones discontinuadas. AWS Glue tampoco estará sujeto a los SLA cuando los trabajos se ejecuten en versiones discontinuadas.

AWS recomienda encarecidamente migrar los trabajos a versiones compatibles.

Para obtener información sobre la migración de los trabajos de Spark a la versión más reciente de AWS Glue, consulte Migración de trabajos de AWS Glue a la versión 5.0 de AWS Glue.

Para migrar los trabajos de shell de Python a la versión más reciente de AWS Glue:

- En la consola, elija `Python 3 (Glue Version 4.0)`.
- En la API CreateJob o UpdateJob, establezca el parámetro `GlueVersion` en `2.0` y `PythonVersion` en `3`, en el parámetro `Command`. La configuración de `GlueVersion` no afecta al comportamiento de los trabajos del intérprete de comandos de Python, por lo que el incremento de `GlueVersion` no supone ninguna ventaja.
- Necesita que el script de su trabajo sea compatible con Python 3.

Migración de trabajos de Spark para AWS Glue a la versión 5.0 de AWS Glue

En este tema se describen los cambios entre las versiones 0.9, 1.0, 2.0, 3.0 y 4.0 de AWS Glue para permitirle migrar sus aplicaciones de Spark y trabajos de ETL a la versión 5.0 de AWS Glue. También se describen las características de la versión 5.0 de AWS Glue y las ventajas de usarla.

Para usar esta función con sus trabajos de ETL de AWS Glue, elija **`5.0`** para la `Glue version` cuando cree sus trabajos.

Temas

- Nuevas características
- Acciones para migrar a AWS Glue 5.0
- Lista de comprobación de migración
- Características de AWS Glue 5.0
- Migración de AWS Glue 4.0 a AWS Glue 5.0

- Migración de AWS Glue 3.0 a AWS Glue 5.0
- Migración de AWS Glue 2.0 a AWS Glue 5.0
- Cambios en el comportamiento del registro en AWS Glue 5.0
- Migración de conectores y controladores JDBC para AWS Glue 5.0

Nuevas características

En esta sección se describen las nuevas características y ventajas de la versión 5.0 de AWS Glue.

- Actualización de Apache Spark de la versión 3.3.0 en AWS Glue 4.0 a la versión 3.5.4 en AWS Glue 5.0. Consulte Mejoras principales de Spark 3.3.0 a Spark 3.5.4.
- Control de acceso detallado (FGAC) nativo de Spark mediante Lake Formation. Esto incluye el FGAC para las tablas de Iceberg, Delta y Hudi. Para obtener más información, consulte Uso de AWS Glue con AWS Lake Formation para el control de acceso detallado.

  Tenga en cuenta las siguientes consideraciones o limitaciones para el FGAC nativo de Spark:

  - Actualmente, no se admiten las escrituras de datos.
  - Para escribir en Iceberg mediante `GlueContext` con Lake Formation hay que usar el control de acceso de IAM en su lugar

  Para obtener una lista completa de las limitaciones y consideraciones al usar el FGAC nativo de Spark, consulte the section called “Consideraciones”.
- La compatibilidad de las Concesiones de acceso a Amazon S3 son una solución de control de acceso escalable para los datos de Amazon S3 desde AWS Glue. Para obtener más información, consulte Uso de Concesiones de acceso a Amazon S3 con AWS Glue.
- Los formatos de tabla abierta (OTF) se actualizaron a Hudi 0.15.0, Iceberg 1.7.1 y Delta Lake 3.3.0
- Compatibilidad con Amazon SageMaker Unified Studio.
- Integración de Amazon SageMaker Lakehouse y la abstracción de datos. Para obtener más información, consulte Consulta de catálogos de datos del metastore con ETL en AWS Glue.
- Compatibilidad para instalar bibliotecas de Python adicionales mediante `requirements.txt`. Para obtener más información, consulte Instalación de bibliotecas de Python adicionales en AWS Glue 5.0 o versiones posteriores mediante requirements.txt.
- La versión 5.0 de AWS Glue admite el linaje de datos en Amazon DataZone. Puede configurar AWS Glue para recopilar automáticamente información sobre el linaje durante la ejecución de los

trabajos de Spark y enviar los eventos de linaje para verlos en Amazon DataZone. Para obtener más información, consulte Linaje de datos en Amazon DataZone.

Para configurarlo en la consola de AWS Glue, active Generar eventos de linaje e introduzca el ID de dominio de Amazon DataZone en la pestaña Detalles del trabajo.

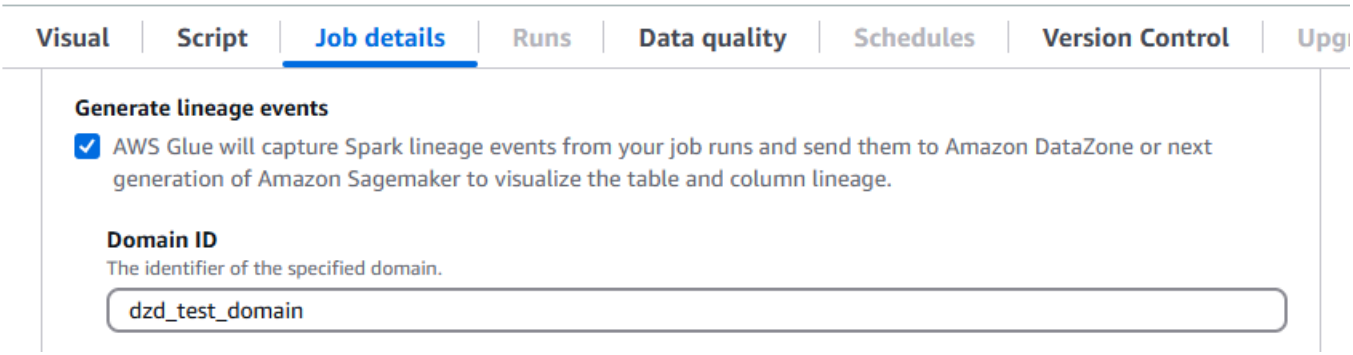

Como alternativa, puede proporcionar el siguiente parámetro de trabajo (proporcione su ID de dominio de DataZone):

- Clave: `--conf`
- Valor

```
extraListeners=io.openlineage.spark.agent.OpenLineageSparkListener
—conf spark.openlineage.transport.type=amazon_datazone_api
-conf spark.openlineage.transport.domainId=<your-domain-ID>
```

- Actualizaciones del conector y del controlador JDBC. Para obtener más información, consulte Apéndice B: actualizaciones de controladores JDBC y Apéndice C: actualizaciones del conector.
- Actualización de Java de la versión 8 a la 17.
- Mayor capacidad de almacenamiento para los procesos de trabajo `G.1X` y `G.2X` de AWS Glue, con un espacio en disco de 94 GB y 138 GB, respectivamente. Además, los nuevos tipos de trabajadores `G.12X`, `G.16X` y las versiones optimizadas para la memoria `R.1X`, `R.2X`, `R.4X` y `R.8X` están disponibles en AWS Glue versión 4.0 y versiones posteriores. Para obtener más información, consulte Jobs
- Compatibilidad con el SDK de AWS para Java (versión 2): los trabajos de AWS Glue 5.0 pueden usar las versiones de Java 1.12.569 o 2.28.8 de si el trabajo es compatible con la versión 2. AWS SDK para Java 2.x es un cambio importante con respecto a la base de código de la versión 1.x. Se basa en Java 8 y agrega varias características solicitadas con frecuencia. Entre estas se incluyen la compatibilidad con operaciones de E/S sin bloqueo y la capacidad de conectar una implementación HTTP diferente en tiempo de ejecución. Para obtener más información, incluida

una guía de migración del SDK para Java de la versión 1 a la 2, consulte la guía SDK de AWSpara Java (versión 2).

Cambios importantes

Tenga en cuenta los siguientes cambios importantes:

- En la versión 5.0 de AWS Glue, si se usa el sistema de archivos S3A y si tanto `fs.s3a.endpoint` como `fs.s3a.endpoint.region` no están configurados, la región predeterminada utilizada por S3A es `us-east-2`. Esto puede provocar problemas, como errores de tiempo de espera de carga en S3, especialmente en los trabajos de VPC. Para mitigar los problemas ocasionados por este cambio, establezca la configuración `fs.s3a.endpoint.region` de Spark cuando utilice el sistema de archivos S3A en AWS Glue 5.0.
- Control de acceso detallado de Lake Formation (FGAC)
  - AWS Glue 5.0 solo admite el nuevo FGAC nativo de Spark (FGAC) mediante Spark DataFrames. No admite FGAC mediante AWS Glue DynamicFrames.
    - Para usar FGAC en la versión 5.0, es necesario migrar de AWS Glue DynamicFrames a Spark DataFrames.
    - Si no necesita FGAC, no hace falta migrar a Spark DataFrame. Las características de GlueContext, como los marcadores de trabajos y los predicados trasladados a la fuente, se mantienen disponibles.
  - Los trabajos con FGAC nativo de Spark requieren un mínimo de 4 nodos de procesamiento: un controlador de usuario, un controlador del sistema, un ejecutor del sistema y un ejecutor de usuario en espera.
  - Para obtener más información, consulte Uso de AWS Glue con AWS Lake Formation para el control de acceso detallado.
- Acceso completo a la tabla (FTA) de Lake Formation
  - AWS Glue 5.0 admite FTA con DataFrames nativo de Spark (nuevo) y con DynamicFrames de GlueContext (heredado, con ciertas limitaciones)
  - FTA nativo de Spark
    - Si el script de la versión 4.0 utiliza GlueContext, migre al uso nativo de Spark.
    - Esta característica está disponible únicamente para tablas Hive e Iceberg
    - Para obtener más información sobre cómo configurar un trabajo en la versión 5.0 con FTA nativo de Spark, consulte

  - FTA con DynamicFrame de GlueContext
    - No es necesario modificar el código
    - Esta característica se limita a tablas que no se generan en tiempo real (no OTF) y no es compatible con Iceberg, Delta Lake ni Hudi.
- No se admite el lector SIMD CSV vectorizado.
- No se admite el registro continuo en el grupo de registro de salida. En su lugar, utilice un grupo de registro de `error`.
- El `job-insights-rule-driver` de información de ejecución de trabajos de AWS Glue ha quedado obsoleto. El flujo de registro `job-insights-rca-driver` ahora se encuentra en el grupo de registro de errores.
- No se admiten los conectores personalizados o de Marketplace basados en Athena.
- No se admiten los conectores de Adobe Marketo Engage, Facebook Ads, Google Analytics 4, Hojas de cálculo de Google, Hubspot, Instagram Ads, Intercom, Jira Cloud, Oracle NetSuite, Salesforce, Salesforce Marketing Cloud, Salesforce Marketing Cloud Account Engagement, SAP OData, ServiceNow, Slack, Snapchat Ads, Stripe, Zendesk ni Zoho CRM.
- Las propiedades personalizadas de log4j no son compatibles con AWS Glue 5.0.

Mejoras principales de Spark 3.3.0 a Spark 3.5.4

Tenga en cuenta las siguientes mejoras:

- Cliente de Python para Spark Connect (SPARK-39375).
- Posibilidad de establecer valores predeterminados para las columnas de las tablas (SPARK-38334).
- Compatibilidad con las “referencias de alias de columnas laterales” (SPARK-27561).
- Endurecimiento del uso de SQLSTATE para las clases de error (SPARK-41994).
- Habilitación de las uniones con el filtro Bloom de forma predeterminada (SPARK-38841).
- Mejora de la escalabilidad de la interfaz de usuario de Spark y de la estabilidad de los controladores para aplicaciones de gran tamaño (SPARK-41053).
- Seguimiento asíncrono del progreso en Structured Streaming (SPARK-39591).
- Procesamiento arbitrario con estado de Python en Structured Streaming (SPARK-40434).
- Mejoras en la cobertura de la API de Pandas (SPARK-42882) y compatibilidad con entradas de NumPy en PySpark (SPARK-39405).

- Generador de perfiles de memoria para las funciones definidas por el usuario de PySpark (SPARK-40281).
- Implementación de un distribuidor de PyTorch (SPARK-41589).
- Publicación de los artefactos de SBOM (SPARK-41893).
- Compatibilidad con entornos exclusivos de IPv6 (SPARK-39457).
- Disponibilidad general de programadores de K8s personalizados (Apache YuniKorn y Volcano) (SPARK-42802).
- Compatibilidad para clientes de Scala and Go en Spark Connect (SPARK-42554 y SPARK-43351).
- Compatibilidad con machine learning distribuido basado en Pytorch para Spark Connect (SPARK-42471).
- Compatibilidad con Structured Streaming para Spark Connect en Python y Scala (SPARK-42938).
- Compatibilidad con la API de Pandas para el cliente de Python Spark Connect (SPARK-42497).
- Incorporación de UDF en Python con Arrow (SPARK-40307).
- Compatibilidad con funciones de tabla definidas por el usuario en Python (SPARK-43798).
- Migración de los errores de PySpark a clases de error (SPARK-42986).
- Marco de pruebas de PySpark (SPARK-44042).
- Compatibilidad con Datasketches HLLSketch (SPARK-16484).
- Mejora de las funciones SQL integradas (SPARK-41231).
- Cláusula IDENTIFIER (SPARK-43205).
- Incorporación de funciones SQL a la API de Scala, Python y R (SPARK-43907).
- Compatibilidad con argumentos con nombre para las funciones SQL (SPARK-43922).
- Posibilidad de evitar que se vuelvan a ejecutar tareas innecesarias en un ejecutor retirado perdido si se han migrado los datos de aleatorización (SPARK-41469).
- Machine learning distribuido **<>** Spark Connect (SPARK-42471).
- Distribuidor de DeepSpeed (SPARK-44264).
- Implementación de puntos de control del registro de cambios para el almacenamiento de estado de RocksDB (SPARK-43421).
- Introducción de propagación de marcas de agua entre los operadores (SPARK-42376).
- Introducción de dropDuplicatesWithinWatermark (SPARK-42931).
- Mejoras en la administración de memoria del proveedor de almacenamiento de estado de RocksDB (SPARK-43311).

Acciones para migrar a AWS Glue 5.0

Para los trabajos existentes, cambie la `Glue version` de la versión anterior a `Glue 5.0` en la configuración del trabajo.

- En AWS Glue Studio, elija `Glue 5.0 - Supports Spark 3.5.4, Scala 2, Python 3` en `Glue version`.
- En la API, elija **`5.0`** en el parámetro `GlueVersion` de la operación de la API `UpdateJob`.

Para nuevos trabajos, elija `Glue 5.0` cuando cree un trabajo.

- En la consola, elija `Spark 3.5.4, Python 3 (Glue Version 5.0) or Spark 3.5.4, Scala 2 (Glue Version 5.0)` en `Glue version`.
- En AWS Glue Studio, elija `Glue 5.0 - Supports Spark 3.5.4, Scala 2, Python 3` en `Glue version`.
- En la API, elija **`5.0`** en el parámetro `GlueVersion` de la operación de la API `CreateJob`.

Para ver los registros de eventos de Spark de AWS Glue 5.0 procedentes de AWS Glue 2.0 o una versión anterior, active un servidor de historial de Spark actualizado para AWS Glue 5.0 mediante CloudFormation o Docker.

Lista de comprobación de migración

Revise esta lista de comprobación para la migración:

- Actualizaciones de Java 17
- [Scala] Actualización de las llamadas del SDK de AWS de la versión 1 a la versión 2
- Migración de Python 3.10 a 3.11
- [Python] Actualización de las referencias a boto de 1.26 a 1.34

Características de AWS Glue 5.0

En esta sección, se describen las características de AWS Glue con más detalle.

Consulta de catálogos de datos del metastore con ETL en AWS Glue

Puede registrar su trabajo de AWS Glue para acceder a AWS Glue Data Catalog, que pone tablas y otros recursos del metastore a disposición de consumidores dispares. El catálogo de datos admite una jerarquía de varios catálogos, que unifica todos los datos de los lagos de datos de Amazon S3. También proporciona una API del metastore de Hive y una API de Apache Iceberg de código abierto para acceder a los datos. Estas características están disponibles para AWS Glue y otros servicios orientados a los datos, como Amazon EMR, Amazon Athena y Amazon Redshift.

Al crear recursos en el catálogo de datos, puede acceder a ellos desde cualquier motor SQL compatible con la API de REST de Apache Iceberg. AWS Lake Formation se encarga de administrar los permisos. Tras la configuración, puede aprovechar las funcionalidades de AWS Glue para consultar datos dispares consultando estos recursos del metastore con aplicaciones conocidas. Entre estas se incluyen Apache Spark y Trino.

Cómo se organizan los recursos de metadatos

Los datos se organizan en una jerarquía lógica de catálogos, bases de datos y tablas, mediante AWS Glue Data Catalog:

- Catálogo: contenedor lógico que contiene objetos de un almacén de datos, como esquemas o tablas.
- Base de datos: organiza los objetos de datos de un catálogo, como tablas y vistas.
- Tablas y vistas: objetos de datos de una base de datos que proporcionan una capa de abstracción con un esquema comprensible. Facilitan el acceso a los datos subyacentes, que pueden estar en varios formatos y ubicaciones.

Migración de AWS Glue 4.0 a AWS Glue 5.0

Todos los parámetros de trabajo existentes y las principales características que existen en AWS Glue 4.0 existirán en AWS Glue 5.0, a excepción de las transformaciones de machine learning.

Se han añadido los siguientes parámetros nuevos:

- `--enable-lakeformation-fine-grained-access`: habilita la característica de control de acceso detallado (FGAC) en las tablas de AWS Lake Formation.

Consulte la documentación de migración de Spark:

- Migration Guide: Spark Core
- Migration Guide: SQL, Datasets and DataFrame
- Migration Guide: Structured Streaming
- Upgrading PySpark

Migración de AWS Glue 3.0 a AWS Glue 5.0

> **Note**
>
> Para conocer los pasos de migración relacionados con AWS Glue 4.0, consulte Migración de AWS Glue 3.0 a AWS Glue 4.0.

Todos los parámetros de trabajo existentes y las principales características que existen en AWS Glue 3.0 existirán en AWS Glue 5.0, a excepción de las transformaciones de machine learning.

Migración de AWS Glue 2.0 a AWS Glue 5.0

> **Note**
>
> Para ver los pasos de migración relacionados con AWS Glue 4.0 y una lista de las diferencias de migración entre las versiones 3.0 y 4.0 de AWS Glue, consulte Migración de AWS Glue 3.0 a AWS Glue 4.0.

Tenga en cuenta también las siguientes diferencias de migración entre las versiones 3.0 y 2.0 de AWS Glue:

- Todos los parámetros de trabajo existentes y las principales características que existen en AWS Glue 2.0 existirán en AWS Glue 5.0, a excepción de las transformaciones de machine learning.
- Varios cambios de Spark por sí solos pueden requerir la revisión de sus scripts para garantizar que no se haga referencia a las características eliminadas. Por ejemplo, Spark 3.1.1 (y versiones posteriores) no habilita UDF sin tipo Scala, pero Spark 2.4 sí los permite.
- No es compatible con Python 2.7.
- Cualquier archivo JAR adicional suministrado en trabajos de AWS Glue 2.0 puede traer dependencias conflictivas, ya que hubo actualizaciones en varias dependencias. Puede evitar conflictos de classpath con el parámetro de trabajo de `--user-jars-first`.

- Cambios en el comportamiento de cargar o guardar marcas de tiempo desde archivos de parquet y hacia ellos. Para obtener más información, consulte Actualización de Spark SQL 3.0 a 3.1
- Diferente paralelismo de tareas de Spark para la configuración del controlador/ejecutor. Puede ajustar el paralelismo de tareas pasando el argumento del trabajo `--executor-cores`.

Cambios en el comportamiento del registro en AWS Glue 5.0

A continuación se presentan los cambios en el comportamiento del registro en AWS Glue 5.0. Para obtener más información, consulte la sección Registro para trabajos de AWS Glue.

- Todos los registros (registros del sistema, registros de los daemon de Spark, registros del usuario y registros de Glue Logger) ahora se escriben de forma predeterminada en el grupo de registro `/aws-glue/jobs/error`.
- El grupo de registro `/aws-glue/jobs/logs-v2` que se usaba para el registro continuo en versiones anteriores ya no se utiliza.
- Ya no es posible cambiar ni personalizar los nombres de los grupos o flujos de registro mediante los argumentos de registro continuo que han sido eliminados. En su lugar, consulte los nuevos argumentos de trabajo disponibles en AWS Glue 5.0.

En AWS Glue 5.0 se han incorporado dos nuevos argumentos de trabajo.

- `--custom-logGroup-prefix`: permite especificar un prefijo personalizado para los grupos de registro `/aws-glue/jobs/error` y `/aws-glue/jobs/output`.
- `--custom-logStream-prefix`: permite especificar un prefijo personalizado para los nombres de los flujos de registro dentro de los grupos de registro.

  Las reglas y limitaciones de validación de los prefijos personalizados incluyen:

  - El nombre completo del flujo de registro debe tener entre 1 y 512 caracteres.
  - El prefijo personalizado de los nombres de los flujos de registro tiene un límite de 400 caracteres.
  - Los caracteres permitidos en los prefijos incluyen letras, números, guiones bajos (_), guiones (-) y barras diagonales (/).

Argumentos de registro continuo obsoletos en AWS Glue 5.0

Los siguientes argumentos de trabajo para el registro continuo se han declarado obsoletos en AWS Glue 5.0.

- `--enable-continuous-cloudwatch-log`
- `--continuous-log-logGroup`
- `--continuous-log-logStreamPrefix`
- `--continuous-log-conversionPattern`
- `--enable-continuous-log-filter`

Migración de conectores y controladores JDBC para AWS Glue 5.0

Para ver las versiones de los conectores de lago de datos y JDBC que se actualizaron, consulte:

- Apéndice B: actualizaciones de controladores JDBC
- Apéndice C: actualizaciones del conector
- Apéndice D: actualizaciones del formato de tabla abierta

Los siguientes cambios se aplican a las versiones de conector o controlador que se identifican en los apéndices de Glue 5.0.

Amazon Redshift

Tenga en cuenta los siguientes cambios:

- Compatibilidad con los nombres de tablas de tres partes para permitir que el conector consulte las tablas de intercambio de datos de Redshift.
- Corrección de la asignación de Spark `ShortType` para usar Redshift `SMALLINT` en lugar de `INTEGER` a fin de ajustarse mejor al tamaño de datos esperado.
- Compatibilidad con los nombres de clúster personalizados (CNAME) para Amazon Redshift sin servidor.

Apache Hudi

Tenga en cuenta los siguientes cambios:

- Compatibilidad con el índice de nivel de registro.
- Compatibilidad con la generación automática de claves de registro. Ya no es necesario especificar el campo de claves de registro.

Apache Iceberg

Tenga en cuenta los siguientes cambios:

- Compatibilidad con el control de acceso detallado con AWS Lake Formation.
- Compatibilidad con la ramificación y el etiquetado, que reciben nombres que hacen referencia a instantáneas con sus propios ciclos de vida independientes.
- Incorporación de un procedimiento de visualización del registro de cambios que genera una vista que contiene los cambios realizados en una tabla durante un período específico o entre instantáneas específicas.

Delta Lake

Tenga en cuenta los siguientes cambios:

- Compatibilidad con el formato universal Delta (UniForm), que permite un acceso sin problemas a través de Apache Iceberg y Apache Hudi.
- Compatibilidad con los vectores de eliminación que implementan un paradigma de tipo Fusionar al leer.

AzureCosmos

Tenga en cuenta los siguientes cambios:

- Compatibilidad con claves de partición jerárquicas.
- Incorporación de la opción de usar un esquema personalizado con StringType (JSON sin procesar) para una propiedad anidada.
- Incorporación de la opción de configuración `spark.cosmos.auth.aad.clientCertPemBase64` para permitir el uso de la autenticación SPN (nombre de ServicePrincipal) con certificado en lugar de secreto de cliente.

Para obtener más información, consulte Azure Cosmos DB Spark connector change log.

Microsoft SQL Server

Tenga en cuenta los siguientes cambios:

- El cifrado de TLS está habilitado de manera predeterminada.
- Si se establece encrypt = false, pero el servidor requiere cifrado, el certificado se valida en función de la configuración de conexión `trustServerCertificate`.
- `aadSecurePrincipalId` y `aadSecurePrincipalSecret` obsoletos.
- Se ha eliminado la API `getAADSecretPrincipalId`.
- Se agregó la resolución CNAME cuando se especifica el dominio.

MongoDB

Tenga en cuenta los siguientes cambios:

- Compatibilidad con el modo de microlotes con Spark Structured Streaming.
- Compatibilidad con tipos de datos BSON.
- Se agregó compatibilidad para leer varias colecciones cuando se utilizan los modos de transmisión continua o por microlotes.
  - Si en la opción de configuración `collection` se incluye una colección con una coma en el nombre, el conector de Spark la tratará como dos colecciones diferentes. Para evitar esto, debe aplicar un carácter de escape a la coma: antepóngale una barra invertida (\).
  - Si en la opción de configuración `collection` se incluye una colección con el nombre “*”, el conector de Spark lo interpretará como una especificación para examinar todas las colecciones. Para evitar esto, debe aplicar un carácter de escape al asterisco; para ello, antepóngale una barra invertida (\).
  - Si en la opción de configuración `collection` se incluye una colección con una barra invertida (\) en el nombre, el conector de Spark tratará la barra invertida como un carácter de escape, lo que puede cambiar la interpretación del valor. Para evitar esto, debe aplicar un carácter de escape a la barra invertida; para ello, antepóngale otra barra invertida (\).

Para obtener más información, consulte las notas de la versión del conector de MongoDB para Spark.

Snowflake

Tenga en cuenta los siguientes cambios:

- Se ha introducido un nuevo parámetro `trim_space` que puede usar para recortar automáticamente los valores de las columnas `StringType` al guardarlas en una tabla de Snowflake. Predeterminado: `false`.
- Se ha deshabilitado el parámetro `abort_detached_query` en el nivel de sesión de forma predeterminada.
- Se ha eliminado el requisito del parámetro SFUSER cuando se utiliza OAUTH.
- Se ha eliminado la característica de delegación avanzada de consultas. Tiene disponibles varias alternativas a esta característica. Por ejemplo, en lugar de cargar datos de las tablas de Snowflake, los usuarios pueden cargar directamente los datos de las consultas SQL de Snowflake.

Para obtener más información, consulte las notas de la versión de Spark para el conector de Snowflake.

Apéndice A: actualizaciones de dependencias importantes

Las siguientes son las actualizaciones de dependencias:

Dependencia	Versión en AWS Glue 5.0	Versión en AWS Glue 4.0	Versión en AWS Glue 3.0	Versión en AWS Glue 2.0	Versión en AWS Glue 1.0
Java	17	8	8	8	8
Spark	3.5.4	3.3.0-amzn-1	3.1.1-amzn-0	2.4.3	2.4.3
Hadoop	3.4.1	3.3.3-amzn-0	3.2.1-amzn-3	2.8.5-amzn-5	2.8.5-amzn-1
Scala	2.12.18	2.12	2.12	2.11	2.11
Jackson	2.15.2	2.12	2.12	2.11	2.11
Hive	2.3.9-amzn-4	2.3.9-amzn-2	2.3.7-amzn-4	1.2	1.2
EMRFS	2.69.0	2.54.0	2.46.0	2.38.0	2.30.0
Json4s	3.7.0-M11	3.7.0-M11	3.6.6	3.5.x	3.5.x

Dependencia	Versión en AWS Glue 5.0	Versión en AWS Glue 4.0	Versión en AWS Glue 3.0	Versión en AWS Glue 2.0	Versión en AWS Glue 1.0
Arrow	12.0.1	7.0.0	2.0.0	0.10.0	0.10.0
Cliente del Catálogo de datos de AWS Glue	4.5.0	3.7.0	3.0.0	1.10.0	N/A
AWS SDK para Java	2.29.52	1.12	1.12		
Python	3.11	3.10	3.7	2.7 y 3.6	2.7 y 3.6
Boto	1.34.131	1.26	1.18	1.12	N/A
Conector de DynamoDB para EMR	5.6.0	4.16.0			

Apéndice B: actualizaciones de controladores JDBC

Las siguientes son las actualizaciones de controladores JDBC:

Controlador	Versión del controlador JDBC en AWS Glue 5.0	Versión del controlador JDBC en AWS Glue 4.0	Versión del controlador JDBC en AWS Glue 3.0	Versión del controlador JDBC en las versiones de AWS Glue anteriores
MySQL	8.0.33	8.0.23	8.0.23	5.1
Microsoft SQL Server	10.2.0	9.4.0	7.0.0	6.1.0

Controlador	Versión del controlador JDBC en AWS Glue 5.0	Versión del controlador JDBC en AWS Glue 4.0	Versión del controlador JDBC en AWS Glue 3.0	Versión del controlador JDBC en las versiones de AWS Glue anteriores
Oracle Database	23.3.0.23.09	21.7	21.1	11.2
PostgreSQL	42.7.3	42.3.6	42.2.18	42.1.0
Amazon Redshift	redshift-jdbc42-2.1.0.29	redshift-jdbc42-2.1.0.16	redshift-jdbc41-1.2.12.1017	redshift-jdbc41-1.2.12.1017
SAP Hana	2.20.17	2.17.12		
Teradata	20.00.00.33	20.00.00.06		

Apéndice C: actualizaciones del conector

A continuación se indican las actualizaciones del conector:

Controlador	Versión del conector en AWS Glue 5.0	Versión del conector en AWS Glue 4.0	Versión del conector en AWS Glue 3.0
Conector de DynamoDB para EMR	5.6.0	4.16.0	
Amazon Redshift	6.4.0	6.1.3	
OpenSearch	1.2.0	1.0.1	
MongoDB	10.4.0	10.0.4	3.0.0
Snowflake	3.0.0	2.12.0	
Google BigQuery	0.32.2	0.32.2	

Controlador	Versión del conector en AWS Glue 5.0	Versión del conector en AWS Glue 4.0	Versión del conector en AWS Glue 3.0
AzureCosmos	4.33.0	4.22.0	
AzureSQL	1.3.0	1.3.0	
Vertica	3.3.5	3.3.5	

Apéndice D: actualizaciones del formato de tabla abierta

A continuación, puede ver las actualizaciones del formato de tabla abierta:

OTF	Versión del conector en AWS Glue 5.0	Versión del conector en AWS Glue 4.0	Versión del conector en AWS Glue 3.0
Hudi	0.15.0	0.12.1	0.10.1
Delta Lake	3.3.0	2.1.0	1.0.0
Iceberg	1.7.1	1.0.0	0.13.1

Migración de trabajos de AWS Glue para Spark a la versión 4.0 de AWS Glue

En este tema se describen los cambios entre las versiones 0.9, 1.0, 2.0 y 3.0 de AWS Glue para permitirle migrar sus aplicaciones de Spark y trabajos de ETL a AWS Glue 4.0. También se describen las características de la versión 4.0 de AWS Glue y las ventajas de usarla.

Para usar esta función con sus trabajos de ETL de AWS Glue, elija **`4.0`** para la `Glue version` cuando cree sus trabajos.

Temas

- Características nuevas admitidas
- Acciones que migrar a AWS Glue 4.0
- Lista de comprobación de migración

- Migración de AWS Glue 3.0 a AWS Glue 4.0
- Migración de AWS Glue 2.0 a AWS Glue 4.0
- Migración de AWS Glue 1.0 a AWS Glue 4.0
- Migración de AWS Glue 0.9 a AWS Glue 4.0
- Migración de conectores y controladores JDBC para AWS Glue 4.0
- Apéndice A: actualizaciones de dependencias importantes
- Apéndice B: actualizaciones de controladores JDBC
- Apéndice C: actualizaciones del conector

Características nuevas admitidas

En esta sección se describen las nuevas características y ventajas de la versión 4.0 de AWS Glue.

- Se basa en Apache Spark 3.3.0, pero incluye optimizaciones en AWS Glue y Amazon EMR, tales como ejecuciones de consultas adaptativas, lectores vectorizados y combinación de particiones y mezclas aleatorias optimizadas.
- Controladores JDBC actualizados para todos los orígenes nativos de AWS Glue, que incluyen MySQL, Microsoft SQL Server, Oracle, PostgreSQL, MongoDB, y bibliotecas y dependencias de Spark actualizadas introducidas por Spark 3.3.0.
- Actualización con un nuevo conector de Amazon Redshift y un controlador JDBC.
- Acceso optimizado a Amazon S3 con el sistema de archivos EMR (EMRFS) actualizado y confirmadores de salida optimizados de Amazon S3 habilitados de forma predeterminada.
- Acceso optimizado al Catálogo de datos con índices de partición, predicados de inserción, lista de particiones y un cliente de metaalmacén de Hive actualizado.
- Integración con Lake Formation para tablas de catálogo gobernadas con filtrado a nivel de celda y transacciones de lago de datos.
- Reducción de la latencia de inicio para mejorar los tiempos generales de finalización del trabajo y la interactividad.
- Los trabajos de Spark se facturan en incrementos de 1 segundo con una duración mínima de facturación 10 veces menor, de un mínimo de 10 minutos a un mínimo de 1 minuto.
- Compatibilidad nativa con marcos de lagos de datos de código abierto con Apache Hudi, Delta Lake y Apache Iceberg.

- Compatibilidad nativa con el complemento Cloud Shuffle Storage basado en Amazon S3 (un complemento de Apache Spark) a fin de usar Amazon S3 para la mezcla aleatoria y la capacidad de almacenamiento elástica.

Mejoras principales de Spark 3.1.1 a Spark 3.3.0

Tenga en cuenta las siguientes mejoras:

- Filtrado en tiempo de ejecución de fila (SPARK-32268).
- Mejoras de ANSI (SPARK-38860).
- Mejoras de los mensajes de error (SPARK-38781).
- Compatibilidad de tipos complejos con el lector vectorizado de Parquet (SPARK-34863).
- Compatibilidad de metadatos de archivos ocultos con Spark SQL (SPARK-37273).
- Se proporciona un generador de perfiles para las UDF de Python o Pandas (SPARK-37443).
- Se introduce Trigger.AvailableNow para ejecutar consultas de transmisión como Trigger.Once en varios lotes (SPARK-36533).
- Capacidades de inserción de Datasource V2 más completas (SPARK-38788).
- Migración de log4j 1 a log4j 2 (SPARK-37814).

Otros cambios notables

Tenga en cuenta los siguientes cambios:

- Cambios importantes
  - Se eliminan las referencias a la compatibilidad con Python 3.6 en los documentos y documentación de Python (SPARK-36977).
  - Se elimina el truco de tupla con nombre al reemplazar el objeto pickle integrado por cloudpickle (SPARK-32079).
  - Se incrementa la versión mínima de Pandas a la 1.0.5 (SPARK-37465).

Acciones que migrar a AWS Glue 4.0

Para los trabajos existentes, cambie la `Glue version` de la versión anterior a `Glue 4.0` en la configuración del trabajo.

- En AWS Glue Studio, elija `Glue 4.0 - Supports Spark 3.3, Scala 2, Python 3` en `Glue version`.
- En la API, elija **`4.0`** en el parámetro `GlueVersion` de la operación de la API `UpdateJob`.

Para nuevos trabajos, elija `Glue 4.0` cuando cree un trabajo.

- En la consola, elija `Spark 3.3, Python 3 (Glue Version 4.0) or Spark 3.3, Scala 2 (Glue Version 3.0)` en `Glue version`.
- En AWS Glue Studio, elija `Glue 4.0 - Supports Spark 3.3, Scala 2, Python 3` en `Glue version`.
- En la API, elija **`4.0`** en el parámetro `GlueVersion` de la operación de la API `CreateJob`.

Para ver los registros de eventos de Spark de AWS Glue 4.0 procedentes de AWS Glue 2.0 o una versión anterior, lance un servidor de historial de Spark actualizado para AWS Glue 4.0 mediante CloudFormation o Docker.

Lista de comprobación de migración

- ¿Las bibliotecas externas de Python de su trabajo dependen de Python 2.7/3.6?
  - Actualice las bibliotecas dependientes de Python 2.7 o 3.6 a Python 3.10, ya que Spark 3.3.0 eliminó por completo la compatibilidad con Python 2.7 y 3.6.

Migración de AWS Glue 3.0 a AWS Glue 4.0

Tenga en cuenta los siguientes cambios al migrar:

- Todos los parámetros de trabajo existentes y las principales características que existen en AWS Glue 3.0 existirán en AWS Glue 4.0.
- AWS Glue 3.0 utiliza Spark 3.1.1 optimizado para Amazon EMR y AWS Glue 4.0 utiliza Spark 3.3.0 optimizado para Amazon EMR.

  Es posible que varios cambios de Spark por sí solos requieran la revisión de sus scripts para garantizar que no se haga referencia a las características eliminadas.
- AWS Glue 4.0 también incluye una actualización de EMRFS y Hadoop. Para saber la versión específica, consulte Apéndice A: actualizaciones de dependencias importantes.

- La versión de AWS SDK que se proporciona en los trabajos de ETL ahora se ha actualizado de la 1.11 a la 1.12.
- Todos los trabajos de Python utilizarán la versión 3.10 de Python. Anteriormente, Python 3.7 se usaba en AWS Glue 3.0.

  Como resultado, se actualizan algunos pymodules que AWS Glue incluye listos para usar.
- Log4j se ha actualizado a Log4j2.
  - Para obtener información sobre la ruta de migración de Log4j2, consulte la documentación de Log4j.
  - En su lugar, debe cambiar el nombre de cualquier archivo log4j.properties personalizado a un archivo log4j2.properties, con las propiedades de log4j2 adecuadas.
- Para migrar determinados conectores, consulte Migración de conectores y controladores JDBC para AWS Glue 4.0.
- Se actualizó el SDK de cifrado de AWS de 1.x a 2.x. Se ven afectados los trabajos de AWS Glue que utilizan configuraciones de seguridad de AWS Glue y los trabajos que dependen de la dependencia del SDK de cifrado de AWS proporcionada en tiempo de ejecución. Consulte las instrucciones para la migración de trabajos de AWS Glue.

  Puede actualizar de forma segura un trabajo de AWS Glue 2.0 o 3.0 a un trabajo de AWS Glue 4.0 porque AWS Glue 2.0 o 3.0 ya contiene la versión puente del SDK de cifrado de AWS.

Consulte la documentación de migración de Spark:

- Upgrading from Spark SQL 3.1 to 3.2 (Actualización de Spark SQL 3.1 a 3.2)
- Upgrading from Spark SQL 3.2 to 3.3 (Actualización de Spark SQL 3.2 a 3.3)

Migración de AWS Glue 2.0 a AWS Glue 4.0

Tenga en cuenta los siguientes cambios al migrar:

> **Note**
>
> Para conocer los pasos de migración relacionados con AWS Glue 3.0, consulte Migración de AWS Glue 3.0 a AWS Glue 4.0.

- Todos los parámetros de trabajo existentes y las principales características que existen en AWS Glue 2.0 existirán en AWS Glue 4.0.
- El confirmador optimizado para S3 de EMRFS para la escritura de datos de Parquet en Amazon S3 está habilitado de forma predeterminada a partir de AWS Glue 3.0. Sin embargo, todavía puede desactivarlo mediante la configuración de `--enable-s3-parquet-optimized-committer` a `false`.
- AWS Glue 2.0 utiliza la versión 2.4 de Spark de código abierto y AWS Glue 4.0, la versión 3.3.0 optimizada para Amazon EMR.
  - Varios cambios de Spark por sí solos pueden requerir la revisión de sus scripts para garantizar que no se haga referencia a las características eliminadas.
  - Por ejemplo, Spark 3.3.0 no permite las UDF sin tipo Scala, pero Spark 2.4 sí.
- La versión de AWS SDK que se proporciona en los trabajos de ETL ahora se ha actualizado de la 1.11 a la 1.12.
- AWS Glue 4.0 también incluye una actualización de EMRFS, controladores JDBC actualizados e inclusiones de optimizaciones adicionales en Spark proporcionadas por AWS Glue.
- Scala se actualiza a la versión 2.12 desde la 2.11, y Scala 2.12 no es compatible con Scala 2.11.
- Python 3.10 es la versión predeterminada utilizada para los scripts de Python, ya que AWS Glue 2.0 solo utilizaba Python 3.7 y 2.7.
  - Python 2.7 no es compatible con Spark 3.3.0. Cualquier trabajo que solicite Python 2 en la configuración del trabajo producirá un error con IllegalArgumentException.
  - Hay disponible un nuevo mecanismo para instalar módulos adicionales de Python a partir de AWS Glue 2.0.
- Varias actualizaciones de dependencias, destacadas en Apéndice A: actualizaciones de dependencias importantes.
- Cualquier archivo JAR adicional suministrado en trabajos existentes de AWS Glue 2.0 puede traer dependencias conflictivas, ya que hubo actualizaciones en varias dependencias en la versión 4.0 con respecto a la 2.0. Puede evitar conflictos de classpath en AWS Glue 4.0 con el parámetro de trabajo `--user-jars-first` de AWS Glue.
- AWS Glue 4.0 usa Spark 3.3. A partir de Spark 3.1, se produjo un cambio en el comportamiento de cargar/guardar marcas de tiempo desde archivos de parquet y hacia estos. Para obtener más información, consulte Actualización de Spark SQL 3.0 a 3.1

  Recomendamos establecer los siguientes parámetros al leer y escribir datos de parquet que contengan columnas de marca temporal. La configuración de estos parámetros puede resolver el

problema de incompatibilidad del calendario que se produce durante la actualización de Spark 2 a Spark 3, tanto para el marco dinámico de AWS Glue como para el marco de datos de Spark. Utilice la opción CORRECTED para leer el valor de fecha y hora tal como está; y la opción LEGACY para rebasar los valores de fecha y hora con respecto a la diferencia de calendario durante la lectura.

```
- Key: --conf
- Value: spark.sql.legacy.parquet.int96RebaseModeInRead=[CORRECTED|LEGACY] --
conf spark.sql.legacy.parquet.int96RebaseModeInWrite=[CORRECTED|LEGACY] --conf
 spark.sql.legacy.parquet.datetimeRebaseModeInRead=[CORRECTED|LEGACY]
```

- Para migrar determinados conectores, consulte Migración de conectores y controladores JDBC para AWS Glue 4.0.
- Se actualizó el SDK de cifrado de AWS de 1.x a 2.x. Se ven afectados los trabajos de AWS Glue que utilizan configuraciones de seguridad de AWS Glue y los trabajos que dependen de la dependencia del SDK de cifrado de AWS proporcionada en tiempo de ejecución. Consulte estas instrucciones para la migración de trabajos de AWS Glue:
  - Puede actualizar de forma segura un trabajo de AWS Glue 2.0 a un trabajo de AWS Glue 4.0 porque AWS Glue 2.0 ya contiene la versión puente del SDK de cifrado de AWS.

Consulte la documentación de migración de Spark:

- Upgrading from Spark SQL 2.4 to 3.0 (Actualización de Spark SQL 2.4 a 3.0)
- Upgrading from Spark SQL 3.1 to 3.2 (Actualización de Spark SQL 3.1 a 3.2)
- Upgrading from Spark SQL 3.2 to 3.3 (Actualización de Spark SQL 3.2 a 3.3)
- Changes in Datetime behavior to be expected since Spark 3.0 (Cambios en el comportamiento de Datetime que se esperan a partir de Spark 3.0).

Migración de AWS Glue 1.0 a AWS Glue 4.0

Tenga en cuenta los siguientes cambios al migrar:

- AWS Glue 1.0 utiliza la versión 2.4 de Spark de código abierto y AWS Glue 4.0, la versión 3.3.0 optimizada para Amazon EMR.
  - Varios cambios de Spark por sí solos pueden requerir la revisión de sus scripts para garantizar que no se haga referencia a las características eliminadas.
  - Por ejemplo, Spark 3.3.0 no permite las UDF sin tipo Scala, pero Spark 2.4 sí.

- Todos los trabajos de AWS Glue 4.0 se ejecutarán con tiempos de inicio significativamente mejorados. Los trabajos de Spark se facturarán en incrementos de 1 segundo con una duración mínima de facturación 10 veces menor, ya que la latencia de inicio pasará de 10 minutos máximo a 1 minuto máximo.
- El comportamiento del registro cambió significativamente en AWS Glue 4.0; Spark 3.3.0 tiene un requisito mínimo de Log4j2.
- Varias actualizaciones de dependencias, que se destacan en el apéndice.
- Scala también se actualiza a la versión 2.12 desde la 2.11, y Scala 2.12 no es compatible con Scala 2.11.
- Python 3.10 es también la versión predeterminada utilizada para los scripts de Python, ya que AWS Glue 0.9 solo utilizaba Python 2.

  Python 2.7 no es compatible con Spark 3.3.0. Cualquier trabajo que solicite Python 2 en la configuración del trabajo producirá un error con IllegalArgumentException.
- Hay disponible un nuevo mecanismo para instalar módulos adicionales de Python mediante pip a partir de AWS Glue 2.0. Para obtener más información, consulte Instalación de módulos de Python adicionales con pip en AWS Glue 2.0+.
- AWS Glue 4.0 no se ejecuta en Apache YARN, por lo que la configuración de YARN no se aplica.
- AWS Glue 4.0 no tiene un Sistema de archivos distribuido de Hadoop (HDFS).
- Cualquier archivo JAR adicional suministrado en trabajos existentes de AWS Glue 1.0 puede traer dependencias conflictivas, ya que hubo actualizaciones en varias dependencias en la versión 4.0 con respecto a la 1.0. Habilitamos AWS Glue 4.0 con el parámetro de trabajo de AWS Glue `--user-jars-first` de forma predeterminada para evitar este problema.
- AWS Glue 4.0 admite el escalado automático. Por lo tanto, la métrica ExecutorAllocationManager estará disponible cuando se habilite el escalado automático.
- Para trabajos de la versión 4.0 de AWS Glue, debe especificar el número de procesos de trabajo y el tipo de proceso de trabajo, pero no un valor de `maxCapacity`.
- Los trabajos de AWS Glue 4.0 todavía no admiten transformaciones de machine learning.
- Para migrar determinados conectores, consulte Migración de conectores y controladores JDBC para AWS Glue 4.0.
- Se actualizó el SDK de cifrado de AWS de 1.x a 2.x. Se ven afectados los trabajos de AWS Glue que utilizan configuraciones de seguridad de AWS Glue y los trabajos que dependen de la dependencia del SDK de cifrado de AWS proporcionada en tiempo de ejecución. Consulte estas instrucciones para la migración de trabajos de AWS Glue.

- No puede migrar ningún trabajo de AWS Glue 0.9 o 1.0 a un trabajo de AWS Glue 4.0 directamente. Esto se debe a que, al actualizar directamente a la versión 2.x o una posterior y habilitar todas las características nuevas de inmediato, el SDK de cifrado de AWS no podrá descifrar el texto cifrado en versiones anteriores del SDK de cifrado de AWS.
- Para llevar a cabo la actualización de forma segura, primero le recomendamos que migre a un trabajo de AWS Glue 2.0 o 3.0 que contenga la versión puente del SDK de cifrado de AWS. Ejecute el trabajo una vez para utilizar la versión puente del SDK de cifrado de AWS.
- Al finalizar, puede migrar de forma segura el trabajo de AWS Glue 2.0 o 3.0 a AWS Glue 4.0.

Consulte la documentación de migración de Spark:

- Upgrading from Spark SQL 2.4 to 3.0 (Actualización de Spark SQL 2.4 a 3.0)
- Upgrading from Spark SQL 3.0 to 3.1 (Actualización de Spark SQL 3.0 a 3.1)
- Upgrading from Spark SQL 3.1 to 3.2 (Actualización de Spark SQL 3.1 a 3.2)
- Upgrading from Spark SQL 3.2 to 3.3 (Actualización de Spark SQL 3.2 a 3.3)
- Changes in Datetime behavior to be expected since Spark 3.0 (Cambios en el comportamiento de Datetime que se esperan a partir de Spark 3.0).

Migración de AWS Glue 0.9 a AWS Glue 4.0

Tenga en cuenta los siguientes cambios al migrar:

- AWS Glue 0.9 utiliza la versión 2.2.1 de Spark de código abierto y AWS Glue 4.0, la versión 3.3.0 optimizada para Amazon EMR.
  - Es posible que varios cambios de Spark por sí solos requieran la revisión de sus scripts para garantizar que no se haga referencia a las características eliminadas.
  - Por ejemplo, Spark 3.3.0 no permite las UDF sin tipo Scala, pero Spark 2.2 sí.
- Todos los trabajos de AWS Glue 4.0 se ejecutarán con tiempos de inicio significativamente mejorados. Los trabajos de Spark se facturarán en incrementos de 1 segundo con una duración mínima de facturación 10 veces menor, porque la latencia de inicio pasará de un máximo de 10 minutos a un máximo de 1 minuto.
- El comportamiento del registro cambió significativamente a partir de AWS Glue 4.0; Spark 3.3.0 tiene un requisito mínimo de Log4j2, como se menciona aquí (https://spark.apache.org/docs/latest/core-migration-guide.html#upgrading-from-core-32-to-33).

- Varias actualizaciones de dependencias, que se destacan en el apéndice.
- Scala también se actualiza a la versión 2.12 desde la 2.11, y Scala 2.12 no es compatible con Scala 2.11.
- Python 3.10 es también la versión predeterminada utilizada para los scripts de Python, ya que AWS Glue 0.9 solo utilizaba Python 2.
  - Python 2.7 no es compatible con Spark 3.3.0. Cualquier trabajo que solicite Python 2 en la configuración del trabajo producirá un error con IllegalArgumentException.
  - Hay disponible un nuevo mecanismo para instalar módulos adicionales de Python mediante pip.
- AWS Glue 4.0 no se ejecuta en Apache YARN, por lo que la configuración de YARN no se aplica.
- AWS Glue 4.0 no tiene un Sistema de archivos distribuido de Hadoop (HDFS).
- Cualquier archivo JAR adicional suministrado en trabajos existentes de AWS Glue 0.9 puede traer dependencias conflictivas, ya que hubo actualizaciones en varias dependencias en la versión 3.0 con respecto a la 0.9. Puede evitar conflictos de classpath en AWS Glue 3.0 con el parámetro de trabajo `--user-jars-first` de AWS Glue.
- AWS Glue 4.0 admite el escalado automático. Por lo tanto, la métrica ExecutorAllocationManager estará disponible cuando se habilite el escalado automático.
- Para trabajos de la versión 4.0 de AWS Glue, debe especificar el número de procesos de trabajo y el tipo de proceso de trabajo, pero no un valor de `maxCapacity`.
- Los trabajos de AWS Glue 4.0 todavía no admiten transformaciones de machine learning.
- Para migrar determinados conectores, consulte Migración de conectores y controladores JDBC para AWS Glue 4.0.
- Se actualizó el SDK de cifrado de AWS de 1.x a 2.x. Se ven afectados los trabajos de AWS Glue que utilizan configuraciones de seguridad de AWS Glue y los trabajos que dependen de la dependencia del SDK de cifrado de AWS proporcionada en tiempo de ejecución. Consulte estas instrucciones para la migración de trabajos de AWS Glue.
  - No puede migrar ningún trabajo de AWS Glue 0.9 o 1.0 a un trabajo de AWS Glue 4.0 directamente. Esto se debe a que, al actualizar directamente a la versión 2.x o una posterior y habilitar todas las características nuevas de inmediato, el SDK de cifrado de AWS no podrá descifrar el texto cifrado en versiones anteriores del SDK de cifrado de AWS.
  - Para llevar a cabo la actualización de forma segura, primero le recomendamos que migre a un trabajo de AWS Glue 2.0 o 3.0 que contenga la versión puente del SDK de cifrado de AWS. Ejecute el trabajo una vez para utilizar la versión puente del SDK de cifrado de AWS.
  - Al finalizar, puede migrar de forma segura el trabajo de AWS Glue 2.0 o 3.0 a AWS Glue 4.0.

Consulte la documentación de migración de Spark:

- Upgrading from Spark SQL 2.2 to 2.3 (Actualización de Spark SQL 2.2 a 2.3)
- Upgrading from Spark SQL 2.3 to 2.4 (Actualización de Spark SQL 2.3 a 2.4)
- Upgrading from Spark SQL 2.4 to 3.0 (Actualización de Spark SQL 2.4 a 3.0)
- Upgrading from Spark SQL 3.0 to 3.1 (Actualización de Spark SQL 3.0 a 3.1)
- Upgrading from Spark SQL 3.1 to 3.2 (Actualización de Spark SQL 3.1 a 3.2)
- Upgrading from Spark SQL 3.2 to 3.3 (Actualización de Spark SQL 3.2 a 3.3)
- Changes in Datetime behavior to be expected since Spark 3.0 (Cambios en el comportamiento de Datetime que se esperan a partir de Spark 3.0).

Migración de conectores y controladores JDBC para AWS Glue 4.0

Para ver las versiones de los conectores de lago de datos y JDBC que se actualizaron, consulte:

- Apéndice B: actualizaciones de controladores JDBC
- Apéndice C: actualizaciones del conector

Hudi

- Mejoras de compatibilidad de Spark SQL:
  - A través del comando `Call Procedure`, se agrega compatibilidad para actualizar, degradar, arrancar, limpiar y reparar. La sintaxis `Create/Drop/Show/Refresh Index` es posible en Spark SQL.
  - Se cerró una laguna de rendimiento entre el uso mediante un DataSource de Spark en comparación con Spark SQL. En el pasado, las escrituras en orígenes de datos solían ser más rápidas que en SQL.
  - Todos los generadores de claves integrados implementan operaciones de API específicas de Spark de mayor rendimiento.
  - Se sustituyó la transformación de UDF en la operación masiva `insert` por transformaciones de RDD para reducir los costos de uso de SerDe.
  - Spark SQL con Hudi requiere que se especifique un campo `primaryKey` mediante `tblproperites` u opciones en la instrucción SQL. En el caso de las operaciones de actualización y eliminación, también se requiere el campo `preCombineField`.

- Cualquier tabla de Hudi creada antes de la versión 0.10.0 sin un campo `primaryKey` tiene que volver a crearse con un campo `primaryKey` a partir de la versión 0.10.0.

PostgreSQL

- Se corrigieron varias vulnerabilidades (CVE).
- Java 8 es compatible de forma nativa.
- Si el trabajo utiliza matrices de matrices, con la excepción de las matrices de bytes, dicho escenario se puede tratar como matrices multidimensionales.

MongoDB

- El conector de MongoDB actual es compatible con la versión 3.1 o posteriores de Spark y con la versión 4.0 o posteriores de MongoDB.
- Debido a la actualización del conector, se modificaron los nombres de algunas propiedades. Por ejemplo, el nombre de la propiedad de URI se cambió a `connection.uri`. Para obtener más información sobre las opciones actuales, consulte el blog sobre el conector de Spark de MongoDB.
- El uso de la versión 4.0 de MongoDB alojada por Amazon DocumentDB presenta algunas diferencias funcionales. Para obtener más información, consulte estos temas:
  - Functional Differences: Amazon DocumentDB and MongoDB (Diferencias funcionales: Amazon DocumentDB y MongoDB)
  - API, operaciones y tipos de datos de MongoDB compatibles.
- La opción “partitioner” se restringe a `ShardedPartitioner`, `PaginateIntoPartitionsPartitioner` y `SinglePartitionPartitioner`. No puede usar los valores predeterminados `SamplePartitioner` y `PaginateBySizePartitioner` para Amazon DocumentDB porque el operador de etapas no admite la API de MongoDB. Para obtener más información, consulte Supported MongoDB APIs, Operations, and Data Types (API, operaciones y tipos de datos de MongoDB admitidos).

Delta Lake

- Delta Lake ahora admite viajes en el tiempo en SQL para consultar datos antiguos con facilidad. Con esta actualización, los viajes en el tiempo ahora están disponibles tanto en Spark SQL como a través de la API de DataFrame. Se agregó compatibilidad con la versión actual de TIMESTAMP en SQL.

- Spark 3.3 presenta Trigger.AvailableNow para ejecutar consultas de transmisión como equivalente a `Trigger.Once` para las consultas por lotes. Esta compatibilidad también está disponible cuando se utilizan tablas Delta como origen de transmisión.
- Compatibilidad con SHOW COLUMNS para devolver la lista de columnas de una tabla.
- Compatibilidad con DESCRIBE DETAIL en la API de DeltaTable de Python y Scala. Recupera información detallada sobre una tabla Delta mediante la API de DeltaTable o Spark SQL.
- Compatibilidad para devolver métricas de operaciones de los comandos Delete, Merge y Update de SQL. Anteriormente, estos comandos de SQL devolvían un DataFrame vacío y ahora devuelven un DataFrame con métricas útiles sobre la operación hecha.
- Optimice las mejoras de rendimiento:
  - Defina la opción de configuración `spark.databricks.delta.optimize.repartition.enabled=true` para usar `repartition(1)` en lugar de `coalesce(1)` en el comando Optimize para obtener un mejor rendimiento al compactar muchos archivos pequeños.
  - Rendimiento mejorado mediante el uso de un enfoque basado en colas para paralelizar los trabajos de compactación.
- Otros cambios notables:
  - Compatibilidad con el uso de variables en los comandos de SQL VACUUM y OPTIMIZE.
  - Mejoras para CONVERT TO DELTA con tablas de catálogo que incluyen lo siguiente:
    - Rellenado automático del esquema de particiones a partir del catálogo cuando no se proporciona.
    - Uso de la información de particiones del catálogo para buscar los archivos de datos que se van a confirmar en lugar de analizar el directorio por completo. En lugar de enviar todos los archivos de datos del directorio de tablas, solo se confirmarán los archivos de datos de los directorios de las particiones activas.
  - Compatibilidad con las lecturas por lotes de cambio de fuente de datos (CDF) en las tablas habilitadas para la asignación de columnas cuando no se utilizaron DROP COLUMN y RENAME COLUMN. Para obtener más información, consulte la documentación de Delta Lake.
  - Mejora del rendimiento del comando Update al habilitar la eliminación de esquemas en la primera aprobación.

Apache Iceberg

- Se agregaron varias mejoras de rendimiento para la planificación de análisis y las consultas de Spark.
- Se agregó un cliente de catálogo REST común que usa confirmaciones basadas en cambios para resolver conflictos de confirmación en el lado del servicio.
- Se admite la sintaxis `AS OF` para las consultas de viajes en el tiempo de SQL.
- Se agregó compatibilidad de combinación en lectura para las consultas MERGE y UPDATE.
- Se agregó compatibilidad para reescribir particiones con el orden Z.
- Se agregaron una especificación y una implementación para Puffin, un formato para estadísticas y blobs de índice grandes, como bocetos de Theta o filtros de Bloom.
- Se agregaron nuevas interfaces para consumir datos de forma incremental (análisis de registros de cambios y anexos).
- Se agregó compatibilidad con operaciones masivas y lecturas por intervalos en las interfaces de FileIO.
- Se agregaron más tablas de metadatos para mostrar los archivos eliminados en el árbol de metadatos.
- El comportamiento de eliminación de tabla cambió. En Iceberg 0.13.1, la ejecución de `DROP TABLE` elimina la tabla del catálogo, así como su contenido. En Iceberg 1.0.0, `DROP TABLE` solo elimina la tabla del catálogo. Para eliminar el contenido de la tabla, utilice `DROP TABLE PURGE`.
- Las lecturas vectorizadas de Parquet están habilitadas de forma predeterminada en Iceberg 1.0.0. Si desea deshabilitar las lecturas vectorizadas, establezca el valor de `read.parquet.vectorization.enabled` en `false`.

Oracle

Se hicieron pequeños cambios.

MySQL

Se hicieron pequeños cambios.

Amazon Redshift

AWS Glue 4.0 incluye un nuevo conector de Amazon Redshift con un nuevo controlador JDBC. Para obtener información sobre las mejoras y sobre cómo llevar a cabo la migración desde versiones anteriores de AWS Glue, consulte the section called “Conexiones Redshift”.

Apéndice A: actualizaciones de dependencias importantes

Las siguientes son las actualizaciones de dependencias:

Dependencia	Versión en AWS Glue 4.0	Versión en AWS Glue 3.0	Versión en AWS Glue 2.0	Versión en AWS Glue 1.0
Spark	3.3.0-amzn-1	3.1.1-amzn-0	2.4.3	2.4.3
Hadoop	3.3.3-amzn-0	3.2.1-amzn-3	2.8.5-amzn-5	2.8.5-amzn-1
Scala	2.12	2.12	2.11	2.11
Jackson	2.13.3	2.10.x	2.7.x	2.7.x
Hive	2.3.9-amzn-2	2.3.7-amzn-4	1.2	1.2
EMRFS	2.54.0	2.46.0	2.38.0	2.30.0
Json4s	3.7.0-M11	3.6.6	3.5.x	3.5.x
Arrow	7.0.0	2.0.0	0.10.0	0.10.0
Cliente del Catálogo de datos de AWS Glue	3.7.0	3.0.0	1.10.0	N/A
Python	3.10	3.7	2.7 y 3.6	2.7 y 3.6
Boto	1.26	1.18	1.12	N/A

Apéndice B: actualizaciones de controladores JDBC

Las siguientes son las actualizaciones de controladores JDBC:

Controlador	Versión del controlador JDBC en las versiones de AWS Glue anteriores	Versión del controlador JDBC en AWS Glue 3.0	Versión del controlador JDBC en AWS Glue 4.0
MySQL	5.1	8.0.23	8.0.23
Microsoft SQL Server	6.1.0	7.0.0	9.4.0
Oracle Database	11.2	21.1	21.7
PostgreSQL	42.1.0	42.2.18	42.3.6
MongoDB	2.0.0	4.0.0	4.7.2
Amazon Redshift	redshift-jdbc41-1.2.12.1017	redshift-jdbc41-1.2.12.1017	redshift-jdbc42-2.1.0.16

Apéndice C: actualizaciones del conector

A continuación se indican las actualizaciones del conector:

Controlador	Versión del conector en AWS Glue 3.0	Versión del conector en AWS Glue 4.0
MongoDB	3.0.0	10.0.4
Hudi	0.10.1	0.12.1
Delta Lake	1.0.0	2.1.0
Iceberg	0.13.1	1.0.0
DynamoDB	1.11	1.12

Actualizaciones de IA generativa para Apache Spark en AWS Glue

La función Actualizaciones de Spark en AWS Glue permite que los ingenieros de datos y desarrolladores actualicen y migren sus trabajos actuales de Spark de AWS Glue a las versiones más recientes de Spark mediante la IA generativa. Los ingenieros de datos pueden utilizarla para escanear sus trabajos de Spark de AWS Glue, generar planes de actualización, ejecutar planes y validar los resultados. Reduce el tiempo y el costo de las actualizaciones de Spark al automatizar el trabajo indiferenciado de identificar y actualizar los scripts, las configuraciones, las dependencias, los métodos y las características de Spark.

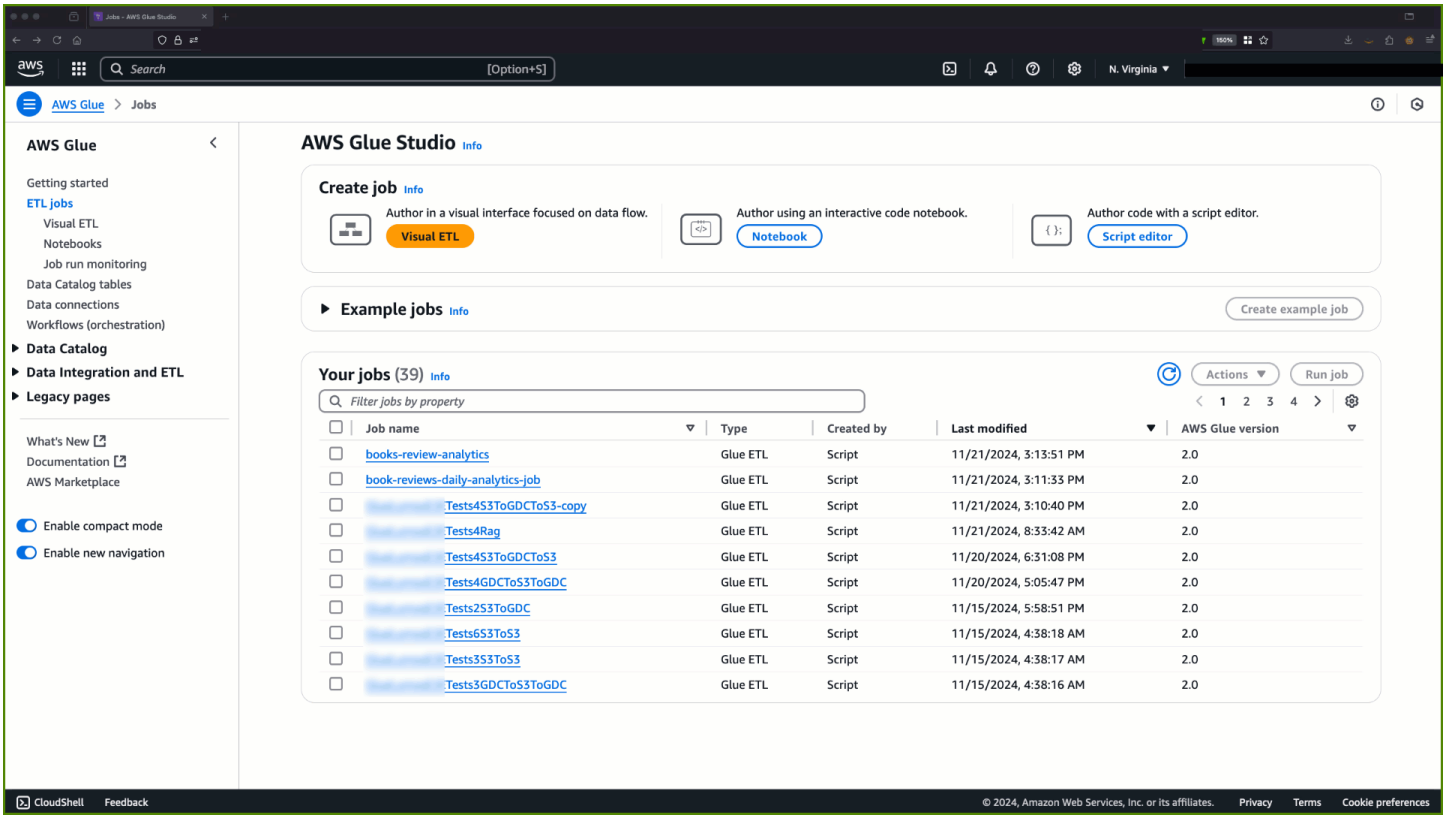

Funcionamiento

Cuando utiliza el análisis de actualizaciones, AWS Glue identifica las diferencias entre las versiones y las configuraciones en el código del trabajo para generar un plan de actualización. El plan de actualización detalla todos los cambios de código y los pasos de migración necesarios. A continuación, AWS Glue crea y ejecuta la aplicación actualizada en un entorno para validar los cambios y genera una lista de cambios de código para que pueda migrar el trabajo. Puede ver el script actualizado junto con el resumen que detalla los cambios propuestos. Tras ejecutar pruebas propias, acepte los cambios y el trabajo de AWS Glue se actualizará automáticamente a la última versión con el nuevo script.

El proceso de análisis de la actualización puede tardar un tiempo en completarse, en función de la complejidad del trabajo y la carga de trabajo. Los resultados del análisis de la actualización se almacenarán en la ruta de Amazon S3 especificada, que se puede revisar para comprender la actualización y cualquier posible problema de compatibilidad. Tras revisar los resultados del análisis de la actualización, puede decidir si desea continuar con la actualización propiamente dicha o hacer los cambios necesarios en el trabajo antes de la actualización.

Requisitos previos

Estos son los requisitos previos necesarios para utilizar la IA generativa para actualizar trabajos en AWS Glue:

- Trabajos de PySpark de AWS Glue 2: solo los trabajos de AWS Glue 2 se pueden actualizar a AWS Glue 5.
- Se necesitan permisos de IAM para iniciar el análisis, revisar los resultados y actualizar el trabajo. Para obtener más información, consulte los ejemplos de la sección Permisos a continuación.
- Si se utiliza AWS KMS para cifrar artefactos de análisis, se necesitan permisos adicionales de AWS AWS KMS. Para obtener más información, consulte los ejemplos de la sección AWS KMSPolítica de a continuación.

Permisos

Para iniciar un nuevo análisis de actualización, necesita los siguientes permisos:

1. Actualice la política de IAM del intermediario con el siguiente permiso:

   JSON

```
{
    "Version":"2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "glue:StartJobUpgradeAnalysis",
                "glue:StartJobRun",
                "glue:GetJobRun",
                "glue:GetJob",
                "glue:BatchStopJobRun"
            ],
```

```
            "Resource": [
                "arn:aws:glue:us-east-1:111122223333:job/jobName"
            ]
        },
        {
            "Effect": "Allow",
            "Action": [
                "s3:GetObject"
            ],
            "Resource": [
              "arn:aws:s3:::amzn-s3-demo-bucket/script-location/*"
            ]
        },
        {
            "Effect": "Allow",
            "Action": [
                "s3:PutObject",
                "s3:GetObject"
            ],
            "Resource": [
              "arn:aws:s3:::amzn-s3-demo-bucket/results/*"
            ]
        },
        {
            "Effect": "Allow",
            "Action": [
                "kms:Decrypt",
                "kms:GenerateDataKey"
            ],
            "Resource": "arn:aws:kms:us-east-1:111122223333:key/key-id"
        }
    ]
}
```

2. Actualice el rol de ejecución del trabajo que vaya a actualizar para incluir la siguiente política en línea:

```
    {
      "Effect": "Allow",
      "Action": ["s3:GetObject"],
      "Resource": [
        "ARN of the Amazon S3 path provided on API",
        "ARN of the Amazon S3 path provided on API/*"
```

```
      ]
    }
```

Por ejemplo, si utiliza la ruta de Amazon S3 `s3://amzn-s3-demo-bucket/upgraded-result`, la política será:

```
{
      "Effect": "Allow",
      "Action": ["s3:GetObject"],
      "Resource": [
        "arn:aws:s3:::amzn-s3-demo-bucket/upgraded-result/",
        "arn:aws:s3:::amzn-s3-demo-bucket/upgraded-result/*"
      ]
    }
```

Para recuperar los detalles de un análisis, necesita los siguientes permisos:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:GetJobUpgradeAnalysis"
      ],
      "Resource": [
        "arn:aws:glue:us-east-1:111122223333:job/jobName"
      ]
    }
  ]
}
```

Para detener un análisis en curso, necesita los siguientes permisos:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:StopJobUpgradeAnalysis",
        "glue:BatchStopJobRun"
      ],
      "Resource": [
        "arn:aws:glue:us-east-1:111122223333:job/jobName"
      ]
    }
  ]
}
```

Para mostrar todos los análisis enviados en relación con un trabajo específico, necesita los siguientes permisos:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListJobUpgradeAnalyses"
      ],
      "Resource": [
        "arn:aws:glue:us-east-1:111122223333:job/jobName"
      ]
    }
  ]
}
```

Para aceptar los cambios de un análisis y actualizar un trabajo, necesita los siguientes permisos:

AWS KMSPolítica de

Para transferir su propia clave personalizada de AWS KMS al iniciar un análisis, consulte la siguiente sección para configurar los permisos adecuados para las claves de AWS KMS.

Configuración del cifrado del artefacto resultante mediante una clave de AWS KMS:

Esta política garantiza que tiene los permisos de cifrado y descifrado de la clave de AWS KMS.

```
{
    "Effect": "Allow",
    "Principal":{
        "AWS": "<IAM Customer caller ARN>"
    },
    "Action": [
      "kms:Decrypt",
      "kms:GenerateDataKey",
    ],
    "Resource": "<key-arn-passed-on-start-api>"
}
```

Ejecución de un análisis de actualización y aplicación del script de actualización

Puede ejecutar un análisis de actualización, que generará un plan de actualización para un trabajo que seleccione en la vista Trabajos.

1. En Trabajos, seleccione un trabajo de AWS Glue 2.0 y, a continuación, elija Ejecutar análisis de actualización en el menú Acciones.

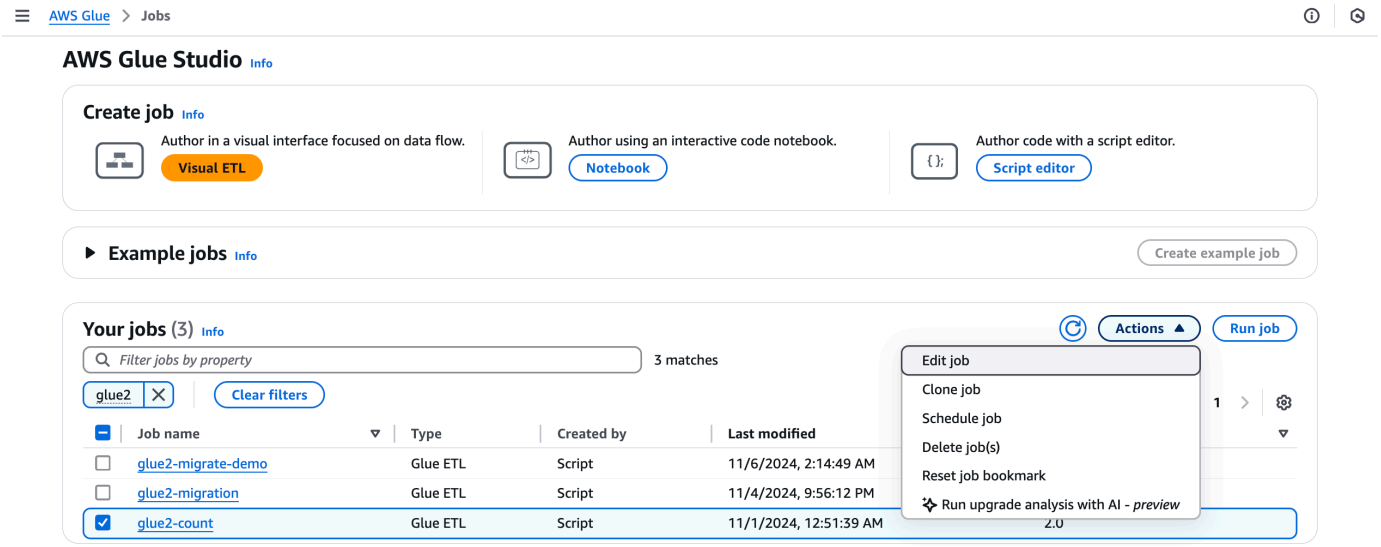

2. En el modal, seleccione una ruta para almacenar el plan de mejoras generado en Ruta de resultados. Debe ser un bucket de Amazon S3 al que pueda acceder y en el que pueda escribir.

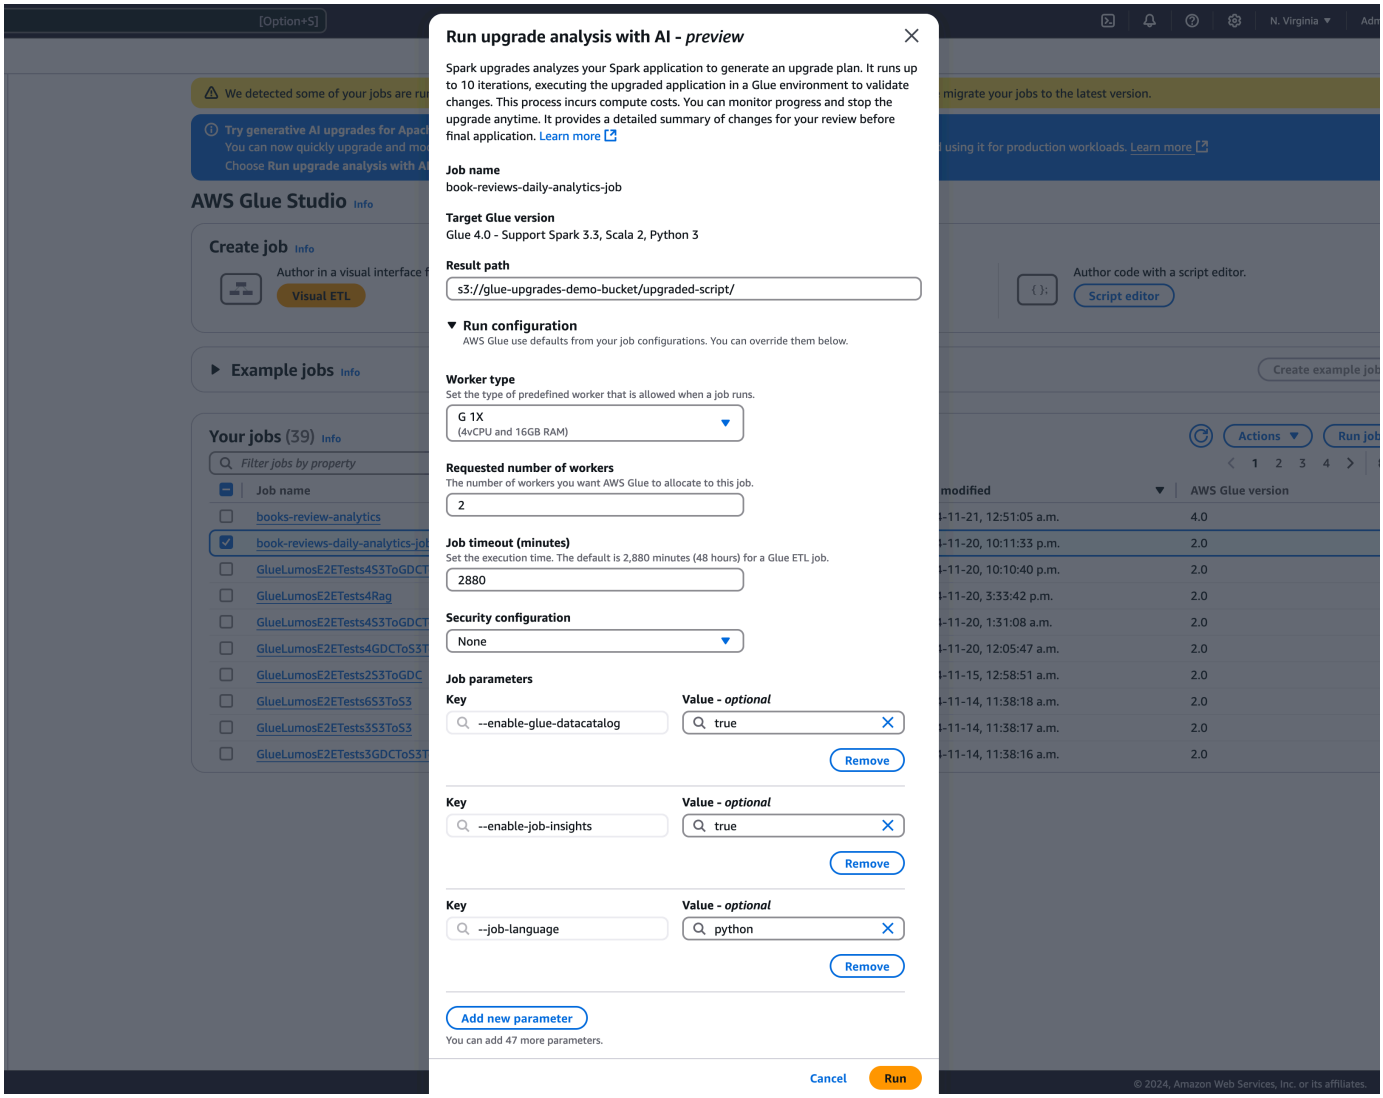

3. Configure las opciones adicionales si es necesario:

- Configuración de ejecución: (opcional): la configuración de ejecución es una configuración opcional que permite personalizar varios aspectos de las ejecuciones de validación hechas durante el análisis de la actualización. Esta configuración se utiliza para ejecutar el script actualizado y permite seleccionar las propiedades del entorno de computación (tipo de proceso de trabajo, número de procesos de trabajo, etc.). Tenga en cuenta que debe utilizar sus cuentas de desarrollador ajenas a la producción para hacer las validaciones de los conjuntos de datos de muestra antes de revisar, aceptar los cambios y aplicarlos a los entornos de producción. La configuración de ejecución incluye los siguientes parámetros personalizables:

- Tipo de trabajador: puede especificar el tipo de trabajador que se utilizará en las ejecuciones de validación, lo que le permitirá elegir los recursos de computación adecuados en función de sus requisitos.
- Número de trabajadores: puede definir el número de procesos de trabajo que se van a aprovisionar para las ejecuciones de validación, lo que le permite escalar los recursos en función de sus necesidades de carga de trabajo.
- Tiempo de espera del trabajo (en minutos): este parámetro le permite establecer un límite de tiempo para las ejecuciones de validación, lo que garantiza que los trabajos finalicen después de un periodo específico para evitar un consumo excesivo de recursos.
- Configuración de seguridad: puede configurar los parámetros de seguridad, como el cifrado y el control de acceso, para garantizar la protección de los datos y los recursos durante las ejecuciones de validación.
- Parámetros de trabajo adicionales: si es necesario, puede agregar nuevos parámetros de trabajo para personalizar aún más el entorno de ejecución de las ejecuciones de validación.

Al aprovechar la configuración de las ejecuciones, puede personalizar las ejecuciones de validación para que se adapten a sus requisitos específicos. Por ejemplo, puede configurar las ejecuciones de validación para usar un conjunto de datos más pequeño, lo que permite que el análisis se complete más rápidamente y optimiza los costos. Este enfoque garantiza que el análisis de actualización se haga de manera eficiente y, al mismo tiempo, minimiza la utilización de los recursos y los costos asociados durante la fase de validación.

- Configuración de cifrado (opcional):
  - Habilitar el cifrado de los artefactos de actualización: habilite el cifrado en reposo al escribir los datos en la ruta de resultados. Si no quiere cifrar los artefactos de actualización, deje esta opción sin marcar.

4. Seleccione Ejecutar para iniciar el análisis de la actualización. Mientras se ejecuta el análisis, puede ver los resultados en la pestaña Análisis de actualización. La ventana de detalles del análisis le mostrará información sobre el análisis, así como enlaces a los artefactos de la actualización.

   - Ruta de resultados: aquí es donde se almacenan el resumen de los resultados y el script de actualización.
   - Script actualizado en Amazon S3: ubicación del script de actualización en Amazon S3. Puede ver el script antes de aplicar la actualización.

- Resumen de la actualización en Amazon S3: la ubicación del resumen de la actualización en Amazon S3. Puede ver el resumen de la actualización antes de aplicarla.

5. Cuando el análisis de actualización se haya completado correctamente, puede aplicar el script de actualización para actualizar automáticamente el trabajo mediante la selección de la opción Aplicar el script actualizado.

   Una vez aplicada, la versión de AWS Glue se actualizará a la versión 4.0. Puede ver el nuevo script en la pestaña Script.

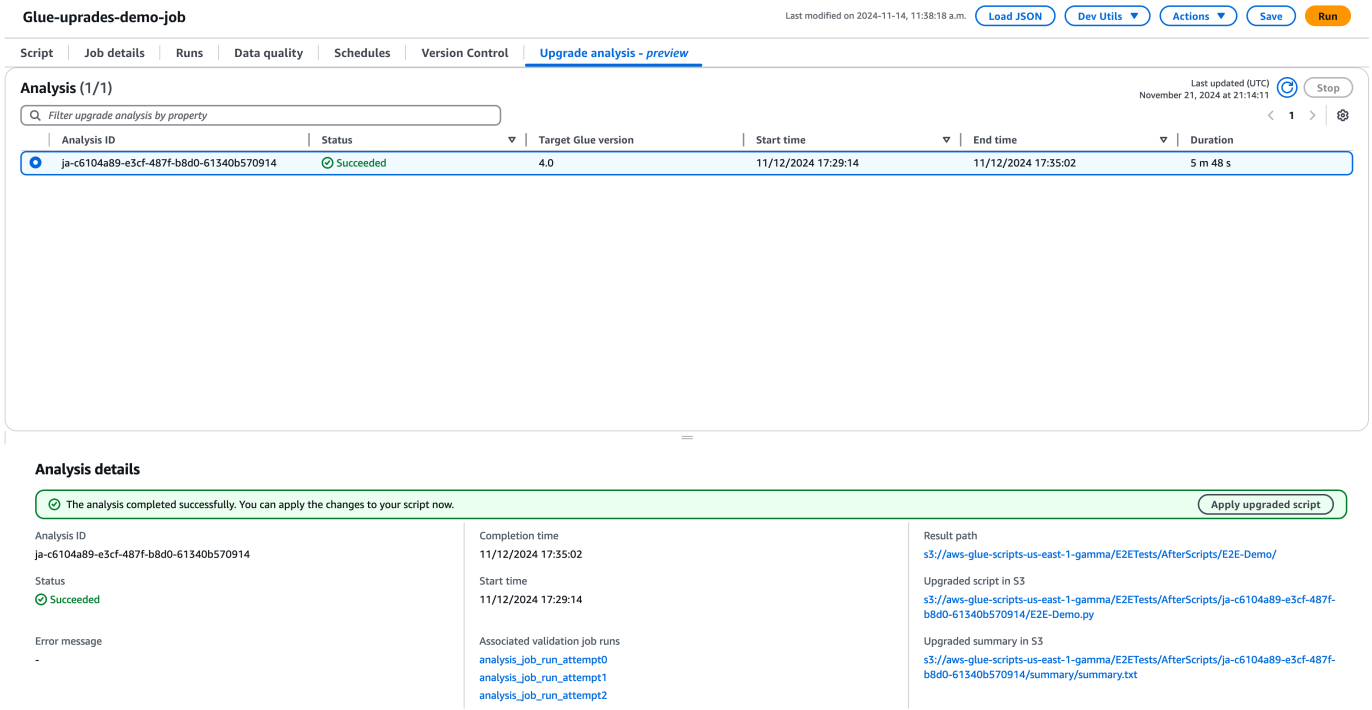

Descripción del resumen de la actualización

En este ejemplo, se muestra el proceso de actualización de un trabajo de AWS Glue de la versión 2.0 a la versión 4.0. El trabajo de muestra lee los datos del producto de un bucket de Amazon S3, aplica varias transformaciones a los datos mediante Spark SQL y, a continuación, guarda los resultados transformados en un bucket de Amazon S3.

Código original (AWS Glue 2.0): antes de la actualización

```
from awsglue.transforms import *
from pyspark.context import SparkContext
from awsglue.context import GlueContext
```

```
from pyspark.sql.types import *
from pyspark.sql.functions import *
from awsglue.job import Job
import json
from pyspark.sql.types import StructType

sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)
spark = glueContext.spark_session
job = Job(glueContext)

gdc_database = "s3://aws-glue-scripts-us-east-1-gamma/demo-database/"
schema_location = (
    "s3://aws-glue-scripts-us-east-1-gamma/DataFiles/"
)

products_schema_string = spark.read.text(
    f"{schema_location}schemas/products_schema"
).first()[0]

product_schema = StructType.fromJson(json.loads(products_schema_string))

products_source_df = (
    spark.read.option("header", "true")
    .schema(product_schema)
    .option(
        "path",
        f"{gdc_database}products/",
    )
    .csv(f"{gdc_database}products/")
)

products_source_df.show()
products_temp_view_name = "spark_upgrade_demo_product_view"
products_source_df.createOrReplaceTempView(products_temp_view_name)

query = f"select {products_temp_view_name}.*, format_string('%0$s-%0$s', category,
 subcategory) as unique_category from {products_temp_view_name}"
products_with_combination_df = spark.sql(query)
products_with_combination_df.show()

products_with_combination_df.createOrReplaceTempView(products_temp_view_name)
product_df_attribution = spark.sql(
    f"""
```

```
SELECT *,
unbase64(split(product_name, ' ')[0]) as product_name_decoded,
unbase64(split(unique_category, '-')[1]) as subcategory_decoded
FROM {products_temp_view_name}
"""
)
product_df_attribution.show()


product_df_attribution.write.mode("overwrite").option("header", "true").option(
    "path", f"{gdc_database}spark_upgrade_demo_product_agg/"
).saveAsTable("spark_upgrade_demo_product_agg", external=True)

spark_upgrade_demo_product_agg_table_df = spark.sql(
    f"SHOW TABLE EXTENDED in default like 'spark_upgrade_demo_product_agg'"
)
spark_upgrade_demo_product_agg_table_df.show()
job.commit()
```

Código nuevo (Glue 4.0): tras la actualización

```
from awsglue.transforms import *
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from pyspark.sql.types import *
from pyspark.sql.functions import *
from awsglue.job import Job
import json
from pyspark.sql.types import StructType

sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)
spark = glueContext.spark_session
# change 1
spark.conf.set("spark.sql.adaptive.enabled", "false")
# change 2
spark.conf.set("spark.sql.legacy.pathOptionBehavior.enabled", "true")
job = Job(glueContext)

gdc_database = "s3://aws-glue-scripts-us-east-1-gamma/demo-database/"
schema_location = (
    "s3://aws-glue-scripts-us-east-1-gamma/DataFiles/"
)
```

```
products_schema_string = spark.read.text(
    f"{schema_location}schemas/products_schema"
).first()[0]

product_schema = StructType.fromJson(json.loads(products_schema_string))

products_source_df = (
    spark.read.option("header", "true")
    .schema(product_schema)
    .option(
        "path",
        f"{gdc_database}products/",
    )
    .csv(f"{gdc_database}products/")
)

products_source_df.show()
products_temp_view_name = "spark_upgrade_demo_product_view"
products_source_df.createOrReplaceTempView(products_temp_view_name)

# change 3
query = f"select {products_temp_view_name}.*, format_string('%1$s-%1$s', category,
 subcategory) as unique_category from {products_temp_view_name}"
products_with_combination_df = spark.sql(query)
products_with_combination_df.show()

products_with_combination_df.createOrReplaceTempView(products_temp_view_name)
# change 4
product_df_attribution = spark.sql(
    f"""
SELECT *,
try_to_binary(split(product_name, ' ')[0], 'base64') as product_name_decoded,
try_to_binary(split(unique_category, '-')[1], 'base64') as subcategory_decoded
FROM {products_temp_view_name}
"""
)
product_df_attribution.show()


product_df_attribution.write.mode("overwrite").option("header", "true").option(
    "path", f"{gdc_database}spark_upgrade_demo_product_agg/"
).saveAsTable("spark_upgrade_demo_product_agg", external=True)
```

```
spark_upgrade_demo_product_agg_table_df = spark.sql(
    f"SHOW TABLE EXTENDED in default like 'spark_upgrade_demo_product_agg'"
)
spark_upgrade_demo_product_agg_table_df.show()
job.commit()
```

Explicación del resumen del análisis

```
In Spark 3.2, spark.sql.adaptive.enabled is enabled by default. To restore the behavior before
Spark 3.2,
you can set spark.sql.adaptive.enabled to false.


In Spark 3.1, path option cannot coexist when the following methods are called with path
parameter(s): DataFrameReader.load(), DataFrameWriter.save(), DataStreamReader.load(), or
DataStreamWriter.start(). In addition, paths option cannot coexist for DataFrameReader.load().
For example, spark.read.format(csv).option(path, /tmp).load(/tmp2) or spark.read.option(path, /
tmp).csv(/tmp2) will throw org.apache.spark.sql.AnalysisException. In Spark version 3.0 and
below, path option is overwritten if one path parameter is passed to above methods; path option
is added to the overall paths if multiple path parameters are passed to DataFrameReader.load().
To restore the behavior before Spark 3.1, you can set
spark.sql.legacy.pathOptionBehavior.enabled to true.


Since Spark 3.3, the `strfmt` in `format_string(strfmt, obj, ...)` and `printf(strfmt,
obj, ...)` will no longer support to use 0$ to specify the first argument, the first argument
should always reference by 1$ when use argument index to indicating the position of the argument
in the argument list.


Since Spark 3.3, the unbase64 function throws error for a malformed str input. Use
try_to_binary(<str>, 'base64') to tolerate malformed input and return NULL instead. In Spark 3.2
and earlier, the unbase64 function returns a best-efforts result for a malformed str input.
```

Según el resumen, hay cuatro cambios propuestos por AWS Glue para actualizar correctamente el script de AWS Glue 2.0 a AWS Glue 4.0:

1. Configuración de Spark SQL (spark.sql.adaptive.enabled): este cambio tiene por objeto restaurar el comportamiento de la aplicación. A partir de Spark 3.2, se ha introducido una nueva característica para la ejecución adaptativa de consultas de Spark SQL. Puede inspeccionar este cambio de configuración y habilitarlo o deshabilitarlo según sus preferencias.
2. Cambio de la API de DataFrame: la opción de ruta no puede coexistir con otras operaciones de DataFrameReader como `load()`. Para retener el comportamiento anterior, AWS Glue actualizó el script para agregar una nueva configuración de SQL (spark.sql.legacy.pathOptionBehavior.enabled).
3. Cambio de la API de Spark SQL: se ha actualizado el comportamiento de `strfmt` en `format_string(strfmt, obj, ...)` para que no se permita `0$` como primer argumento.

Para garantizar la compatibilidad, AWS Glue ha modificado el script para usar 1$ como primer argumento.

4. Cambio de la API de SQL de Spark: la función `unbase64` no permite ingresar cadenas mal formadas. Para retener el comportamiento anterior, AWS Glue actualizó el script para usar la función `try_to_binary`.

Detención de un análisis de actualización en curso

Puede cancelar un análisis de actualización en curso o simplemente detenerlo.

1. Elija la pestaña Análisis de actualizaciones.
2. Seleccione el trabajo que se está ejecutando y, a continuación, elija Detener. Esto detendrá el análisis. A continuación, puede ejecutar otro análisis de actualizaciones en el mismo trabajo.

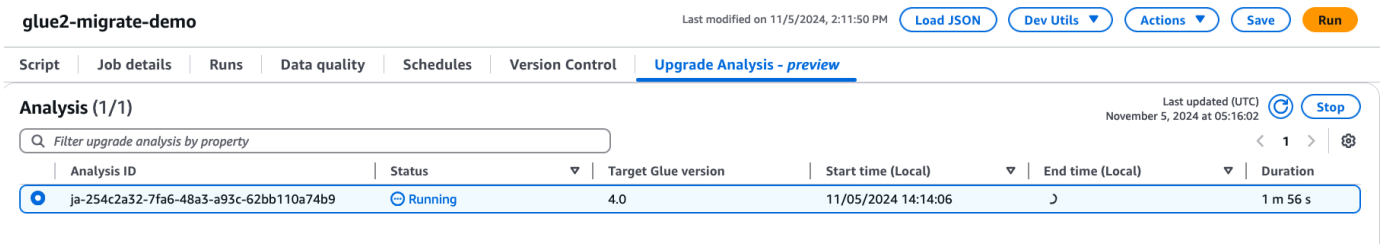

Consideraciones

Al comenzar a usar las actualizaciones de Spark, hay varios aspectos importantes que debe tener en cuenta para un uso óptimo del servicio.

- Alcance y limitaciones del servicio: la versión actual se centra en la actualización de código PySpark desde la versión 2.0 hasta la versión 5.0 de AWS Glue. En este momento, el servicio gestiona el código de PySpark que no depende de dependencias de biblioteca adicionales. Puede ejecutar actualizaciones automatizadas de hasta 10 trabajos simultáneamente en una cuenta de AWS, lo que le permite actualizar varios trabajos de manera eficiente y, al mismo tiempo, mantener la estabilidad del sistema.
  - Solo se admiten trabajos de PySpark.
  - El tiempo de espera del análisis de actualizaciones se agota después de 24 horas.
  - Solo se puede ejecutar un análisis de actualización activo a la vez para un trabajo. Se pueden ejecutar hasta 10 análisis de actualización activos a la vez por cuenta.

- Optimización de los costos durante el proceso de actualización: dado que las actualizaciones de Spark utilizan IA generativa para validar el plan de actualización en varias iteraciones, y cada iteración se ejecuta como una tarea de AWS Glue en su cuenta, es esencial optimizar las configuraciones de ejecución de las tareas de validación para lograr una mayor rentabilidad. Para lograrlo, le recomendamos que especifique una configuración de ejecución al iniciar un análisis de actualización de la siguiente manera:
  - Utilice cuentas de desarrolladores que no sean de producción y seleccione conjuntos de datos simulados de muestra que representen los datos de producción, pero que sean más pequeños para validarlos con la función Actualizaciones de Spark.
  - Utilice recursos de computación del tamaño adecuado, como los trabajadores de G.1X, y seleccione un número adecuado de procesos de trabajo para procesar los datos de la muestra.
  - Habilite el escalado automático de los trabajos de AWS Glue cuando sea aplicable para ajustar automáticamente los recursos en función de la carga de trabajo.

  Por ejemplo, si el trabajo de producción procesa terabytes de datos con 20 procesos de trabajo de G.2X, puede configurar el trabajo de actualización para procesar unos pocos gigabytes de datos representativos con 2 procesos de trabajo de G.2X y activar el escalado automático para la validación.
- Prácticas recomendadas: se recomienda iniciar el proceso de actualización con trabajos que no estén en producción. Este enfoque le permite familiarizarse con el flujo de trabajo de actualización y entender cómo el servicio gestiona los distintos tipos de patrones de código de Spark.
- Alarmas y notificaciones: cuando utilice la característica de actualizaciones con IA generativa en un trabajo, asegúrese de que estén desactivadas las alarmas o notificaciones en caso de ejecución con errores de un trabajo. Durante el proceso de actualización, es posible que se produzcan errores al ejecutar hasta 10 trabajos en su cuenta antes de que se proporcionen los artefactos actualizados.
- Reglas de detección de anomalías: desactive también las reglas de detección de anomalías en el trabajo que se está actualizando, ya que los datos escritos en las carpetas de salida durante las ejecuciones intermedias del trabajo podrían no tener el formato esperado mientras la validación de la actualización se encuentra en curso.
- Utilice el análisis de actualización con trabajos de idempotencia: utilice el análisis de actualización con trabajos de idempotencia para garantizar que cada intento de ejecución posterior de un trabajo de validación sea similar al anterior y no presente problemas. Los trabajos de idempotencia son trabajos que se pueden ejecutar varias veces con los mismos datos de entrada y que producirán el mismo resultado cada vez. Cuando se utilicen las actualizaciones de IA generativa para Apache

Spark en AWS Glue, el servicio ejecutará varias iteraciones de su trabajo como parte del proceso de validación. Durante cada iteración, realizará cambios en el código y las configuraciones de Spark para validar el plan de actualización. Si su trabajo de Spark no es de idempotencia, ejecutarlo varias veces con los mismos datos de entrada podría provocar problemas.

Regiones admitidas

Las actualizaciones con IA generativa para Apache Spark están disponibles en las siguientes regiones:

- Asia-Pacífico: Tokio (ap-northeast-1), Seúl (ap-northeast-2), Mumbai (ap-south-1), Singapur (ap-southeast-1) y Sídney (ap-southeast-2)
- América del Norte: Canadá (ca-central-1)
- Europa: Fráncfort (eu-central-1), Estocolmo (eu-north-1), Irlanda (eu-west-1), Londres (eu-west-2) y París (eu-west-3)
- América del Sur: São Paulo (sa-east-1)
- Estados Unidos: norte de Virginia (us-east-1), Ohio (us-east-2) y Oregón (us-west-2)

Inferencia entre regiones en Spark Upgrades

Spark Upgrades funciona con Amazon Bedrock y aprovecha la inferencia entre regiones (CRIS). Con CRIS, Spark Upgrades seleccionará automáticamente la región óptima de su zona geográfica (tal y como se describe con más detalle aquí) para procesar su solicitud de inferencia, maximizar los recursos de computación disponibles y la disponibilidad del modelo, además de ofrecer la mejor experiencia al cliente. El uso de la inferencia entre regiones no conlleva ningún costo adicional.

Las solicitudes de inferencia entre regiones se mantienen dentro de las regiones de AWS que forman parte de la zona geográfica en la que se encuentran originalmente los datos. Por ejemplo, una solicitud realizada en EE. UU. se mantiene dentro de las regiones de AWS de EE. UU. Si bien los datos solo permanecen almacenados en la región principal, cuando utiliza la inferencia entre regiones, las peticiones de entrada y los resultados de salida pueden llevarse fuera de la región principal. Todos los datos se transmitirán cifrados a través de la red segura de Amazon.

Trabajar con trabajos de Spark en AWS Glue

Proporciona información sobre los trabajos de ETL de AWS Glue para Spark.

Temas

- Uso de los parámetros de trabajo en los trabajos de AWS Glue
- Trabajos de Spark y PySpark de AWS Glue
- Tipos de trabajadores de AWS Glue
- Trabajos ETL de streaming en AWS Glue
- Coincidencia de registros con FindMatches de AWS Lake Formation
- Migrar programas de Apache Spark a AWS Glue

Uso de los parámetros de trabajo en los trabajos de AWS Glue

Al crear un trabajo de Glue AWS, establece algunos campos estándar, como `Role` y`WorkerType`. Puede proporcionar información de configuración adicional a través de los campos `Argument` (Parámetros del trabajo en la consola). En estos campos, puede proporcionar los trabajos de Glue AWS con los argumentos (parámetros) que se enumeran en este tema.

Para obtener más información acerca de la API de trabajo de Glue AWS, consulte the section called “Trabajos”.

> **Note**
>
> Los argumentos de trabajo tienen un límite de tamaño máximo de 260 KB. Una comprobación de validación generará un error si el tamaño del argumento es superior a 260 KB.

Configuración de los parámetros del trabajo

Puede configurar un trabajo a través de la consola, en la pestaña Job details (Detalles del trabajo), en el encabezado Job Parameters (Parámetro del trabajo). Para configurar un trabajo a través de AWS CLI, establezca `DefaultArguments` o `NonOverridableArguments` en un trabajo, o `Arguments` en la ejecución de un trabajo. Los argumentos establecidos en el trabajo se pasarán cada vez que se ejecute el trabajo, mientras que los argumentos establecidos en la ejecución del trabajo solo se pasarán para esa ejecución individual.

Por ejemplo, a continuación se muestra la sintaxis para ejecutar un trabajo con `--arguments` para configurar un parámetro de trabajo.

```
$ aws glue start-job-run --job-name "CSV to CSV" --arguments='--scriptLocation="s3://
my_glue/libraries/test_lib.py"'
```

Acceder a los parámetros del trabajo

Al escribir scripts de Glue AWS, es posible que desee acceder a los valores de los parámetros del trabajo para modificar el comportamiento de su propio código. Proporcionamos métodos auxiliares para hacerlo en nuestras bibliotecas. Estos métodos resuelven los valores de los parámetros de ejecución del trabajo que anulan los valores de los parámetros del trabajo. Al resolver los parámetros establecidos en varios lugares, el trabajo `NonOverridableArguments` anulará el trabajo ejecutado `Arguments`, que anulará el trabajo `DefaultArguments`.

En Python:

En los trabajos de Python, proporcionamos una función llamada `getResolvedParameters`. Para obtener más información, consulte the section called “getResolvedOptions”. Los parámetros del trabajo están disponibles en la variable `sys.argv`.

En Scala:

En los trabajos de Scala, proporcionamos un objeto llamado `GlueArgParser`. Para obtener más información, consulte the section called “GlueArgParser”. Los parámetros del trabajo están disponibles en la variable `sysArgs`.

Referencia de parámetros de trabajo

AWS Glue reconoce los siguientes nombres de argumentos que se pueden utilizar para configurar el entorno de scripts para los trabajos y las ejecuciones de trabajos:

`--additional-python-modules`

Lista delimitada por comas que representa un conjunto de paquetes de Python que se deben instalar. Puede instalar los paquetes desde PyPI o proporcionar una distribución personalizada. Una entrada de paquete de PyPI tendrá el formato *`package`*==*`version`*, con el nombre y la versión del paquete de destino de PyPI. Una entrada de distribución personalizada es la ruta de S3 a la distribución.

Las entradas utilizan la coincidencia de versiones de Python para hacer coincidir el paquete y la versión. Eso significa que tendrá que usar dos signos igual: ==. Existen otros operadores de coincidencia de versiones; para obtener más información, consulte PEP 440.

Para pasar las opciones de instalación del módulo a `pip3`, utilice el parámetro --python-modules-installer-option.

`--auto-scale-within-microbatch`

El valor predeterminado es true. Este parámetro solo se puede usar para los trabajos de transmisión de Glue AWS, que procesan los datos de transmisión en una serie de microlotes y el escalado automático debe estar habilitado. Al establecer este valor en falso, calcula la media móvil exponencial de la duración del lote de los microlotes completados y lo compara con el tamaño de la ventana para determinar si se debe escalar verticalmente o reducir verticalmente el número de ejecutores. El escalado solo se produce cuando se completa un microlote. Al establecer este valor en verdadero, durante un microlote, escala verticalmente cuando el número de tareas de Spark permanece igual durante 30 segundos o cuando el procesamiento por lotes actual es superior al tamaño de la ventana. El número de ejecutores disminuirá si un ejecutor ha estado inactivo durante más de 60 segundos o si la media móvil exponencial de la duración del lote es baja.

`--class`

La clase de Scala que sirve de punto de entrada del script de Scala. Esto solo se aplica si `--job-language` está establecido en `scala`.

`--continuous-log-conversionPattern`

Especifica un patrón de registro de conversión personalizado para un trabajo habilitado para el registro continuo. El patrón de conversión solo se aplica a los registros de controlador y de ejecutor. No afecta la barra de progreso de AWS Glue.

`--continuous-log-logGroup`

Especifica el nombre de un grupo de registro personalizado de Amazon CloudWatch para un trabajo habilitado para el registro continuo.

`--continuous-log-logStreamPrefix`

Especifica el prefijo de un flujo de registro personalizado de CloudWatch para un trabajo habilitado para el registro continuo.

`--customer-driver-env-vars` y **`--customer-executor-env-vars`**

Estos parámetros establecen variables de entorno en sistemas operativos de manera respectiva para cada trabajador (controlador o ejecutor). Puede utilizar estos parámetros al crear plataformas o esquemas personalizados además de AWS Glue para permitir a los usuarios poder escribir por encima. Al activar estos dos marcadores, podrá establecer distintas variables de

entorno para el controlador y para el ejecutor respectivamente sin tener que inyectar la misma lógica en el propio script del trabajo.

Ejemplo de uso

A continuación se muestra un ejemplo de la utilización de estos parámetros:

```
"–customer-driver-env-vars", "CUSTOMER_KEY1=VAL1,CUSTOMER_KEY2=\"val2,val2 val2\"",
"–customer-executor-env-vars", "CUSTOMER_KEY3=VAL3,KEY4=VAL4"
```

El establecimiento de estos en el argumento del trabajo equivale a la ejecución de los siguientes comandos:

En el controlador:

- exportar CUSTOMER_KEY1=VAL1
- exportar CUSTOMER_KEY2="val2,val2 val2"

En el ejecutor:

- exportar CUSTOMER_KEY3=VAL3

Luego, en el propio script de trabajo, se pueden recuperar las variables de entorno con `os.environ.get("CUSTOMER_KEY1")` o `System.getenv("CUSTOMER_KEY1")`.

Sintaxis de uso obligatorio

Controle los siguientes estándares al definir las variables del entorno:

- Cada clave debe contener el `CUSTOMER_ prefix`.

  Por ejemplo: para `"CUSTOMER_KEY3=VAL3,KEY4=VAL4"`, se ignorará `KEY4=VAL4` y no se establecerá.
- Cada par de clave y valor debe estar delimitado por una coma simple.

  Por ejemplo: .: `"CUSTOMER_KEY3=VAL3,CUSTOMER_KEY4=VAL4"`
- Si el valor contiene espacios o comas, debe encerrarse entre comillas.

  Por ejemplo: .: `CUSTOMER_KEY2=\"val2,val2 val2\"`

Esta sintaxis modela con precisión los estándares de configuración de las variables de entorno de bash.

`--datalake-formats`

Es compatible con la versión 3.0 y posteriores de AWS Glue.

Especifica el marco de lago de datos que se va a utilizar. AWS Glue agrega los archivos JAR necesarios para los marcos que especifique en `classpath`. Para obtener más información, consulte Uso de marcos de lagos de datos con trabajos de ETL de AWS Glue.

Puede especificar uno o varios de los siguientes valores, separados por una coma:

- `hudi`
- `delta`
- `iceberg`

Por ejemplo, pase el siguiente argumento para especificar los tres marcos.

```
'--datalake-formats': 'hudi,delta,iceberg'
```

`--disable-proxy-v2`

Deshabilita el proxy de servicio para permitir llamadas de servicio de AWS a Amazon S3, CloudWatch y AWS Glue originadas desde su script a través de la VPC. Para obtener más información, consulte Configuración de las llamadas de AWS para que pasen a través de su VPC. Para deshabilitar el proxy del servicio, defina el valor de este parámetro en `true`.

`--enable-auto-scaling`

Cuando este valor se configura en `true`, se activa el escalado automático y la facturación por proceso de trabajo.

`--enable-continuous-cloudwatch-log`

Permite un registro continuo en tiempo real de los trabajos de AWS Glue. Puede ver los registros de trabajos de Apache Spark en tiempo real en CloudWatch.

`--enable-continuous-log-filter`

Especifica un filtro estándar (`true`) o ningún filtro (`false`) al crear o editar un trabajo habilitado para el registro continuo. Si se elige Standard filter (Filtro estándar), se filtran los mensajes de registro de estado de Apache Hadoop YARN y de controlador/ejecutor de Apache Hadoop YARN no útiles. Si se elige sin filtro, se verán todos los mensajes de registro.

`--enable-glue-datacatalog`

Permite utilizar el Catálogo de datos de AWS Glue como metaalmacén de Apache Spark Hive. Para habilitar esta característica, establezca el valor como `true`.

`--enable-job-insights`

Permite la supervisión adicional del análisis de errores con la información de ejecución de trabajos de AWS Glue. Para obtener más información, consulte the section called “Supervisión con Información de ejecuciones de trabajos de AWS Glue”. De forma predeterminada, el valor se establece en `true` y la información de ejecución de trabajos está habilitada.

Esta opción está disponible para AWS Glule versión 2.0 y 3.0.

`--enable-lakeformation-fine-grained-access`

Permite un control de acceso detallado para trabajos con AWS Glue. Para obtener más información, consulte the section called “Lake Formation para FGAC”.

`--enable-metrics`

Permite recopilar métricas para generar perfiles de trabajo en la ejecución de este trabajo. Estas métricas se encuentran disponibles en la consola de AWS Glue y en la consola de Amazon CloudWatch. El valor de este parámetro no es relevante. Para activar esta característica, puede proporcionar a este parámetro cualquier valor, pero se recomienda `true` para mayor claridad. Para deshabilitar esta característica, elimine este parámetro de la configuración de su trabajo.

`--enable-observability-metrics`

Permite un conjunto de métricas de observabilidad para generar información sobre lo que sucede dentro de cada trabajo que se ejecuta en la página Job Runs Monitoring en la consola AWS Glue y la consola Amazon CloudWatch. Para habilitar esta característica, establezca el valor como true (verdadero). Para deshabilitar esta característica, defínala en `false` o elimine este parámetro de la configuración de su trabajo.

`--enable-rename-algorithm-v2`

Establece la versión del algoritmo de cambio de nombre de EMRFS a la versión 2. Cuando un trabajo de Spark utiliza el modo de sobrescritura de partición dinámica, existe la posibilidad de que se cree una partición duplicada. Por ejemplo, puede tener como resultado una partición duplicada como `s3://bucket/table/location/p1=1/p1=1`. Aquí, P1 es la partición que se está sobrescribiendo. El algoritmo de cambio de nombre versión 2 corrige este problema.

La opción solo está disponible en la versión 1.0 de AWS Glue.

`--enable-s3-parquet-optimized-committer`

Habilita el confirmador optimizado para S3 de EMRFS de forma que puedan escribirse datos de Parquet en Amazon S3. Puede suministrar el par parámetro/valor a través de la consola de AWS Glue cuando cree o actualice un trabajo de AWS Glue. Al establecer el valor en **`true`**, se habilita el confirmador. De forma predeterminada, la marca está activada en AWS Glue 3.0 y desactivada en AWS Glue 2.0.

Para obtener más información, consulte este artículo sobre el uso del confirmador optimizado para S3 de EMRFS.

`--enable-spark-ui`

Cuando se establece en `true`, activa la característica para usar la interfaz de usuario de Spark para monitorear y depurar trabajos de ETL de AWS Glue.

`--executor-cores`

Número de tareas de Spark que se pueden ejecutar en paralelo. Esta opción es compatible con Glue 3.0+ AWS. El valor no debe superar el doble de la cantidad de vCPU en el tipo de trabajador, es decir, 8 en `G.1X`, 16 en `G.2X`, 32 en `G.4X`, 64 en `G.8X`, 96 en `G.12X`, 128 en `G.16X`, y 8 en `R.1X`, 16 en `R.2X`, 32 en `R.4X`, 64 en `R.8X`. Debe tener cuidado al actualizar esta configuración, ya que podría afectar al rendimiento laboral porque el aumento del paralelismo entre las tareas provoca presión en la memoria y el disco y podría limitar los sistemas de origen y destino (por ejemplo, provocaría más conexiones simultáneas en Amazon RDS).

`--extra-files`

Las rutas de Amazon S3 a archivos adicionales, por ejemplo, archivos de configuración que AWS Glue copia en el directorio de trabajo de su script en el nodo del controlador antes de ejecutarlo. Varios valores deben ser rutas completas separadas por una coma (`,`). El valor puede ser archivos individuales o ubicaciones de directorios. Esta opción no es compatible con los tipos de trabajo de intérprete de comandos de Python.

`--extra-jars`

Amazon S3 lleva a archivos adicionales que AWS Glue copia al controlador y a los ejecutores. AWS Glue también añade estos archivos a la ruta de clases de Java antes de ejecutar el script. Varios valores deben ser rutas completas separadas por una coma (`,`). No es necesario que la extensión sea `.jar`

`--extra-py-files`

Las rutas de Amazon S3 a módulos de Python adicionales que AWS Glule agrega a la ruta de Python en el nodo del controlador antes de ejecutar el script. Varios valores deben ser rutas completas separadas por una coma (`,`). Solo se admiten archivos individuales, no una ruta de directorio.

`--job-bookmark-option`

Controla el comportamiento de un marcador de trabajo. Se pueden establecer los siguientes valores de opciones.

--job-bookmark-option Valor	Descripción
`job-bookmark-enable`	Realizar un seguimiento de los datos procesados anteriormente. Cuando se ejecuta un flujo de trabajo, procesar los datos nuevos desde el último punto de comprobación.
`job-bookmark-disable`	Procesar siempre todo el conjunto de datos. Usted es responsable de administrar el resultado de las ejecuciones de trabajos anteriores.
`job-bookmark-pause`	Procesar los datos incrementales desde la última ejecución correcta o los datos en el rango identificado por las siguientes subopciones, sin actualizar el estado del último marcador. Usted es responsable de administrar el resultado de las ejecuciones de trabajos anteriores. Las dos subopciones son las siguientes: • **`job-bookmark-from`** `<from-value>` es el ID de ejecución que representa todas las entradas que se han procesado hasta la última ejecución correcta antes de la misma e incluye el ID de ejecución especificado. La entrada correspondiente se ignora. • **`job-bookmark-to`** `<to-value>` es el ID de ejecución que representa todas las entradas que se han procesado hasta la última ejecución correcta antes de la misma e incluye el ID de ejecución

--job-bookmark-option Valor	Descripción
	especificado. El trabajo procesa la entrada correspondiente, excluida la entrada identificada por `<from-value>` . Cualquier entrada posterior a esta entrada también se excluye para el procesamiento. El estado del marcador de trabajo no se actualiza cuando se especifica este conjunto de opciones. Las subopciones son opcionales. Sin embargo, cuando se utilizan, deben proporcionarse ambas subopciones.

Por ejemplo, para habilitar un marcador de trabajo, transfiera el argumento siguiente.

```
'--job-bookmark-option': 'job-bookmark-enable'
```

`--job-language`

El lenguaje de programación del script. Este valor debe ser `scala` o `python`. Si no está presente este parámetro, el valor predeterminado es `python`.

`--python-modules-installer-option`

Una cadena de texto simple que define las opciones que se van a pasar a `pip3` al instalar módulos con --additional-python-modules. Proporcione opciones como lo haría en la línea de comandos, separadas por espacios y prefijadas por guiones. Para obtener más información acerca del uso de una VPC, consulte the section called “Instalación de módulos adicionales de Python en AWS Glue 2.0 (o posterior) con pip”.

> **Note**
>
> Esta opción no es compatible con los trabajos de AWS Glue cuando se utiliza Python 3.9.

`--scriptLocation`

La ubicación de Amazon Simple Storage Service (Amazon S3) donde se encuentra su script de ETL (en formato `s3://path/to/my/script.py`). Este parámetro invalida una ubicación del script establecida en el objeto `JobCommand`.

`--spark-event-logs-path`

Especifica una ruta de Amazon S3. Al utilizar la función de monitoreo de la interfaz de usuario de Spark, AWS Glue vacía los registros de eventos de Spark a esta ruta de Amazon S3 cada 30 segundos, en un bucket que se puede usar como directorio temporal para almacenar eventos de la interfaz de usuario de Spark.

`--TempDir`

Especifica una ruta de Amazon S3 a un bucket que se puede utilizar como directorio temporal para el trabajo.

Por ejemplo, para establecer un directorio temporal, transfiera el argumento siguiente.

```
'--TempDir': 's3-path-to-directory'
```

> **Note**
>
> AWS Glue crea un bucket temporal para los trabajos si aún no existe un bucket en la región. Este bucket podría permitir el acceso público. Puede modificar el bucket en Amazon S3 para establecer el bloqueo del acceso público o eliminar el bucket más tarde, después de que se hayan completado todos los trabajos de esa región.

`--use-postgres-driver`

Al establecer este valor en `true`, se prioriza el controlador JDBC de Postgre en la ruta de clases para evitar un conflicto con el controlador JDBC de Amazon Redshift. La opción solo está disponible en la versión 2.0 de AWS Glue.

`--user-jars-first`

Al establecer este valor en `true`, se priorizan los archivos JAR adicionales del cliente en el classpath. Esta opción solo se encuentra disponible en AWS Glue versión 2.0 o posterior.

`--conf`

Controla los parámetros de configuración de Spark. Es para casos de uso avanzados.

`--encryption-type`

Parámetro heredado. El comportamiento correspondiente debe configurarse mediante configuraciones de seguridad. Para obtener más información sobre las configuraciones de seguridad, consulte the section called “Cifrado de datos escritos por AWS Glue”.

AWS Glue usa los siguientes argumentos a nivel interno y el usuario nunca debe usarlos:

- `--debug`: interno de AWS Glue. No lo establezca.
- `--mode`: interno de AWS Glue. No lo establezca.
- `--JOB_NAME`: interno de AWS Glue. No lo establezca.
- `--endpoint`: interno de AWS Glue. No lo establezca.

AWS Glue admite el inicio de un entorno con el módulo `site` de Python que utiliza `sitecustomize` para realizar personalizaciones específicas del sitio. Se recomienda iniciar sus propias funciones de inicialización únicamente para casos de uso avanzados y, si se hace todo lo posible, se admite en la versión 4.0 de AWS Glue.

El prefijo de la variable de entorno, `GLUE_CUSTOMER`, está reservado para el uso de los clientes.

Trabajos de Spark y PySpark de AWS Glue

AWS Glue admite trabajos de Spark y PySpark Un trabajo de Spark se ejecuta en un entorno Apache Spark administrado por AWS Glue. Procesa los datos en lotes. Un trabajo ETL de streaming es similar a un trabajo de Spark, excepto que realiza ETL en las transmisiones de datos. Utiliza el marco Apache Spark Structured Streaming. Algunas características de trabajo de Spark no están disponibles para los trabajos ETL de streaming.

En las siguientes secciones, se ofrece información acerca de trabajos Spark y PySpark en AWS Glue.

Temas

- Configuración de las propiedades de trabajos para trabajos de Spark en AWS Glue
- Edición de scripts de Spark en la consola de AWS Glue
- Trabajos (heredado)

- Seguimiento de los datos procesados mediante marcadores de trabajo
- Almacenamiento de datos de mezclas aleatorias de Spark
- Supervisión de trabajos de Spark de AWS Glue
- Solución de problemas de IA generativa para Apache Spark en AWS Glue
- Uso de vistas materializadas con AWS Glue

Configuración de las propiedades de trabajos para trabajos de Spark en AWS Glue

Cuando define su trabajo en la consola de AWS Glue, proporciona valores de propiedades para controlar el entorno en tiempo de ejecución de AWS Glue.

Definición de propiedades de trabajo para trabajos de Spark

En la siguiente lista se describen las propiedades de un trabajo de Spark. Para ver las propiedades de un trabajo de shell de Python, consulte Definición de las propiedades de trabajos de shell de Python. Para obtener información sobre las propiedades de un trabajo ETL de streaming, consulte the section called “Definición de propiedades de trabajo para un trabajo ETL de streaming”.

Las propiedades se muestran en el orden en que aparecen en el asistente Add job (Agregar trabajo) en la consola de AWS Glue.

Nombre

Proporciona una cadena UTF-8 con una longitud máxima de 255 caracteres

Descripción

Brinde una descripción adicional de hasta 2048 caracteres.

Rol de IAM

Especifique el rol de IAM que se utiliza para dar una autorización sobre los recursos que se utilizan para ejecutar el trabajo y obtener acceso a los almacenes de datos. Para obtener más información acerca de los permisos para ejecutar trabajos en AWS Glue, consulte Administración de identidades y accesos para AWS Glue.

Tipo

El tipo de trabajo de ETL. Este se establece de manera automática según el tipo de origen de datos que se seleccione.

- Spark ejecuta un script de ETL de Apache Spark con el comando de trabajo `glueetl`.

- Spark Streaming ejecuta un script de ETL de streaming de Apache Spark con el comando de trabajo `gluestreaming`. Para obtener más información, consulte the section called “Trabajos ETL de streaming”.
- El intérprete de comandos de Python ejecuta un script de Python con el comando de trabajo `pythonshell`. Para obtener más información, consulte Configuración de las propiedades de trabajos del intérprete de comandos de Python en AWS Glue.

versión de AWS Glue

La versión de AWS Glue determina las versiones de Apache Spark y Python que están disponibles para el trabajo, como se especifica en la tabla a continuación.

Versión de AWS Glue	Versiones de Spark y Python admitidas
5.0	• Spark 3.5.4 • Python 3.11
4.0	• Spark 3.3.0 • Python 3.10
3.0	• Spark 3.1.1 • Python 3.7

Idioma

El código del script de ETL define la lógica del trabajo. El script se puede codificar en Python o en Scala. Puede elegir si AWS Glue genera el script que el flujo de trabajo ejecuta o bien si usted mismo lo proporciona. Proporcione el nombre del script y la ubicación en Amazon Simple Storage Service (Amazon S3). Compruebe que no haya un archivo con el mismo nombre que el directorio de script en la ruta. Para obtener más información acerca de cómo usar scripts, consulte Guía de programación de AWS Glue.

Tipo de empleado

Están disponibles los siguientes tipos de proceso de trabajo:

Los recursos disponibles para los trabajadores de AWS Glue se miden en DPU. Una DPU es una medida relativa de la potencia de procesamiento que consta de 4 vCPU de capacidad de cómputo y 16 GB de memoria.

- **`G.025X`**: al elegir este tipo, también debe proporcionar un valor para Número de empleados. Cada trabajador se asigna a 0,25 DPU (2 vCPU, 4 GB de memoria) con un disco de 84 GB (aproximadamente 34 GB libres). Le recomendamos este tipo de proceso de trabajo para trabajos de streaming de bajo volumen. Este tipo de proceso de trabajo solo está disponible para trabajos de transmisión con la versión 3.0 (o posterior) de AWS Glue.
- **`G.1X`**: al elegir este tipo, también debe proporcionar un valor para Número de empleados. Cada trabajador se asigna a 1 DPU (4 vCPU, 16 GB de memoria) con un disco de 94 GB (aproximadamente 44 GB libres). Recomendamos este tipo de trabajador para cargas de trabajo como transformaciones de datos, uniones y consultas, ya que ofrece una forma escalable y rentable de ejecutar la mayoría de los trabajos.
- **`G.2X`**: al elegir este tipo, también debe proporcionar un valor para Número de empleados. Cada trabajador se asigna a 2 DPU (8 vCPU, 32 GB de memoria) con un disco de 138 GB (aproximadamente 78 GB libres). Recomendamos este tipo de trabajador para cargas de trabajo como transformaciones de datos, uniones y consultas, ya que ofrece una forma escalable y rentable de ejecutar la mayoría de los trabajos.
- **`G.4X`**: al elegir este tipo, también debe proporcionar un valor para Número de empleados. Cada trabajador se asigna a 4 DPU (16 vCPU, 64 GB de memoria) con un disco de 256 GB (aproximadamente 230 GB libres). Recomendamos este tipo de trabajador para los trabajos cuyas cargas de trabajo contengan las transformaciones, agregaciones, uniones y consultas más exigentes.
- **`G.8X`**: al elegir este tipo, también debe proporcionar un valor para Número de empleados. Cada trabajador se asigna a 8 DPU (32 vCPU, 128 GB de memoria) con un disco de 512 GB (aproximadamente 485 GB libres). Recomendamos este tipo de trabajador para los trabajos cuyas cargas de trabajo contengan las transformaciones, agregaciones, uniones y consultas más exigentes.
- **`G.12X`**: al elegir este tipo, también debe proporcionar un valor para Número de empleados. Cada trabajador se asigna a 12 DPU (48 vCPU, 192 GB de memoria) con un disco de 768 GB (aproximadamente 741 GB libres). Recomendamos este tipo de trabajador para trabajos con cargas de trabajo muy grandes que consumen muchos recursos y que requieren una capacidad de procesamiento significativa.
- **`G.16X`**: al elegir este tipo, también debe proporcionar un valor para Número de empleados. Cada trabajador se asigna a 16 DPU (64 vCPU, 256 GB de memoria) con un disco de 1024 GB (aproximadamente 996 GB libres). Recomendamos este tipo de trabajador para los trabajos con las cargas de trabajo más grandes que consumen más recursos y que requieren la máxima capacidad de procesamiento.

- **`R.1X`**: al elegir este tipo, también debe proporcionar un valor para Número de empleados. Cada trabajador se asigna a 1 DPU con una configuración optimizada para la memoria. Recomendamos este tipo de trabajador para las cargas de trabajo que consumen mucha memoria y que, con frecuencia, tienen errores de memoria insuficiente o requieren una alta relación entre memoria y CPU.
- **`R.2X`**: al elegir este tipo, también debe proporcionar un valor para Número de empleados. Cada trabajador se asigna a 2 DPU con una configuración optimizada para la memoria. Recomendamos este tipo de trabajador para las cargas de trabajo que consumen mucha memoria y que, con frecuencia, tienen errores de memoria insuficiente o requieren una alta relación entre memoria y CPU.
- **`R.4X`**: al elegir este tipo, también debe proporcionar un valor para Número de empleados. Cada trabajador se asigna a 4 DPU con una configuración optimizada para la memoria. Recomendamos este tipo de trabajador para cargas de trabajo grandes que consumen mucha memoria y que, con frecuencia, tienen errores de memoria insuficiente o requieren una alta relación entre memoria y CPU.
- **`R.8X`**: al elegir este tipo, también debe proporcionar un valor para Número de empleados. Cada trabajador se asigna a 8 DPU con una configuración optimizada para la memoria. Recomendamos este tipo de trabajador para cargas de trabajo muy grandes que consumen mucha memoria y que, con frecuencia, tienen errores de memoria insuficiente o requieren una alta relación entre memoria y CPU.

Especificaciones del tipo de trabajador

La siguiente tabla proporciona especificaciones detalladas de todos los tipos de trabajadores G disponibles:

Especificaciones del tipo de trabajador G

Tipo de trabajador	DPU por nodo	vCPU	Memoria (GB)	Disco (GB)	Espacio libre en el disco (GB)	Ejecutores de Spark por nodo
G.025X	0,25	2	4	84	34	1
G.1X	1	4	16	94	44	1
G.2X	2	8	32	138	78	1

Tipo de trabajador	DPU por nodo	vCPU	Memoria (GB)	Disco (GB)	Espacio libre en el disco (GB)	Ejecutores de Spark por nodo
G.4X	4	16	64	256	230	1
G.8X	8	32	128	512	485	1
G.12X	12	48	192	768	741	1
G.16X	16	64	256	1024	996	1

Importante: Los tipos de trabajadores G.12X y G.16X, así como todos los tipos de trabajadores R (de R.1X a R.8X), tienen una latencia de inicio más alta.

Se le cobra una tarifa por hora en función de la cantidad de DPU que se utilizan para ejecutar sus trabajos ETL. Para obtener más información, consulte la página de precios de AWS Glue.

Para trabajos de AWS Glue versión 1.0 o anterior, cuando configura un trabajo con la consola y especifica un Worker type (Tipo de empleado) de Standard (Estándar), se configura la Maximum capacity (Capacidad máxima) y el Number of workers (Número de empleados) se convierte en el valor de Máximum capacity (Capacidad máxima): 1. Si utiliza AWS Command Line Interface (AWS CLI) o AWS SDK, puede especificar el parámetro Max capacity (Capacidad máxima) o puede especificar tanto Worker type (Tipo de empleado) como Number of workers (Número de empleados).

Para trabajos de versión 2.0 de AWS Glue o posterior, no puede especificar una Capacidad máxima. En su lugar, debe especificar un Worker type (Tipo de empleado) y el Number of workers (Número de empleados).

Los tipos de trabajo **`G.4X`** y **`G.8X`** solo están disponibles para la AWS Glue versión 3.0 de Spark ETL en las siguientes AWS regiones: Este de EE. UU. (Ohio), Este de EE. UU. (Norte de Virginia), Oeste de EE. UU. (Norte de California), Oeste de EE. UU. (Oregón), Asia-Pacífico (Bombay), Asia Pacífico (Seúl), Asia Pacífico (Singapur), Asia Pacífico (Sídney), Asia Pacífico (Tokio), Canadá (centro), Europa (Fráncfort), Europa (Irlanda), Europa (Londres), Europa (España), Europa (Estocolmo) y América del Sur (São Paulo).

Los tipos de trabajadores **`G.12X`**, **`G.16X`** y de **`R.1X`** al **`R.8X`** están disponibles solo para los trabajos de Spark ETL de AWS Glue versión 4.0 o posterior en las siguientes regiones de AWS:

Este de EE. UU. (Norte de Virginia), Oeste de EE. UU. (Oregón), Este de EE. UU. (Ohio), Europa (Irlanda) y Europa (Fráncfort). Se admitirán regiones adicionales en futuras versiones.

Número de trabajadores requerido

Para la mayoría de los tipos de trabajador, debe especificar el número de trabajadores que se asigna cuando se ejecuta el trabajo.

Job bookmark (Marcador de flujo de trabajo)

Especifique cómo AWS Glue procesará la información de estado cuando se ejecute el flujo de trabajo. Puede hacer que recuerde datos procesados previamente, actualice la información de estado o no tenga en cuenta dicha información. Para obtener más información, consulte the section called “Seguimiento de los datos procesados mediante marcadores de trabajo”.

Filas de trabajo ejecutadas

Especifica si las ejecuciones de trabajos se ponen en fila para ejecutarse más tarde cuando no pueden ejecutarse inmediatamente debido a las cuotas de servicio.

Si está marcada, la fija de ejecución de trabajos está habilitada para las ejecuciones de trabajos. Si no se completa, los trabajos ejecutados no se considerarán para ponerlos en fila.

Si esta configuración no coincide con el valor establecido en la ejecución del trabajo, se utilizará el valor proveniente del campo de ejecución del trabajo.

Ejecución flexible

Al configurar un trabajo mediante AWS Studio o la API, puede especificar una clase de ejecución de trabajos estándar o flexible. Sus trabajos pueden tener diferentes grados de prioridad y sensibilidad temporal. La clase de ejecución estándar es ideal para cargas de trabajo urgentes que requieren un inicio rápido de los trabajos y recursos dedicados.

La clase de ejecución flexible es adecuada para trabajos no urgentes, como trabajos de preproducción, pruebas y cargas de datos únicas. Se admiten ejecuciones de trabajos flexibles para trabajos que utilizan AWS Glue versión 3.0 o posterior y tipos de empleados `G.1X` o `G.2X`. Los nuevos tipos de trabajadores (`G.12X`, `G.16X`, y de `R.1X` a `R.8X`) no admiten una ejecución flexible.

Las ejecuciones de trabajos flexibles se facturan en función del número de empleados que se ejecutan en un momento dado. Se puede agregar o eliminar el número de trabajadores para una ejecución de trabajo flexible en ejecución. En lugar de facturar como un simple cálculo de `Max`

`Capacity` * `Execution Time`, cada trabajador contribuirá por el tiempo que ejecutó durante la ejecución del trabajo. La factura es la suma de (`Number of DPUs per worker` * `time each worker ran`).

Para obtener más información, consulte el panel de ayuda de AWS Studio o Jobs y Ejecuciones de trabajo.

Número de reintentos

Especifique el número de veces, entre 0 y 10, que AWS Glue debe reiniciar automáticamente el flujo de trabajo si se produce un error. Los trabajos que alcanzan el límite de tiempo de espera no se reinician.

Job timeout (Tiempo de espera de flujo de trabajo)

Establece el tiempo de ejecución máximo en minutos. El máximo es de 7 días o 10 080 minutos. De lo contrario, las tareas arrojarán una excepción.

Si el valor se deja vacío, el tiempo de espera se establece de forma predeterminada en 2880 minutos.

Cualquier trabajo de AWS Glue existente con un valor de tiempo de espera superior a 7 días se establecerá de forma predeterminada en 7 días. Por ejemplo, si especificó un tiempo de espera de 20 días para un trabajo por lotes, este se detendrá el séptimo día.

> **Prácticas recomendadas para los tiempos de espera de trabajo**
>
> Los trabajos se cobran de acuerdo a los tiempos de ejecución. Para evitar costes inesperados, configure los valores de tiempos de espera correctos para el tiempo de ejecución esperado del trabajo.

Propiedades avanzadas

Nombre de archivo del script

Un nombre de script único para el trabajo. El nombre no puede ser Trabajo sin nombre.

Ruta del script

La ubicación del script de Amazon S3. La ruta debe tener el formato `s3://bucket/prefix/path/`. Debe terminar con una barra (/) y no debe incluir ningún archivo.

Métricas de trabajo

Active o desactive la creación de métricas de Amazon CloudWatch cuando se ejecute este trabajo. Para ver los datos de perfiles, debe habilitar esta opción. Para obtener más información acerca de cómo habilitar y visualizar métricas, consulte Monitorización y depuración de trabajo.

Métricas de observabilidad de trabajos

Active la creación de métricas de observabilidad adicional de CloudWatch cuando se ejecute el trabajo. Para obtener más información, consulte the section called “Monitorización con métricas de observabilidad de AWS Glue”.

Registro continuo

Active el registro continuo en Amazon CloudWatch. Si esta opción no está habilitada, los registros solo estarán disponibles después de que se complete el trabajo. Para obtener más información, consulte the section called “Registro de trabajos de AWS Glue”.

Interfaz de usuario de Spark

Habilite el uso de la interfaz de usuario (UI) de Spark para monitorear este trabajo. Para obtener más información, consulte Habilitación de la interfaz de usuario web de Apache Spark para trabajos de AWS Glue.

Ruta de los registros de la interfaz de usuario de Spark

La ruta para escribir registros mientras la interfaz de usuario de Spark está habilitada.

Configuración del registro y el monitoreo de la interfaz de Spark

Seleccione una de las siguientes opciones:

- Estándar: escriba registros con la identificación de ejecución de trabajos de AWS Glue como nombre de archivo. Active el monitoreo de la interfaz de usuario de Spark en la consola de AWS Glue.
- Heredado: escriba registros con el nombre “spark-application-{marca de tiempo}”. No active el monitoreo de la interfaz de usuario de Spark.
- Estándar y heredado: escriba registros tanto en las ubicaciones estándar como heredadas. Active el monitoreo de la interfaz de usuario de Spark en la consola de AWS Glue.

Simultaneidad máxima

Establece el número máximo de ejecuciones simultáneas que están permitidas para este flujo de trabajo. El valor predeterminado de es 1. Se produce un error cuando se llega a este

umbral. El valor máximo que puede especificar se controla mediante un límite de servicio. Por ejemplo, si una ejecución anterior de un trabajo se sigue ejecutando cuando una nueva instancia se inicia, es posible que desee devolver un error al evitar dos instancias de la misma ejecución de trabajo de forma simultánea.

Ruta temporaria

Proporcione la ubicación de un directorio de trabajo en Amazon S3 donde los resultados intermedios temporales se escriben cuando AWS Glue ejecuta el script. Compruebe que no haya un archivo con el mismo nombre que el directorio temporal en la ruta. Este directorio se utiliza cuando AWS Glue lee y escribe en Amazon Redshift y mediante determinadas transformaciones de AWS Glue.

> **Note**
>
> AWS Glue crea un bucket temporal para los trabajos si aún no existe un bucket en la región. Este bucket podría permitir el acceso público. Puede modificar el bucket en Amazon S3 para establecer el bloque de acceso público o eliminar el bucket más tarde, después de que se hayan completado todos los trabajos de esa región.

Umbral de notificación de retraso (minutos)

Establece el umbral (en minutos) antes de que se envíe una notificación de retraso. Puede configurar este umbral para enviar notificaciones cuando una ejecución de flujo de trabajo `RUNNING`, `STARTING` o `STOPPING` dure más de un número previsto de minutos.

Configuración de seguridad

Elija una configuración de seguridad de la lista. Una configuración de seguridad especifica cómo se cifran los datos en el destino de Amazon S3: sin cifrado, cifrado del lado del servidor con claves administradas por AWS KMS (SSE-KMS) o claves de cifrado administradas por Amazon S3 (SSE-S3).

Cifrado en el servidor

Si selecciona esta opción, cuando el flujo de trabajo de ETL se escribe en Amazon S3, los datos se cifran en reposo mediante cifrado SSE-S3. Tanto el destino de datos de Amazon S3 como los datos que se escriben en un directorio temporal de Amazon S3 se cifran. Esta opción se pasa como parámetro de trabajo. Para obtener más información, consulte Protecting Data Using Server-Side Encryption with Amazon S3-Managed Encryption Keys (SSE-S3)

(Protección de datos mediante el cifrado que se ejecuta en el servidor con las claves de cifrado administradas por Amazon S3 [SSE-S3]) en la Guía del usuario de Amazon Simple Storage Service.

> **Important**
>
> Esta opción se pasa por alto si se especifica una configuración de seguridad.

Use Glue Data Catalog as the Hive metastore (Utilizar el catálogo de datos de Glue como metaalmacén de Hive)

Seleccione esta opción para usar el AWS Glue Data Catalog como metaalmacén de Hive. El rol de IAM que se utiliza para el trabajo debe tener el permiso `glue:CreateDatabase`. Si no existe una base de datos, se crea una denominada “default (predeterminada)” en el Data Catalog.

Connections

Seleccione una configuración de VPC para acceder a los orígenes de datos de Amazon S3 ubicados en la nube privada virtual (VPC). En AWS Glue, puede crear y administrar la conexión de red. Para obtener más información, consulte Conexión a datos.

Bibliotecas

La ruta de la biblioteca de Python, la ruta de los archivos JAR dependientes y la ruta de archivos referenciados

Especifique estas opciones si el script las requiere. Puede definir las rutas de Amazon S3 separadas por comas para estas opciones al definir el trabajo. Puede omitir estas rutas al ejecutar el flujo de trabajo. Para obtener más información, consulte Suministro de sus propios scripts personalizados.

Parámetros del flujo de trabajo

Conjunto de pares de clave-valor que se pasan como parámetros de nombres al script. Estos son valores predeterminados que se utilizan cuando se ejecuta el script, pero se pueden invalidar en desencadenadores o cuando se ejecuta el trabajo. Debe agregar el prefijo `--` al nombre de clave; por ejemplo: `--myKey`. Los parámetros de trabajo se pasan como asignación cuando se utiliza la AWS Command Line Interface.

Para obtener ejemplos, consulte los parámetros de Python en Suministro y acceso a los parámetros de Python en AWS Glue.

Etiquetas

Etiquete su trabajo con una Clave de etiqueta y un Valor de etiqueta opcional. Una vez que se crean las claves de etiquetas, son de solo lectura. Utilice etiquetas en algunos recursos para que le resulte más fácil organizarlos e identificarlos. Para obtener más información, consulte Etiquetas de AWS en AWS Glue.

Restricciones para trabajos que acceden a tablas administradas por Lake Formation

Tenga en cuenta las siguientes notas y restricciones al crear trabajos que lean o escriban en tablas administradas por AWS Lake Formation:

- Las siguientes funciones no se soportan en trabajos que acceden a tablas con filtros de nivel de celda:
  - Marcadores de trabajo y ejecución delimitada
  - Predicados de inserción
  - Predicados de particiones de catálogo del lado del servidor
  - enableUpdateCatalog

Edición de scripts de Spark en la consola de AWS Glue

Los scripts contienen código que extrae datos de orígenes, los transforma y los carga en destinos. AWS Glue ejecuta un script cuando inicia un flujo de trabajo.

AWS GlueLos scripts de ETL de pueden codificarse en Python o Scala. Los scripts de Python utilizan un lenguaje que es una extensión del dialecto Python de PySpark para los trabajos de extraer, transformar y cargar (ETL). El script contiene constructos ampliados para gestionar las transformaciones de ETL. Al generar automáticamente lógica de código fuente para el flujo de trabajo, se crea un script. Puede editar este script o proporcionar su propio script para procesar el flujo de trabajo de ETL.

Para obtener más información acerca de cómo definir y editar scripts en AWS Glue, consulte Guía de programación de AWS Glue.

Bibliotecas o archivos adicionales

Si su script requiere bibliotecas o archivos adicionales, puede especificarlos del modo siguiente:

Ruta de la biblioteca Python

Rutas de Amazon Simple Storage Service (Amazon S3) separadas por comas a las bibliotecas de Python requeridas por el script.

> **Note**
>
> Solo se pueden utilizar bibliotecas Python puras. Todavía no se admiten las bibliotecas que se basan en las extensiones de C, como la biblioteca de análisis de datos Python pandas.

Ruta de archivos JAR dependientes

Rutas de Amazon S3 separadas por comas a archivos JAR que requiere el script.

> **Note**
>
> Actualmente, solo se pueden usar bibliotecas Java o Scala (2.11).

Ruta de archivos a la que se hace referencia

Rutas de Amazon S3 separadas por comas a archivos adicionales (por ejemplo, archivos de configuración) requeridas por el script.

Trabajos (heredado)

Los scripts contienen el código que lleva a cabo el flujo de trabajo de extraer, transformar y cargar (ETL). Puede suministrar su propio script o bien, AWS Glue puede generarlo con su ayuda. Para obtener información sobre la creación de sus propios scripts, consulte Suministro de sus propios scripts personalizados.

Puede editar scripts en la consola de AWS Glue. Cuando edite scripts, podrá añadir orígenes, destinos y transformaciones.

Para editar un script

1. Inicie sesión en la Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/. Después, seleccione pestaña Jobs (Trabajos).

2. Seleccione un flujo de trabajo de la lista y, a continuación, seleccione Action (Acción), Edit script (Editar script) para abrir el editor de scripts.

   También puede acceder al editor de scripts desde la página de detalles del flujo de trabajo. Elija la pestaña Script, y luego elija Edit script (Editar script).

Editor de scripts

Con el editor de scripts de AWS Glue, puede insertar, modificar y eliminar orígenes, destinos y transformaciones en el script. El editor de scripts muestra el script y un diagrama para ayudarle a visualizar el flujo de datos.

Para crear un diagrama para el script, elija Generate diagram (Genera diagrama). AWS Glue utiliza líneas de anotación en el script que comienzan con # # para representar el diagrama. Para representar correctamente el script en el diagrama, debe tener sincronizados los parámetros de las anotaciones y los parámetros del código de Apache Spark.

Con el editor de scripts, puede añadir plantillas de código cuando el cursor esté sobre el script. En la parte superior del editor, seleccione las opciones que correspondan:

- Para agregar una tabla de orígenes al script, seleccione Source (Origen).
- Para agregar una tabla de destinos al script, seleccione Target (Destino).
- Para agregar una ubicación de destino al script, seleccione Target location (Ubicación de destino).
- Para agregar una transformación al script, seleccione Transform (Transformación). Para obtener información sobre las funciones que se invocan en el script, consulte Programación de scripts de ETL de AWS Glue en PySpark.
- Para agregar una transformación de espiga al script, seleccione Spigot (Espiga).

En el código insertado, modifique `parameters` en las anotaciones y el código de Apache Spark. Por ejemplo, si añade una transformación Spigot (Espiga), compruebe que `path` se sustituirá tanto en la anotación `@args` como en la línea de código `output`.

La pestaña Logs (Registros) muestra los registros que están asociados con el flujo de trabajo mientras se ejecuta. Aparecen las últimas 1000 líneas.

La pestaña Schema (Esquema) muestra el esquema de los orígenes y los destinos seleccionados, cuando están disponibles en el Data Catalog.

Seguimiento de los datos procesados mediante marcadores de trabajo

AWS Glue realiza un seguimiento de los datos que ya se han procesado durante una ejecución anterior de un trabajo de ETL mediante información de estado persistente de la ejecución del trabajo. Esta información de estado persistente se llama marcador de flujo de trabajo. Los marcadores de trabajo ayudan a AWS Glue a mantener la información de estado y evitar el reprocesamiento de los datos antiguos. Con los marcadores de trabajo, puede procesar datos nuevos al volver a realizar una ejecución en un intervalo programado. Un marcador de trabajo se compone de los estados de diversos elementos de trabajos, como orígenes, transformaciones y destinos. Por ejemplo, su trabajo de ETL podría leer nuevas particiones en un archivo de Amazon S3. AWS Glue hace el seguimiento de las particiones que el trabajo ha procesado correctamente para evitar procesamiento y datos duplicados en el almacén de datos de destino del trabajo.

Los marcadores de trabajo se implementan para los orígenes de datos JDBC, la transformación Relationalize (Establecimiento de relaciones) y algunos orígenes Amazon Simple Storage Service (Amazon S3). En la siguiente tabla se muestran los formatos de origen Amazon S3 que AWS Glue soporta para los marcadores del trabajo.

Versión de AWS Glue	Formatos de origen de Amazon S3
Versión 0.9	JSON, CSV, Apache Avro, XML
Versión 1.0 y posteriores.	JSON, CSV, Apache Avro, XML, Parquet, ORC

Para obtener información acerca de las versiones de AWS Glue, consulte Definición de propiedades de trabajo para trabajos de Spark.

La característica de marcadores de trabajo tiene funcionalidades adicionales cuando se accede a ella a través de scripts AWS Glue. Al navegar por el script generado, es posible que vea contextos de transformación relacionados con esta característica. Para obtener más información, consulte the section called “Uso de marcadores de trabajo”.

Temas

- Uso de marcadores de trabajo en AWS Glue
- Detalles operativos de la característica de marcadores de trabajo

Uso de marcadores de trabajo en AWS Glue

La opción de marcador de trabajo se transfiere como parámetro al iniciarse el trabajo. En la siguiente tabla se describen las opciones para la configuración de marcadores de trabajo en la consola de AWS Glue.

Job bookmark (Marcador de flujo de trabajo)	Descripción
Habilitado	Hace que el trabajo actualice el estado después de una ejecución para realizar un seguimiento de datos procesados anteriormente. Si el trabajo tiene un origen con compatibilidad de marcador de trabajo, realizará un seguimiento de los datos procesados y cuando se ejecute un trabajo, procesará datos nuevos desde el último punto de control.
Deshabilitado	Los marcadores de trabajo no se utilizan y el trabajo siempre procesa todo el conjunto de datos. Usted es responsable de administrar el resultado de las ejecuciones de trabajos anteriores. Esta es la opción predeterminada.
Pause	Procesar los datos incrementales desde la última ejecución correcta o los datos en el rango identificado por las siguientes subopciones, sin actualizar el estado del último marcador. Usted es responsable de administrar el resultado de las ejecuciones de trabajos anteriores. Las dos subopciones son: • job-bookmark-from <from-value> es el ID de ejecución que represent a toda la entrada que se ha procesado hasta la última ejecución correcta antes de la misma e incluye el ID de ejecución especificado. La entrada correspondiente se ignora. • job-bookmark-to <to-value> es el ID de ejecución que representa toda la entrada que se ha procesado hasta la última ejecución correcta antes de la misma e incluye el ID de ejecución especificado. El trabajo procesa la entrada correspondiente, excluida la entrada identificada por <from-value>. Cualquier entrada posterior a esta entrada también se excluye para el procesamiento.

Job bookmark (Marcador de flujo de trabajo)	Descripción
	El estado del marcador de trabajo no se actualiza cuando se especifica este conjunto de opciones. Las subopciones son opcionales; sin embargo, cuando se utilizan ambas opciones, se deben proporcionar.

Para obtener información detallada sobre los parámetros transferidos a un trabajo en la línea de comandos y para los marcadores de trabajo específicamente, consulte Uso de los parámetros de trabajo en los trabajos de AWS Glue.

Para orígenes de entrada de Amazon S3, los marcadores de trabajo de AWS Glue comprueban la hora de última modificación de los objetos para verificar qué objetos deben volver a procesarse. Si los datos de origen de entrada se han modificado desde la última ejecución de trabajo, los archivos se vuelven a procesar al ejecutar el trabajo de nuevo.

Para los orígenes JDBC, se aplican las reglas siguientes:

- Para cada tabla, AWS Glue utiliza una o más columnas como claves de marcador para determinar los datos nuevos y procesados. Las claves de marcador se combinan para formar una única clave compuesta.
- AWS Glue utiliza la clave principal como clave de marcador de forma predeterminada, siempre que aumente o disminuya secuencialmente (sin espacios).
- Puede especificar las columnas que se van a utilizar como claves de marcador en el script de AWS Glue. Para obtener más información sobre el uso de marcadores de trabajo en scripts de AWS Glue, consulte the section called “Uso de marcadores de trabajo”.
- AWS Glue no admite el uso de columnas con nombres que distinguen mayúsculas de minúsculas como claves de marcadores de trabajo.

Puede retroceder sus marcadores de trabajo para sus trabajos de Spark ETL de AWS Glue a cualquier ejecución de trabajo anterior. Puede admitir escenarios de reposición de datos mejor al rebobinar sus marcadores de trabajo a cualquier ejecución de trabajo anterior reprocesando los datos solo desde la ejecución del trabajo marcado.

Si va a volver a procesar todos los datos utilizando el mismo trabajo, restablezca el marcador de trabajo. Para restablecer el estado del marcador de trabajo, utilice la consola de AWS Glue, la Acción ResetJobBookmark (Python: reset_job_bookmark)operación de API o AWS CLI. Por ejemplo, escriba el siguiente comando usando AWS CLI:

```
aws glue reset-job-bookmark --job-name my-job-name
```

Al retroceder o restablecer un marcador, AWS Glue no limpia los archivos de destino porque podría haber varios destinos y los destinos no se rastrean con marcadores de trabajo. Sólo los archivos de origen se rastrean con marcadores de trabajo. Puede crear diferentes destinos de salida al retroceder y reprocesar los archivos de origen para evitar datos duplicados en la salida.

AWS Glue realiza el seguimiento de los marcadores de flujo de trabajo para cada flujo de trabajo. Si elimina un flujo de trabajo, el marcador de flujo de trabajo se elimina.

En algunos casos, es posible que tenga habilitados marcadores de trabajo de AWS Glue, pero su trabajo de ETL está reprocesando los datos que ya se han procesado anteriormente. Para obtener información acerca de la resolución de causas comunes de este error, consulte Solución de errores de Spark.

Detalles operativos de la característica de marcadores de trabajo

En esta sección se describen más detalles operativos de utilizar marcadores de trabajo.

Los marcadores de trabajo almacenan los estados de un trabajo. Cada instancia del estado está marcada con un nombre de trabajo y un número de versión. Cuando un script invoca `job.init`, recupera su estado y siempre obtiene la última versión. Dentro de un estado, hay varios elementos de estado, que son específicos de cada origen, transformación e instancia de receptor en el script. Estos elementos de estado se identifican mediante un contexto de transformación que se adjunta al elemento correspondiente (origen, transformación o receptor) en el script. Los elementos de estado se guardan de manera granular cuando `job.commit` se haya invocado desde el script de usuario. El script obtiene el nombre del trabajo y la opción de control de los marcadores de trabajo de los argumentos.

Los elementos de estado del marcador de trabajo son datos específicos de origen, transformación o receptor. Por ejemplo, supongamos que desea leer los datos progresivos desde una ubicación de Amazon S3 a la que un proceso o trabajo ascendente escribe en forma constante. En este caso, el script debe determinar qué se ha procesado hasta el momento. La implementación de marcador de

trabajo para el origen de Amazon S3 guarda la información para que cuando el trabajo se ejecute de nuevo, pueda filtrar solo los nuevos objetos mediante la información guardada y recalcular el estado para la próxima ejecución del trabajo. Se utiliza una marca temporal para filtrar los archivos nuevos.

Además de los elementos de estado, los marcadores de trabajo tienen un número de ejecución, un número de intentos y un número de versión. El número de ejecución realiza un seguimiento de la ejecución del trabajo y el número de intentos registra los intentos de ejecución de un trabajo. El número de ejecuciones de un trabajo es un número que se incrementa de forma monotónica por cada ejecución correcta. El número de intentos realiza un seguimiento de los intentos de cada ejecución y solo se incrementa cuando hay una ejecución después de un intento fallido. El número de versión aumenta de forma monotónica y realiza un seguimiento de las actualizaciones de un marcador de trabajo.

En la base de datos del servicio AWS Glue, los estados de favorito de todas las transformaciones se almacenan juntos como pares clave-valor:

```
{
  "job_name" : ...,
  "run_id": ...,
  "run_number": ..,
  "attempt_number": ...
  "states": {
    "transformation_ctx1" : {
      bookmark_state1
    },
    "transformation_ctx2" : {
      bookmark_state2
    }
  }
}
```

Prácticas recomendadas

A continuación, se indican las prácticas recomendadas para utilizar marcadores de trabajo.

- No cambie la propiedad del origen de datos con el favorito habilitado. Por ejemplo, hay un origen de datos datasource0 que apunta a una ruta de entrada A de Simple Storage Service (Amazon S3), y el trabajo ha estado leyendo desde un origen que se ha estado ejecutando durante varias rondas con el favorito habilitado. Si cambia la ruta de entrada de datasource0 a la ruta B de Simple Storage Service (Amazon S3) sin cambiar `transformation_ctx`, el trabajo de AWS Glue utilizará el antiguo estado de favorito almacenado. Eso provocará que se omitan o falten archivos

en la ruta de entrada B, ya que AWS Glue presupondrá que esos archivos se han procesado en ejecuciones anteriores.

- Utilice una tabla de catálogo con favoritos para mejorar la administración de particiones. Los favoritos funcionan para orígenes de datos de Data Catalog o de opciones. No obstante, resulta difícil eliminar/agregar nuevas particiones con el enfoque de opciones. Utilizar una tabla de catálogo con rastreadores puede proporcionar una mejor automatización para realizar un seguimiento de las nuevas particiones agregadas, y ofrece flexibilidad para seleccionar particiones concretas con un predicado de inserción.
- Utilice el enumerador de archivos de Simple Storage Service (Amazon S3) de AWS Glue para conjuntos de datos de gran tamaño. Un favorito mostrará una lista de todos los archivos de cada partición de entrada y realizará el filtrado, de modo que, si hay demasiados archivos en una sola partición, puede que el controlador del favorito se quede sin suficiente memoria. Utilice el enumerador de archivos de Simple Storage Service (Amazon S3) de AWS Glue para evitar mostrar una lista de todos los archivos de la memoria a la vez.

Almacenamiento de datos de mezclas aleatorias de Spark

El mezclado aleatorio es un paso importante en un trabajo de Spark siempre que los datos se reorganizan entre particiones. Esto es necesario porque transformaciones de gran extensión como `join`, `groupByKey`, `reduceByKey`, y `repartition` requieren información de otras particiones para completar el procesamiento. Spark recopila los datos requeridos de cada partición y los combina en una nueva partición. Durante una mezcla aleatoria, los datos se escriben en el disco y se transfieren a través de la red. Como resultado, la operación de mezcla aleatoria está vinculada a la capacidad del disco local. Spark lanza un error `No space left on device` o `MetadataFetchFailedException` cuando no queda suficiente espacio en disco en el ejecutor y no se puede realizar la recuperación.

> **Note**
>
> El complemento AWS Glue Spark shuffle de Amazon S3 solo es compatible con los trabajos de ETL AWS Glue.

Solución

Con AWS Glue, ahora puede utilizar Amazon S3 para almacenar datos de mezclas aleatorias de Spark. Amazon Simple Storage Service (Amazon S3) es un servicio de almacenamiento de objetos

que ofrece escalabilidad, disponibilidad de datos, seguridad y rendimiento líderes del sector. Esta solución separa la informática y el almacenamiento para sus trabajos de Spark y proporciona una elasticidad completa y un almacenamiento de mezclas aleatorias de bajo costo, lo que le permite ejecutar con confianza sus cargas de trabajo con mayor cantidad de mezclas aleatorias.

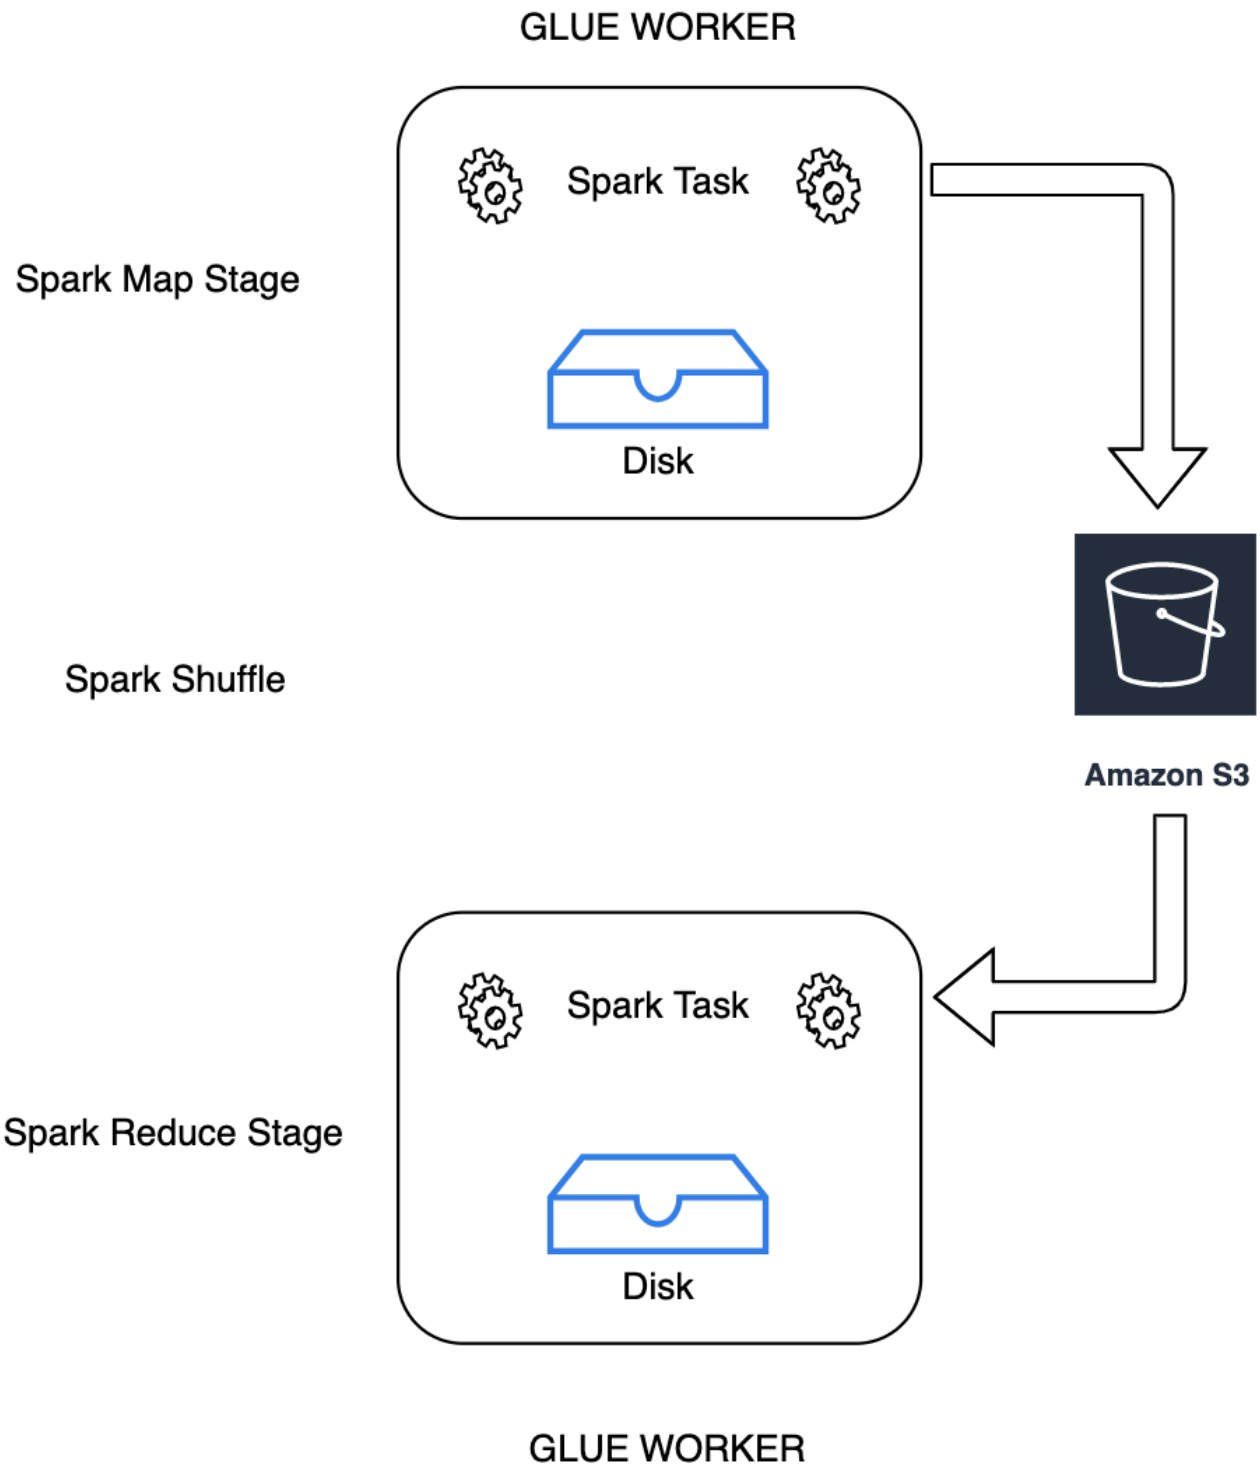

Presentamos Cloud Shuffle Storage, un nuevo complemento para Apache Spark para usar Amazon S3. Puede habilitar la función de mezclado aleatorio de Amazon S3 para ejecutar sus trabajos de AWS Glue con confianza y sin errores si se sabe que están vinculados por la capacidad del disco local para operaciones de mezclas aleatorias grandes. En algunos casos, el mezclado aleatorio en Amazon S3 es ligeramente más lento que el disco local (o EBS) si tiene un gran número de pequeñas particiones o archivos de mezcla aleatoria escritos en Amazon S3.

Requisitos previos para usar el complemento de almacenamiento de Cloud Shuffle

Para usar el complemento de almacenamiento de Cloud Shuffle con trabajos de AWS Glue ETL, necesita lo siguiente:

- Un bucket de Amazon S3 ubicado en la misma región en la que se ejecutó el trabajo, para almacenar los datos intermedios mezclados y volcados. El prefijo Amazon S3 del almacenamiento aleatorio se puede especificar con `--conf spark.shuffle.glue.s3ShuffleBucket=s3://`*`shuffle-bucket`*`/`*`prefix`*`/`, como en el siguiente ejemplo:

  ```
  --conf spark.shuffle.glue.s3ShuffleBucket=s3://glue-shuffle-123456789-us-east-1/glue-shuffle-data/
  ```

- Establezca las políticas de ciclo de vida de almacenamiento de Amazon S3 en el prefijo (como `glue-shuffle-data`) ya que el administrador de mezclas aleatorias no limpia los archivos una vez finalizado el trabajo. Los datos intermedios mezclados y volcados se deben eliminar una vez finalizado el trabajo. Los usuarios pueden establecer políticas de ciclo de vida breves en el prefijo. Las instrucciones para configurar la política de ciclo de vida de Amazon S3 están disponibles en Configurar el ciclo de vida de un bucket en la Guía del usuario de Amazon Simple Storage Service.

Uso del administrador de mezclas aleatorias de AWS Glue Spark desde la consola de AWS

Para configurar el administrador de mezclas aleatorias de AWS Glue Spark con la consola de AWS Glue o AWS Glue Studio cuando configura un trabajo: elija el parámetro de trabajo: --write-shuffle-files-to-s3 para habilitar el mezclado aleatorio de Amazon S3 para el trabajo.

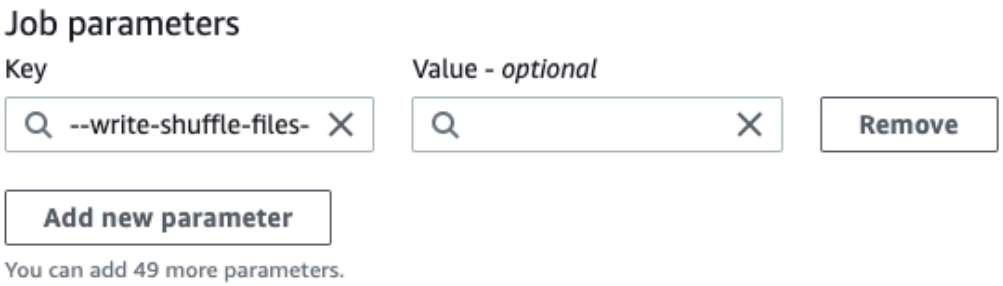

Uso del complemento de mezclas aleatorias de AWS Glue Spark

Los siguientes parámetros de trabajo activan y establecen los ajustes del administrador de mezclas aleatorias de AWS Glue. Estos parámetros son indicadores, por lo que no se tienen en cuenta los valores proporcionados.

- `--write-shuffle-files-to-s3`: el valor de la marca principal habilita la opción del administrador de mezclas aleatorias de AWS Glue Spark para utilizar buckets de Amazon S3 para escribir y leer datos aleatorios. Cuando la marca no se especifica, no se utiliza el administrador de mezclas aleatorias.
- `--write-shuffle-spills-to-s3`: (solo se admite en la versión 2.0 de AWS Glue). Una marca opcional que permite descargar archivos de volcado en buckets de Amazon S3, lo que proporciona resistencia adicional al trabajo de Spark. Esto solo es necesario para cargas de trabajo grandes que provocan grandes desbordamientos al disco. Cuando no se especifica la marca, no se graba ningún archivo de volcado intermedio.
- `--conf spark.shuffle.glue.s3ShuffleBucket=s3://<shuffle-bucket>`: otra marca opcional que especifica el bucket de Amazon S3 en el que se escriben los archivos de mezcla aleatoria. De forma predeterminada, `--TempDir`/shuffle-data. AWS Glue 3.0+ permite escribir archivos aleatorios en varios buckets al especificar los buckets con un delimitador de comas, como en `--conf spark.shuffle.glue.s3ShuffleBucket=s3://`*`shuffle-bucket-1`*`/`*`prefix`*`,s3://`*`shuffle-bucket-2`*`/`*`prefix`*`/`. El uso de varios buckets mejora el rendimiento.

Debe proporcionar los ajustes de configuración de seguridad para habilitar el cifrado en reposo de los datos aleatorios. Para obtener más información sobre las configuraciones de seguridad, consulte the section called “Configuración del cifrado”. AWS Glue admite todas las demás configuraciones relacionadas con mezclas aleatorias proporcionadas por Spark.

Archivos binarios del software para el complemento Cloud Shuffle Storage

También puede descargar los archivos binarios del software del complemento Cloud Shuffle Storage para Apache Spark bajo la licencia Apache 2.0 y ejecutarlo en cualquier entorno de Spark. El nuevo complemento incluye compatibilidad lista para usar con Amazon S3 y también se puede configurar fácilmente para usar otras formas de almacenamiento en la nube, como Google Cloud Storage y Microsoft Azure Blob Storage. Para obtener más información, consulte Cloud Shuffle Storage Plugin for Apache Spark (Complemento Cloud Shuffle Storage para Apache Spark).

Notas y limitaciones

Las siguientes son notas o limitaciones para el administrador de mezclas aleatorias de AWS Glue:

- El administrador de mezclas aleatorias AWS Glue no elimina automáticamente los archivos de datos de mezcla aleatoria (temporales) almacenados en un bucket de Amazon S3 después de completar un trabajo. Para garantizar la protección de los datos, siga las instrucciones que se indican en Requisitos previos para usar el complemento de almacenamiento de Cloud Shuffle antes de activar el complemento Cloud Shuffle Storage Plugin.
- Puede utilizar esta característica si los datos están sesgados.

Complemento Cloud Shuffle Storage para Apache Spark

El complemento Cloud Shuffle Storage es un complemento de Apache Spark compatible con la API de `ShuffleDataIO` que permite almacenar datos aleatorios en sistemas de almacenamiento en la nube (como Amazon S3). Ayuda a complementar o reemplazar la capacidad de almacenamiento del disco local para operaciones aleatorias de gran tamaño que suelen desencadenarse por transformaciones como `join`, `reduceByKey`, `groupByKey` y `repartition` en las aplicaciones de Spark, lo que reduce los errores comunes o la dislocación de precio y rendimiento de las canalizaciones y los trabajos de análisis de datos sin servidor.

AWS Glue

Las versiones 3.0 y 4.0 de AWS Glue incluyen el complemento preinstalado y listo para permitir la transferencia aleatoria a Amazon S3 sin ningún paso adicional. Para más información, consulte Complemento de mezclas aleatorias de Spark para AWS Glue con Amazon S3 para habilitar la característica en las aplicaciones de Spark.

Otros entornos de Spark

El complemento requiere que se establezcan las siguientes configuraciones de Spark en otros entornos de Spark:

- `--conf spark.shuffle.sort.io.plugin.class=com.amazonaws.spark.shuffle.io.cloud.Choppe` esto indica a Spark que debe utilizar este complemento para Shuffle IO.
- `--conf spark.shuffle.storage.path=s3://`*`bucket-name`*`/`*`shuffle-file-dir`*: la ruta en la que se almacenarán los archivos aleatorios.

> **Note**
>
> El complemento sobrescribe una clase principal de Spark. Como resultado, el contenedor del complemento debe cargarse antes que los contenedores de Spark. Para ello, utilice `userClassPathFirst` en entornos YARN locales si el complemento se utiliza fuera de AWS Glue.

Agrupación del complemento con las aplicaciones de Spark

Puede combinar el complemento con las aplicaciones de Spark y distribuciones de Spark (versiones 3.1 y posteriores) si agrega la dependencia del complemento en `pom.xml` de Maven mientras desarrolla las aplicaciones de Spark de manera local. Para más información acerca del complemento y las versiones de Spark, consulte Versiones del complemento.

```
<repositories>
   ...
    <repository>
        <id>aws-glue-etl-artifacts</id>
        <url>https://aws-glue-etl-artifacts.s3.amazonaws.com/release/ </url>
    </repository>
</repositories>
...
<dependency>
    <groupId>com.amazonaws</groupId>
    <artifactId>chopper-plugin</artifactId>
    <version>3.1-amzn-LATEST</version>
</dependency>
```

También puede descargar los archivos binarios de los artefactos de Maven de AWS Glue directamente e incluirlos en la aplicación de Spark de la siguiente manera.

```
#!/bin/bash
sudo wget -v https://aws-glue-etl-artifacts.s3.amazonaws.com/release/com/amazonaws/
chopper-plugin/3.1-amzn-LATEST/chopper-plugin-3.1-amzn-LATEST.jar -P /usr/lib/spark/
jars/
```

Ejemplo spark-submit

```
spark-submit --deploy-mode cluster \
--conf spark.shuffle.storage.s3.path=s3://<ShuffleBucket>/<shuffle-dir> \
--conf spark.driver.extraClassPath=<Path to plugin jar> \
--conf spark.executor.extraClassPath=<Path to plugin jar> \
--class <your test class name> s3://<ShuffleBucket>/<Your application jar> \
```

Opciones de configuración opcionales

Estos son los valores de las opciones de configuración opcionales que controlan el comportamiento aleatorio de Amazon S3.

- `spark.shuffle.storage.s3.enableServerSideEncryption`: habilita y desactiva SSE de S3 para ordenar aleatoriamente y volcar archivos. El valor predeterminado es `true`.
- `spark.shuffle.storage.s3.serverSideEncryption.algorithm`: el algoritmo de SSE que se va a usar. El valor predeterminado es `AES256`.
- `spark.shuffle.storage.s3.serverSideEncryption.kms.key`: el ARN de la clave de KMS cuando aws:kms de SSE está activado.

Junto con estas configuraciones, es posible que deba establecer configuraciones como`spark.hadoop.fs.s3.enableServerSideEncryption`, y otras configuraciones específicas del entorno para garantizar que se aplique el cifrado adecuado para su caso de uso.

Versiones del complemento

Este complemento es compatible con las versiones de Spark asociadas a cada versión de AWS Glue. En la siguiente tabla, se muestra la versión de AWS Glue, la versión de Spark y la versión del complemento asociada a la ubicación de Amazon S3 del binario de software del complemento.

Versión de AWS Glue	Versión de Spark	Versión del complemento	Ubicación de Amazon S3
3.0	3.1	3.1-amzn-LATEST	s3://aws-glue-etl-artifacts/release/com/amazonaws/chopper-plugin/3.1-amzn-0/chopper-plugin-3.1-amzn-LATEST.jar
4.0	3.3	3.3-amzn-LATEST	s3://aws-glue-etl-artifacts/release/com/amazonaws/chopper-plugin/3.3-amzn-0/chopper-plugin-3.3-amzn-LATEST.jar

Licencia

El binario de software de este complemento cuenta con la licencia de Apache-2.0.

Supervisión de trabajos de Spark de AWS Glue

Temas

- Métricas de Spark disponibles en AWS Glue Studio
- Monitorización de trabajos mediante la interfaz de usuario web de Apache Spark
- Supervisión con Información de ejecuciones de trabajos de AWS Glue
- Supervisión con Amazon CloudWatch
- Monitorización y depuración de trabajo

Métricas de Spark disponibles en AWS Glue Studio

La pestaña Metrics (Métricas) muestra las métricas recopiladas cuando se ejecuta un trabajo y se habilita la creación de perfiles. En los trabajos de Spark se muestran los gráficos siguientes:

- Movimiento de datos de ETL

- Perfil de la memoria: controlador y ejecutores

Elija View additional metrics (Ver métricas adicionales) para mostrar los siguientes gráficos:

- Movimiento de datos de ETL
- Perfil de la memoria: controlador y ejecutores
- Mezcla de datos entre los ejecutores
- Carga de la CPU: controlador y ejecutores
- Ejecución de trabajo: ejecutores activos, etapas completadas y número máximo de ejecutores necesarios

Los datos de estos gráficos se insertan en las métricas de CloudWatch si el trabajo se configura para recopilar métricas. Para obtener más información acerca de cómo habilitar métricas e interpretar los gráficos, consulte Monitorización y depuración de trabajo.

Example Gráfico de movimiento de datos de ETL

En el gráfico de movimiento de datos de ETL se muestran las siguientes métricas:

- El número de bytes que leen todos los ejecutores de Amazon S3 —`glue.ALL.s3.filesystem.read_bytes`
- El número de bytes que escriben todos los ejecutores en Amazon S3 —`glue.ALL.s3.filesystem.write_bytes`

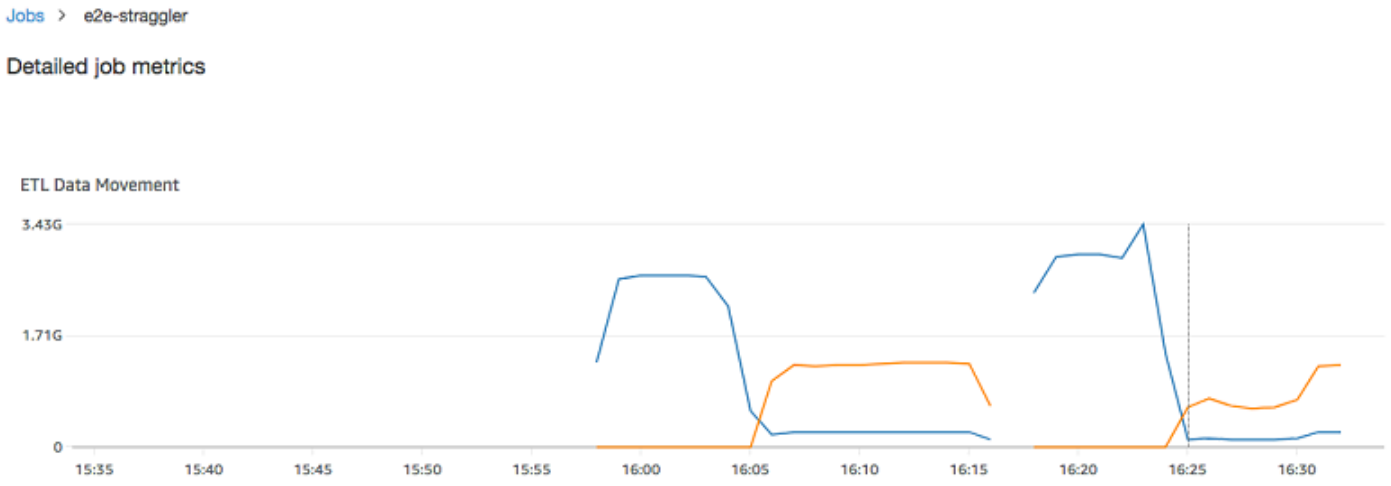

Example Gráfico de perfil de la memoria

En el gráfico de perfil de la memoria se muestran las siguientes métricas:

- La fracción de la memoria usada por el montón de JVM para este controlador (escala: de 0 a 1), un ejecutor identificado por executorId, o todos los ejecutores.
  - `glue.driver.jvm.heap.usage`
  - `glue.executorId.jvm.heap.usage`
  - `glue.ALL.jvm.heap.usage`

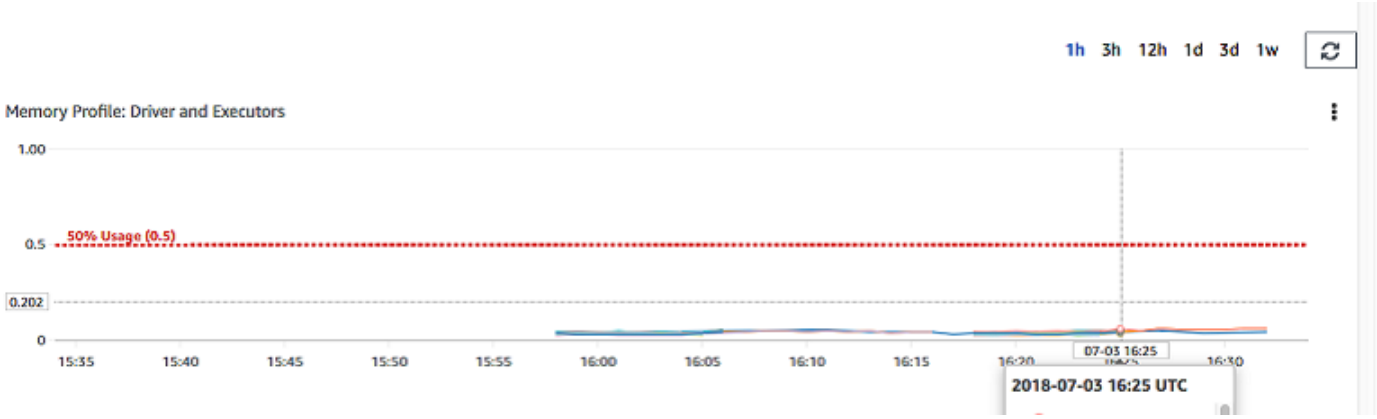

Example Gráfico de mezcla de datos entre los ejecutores

En el gráfico Mezcla de datos entre los ejecutores se muestran las siguientes métricas:

- El número de bytes que leen todos los ejecutores para mezclar los datos entre ellos: `glue.driver.aggregate.shuffleLocalBytesRead`
- El número de bytes que escriben todos los ejecutores para mezclar los datos entre ellos: `glue.driver.aggregate.shuffleBytesWritten`

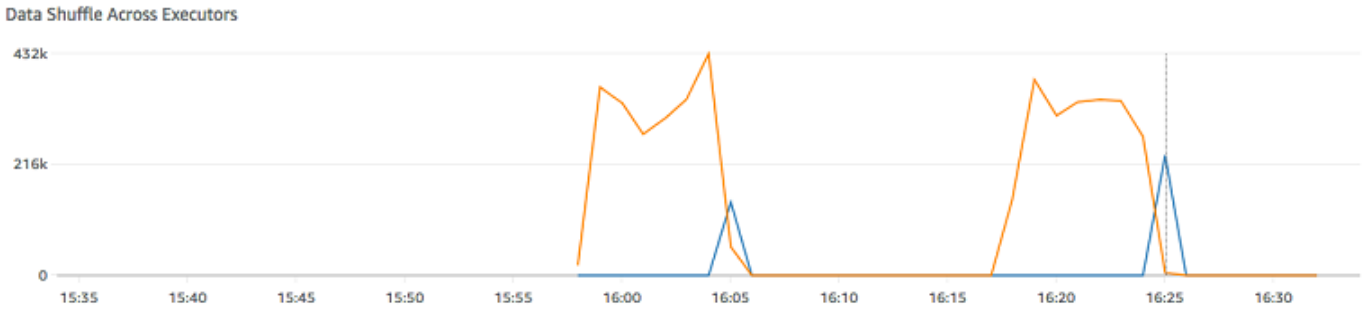

Example Gráfico de carga de la CPU

En el gráfico de carga de la CPU se muestran las siguientes métricas:

- La fracción de la carga del sistema de CPU usada (escala: de 0 a 1) por el controlador, un ejecutor identificado por executorId, o todos los ejecutores.
  - `glue.driver.system.cpuSystemLoad`
  - `glue.executorId.system.cpuSystemLoad`
  - `glue.ALL.system.cpuSystemLoad`

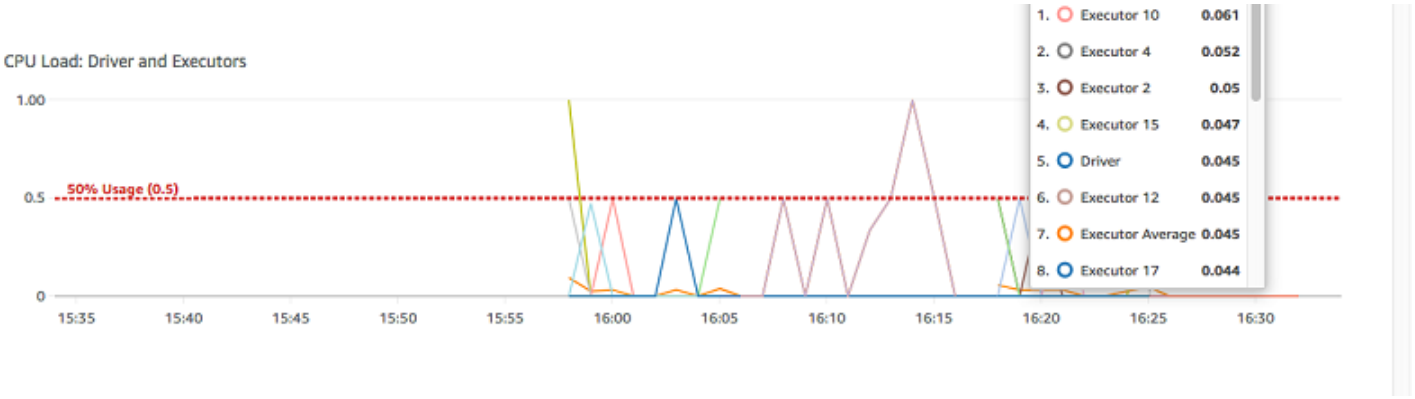

Example Gráfico de ejecución de trabajo

En el gráfico de ejecución de trabajo se muestran las siguientes métricas:

- El número de ejecutores que se ejecutan activamente: `glue.driver.ExecutorAllocationManager.executors.numberAllExecutors`
- El número de etapas completadas: `glue.aggregate.numCompletedStages`

- El número máximo de ejecutores necesarios: `glue.driver.ExecutorAllocationManager.executors.numberMaxNeededExecutors`

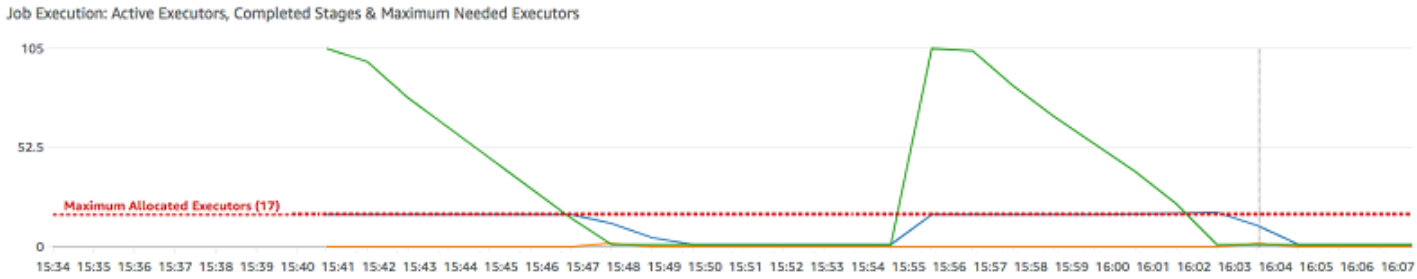

Monitorización de trabajos mediante la interfaz de usuario web de Apache Spark

Puede utilizar la interfaz de usuario web de Apache Spark para monitorizar y depurar trabajos de ETL AWS Glue que se ejecutan en el sistema de trabajos AWS Glue, así como aplicaciones de Spark que se ejecutan en puntos de enlace de desarrollo AWS Glue. La interfaz de usuario de Spark le permite comprobar lo siguiente para cada trabajo:

- La escala de tiempo del evento de cada etapa de Spark
- Un gráfico acíclico dirigido (DAG) del trabajo
- Planes físicos y lógicos para consultas de SparkSQL
- Las variables de entorno de Spark subyacentes para cada trabajo

Para obtener más información sobre el uso de la interfaz de usuario web de Spark, consulta la Interfaz de usuario web en la documentación de Spark. Para obtener orientación sobre cómo interpretar los resultados de la interfaz de usuario de Spark para mejorar el rendimiento de su trabajo, consulte las Prácticas recomendadas para ajustar el rendimiento de AWS Glue para los trabajos de Apache Spark en las Recomendaciones de AWS.

Puede ver la interfaz de usuario de Spark en la consola de AWS Glue. Está disponible cuando un trabajo de AWS Glue se ejecuta en la versión 3.0 o versiones posteriores de AWS Glue y los registros se generan en el formato estándar (en lugar del heredado), que es el predeterminado para los trabajos más recientes. Si tiene archivos de registro de más de 0,5 GB, puede activar la compatibilidad con el registro continuo para las ejecuciones de trabajos en la versión 4.0 o versiones posteriores de AWS Glue para simplificar el archivado de registros, el análisis y la solución de problemas.

Puede habilitar la interfaz de usuario de Spark mediante la consola de AWS Glue o la AWS Command Line Interface (AWS CLI). Al habilitar la interfaz de usuario de Spark, los trabajos de ETL de AWS Glue y las aplicaciones de Spark en puntos de conexión de desarrollo de AWS Glue pueden hacer una copia de seguridad de los registros de eventos de Spark en una ubicación que especifique en Amazon Simple Storage Service (Amazon S3). Los registros de eventos respaldados en Amazon S3 se pueden utilizar con la interfaz de usuario de Spark tanto en tiempo real mientras se está ejecutando el trabajo como después de que se haya completado el trabajo. Mientras los registros permanezcan en Amazon S3, la interfaz de usuario de Spark de la consola de AWS Glue puede verlos.

Permisos

Para utilizar la interfaz de usuario de Spark en la consola de AWS Glue, puede utilizar `UseGlueStudio` o agregar todas las API de servicios individuales. Para utilizar la interfaz de Spark, todas las API son necesarias; sin embargo, los usuarios pueden acceder a las características de la interfaz de Spark al agregar sus API de servicio en el permiso de IAM para un acceso detallado.

`RequestLogParsing` es la más importante, ya que realiza el análisis de los registros. Las API restantes realizan la lectura de los respectivos datos analizados. Por ejemplo, `GetStages` brinda acceso a los datos sobre las etapas de un trabajo de Spark.

La lista de las API de servicio de la interfaz de usuario de Spark elaboradas para `UseGlueStudio` se encuentra a continuación, en la política de muestra. La política a continuación brinda acceso para que solo se utilicen las características de la interfaz de Spark. Para agregar más permisos, como Amazon S3 e IAM, consulte Creación de políticas de IAM personalizadas para AWS Glue Studio.

La lista de las API de servicio de la interfaz de usuario de Spark elaboradas para `UseGlueStudio` se encuentra a continuación, en la política de muestra. Al utilizar una API de servicio de la interfaz de Spark, utilice el espacio de nombre `glue:<ServiceAPI>`.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Sid": "AllowGlueStudioSparkUI",
      "Effect": "Allow",
      "Action": [
```

```
        "glue:RequestLogParsing",
        "glue:GetLogParsingStatus",
        "glue:GetEnvironment",
        "glue:GetJobs",
        "glue:GetJob",
        "glue:GetStage",
        "glue:GetStages",
        "glue:GetStageFiles",
        "glue:BatchGetStageFiles",
        "glue:GetStageAttempt",
        "glue:GetStageAttemptTaskList",
        "glue:GetStageAttemptTaskSummary",
        "glue:GetExecutors",
        "glue:GetExecutorsThreads",
        "glue:GetStorage",
        "glue:GetStorageUnit",
        "glue:GetQueries",
        "glue:GetQuery"
      ],
      "Resource": [
        "*"
      ]
    }
  ]
}
```

Limitaciones

- La interfaz de usuario de Spark en la consola de AWS Glue no está disponible para los trabajos ejecutados antes del 20 de noviembre de 2023, ya que están en el formato de registro heredado.
- La interfaz de usuario de Spark en la consola de AWS Glue admite los registros continuos de la versión 4.0 de AWS Glue, como los que se generan de forma predeterminada en los trabajos de streaming. La suma máxima de todos los archivos de eventos de registro continuo generados es de 2 GB. Para los trabajos de AWS Glue que no admiten registros continuos, el tamaño máximo del archivo de eventos de registro que admite SparkUI es de 0,5 GB.
- La interfaz de usuario de Spark sin servidor no está disponible para los registros de eventos de Spark almacenados en un bucket de Amazon S3 al que solo puede acceder su VPC.

Ejemplo: interfaz de usuario web de Apache Spark

Este ejemplo le muestra cómo utilizar la interfaz de usuario de Spark para entender su desempeño laboral. Las capturas de pantalla muestran la interfaz de usuario web de Spark proporcionada por un servidor de historial de Spark autogestionado. La interfaz de usuario de Spark en la consola de AWS Glue ofrece vistas similares. Para obtener más información sobre el uso de la interfaz de usuario web de Spark, consulta la Interfaz de usuario web en la documentación de Spark.

A continuación, se muestra un ejemplo de una aplicación Spark que lee desde dos orígenes de datos, realiza una transformación de combinación y la escribe en Amazon S3 en formato Parquet.

```
import sys
from awsglue.transforms import *
from awsglue.utils import getResolvedOptions
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job
from pyspark.sql.functions import count, when, expr, col, sum, isnull
from pyspark.sql.functions import countDistinct
from awsglue.dynamicframe import DynamicFrame

args = getResolvedOptions(sys.argv, ['JOB_NAME'])

sc = SparkContext()
glueContext = GlueContext(sc)
spark = glueContext.spark_session

job = Job(glueContext)
job.init(args['JOB_NAME'])

df_persons = spark.read.json("s3://awsglue-datasets/examples/us-legislators/all/
persons.json")
df_memberships = spark.read.json("s3://awsglue-datasets/examples/us-legislators/all/
memberships.json")

df_joined = df_persons.join(df_memberships, df_persons.id == df_memberships.person_id,
 'fullouter')
df_joined.write.parquet("s3://aws-glue-demo-sparkui/output/")

job.commit()
```

La siguiente visualización del DAG muestra las diferentes etapas de este trabajo de Spark.

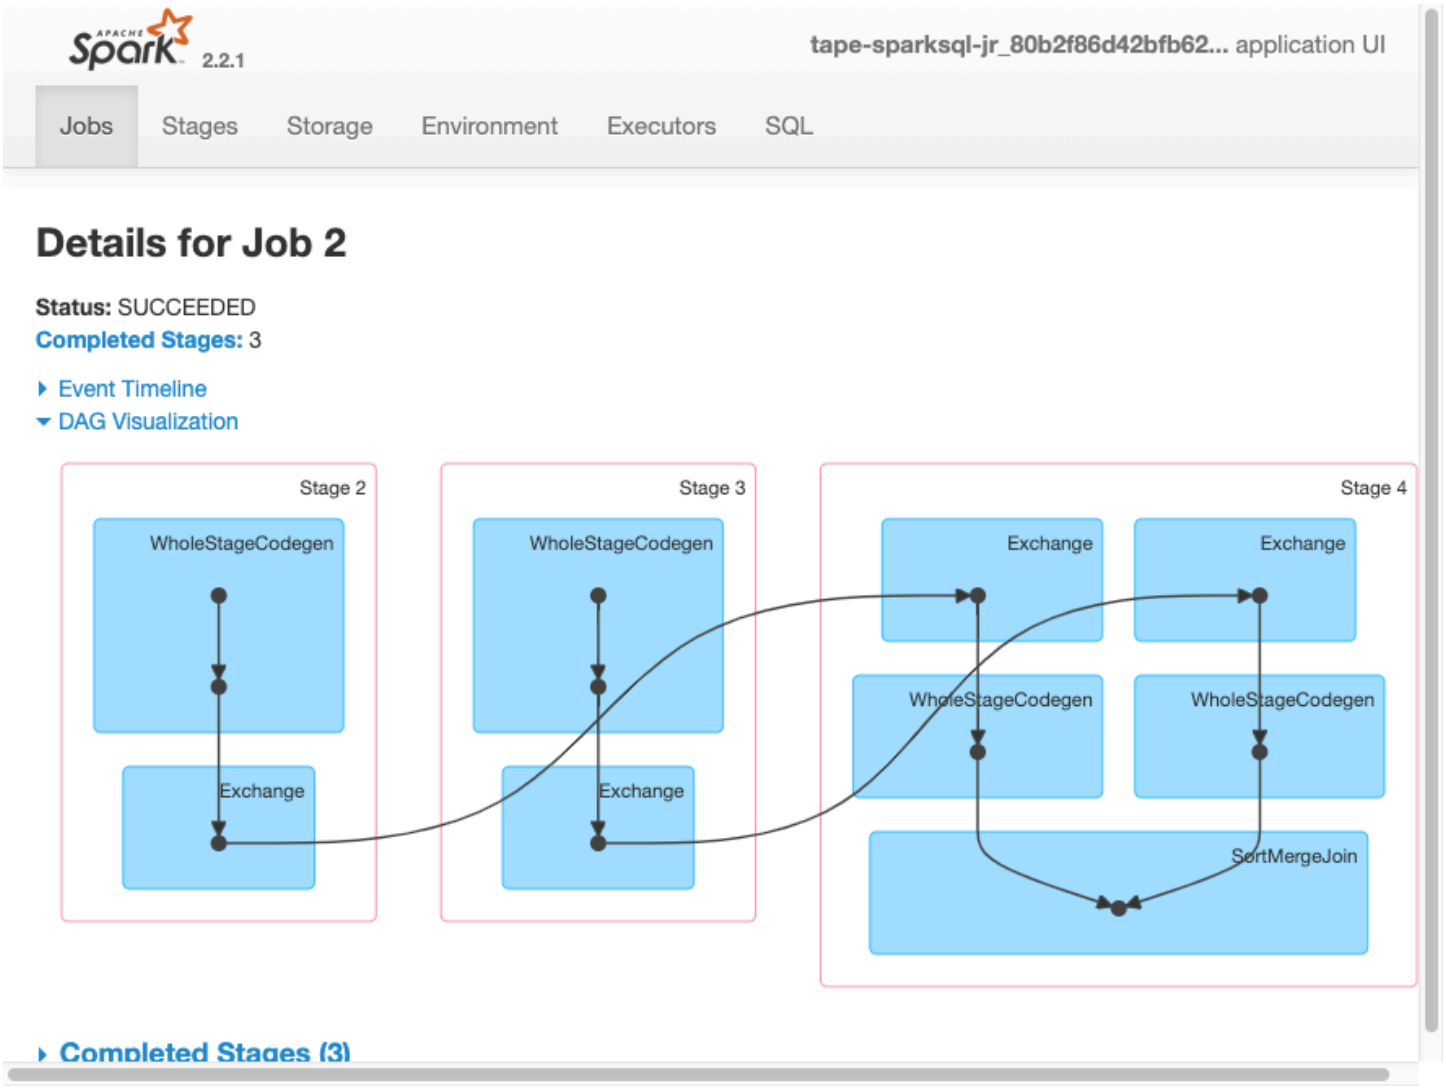

La siguiente escala de tiempo de eventos para un trabajo muestra el inicio, la ejecución y la terminación de diferentes ejecutores de Spark.

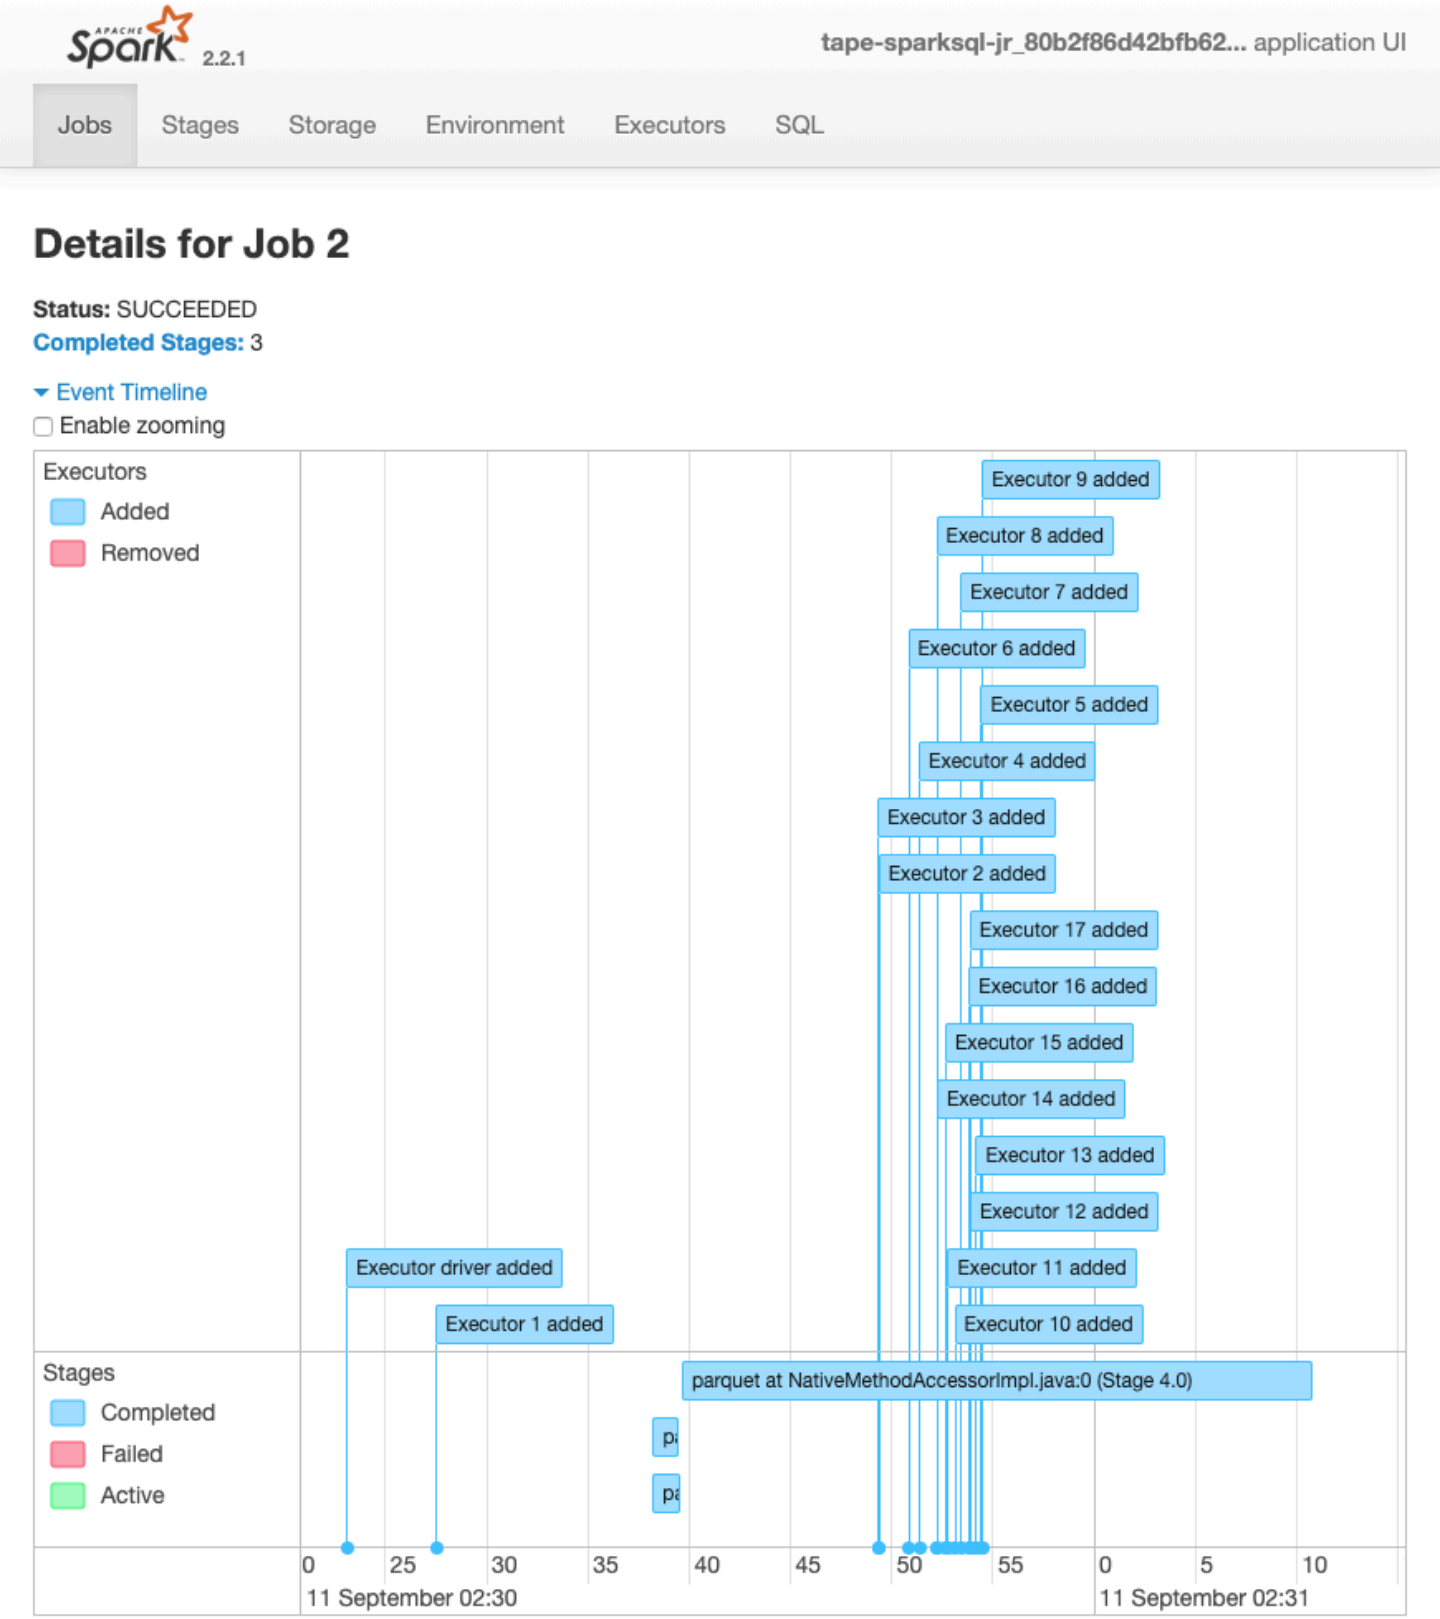
Spark 2.2.1
tape-sparksql-jr_80b2f86d42bfb62... application UI
Jobs
Stages
Storage
Environment
Executors
SQL
Details for Job 2
Status: SUCCEEDED
Completed Stages: 3
Event Timeline
Enable zooming
Executors
Added
Removed
Executor 9 added
Executor 8 added
Executor 7 added
Executor 6 added
Executor 5 added
Executor 4 added
Executor 3 added
Executor 2 added
Executor 17 added
Executor 16 added
Executor 15 added
Executor 14 added
Executor 13 added
Executor 12 added
Executor 11 added
Executor 10 added
Executor driver added
Executor 1 added
Stages
Completed
Failed
Active
parquet at NativeMethodAccessorImpl.java:0 (Stage 4.0)
0
25
30
35
40
45
50
55
0
5
10
11 September 02:30
11 September 02:31
DAG Visualization
Completed Stages (3)

En la siguiente pantalla se muestran los detalles de los planes de consulta de SparkSQL:

- Plan lógico examinado
- Plan lógico analizado
- Plan lógico optimizado
- Plan físico para la ejecución

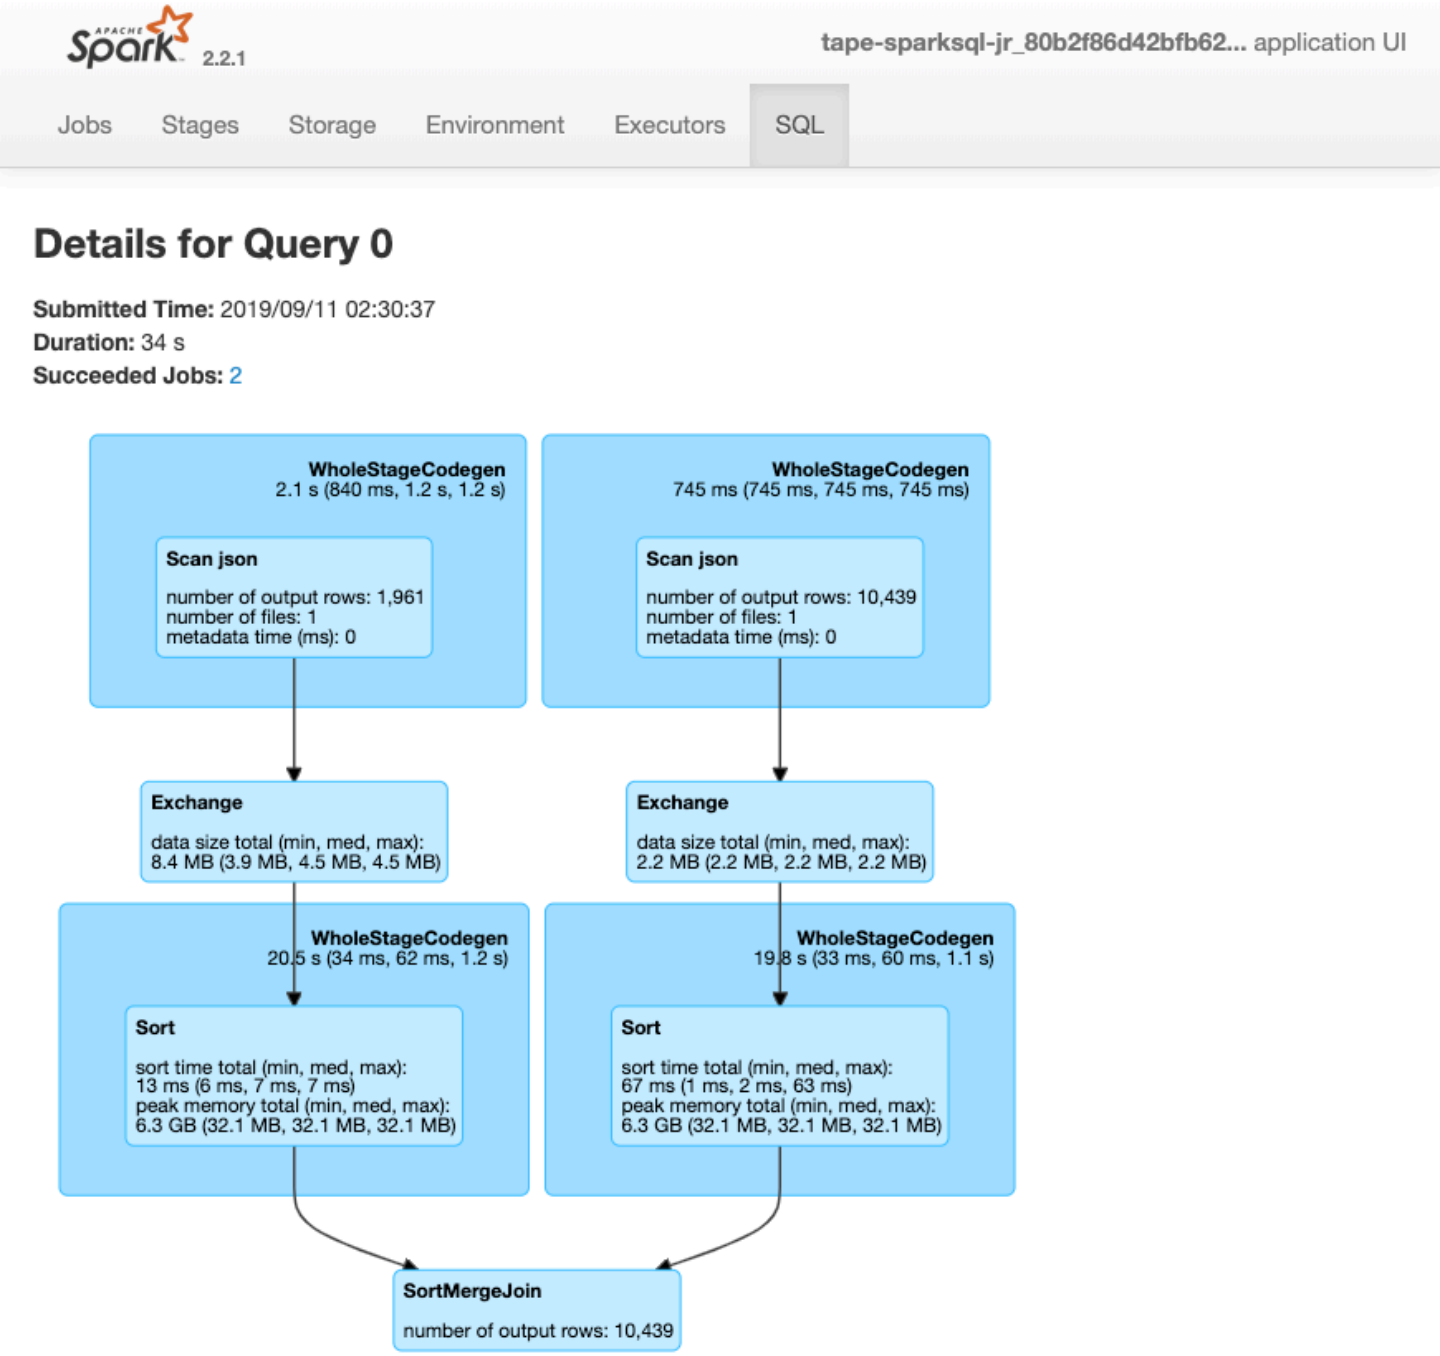
Spark 2.2.1
tape-sparksql-jr_80b2f86d42bfb62... application UI
Jobs
Stages
Storage
Environment
Executors
SQL
Details for Query 0
Submitted Time: 2019/09/11 02:30:37
Duration: 34 s
Succeeded Jobs: 2
WholeStageCodegen
2.1 s (840 ms, 1.2 s, 1.2 s)
Scan json
number of output rows: 1,961
number of files: 1
metadata time (ms): 0
WholeStageCodegen
745 ms (745 ms, 745 ms, 745 ms)
Scan json
number of output rows: 10,439
number of files: 1
metadata time (ms): 0
Exchange
data size total (min, med, max):
8.4 MB (3.9 MB, 4.5 MB, 4.5 MB)
Exchange
data size total (min, med, max):
2.2 MB (2.2 MB, 2.2 MB, 2.2 MB)
WholeStageCodegen
20.5 s (34 ms, 62 ms, 1.2 s)
Sort
sort time total (min, med, max):
13 ms (6 ms, 7 ms, 7 ms)
peak memory total (min, med, max):
6.3 GB (32.1 MB, 32.1 MB, 32.1 MB)
WholeStageCodegen
19.8 s (33 ms, 60 ms, 1.1 s)
Sort
sort time total (min, med, max):
67 ms (1 ms, 2 ms, 63 ms)
peak memory total (min, med, max):
6.3 GB (32.1 MB, 32.1 MB, 32.1 MB)
SortMergeJoin
number of output rows: 10,439
Details
== Parsed Logical Plan ==
Join FullOuter, (id#14 = person_id#50)
:-
Relation[birth_date#8,contact_details#9,death_date#10,family_name#11,gender#12,given_name#13,id#14,identifiers#15
,image#16,images#17,links#18,name#19,other_names#20,sort_name#21] json
+-
Relation[area_id#45,end_date#46,legislative_period_id#47,on_behalf_of_id#48,organization_id#49,person_id#50,role#
51,start_date#52] json
== Analyzed Logical Plan ==
birth_date: string, contact_details: array<struct<type:string,value:string>>, death_date: string, family_name:
string, gender: string, given_name: string, id: string, identifiers:
array<struct<identifier:string,scheme:string>>, image: string, images: array<struct<url:string>>, links:
array<struct<url:string>>, name: string, other_names:
array<struct<lang:string,name:string,note:string>>, sort_name: string, area_id: string, end_date: string,
legislative_period_id: string, on_behalf_of_id: string, organization_id: string, person_id: string, role: string,
start_date: string
Join FullOuter, (id#14 = person_id#50)

Temas

- Habilitación de la interfaz de usuario web de Apache Spark para trabajos de AWS Glue
- Lanzamiento del servidor de historial de Spark

Habilitación de la interfaz de usuario web de Apache Spark para trabajos de AWS Glue

Puede utilizar la interfaz de usuario web de Apache Spark para monitorizar y depurar trabajos de ETL AWS Glue que se ejecutan en el sistema de trabajos AWS Glue. Puede configurar la interfaz de usuario de Spark mediante la consola de AWS Glue o la AWS Command Line Interface (AWS CLI).

Cada 30 segundos, AWS Glue hace una copia de seguridad de los registros de eventos de Spark a la ruta de Amazon S3 que especifique.

Temas

- Configuración de la interfaz de usuario de Spark (consola)
- Configuración de la interfaz de usuario de Spark (AWS CLI)
- Configuración de la interfaz de usuario de Spark para sesiones con cuadernos
- Activación de registros continuos

Configuración de la interfaz de usuario de Spark (consola)

Siga estos pasos para configurar la interfaz de usuario de Spark mediante la Consola de administración de AWS. Cuando se crea un trabajo en AWS Glue, la interfaz de usuario de Spark se habilita de forma predeterminada.

Activar la interfaz de Spark al crear o editar un trabajo

1. Inicie sesión en la Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. En el panel de navegación, seleccione Trabajos.
3. Elija Agregar trabajo o seleccione uno existente.
4. En Detalles del trabajo, abra las Propiedades avanzadas.
5. En la pestaña Interfaz de usuario de Spark, seleccione Escribir registros de interfaz de usuario de Spark en Amazon S3.
6. Especifique una ruta de Amazon S3 para almacenar los registros de eventos de Spark para el trabajo. Tenga en cuenta que cuando utiliza una configuración de seguridad en el trabajo, el

cifrado también se aplica al archivo de registro de la interfaz de usuario de Spark. Para obtener más información, consulte Cifrado de datos escritos por AWS Glue.

7. En la Configuración de registro y monitoreo de la interfaz de usuario de Spark:

   - Si está generando registros para verlos en la consola de AWS Glue, seleccione Estándar.
   - Si está generando registros para verlos en un servidor de historial de Spark, seleccione Heredado.
   - También puede optar por generar ambos.

Configuración de la interfaz de usuario de Spark (AWS CLI)

Para generar registros y verlos con la interfaz de usuario de Spark en la consola de AWS Glue, utilice la AWS CLI y transfiera los siguientes parámetros de trabajo a los trabajos de AWS Glue. Para obtener más información, consulte the section called “Parámetros del flujo de trabajo”.

```
'--enable-spark-ui': 'true',
'--spark-event-logs-path': 's3://s3-event-log-path'
```

Para distribuir los registros a sus ubicaciones antiguas, establezca el parámetro `--enable-spark-ui-legacy-path` en `"true"`. Si no desea generar registros en ambos formatos, elimine el parámetro `--enable-spark-ui`.

Configuración de la interfaz de usuario de Spark para sesiones con cuadernos

> **Warning**
>
> Las sesiones interactivas de AWS Glue no admiten la interfaz de usuario de Spark en la consola. Configure un servidor de historial de Spark.

Si utiliza cuadernos de AWS Glue, configure la interfaz de usuario de Spark antes de iniciar la sesión. Para ello, utilice el comando mágico celular `%%configure`:

```
%%configure { “--enable-spark-ui”: “true”, “--spark-event-logs-path”: “s3://path” }
```

Activación de registros continuos

Activar SparkUI y los archivos de eventos de registro continuo para los trabajos de AWS Glue Glue ofrece varias ventajas:

- Archivos de eventos de registro continuo: al activar los archivos de eventos de registro continuo, AWS Glue genera archivos de registro independientes para cada paso de la ejecución del trabajo, lo que facilita la identificación y la solución de problemas específicos de una etapa o transformación en particular.
- Mejor administración del registro: los archivos de eventos de registro continuo ayudan a administrar los archivos de registro de manera más eficiente. En lugar de tener un único archivo de registro, potencialmente grande, los registros se dividen en archivos más pequeños y fáciles de administrar en función de las etapas de ejecución del trabajo. Esto puede simplificar el archivado, el análisis y la solución de problemas de los registros.
- Tolerancia a errores mejorada: si un trabajo de AWS Glue falla o se interrumpe, los archivos de eventos de registro continuo pueden proporcionar información valiosa sobre la última etapa exitosa, lo que facilita la reanudación del trabajo desde ese punto en lugar de empezar desde cero.
- Optimización de costos: al habilitar los archivos de eventos de registro continuo, puede ahorrar en los costos de almacenamiento asociados a los archivos de registro. En lugar de almacenar un único archivo de registro, potencialmente grande, se almacenan archivos de registro más pequeños y fáciles de administrar, lo que puede resultar más rentable, especialmente para trabajos complejos o de larga duración.

En un entorno nuevo, los usuarios pueden habilitar de forma explícita la acumulación de registros mediante:

```
'—conf': 'spark.eventLog.rolling.enabled=true'
```

o

```
'—conf': 'spark.eventLog.rolling.enabled=true —conf
spark.eventLog.rolling.maxFileSize=128m'
```

Cuando se activan los registros continuos, `spark.eventLog.rolling.maxFileSize` especifica el tamaño máximo del archivo de registro de eventos antes de transferirlo. El valor por defecto de este parámetro opcional, si no se especifica, es 128 MB. El mínimo es 10 MB.

La suma máxima de todos los archivos de eventos de registro continuo generados es de 2 GB. Para los trabajos de AWS Glue que no admiten registros continuos, el tamaño máximo del archivo de eventos de registro que admite SparkUI es de 0,5 GB.

Puede desactivar los registros acumulativos de un trabajo de streaming al introducir una configuración adicional. Tenga en cuenta que el mantenimiento de archivos de registro muy grandes puede resultar costoso.

Para desactivar los registros continuos, proporcione la siguiente configuración:

```
'--spark-ui-event-logs-path': 'true',
'--conf': 'spark.eventLog.rolling.enabled=false'
```

Lanzamiento del servidor de historial de Spark

Puede utilizar un servidor de historial de Spark para visualizar los registros de Spark en su propia infraestructura. Puede ver en la consola de AWS Glue las mismas visualizaciones del trabajo de AWS Glue que se ejecute en las versiones 4.0 o posteriores deAWS Glue , con registros generados en formato estándar (en lugar de tradicional). Para obtener más información, consulte the section called “Monitorización con la interfaz de usuario de Spark”.

Puede lanzar el servidor de historial de Spark mediante una plantilla AWS CloudFormation que aloja el servidor en una instancia EC2 o lanzar localmente mediante Docker.

Temas

- Lanzamiento del servidor de historial de Spark y visualización de la interfaz de usuario de Spark mediante AWS CloudFormation
- Lanzamiento del servidor de historial de Spark y visualización de la interfaz de usuario de Spark mediante Docker

Lanzamiento del servidor de historial de Spark y visualización de la interfaz de usuario de Spark mediante AWS CloudFormation

Puede utilizar una plantilla de AWS CloudFormation para iniciar el servidor de historial de Apache Spark y ver la interfaz de usuario web de Spark. Estas plantillas son ejemplos que debe modificar para satisfacer sus requisitos.

Para iniciar el servidor de historial de Spark y ver la interfaz de usuario de Spark mediante CloudFormation

1. Elija uno de los botones Lanzar pila de la siguiente tabla. Esto lanza la pila en la consola de CloudFormation.

Región	Lanzar
Este de EE. UU. (Ohio)	
Este de EE. UU. (Norte de Virginia)	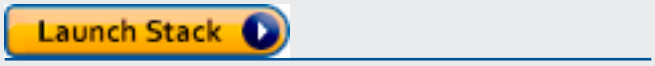
Oeste de EE. UU. (Norte de California)	
Oeste de EE. UU. (Oregón)	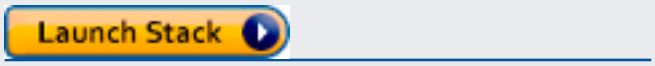
África (Ciudad del Cabo)	
Asia-Pacífico (Hong Kong)	
Asia-Pacífico (Bombay)	
Asia-Pacífico (Osaka)	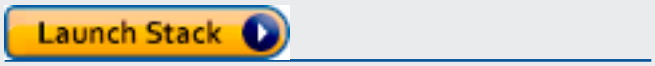
Asia-Pacífico (Seúl)	
Asia-Pacífico (Singapur)	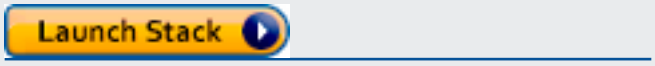
Asia-Pacífico (Sídney)	
Asia-Pacífico (Tokio)	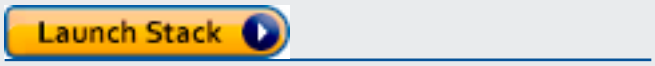
Canadá (centro)	
Europa (Fráncfort)	

Región	Lanzar
Europa (Irlanda)	Launch Stack
Europa (Londres)	Launch Stack
Europa (Milán)	Launch Stack
Europa (París)	Launch Stack
Europa (Estocolmo)	Launch Stack
Medio Oriente (Baréin)	Launch Stack
América del Sur (São Paulo)	Launch Stack

2. En la página Especificar plantilla elija Siguiente.
3. En la página Especificar detalles de pila, escriba el nombre de la pila. Introduzca información adicional en Parámetros.

   a. Configuración de la interfaz de usuario de Spark

      Proporcione la información siguiente:

      - Rango de direcciones IP: el rango de direcciones IP que se puede utilizar para ver la interfaz de usuario de Spark. Si desea restringir el acceso desde un rango de direcciones IP específico, debe utilizar un valor personalizado.
      - Puerto de servidor de historial: el puerto para la interfaz de usuario de Spark. Puede utilizar el valor predeterminado.
      - Directorio de registro de eventos: elija la ubicación en la que se almacenan los registros de eventos de Spark desde el trabajo o los puntos de enlace de desarrollo de AWS Glue. Debe utilizar **`s3a://`** para el esquema de ruta de los registros de eventos.
      - Ubicación del paquete de Spark: puede utilizar el valor predeterminado.

- Ruta del almacén de claves: ruta del almacén de claves SSL/TLS para HTTPS. Si desea utilizar un archivo de almacén de claves personalizado, puede especificar la ruta de S3 `s3://path_to_your_keystore_file` aquí. Si deja este parámetro vacío, se genera y utiliza un almacén de claves basado en certificados autofirmados.
- Contraseña del almacén de claves: ingrese una contraseña del almacén de claves SSL/TLS para HTTPS.

b. Configuración de instancias EC2

Proporcione la información siguiente:

- Tipo de instancia: el tipo de instancia de Amazon EC2 que aloja el servidor de historial de Spark. Dado que esta plantilla lanza una instancia de Amazon EC2 en su cuenta, el costo de Amazon EC2 se cobrará en su cuenta por separado.
- Último ID de AMI: el ID de AMI de Amazon Linux 2 para la instancia del servidor de historial de Spark. Puede utilizar el valor predeterminado.
- ID de VPC: el ID de la nube privada virtual (VPC) para la instancia del servidor de historial de Spark. Puede utilizar cualquiera de las VPC disponibles en su cuenta: no se recomienda utilizar una VPC predeterminada con una ACL de red predeterminada . Para obtener más información, consulte VPC predeterminada y subredes predeterminadas y Creación de una VPC en la Guía del usuario de Amazon VPC.
- ID de subred: el ID de la instancia del servidor de historial de Spark. Puede utilizar cualquiera de las subredes de su VPC. Debe poder acceder a la red desde su cliente a la subred. Si desea obtener acceso a a través de Internet, debe utilizar una subred pública que tenga la gateway de internet en la tabla de ruteo.

c. Elija Siguiente.

4. En la página Configurar las opciones de pila, para utilizar las credenciales de usuario actuales para determinar cómo CloudFormation puede crear, modificar o eliminar recursos de la pila, elija Próximo. También puede especificar un rol en la sección Permisos que utilizará en lugar de los permisos de usuario actuales y, a continuación, elija Siguiente.
5. En la página Revisar, examine la plantilla.

   Elija Confirmo que CloudFormation puede crear recursos de IAM y, a continuación, elija Crear pila.
6. Espere a que se cree la pila.
7. Haga clic en la pestaña Salidas.

a. Copie la URL de SparkUiPublicUrl si está utilizando una subred pública.

b. Copie la URL de SparkUiPrivateUrl si está utilizando una subred privada.

8. Abra un navegador web y pegue la URL. Esto le permite obtener acceso al servidor mediante HTTPS en el puerto especificado. Es posible que el navegador no reconozca el certificado del servidor, en cuyo caso tendrá que anular su protección y continuar.

Lanzamiento del servidor de historial de Spark y visualización de la interfaz de usuario de Spark mediante Docker

Si prefiere el acceso local (no tener una instancia EC2 para el servidor de historial de Apache Spark), también puede utilizar Docker para iniciar el servidor de historial de Apache Spark y ver la interfaz de usuario de Spark localmente. Este Dockerfile es un ejemplo que debe modificar para satisfacer sus requisitos.

Requisitos previos

Para obtener información acerca de cómo instalar Docker en su portátil, consulte la comunidad de Docker Engine.

Iniciar el servidor de historial de Spark y ver la interfaz de usuario de Spark localmente mediante Docker

1. Descargue archivos desde GitHub.

   Descargue Dockerfile y `pom.xml` de las muestras de código de AWS Glue.

2. Determine si desea utilizar las credenciales de usuario o credenciales de usuario federado para acceder a AWS.

   - Para utilizar las credenciales de usuario actuales para acceder a AWS, obtenga los valores que se van a utilizar para `AWS_ACCESS_KEY_ID` y `AWS_SECRET_ACCESS_KEY` en el comando `docker run`. Para obtener más información, consulte Administración de claves de acceso para usuarios de IAM en la Guía del usuario de IAM.
   - Para utilizar usuarios federados SAML 2.0 para acceder a AWS, obtenga los valores de `AWS_ACCESS_KEY_ID`, `AWS_SECRET_ACCESS_KEY` y `AWS_SESSION_TOKEN`. Para obtener más información, consulte Solicitud de credenciales de seguridad temporales

3. Determine la ubicación del directorio de registro de eventos que se utilizará en el comando `docker run`.

4. Cree la imagen de Docker con los archivos del directorio local y utilice el nombre `glue/sparkui` y la etiqueta `latest`.

```
$ docker build -t glue/sparkui:latest .
```

5. Cree e inicie el contenedor de docker.

   En los siguientes comandos, utilice los valores obtenidos anteriormente en los pasos 2 y 3.

   a. Para crear el contenedor de docker mediante las credenciales de usuario, utilice un comando similar al siguiente

```
docker run -itd -e SPARK_HISTORY_OPTS="$SPARK_HISTORY_OPTS -
Dspark.history.fs.logDirectory=s3a://path_to_eventlog
 -Dspark.hadoop.fs.s3a.access.key=AWS_ACCESS_KEY_ID -
Dspark.hadoop.fs.s3a.secret.key=AWS_SECRET_ACCESS_KEY"
 -p 18080:18080 glue/sparkui:latest "/opt/spark/bin/spark-class
 org.apache.spark.deploy.history.HistoryServer"
```

   b. Para crear el contenedor de docker mediante credenciales temporales, utilice `org.apache.hadoop.fs.s3a.TemporaryAWSCredentialsProvider` como proveedor, y proporcione los valores de credenciales obtenidos en el paso 2. Para obtener más información, consulte Uso de credenciales de sesión con TemporaryAWSCredentialsProvider en la documentación de Hadoop: integración con Amazon Web Services.

```
docker run -itd -e SPARK_HISTORY_OPTS="$SPARK_HISTORY_OPTS -
Dspark.history.fs.logDirectory=s3a://path_to_eventlog
 -Dspark.hadoop.fs.s3a.access.key=AWS_ACCESS_KEY_ID -
Dspark.hadoop.fs.s3a.secret.key=AWS_SECRET_ACCESS_KEY
 -Dspark.hadoop.fs.s3a.session.token=AWS_SESSION_TOKEN
 -
Dspark.hadoop.fs.s3a.aws.credentials.provider=org.apache.hadoop.fs.s3a.TemporaryAWSCred
 -p 18080:18080 glue/sparkui:latest "/opt/spark/bin/spark-class
 org.apache.spark.deploy.history.HistoryServer"
```

> **Note**
>
> Estos parámetros de configuración proceden del Módulo Hadoop-AWS. Es posible que tenga que agregar configuración específica en función del caso

de uso. Por ejemplo, los usuarios de regiones aisladas tendrán que configurar `spark.hadoop.fs.s3a.endpoint`.

6. Abra `http://localhost:18080` en el navegador para ver la interfaz de usuario de Spark en forma local.

Supervisión con Información de ejecuciones de trabajos de AWS Glue

Información de ejecuciones de trabajos de AWS Glue es una característica de AWS Glue que simplifica la depuración de trabajos y la optimización de los trabajos de AWS Glue. AWS Glue proporciona la interfaz de usuario de Spark y las métricas y registros de CloudWatch Logs para la supervisión de los trabajos de AWS Glue. Con esta característica, obtiene esta información sobre la ejecución del trabajo de AWS Glue:

- Número de línea del script del trabajo de AWS Glue con error.
- Última acción de Spark que se ejecutó en el plan de consultas de Spark justo antes del error del trabajo.
- Eventos de excepción de Spark relacionados con el error que se muestran en un flujo de registro ordenado por tiempo.
- Análisis de causa raíz y acción recomendada (por ejemplo, ajustar el script) para solucionar el problema.
- Eventos comunes de Spark (mensajes de registro relacionados con una acción de Spark) con una acción recomendada que aborda la causa raíz.

Toda esta información está disponible mediante dos nuevos flujos de registro en CloudWatch Logs para sus trabajos de AWS Glue.

Requisitos

La característica de información sobre la ejecución de los trabajos de AWS Glue está disponible para las versiones 2.0, 3.0, 4.0 y 5.0 de AWS Glue. Puede seguir la guía de migración para actualizar los trabajos existentes desde versiones anteriores de AWS Glue.

Habilitación de información de ejecuciones de trabajos para un trabajo de ETL de AWS Glue

Puede habilitar Información de ejecuciones de trabajos a través de AWS Glue Studio o la CLI.

AWS Glue Studio

Al crear un trabajo mediante AWS Glue Studio, puede habilitar o desactivar Información de ejecuciones de trabajos en la pestaña Job Details (Detalles del trabajo). Compruebe que la casilla Generar información sobre el trabajo esté seleccionada.

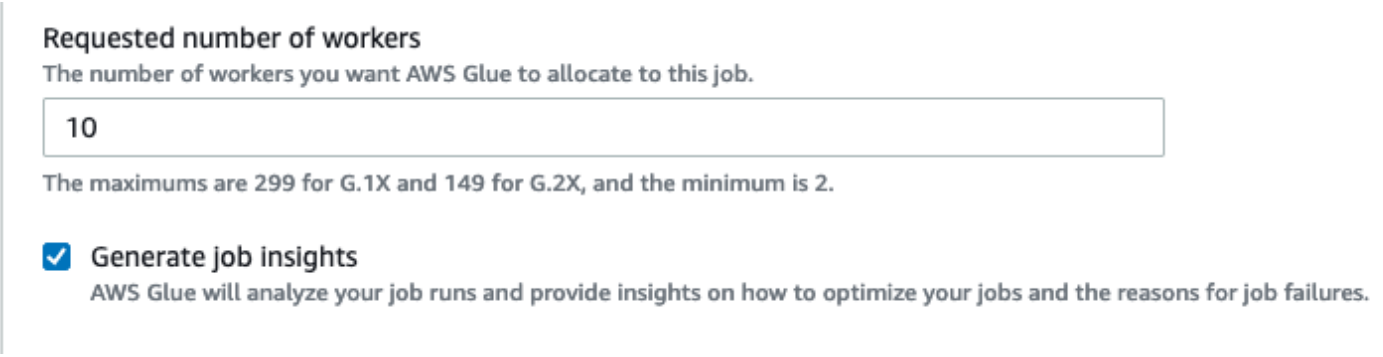

Línea de comandos

Si crea un trabajo a través de la CLI, puede iniciar una ejecución de trabajos con un único nuevo parámetro de trabajo: `--enable-job-insights = true`.

De forma predeterminada, los flujos de registro de Información de ejecuciones de trabajos se crean en el mismo grupo de registros predeterminado que utiliza el registro continuo de AWS Glue, es decir, `/aws-glue/jobs/logs-v2/`. Puede configurar un nombre de grupo de registros personalizado, filtros de registros y configuraciones de grupos de registros con el mismo conjunto de argumentos que el registro continuo. Para obtener más información, consulte Habilitación del registro continuo para trabajos de AWS Glue.

Acceso a los flujos de registro de información de ejecuciones de trabajos en CloudWatch

Con la característica Información de ejecuciones de trabajos habilitada, es posible que haya dos flujos de registro creados cuando falla la ejecución de un trabajo. Cuando un trabajo finaliza correctamente, no se genera ninguno de los flujos.

1. Flujo de registro de análisis de excepciones: `<job-run-id>-job-insights-rca-driver`. Este flujo proporciona lo siguiente:
   - Número de línea del script del trabajo de AWS Glue que causó el error.
   - Última acción de Spark que se ejecutó en el plan de consultas de Spark (DAG).
   - Eventos concisos ordenados por tiempo del controlador de Spark y ejecutores relacionados con la excepción. Puede encontrar detalles como mensajes de error completos, la tarea de Spark

con error y el ID de los ejecutores que le ayudan a centrarse en el flujo de registro del ejecutor específico para llevar a cabo una investigación en profundidad si es necesario.

2. Flujo de información basado en reglas:
   - Análisis de causa raíz y recomendaciones sobre cómo corregir los errores (por ejemplo, utilizar un parámetro de trabajo específico para optimizar el rendimiento).
   - Los eventos relevantes de Spark sirven de base para el análisis de causa raíz y una acción recomendada.

> **Note**
>
> El primer flujo solo existirá si hay eventos de excepción de Spark disponibles para una ejecución de trabajo con error, mientras que el segundo flujo solo existirá si hay información disponible para la ejecución del trabajo con error. Por ejemplo, si el trabajo finaliza correctamente, no se generará ninguno de los flujos; si el trabajo falla, pero no hay ninguna regla definida por el servicio que pueda coincidir con el escenario de error, solo se generará el primer flujo.

Si el trabajo se crea en AWS Glue Studio, los enlaces a los flujos anteriores también están disponibles en la pestaña Job run details (Detalles de ejecuciones de trabajos, es decir, Información de ejecuciones de trabajos) como “Concise and consolidated error logs” (Registros de errores concisos y consolidados) y “Error analysis and guidance” (Análisis de errores y orientación).

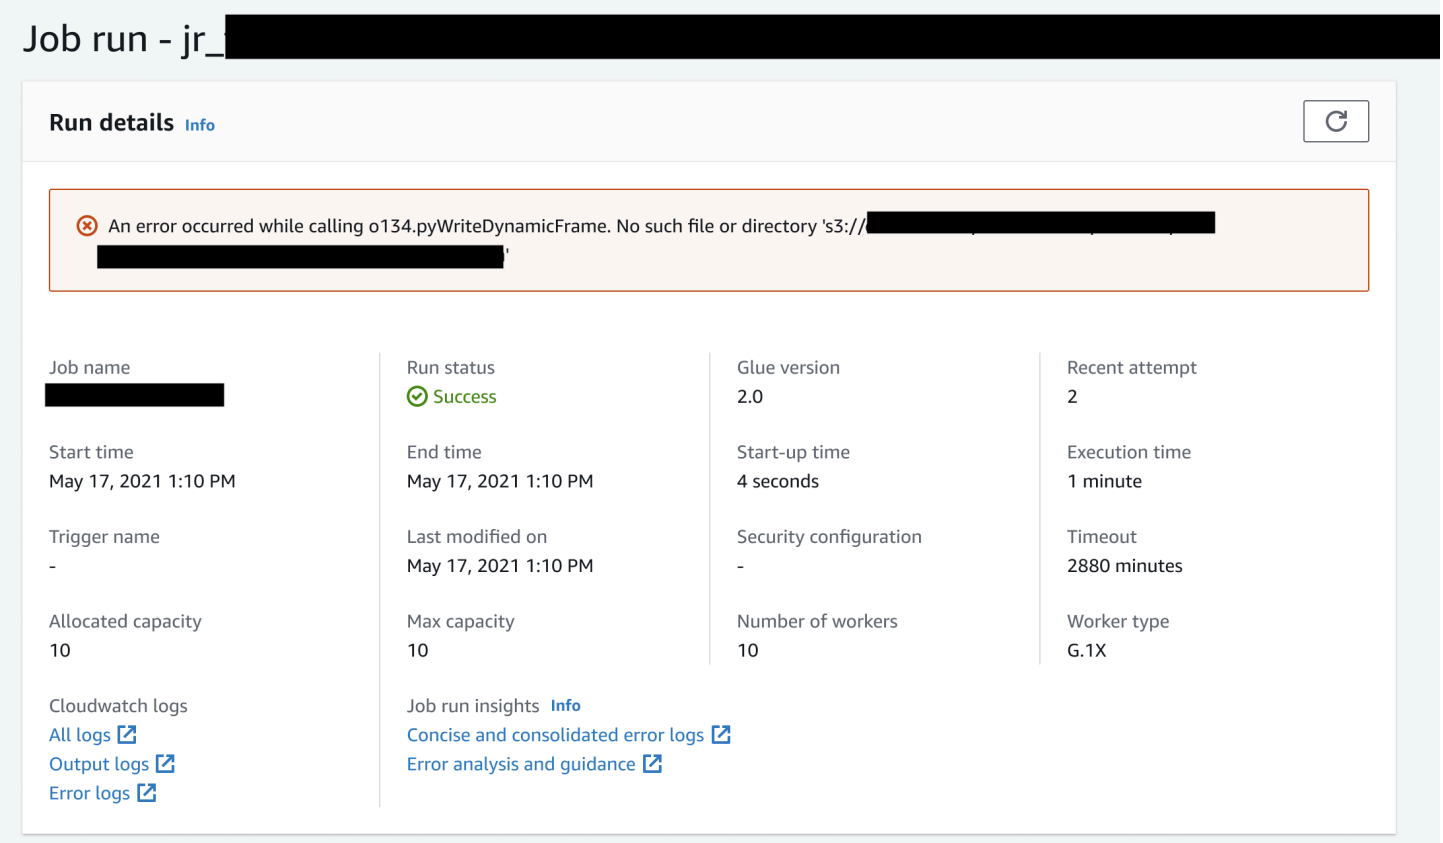

Ejemplo de Información de ejecuciones de trabajos de AWS Glue

En esta sección, mostramos un ejemplo de cómo la característica Información de ejecuciones de trabajos puede ayudarle a resolver un problema en un trabajo con errores. En este ejemplo, un usuario olvidó importar el módulo obligatorio (tensorflow) en un trabajo de AWS Glue para analizar y crear un modelo de machine learning en sus datos.

```
import sys
from awsglue.transforms import *
from awsglue.utils import getResolvedOptions
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job
from pyspark.sql.types import *
from pyspark.sql.functions import udf,col

args = getResolvedOptions(sys.argv, ['JOB_NAME'])

sc = SparkContext()
glueContext = GlueContext(sc)
spark = glueContext.spark_session
```

```
job = Job(glueContext)
job.init(args['JOB_NAME'], args)

data_set_1 = [1, 2, 3, 4]
data_set_2 = [5, 6, 7, 8]

scoresDf = spark.createDataFrame(data_set_1, IntegerType())

def data_multiplier_func(factor, data_vector):
    import tensorflow as tf
    with tf.compat.v1.Session() as sess:
        x1 = tf.constant(factor)
        x2 = tf.constant(data_vector)
        result = tf.multiply(x1, x2)
        return sess.run(result).tolist()

data_multiplier_udf = udf(lambda x:data_multiplier_func(x, data_set_2),
 ArrayType(IntegerType(),False))
factoredDf = scoresDf.withColumn("final_value", data_multiplier_udf(col("value")))
print(factoredDf.collect())
```

Sin la característica Información de ejecuciones de trabajos, como el trabajo falla, solo verá este mensaje de Spark:

```
An error occurred while calling o111.collectToPython. Traceback (most
recent call last):
```

El mensaje es ambiguo y limita la experiencia de depuración. En este caso, esta característica proporciona información adicional en dos flujos de registro de CloudWatch:

1. El flujo de registro `job-insights-rca-driver`:
   - Eventos de excepción: este flujo de registro proporciona los eventos de excepción de Spark relacionados con el error recopilado por el controlador de Spark y los distintos empleados distribuidos. Estos eventos le ayudan a comprender la propagación ordenada por tiempo de la excepción, ya que el código con error se ejecuta en las tareas, los ejecutores y las etapas de Spark distribuidos en los empleados de AWS Glue.
   - Números de línea: este flujo de registro identifica la línea 21, que hizo la llamada para importar el módulo de Python que falta que causó el error; también identifica la línea 24, la llamada a la acción de Spark `collect()`, como última línea ejecutada del script.

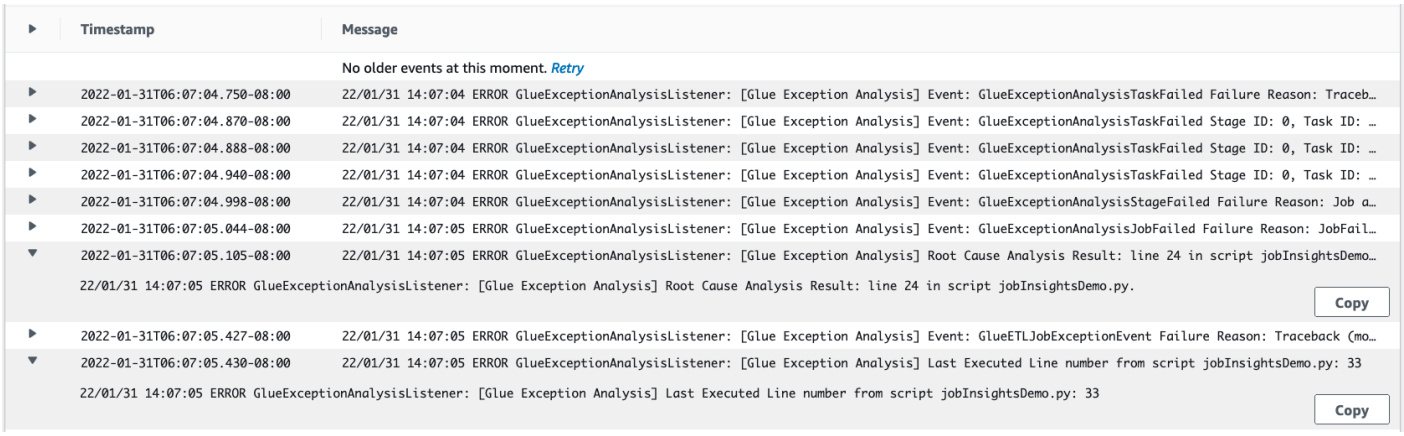

2. El flujo de registro `job-insights-rule-driver`:

   - Causa raíz y recomendación: además del número de línea y el último número de línea ejecutado para el error del script, este flujo de registro muestra el análisis de causa raíz y la recomendación para que siga el documento de AWS Glue y configure los parámetros de trabajo necesarios para utilizar un módulo de Python adicional en su trabajo de AWS Glue.
   - Evento base: este flujo de registro también muestra el evento de excepción de Spark que se evaluó con la regla definida por el servicio para inferir la causa raíz y proporcionar una recomendación.

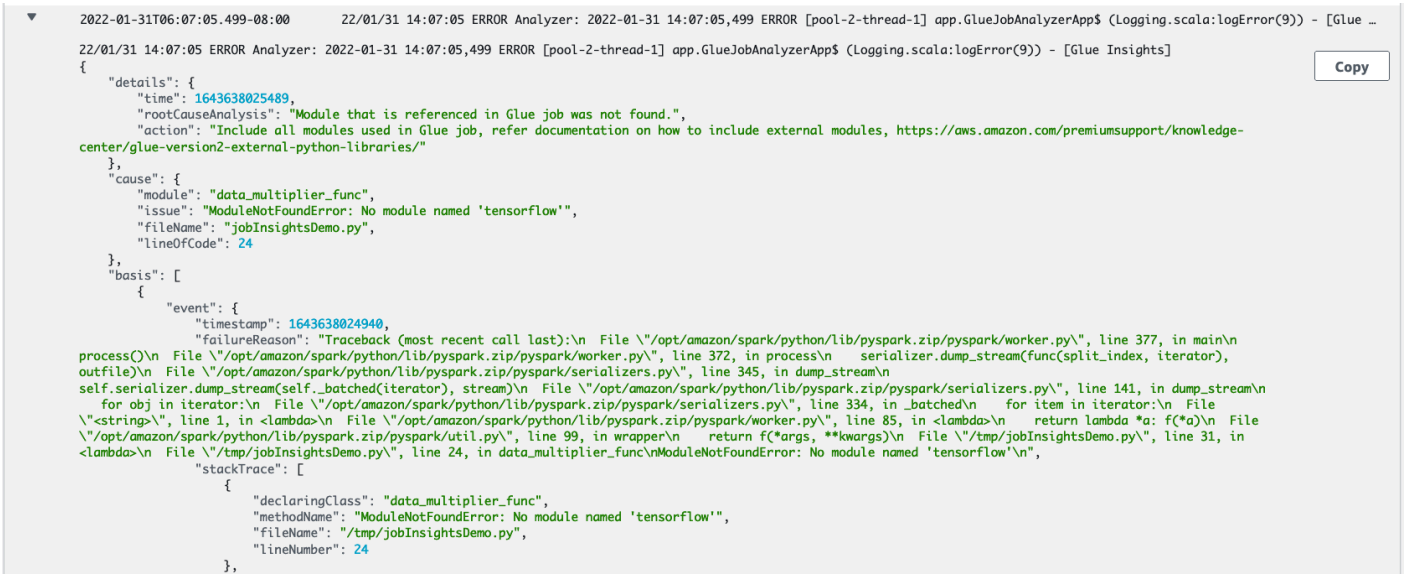

Supervisión con Amazon CloudWatch

Puede monitorear AWS Glue mediante Amazon CloudWatch, que recopila y procesa los datos sin procesar de AWS Glue en métricas legibles y casi en tiempo real. Estas estadísticas se registran durante un periodo de dos semanas, de forma que pueda disponer de información histórica y

obtener una mejor perspectiva sobre el desempeño de la aplicación o servicio web. De forma predeterminada, los datos de las métricas de AWS Glue se envían a CloudWatch en forma automática. Para obtener más información, consulte ¿Qué es Amazon CloudWatch? en la Guía del usuario de Amazon Cloudwatch, y Métricas de AWS Glue.

Registro continuo

AWS Glue también admite el registro continuo en tiempo real para trabajos de AWS Glue. Cuando el registro continuo está habilitado para un trabajo, puede ver los registros en tiempo real en la consola de AWS Glue o en el panel de la consola de CloudWatch. Para obtener más información, consulte Registro de trabajos de AWS Glue.

Métricas de observabilidad

Cuando las Métricas de observabilidad del trabajo están habilitadas, se generan métricas Amazon CloudWatch adicionales cuando se ejecuta el trabajo. Use las métricas de observabilidad AWS Glue para obtener información sobre lo que sucede en el interior de AWS Glue y mejorar la clasificación y el análisis de los problemas.

Temas

- Supervisión de AWS Glue con métricas de Amazon CloudWatch
- Configuración de alarmas de Amazon CloudWatch en perfiles de trabajo de AWS Glue
- Registro de trabajos de AWS Glue
- Monitorización con métricas de observabilidad de AWS Glue

Supervisión de AWS Glue con métricas de Amazon CloudWatch

Puede proporcionar perfiles y supervisar las operaciones de AWS Glue con el generador de trabajos de AWS Glue. Recopila y procesa los datos sin procesar de AWS Glue para convertirlos en métricas legibles y casi en tiempo real en Amazon CloudWatch. Estas estadísticas se retienen y agregan en CloudWatch, de forma que pueda acceder a información histórica para obtener una mejor perspectiva sobre el rendimiento de su aplicación.

> **Note**
>
> Puede incurrir en cargos adicionales cuando habilita las métricas de trabajos y se crean métricas personalizadas de CloudWatch. Para obtener más información, consulte los precios de Amazon CloudWatch .

Información general de métricas de AWS Glue

Cuando usted interactúa con AWS Glue, este último envía métricas a CloudWatch. Puede ver estas métricas en la consola de AWS Glue (el método preferido), el panel de la consola de CloudWatch o AWS Command Line Interface (AWS CLI).

Para consultar las métricas mediante el panel de la consola de AWS Glue

Puede ver gráficos resumidos o detallados de métricas para un trabajo, o bien gráficos detallados para una ejecución de trabajo.

1. Inicie sesión en la Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. En el panel de navegación, seleccione Monitoreo de ejecución de trabajos.
3. En Ejecuciones de trabajos, elija Acciones para detener un trabajo que se ejecute actualmente, ver un trabajo o rebobinar el marcador del trabajo.
4. Seleccione un trabajo y, a continuación, elija Ver detalles de la ejecución para ver información adicional sobre la ejecución del trabajo.

Para ver las métricas a través del panel de consola de CloudWatch

Las métricas se agrupan en primer lugar por el espacio de nombres de servicio y, a continuación, por las diversas combinaciones de dimensiones dentro de cada espacio de nombres.

1. Abra la consola de CloudWatch en https://console.aws.amazon.com/cloudwatch/.
2. En el panel de navegación, seleccione Métricas.
3. Seleccione el espacio de nombres Glue.

Para ver métricas mediante la AWS CLI

- En el símbolo del sistema, ejecute el siguiente comando.

```
aws cloudwatch list-metrics --namespace Glue
```

AWS Glue notifica las métricas para CloudWatch cada 30 segundos y los paneles de métricas de CloudWatch se configuran para mostrarlas cada minuto. Las métricas de AWS Glue representan valores delta que se obtienen de los valores notificados con anterioridad. Si procede, los paneles de

métricas acumulan (suman) los valores de 30 segundos para obtener un valor para el último minuto en su totalidad.

Comportamiento de métricas de AWS Glue para trabajos de Spark

Las métricas AWS Glue se habilitan en la inicialización de un `GlueContext` en un script y suelen actualizarse solo al final de una tarea de Apache Spark. Representan los valores de la suma en todas las tareas Spark hasta el momento.

No obstante, las métricas de Spark que AWS Glue transfiere a CloudWatch suelen ser valores absolutos que representan el estado actual en el momento en que se notifican. AWS Glue los notifica a CloudWatch cada 30 segundos, y los paneles de métricas suelen mostrar la media en los puntos de datos recibidos en el último minuto.

Los nombres de las métricas de AWS Glue están precedidos por uno de los siguientes tipos de prefijo:

- `glue.driver.`: las métricas cuyos nombres comienzan con este prefijo representan las métricas de AWS Glue que provienen de todos los ejecutores en el controlador Spark, o bien las métricas de Spark correspondientes al controlador Spark.
- `glue.`Id de ejecutor`.`: el Id de ejecutor es el número de un ejecutor de Spark especificado. Se corresponde con los ejecutores enumerados en los registros.
- `glue.ALL.`: las métricas cuyos nombres empiezan por este prefijo agregan valores de todos los ejecutores de Spark.

Métricas de AWS Glue

AWS Glue crea perfiles y envía las siguientes métricas a CloudWatch cada 30 segundos, y el panel de métricas de AWS Glue los informa una vez por minuto:

Métrica	Descripción
`glue.driver.aggregate.bytesRead`	El número de bytes leídos desde todos los orígenes de datos por todas las tareas de Spark completadas que se ejecutan en todos los ejecutores. Dimensiones válidas: `JobName` (el nombre del trabajo de AWS Glue), `JobRunId` (el ID de JobRun o `ALL`) y `Type` (recuento).

Métrica	Descripción
	Estadísticas válidas: SUMA. Esta métrica es un valor delta desde el último valor notificado, por lo que en el panel de métricas de AWS Glue, se utiliza una estadística SUMA para la agregación. Unidad: bytes Se puede utilizar para monitorear lo siguiente: • Bytes leídos. • Progreso del trabajo. • Orígenes de datos JDBC. • Problemas de marcadores de trabajos. • Desviación entre ejecuciones de trabajos. Esta métrica se puede utilizar de la misma manera que la métrica `glue.ALL.s3.filesystem.read_bytes`, con la diferencia de que esta métrica se actualiza al final de una tarea de Spark y también captura orígenes de datos que no son S3.

Métrica	Descripción
`glue.driver.aggregate.elapsedTime`	El tiempo transcurrido de ETL en milisegundos (no incluye los tiempos de arranque del trabajo). Dimensiones válidas: `JobName` (el nombre del trabajo de AWS Glue), `JobRunId` (el ID de JobRun o `ALL`) y `Type` (recuento). Estadísticas válidas: SUMA. Esta métrica es un valor delta desde el último valor notificado, por lo que en el panel de métricas de AWS Glue, se utiliza una estadística SUMA para la agregación. Unidad: milisegundos Puede utilizarse para determinar cuánto tiempo se tarda en ejecutar una ejecución de trabajo en promedio. Algunas formas de usar los datos: • Establecimiento de alarmas para los rezagados. • Medición de desviación entre ejecuciones de trabajos.

Métrica	Descripción
`glue.driver.aggregate.numCompletedStages`	Número de etapas completadas en este trabajo. Dimensiones válidas: `JobName` (el nombre del trabajo de AWS Glue), `JobRunId` (el ID de JobRun o `ALL`) y `Type` (recuento). Estadísticas válidas: SUMA. Esta métrica es un valor delta desde el último valor notificado, por lo que en el panel de métricas de AWS Glue, se utiliza una estadística SUMA para la agregación. Unidad: recuento Se puede utilizar para monitorear lo siguiente: • Progreso del trabajo. • Línea de tiempo por etapa de ejecución del trabajo, cuando se correlaciona con otras métricas. Algunas formas de usar los datos: • Identificar etapas exigentes en la ejecución de un trabajo. • Establecer alarmas para picos correlacionados (etapas exigentes) en ejecuciones de trabajos.

Métrica	Descripción
`glue.driver.aggregate.numCompletedTasks`	Número de etapas completadas en el trabajo. Dimensiones válidas: `JobName` (el nombre del trabajo de AWS Glue), `JobRunId` (el ID de JobRun o `ALL`) y `Type` (recuento). Estadísticas válidas: SUMA. Esta métrica es un valor delta desde el último valor notificado, por lo que en el panel de métricas de AWS Glue, se utiliza una estadística SUMA para la agregación. Unidad: recuento Se puede utilizar para monitorear lo siguiente: • Progreso del trabajo. • Paralelismo dentro de una etapa.

Métrica	Descripción
`glue.driver.aggregate.numFailedTasks`	El número de tareas de servicio que han presentado un error. Dimensiones válidas: `JobName` (el nombre del trabajo de AWS Glue), `JobRunId` (el ID de JobRun o `ALL`) y `Type` (recuento). Estadísticas válidas: SUMA. Esta métrica es un valor delta desde el último valor notificado, por lo que en el panel de métricas de AWS Glue, se utiliza una estadística SUMA para la agregación. Unidad: recuento Se puede utilizar para monitorear lo siguiente: • Anomalías de datos que provocan un error en las tareas de trabajo. • Anomalías de clúster que provocan un error en las tareas de trabajo. • Anomalías de scripts que causan un error en las tareas de trabajo. Los datos se pueden usar para establecer alarmas ante mayor cantidad de errores que podrían sugerir anomalías en los datos, clústeres o scripts.

Métrica	Descripción
`glue.driver.aggregate.numKilledTasks`	El número de tareas eliminadas. Dimensiones válidas: `JobName` (el nombre del trabajo de AWS Glue), `JobRunId` (el ID de JobRun o `ALL`) y `Type` (recuento). Estadísticas válidas: SUMA. Esta métrica es un valor delta desde el último valor notificado, por lo que en el panel de métricas de AWS Glue, se utiliza una estadística SUMA para la agregación. Unidad: recuento Se puede utilizar para monitorear lo siguiente: • Irregularidades en el sesgo de datos que dan lugar a excepciones (memoria insuficiente) que eliminan tareas. • Irregularidades en los scripts que dan lugar a excepciones (memoria insuficiente) que eliminan tareas. Algunas formas de usar los datos: • Establecer alarmas ante mayor cantidad de errores que indiquen anomalías en los datos. • Establecer alarmas ante mayor cantidad de errores que indiquen anomalías en los clústeres. • Establecer alarmas ante mayor cantidad de errores que indiquen anomalías en los scripts.

Métrica	Descripción
`glue.driver.aggregate.recordsRead`	Número de registros leídos de todos los orígenes de datos por todas las tareas de Spark completadas que se ejecutan en todos los ejecutores. Dimensiones válidas: `JobName` (el nombre del trabajo de AWS Glue), `JobRunId` (el ID de JobRun o `ALL`) y `Type` (recuento). Estadísticas válidas: SUMA. Esta métrica es un valor delta desde el último valor notificado, por lo que en el panel de métricas de AWS Glue, se utiliza una estadística SUMA para la agregación. Unidad: recuento Se puede utilizar para monitorear lo siguiente: • Registros leídos. • Progreso del trabajo. • Orígenes de datos JDBC. • Problemas de marcadores de trabajos. • Sesgo en trabajos que se ejecutan durante varios días. Esta métrica se puede utilizar de manera similar que la métrica `glue.ALL.s3.filesystem.read_bytes` , con la diferencia de que esta métrica se actualiza al final de una tarea de Spark.

Métrica	Descripción
`glue.driver.aggregate.shuffleBytesWritten`	El número de bytes que escriben todos los ejecutores para mezclar los datos en forma aleatoria entre ellos desde el informe anterior (acumulados por el panel de métricas de AWS Glue como el número de bytes escritos para este propósito durante el minuto anterior). Dimensiones válidas: `JobName` (el nombre del trabajo de AWS Glue), `JobRunId` (el ID de JobRun o `ALL`) y `Type` (recuento). Estadísticas válidas: SUMA. Esta métrica es un valor delta desde el último valor notificado, por lo que en el panel de métricas de AWS Glue, se utiliza una estadística SUMA para la agregación. Unidad: bytes Se puede utilizar para monitorear: mezclas aleatorias de datos en trabajos (combinaciones grandes, agrupados por, repartición, fusión). Algunas formas de usar los datos: • Volver a particionar o descomprimir archivos de entrada grandes antes de procesarlos. • Volver a particionar los datos de manera más uniforme para evitar las teclas de acceso rápido. • Prefiltrar los datos antes de las combinaciones o las operaciones GroupBy (Agrupar por).

Métrica	Descripción
`glue.driver.aggregate.shuffleLocalBytesRead`	El número de bytes que leen todos los ejecutores para mezclar los datos en forma aleatoria entre ellos desde el informe anterior (acumulados por el panel de métricas de AWS Glue como el número de bytes leídos para este propósito durante el minuto anterior) . Dimensiones válidas: `JobName` (el nombre del trabajo de AWS Glue), `JobRunId` (el ID de JobRun o `ALL`) y `Type` (recuento). Estadísticas válidas: SUMA. Esta métrica es un valor delta desde el último valor notificado, por lo que en el panel de métricas de AWS Glue, se utiliza una estadística SUMA para la agregación. Unidad: bytes Se puede utilizar para monitorear: mezclas aleatoria s de datos en trabajos (combinaciones grandes, agrupados por, repartición, fusión). Algunas formas de usar los datos: • Volver a particionar o descomprimir archivos de entrada grandes antes de procesarlos. • Volver a particionar los datos de manera más uniforme con teclas de acceso rápido. • Prefiltrar los datos antes de las combinaciones o las operaciones GroupBy (Agrupar por).

Métrica	Descripción
`glue.driver.BlockManager.disk.diskSpaceUsed_MB`	Número de megabytes de espacio en disco utilizado en todos los ejecutores. Dimensiones válidas: `JobName` (el nombre del trabajo de AWS Glue), `JobRunId` (el ID de JobRun o `ALL`), y `Type` (calibre). Estadísticas válidas: promedio. Esta es una métrica de Spark, notificada como un valor absoluto. Unidades: megabytes Se puede utilizar para monitorear lo siguiente: • Espacio en disco utilizado para bloques que representan particiones RDD almacenadas en caché. • Espacio en disco utilizado para bloques que representan salidas de mezclas aleatorias intermedias. • Espacio en disco utilizado para bloques que representan emisiones. Algunas formas de usar los datos: • Identificar errores de trabajo debido a mayor uso del disco. • Identificar grandes particiones que resulten en desbordamiento o mezclado aleatorio. • Aumentar la capacidad de DPU aprovisionada para corregir estos problemas.

Métrica	Descripción
`glue.driver.ExecutorAllocationManager.executors.numberAllExecutors`	El número de ejecutores de trabajo que se ejecutan activamente. Dimensiones válidas: `JobName` (el nombre del trabajo de AWS Glue), `JobRunId` (el ID de JobRun o `ALL`), y `Type` (calibre). Estadísticas válidas: promedio. Esta es una métrica de Spark, notificada como un valor absoluto. Unidad: recuento Se puede utilizar para monitorear lo siguiente: • Actividad del trabajo. • Ejecutores rezagados (solo con algunos ejecutores en proceso de ejecución) • Paralelismo actual a nivel de ejecutor. Algunas formas de usar los datos: • Volver a particionar o descomprimir archivos de entrada grandes por anticipado si el clúster está infrautilizado. • Identificar retrasos en la ejecución de la etapa o del trabajo debido a escenarios rezagados. • • Comparar con NumberMaxNeedExecutors para comprender las tareas pendientes para aprovisio nar más DPU.

Métrica	Descripción
`glue.driver.ExecutorAllocationManager.executors.numberMaxNeededExecutors`	Número máximo de ejecutores de trabajos (en ejecución activa y pendientes) necesarios para satisfacer la carga actual. Dimensiones válidas: `JobName` (el nombre del trabajo de AWS Glue), `JobRunId` (el ID de JobRun o `ALL`), y `Type` (calibre). Estadísticas válidas: máximo. Esta es una métrica de Spark, notificada como un valor absoluto. Unidad: recuento Se puede utilizar para monitorear lo siguiente: • Actividad del trabajo. • Paralelismo actual a nivel de ejecutor y atraso de tareas pendientes aún no programadas debido a que los ejecutores no están disponibles por la capacidad de DPU o ejecutores eliminados/que presentan error. Algunas formas de usar los datos: • Identificar tareas pendientes/atrasadas de la cola de programación. • Identificar retrasos en la ejecución de la etapa o del trabajo debido a escenarios rezagados. • Comparar con NumberAllExecutors para comprender el trabajo atrasado para aprovisionar más DPU. • Aumentar la capacidad de DPU aprovisionada para corregir el retraso del ejecutor pendiente.

Métrica	Descripción

`glue.driver.jvm.heap.usage`
 	
`glue.Id de ejecutor.jvm.heap.usage`
 	
`glue.ALL.jvm.heap.usage`
	La fracción de memoria usada por el montón de JVM para este controlador (escala: 0-1), ejecutor identific ado por el Id de ejecutor o TODOS los ejecutores.
	
	Dimensiones válidas: `JobName` (el nombre del trabajo de AWS Glue), `JobRunId` (el ID de JobRun o `ALL`), y `Type` (calibre).
	
	Estadísticas válidas: promedio. Esta es una métrica de Spark, notificada como un valor absoluto.
	
	Unidad: porcentaje
	
	Se puede utilizar para monitorear lo siguiente:
	
	• Condiciones de memoria insuficiente (OOM) del controlador con `glue.driver.jvm.he ap.usage` .
	• Condiciones de memoria insuficiente (OOM) del ejecutor con `glue.ALL.jvm.heap.usage` .
	
	Algunas formas de usar los datos:
	
	• Identificar las etapas y los ID de los ejecutores que consumen memoria.
	• Identificar los ID y las etapas de los ejecutores rezagados.
	• Identificar una condición de memoria insuficiente (OOM) del controlador.
	• Identificar una condición de falta de memoria (OOM) del ejecutor y obtener el ID de ejecutor correspondiente para poder obtener un seguimien to de pila del registro del ejecutor.

Métrica	Descripción
	• Identificar los archivos o particiones que pueden tener un sesgo de datos, lo que resulta en rezagos o condiciones de memoria insuficiente (OOM).

Métrica	Descripción

`glue.driver.jvm.heap.used`
 	
`glue.`Id de ejecutor`.jvm.heap.used`
 	
`glue.ALL.jvm.heap.used`
	El número de bytes de memoria utilizados por el montón de JVM para el controlador, el ejecutor identificado por Id de ejecutor, o TODOS los ejecutores.
	
	Dimensiones válidas: `JobName` (el nombre del trabajo de AWS Glue), `JobRunId` (el ID de JobRun o `ALL`), y `Type` (calibre).
	
	Estadísticas válidas: promedio. Esta es una métrica de Spark, notificada como un valor absoluto.
	
	Unidad: bytes
	
	Se puede utilizar para monitorear lo siguiente:
	
	• Condiciones de memoria insuficiente (OOM) del controlador.
	• Condiciones de memoria insuficiente (OOM) del ejecutor.
	
	Algunas formas de usar los datos:
	
	• Identificar las etapas y los ID de los ejecutores que consumen memoria.
	• Identificar los ID y las etapas de los ejecutores rezagados.
	• Identificar una condición de memoria insuficiente (OOM) del controlador.
	• Identificar una condición de falta de memoria (OOM) del ejecutor y obtener el ID de ejecutor correspondiente para poder obtener un seguimien to de pila del registro del ejecutor.

Métrica	Descripción
	• Identificar los archivos o particiones que pueden tener un sesgo de datos, lo que resulta en rezagos o condiciones de memoria insuficiente (OOM).

Métrica	Descripción

`glue.driver.s3.filesystem.read_bytes`
 	
`glue.`Id de ejecutor`.s3.filesystem.read_bytes`
 	
`glue.ALL.s3.filesystem.read_bytes`
	El número de bytes leídos desde Amazon S3 por el controlador, un ejecutor identificado por Id de ejecutor, o TODOS los ejecutores desde el informe anterior (acumulados por el panel de métricas de AWS Glue como número de bytes leídos durante el minuto anterior).
	
	Dimensiones válidas: `JobName`, `JobRunId`, y `Type` (calibre).
	
	Estadísticas válidas: SUMA. Esta métrica es un valor delta desde el último valor notificado, por lo que en el panel de métricas de AWS Glue, se utiliza una estadística SUM para la agregación. El área bajo la curva en el panel de métricas de AWS Glue se puede utilizar para comparar visualmente los bytes leídos por dos ejecuciones de trabajos diferentes.
	
	Unidad: bytes.
	
	Se puede utilizar para monitorear lo siguiente:
	
	• Movimiento de datos de ETL.
	• Progreso del trabajo.
	• Problemas de marcadores de trabajos (datos procesados, reprocesados y omitidos).
	• Comparación de lecturas con la tasa de ingesta de orígenes de datos externos.
	• Desviación entre ejecuciones de trabajos.
	
	Los datos resultantes se pueden utilizar para lo siguiente:
	
	• Planificación de la capacidad de DPU.

Métrica	Descripción
	• Establecer alarmas para picos grandes o caídas en los datos leídos para ejecuciones de trabajos y etapas de trabajo.

Métrica	Descripción

`glue.driver.s3.filesystem.write_bytes`
 	
`glue.`Id de ejecutor`.s3.filesystem.write_bytes`
 	
`glue.ALL.s3.filesystem.write_bytes`
	El número de bytes que escribe el controlador en Amazon S3, un ejecutor identificado por Id de ejecutor, o TODOS los ejecutores desde el informe anterior (agregados por el panel de métricas de AWS Glue como número de bytes escritos durante el minuto anterior).
	
	Dimensiones válidas: `JobName`, `JobRunId`, y `Type` (calibre).
	
	Estadísticas válidas: SUMA. Esta métrica es un valor delta desde el último valor notificado, por lo que en el panel de métricas de AWS Glue, se utiliza una estadística SUM para la agregación. El área bajo la curva en el panel de métricas de AWS Glue se puede utilizar para comparar visualmente los bytes escritos por dos ejecuciones de trabajos diferentes.
	
	Unidad: bytes
	
	Se puede utilizar para monitorear lo siguiente:
	
	• Movimiento de datos de ETL.
	• Progreso del trabajo.
	• Problemas de marcadores de trabajos (datos procesados, reprocesados y omitidos).
	• Comparación de lecturas con la tasa de ingesta de orígenes de datos externos.
	• Desviación entre ejecuciones de trabajos.
	
	Algunas formas de usar los datos:
	
	• Planificación de la capacidad de DPU.

Métrica	Descripción
	• Establecer alarmas para picos grandes o caídas en los datos leídos para ejecuciones de trabajos y etapas de trabajo.
`glue.driver.streaming.numRecords`	El número de registros que se reciben en un microlote. Esta métrica solo está disponible para trabajos de streaming de AWS Glue con la versión AWS Glue 2.0 y superior. Dimensiones válidas: `JobName` (el nombre del trabajo de AWS Glue), `JobRunId` (el ID de JobRun o `ALL`), y `Type` (recuento). Estadísticas válidas: suma, máximo, mínimo, promedio, percentilo Unidad: recuento Se puede utilizar para monitorear lo siguiente: • Registros leídos. • Progreso del trabajo.

Métrica	Descripción
`glue.driver.streaming.batchProcessingTimeInMs`	El tiempo que se tarda en procesar los lotes en milisegundos. Esta métrica solo está disponible para trabajos de streaming de AWS Glue con la versión AWS Glue 2.0 y superior. Dimensiones válidas: `JobName` (el nombre del trabajo de AWS Glue), `JobRunId` (el ID de JobRun o `ALL`), y `Type` (recuento). Estadísticas válidas: suma, máximo, mínimo, promedio, percentilo Unidad: recuento Se puede utilizar para monitorear lo siguiente: • Progreso del trabajo. • Rendimiento del script.

Métrica	Descripción

`glue.driver.system.cpuSystemLoad`
 	
`glue.`Id de ejecutor`.system.cpuSystemLoad`
 	
`glue.ALL.system.cpuSystemLoad`
	Fracción de la carga del sistema de CPU usada (escala: 0-1) por el controlador, un ejecutor identificado por Id de ejecutor, o TODOS los ejecutores.
	
	Dimensiones válidas: `JobName` (el nombre del trabajo de AWS Glue), `JobRunId` (el ID de JobRun o `ALL`), y `Type` (calibre).
	
	Estadísticas válidas: promedio. Esta métrica se notifica como un valor absoluto.
	
	Unidad: porcentaje
	
	Se puede utilizar para monitorear lo siguiente:
	
	• Carga de CPU del controlador.
	• Carga de CPU del ejecutor.
	• Detección de ejecutores o etapas vinculados a la CPU o vinculados a entradas/salidas en un trabajo.
	
	Algunas formas de usar los datos:
	
	• Planificación de la capacidad de DPU junto con métricas de entrada/salida (bytes de lectura/bytes de mezcla aleatoria, paralelismo de tareas) y la métrica del número máximo de ejecutores necesarios.
	• Identificación de la relación vinculada a CPU y entrada/salida. Esto permite la repartición y el aumento de la capacidad aprovisionada para trabajos de ejecución prolongada con conjuntos de datos que pueden dividirse y ocupan menor capacidad de uso de la CPU.

Dimensiones de las métricas de AWS Glue

Las métricas de AWS Glue utilizan el espacio de nombres de AWS Glue y proporcionan métricas para las siguientes dimensiones:

Dimensión	Descripción
`JobName`	Esta dimensión filtra las métricas de todas las ejecuciones de trabajos de un trabajo de AWS Glue específico.
`JobRunId`	Esta dimensión filtra las métricas de ejecución de un trabajo de AWS Glue específico por ID de JobRun, o `ALL`.
`Type`	Esta dimensión filtra las métricas por `count` (un número acumulado) o `gauge` (un valor en un punto en el tiempo).

Para obtener más información, consulte la Guía del usuario de Amazon CloudWatch.

Configuración de alarmas de Amazon CloudWatch en perfiles de trabajo de AWS Glue

Las métricas de AWS Glue también están disponibles en Amazon CloudWatch. Puede configurar alarmas en cualquier métrica de AWS Glue para trabajos programados.

A continuación se muestran algunas situaciones comunes de configuración de alarmas:

- Trabajos con problemas de falta de memoria (OOM): establezca una alarma cuando el uso de la memoria supere la media normal del controlador o un ejecutor de un trabajo de AWS Glue.
- Ejecutores rezagados: establezca una alarma cuando el número de ejecutores caiga por debajo de un determinado umbral durante un largo periodo de tiempo en un trabajo de AWS Glue.
- Reprocesamiento o tareas pendientes de datos: compare las métricas de trabajos individuales en un flujo de trabajo mediante una expresión matemática de CloudWatch. A continuación, puede activar una alarma en el valor de expresión resultante (como la relación de bytes escritos por un trabajo y bytes leídos por un trabajo posterior).

Para obtener instrucciones detalladas acerca de cómo establecer alarmas, consulte Crear o editar una alarma de CloudWatch Alarm en la Guía del usuario de Amazon CloudWatch Events.

Para monitorear y depurar escenarios con CloudWatch, consulte Monitorización y depuración de trabajo.

Registro de trabajos de AWS Glue

En AWS Glue 5.0, todos los trabajos cuentan con capacidades de registro en tiempo real. Además, puede especificar opciones de configuración personalizadas para adaptar el comportamiento de registro. Estas opciones incluyen establecer el nombre del grupo de registro de Amazon CloudWatch, el prefijo del flujo de registro de Amazon CloudWatch (que antecede al ID de ejecución del trabajo de AWS Glue y al ID del controlador o ejecutor), y el patrón de conversión para los mensajes de registro. Estas configuraciones permiten agrupar los registros en grupos de registro personalizados de Amazon CloudWatch con diferentes políticas de expiración. Además, puede analizar los registros con mayor eficacia si define prefijos personalizados para los flujos de registro y patrones de conversión. Este nivel de personalización permite optimizar la administración y el análisis de registros según necesidades específicas.

Comportamiento del registro en AWS Glue 5.0

De forma predeterminada, los registros del sistema, los registros de daemon de Spark y los registros del usuario generados con el registrador de AWS Glue se escriben en el grupo de registro `/aws-glue/jobs/error` de Amazon CloudWatch. Por otro lado, los registros de salida estándar (stdout) y de error estándar (stderr) del usuario se escriben de forma predeterminada en el grupo de registro `/aws-glue/jobs/output`.

Registro personalizado

Puede personalizar el grupo de registro y los prefijos de flujo de registro definidos de forma predeterminada mediante los siguientes argumentos de trabajo:

- `--custom-logGroup-prefix`: permite especificar un prefijo personalizado para los grupos de registro `/aws-glue/jobs/error` y `/aws-glue/jobs/output`. Si especifica un prefijo personalizado, los nombres de los grupos de registro adoptarán el siguiente formato:
  - `/aws-glue/jobs/error` será *`<customer prefix>`*`/error`
  - `/aws-glue/jobs/output` será *`<customer prefix>`*`/output`

- `--custom-logStream-prefix`: permite especificar un prefijo personalizado para los nombres de los flujos de registro dentro de los grupos de registro. Si especifica un prefijo personalizado, los nombres de los flujos de registro adoptarán el siguiente formato:
  - `jobrunid-driver` será *`<customer log stream>`*`-driver`
  - `jobrunid-executorNum` será *`<customer log stream>`*`-executorNum`

Reglas de validación y limitaciones para prefijos personalizados:

- El nombre completo del flujo de registro debe tener entre 1 y 512 caracteres.
- El prefijo personalizado, por sí solo, tiene un límite de 400 caracteres.
- El prefijo personalizado debe coincidir con el patrón de expresión regular "[^:*]*" (los caracteres especiales permitidos son "_", "-" y "/").

Registro de mensajes específicos de aplicación con el registrador de script personalizado

Puede utilizar el registrador de AWS Glue para registrar todos los mensajes específicos de la aplicación en el script que se envían en tiempo real al flujo de registro del controlador.

En el siguiente ejemplo se muestra un script de Python.

```
from awsglue.context import GlueContext
from pyspark.context import SparkContext

sc = SparkContext()
glueContext = GlueContext(sc)
logger = glueContext.get_logger()
logger.info("info message")
logger.warn("warn message")
logger.error("error message")
```

En el siguiente ejemplo se muestra un script de Scala.

```
import com.amazonaws.services.glue.log.GlueLogger

object GlueApp {
  def main(sysArgs: Array[String]) {
    val logger = new GlueLogger
    logger.info("info message")
    logger.warn("warn message")
```

```
    logger.error("error message")
  }
}
```

Habilitación de la barra de progreso para mostrar el progreso del trabajo

AWS Glue proporciona una barra de progreso en tiempo real bajo el flujo de registro `JOB_RUN_ID-progress-bar` para comprobar el estado de ejecución de un trabajo de AWS Glue. En la actualidad se admiten únicamente los trabajos que inicializan `glueContext`. Si ejecuta un trabajo de Spark puro sin inicializar `glueContext`, la barra de progreso de AWS Glue no aparece.

La barra de progreso muestra la siguiente actualización del progreso cada 5 segundos.

```
Stage Number (Stage Name): > (numCompletedTasks + numActiveTasks) /
 totalNumOfTasksInThisStage]
```

Configuración de seguridad con registro en Amazon CloudWatch

Cuando se habilita una configuración de seguridad para los registros de Amazon CloudWatch, AWS Glue crea grupos de registro con patrones de nombres específicos que incorporan el nombre de la configuración de seguridad.

Asignación de nombres a grupos de registro con configuración de seguridad

Los grupos de registro predeterminados y personalizados serán de la siguiente manera:

- Grupo de registro de errores predeterminado: `/aws-glue/jobs/`*`Security-Configuration-Name`*`-role/`*`glue-job-role`*`/error`
- Grupo de registro de salida predeterminado: `/aws-glue/jobs/`*`Security-Configuration-Name`*`-role/`*`glue-job-role`*`/output`
- Grupo de registro de errores personalizado (AWS Glue 5.0): *`custom-log-group-prefix`*`/`*`Security-Configuration-Name`*`-role/`*`glue-job-role`*`/error`
- Grupo de registro de salida personalizado (AWS Glue 5.0): *`custom-log-group-prefix`*`/`*`Security-Configuration-Name`*`-role/`*`glue-job-role`*`/output`

Permisos de IAM necesarios

Debe agregar el permiso `logs:AssociateKmsKey` a los permisos del rol de IAM si habilita una configuración de seguridad con Registros de Amazon CloudWatch. Si no se incluye ese permiso, se deshabilitará el registro continuo.

Además, para configurar el cifrado de los Registros de Amazon CloudWatch, siga las instrucciones en Cifrar datos de registro en Registros de Amazon CloudWatch con AWS Key Management Service, disponible en la Guía del usuario de Registros de Amazon Amazon CloudWatch.

Información adicional

Para obtener más información sobre la creación de configuraciones de seguridad, consulte Administración de configuraciones de seguridad en la consola de AWS Glue.

Temas

- Habilitación del registro continuo para trabajos de AWS Glue 4.0 y trabajos anteriores
- Visualización de registros para trabajos de AWS Glue

Habilitación del registro continuo para trabajos de AWS Glue 4.0 y trabajos anteriores

> **Note**
>
> En AWS Glue 4.0 y versiones anteriores, el registro continuo era una característica disponible. Sin embargo, con la introducción de AWS Glue 5.0, todos los trabajos cuentan con capacidad de registro en tiempo real. Para obtener más información sobre las capacidades de registro y las opciones de configuración en AWS Glue 5.0, consulte la sección Registro para trabajos de AWS Glue.

Puede habilitar el registro continuo a través de la consola de AWS Glue o a través de la AWS Command Line Interface (AWS CLI).

Puede habilitar el registro continuo al crear un trabajo nuevo, editar un trabajo existente o habilitarlo a través de AWS CLI.

También puede especificar opciones de configuración personalizadas, como el nombre del grupo de registro de Amazon CloudWatch, el prefijo de flujo de registro de CloudWatch antes del ID de controlador/ID de ejecutor de ejecución del trabajo de AWS Glue, así como el patrón de conversión de registro para los mensajes de registro. Estas configuraciones le ayudan a establecer registros agregados en grupos de registros personalizados de CloudWatch con diferentes políticas de caducidad y a analizarlos con prefijos de flujo de registro personalizados y patrones de conversión.

Temas

- Uso de Consola de administración de AWS

- Registro de mensajes específicos de aplicación con el registrador de script personalizado
- Habilitación de la barra de progreso para mostrar el progreso del trabajo
- Configuración de seguridad con registro continuo.

Uso de Consola de administración de AWS

Siga estos pasos para usar la consola para habilitar el registro continuo al crear o editar un trabajo de AWS Glue.

Para crear un nuevo trabajo de AWS Glue con registro continuo

1. Inicie sesión en la Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. En el panel de navegación, seleccione Trabajos de ETL.
3. Seleccione Visual ETL.
4. En la pestaña Detalles del trabajo, expanda la sección Propiedades avanzadas.
5. En la sección Registro continuo, seleccione Habilitar registros en CloudWatch.

Para habilitar el registro continuo para un trabajo de AWS Glue que ya tenga

1. Abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. En el panel de navegación, seleccione Trabajos.
3. Elija el trabajo que ya tiene en la lista Jobs (Trabajos).
4. Elija Action (Acción), Edit job (Editar trabajo).
5. En la pestaña Detalles del trabajo, expanda la sección Propiedades avanzadas.
6. En la sección Registro continuo, seleccione Habilitar registros en CloudWatch.

Mediante AWS CLI

Para habilitar el registro continuo debe transferir los parámetros de trabajo a un trabajo de AWS Glue. Transfiera los parámetros de trabajos especiales similares que figuran a continuación a otros parámetros de trabajo de AWS Glue. Para obtener más información, consulte Uso de los parámetros de trabajo en los trabajos de AWS Glue.

```
'--enable-continuous-cloudwatch-log': 'true'
```

Puede especificar un nombre de grupo de registro personalizado de Amazon CloudWatch. Si no se especifica, el nombre predeterminado del grupo de registro es `/aws-glue/jobs/logs-v2`.

```
'--continuous-log-logGroup': 'custom_log_group_name'
```

Puede especificar un prefijo de flujo de registro personalizado de Amazon CloudWatch. Si no se especifica, el prefijo de flujo de registro predeterminado es el ID de ejecución del trabajo.

```
'--continuous-log-logStreamPrefix': 'custom_log_stream_prefix'
```

Puede especificar un patrón de conversión de registro continuo personalizado. Si no se especifica, el patrón de conversión predeterminado es `%d{yy/MM/dd HH:mm:ss} %p %c{1}: %m%n`. Tenga en cuenta que el patrón de conversión solo se aplica a los registros de controlador y ejecutor. No afecta a la barra de progreso de AWS Glue.

```
'--continuous-log-conversionPattern': 'custom_log_conversion_pattern'
```

Registro de mensajes específicos de aplicación con el registrador de script personalizado

Puede utilizar el registrador de AWS Glue para registrar todos los mensajes específicos de la aplicación en el script que se envían en tiempo real al flujo de registro del controlador.

En el siguiente ejemplo se muestra un script de Python.

```
from awsglue.context import GlueContext
from pyspark.context import SparkContext

sc = SparkContext()
glueContext = GlueContext(sc)
logger = glueContext.get_logger()
logger.info("info message")
logger.warn("warn message")
logger.error("error message")
```

En el siguiente ejemplo se muestra un script de Scala.

```
import com.amazonaws.services.glue.log.GlueLogger

object GlueApp {
  def main(sysArgs: Array[String]) {
    val logger = new GlueLogger
```

```
    logger.info("info message")
    logger.warn("warn message")
    logger.error("error message")
  }
}
```

Habilitación de la barra de progreso para mostrar el progreso del trabajo

AWS Glue proporciona una barra de progreso en tiempo real bajo el flujo de registro `JOB_RUN_ID-progress-bar` para comprobar el estado de ejecución de un trabajo de AWS Glue. En la actualidad se admiten únicamente los trabajos que inicializan `glueContext`. Si ejecuta un trabajo de Spark puro sin inicializar `glueContext`, la barra de progreso de AWS Glue no aparece.

La barra de progreso muestra la siguiente actualización del progreso cada 5 segundos.

```
Stage Number (Stage Name): > (numCompletedTasks + numActiveTasks) /
 totalNumOfTasksInThisStage]
```

Configuración de seguridad con registro continuo.

Si se habilita una configuración de seguridad para los registros de CloudWatch, AWS Glue creará un grupo de registro llamado de la siguiente manera para los registros continuos:

```
<Log-Group-Name>-<Security-Configuration-Name>
```

Los grupos de registro predeterminados y personalizados serán de la siguiente manera:

- El grupo de registro continuo predeterminado será `/aws-glue/jobs/error-`*`<Security-Configuration-Name>`*
- El grupo de registro continuo personalizado será *`<custom-log-group-name>`*`-`*`<Security-Configuration-Name>`*

Debe agregar `logs:AssociateKmsKey` a sus permisos de rol de IAM, si habilita una configuración de seguridad con CloudWatch Logs. Si no se incluye ese permiso, se deshabilitará el registro continuo. Además, para configurar el cifrado de CloudWatch Logs, siga las instrucciones en Cifrar datos de registro en CloudWatch Logs mediante AWS Key Management Service en la Guía del usuario de Amazon CloudWatch Logs.

Para obtener más información sobre cómo crear una configuración de seguridad, consulte Administración de las configuraciones de seguridad en la consola de AWS Glue.

> **Note**
>
> Es posible que se generen cargos adicionales al habilitar el registro y crear eventos de registro adicionales de CloudWatch. Para obtener más información, consulte los precios de Amazon CloudWatch .

Visualización de registros para trabajos de AWS Glue

Puede ver registros en tiempo real mediante la consola de AWS Glue o la consola de Amazon CloudWatch.

Para ver registros en tiempo real mediante el panel de la consola de AWS Glue

1. Inicie sesión en la Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. En el panel de navegación, seleccione Trabajos.
3. Añada o inicie el trabajo que ya tiene. Elija Action (Acción), Run job (Ejecutar trabajo).

   Cuando inicia la ejecución de un trabajo, puede ir a una página que contiene información sobre el trabajo en ejecución:

   - La pestaña Logs (Registros) muestra los registros de la aplicación agregados más antiguos.
   - La pestaña Registros muestra una barra de progreso en tiempo real cuando el trabajo se ejecuta con `glueContext` inicializado.
   - La pestaña Registros también incluye los Registros del controlador, que capturan en tiempo real los registros del controlador de Apache Spark, así como los registros de la aplicación generados por el script mediante el registrador de la aplicación de AWS Glue cuando el trabajo está en ejecución.
4. Para trabajos más antiguos también puede ver los registros en tiempo real en la vista Job History (Historial de trabajos) eligiendo Logs (Registros). Esta acción lo lleva a la consola de CloudWatch que muestra todos los flujos de registro del controlador de Spark, ejecutor y barra de progreso para ese trabajo ejecutado.

Para ver registros en tiempo real mediante el panel de la consola de CloudWatch

1. Abra la consola de CloudWatch en https://console.aws.amazon.com/cloudwatch/.

2. En el panel de navegación, elija Log (Registro).
3. Elija el grupo de registro /aws-glue/jobs/error/.
4. En el cuadro Filter (Filtro), pegue ID del trabajo en ejecución.

   Puede ver los registros del controlador, los registros del ejecutor y la barra de progreso (si utiliza el filtro estándar).

Monitorización con métricas de observabilidad de AWS Glue

> **Note**
>
> Las métricas de observabilidad de AWS Glue están disponibles en AWS Glue, versión 4.0 y versiones posteriores.

Use las métricas de observabilidad de AWS Glue para obtener información sobre lo que ocurre dentro de sus trabajos de AWS Glue for Apache Spark y así mejorar la clasificación y el análisis de los problemas. Las métricas de observabilidad se visualizan a través de paneles de control Amazon CloudWatch y se pueden utilizar para analizar la causa raíz de los errores y diagnosticar los cuellos de botella en el rendimiento. Puede reducir el tiempo dedicado a depurar los problemas a gran escala para poder centrarse en resolverlos de forma más rápida y eficaz.

La observabilidad de AWS Glue proporciona métricas Amazon CloudWatch clasificadas en los cuatro grupos siguientes:

- Fiabilidad (es decir, clases de errores): identifique fácilmente los motivos de error más comunes en un intervalo de tiempo determinado que desee abordar.
- Rendimiento (es decir, asimetría): identifique un obstáculo en el rendimiento y aplique técnicas de ajuste. Por ejemplo, si experimenta una disminución del rendimiento debido a la asimetría de los trabajos, es posible que desee activar Spark Adaptive Query Execution y ajustar el umbral de unión descompensado.
- Rendimiento (es decir, rendimiento por fuente/receptor): supervisa las tendencias de lectura y escritura de datos. También puede configurar alarmas Amazon CloudWatch para detectar anomalías.
- Utilización de los recursos (es decir, el personal, la utilización de la memoria y el disco): encuentre de manera eficiente los trabajos con un bajo uso de la capacidad. Es posible que desee habilitar el escalado automático de AWS Glue para esos trabajos.

Cómo empezar con las métricas de observabilidad de AWS Glue

> **Note**
>
> Las nuevas métricas están habilitadas de forma predeterminada en la consola de AWS Glue Studio.

Para configurar las métricas de observabilidad en AWS Glue Studio:

1. Inicie sesión en la consola AWS Glue y seleccione Trabajos ETL en el menú de la consola.
2. Elija un trabajo haciendo clic en el nombre del trabajo en la sección Sus trabajos.
3. Elija la pestaña Detalles del trabajo.
4. Desplácese hasta la parte inferior y seleccione Propiedades avanzadas y, a continuación, Métricas de observabilidad del trabajo.

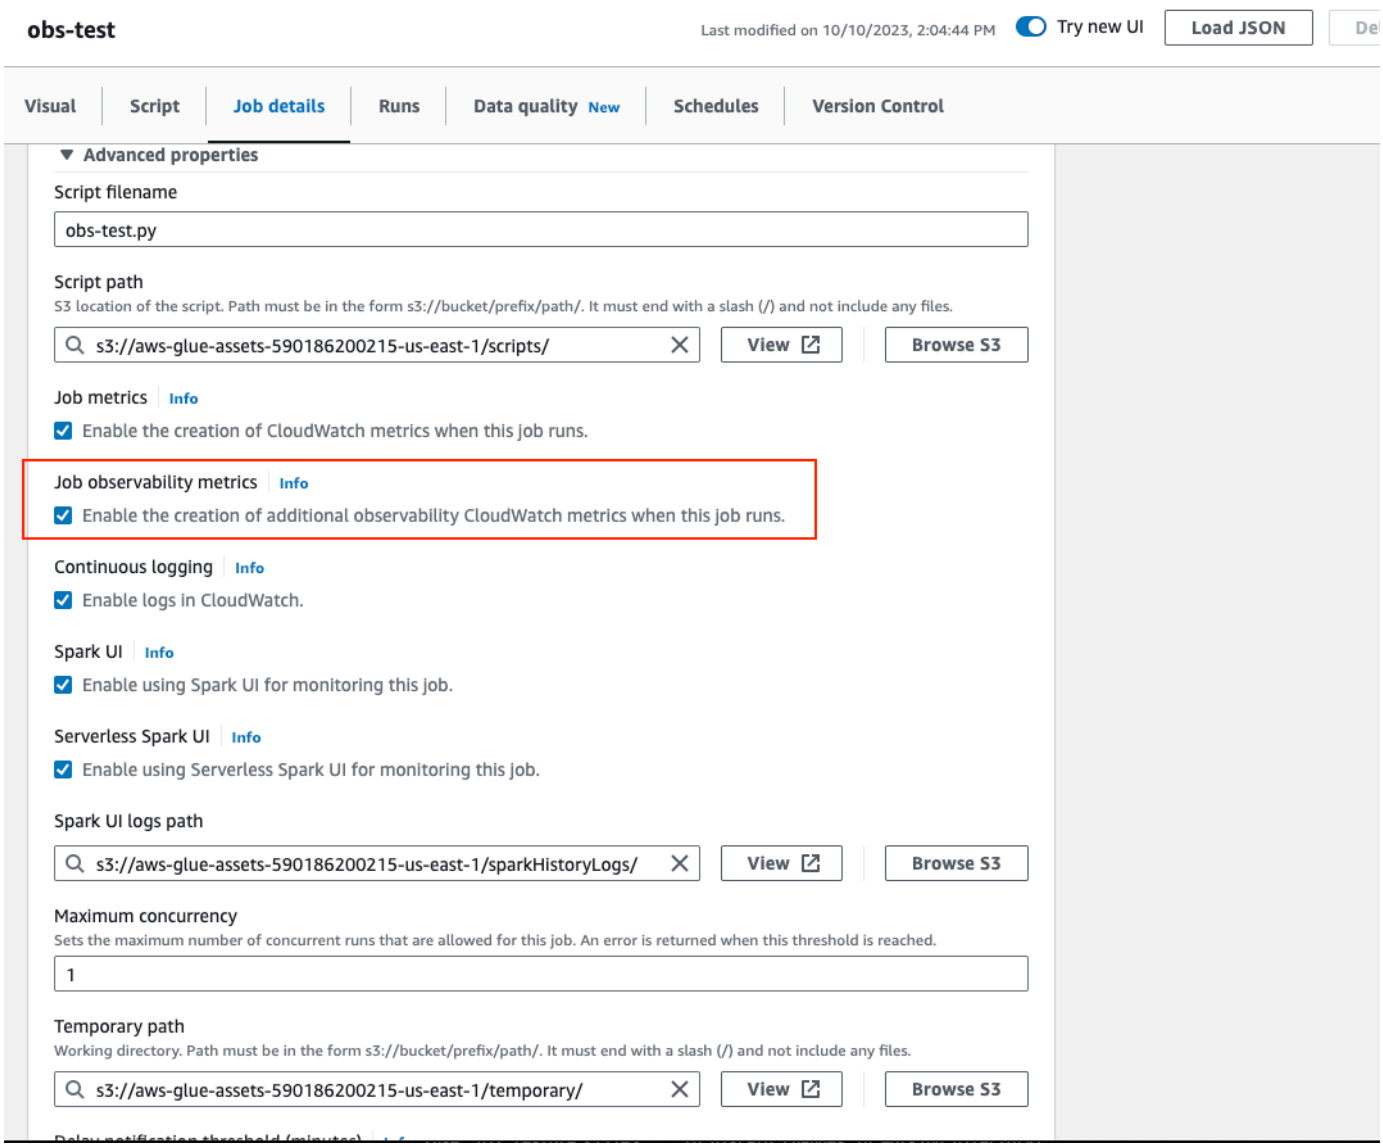

Para habilitar las métricas de observabilidad de AWS Glue usando AWS CLI:

- Agregue al mapa `--default-arguments` el siguiente valor-clave en el archivo JSON de entrada:

```
--enable-observability-metrics, true
```

Uso de la observabilidad de AWS Glue

Dado que las métricas de observabilidad de AWS Glue se proporcionan mediante Amazon CloudWatch, puede usar la consola Amazon CloudWatch, AWS CLI, el SDK o la API para consultar los puntos de datos de las métricas de observabilidad. Consulte Uso de observabilidad de Glue para monitorear el uso de los recursos a fin de reducir el costo para ver un ejemplo de caso práctico en el que se utilizan métricas de observabilidad de AWS Glue.

Uso de la observabilidad de AWS Glue en la consola Amazon CloudWatch

Para consultar y visualizar las métricas en la consola Amazon CloudWatch:

1. Abra la consola Amazon CloudWatch y seleccione Todas las métricas.
2. En Espacios de nombres personalizados, seleccione AWS Glue.
3. Elija Métricas de observabilidad de trabajo, Métricas de observabilidad por origen o Métricas de observabilidad por receptor.
4. Busque el nombre de la métrica, el nombre del trabajo o el identificador de ejecución específicos y selecciónelos.
5. En la pestaña Métricas graficadas, configure la estadística, el período y otras opciones que prefiera.

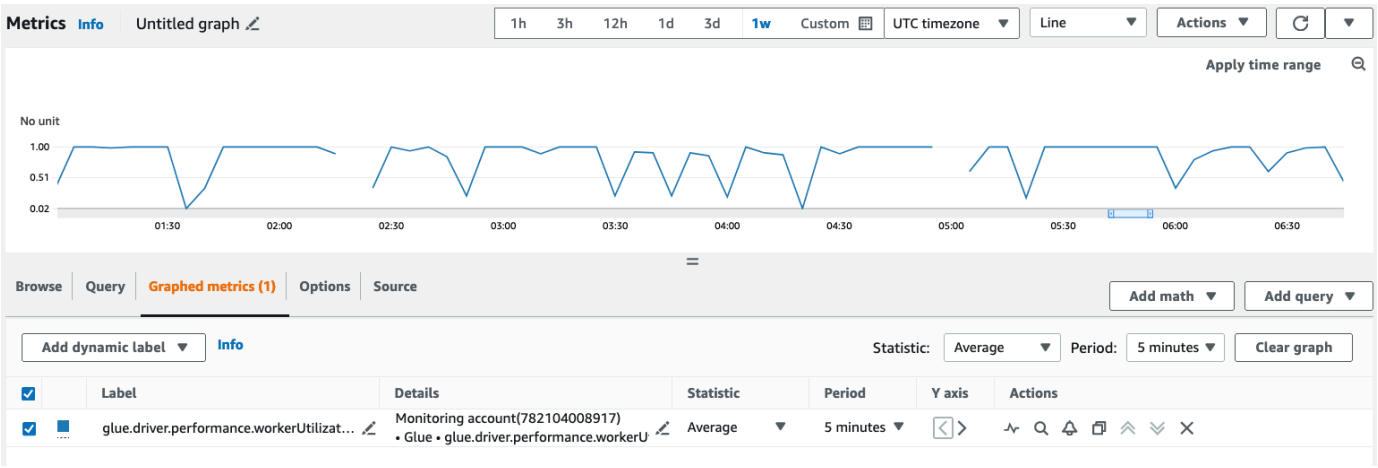

Para consultar una métrica de observabilidad mediante AWS CLI:

1. Cree un archivo JSON de definición de métricas y reemplace `your-Glue-job-name` y `your-Glue-job-run-id`.

```
$ cat multiplequeries.json
```

```
[
    {
        "Id": "avgWorkerUtil_0",
        "MetricStat": {
            "Metric": {
                "Namespace": "Glue",
                "MetricName": "glue.driver.workerUtilization",
                "Dimensions": [
                    {
                        "Name": "JobName",
                        "Value": "<your-Glue-job-name-A>"
                    },
                    {
                        "Name": "JobRunId",
                        "Value": "<your-Glue-job-run-id-A>"
                    },
                    {
                        "Name": "Type",
                        "Value": "gauge"
                    },
                    {
                        "Name": "ObservabilityGroup",
                        "Value": "resource_utilization"
                    }
                ]
            },
            "Period": 1800,
            "Stat": "Minimum",
            "Unit": "None"
        }
    },
    {
        "Id": "avgWorkerUtil_1",
        "MetricStat": {
            "Metric": {
                "Namespace": "Glue",
                "MetricName": "glue.driver.workerUtilization",
                "Dimensions": [
                    {
                        "Name": "JobName",
                        "Value": "<your-Glue-job-name-B>"
                    },
                    {
                        "Name": "JobRunId",
```

```
                        "Value": "<your-Glue-job-run-id-B>"
                    },
                    {
                        "Name": "Type",
                        "Value": "gauge"
                    },
                    {
                        "Name": "ObservabilityGroup",
                        "Value": "resource_utilization"
                    }
                ]
            },
            "Period": 1800,
            "Stat": "Minimum",
            "Unit": "None"
        }
    }
]
```

2. Ejecute el comando `get-metric-data`:

```
$ aws cloudwatch get-metric-data --metric-data-queries file: //multiplequeries.json
 \
     --start-time '2023-10-28T18: 20' \
     --end-time '2023-10-28T19: 10'  \
     --region us-east-1
{
    "MetricDataResults": [
        {
            "Id": "avgWorkerUtil_0",
            "Label": "<your-label-for-A>",
            "Timestamps": [
                "2023-10-28T18:20:00+00:00"
            ],
            "Values": [
                0.06718750000000001
            ],
            "StatusCode": "Complete"
        },
        {
            "Id": "avgWorkerUtil_1",
            "Label": "<your-label-for-B>",
```

```
            "Timestamps": [
                "2023-10-28T18:50:00+00:00"
            ],
            "Values": [
                0.5959183673469387
            ],
            "StatusCode": "Complete"
        }
    ],
    "Messages": []
}
```

Métricas de observabilidad

La observabilidad de AWS Glue crea perfiles y envía las siguientes métricas a Amazon CloudWatch cada 30 segundos, y algunas de estas métricas pueden estar visibles en la página de monitoreo de JobRuns de AWS Glue Studio.

Métrica	Descripción	Categoría
glue.driver.skewness.stage	Categoría métrica: job_performance Spark clasifica la asimetría de la ejecución: esta métrica es un indicador de cuánto dura la actividad más larga en una determinada etapa en comparación con la duración media de las actividades en esa misma etapa. Captura la asimetría de la ejecución, que puede deberse a una asimetría de los datos de entrada o a una transformación (por ejemplo, una unión sesgada). Los valores de esta métrica se sitúan en el rango	job_performance

Métrica	Descripción	Categoría
	de [0, infinito [, donde 0 indica la relación entre el tiempo máximo y el tiempo medio de ejecución de las tareas; entre todas las tareas de la etapa, es inferior a un factor de asimetría de fase determina do. El factor de asimetría de fase predeterminado es 5 y se puede sobreescribir mediante spark conf: spark.metrics.conf .driver.source.glue.jobperf ormance.skewnessFactor Un valor de asimetría de fase igual a 1 significa que la relación es el doble del factor de asimetría de fase. El valor de la asimetría de fase se actualiza cada 30 segundos para reflejar la asimetría actual. El valor al final de la fase refleja la asimetría de fase final. Esta métrica a nivel de etapa se utiliza para calcular la métrica a nivel de trabajo. `glue.driver.skewne ss.job` Dimensiones válidas: JobName (el nombre del trabajo de AWS Glue), JobRunId (el ID de JobRun	

Métrica	Descripción	Categoría
	o ALL), Type (calibre) y ObservAbilityGroup (job_performance) Estadísticas válidas: promedio, máximo, mínimo, percentilo Unidad: recuento	

Métrica	Descripción	Categoría
glue.driver.skewness.job	Categoría métrica: job_performance La asimetría del trabajo es el máximo de la asimetría ponderada de todas las etapas. La asimetría de la etapa (glue.driver.skewness.stage) se pondera con la duración de la etapa. El propósito de esto evitar el caso extremo en el que una etapa muy asimétrica dure muy poco tiempo en comparación con otras etapas (y, por lo tanto, su asimetría no sea significativa para el rendimiento general del trabajo y no valga la pena hacer el esfuerzo para tratar de corregir esa asimetría). Esta métrica se actualiza al finalizar cada etapa y, por lo tanto, el último valor refleja la asimetría general real del trabajo. Dimensiones válidas: JobName (el nombre del trabajo de AWS Glue), JobRunId (el ID de JobRun o ALL), Type (calibre) y ObservAbilityGroup (job_performance)	job_performance

Métrica	Descripción	Categoría
	Estadísticas válidas: promedio, máximo, mínimo, percentilo Unidad: recuento	
glue.succeed.ALL	Categoría métrica: error Número total de tareas ejecutadas correctamente, para completar el panorama de las categorías de errores Dimensiones válidas: JobName (el nombre del trabajo de AWS Glue), JobRunId (el ID de JobRun o ALL), Type (recuento) y ObservAbilityGroup (error) Estadísticas válidas: SUMA Unidad: recuento	error

Métrica	Descripción	Categoría
glue.error.ALL	Categoría métrica: error Número total de errores al momento de ejecutar el trabajo, para completar el panorama de las categorías de errores Dimensiones válidas: JobName (el nombre del trabajo de AWS Glue), JobRunId (el ID de JobRun o ALL), Type (recuento) y ObservAbilityGroup (error) Estadísticas válidas: SUMA Unidad: recuento	error

Métrica	Descripción	Categoría
glue.error. [categoría de error]	Categoría métrica: error En realidad, se trata de un conjunto de métricas que se actualizan únicamente cuando se produce un error en la ejecución de un trabajo. La categorización de los errores ayuda a clasificar y depurar errores. Cuando se produce un error al ejecutar un trabajo, se clasifica el error que lo ha provocado y la métrica de la categoría de error correspondiente se define en 1. Esto ayuda a realizar un análisis de los errores a lo largo del tiempo, así como un análisis de los errores de todos los trabajos, para identificar las categoría s de errores más comunes y empezar a abordarlas. AWS Glue tiene 28 categorías de error, incluidas las categoría s de error OUT_OF_ME MORY (controlador y ejecutor) , PERMISSION, SYNTAX y THROTTLING. Las categoría s de error también incluyen las categorías COMPILATION, LAUNCH y TIMEOUT. Dimensiones válidas: JobName (el nombre del	error

Métrica	Descripción	Categoría
	trabajo de AWS Glue), JobRunId (el ID de JobRun o ALL), Type (recuento) y ObservAbilityGroup (error) Estadísticas válidas: SUMA Unidad: recuento	
glue.driver.workerUtilization	Categoría de métrica: resource_utilization El porcentaje de los trabajado res asignados que se utilizan realmente. Si no es bueno, el escalado automático puede ayudar. Dimensiones válidas: JobName (el nombre del trabajo de AWS Glue), JobRunId (el ID de JobRun o ALL), Type (calibre), y ObservAbilityGroup (resource _utilization) Estadísticas válidas: promedio, máximo, mínimo, percentilo Unidad: porcentaje	resource_utilization

Métrica	Descripción	Categoría
glue.driver.memory.heap. [disponible | usado]	Categoría de métrica: resource_utilization La memoria de pila disponibl e o utilizada por el controlad or durante la ejecución del trabajo. Esto ayuda a entender las tendencias de uso de la memoria, especialmente a lo largo del tiempo, lo que puede ayudar a evitar posibles fallos, además de depurar los errores relacionados con la memoria. Dimensiones válidas: JobName (el nombre del trabajo de AWS Glue), JobRunId (el ID de JobRun o ALL), Type (calibre), y ObservAbilityGroup (resource _utilization) Estadísticas válidas: Average Unidad: bytes	resource_utilization

Métrica	Descripción	Categoría
glue.driver.memory.heap.used.percentage	Categoría de métrica: resource_utilization El controlador utilizó (%) la memoria acumulada durante la ejecución del trabajo. Esto ayuda a entender las tendencias de uso de la memoria, especialmente a lo largo del tiempo, lo que puede ayudar a evitar posibles fallos, además de depurar los errores relacionados con la memoria. Dimensiones válidas: JobName (el nombre del trabajo de AWS Glue), JobRunId (el ID de JobRun o ALL), Type (calibre), y ObservAbilityGroup (resource_utilization) Estadísticas válidas: Average Unidad: porcentaje	resource_utilization

Métrica	Descripción	Categoría
glue.driver.memory.non-heap.[disponible | usado]	Categoría de métrica: resource_utilization La memoria no acumulada disponible o utilizada por el controlador durante la ejecución del trabajo. Esto ayuda a entender las tendencias de uso de la memoria, especialmente a lo largo del tiempo, lo que puede ayudar a evitar posibles fallos, además de depurar los errores relacionados con la memoria. Dimensiones válidas: JobName (el nombre del trabajo de AWS Glue), JobRunId (el ID de JobRun o ALL), Type (calibre), y ObservAbilityGroup (resource_utilization) Estadísticas válidas: Average Unidad: bytes	resource_utilization

Métrica	Descripción	Categoría
glue.driver.memory.non-heap .used.percentage	Categoría de métrica: resource_utilization El controlador utilizó (%) memoria no acumulada durante la ejecución del trabajo. Esto ayuda a entender las tendencias de uso de la memoria, especialmente a lo largo del tiempo, lo que puede ayudar a evitar posibles fallos, además de depurar los errores relacionados con la memoria. Dimensiones válidas: JobName (el nombre del trabajo de AWS Glue), JobRunId (el ID de JobRun o ALL), Type (calibre), y ObservAbilityGroup (resource _utilization) Estadísticas válidas: Average Unidad: porcentaje	resource_utilization

Métrica	Descripción	Categoría
glue.driver.memory.total. [disponible | usado]	Categoría de métrica: resource_utilization La memoria total disponibl e o utilizada por el controlad or durante la ejecución del trabajo. Esto ayuda a entender las tendencias de uso de la memoria, especialmente a lo largo del tiempo, lo que puede ayudar a evitar posibles fallos, además de depurar los errores relacionados con la memoria. Dimensiones válidas: JobName (el nombre del trabajo de AWS Glue), JobRunId (el ID de JobRun o ALL), Type (calibre), y ObservAbilityGroup (resource _utilization) Estadísticas válidas: Average Unidad: bytes	resource_utilization

Métrica	Descripción	Categoría
glue.driver.memory.total.used.percentage	Categoría de métrica: resource_utilization El controlador utilizó (%) de la memoria total durante la ejecución del trabajo. Esto ayuda a entender las tendencias de uso de la memoria, especialmente a lo largo del tiempo, lo que puede ayudar a evitar posibles fallos, además de depurar los errores relacionados con la memoria. Dimensiones válidas: JobName (el nombre del trabajo de AWS Glue), JobRunId (el ID de JobRun o ALL), Type (calibre), y ObservAbilityGroup (resource_utilization) Estadísticas válidas: Average Unidad: porcentaje	resource_utilization

Métrica	Descripción	Categoría
Glue.all.memory.heap. [disponible | usado]	Categoría de métrica: resource_utilization La memoria de pila utilizada /disponible de los ejecutore s. ALL significa todos los ejecutores. Dimensiones válidas: JobName (el nombre del trabajo de AWS Glue), JobRunId (el ID de JobRun o ALL), Type (calibre), y ObservAbilityGroup (resource _utilization) Estadísticas válidas: Average Unidad: bytes	resource_utilization

Métrica	Descripción	Categoría
glue.ALL.memory.heap.used.percentage	Categoría de métrica: resource_utilization La memoria de pila utilizada por los ejecutores (%). ALL significa todos los ejecutores. Dimensiones válidas: JobName (el nombre del trabajo de AWS Glue), JobRunId (el ID de JobRun o ALL), Type (calibre), y ObservAbilityGroup (resource_utilization) Estadísticas válidas: Average Unidad: porcentaje	resource_utilization

Métrica	Descripción	Categoría
glue.ALL.memory.non-heap.[disponible | usado]	Categoría de métrica: resource_utilization La memoria que no es de pila disponible/utilizada por los ejecutores. ALL significa todos los ejecutores. Dimensiones válidas: JobName (el nombre del trabajo de AWS Glue), JobRunId (el ID de JobRun o ALL), Type (calibre), y ObservAbilityGroup (resource_utilization) Estadísticas válidas: Average Unidad: bytes	resource_utilization

Métrica	Descripción	Categoría
glue.ALL.memory.non-heap.used.percentage	Categoría de métrica: resource_utilization Los ejecutores utilizaron (%) de memoria que no es de pila. ALL significa todos los ejecutores. Dimensiones válidas: JobName (el nombre del trabajo de AWS Glue), JobRunId (el ID de JobRun o ALL), Type (calibre), y ObservAbilityGroup (resource_utilization) Estadísticas válidas: Average Unidad: porcentaje	resource_utilization

Métrica	Descripción	Categoría
glue.ALL.memory.total. [disponible | usado]	Categoría de métrica: resource_utilization La memoria total utilizada/ disponible de los ejecutore s. ALL significa todos los ejecutores. Dimensiones válidas: JobName (el nombre del trabajo de AWS Glue), JobRunId (el ID de JobRun o ALL), Type (calibre), y ObservAbilityGroup (resource _utilization) Estadísticas válidas: Average Unidad: bytes	resource_utilization

Métrica	Descripción	Categoría
glue.ALL.memory.total.used.percentage	Categoría de métrica: resource_utilization La memoria total (%) utilizada por los ejecutores. ALL significa todos los ejecutores. Dimensiones válidas: JobName (el nombre del trabajo de AWS Glue), JobRunId (el ID de JobRun o ALL), Type (calibre), y ObservAbilityGroup (resource_utilization) Estadísticas válidas: Average Unidad: porcentaje	resource_utilization

Métrica	Descripción	Categoría
glue.driver.disk. [disponible_GB | usado_GB]	Categoría de métrica: resource_utilization El espacio en disco disponible o usado por el controlador durante la ejecución del trabajo. Esto ayuda a entender las tendencias de uso del disco, especialmente a lo largo del tiempo, lo que puede ayudar a evitar posibles fallos, además de depurar los errores relacionados con la falta de espacio en disco. Dimensiones válidas: JobName (el nombre del trabajo de AWS Glue), JobRunId (el ID de JobRun o ALL), Type (calibre), y ObservAbilityGroup (resource_utilization) Estadísticas válidas: Average Unidad: Gigabytes	resource_utilization

Métrica	Descripción	Categoría
glue.driver.disk.used.percentage]	Categoría de métrica: resource_utilization El espacio en disco disponible o usado por el controlador durante la ejecución del trabajo. Esto ayuda a entender las tendencias de uso del disco, especialmente a lo largo del tiempo, lo que puede ayudar a evitar posibles fallos, además de depurar los errores relacionados con la falta de espacio en disco. Dimensiones válidas: JobName (el nombre del trabajo de AWS Glue), JobRunId (el ID de JobRun o ALL), Type (calibre), y ObservAbilityGroup (resource_utilization) Estadísticas válidas: Average Unidad: porcentaje	resource_utilization

Métrica	Descripción	Categoría
glue.ALL.disk. [disponible_GB | usado_GB]	Categoría de métrica: resource_utilization El espacio en disco usado/disponible de los ejecutores. ALL significa todos los ejecutores. Dimensiones válidas: JobName (el nombre del trabajo de AWS Glue), JobRunId (el ID de JobRun o ALL), Type (calibre), y ObservAbilityGroup (resource_utilization) Estadísticas válidas: Average Unidad: Gigabytes	resource_utilization

Métrica	Descripción	Categoría
glue.ALL.disk.used.percentage	Categoría de métrica: resource_utilization El espacio en disco disponible/usado/usado (%) de los ejecutores. ALL significa todos los ejecutores. Dimensiones válidas: JobName (el nombre del trabajo de AWS Glue), JobRunId (el ID de JobRun o ALL), Type (calibre), y ObservAbilityGroup (resource_utilization) Estadísticas válidas: Average Unidad: porcentaje	resource_utilization

Métrica	Descripción	Categoría
glue.driver.bytesRead	Categoría métrica: rendimiento El número de bytes leídos por fuente de entrada en esta ejecución de trabajo, y en TODAS las fuentes. Esto ayuda a entender el volumen de datos y sus cambios a lo largo del tiempo, lo que ayuda a tratar problemas como la asimetría de los datos. Dimensiones válidas: JobName (el nombre del trabajo de AWS Glue), JobRunID (el JobRun ID. o ALL), Type (calibre), ObservabilityGroup (resource_utilization) y Source (ubicación de los datos de origen) Estadísticas válidas: Average Unidad: bytes	rendimiento

Métrica	Descripción	Categoría
glue.driver. [Registros leídos | Archivos leídos]	Categoría métrica: rendimiento El número de registros/archivos leídos por fuente de entrada en esta ejecución de trabajo, y en TODAS las fuentes. Esto ayuda a entender el volumen de datos y sus cambios a lo largo del tiempo, lo que ayuda a tratar problemas como la asimetría de los datos. Dimensiones válidas: JobName (el nombre del trabajo de AWS Glue), JobRunID (el JobRun ID. o ALL), Type (calibre), ObservabilityGroup (resource_utilization) y Source (ubicación de los datos de origen) Estadísticas válidas: Average Unidad: recuento	rendimiento

Métrica	Descripción	Categoría
glue.driver.partitionsRead	Categoría métrica: rendimiento El número de particiones leídas por fuente de entrada de Amazon S3 en esta ejecución de trabajo, y para TODAS las fuentes. Dimensiones válidas: JobName (el nombre del trabajo de AWS Glue), JobRunID (el JobRun ID. o ALL), Type (calibre), ObservabilityGroup (resource_utilization) y Source (ubicación de los datos de origen) Estadísticas válidas: Average Unidad: recuento	rendimiento

Métrica	Descripción	Categoría
glue.driver.bytesWrittten	Categoría métrica: rendimiento El número de bytes escritos por receptor de salida en esta ejecución de trabajo, y en TODOS los receptores. Esto ayuda a entender el volumen de datos y cómo evoluciona con el tiempo, lo que ayuda a tratar problemas como la asimetría del procesamiento. Dimensiones válidas: JobName (el nombre del trabajo de AWS Glue), JobRunID (el JobRun ID. o ALL), Type (calibre), ObservabilityGroup (resource_utilization) y Sink (ubicación de los datos de sink) Estadísticas válidas: Average Unidad: bytes	rendimiento

Métrica	Descripción	Categoría
glue.driver. [Registros escritos | Archivos escritos]	Categoría métrica: rendimiento El número de registros o archivos escritos por receptor de salida en esta ejecución de trabajo, y en TODOS los receptores. Esto ayuda a entender el volumen de datos y cómo evoluciona con el tiempo, lo que ayuda a tratar problemas como la asimetría del procesamiento. Dimensiones válidas: JobName (el nombre del trabajo de AWS Glue), JobRunID (el JobRun ID. o ALL), Type (calibre), ObservabilityGroup (resource_utilization) y Sink (ubicación de los datos de sink) Estadísticas válidas: Average Unidad: recuento	rendimiento

Categorías de errores

Categorías de errores	Descripción
COMPILATION_ERROR	Los errores surgen durante la compilación del código de Scala.

Categorías de errores	Descripción
CONNECTION_ERROR	Los errores se producen durante la conexión a un servicio remoto/servicio de host/base de datos, etc.
DISK_NO_SPACE_ERROR	Los errores se producen cuando no queda espacio en el disco del controlador/ejecutor.
OUT_OF_MEMORY_ERROR	Los errores se producen cuando no queda espacio en la memoria del controlador/ejecutor.
IMPORT_ERROR	Los errores se producen al importar dependenc ias.
INVALID_ARGUMENT_ERROR	Los errores se producen cuando los argumento s de entrada son inválidos o ilegales.
PERMISSION_ERROR	Los errores se producen cuando no se tiene el permiso para acceder al servicio, los datos, etc.
RESOURCE_NOT_FOUND_ERROR	Los errores se producen cuando los datos, la ubicación, etc. no existen.
QUERY_ERROR	Los errores se producen por la ejecución de una consulta SQL de Spark.
SYNTAX_ERROR	Los errores se producen cuando hay un error de sintaxis en el script.
THROTTLING_ERROR	Los errores se producen cuando se alcanza el límite de simultaneidad del servicio o se supera el límite de la cuota de servicio.
DATA_LAKE_FRAMEWORK_ERROR	Los errores se deben a un marco de lago de datos con soporte nativo de AWS Glue, como Hudi, Iceberg, etc.

Categorías de errores	Descripción
UNSUPPORTED_OPERATION_ERROR	Los errores se producen al realizar una operación no compatible.
RESOURCES_ALREADY_EXISTS_ERROR	Los errores se producen cuando un recurso que se va a crear o añadir ya existe.
GLUE_INTERNAL_SERVICE_ERROR	Los errores se producen cuando hay un problema de servicio interno de AWS Glue.
GLUE_OPERATION_TIMEOUT_ERROR	Los errores se producen cuando se agota el tiempo de espera de una operación de AWS Glue.
GLUE_VALIDATION_ERROR	Los errores se producen cuando no se ha podido validar un valor requerido para el trabajo de AWS Glue.
GLUE_JOB_BOOKMARK_VERSION_MISMATCH_ERROR	Los errores se producen cuando ejecuta el mismo trabajo en el mismo bucket de origen y escribe en el mismo destino o en uno diferente simultáneamente (concurrencia >1)
LAUNCH_ERROR	Los errores se producen durante la fase de inicio del trabajo de AWS Glue.
DYNAMODB_ERROR	Los errores genéricos se deben al servicio de Amazon DynamoDB.
GLUE_ERROR	Los errores genéricos se deben al servicio de AWS Glue.
LAKEFORMATION_ERROR	Los errores genéricos se deben al servicio de AWS Lake Formation.
REDSHIFT_ERROR	Los errores genéricos se deben al servicio de Amazon Redshift.

Categorías de errores	Descripción
S3_ERROR	Los errores genéricos se deben al servicio de Amazon S3.
SYSTEM_EXIT_ERROR	Error genérico de salida del sistema.
TIMEOUT_ERROR	Los errores genéricos se producen cuando el trabajo falla debido al tiempo de espera de la operación.
UNCLASSIFIED_SPARK_ERROR	Los errores genéricos se deben a Spark.
UNCLASSIFIED_ERROR	Categoría de errores predeterminada.

Limitaciones

> **Note**
>
> `glueContext` debe inicializarse para publicar las métricas.

En la dimensión de origen, el valor es la ruta de Amazon S3 o el nombre de la tabla, según el tipo de fuente. Además, si la fuente es JDBC y se usa la opción de consulta, la cadena de consulta se establece en la dimensión de origen. Si el valor tiene más de 500 caracteres, se recorta hasta 500 caracteres. El valor tiene las siguientes limitaciones:

- Se eliminarán los caracteres que no sean ASCII.
- Si el nombre de la fuente no contiene ningún carácter ASCII, se convierte en <non-ASCII input>.

Limitaciones y consideraciones de las métricas de rendimiento

- Se admiten DataFrame y DynamicFrame basado en DataFrame (por ejemplo, JDBC, lectura desde parquet en Amazon S3); sin embargo, no se admite DynamicFrame basado en RDD (por ejemplo, leer csv, json en Amazon S3, etc.). Técnicamente, se admiten todas las lecturas y escrituras visibles en la interfaz de usuario de Spark.

- La métrica `recordsRead` se emitirá si el origen de datos es una tabla de catálogo y el formato es JSON, CSV, texto o Iceberg.
- Las métricas `glue.driver.throughput.recordsWritten`, `glue.driver.throughput.bytesWritten` y `glue.driver.throughput.filesWritten` no están disponibles en las tablas JDBC e Iceberg.
- Es posible que las métricas se retrasen. Si el trabajo finaliza en aproximadamente un minuto, es posible que no haya métricas de rendimiento en Amazon CloudWatch Metrics.

Monitorización y depuración de trabajo

Puede recopilar métricas acerca de los trabajos de AWS Glue y visualizarlas en las consolas de AWS Glue y Amazon CloudWatch para identificar y solucionar problemas. La generación de perfiles en sus trabajos de AWS Glue requiere los siguientes pasos:

1. Habilitar las métricas:

   a. Habilite la opción Job metrics (Métricas del trabajo) en la definición de trabajo. Puede habilitar la creación de perfiles en la consola de AWS Glue o como parámetro del trabajo. Para obtener más información, consulte Definición de propiedades de trabajo para trabajos de Spark o Uso de los parámetros de trabajo en los trabajos de AWS Glue.

   b. Habilite la opción Métricas de observabilidad AWS Glue en la definición de trabajo. Puede habilitar la observabilidad en la consola de AWS Glue o como parámetro del trabajo. Para obtener más información, consulte Monitorización con métricas de observabilidad de AWS Glue.

2. Confirme que el script de trabajo inicializa `GlueContext`. Por ejemplo, el siguiente fragmento de script inicializa `GlueContext` y muestra en qué parte del script se sitúa el código con perfil. Este formato general se usa en las situaciones de depuración siguientes.

```
import sys
from awsglue.transforms import *
from awsglue.utils import getResolvedOptions
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job
import time

## @params: [JOB_NAME]
```

```
args = getResolvedOptions(sys.argv, ['JOB_NAME'])

sc = SparkContext()
glueContext = GlueContext(sc)
spark = glueContext.spark_session
job = Job(glueContext)
job.init(args['JOB_NAME'], args)

...
...
code-to-profile
...
...


job.commit()
```

3. Ejecute el trabajo.
4. Visualización de las métricas:
   a. Visualice las métricas de trabajo en la consola AWS Glue e identifique las métricas que están fuera de lo normal para el controlador o un ejecutor.
   b. Compruebe las métricas de observabilidad en la página de monitorización de las ejecuciones de tareas, en la página de detalles de las ejecuciones de tareas o en Amazon CloudWatch. Para obtener más información, consulte Monitorización con métricas de observabilidad de AWS Glue.
5. Acote la causa raíz mediante la métrica identificada.
6. Opcionalmente, confirme la causa raíz mediante el flujo de registros del controlador o el ejecutor de trabajo identificado.

Casos de uso de las métricas de observabilidad de AWS Glue

- Depuración de excepciones de memoria insuficiente e irregularidades relativas al trabajo
- Depuración de etapas exigentes y tareas rezagadas
- Monitoreo del progreso de varios trabajos
- Monitorización de la planificación de la capacidad de DPU
- Uso de la observabilidad de AWS Glue para monitorear el uso de los recursos a fin de reducir los costos

Depuración de excepciones de memoria insuficiente e irregularidades relativas al trabajo

Puede depurar excepciones de memoria insuficiente (OOM) e irregularidades relativas al trabajo en AWS Glue. En las siguientes secciones se describen situaciones de depuración de excepciones de memoria insuficiente del controlador Apache Spark o un ejecutor de Spark.

- Depuración de una excepción de memoria insuficiente del controlador
- Depuración de una excepción de memoria insuficiente del ejecutor

Depuración de una excepción de memoria insuficiente del controlador

En esta situación, un trabajo de Spark está leyendo un gran número de pequeños archivos desde Amazon Simple Storage Service (Amazon S3). Convierte los archivos al formato Apache Parquet y, a continuación, los escribe en Amazon S3. El controlador Spark se está quedando sin memoria. Los datos de Amazon S3 de entrada tienen más de un millón de archivos en diferentes particiones de Amazon S3.

El código con perfil es el siguiente:

```
data = spark.read.format("json").option("inferSchema", False).load("s3://input_path")
data.write.format("parquet").save(output_path)
```

Visualizar las métricas con perfil en la consola de AWS Glue

En el siguiente gráfico se muestra el uso de la memoria como porcentaje del controlador y los ejecutores. Este uso se traza como un punto de datos que se promedia a lo largo de los valores notificados en el último minuto. En el perfil de la memoria del trabajo, puede ver que la memoria del controlador cruza el umbral seguro del 50 % de uso con rapidez. Por otra parte, el uso medio de la memoria en todos los ejecutores sigue siendo inferior al 4 %. Esto es una clara muestra de irregularidad en la ejecución del controlador en el trabajo de Spark.

La ejecución del trabajo produce un error enseguida y aparece el siguiente error en la pestaña History (Historial) de la consola de AWS Glue: Command Failed with Exit Code 1. Esta cadena de error significa que el trabajo falló debido a un error sistémico, que en este caso se trata de la falta de memoria del controlador.

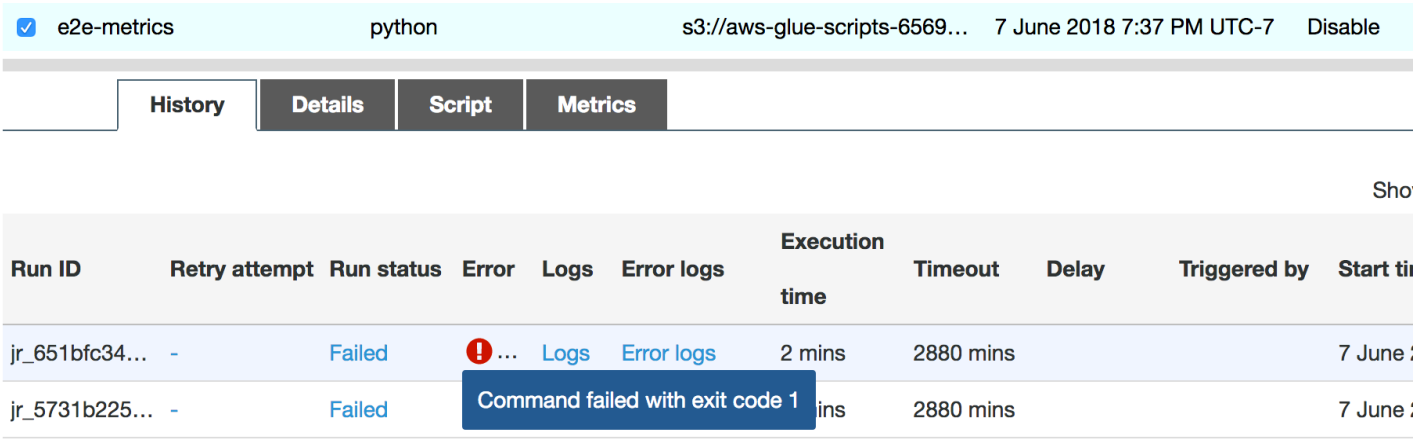

En la consola, elija el enlace Error logs (Registros de error) en la pestaña History (Historial) para confirmar el hallazgo relativo a la falta de memoria del controlador desde CloudWatch Logs. Busque "**`Error`**" en los registros de errores del trabajo para confirmar que se trató, sin duda, de una excepción de memoria insuficiente que imposibilitó la realización del trabajo:

```
# java.lang.OutOfMemoryError: Java heap space
```

```
# -XX:OnOutOfMemoryError="kill -9 %p"
# Executing /bin/sh -c "kill -9 12039"...
```

En la pestaña History (Historial) del trabajo, elija Logs (Registros). Puede encontrar el siguiente rastro de la ejecución del controlador en CloudWatch Logs al empezar el trabajo. El controlador Spark intenta listar todos los archivos en todos los directorios, crea `InMemoryFileIndex` y lanza una tarea por archivo. Esto, a su vez, hace que el controlador Spark tenga que mantener una gran cantidad de estado en memoria para realizar un seguimiento de todas las tareas. Almacena en caché la lista completa de un gran número de archivos para el índice en memoria, lo que da lugar a la falta de memoria de un controlador.

Corregir el procesamiento de varios archivos mediante su agrupación

Puede corregir el procesamiento de los numerosos archivos mediante la capacitación de agrupación en AWS Glue. La agrupación se habilita automáticamente al usar marcos dinámicos y cuando el conjunto de datos de entrada tiene un gran número de archivos (más de 50 000). La agrupación le permite fusionar varios archivos en un grupo y deja que una tarea procese todo el grupo en vez de un solo archivo. Como resultado, la cantidad de estado en memoria que almacena el controlador Spark es considerablemente más baja para realizar un seguimiento de menos tareas. Para obtener más información acerca de cómo habilitar manualmente la agrupación de su conjunto de datos, consulte Lectura de archivos de entrada en grupos más grandes.

Para comprobar el perfil de la memoria del trabajo de AWS Glue, genere perfiles en el siguiente código con la agrupación habilitada:

```
df = glueContext.create_dynamic_frame_from_options("s3", {'paths': ["s3://input_path"],
 "recurse":True, 'groupFiles': 'inPartition'}, format="json")
datasink = glueContext.write_dynamic_frame.from_options(frame = df, connection_type
 = "s3", connection_options = {"path": output_path}, format = "parquet",
 transformation_ctx = "datasink")
```

Puede monitorear el perfil de la memoria y el movimiento de datos de ETL en el perfil de trabajo de AWS Glue.

El controlador se ejecuta por debajo del umbral del 50 % de uso de la memoria durante todo el trabajo de AWS Glue. Los ejecutores transmiten los datos desde Amazon S3, los procesan y los escriben en Amazon S3. Como resultado, consumen un porcentaje de memoria inferior al 5 % en cualquier momento.

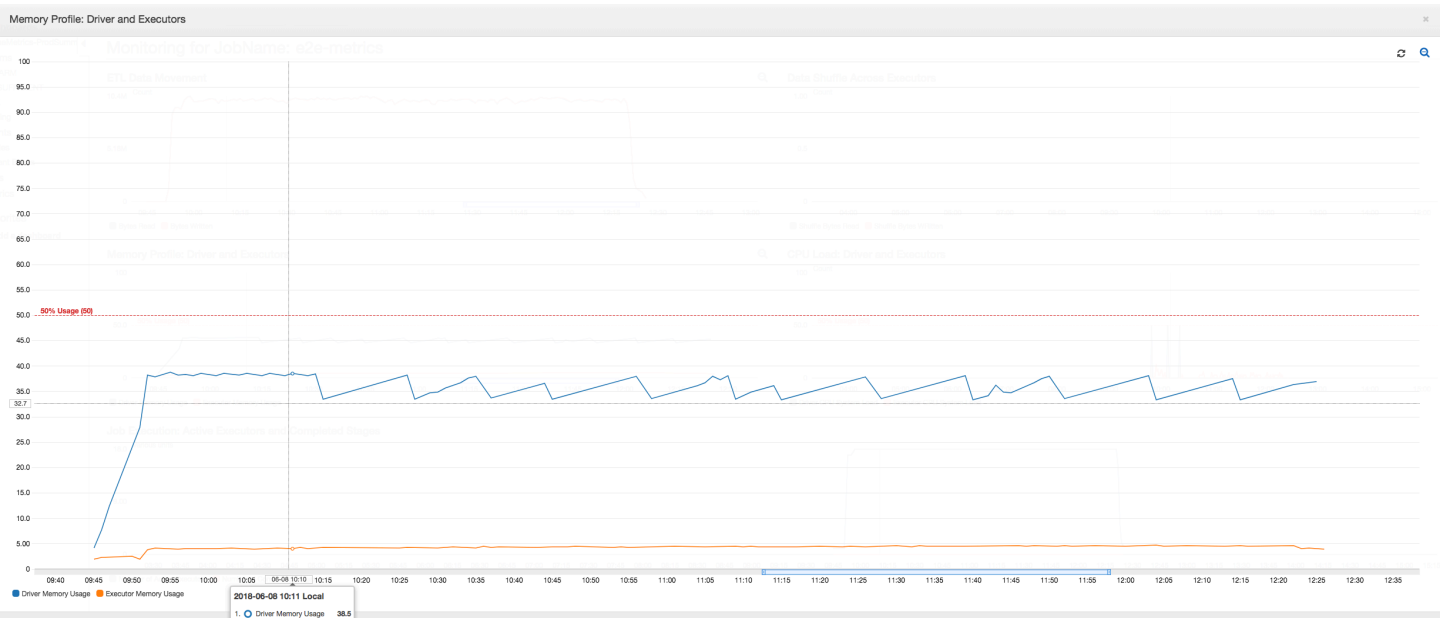

El perfil de movimiento de datos a continuación muestra el número total de bytes de Amazon S3 que todos los ejecutores leen y escriben en el último minuto a medida que progresa el trabajo. Ambos siguen un patrón similar, puesto que todos los ejecutores transmiten los datos. El trabajo termina de procesar el millón de archivos en menos de tres horas.

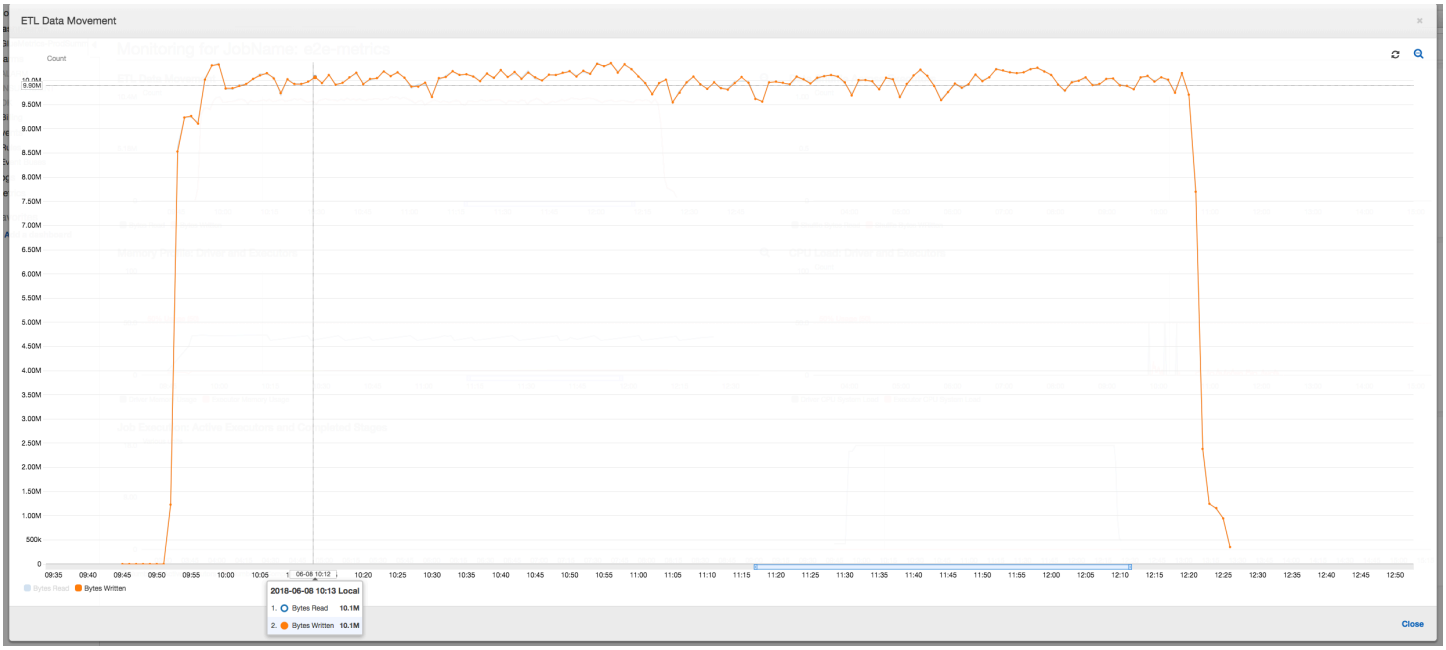

Depuración de una excepción de memoria insuficiente del ejecutor

En esta situación, puede aprender a depurar excepciones de memoria insuficiente que podrían producirse en los ejecutores Apache Spark. El siguiente código usa el lector de Spark MySQL para leer una gran tabla de unos 34 millones de filas en un DataFrame de Spark. A continuación, la

escribe en Amazon S3 en formato Parquet. Puede proporcionar las propiedades de la conexión y usar las configuraciones de Spark predeterminadas para leer la tabla.

```
val connectionProperties = new Properties()
connectionProperties.put("user", user)
connectionProperties.put("password", password)
connectionProperties.put("Driver", "com.mysql.jdbc.Driver")
val sparkSession = glueContext.sparkSession
val dfSpark = sparkSession.read.jdbc(url, tableName, connectionProperties)
dfSpark.write.format("parquet").save(output_path)
```

Visualizar las métricas con perfil en la consola de AWS Glue

Si la pendiente del gráfico de uso de memoria es positiva y supera el 50 por ciento, si se produce un error en el trabajo antes de que se emita la siguiente métrica, la causa bien se puede deber al agotamiento de memoria. En el siguiente gráfico se muestra que, transcurrido un minuto desde el inicio de la ejecución, el uso medio de la memoria en todos los ejecutores aumenta rápidamente por encima del 50 %. El uso llega a alcanzar el 92 % y Apache Hadoop YARN cancela el contenedor que ejecuta el ejecutor.

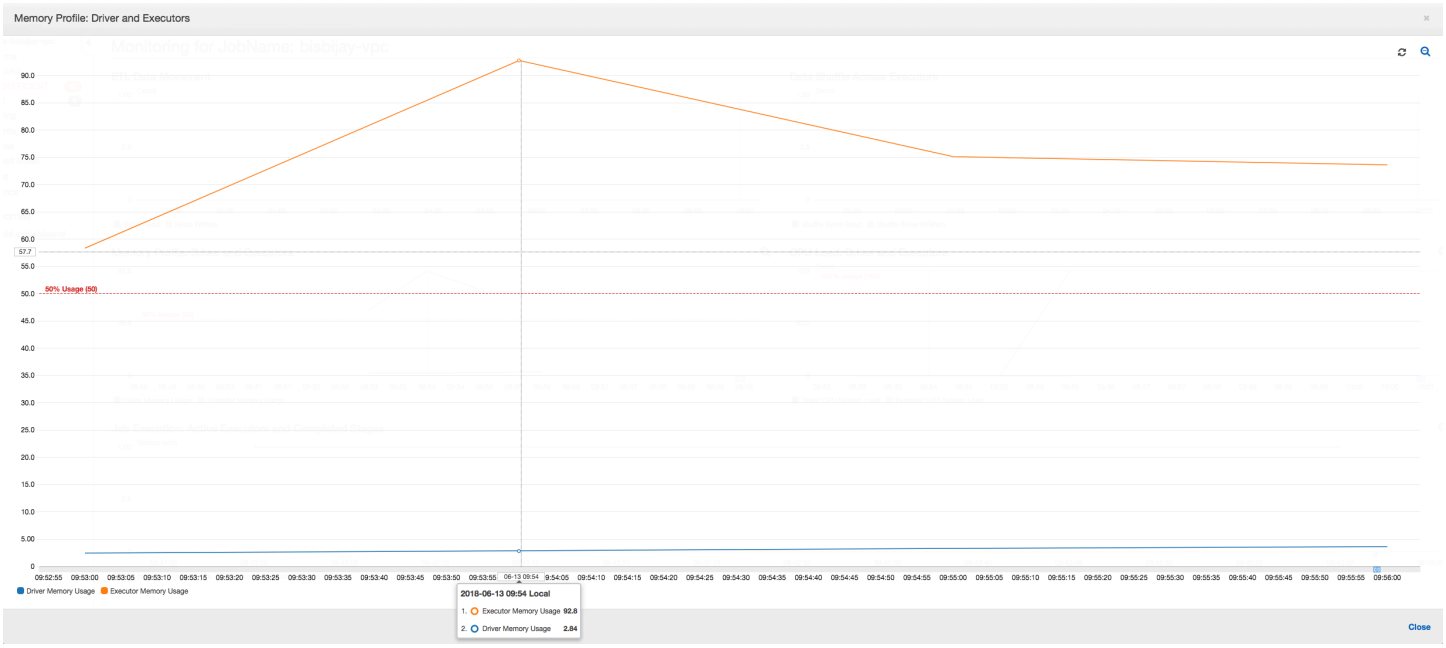

Tal como aparece en el siguiente gráfico, siempre hay un único ejecutor en ejecución hasta que el trabajo produce un error. Esto se debe al lanzamiento de un nuevo ejecutor para reemplazar el ejecutor cancelado. Las lecturas del origen de datos JDBC no se paralelizan de forma

predeterminada, ya que requeriría que se particionara la tabla en una columna y que se abrieran varias conexiones. Como resultado, solo un ejecutor lee la tabla completa de forma secuencial.

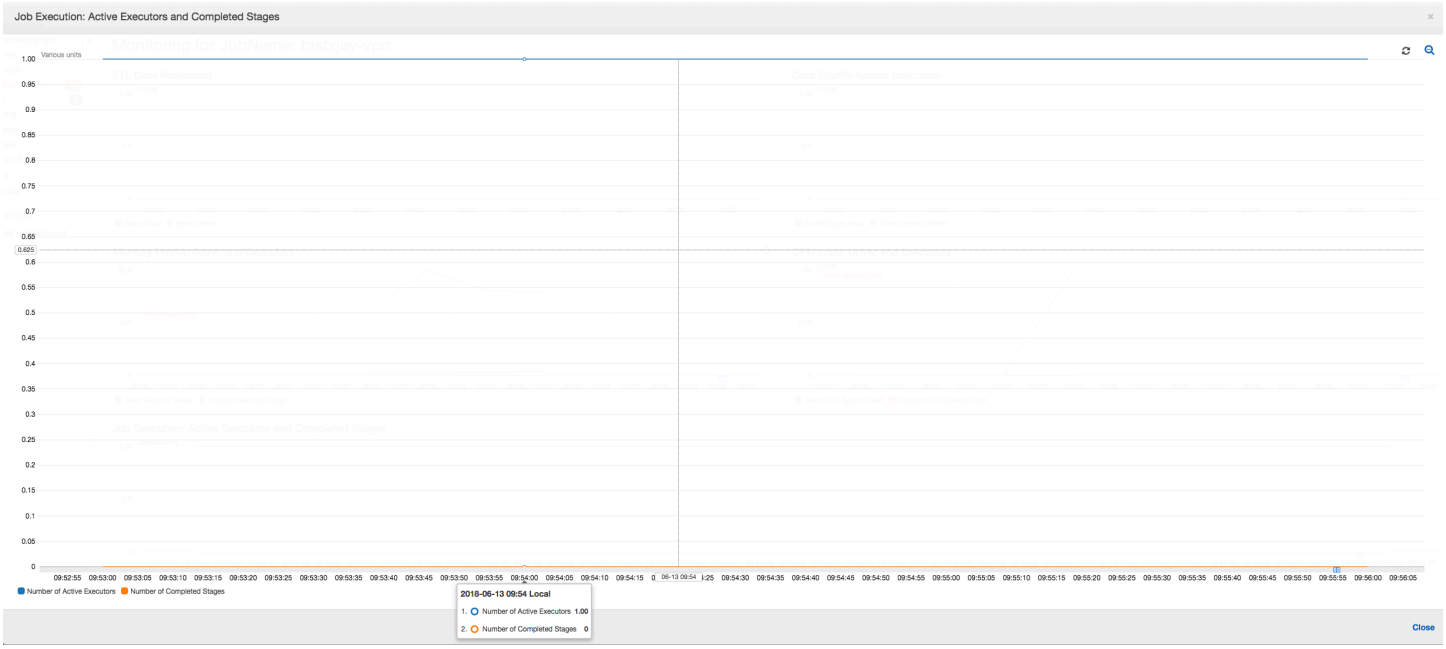

Tal como se muestra en el siguiente gráfico, Spark intenta lanzar una nueva tarea cuatro veces antes de producir el trabajo el error. Puede ver el perfil de la memoria de tres ejecutores. Cada ejecutor usa rápidamente toda su memoria. El cuarto ejecutor se queda sin memoria y el trabajo produce un error. Como resultado, su métrica no se notifica inmediatamente.

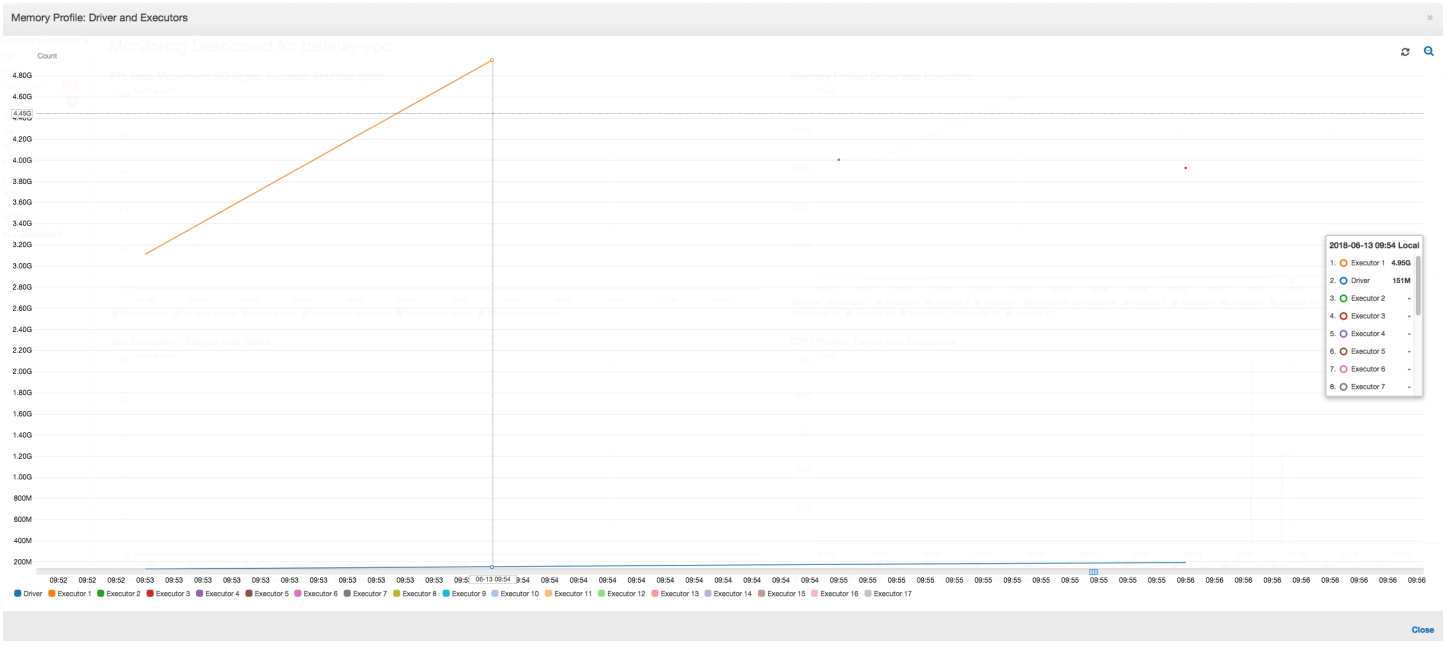

Puede confirmar desde la cadena de error de la consola de AWS Glue que el trabajo produjo un error debido a excepciones de memoria insuficiente, como se muestra en la siguiente imagen.

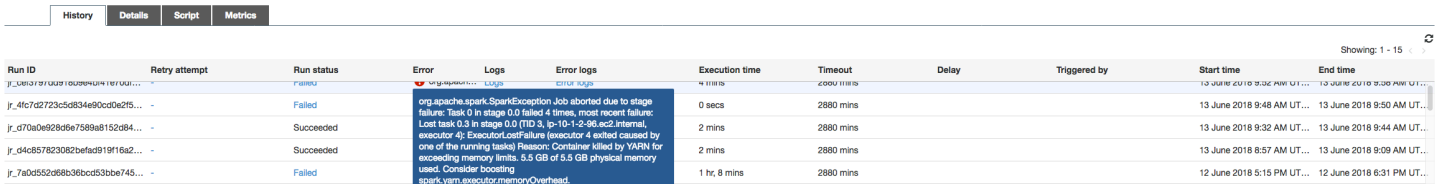

Registros de salida del trabajo: para confirmar aún más su hallazgo de una excepción de memoria insuficiente, examine CloudWatch Logs. Al buscar **`Error`**, verá cómo se cancelan los cuatro ejecutores casi al mismo tiempo como se muestra en el panel de métricas. YARN termina todos, ya que superan sus límites de memoria.

Ejecutor 1

```
18/06/13 16:54:29 WARN YarnAllocator: Container killed by YARN for exceeding
 memory limits. 5.5 GB of 5.5 GB physical memory used. Consider boosting
 spark.yarn.executor.memoryOverhead.
18/06/13 16:54:29 WARN YarnSchedulerBackend$YarnSchedulerEndpoint: Container killed
 by YARN for exceeding memory limits. 5.5 GB of 5.5 GB physical memory used. Consider
 boosting spark.yarn.executor.memoryOverhead.
18/06/13 16:54:29 ERROR YarnClusterScheduler: Lost executor 1 on
 ip-10-1-2-175.ec2.internal: Container killed by YARN for exceeding
 memory limits. 5.5 GB of 5.5 GB physical memory used. Consider boosting
 spark.yarn.executor.memoryOverhead.
18/06/13 16:54:29 WARN TaskSetManager: Lost task 0.0 in stage 0.0 (TID 0,
 ip-10-1-2-175.ec2.internal, executor 1): ExecutorLostFailure (executor 1
 exited caused by one of the running tasks) Reason: Container killed by YARN for
 exceeding memory limits. 5.5 GB of 5.5 GB physical memory used. Consider boosting
 spark.yarn.executor.memoryOverhead.
```

Ejecutor 2

```
18/06/13 16:55:35 WARN YarnAllocator: Container killed by YARN for exceeding
 memory limits. 5.8 GB of 5.5 GB physical memory used. Consider boosting
 spark.yarn.executor.memoryOverhead.
18/06/13 16:55:35 WARN YarnSchedulerBackend$YarnSchedulerEndpoint: Container killed
 by YARN for exceeding memory limits. 5.8 GB of 5.5 GB physical memory used. Consider
 boosting spark.yarn.executor.memoryOverhead.
18/06/13 16:55:35 ERROR YarnClusterScheduler: Lost executor 2 on
 ip-10-1-2-16.ec2.internal: Container killed by YARN for exceeding
 memory limits. 5.8 GB of 5.5 GB physical memory used. Consider boosting
 spark.yarn.executor.memoryOverhead.
18/06/13 16:55:35 WARN TaskSetManager: Lost task 0.1 in stage 0.0 (TID 1,
 ip-10-1-2-16.ec2.internal, executor 2): ExecutorLostFailure (executor 2 exited
```

```
 caused by one of the running tasks) Reason: Container killed by YARN for
 exceeding memory limits. 5.8 GB of 5.5 GB physical memory used. Consider boosting
 spark.yarn.executor.memoryOverhead.
```

Ejecutor 3

```
18/06/13 16:56:37 WARN YarnAllocator: Container killed by YARN for exceeding
 memory limits. 5.8 GB of 5.5 GB physical memory used. Consider boosting
 spark.yarn.executor.memoryOverhead.
18/06/13 16:56:37 WARN YarnSchedulerBackend$YarnSchedulerEndpoint: Container killed
 by YARN for exceeding memory limits. 5.8 GB of 5.5 GB physical memory used. Consider
 boosting spark.yarn.executor.memoryOverhead.
18/06/13 16:56:37 ERROR YarnClusterScheduler: Lost executor 3 on
 ip-10-1-2-189.ec2.internal: Container killed by YARN for exceeding
 memory limits. 5.8 GB of 5.5 GB physical memory used. Consider boosting
 spark.yarn.executor.memoryOverhead.
18/06/13 16:56:37 WARN TaskSetManager: Lost task 0.2 in stage 0.0 (TID 2,
 ip-10-1-2-189.ec2.internal, executor 3): ExecutorLostFailure (executor 3
 exited caused by one of the running tasks) Reason: Container killed by YARN for
 exceeding memory limits. 5.8 GB of 5.5 GB physical memory used. Consider boosting
 spark.yarn.executor.memoryOverhead.
```

Ejecutor 4

```
18/06/13 16:57:18 WARN YarnAllocator: Container killed by YARN for exceeding
 memory limits. 5.5 GB of 5.5 GB physical memory used. Consider boosting
 spark.yarn.executor.memoryOverhead.
18/06/13 16:57:18 WARN YarnSchedulerBackend$YarnSchedulerEndpoint: Container killed
 by YARN for exceeding memory limits. 5.5 GB of 5.5 GB physical memory used. Consider
 boosting spark.yarn.executor.memoryOverhead.
18/06/13 16:57:18 ERROR YarnClusterScheduler: Lost executor 4 on
 ip-10-1-2-96.ec2.internal: Container killed by YARN for exceeding
 memory limits. 5.5 GB of 5.5 GB physical memory used. Consider boosting
 spark.yarn.executor.memoryOverhead.
18/06/13 16:57:18 WARN TaskSetManager: Lost task 0.3 in stage 0.0 (TID 3,
 ip-10-1-2-96.ec2.internal, executor 4): ExecutorLostFailure (executor 4 exited
 caused by one of the running tasks) Reason: Container killed by YARN for
 exceeding memory limits. 5.5 GB of 5.5 GB physical memory used. Consider boosting
 spark.yarn.executor.memoryOverhead.
```

Corregir la configuración del tamaño de búsqueda mediante marcos dinámicos de AWS Glue

El ejecutor se quedó sin memoria durante la lectura de la tabla de JDBC, ya que la configuración predeterminada del tamaño de búsqueda de JDBC de Spark es cero. Esto significa que el controlador JDBC del ejecutor de Spark intenta recuperar los 34 millones de filas de la base de datos de forma conjunta y almacenarlas en caché, aunque Spark se transmita a través de las filas de una en una. Con Spark, puede evitar esta situación estableciendo el parámetro de tamaño de búsqueda en un valor predeterminado distinto de cero.

También puede solucionar este problema con marcos dinámicos de AWS Glue en su lugar. De forma predeterminada, los marcos dinámicos utilizan un tamaño de captura de 1000 filas, que suele ser un valor suficiente. Como resultado, el ejecutor no usa más del 7 % de su memoria total. El trabajo de AWS Glue finaliza en menos de dos minutos con un único ejecutor solamente. Aunque el enfoque recomendado es utilizar los marcos dinámicos de AWS Glue, también se puede definir el tamaño de captura con la propiedad `fetchsize` de Apache Spark. Consulte la guía de Spark SQL, DataFrames y Datasets.

```
val (url, database, tableName) = {
 ("jdbc_url", "db_name", "table_name")
 }
val source = glueContext.getSource(format, sourceJson)
val df = source.getDynamicFrame
glueContext.write_dynamic_frame.from_options(frame = df, connection_type = "s3",
 connection_options = {"path": output_path}, format = "parquet", transformation_ctx =
 "datasink")
```

Métricas con perfil normales: la memoria del ejecutor con marcos dinámicos de AWS Glue nunca supera el umbral seguro, como se muestra en la siguiente imagen. Se transmite en las filas de la base de datos y almacena en caché solo 1000 filas en el controlador JDBC en cualquier momento. No se producen excepciones de memoria insuficiente.

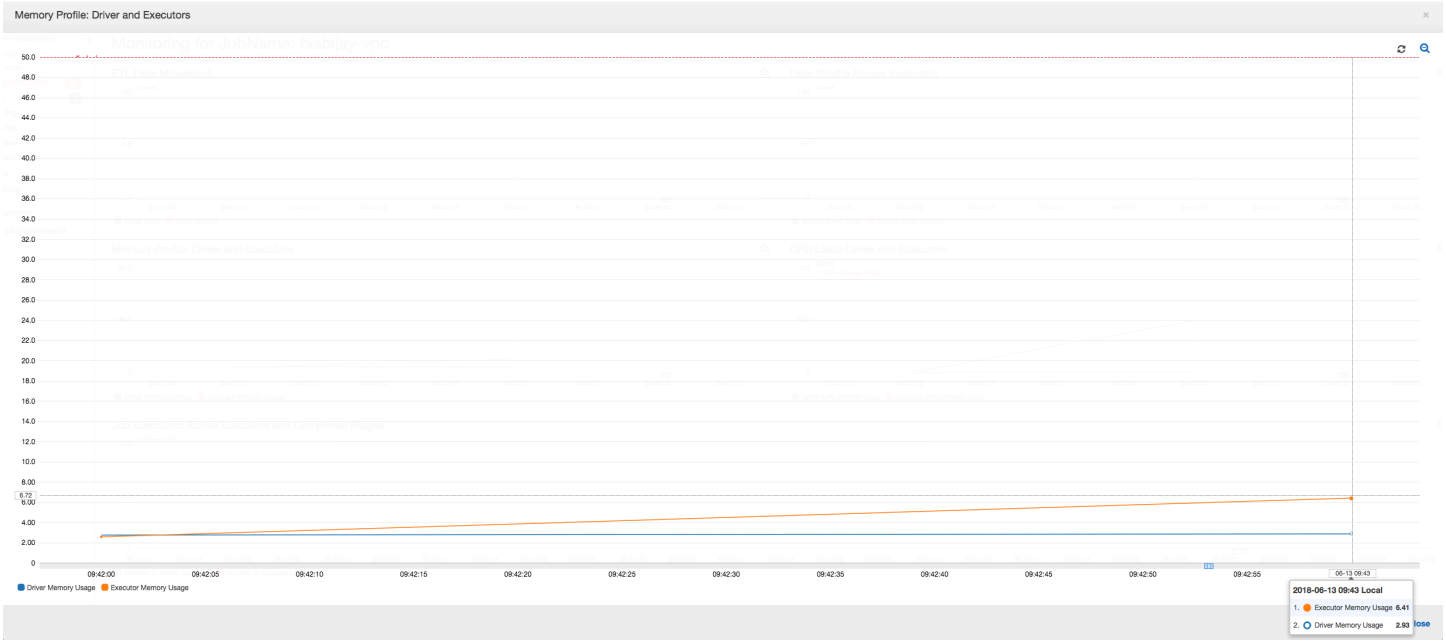

Depuración de etapas exigentes y tareas rezagadas

Puede usar perfiles de trabajo de AWS Glue para identificar etapas exigentes y tareas rezagadas en sus trabajos de extracción, transformación y carga (ETL). Una tarea rezagada tarda mucho más que las demás tareas en una etapa de un trabajo de AWS Glue. Como resultado, la etapa tarda más en completarse, lo que también retrasa el tiempo de ejecución total del trabajo.

Fusión de archivos de entrada pequeños en archivos de salida más grandes

Una tarea rezagada puede producirse si hay una distribución no uniforme de trabajo entre las diferentes tareas, o un sesgo de datos da lugar a un mayor procesamiento de datos por parte de una tarea.

Puede generar perfiles en el siguiente código, un patrón común en Apache Spark, para fusionar un gran número de archivos pequeños en archivos de salida más grandes. En este ejemplo, el conjunto de datos de entrada tiene 32 GB de archivos comprimidos Gzip JSON. El conjunto de datos de salida tiene casi 190 GB de archivos JSON sin comprimir.

El código con perfil es el siguiente:

```
datasource0 = spark.read.format("json").load("s3://input_path")
df = datasource0.coalesce(1)
df.write.format("json").save(output_path)
```

Visualizar las métricas con perfil en la consola de AWS Glue

Puede generar perfiles en su trabajo para examinar cuatro conjuntos de métricas diferentes:

- Movimiento de datos de ETL
- Mezcla de datos entre los ejecutores
- Ejecución de trabajo
- Perfil de la memoria

Movimiento de datos de ETL: en el perfil ETL Data Movement (Movimiento de datos de ETL), todos los ejecutores leen los bytes con bastante rapidez en la primera etapa que se completa en los primeros seis minutos. Sin embargo, el tiempo de ejecución del trabajo total es de aproximadamente una hora, componiéndose principalmente de las escrituras de datos.

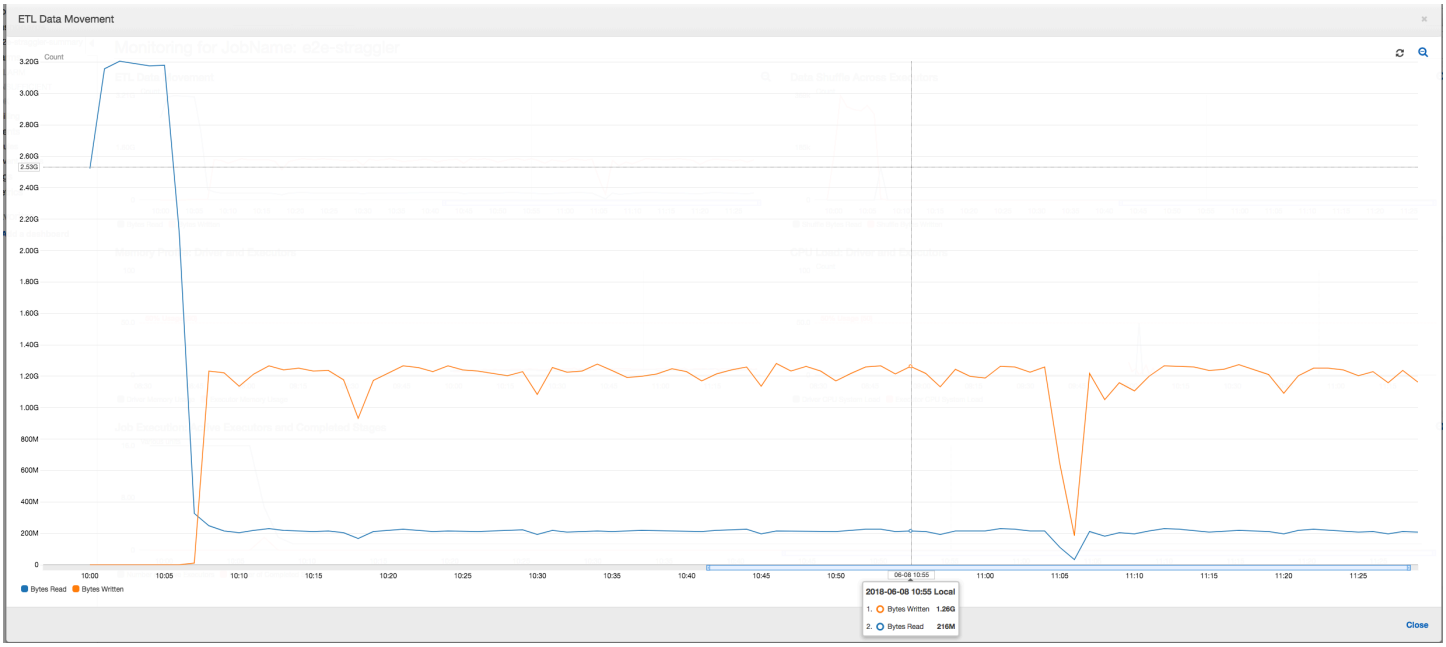

Mezcla de datos entre los ejecutores: el número de bytes leídos y escritos durante la mezcla también muestra un pico antes de finalizar la segunda etapa, como indican las métricas Job Execution (Ejecución de trabajo) y Data Shuffle (Mezcla de datos). Una vez que se mezclan los datos de todos los ejecutores, las lecturas y escrituras siguen solo a partir del tercer ejecutor.

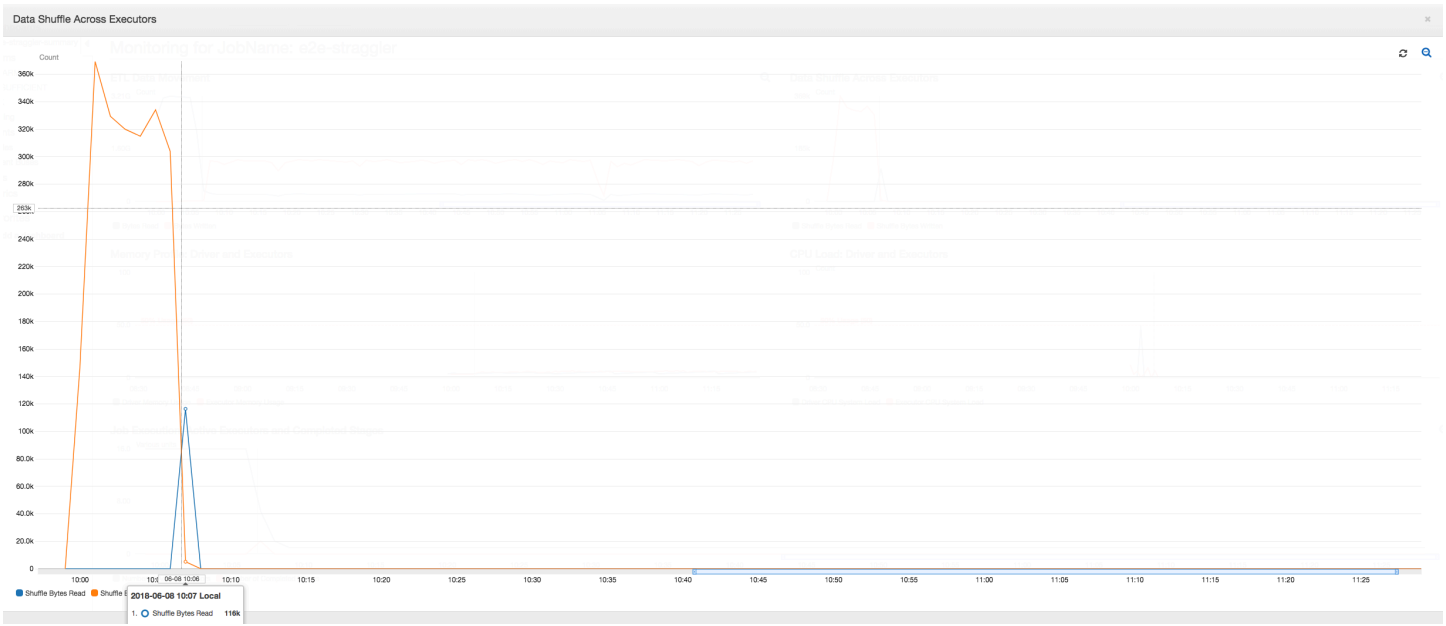

Ejecución de trabajo: tal como se muestra en el gráfico a continuación, todos los demás ejecutores están inactivos y finalmente se renuncia a ellos por el tiempo 10:09. En este momento, el número total de ejecutores disminuye a solo uno. Esto muestra claramente que el tercer ejecutor se compone de la tarea rezagada que más tiempo de ejecución emplea y que contribuye a la mayor parte del tiempo de ejecución del trabajo.

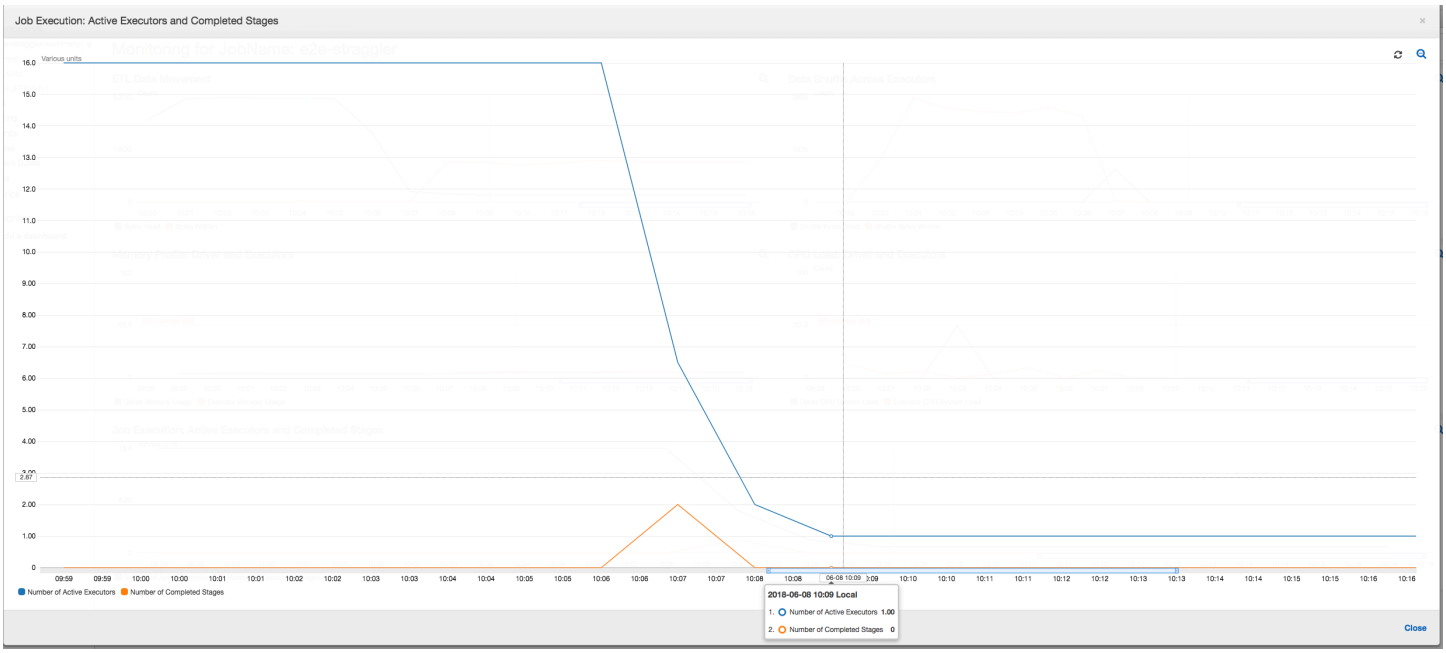

Perfil de la memoria: después de las primeras dos etapas, solo el tercer ejecutor consume memoria de forma activa para procesar los datos. Los demás ejecutores están simplemente inactivos o se ha renunciado a ellos poco después de completarse las primeras dos etapas.

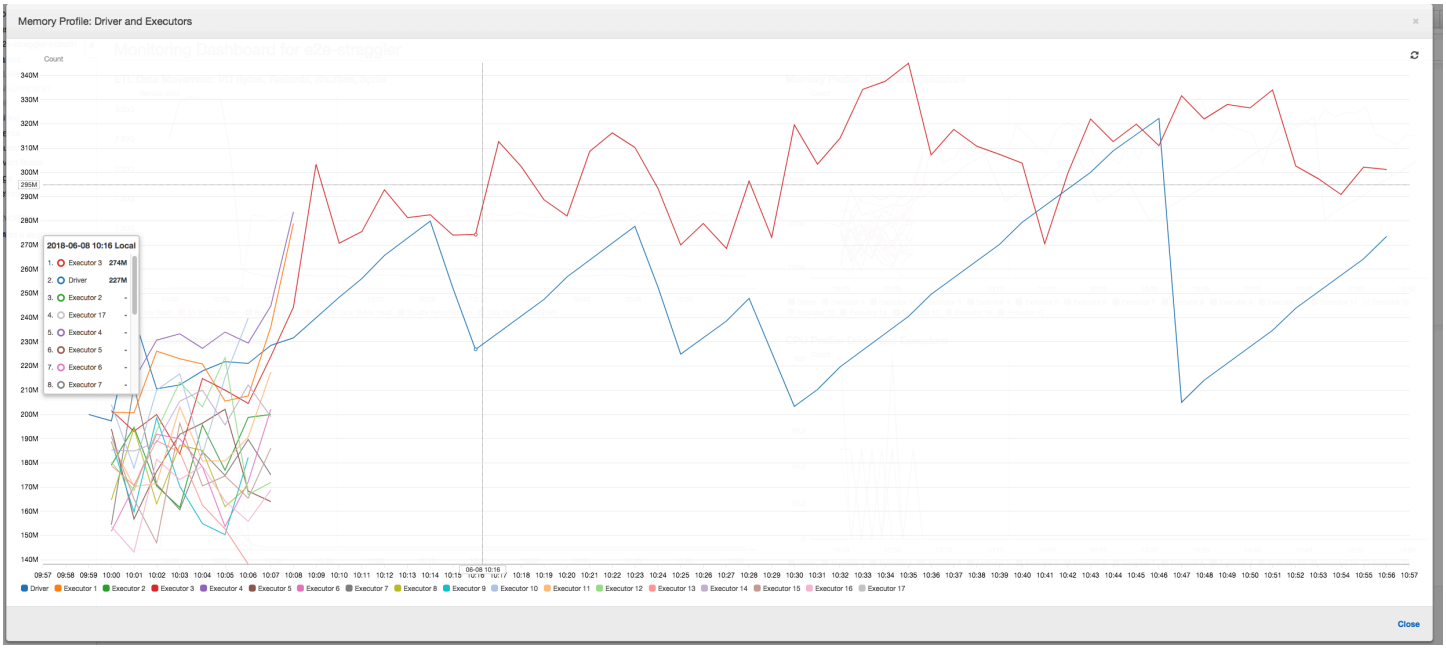

Corregir ejecutores rezagados mediante agrupación

Puede evitar los ejecutores rezagados mediante la capacitación de agrupación en AWS Glue. Utilice la agrupación para distribuir los datos de manera uniforme entre todos los ejecutores y fusionar archivos en archivos más grandes mediante el uso de todos los ejecutores disponibles en el clúster. Para obtener más información, consulte Lectura de archivos de entrada en grupos más grandes.

Para comprobar los movimientos de datos de ETL en el trabajo de AWS Glue, genere perfiles en el siguiente código con la agrupación habilitada:

```
df = glueContext.create_dynamic_frame_from_options("s3", {'paths': ["s3://input_path"],
 "recurse":True, 'groupFiles': 'inPartition'}, format="json")
datasink = glueContext.write_dynamic_frame.from_options(frame = df, connection_type =
 "s3", connection_options = {"path": output_path}, format = "json", transformation_ctx
 = "datasink4")
```

Movimiento de datos de ETL: las escrituras de datos ahora se transmiten en paralelo con las lecturas de datos a lo largo del tiempo de ejecución del trabajo. Como resultado, el trabajo finaliza en ocho minutos, mucho más rápido que antes.

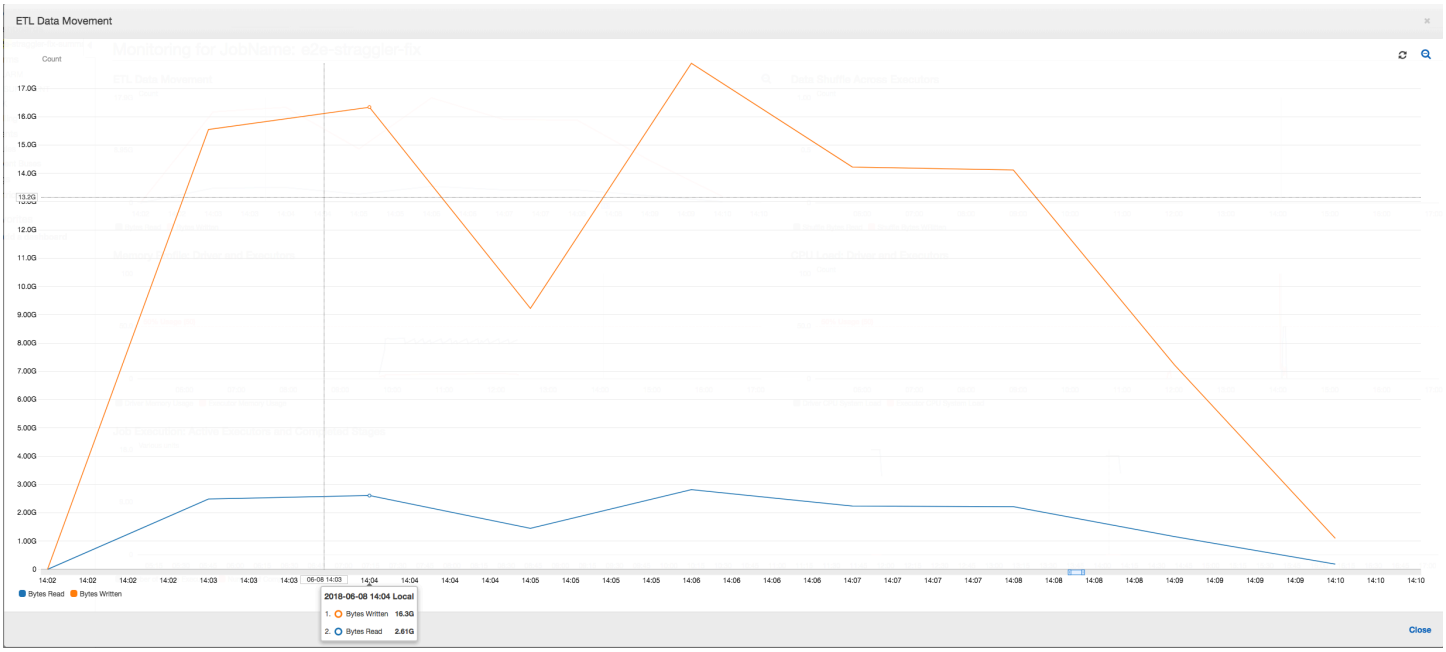

Mezcla de datos entre los ejecutores: como los archivos de entrada se fusionan durante las lecturas mediante la capacitación de agrupación, no hay ninguna mezcla de datos costosa después de las lecturas de datos.

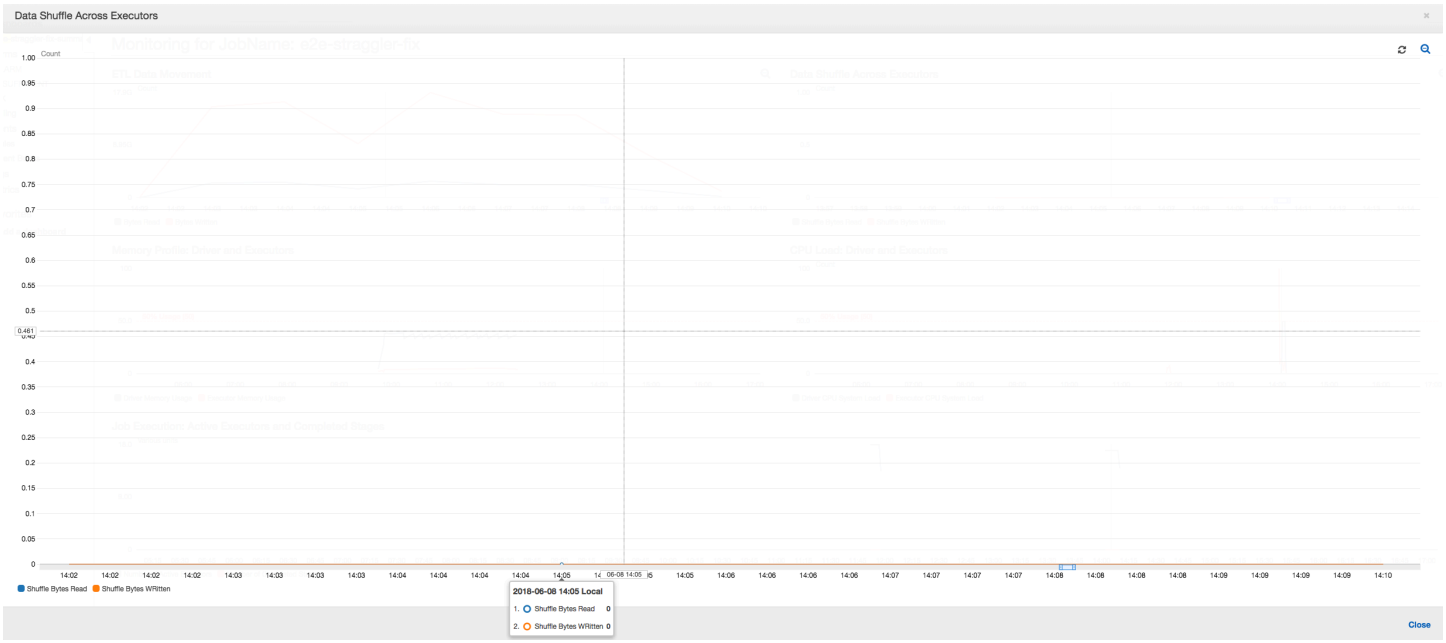

Ejecución de trabajo: las métricas de ejecución de trabajo muestran que el número total de ejecutores activos que ejecutan y procesan datos permanecen bastante constantes. No hay ningún rezagado en el trabajo. Todos los ejecutores están activos y no se renuncia a ellos hasta completarse el trabajo. Como no hay mezcla de datos intermedia alguna entre los ejecutores, solo hay una única etapa en el trabajo.

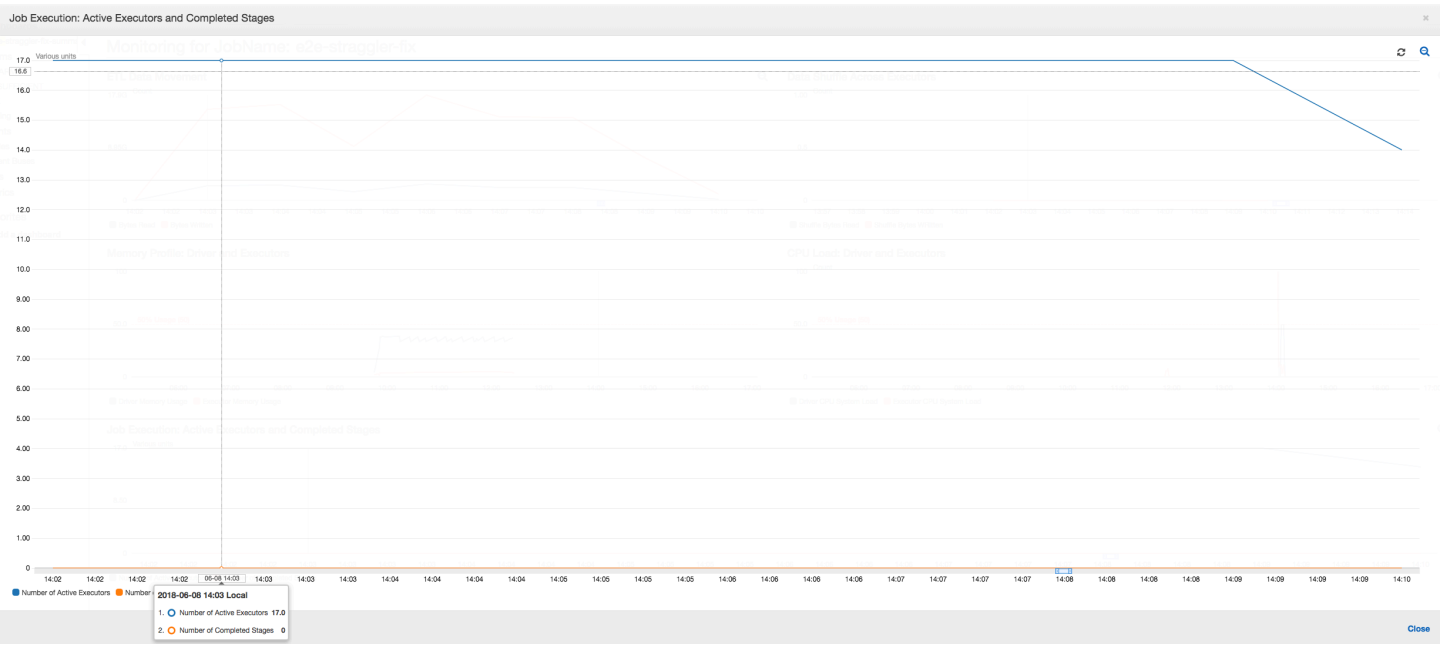

Perfil de memoria: las métricas muestran el consumo de memoria activa entre todos los ejecutores, lo que confirma una vez más que hay actividad en todos los ejecutores. Como los datos se reciben y escriben en paralelo, la huella de memoria total de todos los ejecutores es más o menos uniforme y está muy por debajo del umbral seguro de todos los ejecutores.

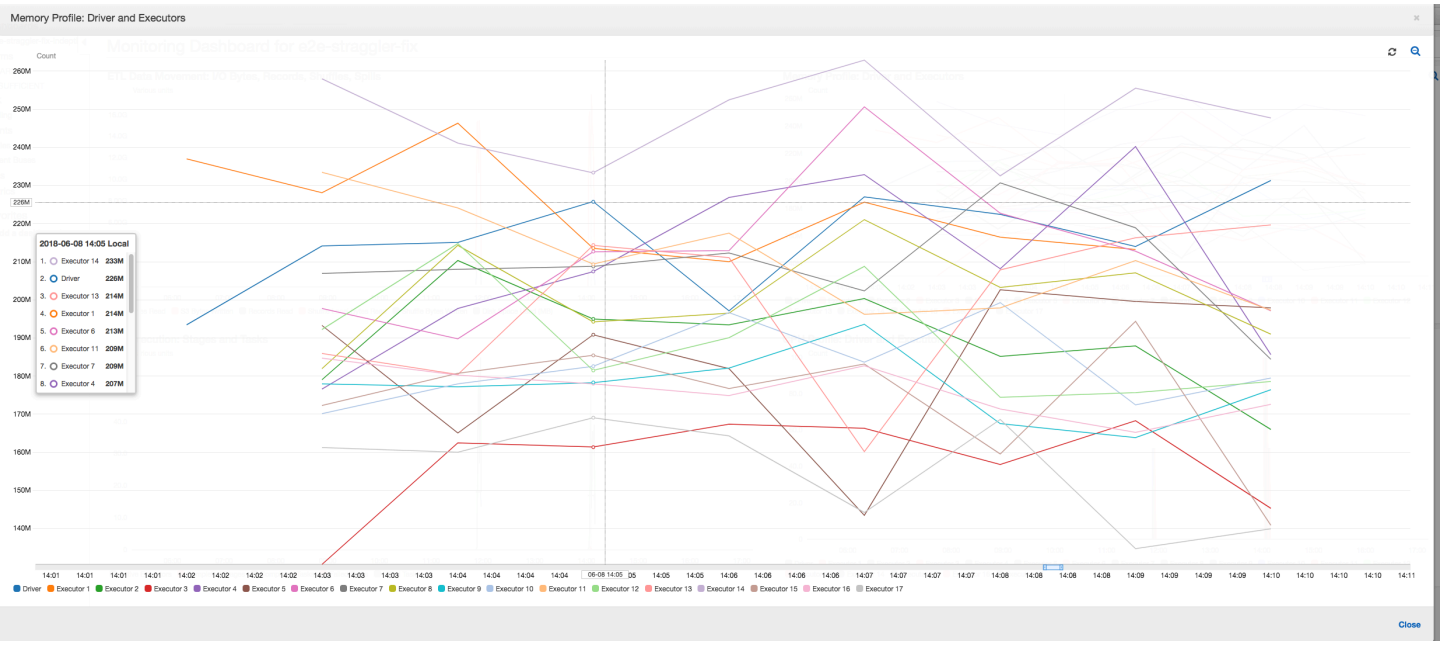

Monitoreo del progreso de varios trabajos

Puede generar perfiles en varios trabajos de AWS Glue de forma conjunta y monitorear el flujo de datos entre ellos. Se trata de un patrón de flujo de trabajo habitual y requiere el monitoreo

del progreso de trabajos individuales, las tareas pendientes de procesamiento de datos, el reprocesamiento de datos y los marcadores de trabajos.

Temas

- Código con perfil
- Visualizar las métricas con perfil en la consola de AWS Glue
- Corregir el procesamiento de los archivos

Código con perfil

En este flujo de trabajo, tiene dos trabajos: un trabajo de entrada y un trabajo de salida. El trabajo de entrada está programado para ejecutarse cada 30 minutos mediante un disparador periódico. El trabajo de salida está programado para ejecutarse tras cada ejecución correcta del trabajo de entrada. Estos trabajos programados se controlan mediante disparadores del trabajo.

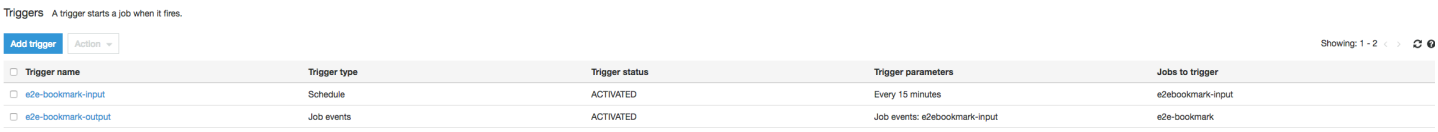

Trabajo de entrada: este trabajo lee datos desde una ubicación de Amazon Simple Storage Service (Amazon S3), los transforma mediante `ApplyMapping` y los escribe en una ubicación de Amazon S3 provisional. El siguiente código es código con perfil para el trabajo de entrada:

```
datasource0 = glueContext.create_dynamic_frame.from_options(connection_type="s3",
 connection_options = {"paths": ["s3://input_path"],
 "useS3ListImplementation":True,"recurse":True}, format="json")
applymapping1 = ApplyMapping.apply(frame = datasource0, mappings = [map_spec])
datasink2 = glueContext.write_dynamic_frame.from_options(frame = applymapping1,
 connection_type = "s3", connection_options = {"path": staging_path, "compression":
 "gzip"}, format = "json")
```

Trabajo de salida: este trabajo lee la salida del trabajo de entrada desde la ubicación provisional en Amazon S3, la vuelve a transformar y la escribe en un destino:

```
datasource0 = glueContext.create_dynamic_frame.from_options(connection_type="s3",
 connection_options = {"paths": [staging_path],
 "useS3ListImplementation":True,"recurse":True}, format="json")
applymapping1 = ApplyMapping.apply(frame = datasource0, mappings = [map_spec])
```

```
datasink2 = glueContext.write_dynamic_frame.from_options(frame = applymapping1,
 connection_type = "s3", connection_options = {"path": output_path}, format = "json")
```

Visualizar las métricas con perfil en la consola de AWS Glue

El siguiente panel superpone la métrica escrita de bytes de Amazon S3 desde el trabajo de entrada en la métrica leída de bytes de Amazon S3 en la misma escala de tiempo del trabajo de salida. La escala de tiempo muestra diferentes ejecuciones de trabajo de los trabajos de entrada y salida. El trabajo de entrada (mostrado en rojo) comienza cada 30 minutos. El trabajo de salida (mostrado en marrón) comienza al finalizar el trabajo de entrada, con una simultaneidad máxima de 1.

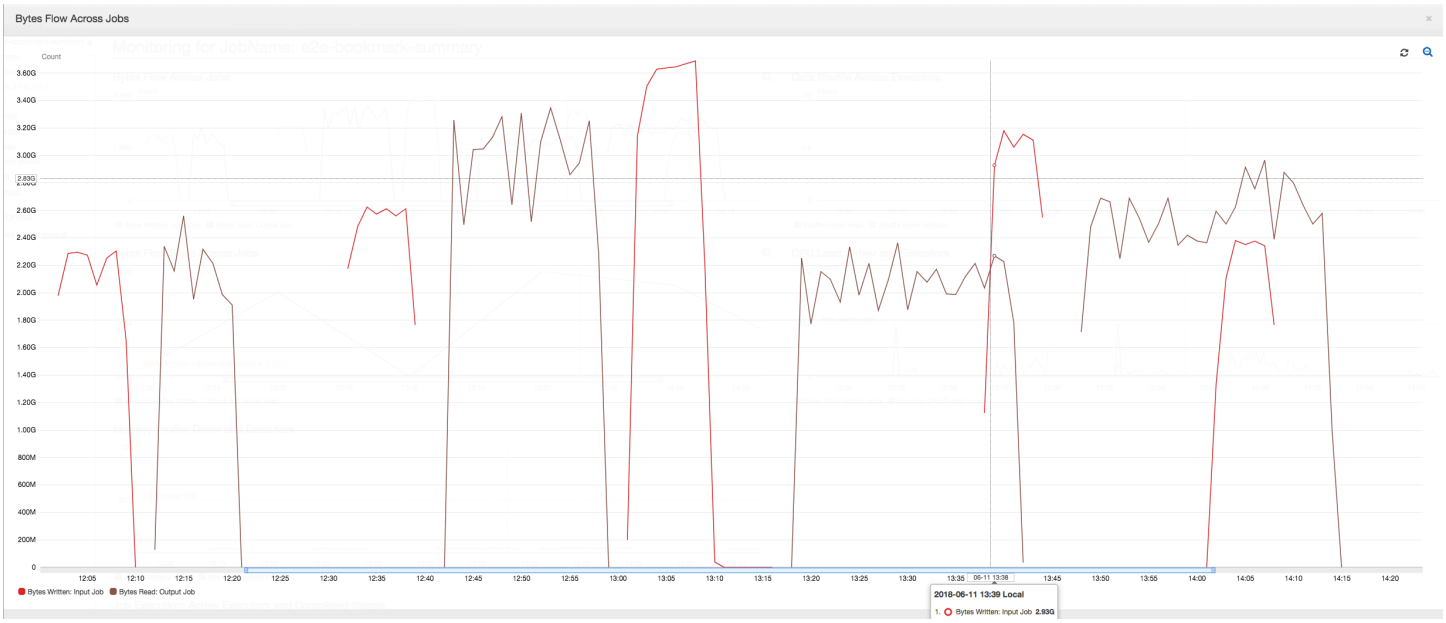

En este ejemplo, los marcadores de trabajos no están habilitados. No se usa ningún contexto de transformación para habilitar marcadores de trabajos en el código de script.

Historial de trabajos: los trabajos de entrada y salida tienen varias ejecuciones, como se muestra en la pestaña History (Historial), las cuales comienzan a partir de las 12:00 h.

El trabajo de entrada de la consola de AWS Glue tiene este aspecto:

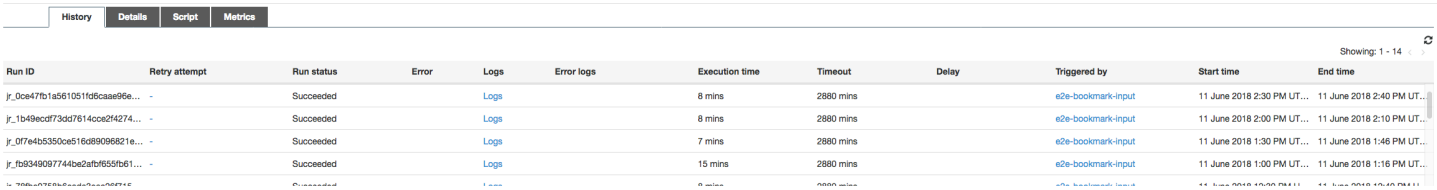

En la siguiente imagen se muestra el trabajo de salida:

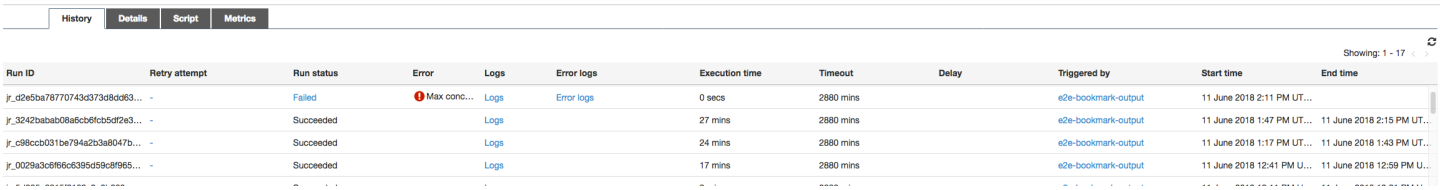

Primeras ejecuciones de trabajo: como se muestra en el siguiente gráfico de bytes de datos leídos y escritos, las primeras ejecuciones de trabajo de los trabajos de entrada y salida entre las 12:00 y las 12:30 h muestran más o menos la misma área bajo las curvas. Esas áreas representan los bytes de Amazon S3 escritos por el trabajo de entrada y los bytes de Amazon S3 leídos por el trabajo de salida. Estos datos también están confirmados por la relación de bytes de Amazon S3 escritos (suma de más de 30 minutos, la frecuencia del desencadenador de trabajo para el trabajo de entrada). El punto de datos de la relación para la ejecución de trabajo de entrada que comenzó a las 12:00 h también es 1.

En el siguiente gráfico se muestra la relación de flujo de datos entre todas las ejecuciones de trabajo:

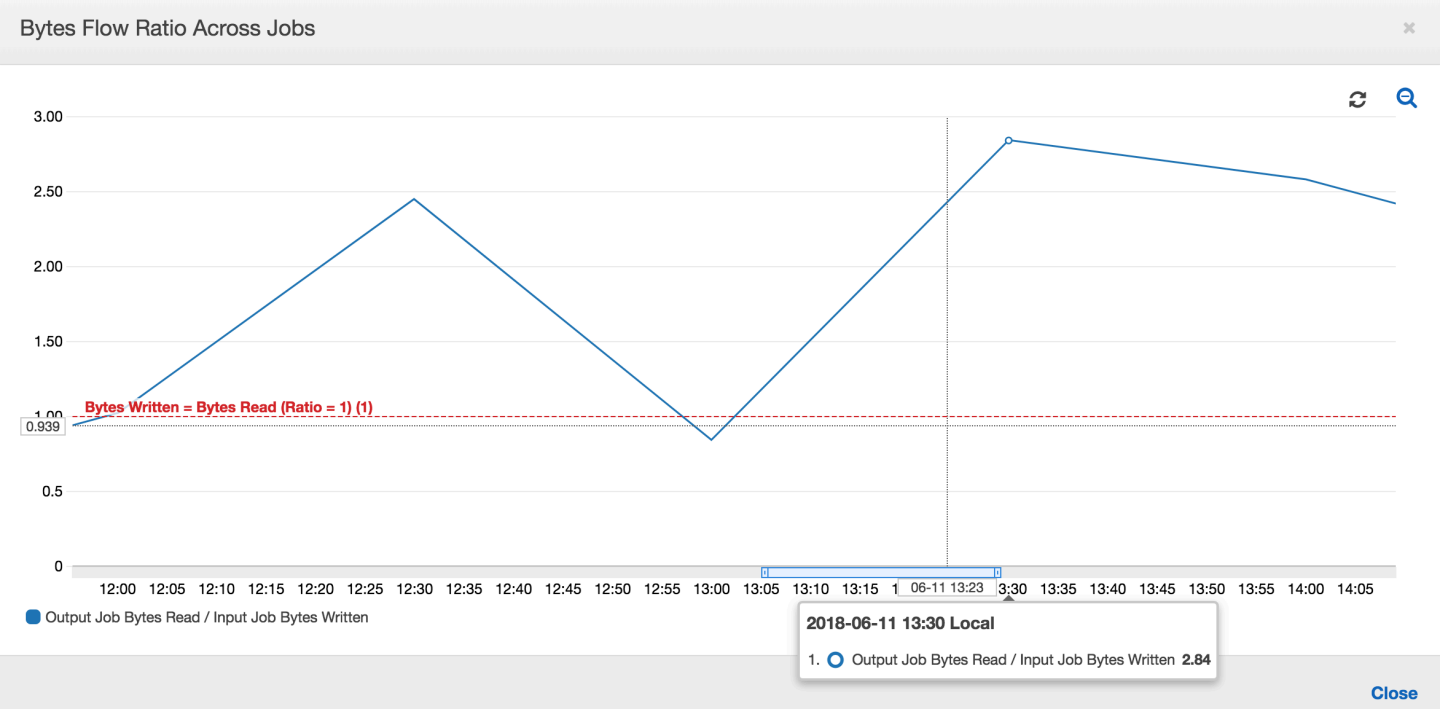

Segundas ejecuciones de trabajo: en la segunda ejecución de trabajo, existe una clara diferencia entre el número de bytes leídos por el trabajo de salida y el número de bytes escritos por el trabajo de entrada (compare el área bajo la curva entre las dos ejecuciones de trabajo para el trabajo de salida, o bien las áreas en la segunda ejecución de los trabajos de entrada y salida). La relación de los bytes leídos y escritos muestra que el trabajo de salida lee alrededor de 2,5 veces los datos escritos por el trabajo de entrada en el segundo periodo de 30 minutos de 12:30 a 13:00 h. Esto se

debe a que el trabajo de salida reprocesó la salida de la primera ejecución de trabajo del trabajo de entrada porque los marcadores de trabajos no estaban habilitados. Una relación superior a 1 muestra que hay tareas pendientes adicionales de datos que el trabajo de salida procesó.

Terceras ejecuciones de trabajo: el trabajo de entrada es bastante coherente en términos del número de bytes escritos (consulte el área bajo las curvas rojas). Sin embargo, la tercera ejecución de trabajo del trabajo de entrada se ejecutó más tiempo del que se había previsto (consulte la larga cola de la curva roja). Como resultado, la tercera ejecución de trabajo del trabajo de salida comenzó tarde. La tercera ejecución de trabajo procesó solo una fracción de los datos acumulados en la ubicación provisional durante los 30 minutos restantes entre las 13:00 y las 13:30 h. La relación del flujo de bytes muestra que solo procesó 0,83 de los datos escritos por la tercera ejecución de trabajo del trabajo de entrada (consulte la relación a las 13:00 h).

Solapamiento de los trabajos de entrada y salida: la cuarta ejecución de trabajo del trabajo de entrada comenzó a las 13:30 h según el programa, antes de finalizar la tercera ejecución de trabajo del trabajo de salida. Existe un solapamiento parcial entre estas dos ejecuciones de trabajo. Sin embargo, la tercera ejecución de trabajo del trabajo de salida captura solo los archivos que listó en la ubicación provisional de Amazon S3 cuando empezó alrededor de las 13:17 h. Esta consta de la salida de todos los datos de las primeras ejecuciones de trabajo del trabajo de entrada. La relación real a las 13:30 h es de aproximadamente 2,75. La tercera ejecución de trabajo del trabajo de salida procesó alrededor de 2,75 veces los datos escritos por la cuarta ejecución de trabajo del trabajo de entrada de 13:00 a 14:00 h.

Tal como muestran estas imágenes, el trabajo de salida reprocesa datos de la ubicación provisional de todas las ejecuciones de trabajo anteriores del trabajo de entrada. Como resultado, la cuarta ejecución de trabajo para el trabajo de salida es la más larga y se solapa con la quinta ejecución de trabajo al completo del trabajo de entrada.

Corregir el procesamiento de los archivos

Debe garantizar que el trabajo de salida procese solo los archivos que no han procesado las ejecuciones de trabajo anteriores del trabajo de salida. Para ello, habilite marcadores de trabajos y establezca el contexto de transformación en el trabajo de salida, como se indica a continuación:

```
datasource0 = glueContext.create_dynamic_frame.from_options(connection_type="s3",
 connection_options = {"paths": [staging_path],
 "useS3ListImplementation":True,"recurse":True}, format="json", transformation_ctx =
 "bookmark_ctx")
```

Con los marcadores de trabajos habilitados, el trabajo de salida no reprocesa los datos en la ubicación provisional de todas las ejecuciones de trabajo anteriores del trabajo de entrada. En la siguiente imagen donde se muestran los datos leídos y escritos, el área bajo la curva marrón es bastante coherente y similar a la de las curvas rojas.

Las relaciones de flujo de bytes también permanecen más o menos próximas a 1 al no haber datos adicionales procesados.

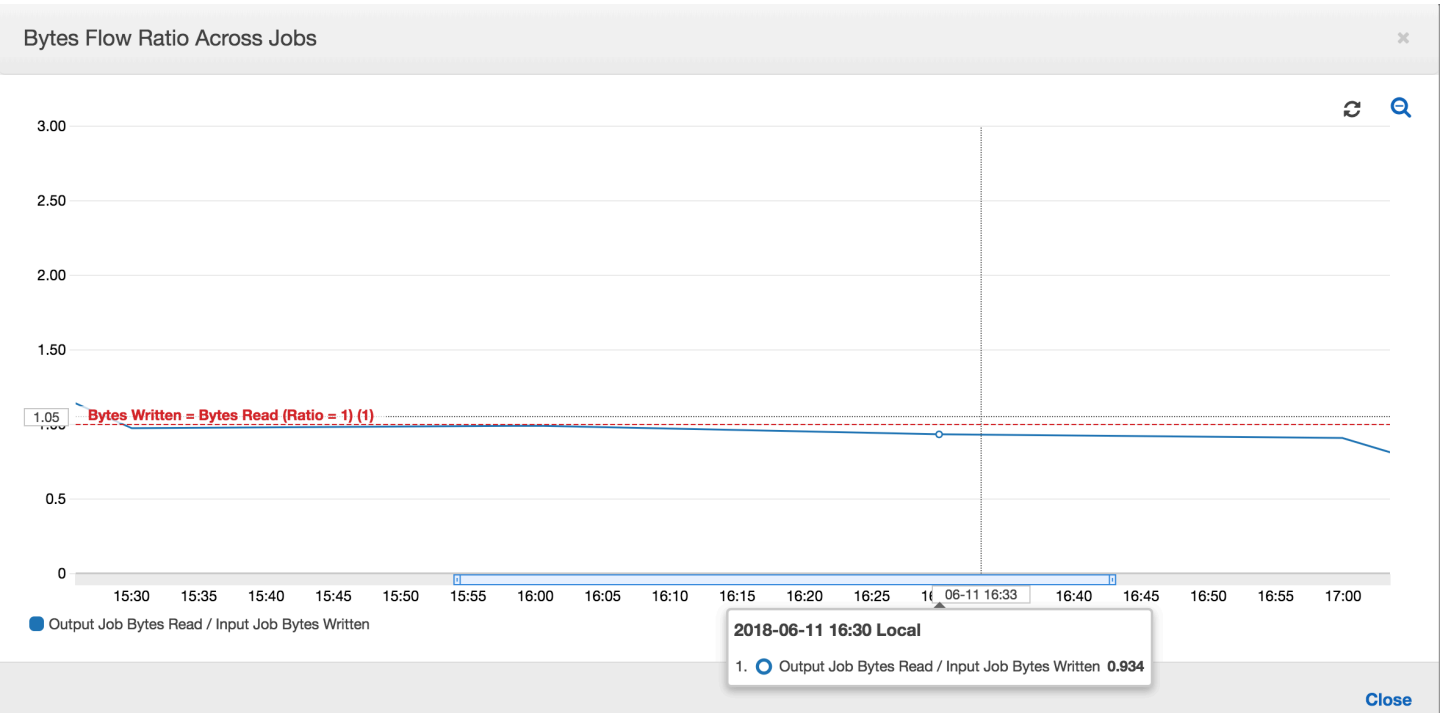

Una ejecución de trabajo para el trabajo de salida comienza y captura los archivos en la ubicación provisional antes de que la siguiente ejecución de trabajo de entrada comience a poner más datos en la ubicación provisional. Siempre que siga haciendo esto, procesará solo los archivos capturados de la ejecución de trabajo de entrada anterior, mientras que la relación permanece próxima a 1.

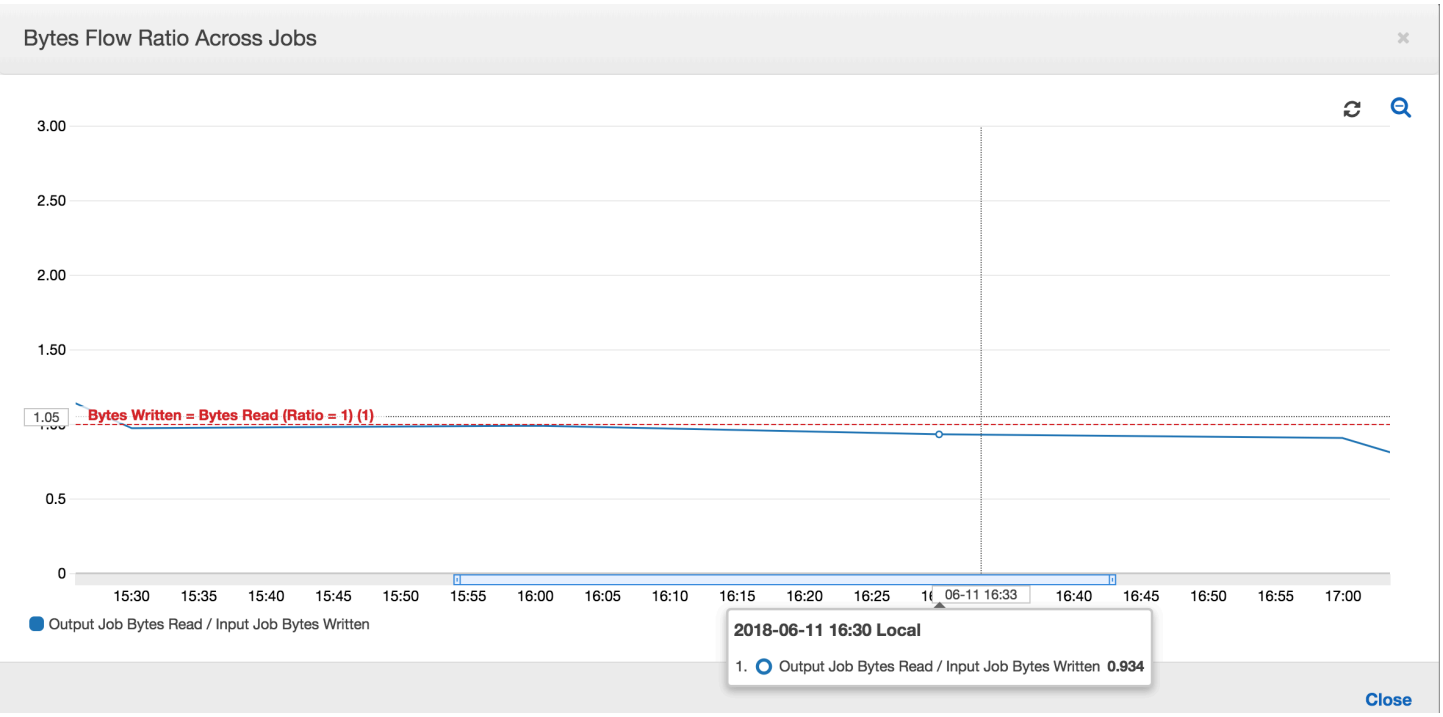

Supongamos que el trabajo de entrada tarda más de lo esperado y, como resultado, el trabajo de salida captura archivos en la ubicación provisional de dos ejecuciones de trabajo de entrada. A continuación, la relación es mayor que 1 para esa ejecución de trabajo de salida. Sin embargo, las siguientes ejecuciones de trabajo del trabajo de salida no procesan ningún archivo que ya hayan procesado las ejecuciones de trabajo anteriores del trabajo de salida.

Monitorización de la planificación de la capacidad de DPU

Puede usar las métricas de trabajos en AWS Glue para estimar el número de unidades de procesamiento de datos (DPU) que se puede utilizar para escalar en horizontal un trabajo de AWS Glue.

> **Note**
>
> Esta página solo corresponde para versiones 0.9 y 1.0 de AWS Glue. Las versiones posteriores de AWS Glue contienen funciones de ahorro de costos que introducen consideraciones adicionales a la hora de planificar la capacidad.

Temas

- Código con perfil
- Visualizar las métricas con perfil en la consola de AWS Glue
- Determinar la capacidad de DPU óptima

Código con perfil

El siguiente script lee una partición de Amazon Simple Storage Service (Amazon S3) que contiene 428 archivos gzip JSON. El script aplica un mapeo para cambiar los nombres de los campos y convertirlos y escribirlos en Amazon S3 en formato Apache Parquet. Aprovisione 10 DPU según el valor predeterminado y ejecute este trabajo.

```
datasource0 = glueContext.create_dynamic_frame.from_options(connection_type="s3",
 connection_options = {"paths": [input_path],
 "useS3ListImplementation":True,"recurse":True}, format="json")
applymapping1 = ApplyMapping.apply(frame = datasource0, mappings = [(map_spec])
datasink2 = glueContext.write_dynamic_frame.from_options(frame = applymapping1,
 connection_type = "s3", connection_options = {"path": output_path}, format =
 "parquet")
```

Visualizar las métricas con perfil en la consola de AWS Glue

Ejecución de trabajo 1: en esta ejecución de trabajo, mostramos cómo encontrar si hay DPU de aprovisionamiento deficiente en el clúster. La funcionalidad de ejecución de trabajos de AWS Glue muestra el número de ejecutores que se ejecutan activamente total, el número de fases completadas y el número máximo de ejecutores necesarios.

El número máximo de ejecutores necesarios se calcula añadiendo el número total de tareas en ejecución y tareas pendientes, y dividiéndolo entre las tareas por ejecutor. Este resultado es una medida del número total de ejecutores necesarios para satisfacer la carga actual.

Por contraste, el número de ejecutores que se ejecutan activamente mide cuántos ejecutores ejecutan tareas Apache Spark activas. A medida que progresa el trabajo, el número máximo de ejecutores necesarios puede cambiar y suele reducirse hacia el final del trabajo al disminuir la cola de tareas pendientes.

La línea roja horizontal del siguiente gráfico muestra el número máximo de ejecutores asignados, que depende del número de DPU que asigna para el trabajo. En este caso, asigna 10 DPU para la ejecución de trabajo. Una DPU está reservada para administración. Nueve DPU ejecutan dos ejecutores cada una y un ejecutor se reserva para el controlador Spark. El controlador Spark se ejecuta dentro de la aplicación principal. Así pues, el número máximo de ejecutores asignados es 2 x 9 -1 = 17 ejecutores.

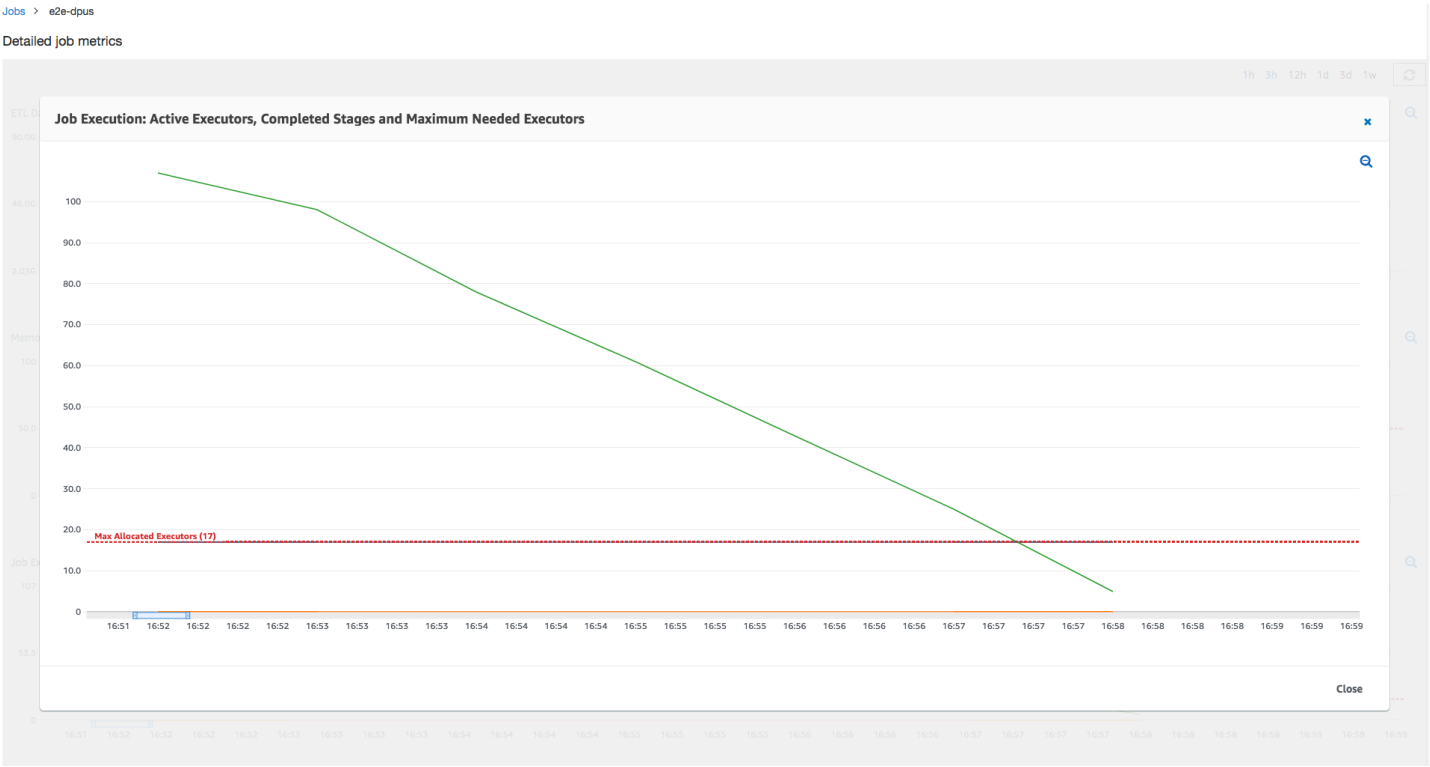

Tal como se muestra en el gráfico, el número máximo de ejecutores necesarios parte de 107 al principio del trabajo, mientras que el número de ejecutores activos sigue siendo 17. Este es igual al número máximo de ejecutores asignados con 10 DPU. La relación entre el número máximo de ejecutores necesarios y el número máximo de ejecutores asignados (que añade 1 a ambos para el controlador Spark) le ofrece el factor de aprovisionamiento deficiente: 108/18 = 6x. Puede aprovisionar 6 (por debajo de la proporción de aprovisionamiento)* 9 (capacidad de DPU actual - 1)+1 DPU = 55 DPU para escalar en horizontal el trabajo a fin de ejecutarlo con el máximo paralelismo y finalizar con mayor rapidez.

La consola de AWS Glue muestra las métricas detalladas de trabajos como una línea estática que representa el número original de ejecutores máximos asignados. La consola calcula los ejecutores máximos asignados a partir de la definición de trabajo de las métricas. En cambio, para las métricas detalladas de ejecución de trabajos, la consola calcula los ejecutores máximos asignados a partir de la configuración de ejecución de trabajos, específicamente las DPU asignadas a la ejecución de trabajos. Para ver las métricas de una ejecución de trabajo individual, seleccione la ejecución de trabajo y elija View run metrics (Ver métricas de ejecución).

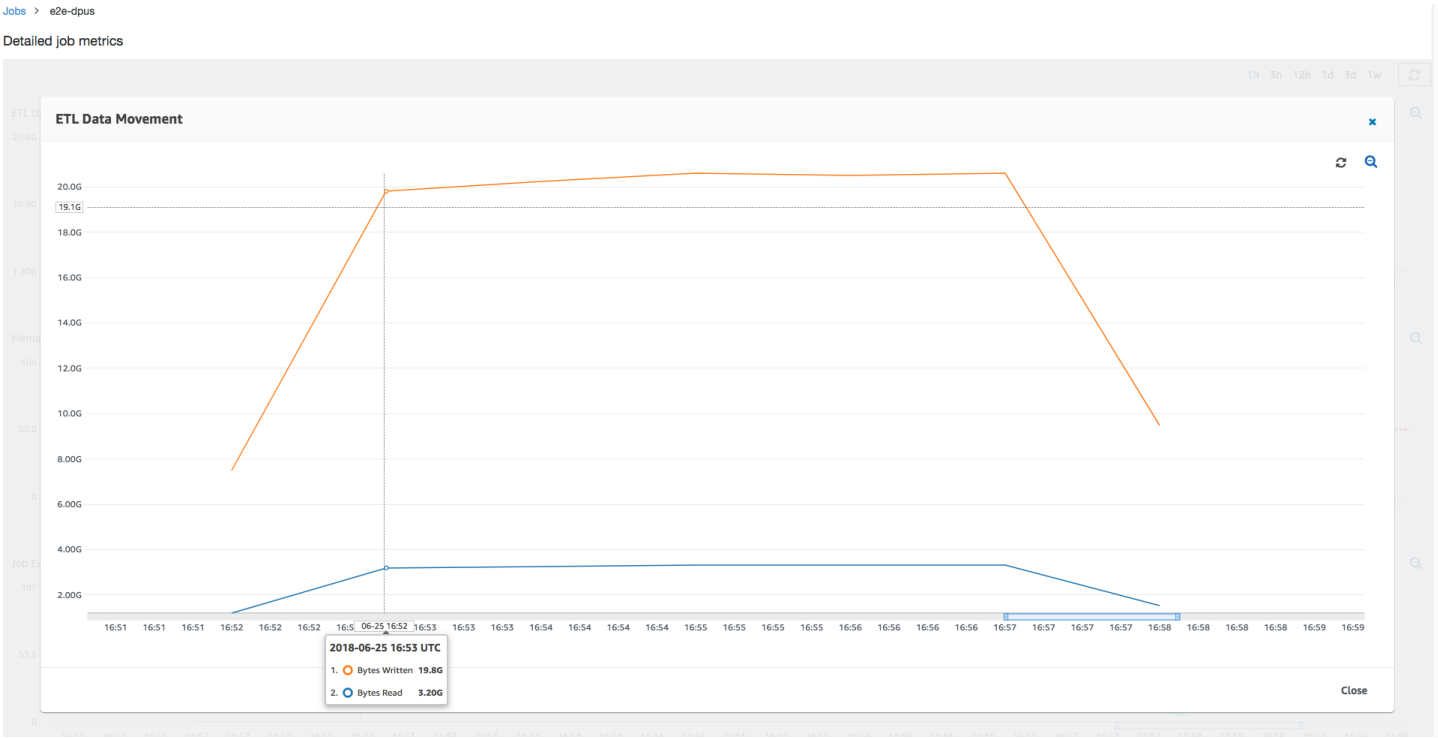

Al examinar los bytes de Amazon S3 leídos y escritos, observe que el trabajo dedica los seis minutos a la streaming de datos desde Amazon S3 y a escribir dichos datos en paralelo. Todos los núcleos de las DPU asignadas leen y escriben en Amazon S3. El número máximo de ejecutores necesarios, 107, también coincide con el número de archivos en la ruta de entrada de Amazon S3, 428. Cada ejecutor puede lanzar cuatro tareas Spark para procesar cuatro archivos de entrada (gzip JSON).

Determinar la capacidad de DPU óptima

En función de los resultados de la ejecución de trabajo anterior, puede aumentar el número total de DPU asignadas a 55, así como consultar el rendimiento del trabajo. El trabajo finaliza en menos de tres minutos, la mitad del tiempo que requería anteriormente. El escalado en horizontal del trabajo no es lineal en este caso porque se trata de un trabajo de corta ejecución. Los trabajos con tareas de larga duración o un gran número de tareas (un gran número correspondiente al máximo de ejecutores necesarios) se benefician de una aceleración de rendimiento de escalado en horizontal de DPU casi lineal.

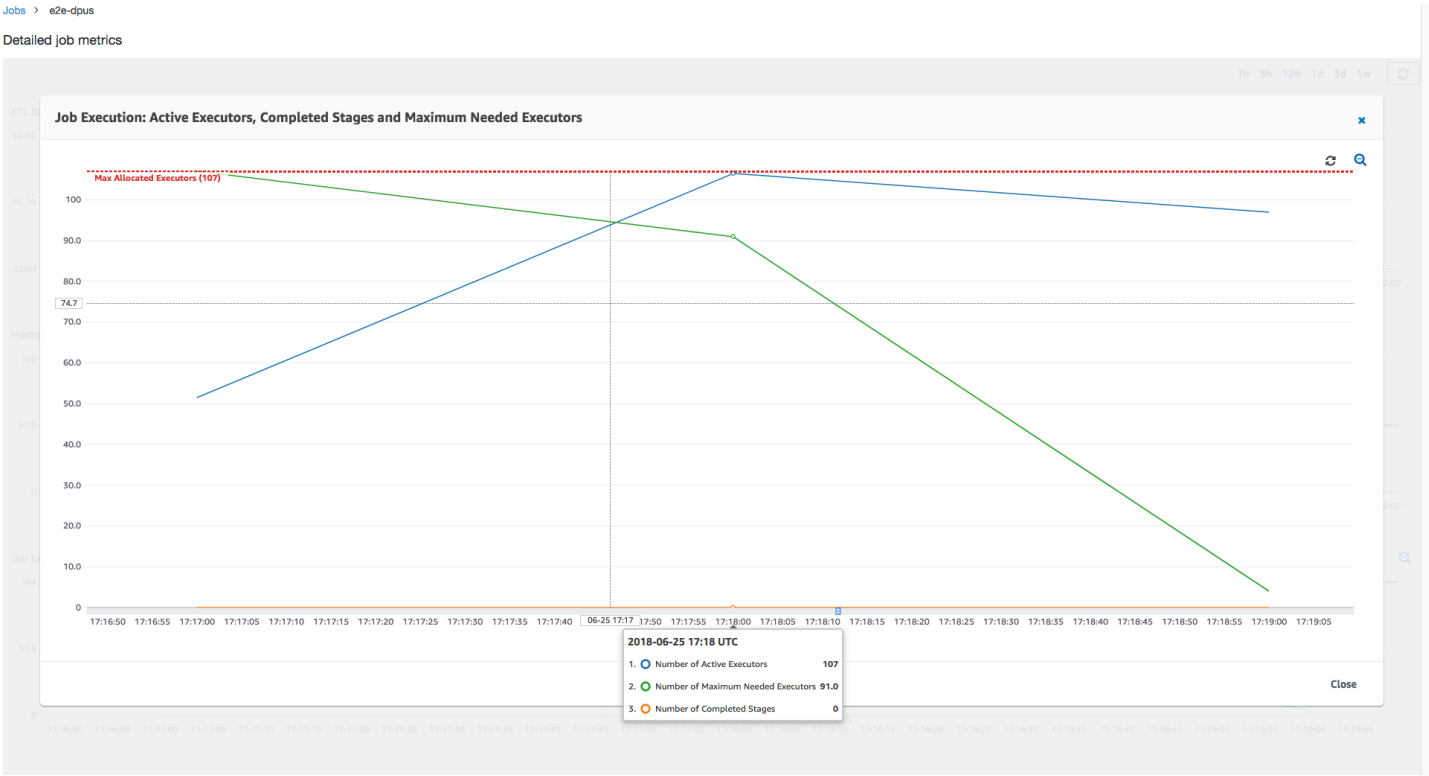

Tal como se muestra en la imagen anterior, el número total de ejecutores activos alcanza el máximo asignado, 107 ejecutores. Del mismo modo, el número máximo de ejecutores necesarios nunca supera el número máximo de ejecutores asignados. El número máximo de ejecutores necesarios se calcula a partir de los recuentos de tareas pendientes y tareas que se ejecutan activamente, por lo que podría ser inferior al número de ejecutores activos. Esto se debe a que puede haber ejecutores que estén inactivos parcial o completamente durante un corto periodo de tiempo y no se hayan retirado aún.

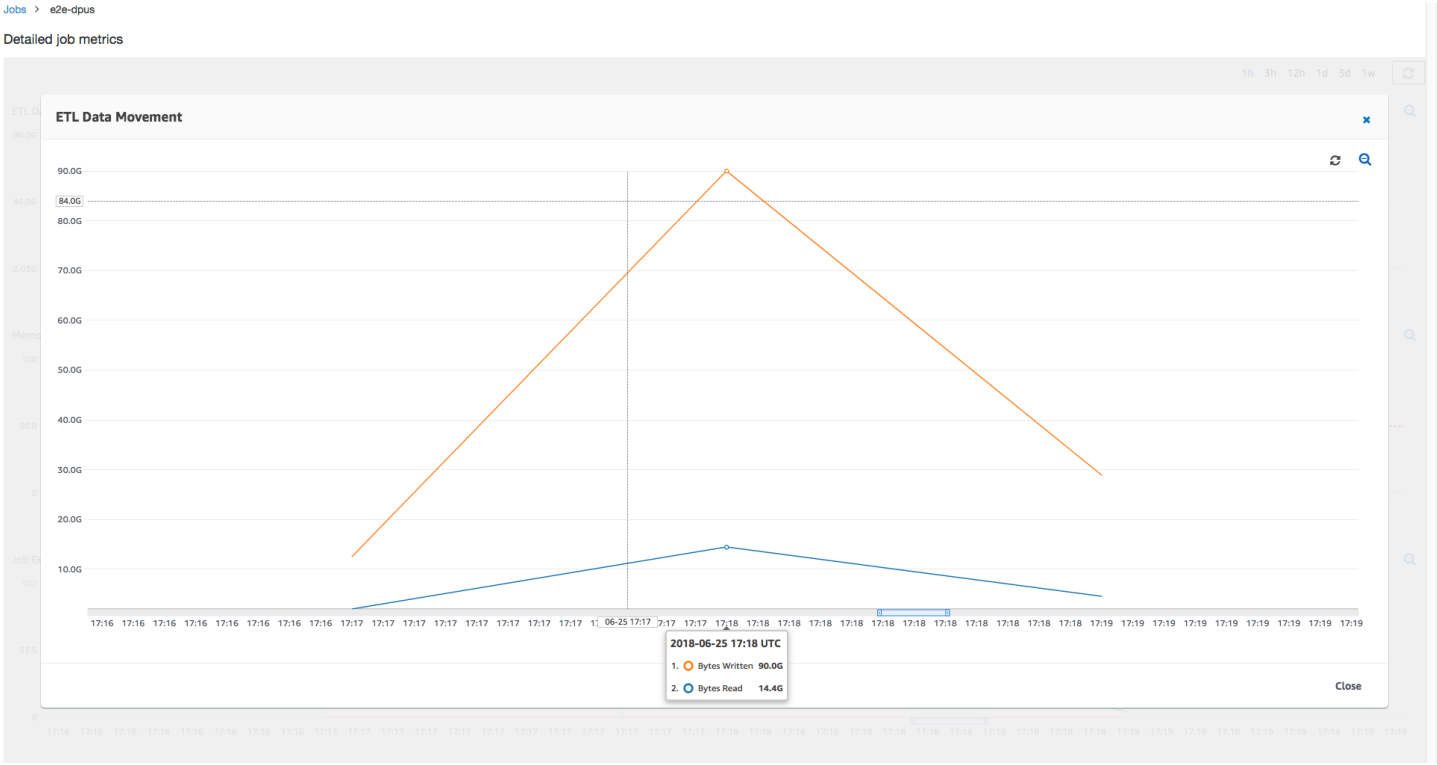

Esta ejecución de trabajo usa seis veces más ejecutores para leer y escribir desde Amazon S3 en paralelo. Como resultado, esta ejecución de trabajo usa más ancho de banda de Amazon S3 tanto para las lecturas como para las escrituras, y finaliza con mayor rapidez.

Identificar DPU sobreaprovisionadas

A continuación, puede determinar si escalar en horizontal el trabajo con 100 DPU (99 x 2 = 198 ejecutores) ayuda a escalar más en horizontal. Tal como se muestra en el siguiente gráfico, el trabajo sigue tardando tres minutos en finalizar. Del mismo modo, el trabajo no escala en horizontal más allá de 107 ejecutores (configuración de 55 DPU) y los 91 ejecutores restantes están sobreaprovisionados y no se han utilizado en absoluto. Esto muestra que es posible que aumentar el número de DPU no siempre mejore el rendimiento, como se desprende del número máximo de ejecutores necesarios.

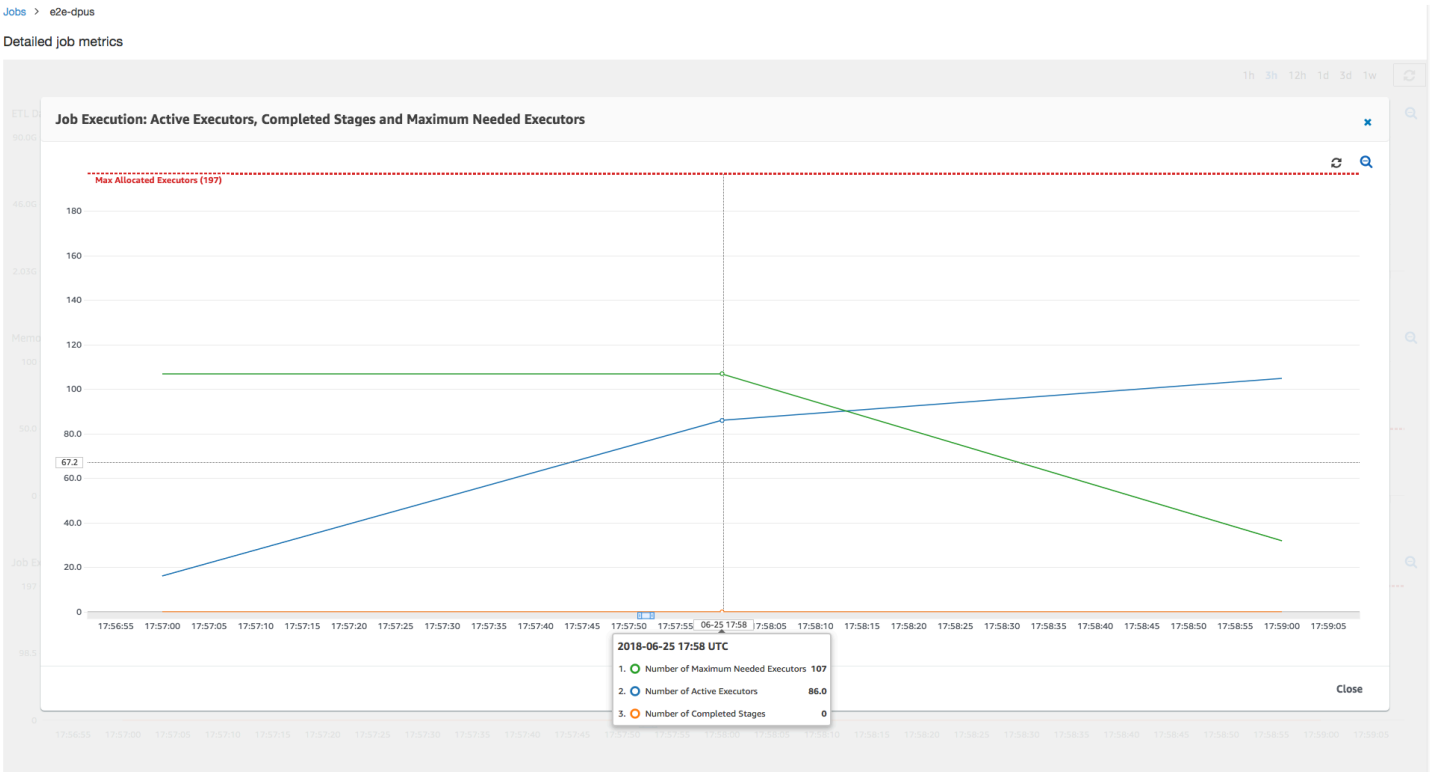

Comparar las diferencias de tiempo

Las tres ejecuciones de trabajo mostradas en la siguiente tabla resumen los tiempos de ejecución de trabajo para 10 DPU, 55 DPU y 100 DPU. Puede encontrar la capacidad de DPU para mejorar el tiempo de ejecución de trabajo mediante las estimaciones que estableció monitorizando la primera ejecución de trabajo.

ID de tarea	Número de DPU	Hora de ejecución
jr_c894524c8ef5048a4d9...	10	6 min.
jr_1a466cf2575e7ffe6856...	55	3 min.
jr_34fa1ed4c6aa9ff0a814...	100	3 min.

Solución de problemas de IA generativa para Apache Spark en AWS Glue

La resolución de problemas mediante IA generativa para trabajos de Apache Spark en AWS Glue es una nueva funcionalidad que ayuda a los ingenieros y científicos de datos a diagnosticar y solucionar problemas en sus aplicaciones de Spark con facilidad. Al utilizar el machine learning y

las tecnologías de IA generativa, esta característica analiza los problemas en los trabajos de Spark y proporciona un análisis detallado de la causa raíz junto con recomendaciones prácticas para resolverlos. La solución de problemas con IA generativa para Apache Spark está disponible para tareas que se ejecutan en la versión 4.0 de AWS Glue o posterior.

Transforme la resolución de problemas de Apache Spark con nuestro Agente de resolución de problemas impulsado por IA, ahora compatible con todos los modos de implementación principal es, incluidos AWS Glue, Amazon EMR-EC2, Amazon EMR sin servidor y Amazon SageMaker AI Notebooks. Este potente agente elimina los procesos complejos de depuración al combinar interacciones en lenguaje natural, análisis de cargas de trabajo en tiempo real y recomenda ciones inteligentes de código en una experiencia integrada y fluida. Para obtener información sobre los detalles de implementación, consulte ¿Qué es el agente de solución de problemas de Apache Spark para Amazon EMR? Vea la segunda demostración en Uso del agente de solución de problemas para obtener ejemplos de solución de problemas de AWS Glue.

¿Cómo funciona la solución de problemas de IA generativa para Apache Spark?

En el caso de los trabajos con errores de Spark, la solución de problemas de IA generativa analiza los metadatos del trabajo y las métricas y registros precisos asociados a la firma del error para generar un análisis de la causa raíz y recomienda soluciones específicas y prácticas para solucionar los errores de los trabajos.

Configuración de la solución de problemas de IA generativa para Apache Spark para los trabajos

Configuración de permisos de IAM

Para conceder permisos a las API utilizadas por la solución de problemas de Spark para los trabajos en AWS Glue, se requieren los permisos de IAM adecuados. Para obtener permisos, adjunte a su identidad de IAM (como el usuario, el rol o el grupo) la política de AWS personalizada que figura a continuación.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
```

```
      "Effect": "Allow",
      "Action": [
        "glue:StartCompletion",
        "glue:GetCompletion"
      ],
      "Resource": [
        "arn:aws:glue:*:*:completion/*",
        "arn:aws:glue:*:*:job/*"
      ]
    }
  ]
}
```

> **Note**
>
> Las dos API siguientes se utilizan en la política de IAM para permitir esta experiencia a través de la consola de AWS Glue Studio: `StartCompletion` y `GetCompletion`.

Asignación de permisos

Para dar acceso, agregue permisos a los usuarios, grupos o roles:

- Para los usuarios y los grupos en IAM Identity Center: creación de un conjunto de permisos. Siga las instrucciones que se detallan en Creación de un conjunto de permisos en la Guía del usuario de IAM Identity Center.
- Para los usuarios administrados en IAM a través de un proveedor de identidades: creación de un rol para la federación de identidades. Siga las instrucciones descritas en Crear un rol para un proveedor de identidad de terceros (federación) en la Guía del usuario de IAM.
- Para los usuarios de IAM: creación de un rol que el usuario pueda asumir. Siga las instrucciones descritas en Crear un rol para delegar permisos a un usuario de IAM en la Guía del usuario de IAM.

Ejecución de un análisis de solución de problemas a partir de una ejecución de trabajo con errores

Puede acceder a la característica de solución de problemas a través de varias rutas en la consola de AWS Glue. A continuación, se explica cómo empezar:

Opción 1: desde la página de lista de trabajos

1. Abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. En el panel de navegación, elija Trabajos de extracción, transformación y carga (ETL).
3. Localice el trabajo con error en la lista de trabajos.
4. Seleccione la pestaña Ejecuciones en la sección de detalles del trabajo.
5. Haga clic en la ejecución de trabajo con error que quiere analizar.
6. Elija Solucionar problemas con IA para iniciar el análisis.
7. Cuando finalice el análisis de solución de problemas, podrá ver el análisis de la causa raíz y las recomendaciones en la pestaña Análisis de solución de problemas situada en la parte inferior de la pantalla.

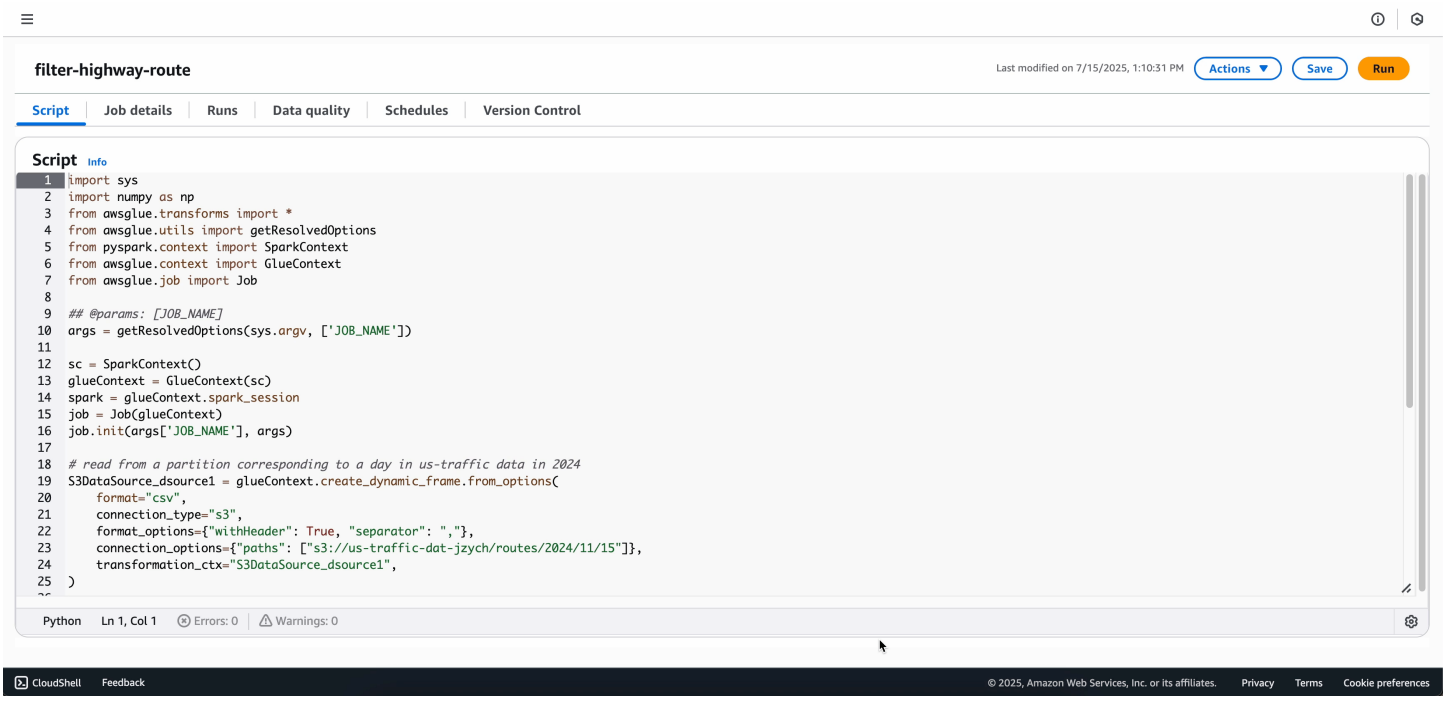

Opción 2: uso de la página Supervisión de ejecución de trabajos

1. Vaya a la página Supervisión de ejecución de trabajos.
2. Localice la ejecución de trabajos con errores.
3. Elija el menú desplegable Acciones.
4. Elige Solucionar problemas con IA.

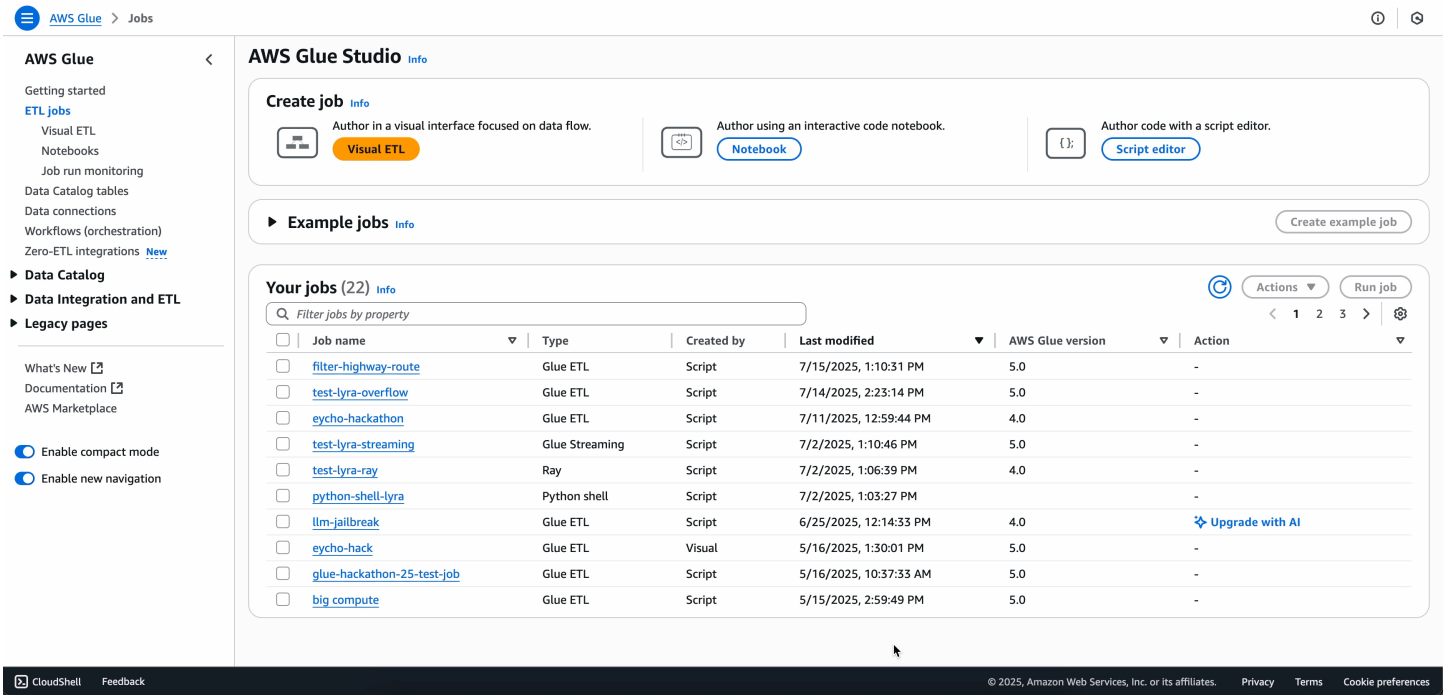

Opción 3: desde la página Detalles de la ejecución del trabajo

1. Para ir a la página de detalles de la ejecución de un trabajo con errores, haga clic en Ver detalles de una ejecución con errores en la pestaña Ejecuciones o seleccione la ejecución del trabajo en la página Supervisión de ejecución de trabajos.
2. En la página de detalles de la ejecución del trabajo, busque la pestaña Análisis de solución de problemas.

Categorías de resolución de problemas compatibles

Este servicio se centra en tres categorías principales de problemas que los ingenieros y los desarrolladores de datos suelen encontrar en sus aplicaciones de Spark:

- Errores de configuración y acceso a los recursos: cuando se ejecutan aplicaciones de Spark en AWS Glue, los errores de configuración y acceso a los recursos son algunos de los problemas más comunes pero difíciles de diagnosticar. Estos errores suelen producirse cuando la aplicación Spark intenta interactuar con los recursos de AWS, pero encuentra problemas con los permisos, la falta de recursos o problemas de configuración.
- Problemas con la memoria del controlador y el ejecutor de Spark: los errores relacionados con la memoria en los trabajadores de Apache Spark pueden ser difíciles de diagnosticar y resolver.

Estos errores suelen manifestarse cuando los requisitos de procesamiento de datos superan los recursos de memoria disponibles, ya sea en el nodo controlador o en los nodos ejecutores.

- Problemas de capacidad del disco de Spark: los errores relacionados con el almacenamiento en los trabajos de Spark de AWS Glue suelen surgir durante las operaciones aleatorias, el derrame de datos o cuando se trata de transformaciones de datos a gran escala. Estos errores pueden ser particularmente complicados, ya que es posible que no se manifiesten hasta que el trabajo haya estado ejecutándose durante un tiempo, lo que podría desperdiciar valiosos recursos y tiempo de computación.

> **Note**
>
> Antes de implementar los cambios sugeridos en su entorno de producción, revíselos detenidamente. El servicio ofrece recomendaciones basadas en patrones y prácticas recomendadas, pero su caso de uso específico puede requerir consideraciones adicionales.

Regiones admitidas

La solución de problemas con IA generativa para Apache Spark está disponible en las siguientes regiones:

- África: (Ciudad del Cabo) (af-south-1)
- Asia Pacífico: Hong Kong (ap-east-1), Tokio (ap-northeast-1), Seúl (ap-northeast-2), Osaka (ap-northeast-3), Mumbai (ap-south-1), Singapur (ap-southeast-1), Sídney (ap-southeast-2) y Yakarta (ap-southeast-3)
- Europa: Fráncfort (eu-central-1), Estocolmo (eu-north-1), Milán (eu-south-1), Irlanda (eu-west-1), Londres (eu-west-2) y París (eu-west-3)
- Medio Oriente: Baréin (me-south-1) y Emiratos Árabes Unidos (me-central-1)
- América del Norte: Canadá (ca-central-1)
- América del Sur: São Paulo (sa-east-1)
- Estados Unidos: Virginia del Norte (us-east-1), Ohio (us-east-2), California del Norte (us-west-1) y Oregón (us-west-2)

Uso de vistas materializadas con AWS Glue

La versión 5.1 y posteriores de AWS Glue admiten la creación y administración de vistas materializadas de Apache Iceberg en el catálogo de datos de AWS Glue. Una vista materializada es una tabla administrada que almacena el resultado precalculado de una consulta SQL en formato Apache Iceberg y se actualiza de forma incremental a medida que cambian las tablas de origen subyacentes. Puede utilizar las vistas materializadas para simplificar la canalización de transformación de datos y acelerar el rendimiento de las consultas para cargas de trabajo analíticas complejas.

Cuando crea una vista materializada mediante Spark en AWS Glue, la definición de la vista y sus metadatos se almacenan en el catálogo de datos de AWS Glue. Los resultados precalculados se almacenan como tablas de Apache Iceberg en buckets de tablas de Amazon S3 o en buckets de uso general de Amazon S3 dentro de su cuenta. El catálogo de datos de AWS Glue supervisa automáticamente las tablas de origen y actualiza las vistas materializadas mediante infraestructura de cómputo administrada.

Temas

- Cómo funcionan las vistas materializadas con AWS Glue
- Requisitos previos
- Configuración de Spark para usar vistas materializadas
- Creación de vistas materializadas
- Consulta de vistas materializadas
- Actualización de vistas materializadas
- Administración de vistas materializadas
- Permisos para vistas materializadas
- Supervisión de las operaciones de vistas materializadas
- Ejemplo: flujo de trabajo completo
- Consideraciones y limitaciones

Cómo funcionan las vistas materializadas con AWS Glue

Las vistas materializadas se integran con AWS Glue mediante la compatibilidad con Iceberg de Apache Spark en tareas de AWS Glue y cuadernos de AWS Glue Studio. Cuando configura su sesión de Spark para usar el catálogo de datos de AWS Glue, puede crear vistas materializadas

mediante sintaxis SQL estándar. El optimizador de Spark puede reescribir automáticamente las consultas para utilizar vistas materializadas cuando ofrecen un mejor rendimiento, lo que elimina la necesidad de modificar manualmente el código de la aplicación.

El catálogo de datos de AWS Glue administra todos los aspectos operativos del mantenimiento de la vista materializada, incluidos:

- Detección de cambios en las tablas fuente mediante la capa de metadatos de Apache Iceberg
- Programación y ejecución de operaciones de actualización mediante cómputo Spark administrado
- Cómo determinar si realizar una actualización completa o incremental en función de los cambios en los datos
- Almacenamiento de resultados precalculados en formato Apache Iceberg para el acceso con múltiples motores

Puede consultar vistas materializadas desde AWS Glue mediante las mismas interfaces de Spark SQL que utiliza para las tablas normales. También se puede acceder a los datos precalculados desde otros servicios, como Amazon Athena y Amazon Redshift.

Requisitos previos

Para utilizar vistas materializadas con AWS Glue, necesita:

- Una cuenta de .
- La versión 5.1 de AWS Glue, o posteriores
- Tablas fuente en formato Apache Iceberg registradas en el catálogo de datos de AWS Glue
- Permisos de AWS Lake Formation configurados para las tablas de origen y las bases de datos de destino
- Un bucket de tablas de S3 o un bucket de uso general de Amazon S3 registrado en AWS Lake Formation para almacenar los datos de las vistas materializadas.
- Un rol de IAM con permisos para acceder al catálogo de datos de AWS Glue y Amazon S3

Configuración de Spark para usar vistas materializadas

Para crear y administrar vistas materializadas en AWS Glue, configure su sesión de Spark con las extensiones de Iceberg y la configuración del catálogo requeridas. El método de configuración varía en función de si utiliza tareas de AWS Glue o cuadernos de AWS Glue Studio.

Configuración de tareas de AWS Glue

Al crear o actualizar un trabajo de AWS Glue, añada los siguientes parámetros de configuración como parámetros del trabajo:

Para buckets de tablas de S3

```
job = glue.create_job(
    Name='materialized-view-job',
    Role='arn:aws:iam::111122223333:role/GlueServiceRole',
    Command={
        'Name': 'glueetl',
        'ScriptLocation': 's3://amzn-s3-demo-bucket/scripts/mv-script.py',
        'PythonVersion': '3'
    },
    DefaultArguments={
        '--enable-glue-datacatalog': 'true',
        '--conf':
 'spark.sql.extensions=org.apache.iceberg.spark.extensions.IcebergSparkSessionExtensions
 '
        '--conf spark.sql.catalog.glue_catalog=org.apache.iceberg.spark.SparkCatalog '
                  '--conf spark.sql.catalog.glue_catalog.type=glue '
                  '--conf spark.sql.catalog.glue_catalog.warehouse=s3://amzn-s3-demo-
bucket/warehouse '
                  '--conf spark.sql.catalog.glue_catalog.glue.region=us-east-1 '
                  '--conf spark.sql.catalog.glue_catalog.glue.id=111122223333 '
                  '--conf spark.sql.catalog.glue_catalog.glue.account-id=111122223333
 ',
                  '--conf spark.sql.catalog.glue_catalog.glue.lakeformation-
enabled=true ',
                  '--conf
 spark.sql.catalog.s3t_catalog=org.apache.iceberg.spark.SparkCatalog '
                  '--conf spark.sql.catalog.s3t_catalog.type=glue '
                  '--conf
 spark.sql.catalog.s3t_catalog.glue.id=111122223333:s3tablescatalog/my-table-bucket ',
                  '--conf spark.sql.catalog.s3t_catalog.glue.account-id=111122223333 ',
                  '--conf spark.sql.catalog.s3t_catalog.glue.lakeformation-enabled=true
 ',
                  '--conf spark.sql.catalog.s3t_catalog.warehouse=s3://amzn-s3-demo-
bucket/mv-warehouse '
                  '--conf spark.sql.catalog.s3t_catalog.glue.region=us-east-1 '
                  '--conf spark.sql.defaultCatalog=s3t_catalog '
                  '--conf spark.sql.optimizer.answerQueriesWithMVs.enabled=true '
```

```
                  '--conf spark.sql.materializedViews.metadataCache.enabled=true'
    },
    GlueVersion='5.1'
)
```

Para buckets de uso general de S3

```
job = glue.create_job(
    Name='materialized-view-job',
    Role='arn:aws:iam::111122223333:role/GlueServiceRole',
    Command={
        'Name': 'glueetl',
        'ScriptLocation': 's3://amzn-s3-demo-bucket/scripts/mv-script.py',
        'PythonVersion': '3'
    },
    DefaultArguments={
        '--enable-glue-datacatalog': 'true',
        '--conf':
 'spark.sql.extensions=org.apache.iceberg.spark.extensions.IcebergSparkSessionExtensions
 '
                  '--conf
 spark.sql.catalog.glue_catalog=org.apache.iceberg.spark.SparkCatalog '
                  '--conf spark.sql.catalog.glue_catalog.type=glue '
                  '--conf spark.sql.catalog.glue_catalog.warehouse=s3://amzn-s3-demo-
bucket/warehouse '
                  '--conf spark.sql.catalog.glue_catalog.glue.region=us-east-1 '
                  '--conf spark.sql.catalog.glue_catalog.glue.id=111122223333 ',
                  '--conf spark.sql.catalog.glue_catalog.glue.account-id=111122223333
 ',
                  '--conf spark.sql.catalog.glue_catalog.glue.lakeformation-
enabled=true ',
                  '--conf spark.sql.defaultCatalog=glue_catalog '
                  '--conf spark.sql.optimizer.answerQueriesWithMVs.enabled=true '
                  '--conf spark.sql.materializedViews.metadataCache.enabled=true'
    },
    GlueVersion='5.1'
)
```

Configuración de cuadernos de AWS Glue Studio

En los cuadernos de AWS Glue Studio, configure su sesión de Spark mediante el comando mágico %%configure al inicio del cuaderno:

```
%%configure
{
    "conf": {
        "spark.sql.extensions":
 "org.apache.iceberg.spark.extensions.IcebergSparkSessionExtensions",
        "spark.sql.catalog.glue_catalog": "org.apache.iceberg.spark.SparkCatalog",
        "spark.sql.catalog.glue_catalog.type": "glue",
        "spark.sql.catalog.glue_catalog.warehouse": "s3://amzn-s3-demo-bucket/
warehouse",
        "spark.sql.catalog.glue_catalog.glue.region": "us-east-1",
        "spark.sql.catalog.glue_catalog.glue.id": "111122223333",
        "spark.sql.catalog.glue_catalog.glue.account-id": "111122223333",
        "spark.sql.catalog.glue_catalog.glue.lakeformation-enabled": "true",
        "spark.sql.defaultCatalog": "glue_catalog",
        "spark.sql.optimizer.answerQueriesWithMVs.enabled": "true",
        "spark.sql.materializedViews.metadataCache.enabled": "true"
    }
}
```

Habilitación de la actualización incremental

Para habilitar la optimización de la actualización incremental, añada las siguientes propiedades de configuración a los parámetros del trabajo o a la configuración del cuaderno:

```
--conf spark.sql.optimizer.incrementalMVRefresh.enabled=true
--conf spark.sql.optimizer.incrementalMVRefresh.deltaThresholdCheckEnabled=false
```

Parámetros de configuración

Los siguientes parámetros de configuración controlan el comportamiento de la vista materializada:

- `spark.sql.extensions`: habilita las extensiones de sesión de Iceberg Spark necesarias para la compatibilidad con la vista materializada.
- `spark.sql.optimizer.answerQueriesWithMVs.enabled`: habilita la reescritura automática de consultas para usar vistas materializadas. Establézcalo en «true» para activar esta optimización.
- `spark.sql.materializedViews.metadataCache.enabled`: permite el almacenamiento en caché de los metadatos de las vistas materializadas para la optimización de las consultas. Establézcalo en «true» para mejorar el rendimiento de la reescritura de consultas.

- `spark.sql.optimizer.incrementalMVRefresh.enabled`: permite la optimización de la actualización incremental. Establézcalo en «true» para procesar solo los datos modificados durante las operaciones de actualización.
- `spark.sql.optimizer.answerQueriesWithMVs.decimalAggregateCheckEnabled`: controla la validación de las operaciones de agregación decimal en la reescritura de consultas. Establézcalo en «false» para desactivar determinadas comprobaciones de desbordamiento decimal.

Creación de vistas materializadas

Puede crear vistas materializadas mediante la instrucción SQL CREATE MATERIALIZED VIEW en tareas o en cuadernos de AWS Glue. La definición de vista especifica la lógica de transformación como una consulta SQL que hace referencia a una o más tablas de origen.

Creación de una vista materializada básica en las tareas de AWS Glue

En el siguiente ejemplo, se muestra cómo crear una vista materializada en un script de tarea de AWS Glue; utilice nombres de tabla totalmente calificados con la convención de nomenclatura de tres partes en la definición de la vista:

```
from awsglue.context import GlueContext
from pyspark.context import SparkContext

sc = SparkContext()
glueContext = GlueContext(sc)
spark = glueContext.spark_session

# Create materialized view
spark.sql("""
    CREATE MATERIALIZED VIEW customer_orders
    AS
    SELECT
        customer_name,
        COUNT(*) as order_count,
        SUM(amount) as total_amount
    FROM glue_catalog.sales.orders
    GROUP BY customer_name
""")
```

Creación de una vista materializada con actualización automática

Para configurar la actualización automática, especifique un calendario de actualización al crear la vista y utilice nombres de tabla totalmente calificados con la convención de nomenclatura de tres partes en la definición de la vista:

```
spark.sql("""
    CREATE MATERIALIZED VIEW customer_orders
    SCHEDULE REFRESH EVERY 1 HOUR
    AS
    SELECT
        customer_name,
        COUNT(*) as order_count,
        SUM(amount) as total_amount
    FROM glue_catalog.sales.orders
    GROUP BY customer_name
""")
```

Creación de una vista materializada con referencias entre catálogos

Cuando las tablas de origen se encuentran en un catálogo distinto del de la vista materializada, utilice nombres de tabla totalmente calificados con la convención de nomenclatura de tres partes tanto en el nombre de la vista como en la definición de la vista:

```
spark.sql("""
    CREATE MATERIALIZED VIEW s3t_catalog.analytics.customer_summary
    AS
    SELECT
        customer_name,
        COUNT(*) as order_count,
        SUM(amount) as total_amount
    FROM glue_catalog.sales.orders
    GROUP BY customer_name
""")
```

Creación de vistas materializadas en cuadernos de AWS Glue Studio

En los cuadernos de AWS Glue Studio, puede usar el comando mágico %%sql para crear vistas materializadas y utilizar nombres de tabla totalmente calificados con la convención de nomenclatura de tres partes en la definición de la vista:

```
%%sql
```

```
CREATE MATERIALIZED VIEW customer_orders
AS
SELECT
    customer_name,
    COUNT(*) as order_count,
    SUM(amount) as total_amount
FROM glue_catalog.sales.orders
GROUP BY customer_name
```

Consulta de vistas materializadas

Después de crear una vista materializada, puede consultarla como cualquier otra tabla mediante instrucciones SQL SELECT estándar en sus tareas o cuadernos de AWS Glue.

Consultas en tareas de AWS Glue

```
from awsglue.context import GlueContext
from pyspark.context import SparkContext

sc = SparkContext()
glueContext = GlueContext(sc)
spark = glueContext.spark_session

# Query materialized view
result = spark.sql("SELECT * FROM customer_orders")
result.show()
```

Consultas en los cuadernos de AWS Glue Studio

```
%%sql
SELECT * FROM customer_orders
```

Reescritura automática de consultas

Cuando la reescritura automática de consultas está habilitada, el optimizador de Spark analiza las consultas y utiliza automáticamente las vistas materializadas para mejorar el rendimiento. Por ejemplo, la siguiente consulta no se ejecuta:

```
result = spark.sql("""
    SELECT
        customer_name,
```

```
        COUNT(*) as order_count,
        SUM(amount) as total_amount
    FROM orders
    GROUP BY customer_name
""")
```

El optimizador de Spark reescribe automáticamente esta consulta para utilizar la vista materializada «customer_orders» en lugar de procesar la tabla base de pedidos, siempre que la vista materializada esté actualizada.

Verificación de la reescritura automática de consultas

Para verificar si una consulta utiliza la reescritura automática de consultas, use el comando EXPLAIN EXTENDED:

```
spark.sql("""
    EXPLAIN EXTENDED
    SELECT customer_name, COUNT(*) as order_count, SUM(amount) as total_amount
    FROM orders
    GROUP BY customer_name
""").show(truncate=False)
```

En el plan de ejecución, busque el nombre de la vista materializada en la operación BatchScan. Si el plan muestra BatchScan glue_catalog.analytics.customer_orders en lugar de BatchScan glue_catalog.sales.orders, la consulta se ha reescrito automáticamente para usar la vista materializada.

Tenga en cuenta que la reescritura automática de consultas requiere tiempo para que se complete la caché de metadatos de Spark después de crear una vista materializada. Este proceso suele completarse en un plazo de 30 segundos.

Actualización de vistas materializadas

Puede actualizar las vistas materializadas mediante dos métodos: actualización completa o actualización incremental. La actualización completa vuelve a calcular toda la vista materializada a partir de todos los datos de las tablas base, mientras que la actualización incremental procesa únicamente los datos que han cambiado desde la última actualización.

Actualización completa manual en tareas de AWS Glue

Para realizar una actualización completa de una vista materializada:

```
spark.sql("REFRESH MATERIALIZED VIEW customer_orders FULL")

# Verify updated results
result = spark.sql("SELECT * FROM customer_orders")
result.show()
```

Actualización incremental manual en tareas de AWS Glue

Para realizar una actualización incremental, asegúrese de que la actualización incremental esté habilitada en la configuración de su sesión de Spark y, a continuación, ejecute:

```
spark.sql("REFRESH MATERIALIZED VIEW customer_orders")

# Verify updated results
result = spark.sql("SELECT * FROM customer_orders")
result.show()
```

El catálogo de datos de AWS Glue determina automáticamente si la actualización incremental es aplicable en función de la definición de la vista y de la cantidad de datos modificados. Si la actualización incremental no es posible, la operación recurre a una actualización completa.

Actualización en los cuadernos de AWS Glue Studio

En los cuadernos, use el comando mágico %%sql:

```
%%sql
REFRESH MATERIALIZED VIEW customer_orders FULL
```

Verificación de la ejecución de la actualización incremental

Para confirmar que la actualización incremental se ejecutó correctamente, habilite el registro de depuración en su tarea de AWS Glue:

```
from awsglue.context import GlueContext
from pyspark.context import SparkContext
import logging

sc = SparkContext()
glueContext = GlueContext(sc)
spark = glueContext.spark_session
```

```
# Enable debug logging
logger = logging.getLogger('org.apache.spark.sql')
logger.setLevel(logging.DEBUG)

# Execute refresh
spark.sql("REFRESH MATERIALIZED VIEW customer_orders")
```

Busque el siguiente mensaje en los registros de la tarea de AWS Glue:

```
DEBUG RefreshMaterializedViewExec: Executed Incremental Refresh
```

Administración de vistas materializadas

AWS Glue proporciona comandos SQL para administrar el ciclo de vida de las vistas materializadas en sus tareas y cuadernos.

Descripción de una vista materializada

Para ver los metadatos de una vista materializada, incluida su definición, el estado de actualización y la marca de tiempo de la última actualización:

```
spark.sql("DESCRIBE EXTENDED customer_orders").show(truncate=False)
```

Modificación de una vista materializada

Para modificar el calendario de actualización de una vista materializada existente:

```
spark.sql("""
    ALTER MATERIALIZED VIEW customer_orders
    ADD SCHEDULE REFRESH EVERY 2 HOURS
""")
```

Para eliminar la actualización automática:

```
spark.sql("""
    ALTER MATERIALIZED VIEW customer_orders
    DROP SCHEDULE
""")
```

Eliminación de una vista materializada

Para eliminar una vista materializada:

```
spark.sql("DROP MATERIALIZED VIEW customer_orders")
```

Este comando elimina la definición de la vista materializada del catálogo de datos de AWS Glue y borra los datos de la tabla Iceberg subyacente de su bucket de Amazon S3.

Listado de vistas materializadas

Para enumerar todas las vistas materializadas de una base de datos:

```
spark.sql("SHOW VIEWS FROM analytics").show()
```

Permisos para vistas materializadas

Para crear y administrar vistas materializadas, debe configurar los permisos de AWS Lake Formation. El rol de IAM que crea la vista materializada (la función de definición) requiere permisos específicos en las tablas de origen y las bases de datos de destino.

Permisos requeridos para el rol definidor

El rol definidor debe contar con los siguientes permisos de Lake Formation:

- En las tablas de origen: permisos SELECT o ALL, sin filtros de filas, columnas ni celdas.
- En la base de datos de destino: permiso CREATE_TABLE
- En el catálogo de datos de AWS Glue: permisos de la API GetTable y CreateTable

Cuando crea una vista materializada, el ARN del rol definidor se almacena en la definición de la vista. El catálogo de datos de AWS Glue asume este rol al ejecutar operaciones de actualización automática. Si el rol definidor pierde el acceso a las tablas de origen, las operaciones de actualización fallarán hasta que se restablezcan los permisos.

Permisos de IAM para tareas de AWS Glue

El rol de IAM de su tarea de AWS Glue requiere los siguientes permisos:

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "glue:GetCatalog",
```

```
                "glue:GetCatalogs",
                "glue:GetTable",
                "glue:GetTables",
                "glue:CreateTable",
                "glue:UpdateTable",
                "glue:DeleteTable",
                "glue:GetDatabase",
                "glue:GetDatabases",
                "cloudwatch:PutMetricData"
            ],
            "Resource": "*"
        },
        {
            "Effect": "Allow",
            "Action": [
                "s3:GetObject",
                "s3:PutObject",
                "s3:DeleteObject"
            ],
            "Resource": [
                "arn:aws:s3:::amzn-s3-demo-bucket/*"
            ]
        },
        {
            "Effect": "Allow",
            "Action": [
                "s3:ListBucket"
            ],
            "Resource": [
                "arn:aws:s3:::amzn-s3-demo-bucket"
            ]
        },
        {
            "Effect": "Allow",
            "Action": [
                "logs:CreateLogGroup",
                "logs:CreateLogStream",
                "logs:PutLogEvents"
            ],
            "Resource": [
                "arn:aws:logs:*:*:*:/aws-glue/*"
            ]
        },
        {
```

```
            "Effect": "Allow",
            "Action": [
                "lakeformation:GetDataAccess"
            ],
            "Resource": "*"
        }
    ]
}
```

El rol que utilice para la actualización automática de vistas materializadas debe contar con el permiso iam:PassRole sobre dicho rol.

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "iam:PassRole"
      ],
      "Resource": [
        "arn:aws:iam::111122223333:role/materialized-view-role-name"
      ]
    }
  ]
}
```

Para permitir que Glue actualice automáticamente la vista materializada, el rol también debe contar con la siguiente política de confianza, que habilita al servicio a asumir dicho rol.

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "iam:PassRole"
      ],
      "Resource": [
```

```
        "arn:aws:iam::111122223333:role/materialized-view-role-name"
      ]
    }
  ]
}
```

Si la vista materializada se almacena en buckets de tablas de S3, también debe añadir el siguiente permiso al rol.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "s3tables:PutTableMaintenanceConfiguration"
      ],
      "Resource": "arn:aws:s3tables:*:123456789012:*"
    }
  ]
}
```

Concesión de acceso a vistas materializadas

Para conceder a otros usuarios acceso para consultar una vista materializada, utilice AWS Lake Formation para otorgar el permiso SELECT sobre la tabla de la vista materializada. Los usuarios pueden consultar la vista materializada sin necesidad de tener acceso directo a las tablas de origen subyacentes.

Para obtener información detallada sobre la configuración de los permisos de Lake Formation, consulte Concesión y revocación de permisos en recursos del catálogo de datos en la Guía para desarrolladores de AWS Lake Formation.

Supervisión de las operaciones de vistas materializadas

El catálogo de datos de AWS Glue publica métricas y registros para las operaciones de actualización de vistas materializadas en Amazon CloudWatch. Puede supervisar el estado de actualización, la duración y el volumen de datos procesados mediante métricas de CloudWatch.

Visualización de registros de la tarea

Para ver los registros de las tareas de AWS Glue que crean o actualizan vistas materializadas:

1. Abra la consola de AWS Glue.
2. En el panel de navegación, seleccione Tareas.
3. Seleccione su tarea y elija Ejecuciones.
4. Seleccione una ejecución específica y elija Registros para ver los registros de CloudWatch.

Configuración de alarmas

Para recibir notificaciones cuando las operaciones de actualización fallen o superen la duración prevista, cree alarmas de CloudWatch sobre las métricas de las vistas materializadas. También puede configurar reglas de Amazon EventBridge para activar respuestas automatizadas ante eventos de actualización.

Ejemplo: flujo de trabajo completo

En el siguiente ejemplo, se muestra un flujo de trabajo completo para crear y utilizar una vista materializada en AWS Glue.

Ejemplo de script de tarea de AWS Glue

```
import sys
from awsglue.transforms import *
from awsglue.utils import getResolvedOptions
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job

args = getResolvedOptions(sys.argv, ['JOB_NAME'])
sc = SparkContext()
glueContext = GlueContext(sc)
spark = glueContext.spark_session
job = Job(glueContext)
job.init(args['JOB_NAME'], args)

# Create database and base table
spark.sql("CREATE DATABASE IF NOT EXISTS sales")
spark.sql("USE sales")
```

```
spark.sql("""
    CREATE TABLE IF NOT EXISTS orders (
        id INT,
        customer_name STRING,
        amount DECIMAL(10,2),
        order_date DATE
    )
""")

# Insert sample data
spark.sql("""
    INSERT INTO orders VALUES
        (1, 'John Doe', 150.00, DATE('2024-01-15')),
        (2, 'Jane Smith', 200.50, DATE('2024-01-16')),
        (3, 'Bob Johnson', 75.25, DATE('2024-01-17'))
""")

# Create materialized view
spark.sql("""
    CREATE MATERIALIZED VIEW customer_summary
    AS
    SELECT
        customer_name,
        COUNT(*) as order_count,
        SUM(amount) as total_amount
    FROM glue_catalog.sales.orders
    GROUP BY customer_name
""")

# Query the materialized view
print("Initial materialized view data:")
spark.sql("SELECT * FROM customer_summary").show()

# Insert additional data
spark.sql("""
    INSERT INTO orders VALUES
        (4, 'Jane Smith', 350.00, DATE('2024-01-18')),
        (5, 'Bob Johnson', 100.25, DATE('2024-01-19'))
""")

# Refresh the materialized view
spark.sql("REFRESH MATERIALIZED VIEW customer_summary FULL")

# Query updated results
```

```
print("Updated materialized view data:")
spark.sql("SELECT * FROM customer_summary").show()

job.commit()
```

Ejemplo de cuaderno de AWS Glue Studio

```
%%configure
{
    "conf": {
        "spark.sql.extensions":
 "org.apache.iceberg.spark.extensions.IcebergSparkSessionExtensions",
        "spark.sql.catalog.glue_catalog": "org.apache.iceberg.spark.SparkCatalog",
        "spark.sql.catalog.glue_catalog.type": "glue",
        "spark.sql.catalog.glue_catalog.warehouse": "s3://amzn-s3-demo-bucket/
warehouse",
        "spark.sql.catalog.glue_catalog.glue.region": "us-east-1",
        "spark.sql.catalog.glue_catalog.glue.id": "111122223333",
        "spark.sql.catalog.glue_catalog.glue.account-id": "111122223333",
        "spark.sql.catalog.glue_catalog.glue.lakeformation-enabled": "true",
        "spark.sql.defaultCatalog": "glue_catalog",
        "spark.sql.optimizer.answerQueriesWithMVs.enabled": "true",
        "spark.sql.materializedViews.metadataCache.enabled": "true"
    }
}
```

```
%%sql
CREATE DATABASE IF NOT EXISTS sales
```

```
%%sql
USE sales
```

```
%%sql
CREATE TABLE IF NOT EXISTS orders (
    id INT,
    customer_name STRING,
    amount DECIMAL(10,2),
    order_date DATE
)
```

```
%%sql
```

```
INSERT INTO orders VALUES
    (1, 'John Doe', 150.00, DATE('2024-01-15')),
    (2, 'Jane Smith', 200.50, DATE('2024-01-16')),
    (3, 'Bob Johnson', 75.25, DATE('2024-01-17'))
```

```
%%sql
CREATE MATERIALIZED VIEW customer_summary
AS
SELECT
    customer_name,
    COUNT(*) as order_count,
    SUM(amount) as total_amount
FROM glue_catalog.sales.orders
GROUP BY customer_name
```

```
%%sql
SELECT * FROM customer_summary
```

```
%%sql
INSERT INTO orders VALUES
    (4, 'Jane Smith', 350.00, DATE('2024-01-18')),
    (5, 'Bob Johnson', 100.25, DATE('2024-01-19'))
```

```
%%sql
REFRESH MATERIALIZED VIEW customer_summary FULL
```

```
%%sql
SELECT * FROM customer_summary
```

Consideraciones y limitaciones

Tenga en cuenta lo siguiente al usar vistas materializadas con AWS Glue:

- Las vistas materializadas requieren la versión 5.1 de AWS Glue, o posterior.
- Las tablas de origen deben ser tablas de Apache Iceberg registradas en el catálogo de datos de AWS Glue. Las tablas de Apache Hive, Apache Hudi y Delta Lake de Linux Foundation no son compatibles en el lanzamiento.
- Las tablas de origen deben residir en la misma región y en la misma cuenta que la vista materializada.

- Todas las tablas de origen deben regirse por AWS Lake Formation. No se admiten los permisos exclusivos de IAM ni el acceso híbrido.
- Las vistas materializadas no pueden hacer referencia a vistas del catálogo de datos de AWS Glue, vistas multidialecto ni otras vistas materializadas como tablas de origen.
- El rol definidor de la vista debe contar con acceso de lectura completo (permisos SELECT o ALL) en todas las tablas de origen, sin aplicar filtros de filas, columnas ni celdas.
- Las vistas materializadas son eventualmente coherentes con las tablas de origen. Durante la ventana de actualización, las consultas pueden devolver datos obsoletos. Ejecute una actualización manual para obtener consistencia inmediata.
- El intervalo mínimo de actualización automática es de una hora.
- La actualización incremental admite un conjunto limitado de operaciones SQL. La definición de la vista debe ser un único bloque SELECT-FROM-WHERE-GROUP BY-HAVING y no puede contener operaciones de conjunto, subconsultas, la palabra clave DISTINCT en SELECT o en funciones de agregación, funciones de ventana ni uniones distintas de INNER JOIN.
- La actualización incremental no admite funciones definidas por el usuario ni determinadas funciones integradas. Solo se admite un subconjunto de las funciones integradas de Spark SQL.
- La reescritura automática de consultas solo tiene en cuenta vistas materializadas cuyas definiciones pertenecen a un subconjunto restringido de SQL, similar a las restricciones de la actualización incremental.
- Los identificadores que contienen caracteres especiales distintos de caracteres alfanuméricos y guiones bajos no son compatibles en las consultas CREAR VISTA MATERIALIZADA. Esto se aplica a todos los tipos de identificadores, incluidos los nombres de catálogo/espacio de nombres/tabla, los nombres de columnas y campos de estructuras, las CTE y los alias.
- Las columnas de las vistas materializadas que comienzan con el prefijo __ivm están reservadas para uso del sistema. Amazon se reserva el derecho de modificar o eliminar estas columnas en versiones futuras.
- Las cláusulas SORT BY, LIMIT, OFFSET, CLUSTER BY y ORDER BY no son compatibles en las definiciones de vistas materializadas.
- No se admiten tablas de origen entre regiones ni entre cuentas.
- Las tablas a las que hace referencia la consulta de la vista deben utilizar la convención de nomenclatura de tres partes (por ejemplo, glue_catalog.my_db.my_table), ya que la actualización automática no utiliza la configuración predeterminada de catálogo ni de base de datos.
- Las operaciones de actualización completa sobrescriben la tabla en su totalidad y hacen que las instantáneas anteriores dejen de estar disponibles.

- Las funciones no deterministas, como rand() o current_timestamp(), no son compatibles en las definiciones de vistas materializadas.

Tipos de trabajadores de AWS Glue

Descripción general

AWS Glue proporciona varios tipos de trabajadores para adaptarse a diferentes requisitos de carga de trabajo, desde pequeños trabajos de transmisión hasta tareas de procesamiento de datos a gran escala que consumen mucha memoria. En esta sección se proporciona información completa sobre todos los tipos de trabajadores disponibles, sus especificaciones y recomendaciones de uso.

Categorías de tipos de trabajadores

AWS Glue ofrece dos categorías principales de tipos de trabajadores:

- Tipos de trabajadores G: trabajador informáticos de uso general optimizados para cargas de trabajo de ETL estándar
- Tipos de trabajadores R: trabajadores con memoria optimizada diseñados para aplicaciones Spark con un gran consumo de memoria

Unidades de procesamiento de datos (DPU)

Los recursos disponibles para los trabajadores de AWS Glue se miden en DPU. Una DPU es una medida relativa de la potencia de procesamiento que consta de 4 vCPU de capacidad de cómputo y 16 GB de memoria.

DPU optimizadas para memoria (M-DPU): los trabajador de tipo R utilizan M-DPU, que proporcionan el doble de asignación de memoria para un tamaño determinado en comparación con las DPU estándar. Esto significa que, si bien una DPU estándar proporciona 16 GB de memoria, una M-DPU en trabajador de tipo R proporciona 32 GB de memoria optimizada para aplicaciones Spark con un gran consumo de memoria.

Tipos de trabajadores disponibles

G.1 X

- DPU: 1 DPU (4 vCPU, 16 GB de memoria)

- Almacenamiento: disco de 94 GB (aproximadamente 44 GB libres)
- Caso de uso: consultas, uniones y transformaciones de datos; escalables y rentables para la mayoría de los trabajos

G.2 X

- DPU: 2 DPU (8 vCPU, 32 GB de memoria)
- Almacenamiento: disco de 138 GB (aproximadamente 78 GB libres)
- Caso de uso: consultas, uniones y transformaciones de datos; escalables y rentables para la mayoría de los trabajos

G.4X

- DPU: 4 DPU (16 vCPU, 64 GB de memoria)
- Almacenamiento: disco de 256 GB (aproximadamente 230 GB libres)
- Caso de uso: transformaciones, agregaciones, uniones y consultas exigentes

G.8X

- DPU: 8 DPU (32 vCPU, 128 GB de memoria)
- Almacenamiento: disco de 512 GB (aproximadamente 485 GB libres)
- Caso de uso: transformaciones, agregaciones, uniones y consultas exigentes

G.12X

- DPU: 12 DPU (48 vCPU, 192 GB de memoria)
- Almacenamiento: disco de 768 GB (aproximadamente 741 GB libres)
- Caso de uso: cargas de trabajo muy grandes que consumen muchos recursos y requieren una capacidad informática significativa

G.16X

- DPU: 16 DPU (64 vCPU, 256 GB de memoria)
- Almacenamiento: disco de 1024 GB (aproximadamente 996 GB libres)

- Caso de uso: las cargas de trabajo más grandes que consumen la mayor cantidad de recursos y requieren la capacidad informática máxima

R.1X: optimizado para la memoria*

- DPU: 1 M-DPU (4 vCPU, 32 GB de memoria)
- Caso de uso: cargas de trabajo con una gran consumo de memoria y con errores frecuentes de falta de memoria o que requieren una alta relación entre memoria y CPU

R.2X: optimizado para la memoria*

- DPU: 2 M-DPU (8 vCPU, 64 GB de memoria)
- Caso de uso: cargas de trabajo con una gran consumo de memoria y con errores frecuentes de falta de memoria o que requieren una alta relación entre memoria y CPU

R.4X: optimizado para la memoria*

- DPU: 4 M-DPU (16 vCPU, 128 GB de memoria)
- Caso de uso: cargas de trabajo grandes con un gran consumo de memoria y con errores frecuentes de falta de memoria o que requieren una alta relación entre memoria y CPU

R.8X: optimizado para la memoria*

- DPU: 8 M-DPU (32 vCPU, 256 GB de memoria)
- Caso de uso: cargas de trabajo muy grandes con una gran consumo de memoria y con errores frecuentes de falta de memoria o que requieren una alta relación entre memoria y CPU

* Puede tener una mayor latencia de inicio con estos trabajadores. Para resolver este problema, pruebe lo siguiente:

- Espere unos minutos y después envíe el trabajo de nuevo.
- Envíe un nuevo trabajo con menos trabajadores.
- Envíe un nuevo trabajo con un tipo o tamaño de trabajador diferente.

Tabla de especificaciones del tipo de trabajador

Especificaciones del tipo de trabajador

Tipo de trabajador	DPU por nodo	vCPU	Memoria (GB)	Disco (GB)	Espacio libre en el disco aproximado (GB)	Ejecutores de Spark por nodo
G.1 X	1	4	16	94	44	1
G.2 X	2	8	32	138	78	1
G.4X	4	16	64	256	230	1
G.8X	8	32	128	512	485	1
G.12X	12	48	192	768	741	1
G.16X	16	64	256	1024	996	1
R.1X	1	4	32	94	44	1
R.2X	2	8	64	138	78	1
R.4X	4	16	128	256	230	1
R.8X	8	32	256	512	485	1

Nota: Los tipos de trabajadores R tienen configuraciones optimizadas para cargas de trabajo que consumen mucha memoria.

Consideraciones importantes

Latencia de inicio

> **Important**
>
> Los tipos de trabajadores G.12X y G.16X, así como todos los tipos de trabajadores R (de R.1X a R.8X), pueden tener una latencia de inicio más alta. Para resolver este problema, pruebe lo siguiente:
>
> - Espere unos minutos y después envíe el trabajo de nuevo.
> - Envíe un nuevo trabajo con menos trabajadores.
> - Envíe un nuevo trabajo con un tipo y tamaño de trabajador diferente.

Elección del tipo de trabajador correcto

Para cargas de trabajo de ETL estándar

- G.1X o G.2X: los más rentables para las típicas uniones, consultas y transformaciones de datos
- G.4X o G.8X: para cargas de trabajo más exigentes con conjuntos de datos más grandes

Para cargas de trabajo a gran escala

- G.12X: para conjuntos de datos muy grandes que requieren recursos informáticos considerables
- G.16X: la capacidad informática máxima para las cargas de trabajo más exigentes

Para cargas de trabajo con un gran consumo de memoria

- R.1X o R.2X: trabajos con un gran consumo de memoria de tamaño pequeño a mediano
- R.4X o R.8X: grandes cargas de trabajo con un gran consumo de memoria y frecuentes errores de falta de memoria

Consideraciones sobre optimización de costos

- Trabajadores estándar G: proporcionan un equilibrio entre los recursos informáticos, de memoria y de red, y se pueden usar para una variedad de cargas de trabajo diversas a un costo menor.

- Trabajadores R: están especializados para tareas con un gran consumo de memoria con un rendimiento rápido para cargas de trabajo que procesan grandes conjuntos de datos en la memoria.

Prácticas recomendadas

Directrices de selección de trabajadores

1. Comience con los trabajadores estándar (G.1X, G.2X) para la mayoría de las cargas de trabajo.
2. Use trabajadores R cuando reciba errores de falta de memoria frecuentes o tenga cargas de trabajo con operaciones que consumen mucha memoria, como el almacenamiento en caché, la mezcla de datos y las agregaciones.
3. Considere usar G.12X/G.16X para cargas de trabajo con requisitos informáticos altos que requieren el máximo de recursos.
4. Tenga en cuenta las limitaciones de capacidad al usar nuevos tipos de trabajadores en flujos de trabajo con restricciones de tiempo.

Optimización del rendimiento

- Supervise las métricas de CloudWatch para comprender la utilización de los recursos.
- Use los recuentos de trabajadores adecuados en función del tamaño y la complejidad de los datos.
- Considere usar estrategias de partición de datos para optimizar la eficiencia de los trabajadores.

Trabajos ETL de streaming en AWS Glue

Puede crear trabajos de extracción, transformación y carga (ETL) de streaming que se ejecuten continuamente, consuman datos de orígenes de streaming como Amazon Kinesis Data Streams, Apache Kafka y Amazon Managed Streaming for Apache Kafka (Amazon MSK). Los trabajos limpian y transforman los datos y, a continuación, cargan los resultados en los lagos de datos de Amazon S3 o en los almacenes de datos JDBC.

Además, puede generar datos para los flujos de Amazon Kinesis Data Streams. Esta característica solo está disponible al escribir scripts de AWS Glue. Para obtener más información, consulte the section called “Conexión de Kinesis”.

De forma predeterminada, AWS Glue procesa y escribe datos en periodos de 100 segundos. Esto permite que los datos se procesen de forma eficiente y permite que las agregaciones se realicen

en los datos que lleguen más tarde de lo previsto. Puede modificar este tamaño de ventana para aumentar la puntualidad o la precisión de la agregación. Los trabajos de streaming de AWS Glue utilizan puntos de control en lugar de marcadores de trabajo para rastrear los datos leídos.

> **Note**
>
> AWS Glue factura por hora para trabajos de ETL de streaming mientras se están ejecutando.

Este video analiza los desafíos de costos de ETL de streaming y las funciones de ahorro de costos en AWS Glue.

La creación de un trabajo ETL de streaming consta de los siguientes pasos:

1. Para un origen de streaming de Apache Kafka, cree una conexión de AWS Glue al origen de Kafka o al clúster de Amazon MSK.
2. Cree manualmente una tabla del Catálogo de datos para el origen de streaming.
3. Cree un trabajo ETL para el origen de datos de streaming. Defina propiedades de trabajo específicas de streaming y proporcione su propio script o también puede modificar el script generado.

Para obtener más información, consulte ETL de streaming en AWS Glue.

Al crear un trabajo de ETL de streaming para Amazon Kinesis Data Streams, no es necesario crear una conexión de AWS Glue. Sin embargo, si hay una conexión asociada al trabajo de ETL de streaming de AWS Glue que tenga Kinesis Data Streams como origen, se requiere un punto de enlace de la nube privada virtual (VPC) para Kinesis. Para obtener más información, consulte Creación de un punto de conexión de interfaz en la Guía del usuario de Amazon VPC. Al especificar un flujo de Amazon Kinesis Data Streams en otra cuenta, debe configurar los roles y las políticas para permitir el acceso entre cuentas. Para obtener más información, consulte Ejemplo: leer desde un flujo de Kinesis en una cuenta diferente.

Los trabajos de ETL de streaming en AWS Glue pueden detectar automáticamente datos comprimidos, descomprimir de forma transparente los datos de streaming, realizar las transformaciones habituales en el origen de entrada y cargarlos en el almacén de salida.

AWS Glue admite la descompresión automática para los siguientes tipos de compresión dado el formato de entrada:

Tipo de compresión	Archivo Avro	Datos de Avro	JSON	CSV	Grok
BZIP2	Sí	Sí	Sí	Sí	Sí
GZIP	No	Sí	Sí	Sí	Sí
SNAPPY	Sí (Snappy sin formato)	Sí (con encuadre de Snappy)	Sí (con encuadre de Snappy)	Sí (con encuadre de Snappy)	Sí (con encuadre de Snappy)
XZ	Sí	Sí	Sí	Sí	Sí
ZSTD	Sí	No	No	No	No
DEFLATE	Sí	Sí	Sí	Sí	Sí

Temas

- Creación de una conexión de AWS Glue para un flujo de datos Apache Kafka
- Creación de una tabla del Catálogo de datos para un origen de streaming
- Notas y restricciones para orígenes de streaming de Avro
- Aplicación de patrones Grok a orígenes de streaming
- Definición de propiedades de trabajo para un trabajo ETL de streaming
- Notas y restricciones de ETL de streaming

Creación de una conexión de AWS Glue para un flujo de datos Apache Kafka

Para leer en una transmisión de Apache Kafka, debe crear una conexión de AWS Glue.

Para crear una conexión de AWS Glue para un origen de Kafka (consola)

1. Abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. En el panel de navegación, en Data catalog (Catálogo de datos), elija Connections (Conexiones).
3. Elija Agregar conexión y, en la página Configurar las propiedades de la conexión escriba un nombre de conexión.

> **Note**
>
> Para obtener más información acerca de cómo especificar propiedades de conexión, consulte Propiedades de conexión de AWS Glue.

4. En Tipo de conexión, elija Kafka.
5. Para Kafka bootstrap servers URLs (URL de servidores de arranque Kafka), ingrese el host y el número de puerto de los agentes de arranque para su clúster de Amazon MSK o Apache Kafka. Utilice sólo los puntos de enlace de Transport Layer Security (TLS) para establecer la conexión inicial con el clúster de Kafka. No se admiten puntos de enlace de texto no cifrado.

   A continuación se ofrece una lista de pares de nombre de host y número de puerto para un clúster de Amazon MSK a modo de ejemplo.

   ```
   myserver1.kafka.us-east-1.amazonaws.com:9094,myserver2.kafka.us-
   east-1.amazonaws.com:9094,
   myserver3.kafka.us-east-1.amazonaws.com:9094
   ```

   Para obtener más información sobre cómo obtener la información del agente de arranque, consulte Obtener los agentes de arranque para un clúster de Amazon MSK en la Guía para desarrolladores de Amazon Managed Streaming for Apache Kafka.
6. Si desea una conexión segura al origen de datos de Kafka, seleccione Require SSL connection (Solicitar conexión SSL), y para Kafka private CA certificate location (Ubicación del certificado de CA privado de Kafka), ingrese una ruta válida de Amazon S3 a un certificado SSL personalizado.

   Para una conexión SSL a Kafka autoadministrado, el certificado personalizado es obligatorio. Es opcional para Amazon MSK.

   Para obtener más información sobre cómo especificar un certificado personalizado para Kafka, consulte the section called “Propiedades de las conexiones SSL”.
7. Use AWS Glue Studio o CLI AWS para especificar un método de autenticación de cliente Kafka. Para obtener acceso a AWS Glue Studio, seleccione AWS Glue en el menú ETL en el panel de navegación izquierdo.

   Para obtener más información acerca de los métodos de autenticación de cliente Kafka, consulte Propiedades de conexión de AWS Glue Kafka para autenticación de clientes .
8. Si lo desea, escriba una descripción y, a continuación, elija Next (Siguiente).

9. Para un clúster de Amazon MSK, especifique la nube virtual privada (VPC), su subred y el grupo de seguridad. La información de la VPC es opcional para Kafka autoadministrado.
10. Elija Next (Siguiente) para revisar todas las propiedades de conexión y, a continuación, elija Finish (Finalizar).

Para obtener más información acerca de las conexiones de AWS Glue, consulte Conexión a datos.

Propiedades de conexión de AWS Glue Kafka para autenticación de clientes

Autenticación SASL/GSSAPI (Kerberos)

La elección de este método de autenticación le permitirá especificar propiedades de Kerberos.

Keytab de Kerberos

Seleccione la ubicación del archivo keytab. Una keytab almacena claves a largo plazo para uno o varias entidades principales. Para obtener más información, consulte MIT Kerberos Documentation: Keytab (Documentación de MIT Kerberos: Keytab).

Archivo Kerberos krb5.conf

Seleccione el archivo krb5.conf. Contiene el dominio predeterminado (una red lógica, similar a un dominio, que define un grupo de sistemas bajo el mismo KDC) y la ubicación del servidor KDC. Para obtener más información, consulte MIT Kerberos Documentation: krb5.conf (Documentación de MIT Kerberos: krb5.conf).

Nombre principal y nombre de servicio de Kerberos

Ingrese el nombre principal y el de servicio de Kerberos. Para obtener más información, consulte la documentación de Kerberos de MIT: principal de Kerberos.

Autenticación SASL/SCRAM-SHA-512

La elección de este método de autenticación le permitirá especificar credenciales de autenticación.

AWS Secrets Manager

Busque el token en el cuadro de búsqueda mediante el nombre o ARN.

Nombre de usuario y contraseña del proveedor directamente

Busque el token en el cuadro de búsqueda mediante el nombre o ARN.

Autenticación SSL del cliente

La elección de este método de autenticación le permite seleccionar la ubicación del almacén de claves del cliente Kafka navegando por Amazon S3. Opcionalmente, puede ingresar la contraseña del almacén de claves del cliente Kafka y la contraseña de clave de cliente Kafka.

Autenticación de IAM

Este método de autenticación no requiere especificaciones adicionales y solo se aplica cuando la fuente de streaming es Kafka para MSK.

Autenticación de SASL/PLAIN

Al elegir este método de autenticación, puede especificar las credenciales de autenticación.

Creación de una tabla del Catálogo de datos para un origen de streaming

Es posible crear de forma manual una tabla del Catálogo de datos que especifique las propiedades del flujo de datos de origen, incluido el esquema de datos, para un origen de streaming. Esta tabla se utiliza como origen de datos para el trabajo ETL de streaming.

Si no conoce el esquema de los datos en el flujo de datos de origen, puede crear la tabla sin un esquema. A continuación, cuando cree el trabajo de ETL de streaming, puede habilitar la función detección de esquema de AWS Glue. AWS Glue determinará el esquema a partir de los datos de streaming.

Utilice la consola de AWS Glue, la AWS Command Line Interface (AWS CLI) o la API de AWS Glue para crear la tabla. Para obtener información sobre cómo crear una tabla manualmente con la consola de AWS Glue, consulte the section called “Creación de tablas”.

> **Note**
>
> No puede usar la consola de AWS Lake Formation para crear la tabla; debe usar la consola de AWS Glue.

Tenga en cuenta también la siguiente información para los orígenes de streaming en formato Avro o para los datos de registro a los que puede aplicar patrones Grok.

- the section called “Notas y restricciones para orígenes de streaming de Avro”
- the section called “Aplicación de patrones Grok a orígenes de streaming”

Temas

- Origen de datos de Kinesis
- Origen de datos de Kafka
- Origen de tablas de AWS Glue Schema Registry

Origen de datos de Kinesis

Al crear la tabla, configure las siguientes propiedades de ETL de streaming (consola).

Tipo de origen

Kinesis

Para un origen de Kinesis en la misma cuenta:

Región

La región de AWS en la que reside el servicio Amazon Kinesis Data Streams. La región y el nombre del flujo de Kinesis se traducen juntos a un ARN de flujo.

Ejemplo: https://kinesis.us-east-1.amazonaws.com

Nombre de flujo de Kinesis

Nombre de la transmisión, tal como se describe en Creación de una transmisión en la Guía para desarrolladores de Amazon Kinesis Data Streams.

Para un origen de Kinesis en otra cuenta, consulte este ejemplo para configurar los roles y políticas que permitan el acceso entre cuentas. Configure estas opciones:

ARN de flujo

El ARN del flujo de datos de Kinesis con el que está registrado el consumidor. Para obtener más información, consulte Nombres de recursos de Amazon (ARNs) y espacios de nombres de servicios de AWS en la Referencia general de AWS.

ARN de rol asumido

El nombre de recurso de Amazon (ARN) del rol que se asignará.

Nombre de la sesión (opcional)

Un identificador para la sesión del rol asumido.

Utilice el nombre de la sesión del rol para identificar de forma única una sesión cuando el mismo rol es asumido por diferentes entidades o por diferentes razones. En escenarios entre

cuentas, el nombre de la sesión del rol es visible para la cuenta que es titular del rol. Esta cuenta podrá registrar el rol. El nombre de la sesión del rol también se utiliza en el ARN de la entidad principal del rol asumido. Esto significa que las solicitudes posteriores de API entre cuentas que utilizan las credenciales de seguridad temporales expondrán el nombre de la sesión del rol a la cuenta externa en sus registros de AWS CloudTrail.

Para configurar las propiedades de ETL de streaming para Amazon Kinesis Data Streams (API de AWS Glue o AWS CLI)

- Para configurar las propiedades de ETL de streaming para un origen de Kinesis en la misma cuenta, especifique los parámetros `streamName` y `endpointUrl` en la estructura `StorageDescriptor` de la operación de la API `CreateTable` o el comando de la CLI `create_table`.

```
"StorageDescriptor": {
 "Parameters": {
  "typeOfData": "kinesis",
  "streamName": "sample-stream",
  "endpointUrl": "https://kinesis.us-east-1.amazonaws.com"
 }
 ...
}
```

  O bien, especifique `streamARN`.

  Example

```
"StorageDescriptor": {
 "Parameters": {
  "typeOfData": "kinesis",
  "streamARN": "arn:aws:kinesis:us-east-1:123456789:stream/sample-stream"
 }
 ...
}
```

- Para configurar las propiedades de ETL de streaming para un origen de Kinesis en otra cuenta, especifique los parámetros `streamARN`, `awsSTSRoleARN` y `awsSTSSessionName` (opcional) en la estructura `StorageDescriptor` en la operación de la API `CreateTable` o el comando de la CLI `create_table`.

```
"StorageDescriptor": {
 "Parameters": {
  "typeOfData": "kinesis",
  "streamARN": "arn:aws:kinesis:us-east-1:123456789:stream/sample-stream",
  "awsSTSRoleARN": "arn:aws:iam::123456789:role/sample-assume-role-arn",
  "awsSTSSessionName": "optional-session"
 }
 ...
}
```

Origen de datos de Kafka

Al crear la tabla, configure las siguientes propiedades de ETL de streaming (consola).

Tipo de origen

Kafka

Para un origen de Kafka:

Nombre del tema

Nombre del tema como se especifica en Kafka.

Connection

Una conexión de AWS Glue que hace referencia a un origen de Kafka, como se describe en the section called “Crear una conexión para un flujo de datos Kafka”.

Origen de tablas de AWS Glue Schema Registry

A fin de utilizar AWS Glue Schema Registry para trabajos de streaming, siga las instrucciones de Caso de uso: AWS Glue Data Catalog para crear o actualizar una tabla de Schema Registry.

Actualmente, el streaming de AWS Glue solo soporta el formato Avro de Glue Schema Registry con inferencia de esquema establecida en `false`.

Notas y restricciones para orígenes de streaming de Avro

Las siguientes notas y restricciones corresponden a los orígenes de streaming en formato Avro:

- Cuando se activa la detección de esquemas, el esquema de Avro debe incluirse en la carga. Cuando se desactiva, la carga debe contener solo datos.
- Algunos tipos de datos de Avro no se admiten en marcos dinámicos. No se pueden especificar estos tipos de datos al definir el esquema con la página Define a schema (Definir un esquema) en el asistente de creación de tabla en la consola de AWS Glue. Durante la detección de esquemas, los tipos no soportados en el esquema Avro se convierten en tipos soportados de la siguiente manera:
  - `EnumType => StringType`
  - `FixedType => BinaryType`
  - `UnionType => StructType`
- Si define el esquema de tabla mediante la página Define a schema (Definir un esquema) en la consola, el tipo de elemento raíz implícito para el esquema es `record`. Si desea un tipo de elemento raíz distinto de `record`, por ejemplo, `array` or `map`, no puede especificar el esquema mediante la página Define a schema (Definir un esquema). En su lugar, debe omitir esa página y especificar el esquema como propiedad de tabla o dentro del script de ETL.
  - Para especificar el esquema en las propiedades de la tabla, complete el asistente de creación de tabla, edite los detalles de la tabla y agregue un nuevo par clave-valor en Table properties (Propiedades de la tabla). Utilice la clave `avroSchema`, e ingrese un objeto JSON de esquema para el valor, tal y como se muestra en la siguiente captura de pantalla.

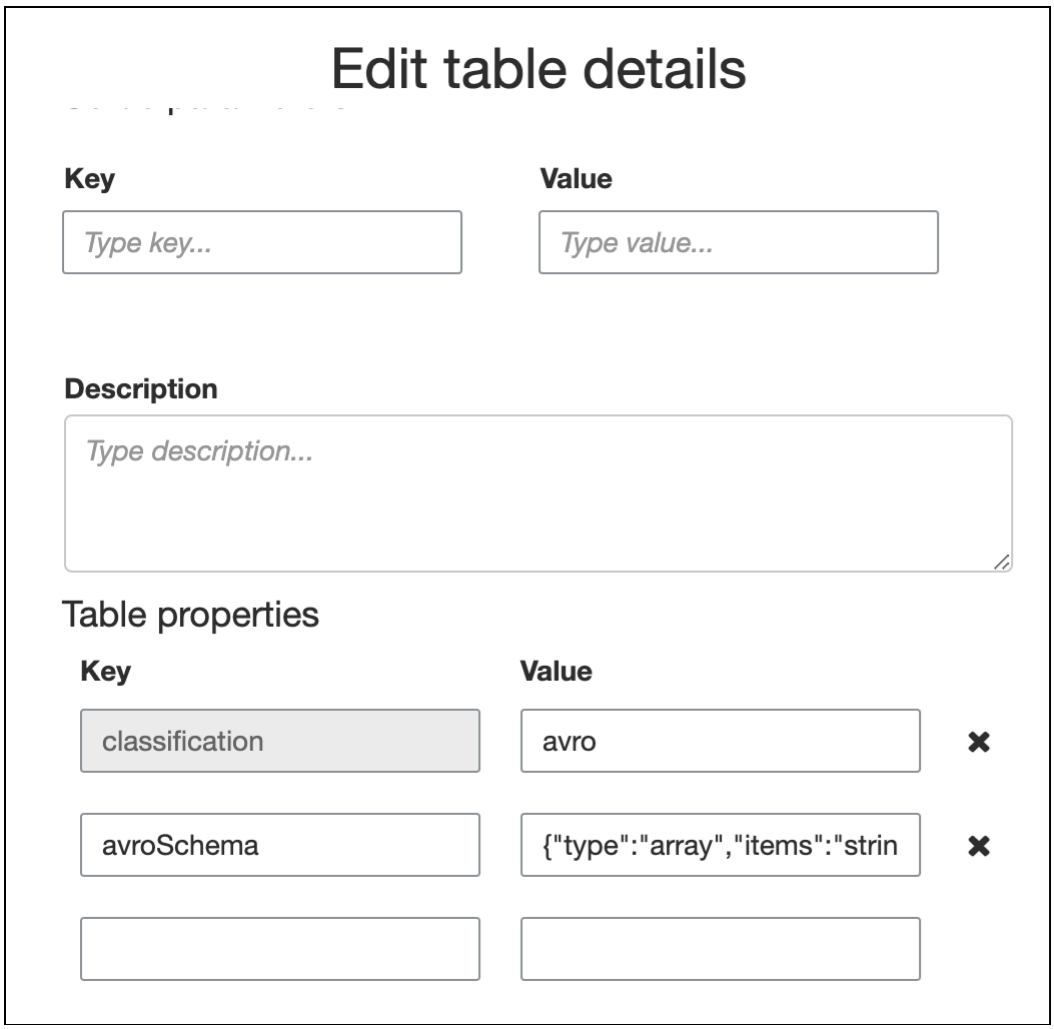

- Para especificar el esquema en el script de ETL, modifique la instrucción de asignación `datasource0` y agregue la clave `avroSchema` a la instrucción `additional_options`, tal y como se muestra en los siguientes ejemplos de Python y Scala.

  Python

  ```
  SCHEMA_STRING = '{"type":"array","items":"string"}'
  datasource0 = glueContext.create_data_frame.from_catalog(database =
   "database", table_name = "table_name", transformation_ctx = "datasource0",
   additional_options = {"startingPosition": "TRIM_HORIZON", "inferSchema":
   "false", "avroSchema": SCHEMA_STRING})
  ```

  Scala

  ```
  val SCHEMA_STRING = """{"type":"array","items":"string"}"""
  val datasource0 = glueContext.getCatalogSource(database = "database", tableName
   = "table_name", redshiftTmpDir = "", transformationContext = "datasource0",
  ```

```
additionalOptions = JsonOptions(s"""{"startingPosition": "TRIM_HORIZON",
"inferSchema": "false", "avroSchema":"$SCHEMA_STRING"}""")).getDataFrame()
```

Aplicación de patrones Grok a orígenes de streaming

Puede crear un trabajo de ETL de streaming para un origen de datos de registro y utilizar patrones Grok para convertir los registros en datos estructurados. Luego, el trabajo de ETL procesa los datos como un origen de datos estructurados. Especifique los patrones Grok que se aplicarán al crear la tabla del Catálogo de datos para el origen de streaming.

Para obtener información acerca de los patrones Grok y los valores de la cadena de patrones personalizados, consulte Escritura de clasificadores personalizados de Grok.

Para agregar patrones Grok a la tabla del Catálogo de datos (consola)

- Utilice el asistente de creación de tablas y cree la tabla con los parámetros especificados en the section called “Creación de una tabla del Catálogo de datos para un origen de streaming”. Especifique el formato de datos como Grok, complete el campo Grok pattern (Patrón de Grok) y, opcionalmente, agregue patrones personalizados en Custom patterns (Patrones personalizados) (opcional).

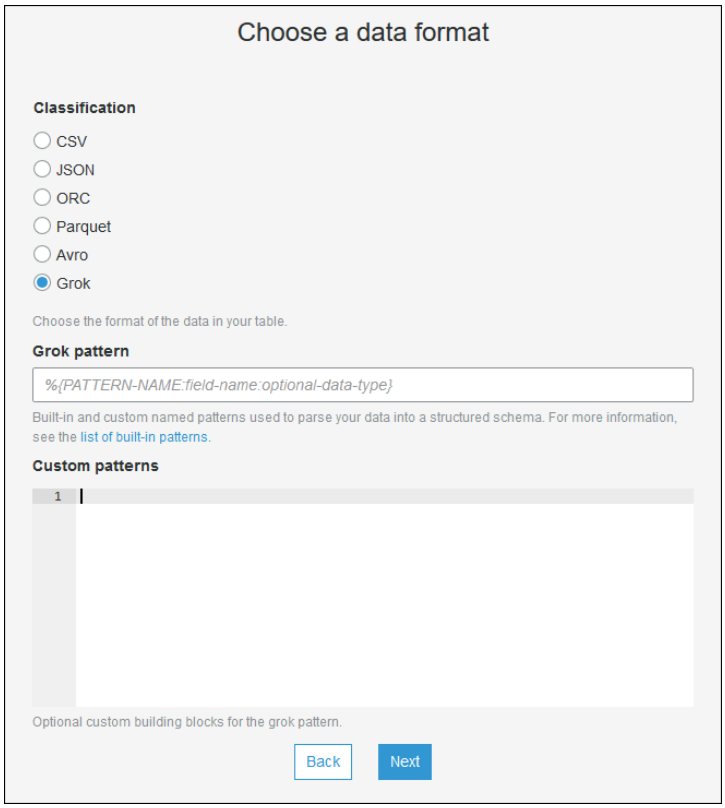

Presione Enter (Intro) después de cada patrón personalizado.

Para agregar patrones grok a la tabla del Catálogo de datos (API de AWS Glue o AWS CLI)

- Agregue el parámetro `GrokPattern` y, opcionalmente, el parámetro `CustomPatterns` a la operación de API `CreateTable` o al comando de la CLI `create_table`.

```
 "Parameters": {
...
    "grokPattern": "string",
    "grokCustomPatterns": "string",
...
},
```

Indique `grokCustomPatterns` como una cadena y use “\n” como separador entre patrones.

El siguiente ejemplo muestra cómo especificar estos parámetros.

Example

```
"parameters": {
...
    "grokPattern": "%{USERNAME:username} %{DIGIT:digit:int}",
    "grokCustomPatterns": "digit \d",
...
}
```

Definición de propiedades de trabajo para un trabajo ETL de streaming

Cuando defina un trabajo de ETL de streaming en la consola de AWS Glue, proporcione las siguientes propiedades específicas de los flujos. Para obtener propiedades de trabajo adicionales, consulte Definición de propiedades de trabajo para trabajos de Spark.

rol de IAM

Especifique el rol AWS Identity and Access Management (IAM) que se usa para dar una autorización a los recursos que se utilizan para ejecutar un trabajo, acceder a orígenes de streaming y acceder a almacenes de datos de destino.

Para acceder a Amazon Kinesis Data Streams, asocie la política `AmazonKinesisFullAccess` administrada por AWS al rol o asocie una política IAM similar que permita un acceso más detallado. Para obtener información sobre políticas de ejemplo, consulte Control del acceso a los recursos de Amazon Kinesis Data Streams mediante IAM.

Para obtener más información acerca de los permisos para ejecutar trabajos en AWS Glue, consulte Administración de identidades y accesos para AWS Glue.

Tipo

Elija Spark Streaming.

Versión de AWS Glue

La versión de AWS Glue determina las versiones de Apache Spark y Python o Scala que están disponibles para el trabajo. Elija una selección que especifique la versión de Python o Scala disponible para el trabajo. AWS Glue La versión 2.0 con soporte de Python 3 es la predeterminada para los trabajos de ETL de streaming.

Periodo de mantenimiento

Especifica una ventana en la que se puede reiniciar un trabajo de streaming. Consulte the section called “Periodos de mantenimiento”.

Job timeout (Tiempo de espera de flujo de trabajo)

Si lo desea, escriba una duración en minutos. El valor predeterminado está en blanco.

- Los trabajos de streaming deben tener un valor de tiempo de espera inferior a 7 días o 10 080 minutos.
- Si el valor se deja en blanco, el trabajo se reiniciará después de 7 días, si no ha establecido un periodo de mantenimiento. Si ha configurado un periodo de mantenimiento, el trabajo se reiniciará durante el periodo de mantenimiento después de 7 días.

Origen de datos

Elimine la tabla que creó en the section called “Creación de una tabla del Catálogo de datos para un origen de streaming”.

Destino de datos

Realice una de las siguientes acciones:

- Elija Crear tablas en el destino de datos y especifique las siguientes propiedades de destino de datos.

Almacén de datos

Seleccione Amazon S3 o JDBC.

Formato

Elija cualquier formato. Todos son compatibles para streaming.

- Elija Use tables in the data catalog and update your data target (Utilizar tablas en el Catálogo de datos y actualizar el destino de los datos) y elija una tabla para un almacén de datos JDBC.

Definición de esquema de salida

Realice una de las siguientes acciones:

- Seleccione Automatically detect schema of each record (Detectar automáticamente el esquema de cada registro) para habilitar la detección de esquemas. AWS Glue determina el esquema a partir de los datos de streaming.
- Seleccione Specify output schema for all records (Especificar esquema de salida para todos los registros) para utilizar la transformación de la función de aplicar mapeo a fin de definir el esquema de salida.

Script

Si lo desea, proporcione su propio script o modifique el script generado para realizar operaciones compatibles con el motor Apache Spark Structured Streaming. Para obtener información sobre las operaciones disponibles, consulte Operaciones en DataFrames/conjuntos de datos de streaming.

Notas y restricciones de ETL de streaming

Tenga en cuenta las siguientes notas y restricciones:

- La descompresión automática para los trabajos de ETL de streaming en AWS Glue solo está disponible para los tipos de compresión admitidos. Tenga también en cuenta lo siguiente:
  - Con encuadre de Snappy se refiere al formato de encuadre oficial para Snappy.
  - Deflate es compatible con la versión 3.0 de Glue, no con la versión 2.0.
- Cuando se utiliza la detección de esquemas, no se pueden realizar combinaciones de datos de streaming.
- Los trabajos ETL de streaming de AWS Glue no admiten el tipo de datos de la Unión para el Registro de esquemas de AWS Glue con formato Avro.

- Su script de ETL puede usar las transformaciones incorporadas de AWS Glue y las transformaciones nativas de Apache Spark Structured Streaming. Para obtener más información, consulte Operaciones en DataFrames/conjuntos de datos de streaming en el sitio web de Apache Spark o Referencia de transformaciones de PySpark de AWS Glue.
- Los trabajos de ETL de streaming de AWS Glue utilizan puntos de comprobación para realizar un seguimiento de los datos que se han leído. Por lo tanto, un trabajo detenido y reiniciado comienza donde lo dejó en la transmisión. Si desea volver a procesar los datos, puede eliminar la carpeta de puntos de control a la que se hace referencia en el script.
- No se admiten los marcadores de trabajo.
- Para la función de distribución mejorada de Kinesis Data Streams en un trabajo, consulte the section called “Uso de una distribución mejorada en los trabajos de streaming de Kinesis”.
- Si utiliza una tabla del Catálogo de datos creada a partir de AWS Glue Schema Registry, cuando se encuentre disponible una versión de esquema nueva, para reflejar el esquema nuevo, debe realizar lo siguiente:
  1. Detenga los trabajos asociados a la tabla.
  2. Actualice el esquema de la tabla del Catálogo de datos.
  3. Reinicie los trabajos asociados a la tabla.

Coincidencia de registros con FindMatches de AWS Lake Formation

> **Note**
>
> La coincidencia de registros no está disponible por el momento en las siguientes regiones de la consola de AWS Glue: Medio Oriente (EAU), Europa (España), Asia-Pacífico (Yakarta) y Europa (Zúrich).

AWS Lake Formation proporciona las capacidades de machine learning para crear transformaciones personalizadas para borrar sus datos. En la actualidad, hay una transformación disponible denominada FindMatches. La transformación FindMatches le permite identificar registros duplicados o coincidentes en el conjunto de datos, incluso cuando los registros no tienen un identificador único común y no coinciden exactamente los campos. Esto no requiere escribir ningún código ni saber cómo funciona machine learning. FindMatches puede resultar útil en muchos problemas diferentes, como:

- Coincidencia de clientes: vinculación de registros de clientes en diferentes bases de datos de clientes, incluso cuando muchos campos de clientes no coincidan exactamente en las bases de datos (por ejemplo, ortografía de nombres diferentes, diferencias de direcciones, datos que faltan o no son precisos, etc.).
- Coincidencia de productos: cotejar los productos del catálogo con otros orígenes de productos, como el catálogo de productos con el catálogo de un competidor, donde las entradas se estructuran de forma diferente.
- Mejora de la detección de fraudes: identificar cuentas de cliente duplicadas, determinar cuándo una cuenta recién creada es (o podría ser) una coincidencia para un usuario fraudulento conocido anteriormente.
- Otros problemas de coincidencia: coincidencia de direcciones, películas, listas de partes, etc. En general, si un ser humano pudiera examinar las filas de la base de datos y determinar que eran una coincidencia, existe una muy buena posibilidad de que la transformación FindMatches pueda ayudarle.

Puede crear estas transformaciones cuando cree un trabajo. La transformación que se crea se basa en un esquema de almacén de datos de origen y datos de ejemplo del conjunto de datos de origen que se etiquetan (a este proceso se lo denomina “enseñar” a una transformación). Los registros que se etiquetan deben estar presentes en el conjunto de datos de origen. En este proceso, se genera un archivo que se etiqueta y que luego se vuelve a cargar, y del que la transformación aprende en cierto modo. Después de enseñar a su transformación, puede invocarla desde su trabajo de AWS Glue basado en Spark (PySpark o Scala Spark) y utilizarla en otros scripts con un almacén de datos de origen compatible.

Una vez que se crea la transformación, se almacena en AWS Glue. En la consola de AWS Glue, puede administrar las transformaciones que cree. En el panel de navegación, en Integración de datos y ETL, en Herramientas de clasificación de datos > Coincidencia de registros, puede editar y entrenar su transformación de machine learning. Para obtener más información sobre la administración de transformaciones en la consola, consulte Uso de transformaciones de machine learning.

> **Note**
>
> Los trabajos de FindMatches de AWS Glue versión 2.0 utilizan el bucket de Amazon S3 `aws-glue-temp-<accountID>-<region>` para almacenar archivos temporales mientras la transformación procesa datos. Puede eliminar estos datos una vez finalizada la ejecución,

ya sea en forma manual o mediante la configuración de una regla de ciclo de vida de Amazon S3.

Tipos de transformaciones de machine learning

Puede crear transformaciones de machine learning para limpiar sus datos. Puede llamar a estas transformaciones desde el script de ETL. Los datos pasan de transformación en transformación en una estructura de datos denominada DynamicFrame, que es una extensión de `DataFrame` de Apache Spark SQL. `DynamicFrame` contiene sus datos y usted hace referencia a su esquema para procesar los datos.

Los tipos de transformaciones de machine learning disponibles son los siguientes:

Búsqueda de coincidencias

Permite buscar registros duplicados en los datos de origen. Enseñe esta transformación de machine learning mediante el etiquetado de conjuntos de datos de ejemplo para indicar las filas que coinciden. La transformación de machine learning aprende qué filas deben ser coincidencias a medida que usted se lo va enseñando utilizando datos etiquetados de ejemplo. En función de cómo configure la transformación, se genera una de las siguientes salidas:

- Una copia de la tabla de entrada además de una columna `match_id` completada con valores que indican conjuntos de coincidencia de registros. La columna `match_id` es un identificador arbitrario. Cualquier registro que tenga el mismo `match_id` se ha identificado como coincidente entre sí. Los registros con diferentes `match_id`no coinciden.
- Una copia de la tabla de entrada con las filas duplicadas eliminadas. Si se detectan varios duplicados, se guarda el registro con el menor clave principal.

Búsqueda de coincidencias progresivas

La transformación Buscar coincidencias también se puede configurar para buscar coincidencias en los fotogramas existentes y progresivos y devolver como salida una columna que contiene un ID único por grupo de coincidencias.

Para obtener más información, consulte: Búsqueda de coincidencias progresivas

Uso de la transformación FindMatches

Puede utilizar la transformación `FindMatches` para buscar registros duplicados en los datos de origen. Se genera un archivo de etiquetado o se proporciona para ayudar a enseñar a la transformación.

> **Note**
>
> En la actualidad, las transformaciones de `FindMatches` que utilizan una clave de cifrado personalizada no se soportan en las siguientes regiones:
>
> - Asia-Pacífico (Osaka): `ap-northeast-3`

Para empezar con la transformación FindMatches, puede seguir los pasos que se indican a continuación. Para obtener un ejemplo más avanzado y detallado, consulte el blog sobre macrodatos de AWS: Armonizar los datos con la ML de FindMatches AWS Glue y AWS Lake Formation para crear una vista 360 del cliente.

Introducción al uso de la transformación de FindMatches

Siga estos pasos para iniciar la transformación de `FindMatches`:

1. Cree una tabla en AWS Glue Data Catalog para los datos de origen que tienen que borrarse. Para obtener información sobre cómo crear un rastreador, consulte Trabajar de rastreadores en la consola de AWS Glue.

   Si los datos de origen son un archivo basado en texto como un archivo de valores separados por comas (CSV), tenga en cuenta lo siguiente:

   - Mantenga el archivo de etiquetado y el archivo CSV de registro de entrada en carpetas independientes. De lo contrario, el rastreador de AWS Glue podría considerarlos como varias partes de la misma tabla y crear tablas en el Catálogo de datos de forma incorrecta.
   - A menos que su archivo CSV incluya únicamente caracteres ASCII, asegúrese de que se utiliza UTF-8 sin codificación BOM (byte order mark, marca de orden de bytes) para los archivos CSV. Microsoft Excel a menudo añade una BOM al principio de archivos CSV UTF-8. Para eliminarlo, abra el archivo CSV en un editor de texto y vuelva a guardar el archivo como UTF-8 sin BOM.
2. En la consola AWS Glue, cree un trabajo y elija el tipo de transformación de búsqueda de coincidencias.

> **Important**
>
> La tabla de origen de datos que elija para el trabajo no puede tener más de 100 columnas.

3. AWS Glue Indique a que genere un archivo de etiquetado eligiendo Generate labeling file (Generar archivo de etiquetado). AWS Glue realiza la primera pasada al agrupar registros similares para cada uno de ellos para que `labeling_set_id` pueda revisar esas agrupaciones. Las coincidencias se etiquetan en la columna `label`.
   - Si ya tiene un archivo de etiquetado, es decir, un ejemplo de registros que indican filas de coincidencia, cargue el archivo en Amazon Simple Storage Service (Amazon S3). Para obtener más información sobre el formato del archivo de etiquetado, consulte Formato de archivo de etiquetado. Continúe con el paso 4.
4. Descargue el archivo de etiquetado y etiquete el archivo tal y como se describe en la sección Etiquetado.
5. Cargue el archivo de etiquetado corregido. AWS Glue ejecuta tareas para enseñar a la transformación cómo encontrar coincidencias.

   En la página de lista Machine learning transforms (Transformaciones de machine learning), elija la pestaña History (Historial). Esta página indica cuándo AWS Glue realiza las siguientes tareas:
   - Importar etiquetas
   - Exportar etiquetas
   - Generar etiquetas
   - Estimar calidad
6. Para crear una mejor transformación, puede descargar, etiquetar y cargar de forma iterativa el archivo de etiquetado. En las ejecuciones iniciales, es posible que una gran cantidad de registros no coincidan. Sin embargo, AWS Glue aprende a medida que sigue enseñándole mediante la comprobación del archivo de etiquetado.
7. Evalúe y ajuste su transformación mediante la evaluación del rendimiento y resultados de búsqueda de coincidencias. Para obtener más información, consulte Ajuste de transformaciones de machine learning en AWS Glue.

Etiquetado

Cuando `FindMatches` genera un archivo de etiquetado, los registros se seleccionan en la tabla de origen. En función del entrenamiento anterior, `FindMatches` identifica los registros más valiosos de los que puede aprender.

La acción de etiquetado consiste en editar un archivo (le recomendamos que utilice una hoja de cálculo como Microsoft Excel) y agregar en la columna `label` identificadores o etiquetas que identifiquen los registros coincidentes y no coincidentes. Es importante disponer de una definición clara y coherente de las coincidencias en los datos de origen. `FindMatches` aprende a partir de los registros que se designan (o no) como coincidencias y utiliza estas decisiones para aprender a buscar registros duplicados.

Cuando `FindMatches` genere un archivo de etiquetado, se generarán aproximadamente 100 registros. Estos 100 registros normalmente se dividen en 10 conjuntos de etiquetado, cada uno de los cuales se identifica mediante un `labeling_set_id` único generado por `FindMatches`. Cada conjunto de etiquetado debe considerarse como una tarea de etiquetado independiente de los demás conjuntos de etiquetado. Su tarea consiste en identificar registros coincidentes y no coincidentes dentro de cada conjunto de etiquetado.

Sugerencias para editar archivos de etiquetado en una hoja de cálculo.

Cuando edite el archivo de etiquetado en una aplicación de hoja de cálculo, tenga en cuenta lo siguiente:

- Es posible que el archivo no se abra con los campos de columna totalmente expandidos. Puede que tenga que expandir las columnas `labeling_set_id` y `label` para ver el contenido de esas celdas.
- Si la columna de clave principal es un nombre, como un tipo de datos `long`, es posible que la hoja de cálculo la interprete como un número y cambie el valor. Este valor de la clave debe tratarse como texto. Para solucionar este problema, dé formato a todas las celdas en la columna de clave principal como datos de texto.

Formato de archivo de etiquetado

El archivo de etiquetado que AWS Glue genera para enseñar a su transformación `FindMatches` utiliza el siguiente formato. Si genera su propio archivo de AWS Glue, también debe utilizar este formato:

- Es un archivo de valores separados por comas (CSV).
- Debe estar codificado en `UTF-8`. Si edita el archivo con Microsoft Windows, se puede codificar con `cp1252`.
- Debe ser una ubicación de Amazon S3 para transferirlo a AWS Glue.
- Use una cantidad de filas moderada para cada tarea de etiquetado. Se recomiendan entre 10 y 20 filas por tarea, aunque se considera aceptable utilizar entre 2 y 30 filas. No se recomiendan tareas de más de 50 filas, ya que pueden generar resultados deficientes o errores en el sistema.
- Si dispone de datos que ya están etiquetados y que se componen de pares de registros etiquetados como «coincidencia» o «no coincidencia», puede utilizarlos. Estos pares etiquetados pueden representarse como conjuntos de etiquetado de tamaño 2. En este caso, etiquete los dos registros, por ejemplo, con una letra «A» si coinciden y, si no coinciden, etiquete uno como «A» y otro como «B».

  > **Note**
  >
  > Puesto que dispone de columnas adicionales, el archivo de etiquetado dispone de un esquema diferente de un archivo que contiene sus datos de origen. Coloque el archivo de etiquetado en una carpeta diferente de cualquier archivo CSV de entrada de transformación de manera que el rastreador de AWS Glue no lo tenga en cuenta cuando cree las tablas en el Catálogo de datos. De lo contrario, las tablas creadas por el rastreador de AWS Glue podrían representar incorrectamente sus datos.

- AWS Glue requiere las dos primeras columnas (`labeling_set_id` y `label`). Las columnas restantes deben coincidir con el esquema de los datos que se van a procesar.
- En cada `labeling_set_id`, debe identificar todos los registros coincidentes utilizando la misma etiqueta. Una etiqueta es una cadena única que se incluye en la columna `label`. Le recomendamos utilizar etiquetas que contengan caracteres simples, como A, B, C, etc. Las etiquetas distinguen mayúsculas y minúsculas y se colocan en la columna `label`.
- Se entiende que las filas que contienen el mismo `labeling_set_id` y la misma etiqueta se etiquetan como coincidencia.
- Se entiende que las filas que contienen el mismo `labeling_set_id` y una etiqueta diferente se etiquetan como no coincidencia.
- Se entiende que las filas que contienen un `labeling_set_id` diferente no transmiten información que permita determinar si es o no una coincidencia.

A continuación se muestra un ejemplo de etiquetado de los datos:

labeling_set_id	etiqueta	first_name	last_name	Birthday
ABC123	A	John	Doe	04/01/1980
ABC123	B	Jane	Smith	04/03/1980
ABC123	A	Johnny	Doe	04/01/1980
ABC123	A	Jon	Doe	04/01/1980
DEF345	A	Richard	Jones	12/11/1992
DEF345	A	Rich	Jones	11/12/1992
DEF345	B	Sarah	Jones	12/11/1992
DEF345	C	Richie	Jones Jr.	05/06/2017
DEF345	B	Sarah	Jones-Walker	12/11/1992
GHI678	A	Robert	Miller	1/3/1999
GHI678	A	Bob	Miller	1/3/1999
XYZABC	A	William	Robinson	2/5/2001
XYZABC	B	Andrew	Robinson	2/5/1971

- En el ejemplo anterior identificamos a John/Johnny/Jon Doe como una coincidencia y enseñamos al sistema que estos registros no coinciden con Jane Smith. Por otro lado, enseñamos al sistema que Richard y Rich Jones son la misma persona, pero que estos registros no coinciden con Sarah Jones/Jones-Walker ni Richie Jones Jr.
- Como puede ver, el alcance de las etiquetas está limitado por el `labeling_set_id`. Por lo tanto, las etiquetas no superan los límites de `labeling_set_id`. Por ejemplo, una etiqueta "A" en `labeling_set_id` 1 no tiene ninguna relación con la etiqueta "A" en `labeling_set_id` 2.
- Si un registro no tiene coincidencias dentro de un conjunto de etiquetado, debe asignarle una etiqueta única. Por ejemplo, Jane Smith no coincide con ningún registro del conjunto de etiquetado ABC123, por lo que es el único registro de ese conjunto de etiquetado con la etiqueta B.

- El conjunto de etiquetado «GHI678" demuestra que un conjunto de etiquetado puede componerse exclusivamente de dos registros a los que se les da la misma etiqueta para indicar que coinciden. Del mismo modo, «XYZABC» muestra dos registros con etiquetas diferentes para indicar que no coinciden.
- Tenga en cuenta que a veces los conjuntos de etiquetado pueden no contener coincidencias (es decir, cada registro del conjunto de etiquetado tiene una etiqueta diferente) o tener todos los registros iguales (todos con la misma etiqueta). Esto es correcto siempre que, colectivamente, los conjuntos de etiquetado contengan ejemplos de registros que sean iguales y diferentes, según sus criterios.

> **Important**
>
> Confirme que el rol de IAM que transfiere a AWS Glue tenga acceso al bucket de Amazon S3 que contiene el archivo de etiquetado. Convencionalmente, las políticas de AWS Glue conceden permiso a buckets o carpetas de Amazon S3 cuyos nombres tienen el prefijo aws-glue-. Si sus archivos de etiquetado están en una ubicación distinta, agregue permiso a esa ubicación en el rol de IAM.

Ajuste de transformaciones de machine learning en AWS Glue

Puede ajustar las transformaciones de machine learning en AWS Glue para mejorar los resultados de sus trabajos de limpieza de datos para cumplir sus objetivos. Para mejorar su transformación, puede enseñarle mediante la generación de un conjunto de etiquetas, la adición de etiquetas y, a continuación, la repetición de estos pasos varias veces hasta que disponga de los resultados deseados. También puede realizar el ajuste al modificar algunos parámetros de machine learning.

Para obtener más información sobre las transformaciones de machine learning, consulte Coincidencia de registros con FindMatches de AWS Lake Formation.

Temas

- Mediciones de machine learning
- Decidir entre precisión y exhaustividad
- Decisión entre exactitud y costo
- Estimación de la calidad de coincidencias mediante las puntuaciones de confianza de las coincidencias

- Enseñanza de la transformación de búsqueda de coincidencias

Mediciones de machine learning

Para comprender las mediciones que se utilizan para ajustar la transformación de machine learning, debe estar familiarizado con la siguiente terminología:

Verdadero positivo (VP)

Una coincidencia en los datos que ha encontrado la transformación correctamente. Se denomina a veces "acierto".

Verdadero negativo (VN)

Una no coincidencia en los datos que la transformación ha rechazado correctamente.

Falso positivo (FP)

Una no coincidencia en los datos que la transformación clasificó erróneamente como una coincidencia, que, en ocasiones, se denomina falsa alarma.

Falso negativo (FN)

Una coincidencia en los datos que la transformación no encontró. Se denomina a veces "fallo".

Para obtener más información sobre la terminología que se utiliza en el machine learning, consulte Confusion matrix (Matriz de confusión) en Wikipedia.

Para ajustar sus transformaciones de machine learning, puede cambiar el valor de las siguientes mediciones en la sección de propiedades avanzadas de la transformación.

- Precisión mide qué tan bien la transformación encuentra verdaderos positivos entre el número total de registros que identifica como positivos (verdaderos positivos y falsos positivos). Para obtener más información, consulte Precisión y exhaustividad en Wikipedia.
- La exhaustividad mide la facilidad con la que de la transformación encuentra verdaderos positivos en los registros totales en los datos de origen. Para obtener más información, consulte Precisión y exhaustividad en Wikipedia.
- Laexactitud mide la facilidad con la que la transformación encuentra verdaderos positivos y verdaderos negativos. El aumento de la exactitud requiere más recursos informáticos y costos. Sin embargo, también genera una mayor exhaustividad. Para obtener más información, consulte Precisión y exactitud en Wikipedia.

- El costo mide la cantidad de recursos informáticos y, por lo tanto, dinero, necesario para ejecutar la transformación.

Decidir entre precisión y exhaustividad

Cada transformación`FindMatches` contiene un parámetro `precision-recall`. Utilice este parámetro para especificar una de las siguientes opciones:

- Si está más preocupado por la transformación que indica falsamente que dos registros coinciden cuando realmente no lo hace, debe hacer hincapié en precisión.
- Si está más preocupado por la transformación que no detecta correctamente los registros que coinciden, debe hacer hincapié en exhaustividad.

Puede realizar esta compensación en la consola de AWS Glue o mediante las operaciones de la API de machine learning de AWS Glue.

Cuándo favorecer la precisión

Favorezca la precisión si está más preocupado por el resigo que genera `FindMatches` en un par de registros que coinciden cuando realmente no coinciden. Para favorecer la precisión, elija un valor de compensación de precisión-exhaustividad superior. Con un valor más alto, la transformación `FindMatches` requiere más evidencias para decidir que un par de registros debe coincidir. La transformación se ajusta para sesgarse hacia una situación en la que los registros no coinciden.

Por ejemplo, supongamos que va a utilizar `FindMatches` para detectar elementos duplicados en un catálogo de vídeo y proporciona un valor de precisión-exhaustividad más alto para la transformación. Si su transformación detecta incorrectamente que Star Wars: Una nueva esperanza es igual que Star Wars: El imperio contraataca, es posible que el cliente que quiere Una nueva esperanza vea El imperio contraataca. Esto sería una experiencia del cliente deficiente.

Sin embargo, si la transformación no es capaz de detectar que Star Wars: Una nueva esperanza y Star Wars: Episodio IV - Una nueva esperanza son el mismo elemento, el cliente podría confundirse al principio pero podría reconocerlos como el mismo. Sería un error, pero no tan grave como la situación anterior.

Cuándo favorecer la exhaustividad

Favorezca la exhaustividad si está más preocupado por el riesgo de que se puedan producir errores en los resultados de la transformación `FindMatches` al detectar un par de registros que en

realidad no coinciden. Para favorecer la exhaustividad, elija un valor de compensación de precisión-exhaustividad inferior. Con un valor más bajo, la transformación `FindMatches` requiere menos evidencias para decidir que un par de registros debe coincidir. La transformación se ajusta para sesgarse hacia una situación en la que los registros coinciden.

Por ejemplo, esto podría ser una prioridad para una organización de seguridad. Supongamos que quiere disponer de coincidencias de clientes en relación con una lista de defraudadores conocidos y es importante determinar si un cliente es un defraudador. Está utilizando `FindMatches` para que la lista de defraudadores coincida con la lista de clientes. Cada vez que `FindMatches` detecta una coincidencia entre las dos listas, se asigna un auditor humano para comprobar que la persona es, de hecho, un defraudador. Es posible que su organización prefiera para elegir la exhaustividad en lugar de la precisión. Es decir, puede emplear auditores para que revisen y rechacen manualmente algunos casos cuando el cliente no sea un defraudador en lugar de no poder identificar que un cliente está, de hecho, en la lista de defraudadores.

Cómo favorecer tanto la precisión como la exhaustividad

La mejor forma de mejorar tanto la precisión como la exhaustividad es etiquetar más datos. A medida que etiqueta más datos, mejora la exactitud global de la transformación `FindMatches` y, por lo tanto, tanto la precisión como la exhaustividad son superiores. Sin embargo, incluso con la transformación más precisa, siempre hay un área en gris que necesita experimentar para el favorecimiento de la precisión o la exhaustividad, o elegir un valor intermedio.

Decisión entre exactitud y costo

Cada transformación `FindMatches` contiene un parámetro `accuracy-cost`. Puede utilizar este parámetro para especificar una de las siguientes opciones:

- Si está más preocupado en que la transformación informe de forma exacta de que los dos registros coinciden, debe hacer hincapié en exactitud.
- Si está más preocupado por el costo o la velocidad de ejecución de la transformación, debe hacer hincapié en costo menor.

Puede realizar esta compensación en la consola de AWS Glue o mediante las operaciones de la API de machine learning de AWS Glue.

Cuando favorecer la exactitud

Favorezca la exactitud si está más preocupado por el riesgo de que los resultados de `find matches` no contengan coincidencias. Para favorecer la exactitud, elija un valor de compensación de exactitud-costo superior. Con un volumen más alto, la transformación `FindMatches` requiere más tiempo para realizar una búsqueda más exhaustiva para que los registros coincidan correctamente. Tenga en cuenta que con este parámetro no es menos probable que se trate incorrectamente un par de registro no coincidente como coincidencia. La transformación se ajusta para sesgarse hacia una situación de dedicación de más tiempo a buscar coincidencias.

Cuándo favorecer el costo

Favorezca el costo si está más preocupado por el costo de ejecución de la transformación `find matches` y menos por la cantidad de coincidencias encontradas. Para favorecer el costo, elija un valor de compensación de exactitud-costo inferior. Con un valor inferior, la transformación `FindMatches` requiere menos recursos que ejecutar. La transformación se ajusta para sesgarse hacia una situación de búsqueda de menos coincidencias. Si los resultados son aceptables cuando se favorece el costo inferior, utilice esta configuración.

Cómo favorecer tanto la exactitud como el costo bajo

Es necesario más tiempo de procesamiento para examinar más pares de registros y determinar si deben ser coincidencias. Si desea reducir el costo sin reducir la calidad, estas son algunas medidas que puede adoptar:

- Eliminación de registros en el origen de datos para el que lo le preocupa la coincidencia.
- Eliminación de columnas de origen de datos de las que esté seguro de que no son útiles para crear una decisión de coincidencia/no coincidencia. Una buena forma de decidir esto es eliminar columnas que cree que no afectan a su propia decisión sobre si un conjunto de registros es "el mismo".

Estimación de la calidad de coincidencias mediante las puntuaciones de confianza de las coincidencias

Las puntuaciones de confianza de coincidencias proporcionan una estimación de la calidad de las coincidencias encontradas por FindMatches para distinguir entre registros coincidentes en los que el modelo de machine learning es muy confiable, incierto o improbable. Una puntuación de confianza de coincidencia estará entre 0 y 1, donde una puntuación más alta significa mayor similitud. El análisis de las puntuaciones de confianza de coincidencias le permite distinguir entre grupos de coincidencias en los que el sistema tiene mucha confianza (que puede decidir fusionar), clústeres

sobre los que el sistema no está seguro (que puede decidir hacer revisar por un humano) y clústeres que el sistema considera improbables (que puede decidir rechazar).

Es posible que quiera ajustar sus datos de formación en situaciones en las que vea una puntuación de confianza alta, pero determine que no hay coincidencias, o en las que vea una puntuación baja pero determine que sí hay, de hecho, coincidencias.

Las puntuaciones de confianza son especialmente útiles cuando hay conjuntos de datos industriales de gran tamaño, en los que no es factible revisar todas las decisiones de FindMatches.

Las puntuaciones de confianza de coincidencias están disponibles en AWS Glue, versión 2.0 o posterior.

Generación de puntuaciones de confianza de coincidencias

Puede generar puntuaciones de confianza de coincidencias al establecer el valor booleano de `computeMatchConfidenceScores` a verdadero cuando llama a la API `FindMatches` o `FindIncrementalMatches`.

AWS Glue agrega una nueva `column match_confidence_score` al resultado.

Ejemplos de puntuación de coincidencias

Por ejemplo, considere los siguientes registros coincidentes:

Puntuación >=0,9

Resumen de registros coincidentes:

```
  primary_id  |   match_id  | match_confidence_score

3281355037663    85899345947   0.9823658302132061
1546188247619    85899345947   0.9823658302132061
```

Detalles:

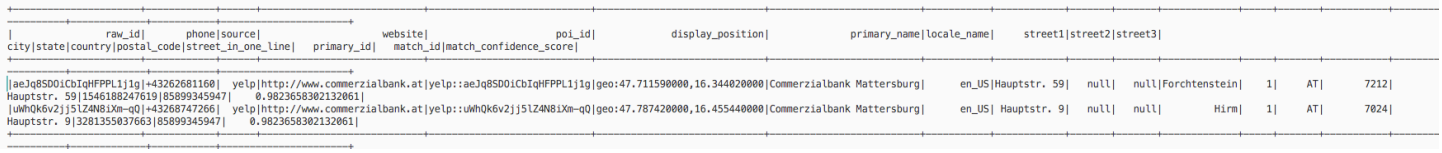

```
+------------+-----------+------+--------------------+--------------------+--------------------+-------------+--------------------+-----------+-------+-------+-----+-------+-----+-------+-----+-------+-----+-------+
|                raw_id|      phone|source|             website|              poi_id|    display_position|primary_name|locale_name|    street1|street2|street3|
city|state|country|postal_code|street_in_one_line|   primary_id|   match_id|match_confidence_score|
+------------+-----------+------+--------------------+--------------------+--------------------+-------------+--------------------+-----------+-------+-------+-----+-------+-----+-------+-----+-------+-----+-------+
|aeJq8SDOiCbIqHFPPL1j1g|+43262681160|  yelp|http://www.commerzialbank.at|yelp::aeJq8SDOiCbIqHFPPL1j1g|geo:47.711590000,16.344020000|Commerzialbank Mattersburg|      en_US|Hauptstr. 59|   null|   null|Forchtenstein|    1|     AT|       7212|
Hauptstr. 59|1546188247619|85899345947|    0.9823658302132061|
|uWhQk6v2jj5lZ4N8iXm-qQ|+43268747266|  yelp|http://www.commerzialbank.at|yelp::uWhQk6v2jj5lZ4N8iXm-qQ|geo:47.787420000,16.455440000|Commerzialbank Mattersburg|      en_US| Hauptstr. 9|   null|   null|         Hirm|    1|     AT|       7024|
Hauptstr. 9|3281355037663|85899345947|    0.9823658302132061|
+------------+-----------+------+--------------------+--------------------+--------------------+-------------+--------------------+-----------+-------+-------+-----+-------+-----+-------+-----+-------+-----+-------+
```

En este ejemplo, podemos ver que dos registros son muy similares y comparten `display_position`, `primary_name` y `street name`.

Puntuación >=0,8 y puntuación <0,9

Resumen de registros coincidentes:

```
  primary_id  |   match_id   | match_confidence_score

309237680432     85899345928   0.8309852373674638
3590592666790    85899345928   0.8309852373674638
343597390617     85899345928   0.8309852373674638
249108124906     85899345928   0.8309852373674638
463856477937     85899345928   0.8309852373674638
```

Detalles:

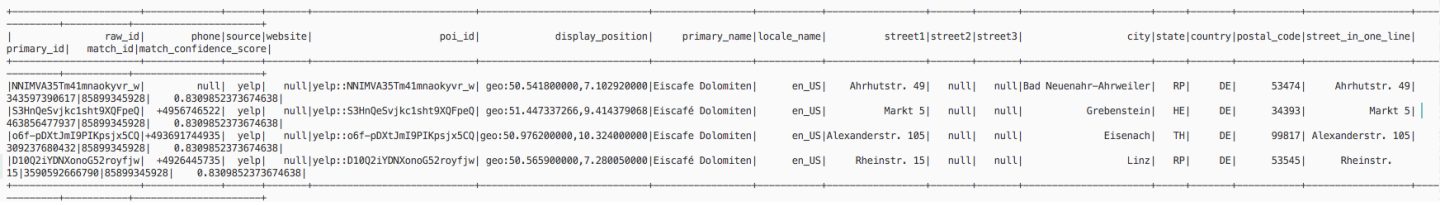

En este ejemplo, podemos ver que estos registros comparten el mismo `primary_name` y `country`.

Puntuación >=0,6 y puntuación <0,7

Resumen de registros coincidentes:

```
  primary_id  |   match_id   | match_confidence_score

2164663519676    85899345930   0.6971099896480333
 317827595278    85899345930   0.6971099896480333
 472446424341    85899345930   0.6971099896480333
3118146262932    85899345930   0.6971099896480333
 214748380804    85899345930   0.6971099896480333
```

Detalles:

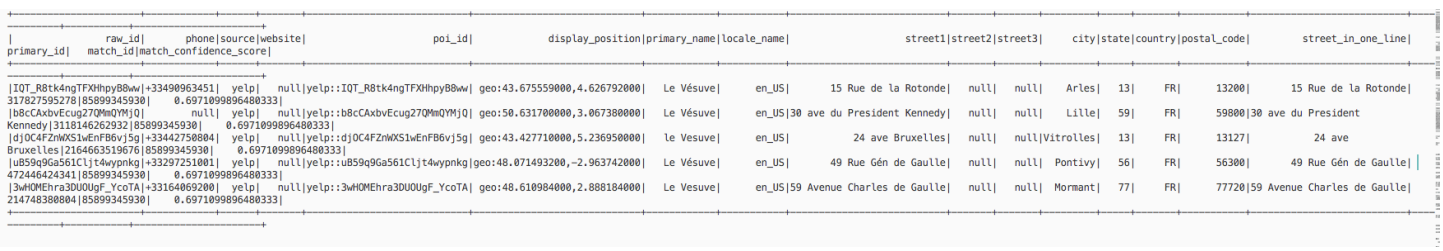

En este ejemplo, podemos ver que estos registros comparten solo el mismo `primary_name`.

Para obtener más información, consulte:

- Paso 5: Agregar y ejecutar un trabajo con su transformación de machine learning.
- PySpark: Clase FindMatches
- PySpark: Clase FindIncrementalMatches
- Scala: Clase FindMatches
- Scala: Clase FindIncrementalMatches

Enseñanza de la transformación de búsqueda de coincidencias

A las transformaciones `FindMatches` se les debe enseñar qué debe considerarse una coincidencia y qué no. Puede enseñar a su transformación mediante la adición de etiquetas en un archivo y la carga de sus opciones a AWS Glue.

Puede organizar esta etiqueta en la consola de AWS Glue o mediante las operaciones de la API de machine learning de AWS Glue.

¿Cuántas veces debo añadir etiquetas? ¿Cuántas etiquetas necesito?

Las respuestas a estas preguntas dependen principalmente de usted. Debe evaluar si `FindMatches` ofrece el nivel de exactitud que necesita y si cree que el esfuerzo de etiquetado adicional merece la pena. La mejor manera de decidir esto es analizar las métricas "Precisión", "Exhaustividad" y "Área bajo la curva de precisión-exhaustividad" que puede generar cuando elije Estimate quality (Estimar calidad) en la consola de AWS Glue. Después de etiquetar más conjuntos de tareas, vuelva a ejecutar esas métricas y compruebe si han mejorado. Si después del etiquetado de algunos conjuntos de tareas, no observa una mejora en la métrica en la que se está centrando, es posible que la calidad de la transformación se haya estabilizado.

¿Por qué las etiquetas de verdadero positivo y verdadero negativo son necesarias?

La transformación `FindMatches` precisa ejemplos positivos y negativos para aprender lo que cree que es una coincidencia. Si está etiquetando datos de entrenamiento generados por `FindMatches` (por ejemplo, mediante la opción I do not have labels [No tengo etiquetas]), `FindMatches` intenta generar un conjunto de "ID de conjuntos de etiquetas" para usted. Dentro de cada tarea, proporcione la misma "etiqueta" a algunos registros y diferentes "etiquetas" a otros. Es decir, por lo general,

las tareas no son todas iguales o todas diferentes (pero es correcto si una tarea determinada es totalmente igual o es totalmente diferente).

Si está enseñando a su transformación `FindMatches` a usar la opción Upload labels from S3 (Cargar etiquetas desde S3), intente incluir ambos ejemplos de registros de coincidencia y no coincidencia. Es aceptable disponer de solo un tipo. Estas etiquetas le ayudan a crear una transformación `FindMatches` más exacta, pero sigue necesitando etiquetas algunos registros que genera mediante la opción Generate labeling file (Generar archivo de etiquetado).

¿Cómo puedo hacer que la transformación coincida exactamente de la forma que le he enseñado?

La transformación `FindMatches` aprende a partir de las etiquetas que proporciona, por lo que puede generar pares de registros que no respeten las etiquetas proporcionadas. Para hacer que la transformación `FindMatches` respete las etiquetas, seleccione EnforceProvidedLabels en FindMatchesParameter.

¿Qué técnicas puede usar cuando una transformación ML identifica elementos como coincidencias que no son coincidencias reales?

Puede utilizar las siguientes técnicas:

- Aumente `precisionRecallTradeoff` a un valor superior. Esto provoca finalmente que se encuentren menos coincidencias, pero también debe fragmentar su clúster de gran tamaño cuando alcance un valor lo suficientemente alto.
- Elija las filas de salida correspondientes a los resultados incorrectos y vuelva a darles formato como conjunto de etiquetas (quitando la columna `match_id` y añadiendo una columna `labeling_set_id` y `label`). Si es necesario, fragmente (subdivida) en varios conjuntos de etiquetas para garantizar que la etiquetadora pueda mantener cada conjunto de etiquetas en cuenta mientras asigna etiquetas. A continuación, etiquete correctamente los conjuntos de coincidencia y cargue el archivo de etiquetas y anéxelo a sus etiquetas existentes. Esto podría enseñar a su transformador lo que necesita sobre lo que está buscando para entender el patrón.
- (Avanzado) Por último, observe los datos para ver si existe un patrón del que el sistema no informa. Preprocese esos datos mediante funciones de AWS Glue estándar para normalizar los datos. Resalte lo que desee que el algoritmo aprenda mediante la separación de datos que sepa que tienen una importancia distinta en sus propias columnas. También puede crear columnas combinadas a partir de columnas con datos que sepa que están relacionados.

Uso de transformaciones de machine learning

Puede utilizar AWS Glue para crear transformaciones de machine learning personalizadas que puedan utilizarse para limpiar sus datos. Puede usar estas transformaciones cuando cree un trabajo en la consola de AWS Glue.

Para obtener información sobre cómo crear una transformación de machine learning, consulte Coincidencia de registros con FindMatches de AWS Lake Formation.

Temas

- Propiedades de transformación
- Agregado y edición de transformaciones de machine learning
- Visualización de los detalles de la transformación
- Cómo enseñar a las transformaciones mediante el uso de etiquetas

Propiedades de transformación

Para ver una transformación de machine learning existente, inicie sesión en la Consola de administración de AWS, y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/. En el panel de navegación, en Integración de datos y ETL, elija Herramientas de clasificación de datos > Coincidencia de registros.

Las propiedades de cada transformación:

Transform name (Nombre de transformación)

El nombre único que asignó a la transformación cuando la creó.

ID

Un ID único de la transformación.

Recuento de etiquetas

La cantidad de etiquetas en el archivo de etiquetado que se proporcionó para ayudar a enseñar a la transformación.

Status

Indica si la transformación tiene el estado Ready (Listo) o Needs teaching (Necesita formación). Para ejecutar una transformación de machine learning correctamente en un trabajo, el estado debe ser Ready (Listo).

Created (Creado)

La fecha en que se creó la transformación.

Modificado

La fecha en la que se actualizó por última vez la transformación.

Descripción

La descripción suministrada para la transformación, si se ha proporcionado una.

AWS GlueVersión

La versión de AWS Glue usada.

ID de ejecución

El nombre único que asignó a la transformación cuando la creó.

Tipo de tarea

El tipo de transformación de machine learning; por ejemplo, Find matching records (Búsqueda de registros de coincidencia).

Status

Indica el estado de la ejecución de la tarea. Entre las causas posibles se incluyen las siguientes:

- Inicio
- Running
- Detención
- Stopped
- Realizado correctamente
- Failed
- Tiempo de espera

Error

Si el estado es Con error, aparece un mensaje de error que describe el motivo.

Agregado y edición de transformaciones de machine learning

Puede ver, eliminar, configurar y enseñar, o ajustar una transformación en la consola de AWS Glue. Active la casilla de verificación junto a la transformación en la lista, elija Action (Acción) y, a continuación, seleccione la acción que desee realizar.

Crear una nueva transformación de ML

Para agregar una nueva transformación de machine learning, elija Crear transformación. Siga las instrucciones en el asistente Agregar trabajo. Para obtener más información, consulte Coincidencia de registros con FindMatches de AWS Lake Formation.

Paso 1. Configure propiedades de transformación

1. Ingrese el nombre y la descripción (opcional).
2. Si lo desea, establezca la configuración de seguridad. Consulte Uso de cifrado de datos con transformaciones de machine learning.
3. Si lo desea, establezca la configuración de ejecución de tareas. La configuración de ejecución de tareas permite personalizar la forma en que se ejecuta la tarea. Seleccione el tipo de trabajador, el número de trabajadores, el tiempo de espera de la tarea (en minutos), el número de reintentos y la versión de AWS Glue.
4. Si lo desea, defina las etiquetas. Las etiquetas son marcas que asigna a un recurso de AWS. Cada etiqueta consta de una clave y un valor opcional. Las etiquetas se pueden usar para buscar y filtrar los recursos o hacer un seguimiento de los costos de AWS.

Paso 2. Elija la tabla y la clave principal.

1. Elija la base de datos y la tabla del catálogo de AWS Glue.
2. Elija una clave principal de la tabla seleccionada. La columna de clave principal normalmente contiene un identificador único para cada registro del origen de datos.

Paso 3. Seleccione las opciones de ajuste.

1. Para Exhaustividad vs. precisión, elija el valor de ajuste para la transformación y así favorecer la exhaustividad o la precisión. De forma predeterminada, está seleccionada la opción Equilibrado, pero puede elegir entre favorecer la exhaustividad o la precisión o bien elegir Personalizado e ingresar un valor entre 0,0 y 1,0 (ambos incluidos).
2. Para menor costo vs. precisión, elija el valor de ajuste que favorezca una reducción del costo o la precisión o bien elija Personalizado e ingrese un valor entre 0,0 y 1,0 (ambos incluidos).
3. Para Forzar la coincidencia, seleccione Forzar la salida para que coincida con las etiquetas si quiere enseñarle a la transformación de ML a que la salida coincida con las etiquetas utilizadas.

Paso 4. Revisar y crear.

1. Revise las opciones de los pasos 1 a 3.
2. Seleccione Editar para cualquier paso que necesite modificarse. Seleccione Crear transformación para completar el asistente de creación de transformaciones.

Uso de cifrado de datos con transformaciones de machine learning

Al agregar una transformación de machine learning a AWS Glue, puede especificar opcionalmente una configuración de seguridad asociada con el origen de datos o el destino de datos. Si el bucket de Amazon S3 utilizado para almacenar los datos está cifrado con una configuración de seguridad, especifique la misma configuración de seguridad al crear la transformación.

También puede elegir utilizar el cifrado del lado del servidor con AWS KMS (SSE-KMS) para cifrar el modelo y las etiquetas, y así evitar la inspección de parte de personas no autorizadas. Si elige esta opción, se le pedirá que elija la opción AWS KMS key por nombre, o puede elegir Enter a key ARN (Ingresar una clave de ARN). Si elige ingresar el ARN para la clave KMS, aparecerá un segundo campo en el que puede introducir el ARN de la clave KMS.

> **Note**
>
> En la actualidad, las transformaciones de ML que utilizan una clave de cifrado personalizada no son compatibles en las siguientes regiones:
>
> - Asia-Pacífico (Osaka): `ap-northeast-3`

Visualización de los detalles de la transformación

Visualización de las propiedades de transformación

La página de Propiedades de la transformación incluye los atributos de la transformación. Muestra los detalles sobre la definición de transformación, incluidos los siguientes:

- Transform name (Nombre de transformación) muestra el nombre de la transformación.
- Type (Tipo) muestra el tipo de transformación.
- Status (Estado) muestra si la transformación ya se está usando en un script o trabajo.
- Force output to match labels (Forzar resultado para que las etiquetas coincidan) muestra si la transformación fuerza el resultado para que las etiquetas proporcionadas por el usuario coincidan.

- La Spark version (versión de Spark) se relaciona con la versión de AWS Glue que eligió en Task run properties (Propiedades de ejecución de tarea) al agregar la transformación. Se recomienda AWS Glue 1.0 y Spark 2.4 para la mayoría de los clientes. Para obtener más información, consulte Versiones de AWS Glue.

Pestañas Historial, Estimación de la calidad y Etiquetas

Los detalles de la transformación incluirán la información que definió al crear la transformación. Para ver los detalles de una transformación, seleccione la transformación en la lista Machine learning transforms (Transformaciones de machine learning) y revise la información en las siguientes pestañas:

- Historial
- Estimar calidad
- Etiquetas

Historial

La pestaña History (Historial) muestra su historial de ejecuciones de tareas de transformación. Se ejecutan varios tipos de tareas para enseñar a una transformación. Para cada tarea, las métricas de ejecución incluyen lo siguiente:

- El Run ID (ID de ejecución) es un identificador creado por AWS Glue para cada una de las ejecuciones de esta tarea.
- Task type (Tipo de tarea) muestra el tipo de ejecución de tareas.
- Status (Estado) muestra el éxito de cada tarea que aparece con la ejecución más reciente en la parte superior.
- En Error, se muestran los detalles de un mensaje de error si la ejecución no se ha realizado correctamente.
- En Start time (Hora de inicio) se muestra la fecha y la hora (hora local) en que se inició la tarea.
- En Hora de finalización se muestra la fecha y la hora (hora local) en que finalizó la tarea.
- Logs (Registros) se vincula a los registros escritos en `stdout` para esta ejecución de trabajo.

  El enlace Logs (Registros) lo dirigirá a Amazon CloudWatch Logs. Aquí podrá ver los detalles sobre las tablas que creó en AWS Glue Data Catalog y los errores detectados. Puede administrar su periodo de retención de registros en la consola de CloudWatch. La retención de registros

predeterminada es `Never Expire`. Para obtener más información sobre cómo cambiar el periodo de retención, consulte Cambiar la retención de datos de registro en CloudWatch Logs en la Guía del usuario de Amazon CloudWatch Logs.

- En Archivo de etiqueta se muestra un enlace a Amazon S3 para un archivo de etiquetado generado.

Estimar calidad

La pestaña Estimate quality (Estimar calidad) muestra las métricas que utiliza para medir la calidad de la transformación. Las estimaciones se calculan al comparar las predicciones de coincidencia de transformación obtenidas a partir de un subconjunto de sus datos etiquetados con las etiquetas que ha proporcionado. Estas estimaciones son aproximadas. Puede invocar una ejecución de tareas de estimación de calidad para esta pestaña.

La pestaña Estimar calidad muestra las métricas de la última ejecución de Estimar calidad incluidas las siguientes propiedades:

- El área bajo la curva Precision-Recall (Precisión-exhaustividad) es un único número que calcula el límite superior de la calidad general de la transformación. Es independiente de la elección realizada para el parámetro precisión-exhaustividad. Los valores más altos indican que cuenta con una compensación de precisión-exhaustividad más atractiva.
- Precision (Precisión) indica la frecuencia con la que la transformación es correcta cuando predice una coincidencia.
- Recall upper limit (Límite superior de exhaustividad) indica la frecuencia con la que la transformación predice la coincidencia en una coincidencia real.
- F1 indica la exactitud de la transformación entre 0 y 1, donde 1 es la mejor exactitud. Para obtener más información, consulte Valor-F en Wikipedia.
- La tabla Column importance (Importancia de columnas) muestra los nombres de columna y la puntuación de importancia para cada columna. La importancia de columna ayuda a comprender cómo contribuyen las columnas al modelo, al identificar qué columnas de los registros se están utilizando con mayor frecuencia para hacer la coincidencia. Estos datos pueden solicitarle que agregue o cambie el conjunto de etiquetas para aumentar o reducir la importancia de las columnas.

  La columna Importance (Importancia) proporciona una puntuación numérica para cada columna, como un decimal no mayor que 1,0.

Para obtener más información sobre cómo comprender las estimaciones de calidad frente a verdadera calidad, consulte Estimaciones de calidad frente a calidad integral (verdadero).

Para obtener más información sobre cómo ajustar su transformación, consulte Ajuste de transformaciones de machine learning en AWS Glue.

Estimaciones de calidad frente a calidad integral (verdadero)

AWS Glue estima la calidad de su transformación al presentar el modelo de machine learning interno con un número de pares de registros que proporcionó para las etiquetas de coincidencia, pero que el modelo no ha visto antes. Estas estimaciones de calidad son una función de la calidad del modelo de machine learning (que está influenciado por el número de registros que etiqueta para "enseñar" a la transformación). La recuperación integral o verdadera (que no se calcula automáticamente mediante la `ML transform`) también se ve influenciada por el mecanismo de filtrado de `ML transform` que propone una amplia variedad de posibles coincidencias con el modelo de machine learning.

Puede ajustar este método de filtrado principalmente al especificar el valor de ajuste Costo inferior-exactitud. A medida que este valor de ajuste se acerca al valor que favorece la Exactitud, el sistema realiza una búsqueda más completa y más cara de pares de registro que pueden ser coincidencias. Se ofrecen más pares de registro a su modelo de machine learning y la exhaustividad de verdad o integral de su `ML transform` se acerca a la métrica de exhaustividad estimada. Como resultado, los cambios en la calidad integral de las coincidencias, como resultado de los cambios en la compensación de costo/precisión de las coincidencias, normalmente no se verán reflejados en la estimación de calidad.

Etiquetas

Las etiquetas son marcas que asigna a un recurso de AWS. Cada etiqueta consta de una clave y un valor opcional. Las etiquetas se pueden usar para buscar y filtrar los recursos o hacer un seguimiento de los costos de AWS.

Cómo enseñar a las transformaciones mediante el uso de etiquetas

Puede enseñar a la transformación de ML mediante etiquetas (ejemplos) al seleccionar Enseñar transformación en la página de detalles de la transformación de ML. Si enseña a su algoritmo de machine learning con ejemplos (denominados “etiquetas”), puede elegir las etiquetas existentes para usarlas o crear un archivo de etiquetado.

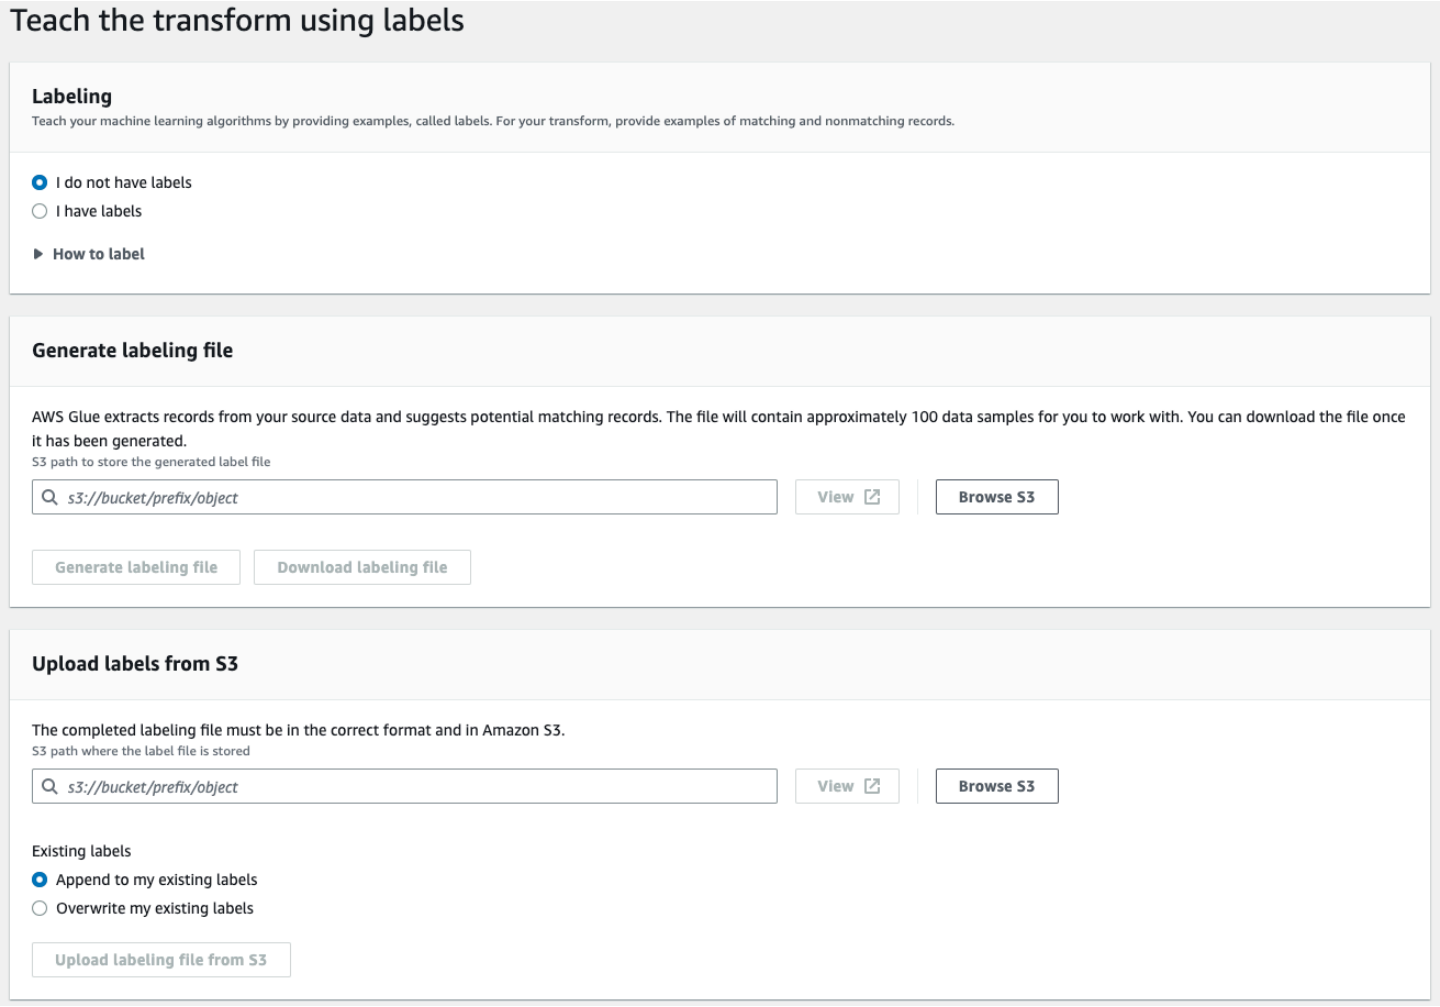

- Etiquetado: si tiene etiquetas, elija Tengo etiquetas. Si no tiene etiquetas, puede continuar con el siguiente paso, es decir, generar un archivo de etiquetado.
- Generar un archivo de etiquetado: AWS Glue extrae los registros de los datos de origen y sugiere posibles registros de coincidencias. Usted elige el bucket de Amazon S3 para almacenar el archivo de etiquetas generado. Elija Generar archivo de etiquetado para iniciar el proceso. Cuando haya terminado, elija Descargar archivo de etiquetado. El archivo descargado tendrá una columna de etiquetas en la que podrá rellenar las etiquetas.
- Cargar etiquetas desde Amazon S3: elija el archivo de etiquetado completo del bucket de Amazon S3 en el que está almacenado el archivo de etiquetas. A continuación, elija agregar las etiquetas a las etiquetas existentes o sobrescribirlas. Seleccione Cargar archivo de etiquetado desde Amazon S3.

Tutorial: creación de una transformación de machine learning con AWS Glue

Este tutorial le guiará a través de las acciones para crear y administrar una transformación de machine learning (ML) con AWS Glue. Antes de utilizar este tutorial, debe estar familiarizado con el uso de la consola de AWS Glue para añadir rastreadores y trabajos, y editar scripts. También debe estar familiarizado con la búsqueda y descarga de archivos en la consola de Amazon Simple Storage Service (Amazon S3).

En este ejemplo, se creará una transformación `FindMatches` para encontrar los registros coincidentes, enseñarle cómo identificar registros de coincidencia y no coincidencia, y utilizarla en un trabajo de AWS Glue. El trabajo de AWS Glue escribe un nuevo archivo de Amazon S3 con una columna adicional denominada `match_id`.

En este tutorial se ha utilizado un archivo denominado `dblp_acm_records.csv` como dato de origen. Este archivo es una versión modificada de publicaciones académicas (DBLP y ACM) disponible a partir del conjunto de datos de DBLP y ACM original. El archivo `dblp_acm_records.csv` es un archivo de valores separados por comas (CSV) en formato UTF-8 sin marca de orden de bytes (BOM).

El segundo archivo `dblp_acm_labels.csv`, es un archivo de etiquetado de ejemplo que contiene registros de coincidencia y no coincidencia utilizados para enseñar a la transformación como parte del tutorial.

Temas

- Paso 1: Rastrear los datos de origen
- Paso 2: Agregar una transformación de machine learning
- Paso 3: Agregar una transformación de machine learning
- Paso 4: Calcular la calidad de su transformación de machine learning
- Paso 5: Agregar y ejecutar un trabajo con su transformación de machine learning.
- Paso 6: Verificar los datos de salida desde Amazon S3

Paso 1: Rastrear los datos de origen

En primer lugar, rastree el archivo CSV de Amazon S3 de origen para crear una tabla de metadatos correspondiente en el Data Catalog.

> **Important**
>
> Para dirigir el rastreador para crear una tabla únicamente para el archivo CSV, almacene los datos de origen de CSV en una carpeta de Amazon S3 diferente de los demás archivos.

1. Inicie sesión en la Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. En el panel de navegación, elija Crawlers (Rastreadores) y Add crawler (Añadir rastreador).
3. Siga el asistente para crear y ejecutar un rastreador denominado `demo-crawl-dblp-acm` con salida a la base de datos `demo-db-dblp-acm`. Cuando ejecute el asistente, cree la base de datos `demo-db-dblp-acm` si no existe todavía. Elija una ruta de inclusión de Amazon S3 a los datos de ejemplo en la región de AWS actual. Por ejemplo, en el caso de `us-east-1`, la ruta de inclusión de Amazon S3 para el archivo de origen es `s3://ml-transforms-public-datasets-us-east-1/dblp-acm/records/dblp_acm_records.csv`.

   Si se ejecuta correctamente, el rastreador crea la tabla `dblp_acm_records_csv` con las siguientes columnas: id, title (título), authors (autores), venue (lugar), year (año) y source (origen).

Paso 2: Agregar una transformación de machine learning

A continuación, agregue una transformación de machine learning que se base en el esquema de la tabla de origen de datos creada por el rastreador denominada `demo-crawl-dblp-acm`.

1. En la consola de AWS Glue, en el panel de navegación, en la sección Integración de datos y ETL, seleccione Herramientas de clasificación de datos > Coincidencia de registros y, a continuación, Agregar transformación. Siga el asistente para crear una transformación `Find matches` con las siguientes propiedades.

   a. En Transform name (Nombre de transformación), escriba **`demo-xform-dblp-acm`**. Este es el nombre de la transformación que se utiliza para buscar coincidencias en los datos de origen.

   b. En IAM role (Rol de IAM) elija un rol de IAM que tenga permiso para los datos de origen de Amazon S3, el archivo de etiquetado y las operaciones de la API de AWS Glue. Para obtener más información, consulte Creación de un rol de IAM para AWS Glue en la Guía para desarrolladores de AWS Glue.

c. En Data source (Origen de datos), elija la tabla denominada dblp_acm_records_csv en la base de datos demo-db-dblp-acm.

d. En Primary key (Clave principal), elija la columna de clave principal para la tabla, id.

2. En el asistente, elija Finish (Finalizar) y vuelva a la lista ML transforms (Transformaciones de ML).

Paso 3: Agregar una transformación de machine learning

A continuación, debe enseñar a su transformación de machine learning a usar el archivo de etiquetado de ejemplo del tutorial.

No puede utilizar una transformación de lenguaje automático en un trabajo de extracción, transformación y carga (ETL) hasta que el estado sea Ready for use (Listo para su uso). Para que la transformación esté preparada, debe enseñarle cómo identificar registros de coincidencia y no coincidencia mediante el ofrecimiento de ejemplos de registros de coincidencia y no coincidencia. Para enseñar a su transformación, puede generar un archivo de etiquetas, añadir etiquetas y, a continuación, subir un archivo de etiquetas. En este tutorial, puede utilizar el archivo de etiquetado de ejemplo denominado `dblp_acm_labels.csv`. Para obtener más información sobre el proceso de etiquetado, consulte Etiquetado.

1. En el panel de navegación de la consola de AWS Glue, elija Coincidencia de registros.
2. Elija la transformación `demo-xform-dblp-acm` y, a continuación, elija Action (Acción) y Teach (Enseñar). Siga el asistente para enseñar a su transformación `Find matches`.
3. En la página de propiedades de transformación, elija I have labels (Tengo etiquetas). Elija una ruta de Amazon S3 al archivo de etiquetado de ejemplo en la región de AWS actual. Por ejemplo, para `us-east-1`, cargue el archivo de etiquetado proporcionado de la ruta de Amazon S3 `s3://ml-transforms-public-datasets-us-east-1/dblp-acm/labels/dblp_acm_labels.csv` con la opción overwrite (sobreescribir) las etiquetas existentes. El archivo de etiquetado debe estar ubicado en Amazon S3 en la misma región que la consola de AWS Glue.

   Al cargar un archivo de etiquetado, se inicia una tarea en AWS Glue para añadir o sobrescribir las etiquetas utilizadas para enseñar a la transformación cómo procesar el origen de datos.
4. En la última página del asistente, elija Finish (Finalizar), y vuelva a la lista ML transforms (Transformaciones de ML).

Paso 4: Calcular la calidad de su transformación de machine learning

A continuación, puede estimar la calidad de su transformación de machine learning. La calidad depende de la cantidad de etiquetado que acaba de realizar. Para obtener más información sobre la calidad de estimación, consulte Estimar calidad.

1. En la consola de AWS Glue, en el panel de navegación, en Integración de datos y ETL, seleccione Herramientas de clasificación de datos > Coincidencia de registros.
2. Elija la transformación `demo-xform-dblp-acm` y elija la pestaña Estimate quality (Estimar calidad). Esta pestaña muestra las estimaciones de calidad actuales, si estuvieran disponibles, para la transformación.
3. Elija Estimate quality (Estimar calidad) para iniciar una tarea para estimar la calidad de la transformación. La exactitud de la estimación de calidad se basa en el etiquetado de los datos de origen.
4. Diríjase a la pestaña History (Historial). En este panel, aparecen las ejecuciones de tareas para la transformación, incluida la tarea de Estimating quality (Estimación de calidad). Para obtener más información sobre la ejecución, elija Logs (Registros). Compruebe que el estado de ejecución sea Suceeded (Correcto) cuando finalice.

Paso 5: Agregar y ejecutar un trabajo con su transformación de machine learning.

En este paso, utilice la transformación de machine learning para agregar y ejecutar un trabajo en AWS Glue. Cuando la transformación `demo-xform-dblp-acm` esté lista para su uso, podrá utilizarla en un trabajo de ETL.

1. En el panel de navegación de la consola de AWS Glue, seleccione Jobs (Trabajos).
2. Elija Add job (Añadir trabajo) y siga los pasos en el asistente para crear un trabajo de ETL Spark con un script generado. Elija los siguientes valores de propiedad para su transformación:
   a. En Name (Nombre), elija el trabajo de ejemplo en este tutorial, demo-etl-dblp-acm.
   b. En IAM role (Rol de IAM), elija un rol de IAM con permiso para los datos de origen de Amazon S3, el archivo de etiquetado y las operaciones de la API de AWS Glue. Para obtener más información, consulte Creación de un rol de IAM para AWS Glue en la Guía para desarrolladores de AWS Glue.
   c. En ETL language (Lenguaje de ETL), elija Scala. Este es el lenguaje de programación en el script de ETL.

d. En Script file name (Nombre de archivo de script), elija demo-etl-dblp-acm. Este es el nombre de archivo del script de Scala (mismo nombre de archivo).

e. En Data source (Origen de datos), elija dblp_acm_records_csv. El origen de datos que elija debe coincidir con el esquema de origen de datos de transformación de machine learning.

f. En Transform type (Tipo de transformación), elija Find matching records (Buscar registros de coincidencia) para crear un trabajo mediante una transformación de machine learning.

g. Borre Remove duplicate records (Eliminar registros duplicados). No quiere eliminar registros duplicados porque los registros de salida escritos disponen de un campo `match_id` adicional añadido.

h. En Transform (Transformación), elija demo-xform-dblp-acm, la transformación de machine learning utilizada por el trabajo.

i. En Create tables in your data target (Crear tablas en su destino de datos), elija crear tablas con las siguientes propiedades:

- Data store type (Tipo de almacén de datos): **`Amazon S3`**
- Format (Formato): **`CSV`**
- Compression type (Tipo de compresión): **`None`**
- Target path (Ruta de destino): la ruta de Amazon S3 donde se escribe la salida del trabajo (en la región de AWS de la consola actual)

3. Elija Save job and edit script (Guardar trabajo y editar script) para mostrar la página del editor de scripts.

4. Edite el script para añadir una instrucción para que la salida del trabajo en Target path (Ruta de destino) se sobrescriba en un archivo de partición único. Añada esta instrucción inmediatamente después de la instrucción que ejecuta la transformación `FindMatches`. La instrucción es similar a la siguiente.

```
val single_partition = findmatches1.repartition(1)
```

Debe modificar la instrucción `.writeDynamicFrame(findmatches1)` para escribir la salida como `.writeDynamicFrame(single_partion)`.

5. Después de editar el script, elija Save (Guardar). El script modificado tiene un aspecto similar al siguiente código, pero se personaliza para su entorno.

```
import com.amazonaws.services.glue.GlueContext
```

```
import com.amazonaws.services.glue.errors.CallSite
import com.amazonaws.services.glue.ml.FindMatches
import com.amazonaws.services.glue.util.GlueArgParser
import com.amazonaws.services.glue.util.Job
import com.amazonaws.services.glue.util.JsonOptions
import org.apache.spark.SparkContext
import scala.collection.JavaConverters._

object GlueApp {
  def main(sysArgs: Array[String]) {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)
    // @params: [JOB_NAME]
    val args = GlueArgParser.getResolvedOptions(sysArgs, Seq("JOB_NAME").toArray)
    Job.init(args("JOB_NAME"), glueContext, args.asJava)
    // @type: DataSource
    // @args: [database = "demo-db-dblp-acm", table_name = "dblp_acm_records_csv",
 transformation_ctx = "datasource0"]
    // @return: datasource0
    // @inputs: []
    val datasource0 = glueContext.getCatalogSource(database = "demo-db-dblp-acm",
 tableName = "dblp_acm_records_csv", redshiftTmpDir = "", transformationContext =
 "datasource0").getDynamicFrame()
    // @type: FindMatches
    // @args: [transformId = "tfm-123456789012", emitFusion = false,
 survivorComparisonField = "<primary_id>", transformation_ctx = "findmatches1"]
    // @return: findmatches1
    // @inputs: [frame = datasource0]
    val findmatches1 = FindMatches.apply(frame = datasource0, transformId
 = "tfm-123456789012", transformationContext = "findmatches1",
 computeMatchConfidenceScores = true)


    // Repartition the previous DynamicFrame into a single partition.
    val single_partition = findmatches1.repartition(1)


    // @type: DataSink
    // @args: [connection_type = "s3", connection_options = {"path": "s3://aws-
glue-ml-transforms-data/sal"}, format = "csv", transformation_ctx = "datasink2"]
    // @return: datasink2
    // @inputs: [frame = findmatches1]
    val datasink2 = glueContext.getSinkWithFormat(connectionType =
 "s3", options = JsonOptions("""{"path": "s3://aws-glue-ml-transforms-
```

```
data/sal"}"""), transformationContext = "datasink2", format =
 "csv").writeDynamicFrame(single_partition)
    Job.commit()
  }
}
```

6. Elija Run job (Ejecutar trabajo) para iniciar la ejecución de trabajo. Compruebe el estado del trabajo en la lista de trabajos. Cuando el trabajo finaliza, en ML transform (Transformación ML), en la pestaña History (Historial), habrá una nueva fila Run ID (ID de ejecución) añadida al tipo ETL job (Trabajo de ETL).
7. Diríjase a Jobs (Trabajos), pestaña History (Historial). En este panel, aparecen las ejecuciones de trabajo. Para obtener más información sobre la ejecución, elija Logs (Registros). Compruebe que el estado de ejecución sea Suceeded (Correcto) cuando finalice.

Paso 6: Verificar los datos de salida desde Amazon S3

En este paso, verificará la salida de la ejecución de trabajo en el bucket de Amazon S3 que elija cuando agregue el trabajo. Puede descargar el archivo de salida en su máquina local y verificar que se identificaron los registros de coincidencia.

1. Abra la consola de Amazon S3 en https://console.aws.amazon.com/s3.
2. Descargue el archivo de salida de destino del trabajo `demo-etl-dblp-acm`. Abra el archivo en una aplicación de hoja de cálculo (es posible que tenga que añadir una extensión de archivo `.csv` para que el archivo se abra correctamente).

   La imagen siguiente muestra un fragmento de la salida en Microsoft Excel.

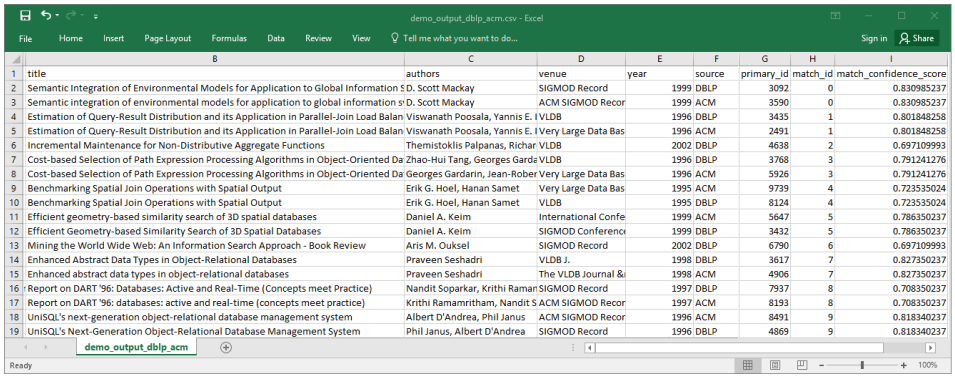

	B	C	D	E	F	G	H	I
1	title	authors	venue	year	source	primary_id	match_id	match_confidence_score
2	Semantic Integration of Environmental Models for Application to Global Information S	D. Scott Mackay	SIGMOD Record	1999	DBLP	3092	0	0.830985237
3	Semantic integration of environmental models for application to global information s	D. Scott Mackay	ACM SIGMOD Recor	1999	ACM	3590	0	0.830985237
4	Estimation of Query-Result Distribution and its Application in Parallel-Join Load Balan	Viswanath Poosala, Yannis E. I	VLDB	1996	DBLP	3435	1	0.801848258
5	Estimation of Query-Result Distribution and its Application in Parallel-Join Load Balan	Viswanath Poosala, Yannis E. I	Very Large Data Bas	1996	ACM	2491	1	0.801848258
6	Incremental Maintenance for Non-Distributive Aggregate Functions	Themistoklis Palpanas, Richar	VLDB	2002	DBLP	4638	2	0.697109993
7	Cost-based Selection of Path Expression Processing Algorithms in Object-Oriented Da	Zhao-Hui Tang, Georges Garda	VLDB	1996	DBLP	3768	3	0.791241276
8	Cost-based Selection of Path Expression Processing Algorithms in Object-Oriented Da	Georges Gardarin, Jean-Rober	Very Large Data Bas	1996	ACM	5926	3	0.791241276
9	Benchmarking Spatial Join Operations with Spatial Output	Erik G. Hoel, Hanan Samet	Very Large Data Bas	1995	ACM	9739	4	0.723535024
10	Benchmarking Spatial Join Operations with Spatial Output	Erik G. Hoel, Hanan Samet	VLDB	1995	DBLP	8124	4	0.723535024
11	Efficient geometry-based similarity search of 3D spatial databases	Daniel A. Keim	International Confe	1999	ACM	5647	5	0.786350237
12	Efficient Geometry-based Similarity Search of 3D Spatial Databases	Daniel A. Keim	SIGMOD Conferenc	1999	DBLP	3432	5	0.786350237
13	Mining the World Wide Web: An Information Search Approach - Book Review	Aris M. Ouksel	SIGMOD Record	2002	DBLP	6790	6	0.697109993
14	Enhanced Abstract Data Types in Object-Relational Databases	Praveen Seshadri	VLDB J.	1998	DBLP	3617	7	0.827350237
15	Enhanced abstract data types in object-relational databases	Praveen Seshadri	The VLDB Journal &	1998	ACM	4906	7	0.827350237
16	Report on DART '96: Databases: Active and Real-Time (Concepts meet Practice)	Nandit Soparkar, Krithi Raman	SIGMOD Record	1997	DBLP	7937	8	0.708350237
17	Report on DART '96: databases: active and real-time (concepts meet practice)	Krithi Ramamritham, Nandit S	ACM SIGMOD Recor	1997	ACM	8193	8	0.708350237
18	UniSQL's next-generation object-relational database management system	Albert D'Andrea, Phil Janus	ACM SIGMOD Recor	1996	ACM	8491	9	0.818340237
19	UniSQL's Next-Generation Object-Relational Database Management System	Phil Janus, Albert D'Andrea	SIGMOD Record	1996	DBLP	4869	9	0.818340237

   El archivo de origen y destino de datos tiene 4911 registros. Sin embargo, la transformación `Find matches` añade otra columna denominada `match_id` para identificar registros de coincidencia en la salida. Las filas con el mismo `match_id` se consideran registros de

coincidencia. La `match_confidence_score` es un número entre 0 y 1 que proporciona una estimación de la calidad de las coincidencias encontradas por `Find matches`.

3. Ordene el archivo de salida por `match_id` para ver fácilmente qué registros son coincidencias. Compare los valores en las demás columnas para ver si acepta los resultados de la transformación `Find matches`. Si no es así, puede seguir enseñando a la transformación mediante la adición de más etiquetas.

   También puede ordenar el archivo por otro campo, como `title`, para ver si los registros con títulos similares tienen el mismo `match_id`.

Búsqueda de coincidencias progresivas

La característica de búsqueda de coincidencias permite identificar registros duplicados o coincidentes en el conjunto de datos, incluso cuando los registros no tienen un identificador único común y no coinciden exactamente los campos. La versión inicial de búsqueda de coincidencia transforma los registros coincidentes identificados dentro de un único conjunto de datos. Cuando agregó datos nuevos al conjunto de datos, tuvo que fusionarlo con el conjunto de datos limpio existente y volver a ejecutar la coincidencia con el conjunto de datos fusionado completo.

La característica de coincidencia progresiva facilita la coincidencia con los registros progresivos con respecto a los conjuntos de datos coincidentes existentes. Suponga que desea asociar los datos de los clientes potenciales con los conjuntos de datos de clientes existentes. La capacidad de coincidencia progresiva proporciona la flexibilidad de asociar cientos de miles de nuevos clientes potenciales con una base de datos existente de clientes potenciales y clientes existentes mediante la fusión de los resultados en una única base de datos o tabla. Al hacer coincidir solo entre los conjuntos de datos nuevos y existentes, la optimización de búsqueda de coincidencias progresivas reduce el tiempo de cálculo, lo que también reduce los costos.

La utilización de la coincidencia progresiva es similar a la búsqueda de coincidencias tal como se describe en Tutorial: creación de una transformación de machine learning con AWS Glue. En este tema, se identifican únicamente las diferencias con la coincidencia progresiva.

Para obtener más información, consulte la publicación del blog de Coincidencia progresiva de datos.

Ejecución de un trabajo de coincidencia progresiva

Para el siguiente procedimiento, suponga lo siguiente:

- Se ha rastreado el conjunto de datos existente y los resultados se han pasado a la tabla first_records. El conjunto de datos de first_records debe ser un conjunto de datos coincidente, o bien el resultado del trabajo coincidente.
- Se ha creado y entrenado una transformación de FindMatches con AWS Glue versión 2.0. Esta es la única versión de AWS Glue que soporta coincidencias progresivas.
- El lenguaje de ETL es Scala. Tenga en cuenta que también se soporta Python.
- El modelo ya generado se denomina `demo-xform`.

1. Rastree el conjunto de datos progresivo hasta la tabla second_records.
2. En el panel de navegación de la consola de AWS Glue, seleccione Jobs (Trabajos).
3. Elija Add job (Añadir trabajo) y siga los pasos en el asistente para crear un trabajo de ETL Spark con un script generado. Elija los siguientes valores de propiedad para su transformación:
   a. Para Name (Nombre), elija demo-etl.
   b. En IAM role (Rol de IAM), elija un rol de IAM con permiso para los datos de origen de Amazon S3, el archivo de etiquetado y las operaciones de la API de AWS Glue.
   c. En ETL language (Lenguaje de ETL), elija Scala.
   d. En Script file name (Nombre de archivo de script), elija demo-etl. Este es el nombre de archivo del script de Scala.
   e. Para Data source (Origen de datos), elija first_records. El origen de datos que elija debe coincidir con el esquema de origen de datos de transformación de machine learning.
   f. En Transform type (Tipo de transformación), elija Find matching records (Buscar registros de coincidencia) para crear un trabajo mediante una transformación de machine learning.
   g. Seleccione la opción de coincidencia progresiva y para Data source (Origen de datos), seleccione la tabla denominada second_records.
   h. En Transform (Transformación), elija demo-xform, la transformación de machine learning utilizada por el trabajo.
   i. Elija Create tables in your data target (Crear tablas en el destino de datos) o Use tables in the data catalog and update your data target (Utilizar tablas en el Catálogo de datos y actualizar el destino de datos).
4. Elija Save job and edit script (Guardar trabajo y editar script) para mostrar la página del editor de scripts.
5. Elija Run job (Ejecutar trabajo) para iniciar la ejecución de trabajo.

Uso de FindMatches en un trabajo visual

Para usar la transformación FindMatches en AWS Glue Studio, puede usar el nodo Custom Transform que invoca la API FindMatches. Para obtener más información sobre cómo usar una transformación personalizada, consulte Crear una transformación personalizada.

> **Note**
>
> Actualmente, la API FindMatches solo funciona con `Glue 2.0`. Para ejecutar un trabajo con la transformación personalizada que invoca la API FindMatches, asegúrese de que la versión de AWS Glue sea `Glue 2.0` en la pestaña Detalles del trabajo. Si la versión de AWS Glue no es `Glue 2.0`, el trabajo fallará en tiempo de ejecución y mostrará el siguiente mensaje de error: “no se puede importar el nombre 'FindMatches' de 'awsglueml.transforms'”.

Requisitos previos

- Para utilizar la transformación FindMatches abra la consola de AWS Glue Studio en https://console.aws.amazon.com/gluestudio/.
- Cree una transformación de machine learning. Cuando se crea, se genera un transformId. Para realizar los pasos que se indican a continuación, necesitará este ID. Para obtener más información sobre cómo crear una transformación de machine learning, consulte Agregar y editar transformaciones de machine learning.

Agregar una transformación de FindMatches

Para agregar una transformación de FindMatches:

1. En el editor de trabajos de AWS Glue Studio, abra el panel de recursos mediante un clic en el símbolo de la cruz situado en la esquina superior izquierda del gráfico visual del trabajo y elija un origen de datos en la pestaña Datos. Este es el origen de datos en el que desea comprobar si hay coincidencias.

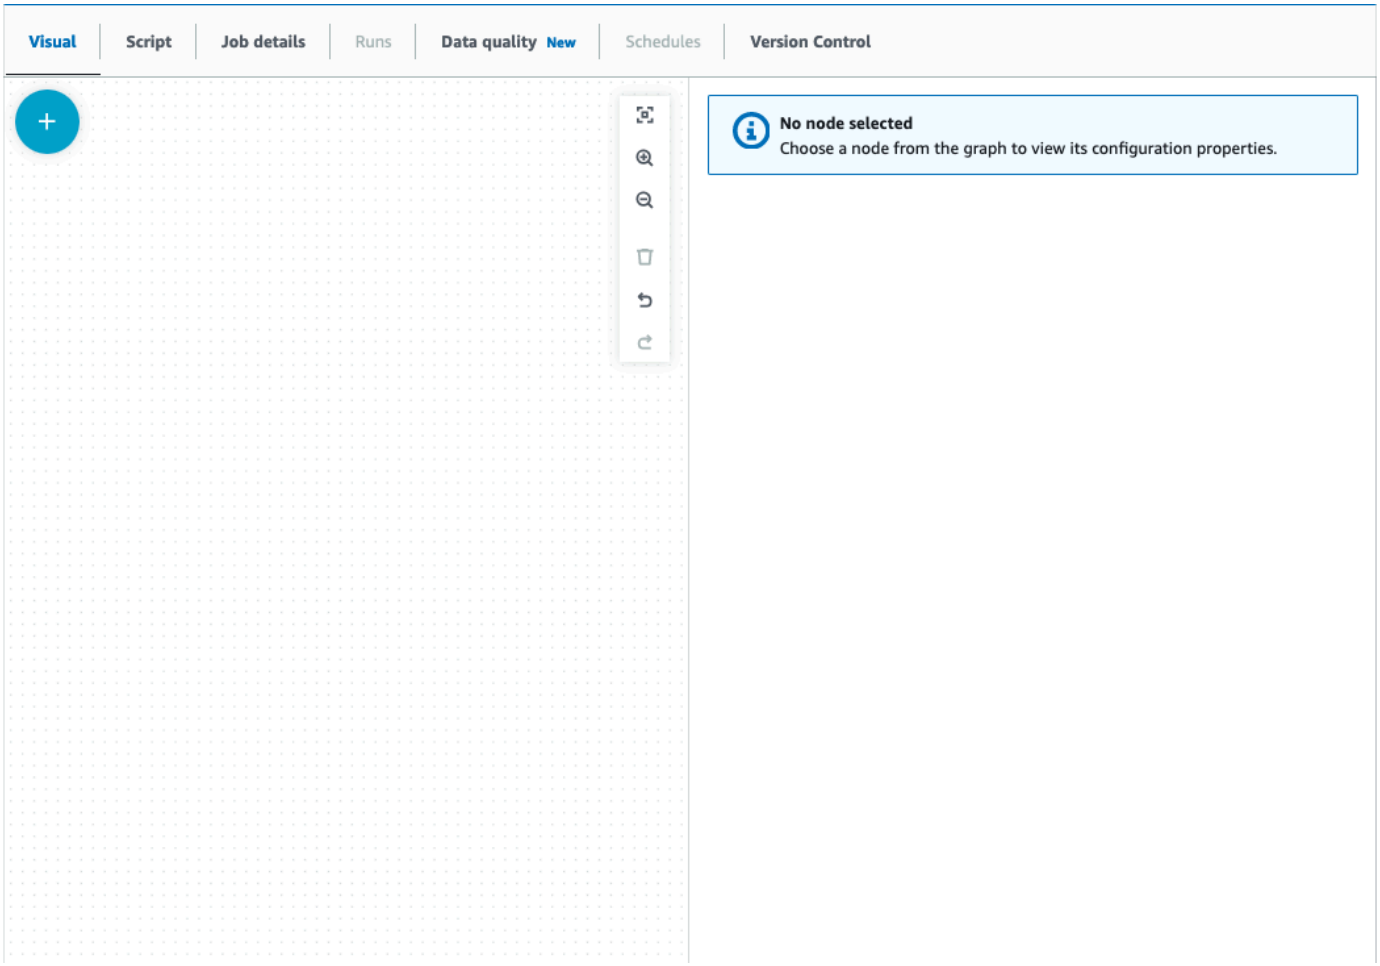

2. Seleccione el nodo del origen de datos y, a continuación, abra el panel de recursos mediante un clic en el símbolo de la cruz situado en la esquina superior izquierda del gráfico visual del trabajo y busque “transformación personalizada”. Elija el nodo Transformación personalizada para agregarlo al gráfico. La transformación personalizada está vinculada al nodo de origen de datos. Si no lo está, puede hacer clic en el nodo Transformación personalizada y elegir la pestaña Propiedades del nodo y, a continuación, en Nodos principales, elegir el origen de datos.
3. Haga clic en el nodo Transformación personalizada del gráfico visual y, a continuación, seleccione la pestaña Propiedades del nodo y asigne un nombre a la transformación personalizada. Se recomienda cambiar el nombre de la transformación para que el nombre de la transformación sea fácilmente identificable en el gráfico visual.
4. Seleccione la pestaña Transformación, donde podrá editar el bloque de código. Aquí es donde se puede agregar el código para invocar la API FindMatches.

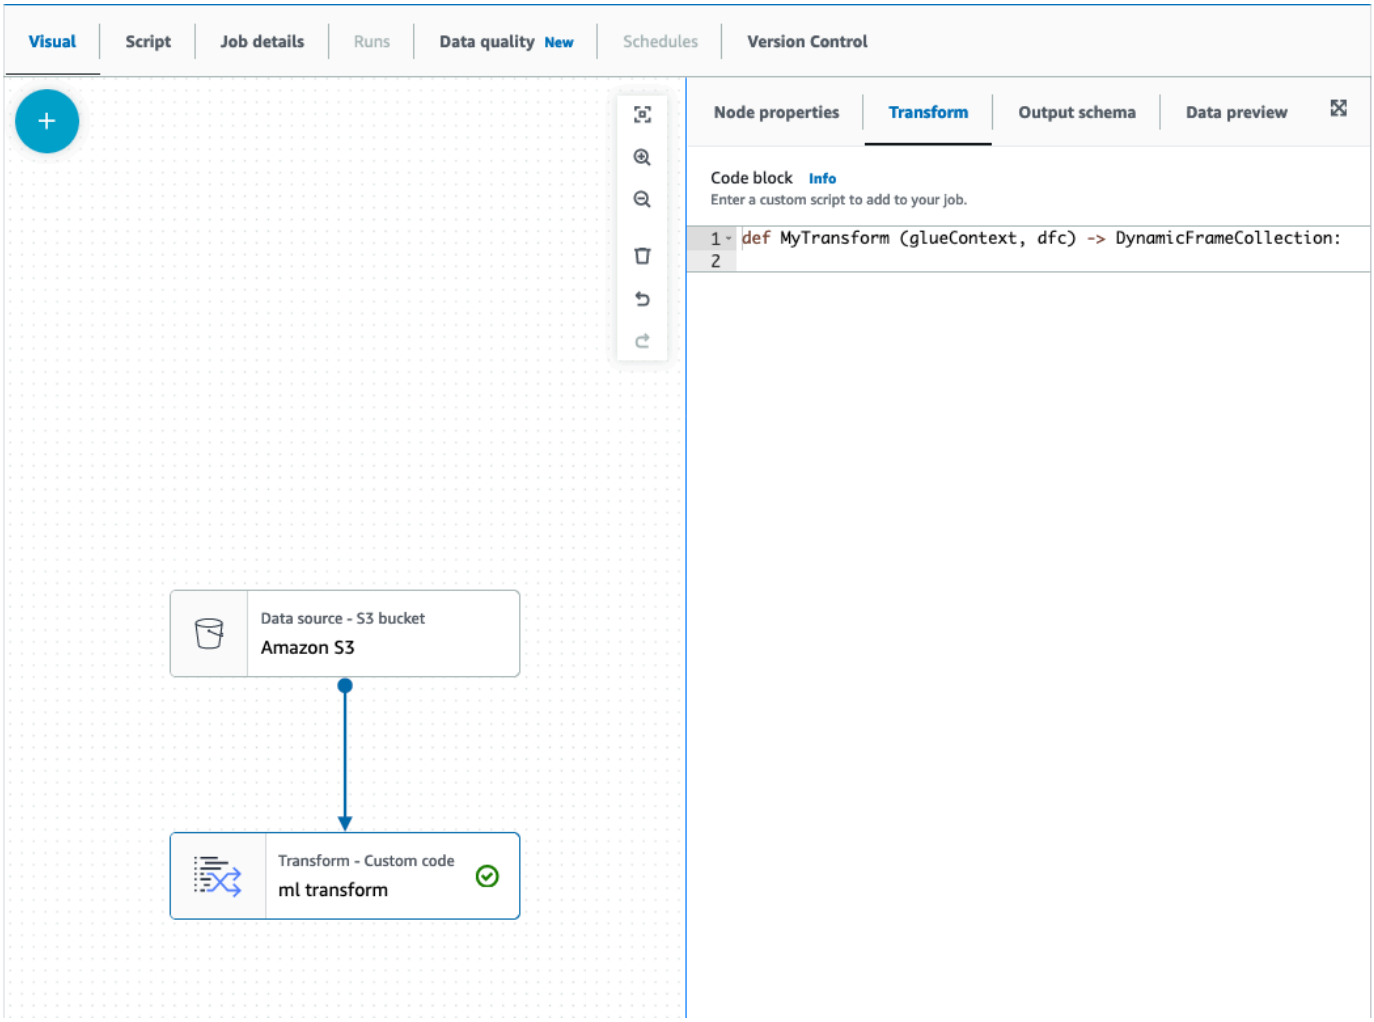

El bloque de código contiene código rellenado previamente para que pueda empezar. Sobrescriba el código rellenado previamente con la plantilla que se muestra a continuación. La plantilla tiene un marcador de posición para el transformId, que puede proporcionar.

```
def MyTransform (glueContext, dfc) -> DynamicFrameCollection:
    dynf = dfc.select(list(dfc.keys())[0])
    from awsglueml.transforms import FindMatches
    findmatches = FindMatches.apply(frame = dynf, transformId = "<your id>")
    return(DynamicFrameCollection({"FindMatches": findmatches}, glueContext))
```

5. Haga clic en el nodo Transformación personalizada en el gráfico visual y, a continuación, abra el panel de recursos mediante un clic en el símbolo de la cruz situado en la esquina superior izquierda del gráfico visual del trabajo y busque “Seleccionar de la colección”. No es necesario cambiar la selección predeterminada, ya que solo hay un DynamicFrame en la colección.

6. Puede seguir agregando transformaciones o almacenar el resultado, que ahora está enriquecido con las columnas adicionales de búsqueda de coincidencias. Si desea hacer referencia a esas nuevas columnas en las transformaciones posteriores, debe agregarlas al esquema de salida de la transformación. La forma más sencilla de hacerlo es elegir la pestaña de vista previa de datos y, a continuación, en la pestaña de esquema, elegir “Usar esquema de vista previa de datos”.
7. Para personalizar FindMatches, puede agregar parámetros adicionales para pasarlos al método 'aplicar'. Consulte Clase FindMatches.

Agregar una transformación de FindMatches de forma incremental

En el caso de coincidencias incrementales, el proceso es el mismo que el de Agregar una transformación FindMatches con las siguientes diferencias:

- En lugar de un nodo principal para la transformación personalizada, necesita dos nodos principales.
- El primer nodo principal debe ser el conjunto de datos.
- El segundo nodo principal debe ser el conjunto de datos incremental.

  Sustituya `transformId` con su `transformId` en la plantilla de bloque de código:

```
def MyTransform (glueContext, dfc) -> DynamicFrameCollection:
    dfs = list(dfc.values())
    dynf = dfs[0]
    inc_dynf = dfs[1]
    from awsglueml.transforms import FindIncrementalMatches
    findmatches = FindIncrementalMatches.apply(existingFrame = dynf, incrementalFrame
 = inc_dynf,
                                    transformId = "<your id>")
    return(DynamicFrameCollection({"FindMatches": findmatches}, glueContext))
```

- Para ver los parámetros opcionales, consulte Clase FindIncrementalMatches.

Migrar programas de Apache Spark a AWS Glue

Apache Spark es una plataforma de código abierto para cargas de trabajo de computación distribuidas que se realizan en conjuntos de datos de gran tamaño. AWS Glue aprovecha las capacidades de Spark para ofrecer una experiencia de ETL optimizada. Puede migrar programas

de Spark a AWS Glue para aprovechar nuestras características. AWS Glue proporciona las mismas mejoras de rendimiento que cabría esperar de Apache Spark en Amazon EMR.

Ejecutar código Spark

El código nativo Spark se puede ejecutar en un entorno de AWS Glue directamente. Los scripts a menudo se desarrollan al cambiar iterativamente un fragmento de código, un flujo de trabajo adecuado para una sesión interactiva. No obstante, el código existente es más adecuado para su ejecución en un trabajo de AWS Glue, que permite programar y obtener sistemáticamente registros y métricas para cada ejecución de script. Puede cargar y editar un script existente mediante la consola.

1. Adquiera el origen de su script. Para este ejemplo, utilizará un script de muestra del repositorio de Apache Spark. Ejemplo de binarizer
2. En la consola de AWS Glue, expanda el panel de navegación izquierdo y seleccione ETL > Jobs (Trabajos)

   En el panel Create job (Crear trabajo), seleccioneSpark script editor (Editor de scripts de Spark). Aparecerá la sección Options (Opciones). En Options (Opciones), elija Upload and edit an existing script (Cargar y editar un script existente).

   Aparecerá la sección File upload (Cargar archivo). En File upload (Cargar archivo), haga clic en Choose file (Elegir archivo). Aparecerá el selector de archivos del sistema. Vaya hasta la ubicación donde guardó `binarizer_example.py`, selecciónelo y confirme la opción elegida.

   Aparecerá el botón Create (Crear) en el encabezado del panel Create job (Crear trabajo). Haga clic allí.

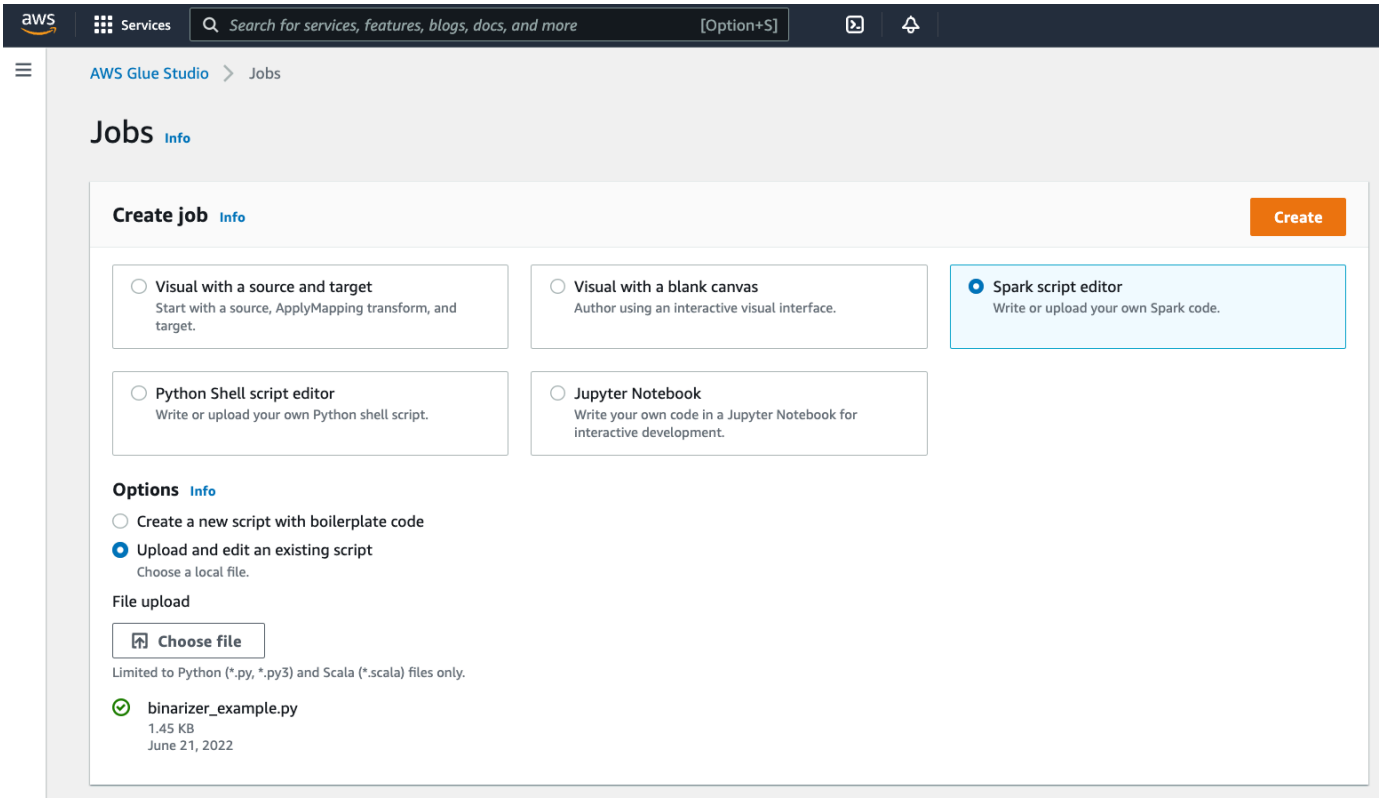

3. El navegador irá hasta el editor de scripts. En el encabezado, haga clic en la pestaña Job details (Detalles del trabajo). Defina el nombre y el Rol de IAM. Para obtener información sobre los roles de IAM de AWS Glue, consulte the section called “Configuración de permisos de IAM”.

   Opcionalmente: configure Requested number of workers (Cantidad solicitada de trabajadores) en 2 y Number of retries (Cantidad de reintentos) en 1. Estas opciones son valiosas a la hora de ejecutar trabajos de producción, pero rechazarlas agilizará la experiencia mientras prueba una función.

   En la barra de navegación, haga clic en Save (Guardar), luego en Run (Ejecutar)

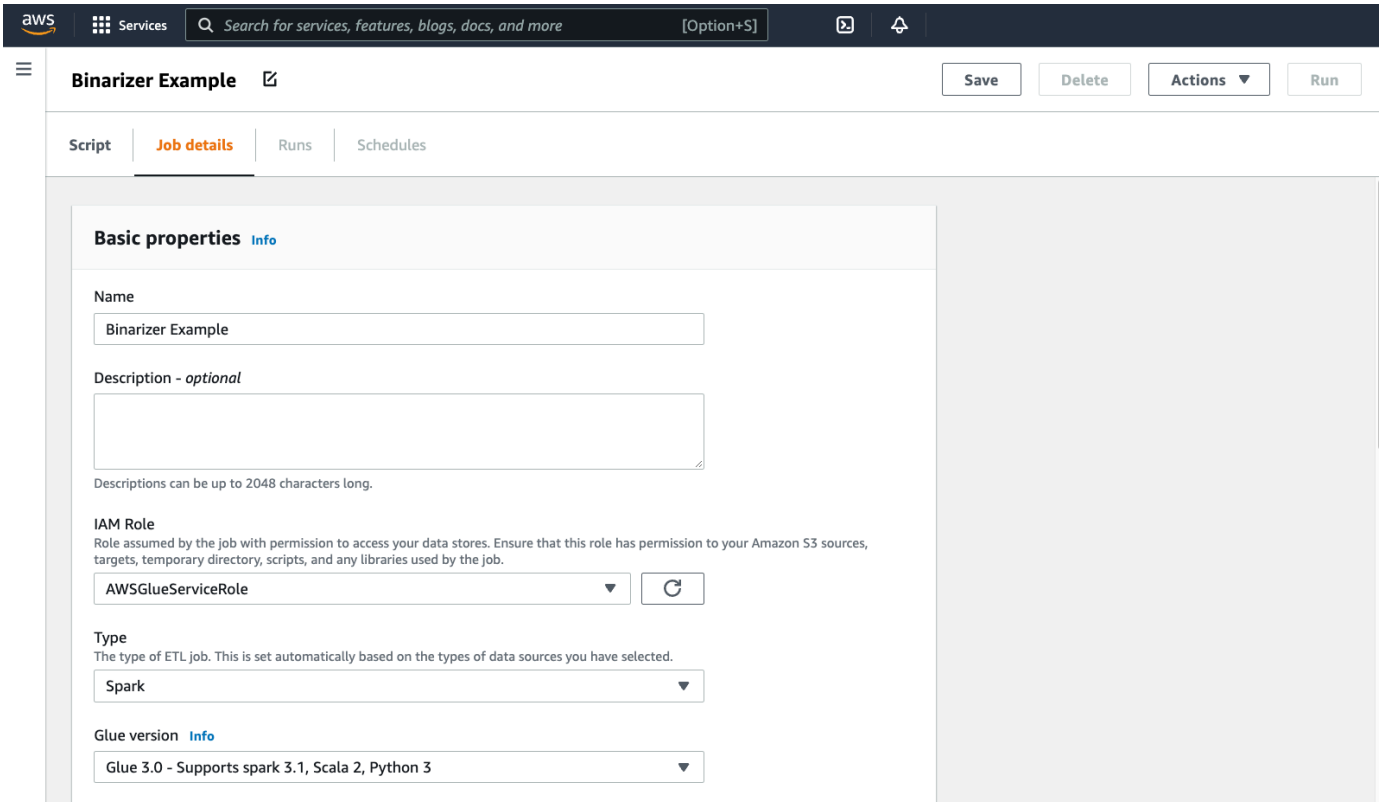

4. Vaya a la pestaña Runs (Ejecuciones). Verá un panel correspondiente a la ejecución de su trabajo. Espere unos minutos y la página deberá actualizarse automáticamente para mostrar Succeeded (Exitoso) en Run status (Estado de la ejecución).

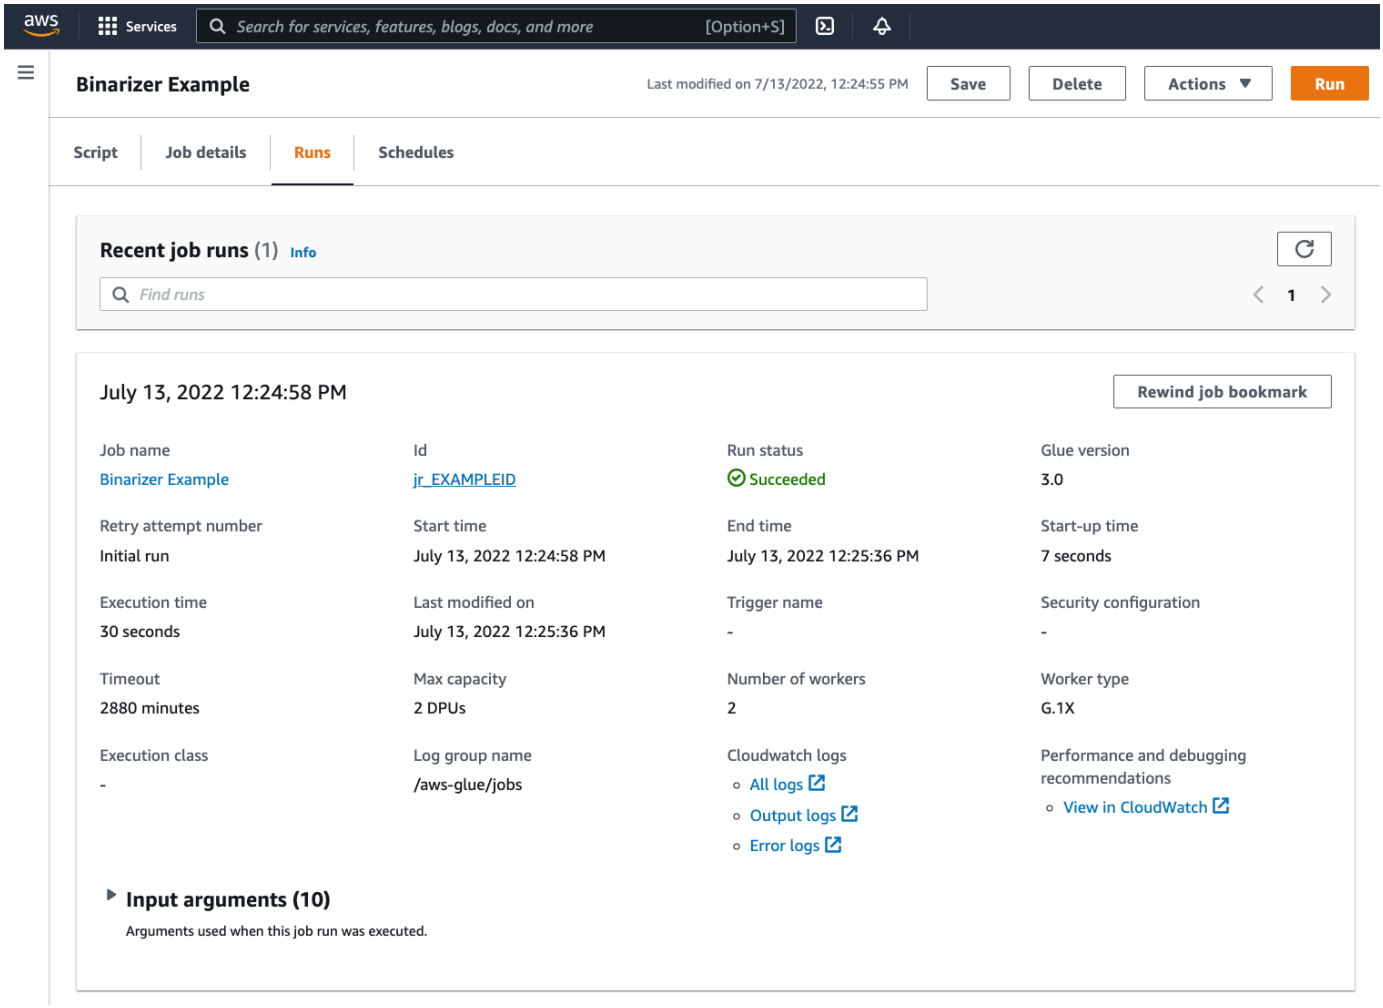

5. Deberá examinar la salida para confirmar que el script de Spark se ejecutó según lo previsto. Este script de ejemplo de Apache Spark debe escribir una cadena en la secuencia de salida. Puede encontrarlo yendo a Output logs (Registros de salida) en Registros de Cloudwatch (Cloudwatch logs) en el panel para la ejecución correcta del trabajo. Tenga en cuenta el id de ejecución de trabajo, un id generado en la etiqueta Id (Identificador) que comienza con `jr_`.

   Esto abrirá la consola de CloudWatch, configurada para visualizar el contenido del AWS Gluegrupo de registro`/aws-glue/jobs/output` predeterminado, filtrado al contenido de los flujos de registro para el identificador de ejecución del trabajo. Cada trabajador habrá generado un flujo de registro, que se muestra como filas en Log streams (Flujos de registro). Un trabajador debería haber ejecutado el código solicitado. Deberá abrir todos los flujos de registro para identificar al trabajador correcto. Una vez que encuentre el trabajador correcto, se debería ver la salida del script, como se ve en la siguiente imagen:

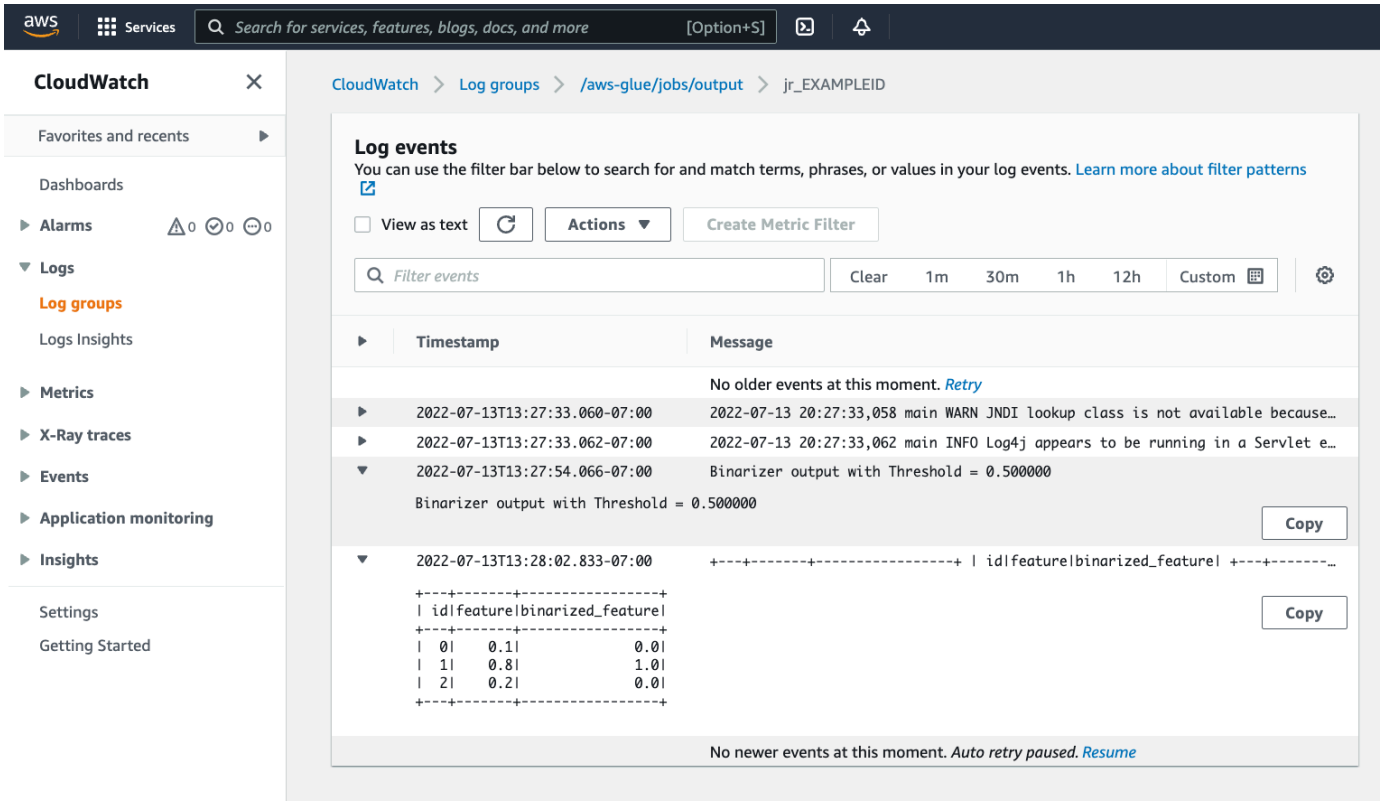

Procedimientos comunes necesarios para migrar programas Spark

Evaluar el soporte de la versión de Spark

Las versiones de AWS Glue determinan la versión de Apache Spark y Python disponible para el trabajo de AWS Glue. Puede encontrar nuestras versiones de AWS Glue y lo que admiten en the section called “AWS GlueVersiones de ”. Es posible que tenga que actualizar el programa de Spark para que sea compatible con una versión más reciente de Spark con el fin de acceder a determinadas características de AWS Glue.

Incluir bibliotecas de terceros

Muchos programas de Spark existentes tendrán dependencias, tanto en artefactos privados como públicos. AWS Glue admite dependencias de estilo JAR para trabajos de Scala, así como dependencias Wheel y de origen puro de Python para trabajos de Python.

Python: para obtener información sobre las dependencias de Python, consulte the section called “Bibliotecas Python”

Las dependencias habituales de Python se proporcionan en el entorno de AWS Glue, incluida la biblioteca Pandas que se suele solicitar. Estas dependencias se incluyen en AWS Glue versión

2.0+. Para obtener más información sobre los módulos proporcionados, consulte the section called "Módulos de Python que ya se proporcionaron en AWS". Si necesita suministrar un trabajo con una versión diferente de una dependencia incluida de manera predeterminada, puede utilizar `--additional-python-modules`. Para obtener información sobre argumentos de trabajo, consulte the section called "Parámetros del flujo de trabajo".

Puede proporcionar dependencias de Python adicionales con el argumento de trabajo `--extra-py-files`. Si va a migrar un trabajo desde un programa de Spark, este parámetro es una buena opción porque equivale funcionalmente al indicador `--py-files` de PySpark y está sujeto a las mismas limitaciones. Para obtener más información sobre el parámetro `--extra-py-files`, consulte the section called "Inclusión de archivos de Python con características nativas de PySpark"

Para los nuevos trabajos, puede administrar las dependencias de Python con el argumento de trabajo `--additional-python-modules`. El uso de este argumento permite una experiencia de administración de dependencias más completa. Este parámetro admite dependencias de estilo Wheel, incluidas aquellas con enlaces de código nativo compatibles con Amazon Linux 2.

Scala

Puede proporcionar dependencias de Scala adicionales con el argumento de trabajo `--extra-jars`. Las dependencias deben estar alojadas en Amazon S3 y el valor del argumento debe ser una lista delimitada por comas de rutas de Amazon S3 sin espacios. Puede que le resulte más fácil administrar la configuración si reagrupa las dependencias antes de alojarlas y configurarlas. AWS Glue Las dependencias JAR contienen código de bytes de Java, que se puede generar desde cualquier lenguaje JVM. Puede usar otros lenguajes de JVM, como Java, para escribir dependencias personalizadas.

Administrar credenciales de origen de datos.

Los programas Spark existentes pueden incluir una configuración compleja o personalizada para extraer datos de sus fuentes de datos. Los flujos de autenticación de orígenes de datos habituales son compatibles con conexiones de AWS Glue. Para obtener más información acerca de las conexiones de AWS Glue, consulte Conexión a datos.

Las conexiones de AWS Glue facilitan la conexión de un trabajo a diversos tipos de almacenes de datos principalmente de dos formas: mediante llamadas de métodos a nuestras bibliotecas y configurando Additional network connection (Conexión de red adicional) en la consola de AWS. También puede llamar al AWS SDK desde su trabajo para recuperar información de una conexión.

Llamada de métodos: las conexiones de AWS Glue están estrechamente integradas con el Catálogo de datos de AWS Glue, un servicio que permite seleccionar información sobre los conjuntos de datos, y los métodos disponibles para interactuar con las conexiones de AWS Glue así lo reflejan. Si tiene una configuración de autenticación existente que le gustaría reutilizar, para conexiones JDBC, puede acceder a la configuración de conexión de AWS Glue mediante el método `extract_jdbc_conf` en `GlueContext`. Para obtener más información, consulte the section called "extract_jdbc_conf".

Configuración de la consola: los trabajos de AWS Glue utilizan las conexiones de AWS Glue asociadas para configurar conexiones a subredes de Amazon VPC. Si administra directamente sus materiales de seguridad, es posible que tenga que proporcionar una Additional network connection (Conexión de red adicional) de tipo `NETWORK` en la consola de AWS para configurar el enrutamiento. Para obtener más información sobre la API de conexión de AWS Glue, consulte the section called "Connections".

Si sus programas Spark tienen un flujo de autenticación personalizado o poco común, es posible que tenga que gestionar los materiales de seguridad de forma manual. Si las conexiones de AWS Glue no resultan adecuadas, se puede alojar de manera segura los materiales de seguridad en Secrets Manager y acceder a ellos a través de boto3 o el AWS SDK, que se proporcionan en el trabajo.

Configurar Apache Spark

Las migraciones complejas a menudo alteran la configuración de Spark para adaptarse a sus cargas de trabajo. Las versiones modernas de Apache Spark permiten configurar el tiempo de ejecución con `SparkSession`. AWS Glue Se proporciona un `SparkSession` a los trabajos 3.0+, que se puede modificar para establecer la configuración del tiempo de ejecución. Configuración Apache Spark. Ajustar Spark es complejo, y AWS Glue no garantiza asistencia para realizar toda la configuración de Spark. Si la migración requiere una configuración importante en el nivel de Spark, contacte con el servicio de asistencia.

Establecer configuración personalizada

Los programas de Spark migrados se pueden diseñar para que adopten una configuración personalizada. AWS Glue permite establecer la configuración en el nivel del trabajo y la ejecución del trabajo, mediante los argumentos del trabajo. Para obtener información sobre argumentos de trabajo, consulte the section called "Parámetros del flujo de trabajo". Puede acceder a los argumentos del trabajo dentro del contexto de un trabajo a través de nuestras bibliotecas. AWS Glue proporciona una función de utilidad para ofrecer una vista coherente de los argumentos establecidos en el trabajo y

aquellos establecidos en la ejecución del trabajo. Consulte the section called “getResolvedOptions” en Python y the section called “GlueArgParser” en Scala.

Migración de código Java

Como se explica en the section called “Bibliotecas de terceros”, sus dependencias pueden contener clases generadas por lenguajes JVM, como Java o Scala. Sus dependencias pueden incluir un método de `main`. Puede usar un método de `main` en una dependencia como punto de entrada para un trabajo de Scala de AWS Glue. Esto permite escribir su método de `main` en Java, o reutilizar un método de `main` empaquetado según los estándares de su propia biblioteca.

Para usar un método de `main` de una dependencia, realice lo siguiente: borre el contenido del panel de edición proporcionando el objeto predeterminado `GlueApp`. Proporcione el nombre completo de una clase en una dependencia como argumento de trabajo con la clave de `--class`. Luego, podrá activar una ejecución de trabajo.

No se puede configurar el orden ni la estructura de los argumentos que AWS Glue pasa al método `main`. Si el código existente necesita leer la configuración establecida en AWS Glue, es probable que esto provoque incompatibilidad con el código anterior. Si usa `getResolvedOptions`, tampoco tendrá un buen lugar para llamar a este método. Considere la posibilidad de invocar la dependencia directamente desde un método main generado por AWS Glue. El siguiente script de ETL de AWS Glue muestra un ejemplo de esto.

```
import com.amazonaws.services.glue.util.GlueArgParser

object GlueApp {
  def main(sysArgs: Array[String]) {
    val args = GlueArgParser.getResolvedOptions(sysArgs, Seq("JOB_NAME").toArray)

    // Invoke static method from JAR. Pass some sample arguments as a String[], one
 defined inline and one taken from the job arguments, using getResolvedOptions
    com.mycompany.myproject.MyClass.myStaticPublicMethod(Array("string parameter1",
 args("JOB_NAME")))

    // Alternatively, invoke a non-static public method.
    (new com.mycompany.myproject.MyClass).someMethod()
  }
}
```

Trabajar con tareas de Ray en AWS Glue

En esta sección se proporciona información sobre el uso de AWS Glue para trabajos de Ray. Para obtener más información sobre cómo escribir scripts de AWS Glue para Ray, consulte la sección the section called “AWS Glue para Ray”.

Temas

- Introducción a AWS Glue para Ray
- Entornos de tiempo de ejecución de Ray compatibles
- Contabilidad de los trabajadores en los trabajos de Ray
- Uso de los parámetros de trabajo en los trabajos de Ray
- Supervisión de trabajos de Ray con métricas

Introducción a AWS Glue para Ray

Para trabajar con AWS Glue para Ray, se utilizan los mismos trabajos de AWS Glue y las mismas sesiones interactivas que se usan con AWS Glue para Spark. Los trabajos de AWS Glue están diseñados para ejecutar el mismo script de forma periódica, mientras que las sesiones interactivas están diseñadas para permitir ejecutar fragmentos de código de forma secuencial con los mismos recursos aprovisionados.

AWS Glue ETL y Ray son diferentes en el fondo, por lo que en el script tendrá acceso a diferentes herramientas, características y configuraciones. Como nuevo marco de cálculo administrado por AWS Glue, Ray tiene una arquitectura diferente y usa un vocabulario diferente para describir lo que hace. Para más información, consulte Architecture Whitepapers (Documentos técnicos sobre la arquitectura) en la documentación sobre Ray.

> **Note**
>
> AWS Glue para Ray está disponible en el Este de EE. UU. (Norte de Virginia), Este de EE. UU. (Ohio), Oeste de EE. UU. (Oregón), Asia Pacífico (Tokio) y Europa (Irlanda).

Trabajos de Ray en la consola de AWS Glue Studio

En la página Trabajos de la consola de AWS Glue Studio, puede seleccionar una nueva opción al crear un trabajo en el editor de scripts AWS Glue Studio Ray. Seleccione esta opción para crear un

trabajo de Ray en la consola. Para más información sobre los trabajos y cómo se utilizan, consulte Creación de trabajos de ETL visual.

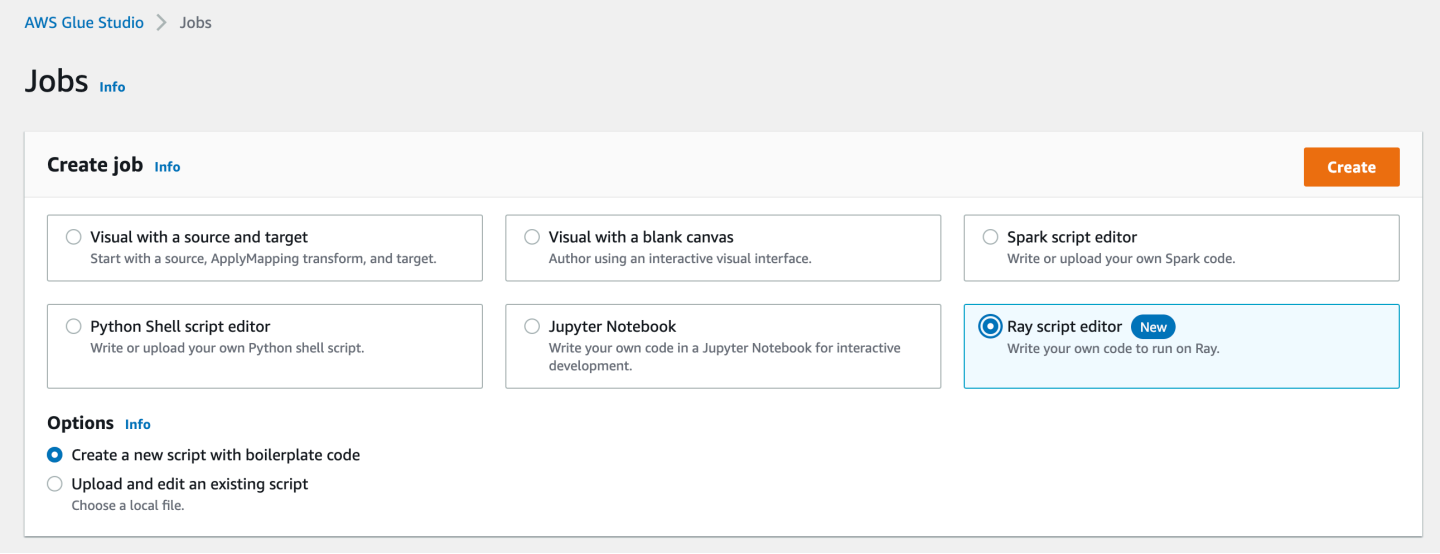

Trabajos de Ray en la AWS CLI y SDK

Los trabajos de Ray en la AWS CLI utilizan las mismas acciones y parámetros del SDK que los demás trabajos. AWS Glue para Ray introduce nuevos valores para determinados parámetros. Para más información sobre la API de trabajos, consulte the section called “Trabajos”.

Entornos de tiempo de ejecución de Ray compatibles

En los trabajos de Spark, `GlueVersion` determina las versiones de Apache Spark y Python disponibles en un trabajo de AWS Glue para Spark. La versión de Python indica la versión admitida para trabajos de tipo Spark. No es así como se configuran los entornos de tiempo de ejecución de Ray.

Para los trabajos de Ray, debe configurar `GlueVersion` en `4.0` o superior. Sin embargo, las versiones de Ray, Python y bibliotecas adicionales que están disponibles en el trabajo de Ray vienen determinadas por el campo `Runtime` de la definición del trabajo.

El entorno de tiempo de ejecución de `Ray2.4` estará disponible durante un mínimo de 6 meses después del lanzamiento. A medida que Ray evolucione rápidamente, podrá incorporar actualizaciones y mejoras de Ray en futuras versiones del entorno de tiempo de ejecución.

Valores válidos: `Ray2.4`

Valor de tiempo de ejecución	Versiones de Ray y Python
`Ray2.4` (para AWS Glue 4.0+)	Ray 2.4.0 Python 3.9

Información adicional

- Para ver las notas de la versión que acompañan a las versiones de AWS Glue para Ray, consulte the section called “AWS GlueVersiones de ”.
- Para ver las bibliotecas de Python que se proporcionan en un entorno de tiempo de ejecución, consulte the section called “Módulos incluidos con los trabajos de Ray”.

Contabilidad de los trabajadores en los trabajos de Ray

AWS Glue ejecuta los trabajos de Ray en los nuevos tipos de trabajadores de EC2 basados en Graviton, que solo están disponibles para los trabajos de Ray. Para aprovisionar adecuadamente a estos trabajadores para las cargas de trabajo para las que Ray está diseñado, ofrecemos una proporción diferente entre los recursos de cómputo y los recursos de memoria que la mayoría de los trabajadores. Para tener en cuenta estos recursos, utilizamos la unidad de procesamiento de datos optimizada para la memoria (M-DPU) en lugar de la unidad de procesamiento de datos (DPU) estándar.

- Una M-DPU corresponde a 4 vCPU y 32 GB de memoria.
- Una DPU corresponde a 4 vCPU y 16 GB de memoria. Las DPU se utilizan para contabilizar los recursos en AWS Glue con los trabajos de Spark y los trabajadores correspondientes.

Actualmente, los trabajos de Ray tienen acceso a un tipo de trabajador, `Z.2X`. El trabajador `Z.2X` se asigna a 2 M-DPU (8 vCPU, 64 GB de memoria) y tiene 128 GB de espacio en disco. Una máquina `Z.2X` proporciona 8 trabajadores de Ray (uno por vCPU).

La cantidad de M-DPU que puede utilizar simultáneamente en una cuenta está sujeta a una cuota de servicio. Para más información acerca de los límites de su cuenta de AWS Glue, consulte Puntos de conexión y cuotas de AWS Glue.

La cantidad de nodos de trabajo que están disponibles para un trabajo de Ray con `--number-of-workers (NumberOfWorkers)` se especifica en la definición de trabajo. Para obtener más información acerca de los valores Ray en la API de trabajos, consulte the section called “Trabajos”.

También puede especificar un número mínimo de trabajadores que un trabajo de Ray debe asignar con el parámetro de trabajo de `--min-workers`. Para obtener más información acerca de la configuración de parámetros de trabajos, consulte the section called “Referencia”.

Uso de los parámetros de trabajo en los trabajos de Ray

Establece los argumentos para los trabajos de Ray AWS Glue de la misma manera que establece los argumentos para AWS Glue para los trabajos de Spark. Para obtener más información sobre la API de AWS Glue, consulte the section called “Trabajos”. Puede configurar los trabajos de Ray AWS Glue con diferentes argumentos, que se enumeran en esta referencia. También puede presentar sus propios argumentos.

Puede configurar un trabajo en la consola, en la pestaña Job details (Detalles del trabajo), en el encabezado Job Parameters (Parámetros del trabajo). También puede configurar un trabajo mediante la AWS CLI al establecer `DefaultArguments` en un trabajo o `Arguments` en una ejecución de trabajos. Los parámetros de los trabajos y los argumentos predeterminados permanecerán con el trabajo durante varias ejecuciones.

Por ejemplo, a continuación se muestra la sintaxis para ejecutar un trabajo con `--arguments` para configurar un parámetro especial.

```
$ aws glue start-job-run --job-name "CSV to CSV" --arguments='--scriptLocation="s3://
my_glue/libraries/test_lib.py",--test-environment="true"'
```

Después de establecer los argumentos, puede acceder a los parámetros del trabajo desde su trabajo de Ray mediante variables de entorno. Esto permite configurar el trabajo para cada ejecución. El nombre de la variable de entorno será el nombre del argumento del trabajo sin el prefijo `--`.

Por ejemplo, en el anterior, los nombres de las variables serían `scriptLocation` y `test-environment`. Luego, recuperaría el argumento mediante los métodos disponibles en la biblioteca estándar: `test_environment = os.environ.get('test-environment')`. Para más información sobre el acceso a las variables de entorno con Python, consulte módulo del sistema operativo en la documentación de Python.

Configure la forma en que los trabajos de Ray generan registros

De forma predeterminada, los trabajos de Ray generan registros y métricas que se envían a CloudWatch y Amazon S3. Puede usar el parámetro `--logging_configuration` para modificar la forma en que se generan los registros; actualmente, puede usarlo para evitar que los trabajos de Ray generen varios tipos de registros. Este parámetro toma un objeto JSON, cuyas claves corresponden a los registros o comportamientos que desea modificar. Admite las siguientes claves:

- `CLOUDWATCH_METRICS`: configura las series de métricas de CloudWatch que se pueden usar para visualizar el estado del trabajo. Para obtener más información sobre las métricas, consulte the section called “Métricas de trabajo de Ray”.
- `CLOUDWATCH_LOGS`: configura los registros de CloudWatch que proporcionan detalles a nivel de aplicación de Ray acerca del estado de ejecución del trabajo. Para obtener más información acerca de los registros, consulte the section called “Solución de errores de Ray”.
- `S3`: configura lo que AWS Glue escribe en Amazon S3, principalmente información similar a la de los registros de CloudWatch, pero como archivos y no como flujos de registros.

Para deshabilitar un comportamiento de registro de Ray, indique el valor `{\"IS_ENABLED\": \"False\"}`. Por ejemplo, para deshabilitar las métricas y los registros de CloudWatch, proporcione la siguiente configuración:

```
"--logging_configuration": "{\"CLOUDWATCH_METRICS\": {\"IS_ENABLED\": \"False\"},
 \"CLOUDWATCH_LOGS\": {\"IS_ENABLED\": \"False\"}}"
```

Referencia

Los trabajos de Ray reconocen los siguientes nombres de argumentos que se pueden usar para configurar el entorno de scripts para los trabajos de Ray y las ejecuciones de trabajos:

- `--logging_configuration`: se usa para detener la generación de varios registros creados por trabajos de Ray. Estos registros se generan de forma predeterminada en todos los trabajos de Ray. Formato: objeto JSON incluido en una cadena de escape. Para obtener más información, consulte the section called “Configure la forma en que los trabajos de Ray generan registros”.
- `--min-workers`: la cantidad mínima de nodos de trabajo que se asignan a un trabajo de Ray. Un nodo de trabajo puede ejecutar varias réplicas, una por CPU virtual. Formato: entero. Mínimo: 0. Máximo: valor especificado en `--number-of-workers (NumberOfWorkers)` en la definición

del trabajo. Para obtener más información sobre la contabilidad de los nodos de trabajo, consulte the section called “Contabilidad de los trabajadores en los trabajos de Ray”.

- `--object_spilling_config`: AWS Glue porque Ray admite el uso de Amazon S3 como una forma de ampliar el espacio disponible para el almacén de objetos de Ray. Para habilitar este comportamiento, puede proporcionar a Ray un objeto que vuelque un objeto de configuración de JSON con este parámetro. Para obtener más información sobre la configuración de volcado de objetos de Ray, consulte Derrame de objetos en la documentación de Ray. Formato: objeto JSON.

  AWS Glue para Ray solo admite el volcado en el disco o en Amazon S3 a la vez. Puede proporcionar varios lugares para el volcado, siempre y cuando respeten esta limitación. Cuando vuelque a Amazon S3, también necesitará agregar permisos de IAM al trabajo para este bucket.

  Al proporcionar un objeto JSON como configuración con la CLI, debe proporcionarlo como una cadena, con el objeto JSON incluido en una cadena de escape. Por ejemplo, un valor de cadena para volcar en una ruta de Amazon S3 tendría el siguiente aspecto: `"{\"type\": \"smart_open\", \"params\": {\"uri\":\"s3path\"}}"`. En AWS Glue Studio, proporcione este parámetro como un objeto JSON sin formato adicional.
- `--object_store_memory_head`: la memoria asignada al almacén de objetos de Plasma en el nodo principal de Ray. Esta instancia ejecuta servicios de administración de clústeres, así como réplicas de procesos de trabajo. El valor representa un porcentaje de memoria libre en la instancia después de un inicio en caliente. Este parámetro se utiliza para ajustar las cargas de trabajo de uso intensivo de la memoria. Los valores predeterminados son aceptables para la mayoría de los casos de uso. Formato: entero positivo. Mínimo: 1. Máximo: 100.

  Para más información sobre Plasma, consulte The Plasma In-Memory Object Store (Almacén de objetos en memoria de Plasma) en la documentación de Ray.
- `--object_store_memory_worker`: memoria asignada al almacén de objetos de Plasma en los nodos de trabajo de Ray. Estas instancias solo ejecutan réplicas de procesos de trabajo. El valor representa un porcentaje de memoria libre en la instancia después de un inicio en caliente. Este parámetro se utiliza para ajustar las cargas de trabajo de uso intensivo de la memoria. Los valores predeterminados son aceptables para la mayoría de los casos de uso. Formato: entero positivo. Mínimo: 1. Máximo: 100.

  Para más información sobre Plasma, consulte The Plasma In-Memory Object Store (Almacén de objetos en memoria de Plasma) en la documentación de Ray.
- `--pip-install`: un conjunto de paquetes de Python para instalar. Puede instalar paquetes desde PyPI con este argumento. Formato: lista delimitada por comas.

Una entrada de paquete de PyPI tiene el formato `package==version`, con el nombre y la versión de PyPI del paquete de destino. Las entradas utilizan la coincidencia de versiones de Python para hacer coincidir el paquete y la versión, como ==, no la igualdad simple =. Hay otros operadores de coincidencia de versión. Para más información, consulte PEP 440 en el sitio web de Python. También puede proporcionar módulos personalizados con `--s3-py-modules`.

- `--s3-py-modules`: un conjunto de rutas de Amazon S3 que alojan distribuciones de módulos de Python. Formato: lista delimitada por comas.

  Puede usar esto para distribuir sus propios módulos en el trabajo de Ray. También puede proporcionar módulos desde PyPI con `--pip-install`. A diferencia de ETL de AWS Glue, los módulos personalizados no se configuran mediante pip, sino que se pasan a Ray para ser distribuidos. Para obtener más información, consulte the section called “Módulos de Python adicionales para trabajos de Ray”.

- `--working-dir`: una ruta a un archivo .zip alojado en Amazon S3 que contiene archivos que se van a distribuir a todos los nodos que ejecutan el trabajo de Ray. Formato: cadena. Para obtener más información, consulte the section called “Proporcionar archivos a su trabajo de Ray”.

Supervisión de trabajos de Ray con métricas

Puede supervisar los trabajos de Ray mediante AWS Glue Studio y Amazon CloudWatch. CloudWatch recopila y procesa las métricas sin formato desde AWS Glue con Ray, lo que las hace disponibles para el análisis. Estas métricas se visualizan en la consola de AWS Glue Studio, por lo que puede supervisar el trabajo a medida que se ejecuta.

Para obtener información general sobre cómo supervisar AWS Glue, consulte the section called “Uso de métricas de CloudWatch”. Para obtener una descripción general de cómo utilizar las métricas de CloudWatch publicadas por AWS Glue, consulte the section called “Monitoreo con CloudWatch”.

Supervisión de los trabajos de Ray en la consola de AWS Glue

En la página de detalles para una ejecución de trabajo, debajo de la sección Detalles de ejecución, puede consultar los gráficos agregados prediseñados que visualizan las métricas de trabajo disponibles. AWS Glue Studio envía las métricas del trabajo a CloudWatch para cada ejecución de trabajo. Con ellas, puede crear un perfil del clúster y las tareas y acceder a información detallada sobre cada nodo.

Para obtener más información sobre los gráficos de métricas disponibles, consulte the section called “Visualización de métricas de Amazon CloudWatch para una ejecución de trabajo de Ray”.

Información general de las métricas de trabajos de Ray en CloudWatch

Publicamos las métricas de Ray cuando la supervisión detallada está habilitada en CloudWatch. Las métricas se publican en el espacio de nombres de CloudWatch `Glue/Ray`.

- Métricas de la instancia

  Publicamos métricas acerca del uso de la CPU, la memoria y el disco de las instancias asignadas a un trabajo. Estas métricas se identifican mediante características como `ExecutorId`, `ExecutorType` y `host`. Estas métricas son un subconjunto de las métricas estándar de los agentes de CloudWatch de Linux. Puede encontrar información sobre los nombres y características de las métricas en la documentación de CloudWatch. Para más información, consulte Métricas que el agente de CloudWatch ha recopilado.

- Métricas del clúster de Ray

  Reenviamos las métricas de los procesos de Ray que ejecutan el script en este espacio de nombres, luego proporcionamos los más críticos. Las métricas disponibles pueden diferir según la versión de Ray. Para más información sobre qué versión de Ray está en ejecución en su trabajo, consulte the section called “AWS GlueVersiones de ”.

  Ray recopila métricas al nivel de instancia. También proporciona métricas para las tareas y el clúster. Para obtener más información sobre la estrategia de métricas subyacente de Ray, consulte Métricas en la documentación de Ray.

> **Note**
>
> No publicamos las métricas de Ray en el espacio de nombres de `Glue/Job Metrics/`, que solo se usa para trabajos de ETL de AWS Glue.

Configuración de las propiedades de trabajos del intérprete de comandos de Python en AWS Glue

Un trabajo de shell de Python puede usarse para ejecutar scripts de Python como un shell en AWS Glue. Con un trabajo del intérprete de comandos de Python puede ejecutar scripts compatibles con Python 3.6 o Python 3.9.

> **Note**
>
> La compatibilidad con Pyshell v3.6 finalizará el 1 de marzo de 2026. Para migrar sus cargas de trabajo, consulte Migrar desde trabajos de la shell de Python de AWS Glue. Si desea continuar con el intérprete de comandos de Python v3.9, consulte Migración del intérprete de comandos de Python 3.6 al intérprete de comandos de Python 3.9.

Temas

- Limitaciones
- Entorno de ejecución
- Definición de las propiedades de trabajos de shell de Python
- Bibliotecas compatibles con trabajos de shell de Python
- Proporcionar su propia biblioteca de Python
- Use AWS CloudFormation con los trabajos del intérprete de comandos de Python en AWS Glue
- Migración del intérprete de comandos de Python 3.6 al intérprete de comandos de Python 3.9
- Migrar desde trabajos de shell de AWS Glue Python

Limitaciones

Tenga en cuenta las siguientes limitaciones de los trabajos de Python Shell:

- No se pueden utilizar marcadores de trabajos con los trabajos de shell de Python.
- No se puede empaquetar ninguna biblioteca de Python como archivos `.egg` en Python 3.9 y superiores. En su lugar, utilice `.whl`.
- No se puede usar la opción `--extra-files` debido a una limitación en las copias temporales de los datos de S3.

Entorno de ejecución

Los trabajos del intérprete de comandos de Python se ejecutan en un entorno de ejecución administrado que proporciona acceso al almacenamiento local para el procesamiento temporal de datos:

Almacenamiento temporal local

El directorio `/tmp` está disponible para el almacenamiento temporal durante la ejecución del trabajo. Este directorio proporciona aproximadamente 14 GiB de espacio libre que puede utilizar para:

- Procesamiento de archivos temporales
- Almacenamiento de datos intermedios
- Almacenamiento en caché de pequeños conjuntos de datos

> **Note**
>
> El directorio `/tmp` es efímero y se limpia una vez finalizado el trabajo. No lo utilice para el almacenamiento persistente de datos importantes.

Definición de las propiedades de trabajos de shell de Python

Estas secciones describen la definición de propiedades de trabajo en AWS Glue Studio, o mediante el CLI de AWS.

AWS Glue Studio

Al definir su trabajo de shell de Python en AWS Glue Studio, debe proporcionar algunas de las siguientes propiedades:

rol de IAM

Especifique el rol de AWS Identity and Access Management (IAM) que se usa para dar una autorización a los recursos que se utilizan para ejecutar el flujo de trabajo y obtener acceso a los almacenes de datos. Para obtener más información acerca de los permisos para ejecutar trabajos en AWS Glue, consulte Administración de identidades y accesos para AWS Glue.

Tipo

Elija Python shell (Shell de Python) para ejecutar un script de Python con el comando de trabajo llamado `pythonshell`.

Versión de Python

Elija la versión de Python. El valor por defecto es Python 3.9. Las versiones válidas son Python 3.6 y Python 3.9.

Cargar bibliotecas de análisis comunes (recomendado)

Elija esta opción para incluir bibliotecas comunes para Python 3.9 en el shell de Python.

Si sus bibliotecas son personalizadas o entran en conflicto con las preinstaladas, puede optar por no instalar bibliotecas comunes. Sin embargo, puede instalar bibliotecas adicionales además de las bibliotecas comunes.

Si selecciona esta opción, la opción `library-set` se establece en `analytics`. Al anular la selección de esta opción, la opción `library-set` se establece en `none`.

Nombre de archivo de script y ruta de script

El código del script define la lógica de procedimiento del trabajo. Proporcione el nombre del script y la ubicación en Amazon Simple Storage Service (Amazon S3). Compruebe que no haya un archivo con el mismo nombre que el directorio de script en la ruta. Para obtener más información acerca de cómo usar scripts, consulte Guía de programación de AWS Glue.

Script

El código del script define la lógica de procedimiento del trabajo. Puede codificar el script en Python 3.6 o Python 3.9. Puede editar scripts en AWS Glue Studio.

Unidades de procesamiento de datos

El número máximo de unidades de procesamiento de datos (DPU) de AWS Glue que se pueden asignar cuando se ejecute este trabajo. Una DPU es una medida relativa de la potencia de procesamiento que consta de 4 vCPU de capacidad de cómputo y 16 GB de memoria. Para más información, consulte Precios de AWS Glue.

Puede establecer el valor en 0.0625 o 1. El valor predeterminado es 0.0625. En cualquier caso, el disco local para la instancia será de 20 GB.

CLI

También puede crear un trabajo de shell de Python con la AWS CLI, como en el siguiente ejemplo.

```
aws glue create-job --name python-job-cli --role Glue_DefaultRole
    --command '{"Name" :  "pythonshell", "PythonVersion": "3.9", "ScriptLocation" :
"s3://amzn-s3-demo-bucket/scriptname.py"}'
    --max-capacity 0.0625
```

> **Note**
>
> No es necesario especificar la versión de AWS Glue ya que el parámetro `--glue-version` no se aplica a los trabajos del intérprete de comandos de AWS Glue. Se ignorará cualquier versión especificada.

Trabajos que crea con el valor AWS CLI predeterminado en Python 3. Las versiones válidas de Python son 3 (que corresponden a 3.6) y 3.9. Para especificar Python 3.6, agregue esta tupla al parámetro `--command`: `"PythonVersion":"3"`

Para especificar Python 3.9, agregue esta tupla al parámetro `--command`: `"PythonVersion":"3.9"`

Para establecer la capacidad máxima utilizada por un trabajo de shell de Python, proporcione el parámetro `--max-capacity`. En los trabajos de shell de Python, no se puede utilizar el parámetro `--allocated-capacity`.

Bibliotecas compatibles con trabajos de shell de Python

En el shell de Python con Python 3.9, puede elegir el conjunto de bibliotecas para usar los conjuntos de bibliotecas preempaquetados según sus necesidades. Puede utilizar la opción `library-set` para elegir el conjunto de bibliotecas. Los valores válidos son `analytics` y `none`.

El entorno para la ejecución de un trabajo de shell de Python admite las siguientes bibliotecas:

Versión de Python	Python 3.6	Python 3.9	
Conjunto de bibliotecas	N/A	análisis	none

Versión de Python	Python 3.6	Python 3.9	
avro		1.11.0	
awscli	116.242	1.23.5	1.23.5
awswrangler		2.15.1	
botocore	1.12.232	1.24.21	1.23.5
boto3	1.9.203	1.21.21	
elasticsearch		8.2.0	
numpy	1.16.2	1.22.3	
pandas	0.24.2	1.4.2	
psycopg2		2.9.3	
pyathena		2.5.3	
PyGreSQL	5.0.6		
PyMySQL		1.0.2	
pyodbc		4.0.32	
pyorc		0.6.0	
redshift-connector		2.0.907	
solicitudes	2.22.0	2.27.1	
scikit-learn	0.20.3	1.0.2	
scipy	1.2.1	1.8.0	
SQLAlchemy		1.4.36	
s3fs		2022.3.0	

Puede utilizar la biblioteca NumPy en un trabajo de shell de Python para cálculos científicos. Para obtener más información, consulte NumPy. En el siguiente ejemplo se muestra un script NumPy que puede utilizarse en un trabajo de shell de Python. El script imprime “Hello world” y los resultados de varios cálculos matemáticos.

```
import numpy as np
print("Hello world")

a = np.array([20,30,40,50])
print(a)

b = np.arange( 4 )

print(b)

c = a-b

print(c)

d = b**2

print(d)
```

Proporcionar su propia biblioteca de Python

Uso de PIP

El shell de Python que usa Python 3.9 también le permite proporcionar módulos de Python adicionales o versiones diferentes al nivel de trabajo. Puede utilizar la opción `--additional-python-modules` con una lista de módulos Python separados por comas para agregar un nuevo módulo o cambiar la versión de un módulo existente. No puede proporcionar módulos de Python personalizados alojados en Amazon S3 con este parámetro al usar trabajos de intérprete de comandos de Python.

Por ejemplo, para actualizar o agregar un nuevo módulo `scikit-learn`, utilice la siguiente clave y valor: `"--additional-python-modules", "scikit-learn==0.21.3"`.

AWS Glue utiliza el instalador de paquetes de Python (pip3) para instalar los módulos adicionales. Puede incluir opciones de pip3 adicionales dentro del valor `--additional-python-modules`. Por

ejemplo, `"scikit-learn==0.21.3 -i https://pypi.python.org/simple/"`. Se aplican incompatibilidades o limitaciones de pip3.

> **Note**
>
> Para evitar incompatibilidades en el futuro, recomendamos usar bibliotecas creadas para Python 3.9.

Uso de un archivo Egg o Whl

Es posible que ya tenga una o varias bibliotecas de Python empaquetadas como un archivo `.egg` o `.whl`. En caso afirmativo, puede especificarlos en su trabajo utilizando la AWS Command Line Interface (AWS CLI) bajo la marca "`--extra-py-files`", como en el siguiente ejemplo.

```
aws glue create-job --name python-redshift-test-cli --role role --command '{"Name" :
 "pythonshell", "ScriptLocation" : "s3://MyBucket/python/library/redshift_test.py"}'
    --connections Connections=connection-name --default-arguments '{"--extra-py-
files" : ["s3://amzn-s3-demo-bucket/EGG-FILE", "s3://amzn-s3-demo-bucket/WHEEL-FILE"]}'
```

Si no está seguro de cómo crear un archivo `.egg` o `.whl` desde una biblioteca de Python, siga estos pasos. Este ejemplo es aplicable en macOS, Linux y Windows Subsystem for Linux (WSL).

Para crear un archivo .egg o.whl de Python

1. Cree un clúster de Amazon Redshift en una nube virtual privada (VPC) y agregue algunos datos a una tabla.
2. Cree una conexión de AWS Glue para la combinación VPC-GrupoDeSeguridad-Subred que utilizó para crear el clúster. Compruebe que la conexión se realiza correctamente.
3. Cree un directorio llamado `redshift_example` y cree un archivo denominado `setup.py`. Pegue el siguiente código en `setup.py`.

   ```
   from setuptools import setup

   setup(
       name="redshift_module",
       version="0.1",
       packages=['redshift_module']
   )
   ```

4. En el directorio `redshift_example`, cree un directorio `redshift_module`. En el directorio `redshift_module`, cree los archivos `__init__.py` y `pygresql_redshift_common.py`.
5. Deje vacío el archivo `__init__.py`. En `pygresql_redshift_common.py`, pegue el siguiente código: Sustituya *`port`*, *`db_name`*, *`user`*, y *`password_for_user`* con los detalles específicos de su clúster de Amazon Redshift. Sustituya *`table_name`* por el nombre de la tabla en Amazon Redshift.

```
import pg


def get_connection(host):
    rs_conn_string = "host=%s port=%s dbname=%s user=%s password=%s" % (
        host, port, db_name, user, password_for_user)

    rs_conn = pg.connect(dbname=rs_conn_string)
    rs_conn.query("set statement_timeout = 1200000")
    return rs_conn


def query(con):
    statement = "Select * from table_name;"
    res = con.query(statement)
    return res
```

6. Si no está ya en él, cambie al directorio `redshift_example`.
7. Realice una de las siguientes acciones:

   - Ejecute el siguiente comando para crear un archivo `.egg`.

     ```
     python setup.py bdist_egg
     ```

   - Ejecute el siguiente comando para crear un archivo `.whl`.

     ```
     python setup.py bdist_wheel
     ```

8. Instale las dependencias necesarias para el comando anterior.
9. El comando crea un archivo en el directorio `dist`:

   - Si ha creado un archivo egg, se llamará `redshift_module-0.1-py2.7.egg`.

- Si ha creado un archivo wheel, se llamará `redshift_module-0.1-py2.7-none-any.whl`.

Cargue este archivo en Amazon S3.

En este ejemplo, la ruta del archivo cargado es *`s3://amzn-s3-demo-bucket/EGG-FILE`* o *`s3://amzn-s3-demo-bucket/WHEEL-FILE`*.

10. Cree un archivo de Python que se debe usar como script para el trabajo de AWS Glue y añada el siguiente código al archivo.

```
from redshift_module import pygresql_redshift_common as rs_common

con1 = rs_common.get_connection(redshift_endpoint)
res = rs_common.query(con1)

print "Rows in the table cities are: "

print res
```

11. Cargue el archivo anterior en Amazon S3. En este ejemplo, la ruta del archivo cargado es *`s3://amzn-s3-demo-bucket/scriptname.py`*.
12. Cree un trabajo de shell de Python con este script. En la consola de AWS Glue, en la página Job properties (Propiedades del trabajo), especifique la ruta del archivo `.egg/.whl` en el cuadro Python library path (Ruta de la biblioteca Python). Si tiene varios archivos `.egg/.whl` y archivos de Python, proporcione una lista separada por comas en este cuadro.

    Al modificar o cambiar el nombre de los archivos `.egg`, los nombres de archivo deben usar los nombres predeterminados generados por el comando “python setup.py bdist_egg” o deben cumplir con las convenciones de nomenclatura del módulo Python. Para obtener más información, consulte Style Guide for Python Code.

    Con la AWS CLI, cree un trabajo con un comando, como en el siguiente ejemplo.

```
aws glue create-job --name python-redshift-test-cli --role Role --command
 '{"Name" :  "pythonshell", "ScriptLocation" : "s3://amzn-s3-demo-bucket/
scriptname.py"}'
     --connections Connections="connection-name" --default-arguments '{"--extra-
py-files" : ["s3://amzn-s3-demo-bucket/EGG-FILE", "s3://amzn-s3-demo-bucket/WHEEL-
FILE"]}'
```

Cuando se ejecuta el trabajo, el script imprime las filas creadas en la tabla *table_name* en el clúster de Amazon Redshift.

Use AWS CloudFormation con los trabajos del intérprete de comandos de Python en AWS Glue

Puede usar AWS CloudFormation con los trabajos del intérprete de comandos de Python en AWS Glue. A continuación, se muestra un ejemplo:

```
AWSTemplateFormatVersion: 2010-09-09
Resources:
  Python39Job:
    Type: 'AWS::Glue::Job'
    Properties:
      Command:
        Name: pythonshell
        PythonVersion: '3.9'
        ScriptLocation: 's3://bucket/location'
      MaxRetries: 0
      Name: python-39-job
      Role: RoleName
```

El grupo de Amazon CloudWatch Logs para la salida de los trabajos de shell de Python es `/aws-glue/python-jobs/output`. En el caso de los errores, consulte el grupo de registros `/aws-glue/python-jobs/error`.

Migración del intérprete de comandos de Python 3.6 al intérprete de comandos de Python 3.9

Para migrar sus trabajos del intérprete de comandos de Python a la versión AWS Glue más reciente:

1. En la consola de AWS Glue (https://console.aws.amazon.com/glue/), elija su trabajo del intérprete de comandos de Python existente.
2. En la pestaña Detalles del trabajo, establezca la versión de Python en `Python 3.9` y seleccione Guardar.
3. Asegúrese de que su script de trabajo sea compatible con Python 3.9 y de que se ejecute correctamente.

Migrar desde trabajos de shell de AWS Glue Python

AWS lanzó los trabajos de shell deAWS Glue Python en 2018 AWS lanzó los trabajos de shell de AWS Glue Python en 2018 con el fin de ofrecer a los clientes una forma sencilla de ejecutar scripts de Python para trabajos ETL de tamaño pequeño a mediano y activar consultas SQL. Sin embargo, ahora hay opciones más modernas y flexibles para abordar las cargas de trabajo que se ejecutan actualmente en PythonShell. En este tema se explica cómo migrar las cargas de trabajo de los trabajos de shell de AWS Glue Python a una de estas opciones alternativas para aprovechar las nuevas capacidades disponibles.

En este tema se explica cómo hacer la migración de trabajos de shell de AWS Glue Python a opciones alternativas.

Migración de la carga de trabajo a los trabajos de AWS Glue Spark

Los trabajos de AWS Glue Spark y PySpark le permiten ejecutar sus cargas de trabajo de forma distribuida. Dado que tanto los trabajos de shell de AWS Glue Python como los de AWS Glue Spark se ejecutan en la misma plataforma, es fácil migrarlos y puede seguir utilizando las características de AWS Glue existentes que utiliza con los trabajos de shell de Python, como AWS Glue Workflows, AWS Glue Triggers, la integración de Amazon EventBridge de AWS Glue, la instalación de paquetes basada en PIP, etc.

Sin embargo, los trabajos de AWS Glue Spark están diseñados para ejecutar cargas de trabajo de Spark y el número mínimo de trabajadores es de 2. Si migra desde trabajos de shell de Python sin modificar sus scripts, se utilizará en realidad un solo elemento de trabajo y los demás permanecerán inactivos. Esto aumentará sus costos.

Para que sea eficiente, reescriba su script de trabajo de Python para utilizar las capacidades de Spark y distribuir la carga de trabajo entre varios trabajadores. Si su script de Python está basado en Pandas, es fácil migrarlo con la nueva API de Pandas en Spark. Obtenga más información sobre esto en AWS Big Data Blog: análisis profundo de AWS Glue 4.0 para Apache Spark.

Migración de una carga de trabajo a AWS Lambda

AWS Lambda es un servicio informático sin servidor que permite ejecutar código sin aprovisionar ni administrar servidores. Como AWS Lambda tiene tiempos de inicio más cortos y opciones de capacidad de cómputo más flexibles, puede aprovechar estas ventajas. Para administrar bibliotecas de Python adicionales, los trabajos de shell deAWS Glue Python utilizan una instalación basada en

PIP. Sin embargo, para AWS Lambda, debe elegir una de las siguientes opciones: un archivo zip, una imagen de contenedor o capas Lambda.

Por otro lado, el tiempo de espera máximo de AWS Lambda es de 900 segundos (15 minutos). Si la duración de su carga de trabajo actual del trabajo de shell de AWS Glue Python es mayor, o si su carga de trabajo tiene un patrón de picos que puede provocar una mayor duración de los trabajos, le recomendamos que explore otras opciones en lugar de AWS Lambda.

Migración de la carga de trabajo a Amazon ECS/Fargate

Amazon Elastic Container Service (Amazon ECS) es un servicio completamente administrado que simplifica la implementación, la administración y el escalado de aplicaciones en contenedores. AWS Fargate es un motor de cómputo sin servidor para cargas de trabajo en contenedores que se ejecutan en Amazon ECS y Amazon Elastic Kubernetes Service (Amazon EKS). No hay un tiempo de espera máximo en Amazon ECS y Fargate, por lo que es una buena opción para trabajos de larga duración. Dado que tiene el control total sobre la imagen de su contenedor, puede incluir su script de Python y las bibliotecas de Python adicionales en el contenedor y usarlas. Sin embargo, debe colocar su script de Python en contenedores para utilizar este enfoque.

Migración de la carga de trabajo al operador Python de Amazon Managed Workflows para Apache Airflow

Amazon Managed Workflows para Apache Airflow (MWAA) es un servicio de orquestación administrada para Apache Airflow que facilita la configuración y el funcionamiento de canalizaciones de datos integrales en la nube a escala. Si ya dispone de un entorno MWAA, le resultará sencillo utilizar el operador Python en lugar de los trabajos de shell de AWS Glue Python. El operador Python es un operador que ejecuta código Python dentro de un flujo de trabajo de Airflow. Sin embargo, si no cuenta con un entorno MWAA existente, le recomendamos que explore otras opciones.

Migración de la carga de trabajo a trabajos de entrenamiento de Amazon SageMaker AI AI

Amazon SageMaker AI Training es un servicio de machine learning (ML) totalmente administrado que Amazon SageMaker AI ofrece y que le ayuda a entrenar de manera eficaz una amplia gama de modelos de ML a escala. El núcleo de los trabajos de Amazon SageMaker AI AI es la creación de contenedores de las cargas de trabajo de ML y la capacidad de administrar los recursos de computación de AWS. Si prefiere un entorno sin servidor en el que no haya un tiempo de espera máximo, los trabajos de entrenamiento de Amazon SageMaker AI AI podrían ser una buena opción

para usted. Sin embargo, la latencia de inicio tiende a ser mayor que la de los trabajos de shell de AWS Glue Python. Para trabajos sensibles a la latencia, le recomendamos explorar otras opciones.

Supervisión de AWS Glue

El monitoreo es una parte importante del mantenimiento de la fiabilidad, la disponibilidad y el desempeño de AWS Glue y otras soluciones de AWS. AWS ofrece herramientas de monitorización que puede utilizar para controlar a AWS Glue, informar cuando algo no funciona y realizar acciones automáticamente cuando proceda:

Puede utilizar las siguientes herramientas de monitorización automatizado para vigilar AWS Glue e informar cuando haya algún problema:

- Amazon CloudWatch Events proporciona un flujo de eventos de sistema casi en tiempo real que describe cambios en los recursos de AWS. CloudWatch Events habilita una informática basada en eventos automatizada. Puede escribir reglas que vigilan determinados eventos y activan acciones automatizadas en otros servicios de AWS cuando estos eventos se producen. Para obtener más información, consulte la Guía del usuario de los Eventos de Amazon CloudWatch.
- Amazon CloudWatch Logs le permite monitorear, almacenar y tener acceso a los archivos de registro desde instancias de Amazon EC2, AWS CloudTrail u otros orígenes. Los registros de CloudWatch pueden monitorear información en los registros y enviarle una notificación cuando se llega a determinados umbrales. También se pueden archivar los datos del registro en un almacenamiento de larga duración. Para obtener más información, consulte la Guía del usuario de Registros de Amazon CloudWatch.
- AWS CloudTrail captura llamadas a la API y eventos relacionados efectuados por su cuenta de AWS o en su nombre, y entrega los archivos de registro al bucket de Amazon S3 que se haya especificado. También se puede identificar qué usuarios y cuentas llaman a AWS, la dirección IP de origen desde la que se realizan las llamadas y el momento en que se efectúan las llamadas. Para obtener más información, consulte la Guía del usuario de AWS CloudTrail.

Además, tiene acceso a la siguiente información de la consola de AWS Glue que le ayudará a depurar y perfilar los trabajos:

- Trabajos de Spark: puede visualizar series de métricas seleccionadas de CloudWatch y los trabajos más nuevos tienen acceso a la interfaz de usuario de Spark. Para obtener más información, consulte the section called “Monitoreo de trabajos de Spark”.

- Trabajos de Ray: puede visualizar las series de métricas seleccionadas de CloudWatch. Para obtener más información, consulte the section called “Métricas de trabajo de Ray”.

Temas

- Etiquetas de AWS en AWS Glue
- Automatizar AWS Glue con EventBridge
- Monitorización de recursos de AWS Glue
- Registrar llamadas a la API de AWS Glue con AWS CloudTrail

Etiquetas de AWS en AWS Glue

Para que le resulte más fácil administrar los recursos de AWS Glue, también puede asignar sus propias etiquetas a algunos tipos de recursos de AWS Glue. Una etiqueta es una marca que se asigna a un recurso de AWS. Cada etiqueta está formada por una clave y un valor opcional, ambos definidos por el usuario. Puede utilizar etiquetas de AWS Glue para organizar e identificar los recursos. Las etiquetas se pueden utilizar para crear informes de contabilidad de costos y restringir el acceso a los recursos. Si utiliza AWS Identity and Access Management, puede controlar qué usuarios de su cuenta de AWS tienen permiso para crear, editar o eliminar etiquetas. Además de los permisos para llamar a las API relacionadas con etiquetas, también necesita el permiso `glue:GetConnection` para llamar a las API de etiquetado en las conexiones y el permiso `glue:GetDatabase` para llamar a las API de etiquetado en las bases de datos. Para obtener más información, consulte ABAC con AWS Glue.

En AWS Glue, se pueden etiquetar los siguientes recursos:

- Connection
- Database
- Rastreador
- Sesión interactiva
- Punto de enlace de desarrollo
- Trabajo
- Desencadenador
- Flujo de trabajo
- Esquema

- Transformación de machine learning
- Conjunto de reglas de calidad de datos
- Esquemas de streaming
- Registros de esquemas de streaming

> **Note**
>
> Como práctica recomendada, para permitir el etiquetado de estos recursos de AWS Glue, incluya siempre la acción `glue:TagResource` en sus políticas.

Cuando utilice etiquetas con , tenga en cuenta lo siguiente: AWS Glue.

- Se permite un máximo de 50 etiquetas por entidad.
- En AWS Glue, debe especificar etiquetas como una lista de pares clave-valor con el formato `{"string": "string" ...}`
- Al crear una etiqueta en un objeto, la clave de etiqueta es obligatoria y el valor de la etiqueta es opcional.
- La clave y el valor de la etiqueta distinguen entre mayúsculas y minúsculas.
- La clave de etiqueta y el valor de etiqueta no deben contener el prefijo aws. No se permiten operaciones en este tipo de etiquetas.
- La longitud máxima de la clave de etiqueta es de 128 caracteres Unicode en UTF-8. La clave de etiqueta no debe estar vacía ni ser nula.
- La longitud máxima del valor de etiqueta es de 256 caracteres Unicode en UTF-8. El valor de etiqueta puede estar vacío o ser nulo.

Compatibilidad con el etiquetado en conexiones de AWS Glue

Puede restringir los permisos de la acción `CreateConnection`, `UpdateConnection`, `GetConnection` y `DeleteConnection` en función de la etiqueta de recurso. Esto permite implementar el control de acceso de privilegio mínimo en trabajos de AWS Glue con orígenes de datos JDBC que necesitan obtener información de conexión JDBC de Data Catalog.

Ejemplo de uso

Creación de una conexión AWS Glue con la etiqueta ["connection-category", "dev-test"].

Especifique la condición de etiqueta para la acción `GetConnection` en la política de IAM.

```
{
   "Effect": "Allow",
   "Action": [
     "glue:GetConnection"
     ],
   "Resource": "*",
   "Condition": {
     "ForAnyValue:StringEquals": {
       "aws:ResourceTag/tagKey": "dev-test"
     }
   }
 }
```

Ejemplos

Los siguientes ejemplos crean un trabajo con etiquetas asignadas.

AWS CLI

```
aws glue create-job --name job-test-tags --role MyJobRole --command
 Name=glueetl,ScriptLocation=S3://aws-glue-scripts//prod-job1
--tags key1=value1,key2=value2
```

CloudFormation JSON

```
{
  "Description": "AWS Glue Job Test Tags",
  "Resources": {
    "MyJobRole": {
      "Type": "AWS::IAM::Role",
      "Properties": {
        "AssumeRolePolicyDocument": {
          "Version": "2012-10-17",
          "Statement": [
            {
              "Effect": "Allow",
              "Principal": {
                "Service": [
                  "glue.amazonaws.com"
                ]
              },
```

```
            "Action": [
              "sts:AssumeRole"
            ]
          }
        ]
      },
      "Path": "/",
      "Policies": [
        {
          "PolicyName": "root",
          "PolicyDocument": {
            "Version": "2012-10-17",
            "Statement": [
              {
                "Effect": "Allow",
                "Action": "*",
                "Resource": "*"
              }
            ]
          }
        }
      ]
    }
  },
  "MyJob": {
    "Type": "AWS::Glue::Job",
    "Properties": {
      "Command": {
        "Name": "glueetl",
        "ScriptLocation": "s3://aws-glue-scripts//prod-job1"
      },
      "DefaultArguments": {
        "--job-bookmark-option": "job-bookmark-enable"
      },
      "ExecutionProperty": {
        "MaxConcurrentRuns": 2
      },
      "MaxRetries": 0,
      "Name": "cf-job1",
      "Role": {
         "Ref": "MyJobRole",
         "Tags": {
              "key1": "value1",
              "key2": "value2"
```

```
            }
          }
        }
      }
    }
}
```

CloudFormation YAML

```
Description: AWS Glue Job Test Tags
Resources:
  MyJobRole:
    Type: AWS::IAM::Role
    Properties:
      AssumeRolePolicyDocument:
        Version: '2012-10-17'
        Statement:
          - Effect: Allow
            Principal:
              Service:
                - glue.amazonaws.com
            Action:
              - sts:AssumeRole
      Path: "/"
      Policies:
        - PolicyName: root
          PolicyDocument:
            Version: '2012-10-17'
            Statement:
              - Effect: Allow
                Action: "*"
                Resource: "*"
  MyJob:
    Type: AWS::Glue::Job
    Properties:
      Command:
        Name: glueetl
        ScriptLocation: s3://aws-glue-scripts//prod-job1
      DefaultArguments:
        "--job-bookmark-option": job-bookmark-enable
      ExecutionProperty:
        MaxConcurrentRuns: 2
      MaxRetries: 0
```

```
      Name: cf-job1
      Role:
        Ref: MyJobRole
        Tags:
           key1: value1
           key2: value2
```

Para obtener más información, consulte Estrategias de etiquetado de AWS.

Para obtener más información acerca de cómo controlar el acceso con etiquetas, consulte ABAC con AWS Glue.

Automatizar AWS Glue con EventBridge

Puede utilizar Amazon EventBridge para automatizar los servicios de AWS y responder automáticamente a eventos del sistema, como problemas de disponibilidad de las aplicaciones o cambios en los recursos. Los eventos de los servicios de AWS se envían a EventBridge casi en tiempo real. Puede crear reglas sencillas para indicar qué eventos le resultan de interés, así como qué acciones automatizadas se van a realizar cuando un evento cumple una de las reglas. Entre las acciones que se pueden activar automáticamente se incluyen las siguientes:

- Invocar una función de AWS Lambda
- Invocar Ejecutar comando de Amazon EC2
- Desviar el evento a Amazon Kinesis Data Streams
- Activar una máquina de estado de AWS Step Functions
- Notificar un tema de Amazon SNS o una cola de Amazon SQS

Algunos ejemplos del uso de EventBridge con AWS Glue incluyen los siguientes:

- Activar una función de Lambda cuando se realiza correctamente un trabajo de ETL
- Notificar un tema de Amazon SNS cuando un trabajo de ETL produce error

El siguiente EventBridge es generado por AWS Glue.

- Se generan eventos de `"detail-type":"Glue Job State Change"` para `SUCCEEDED`, `FAILED`, `TIMEOUT` y `STOPPED`.
- Se generan eventos de `"detail-type":"Glue Job Run Status"` para ejecuciones de trabajos `RUNNING`, `STARTING` o `STOPPING` cuando superan el umbral de notificación de retraso

de flujo de trabajo. Debe configurar la propiedad de umbral de notificación de retraso en el trabajo para recibir estos eventos.

Solo se genera un evento por estado de ejecución de un trabajo cuando se supera el umbral de notificación de retraso en el trabajo.

- Se generan eventos de `"detail-type":"Glue Crawler State Change"` para `Started`, `Succeeded` y `Failed`.
- Los eventos para `“detail_type”:“Glue Scheduled Crawler Invocation Failure”` se generan cuando el rastreador programado no se inicia. En los detalles de la notificación:
  - `customerId` contiene el ID de la cuenta del cliente.
  - `crawlerName` contiene el nombre del rastreador que no se pudo iniciar.
  - `errorMessage` contiene el mensaje de excepción del error de invocación.
- Los eventos para `“detail_type”:“Glue Auto Statistics Invocation Failure“` se generan cuando la ejecución de la tarea de estadísticas de columnas gestionada automáticamente no se inicia. En los detalles de la notificación:
  - `catalogId` contiene el ID asociado a un catálogo.
  - `databaseName` contiene el nombre de la base de datos afectada.
  - `tableName` contiene el nombre de la tabla afectada.
  - `errorMessage` contiene el mensaje de excepción del error de invocación.
- Los eventos para `“detail_type”:“Glue Scheduled Statistics Invocation Failure”` se generan cuando falla el inicio de la tarea programada (cron) de estadísticas de columnas. En los detalles de la notificación:
  - `catalogId` contiene el ID asociado a un catálogo.
  - `databaseName` contiene el nombre de la base de datos afectada.
  - `tableName` contiene el nombre de la tabla afectada.
  - `errorMessage` contiene el mensaje de excepción del error de invocación.
- Los eventos para `“detail_type”:“Glue Statistics Task Started”` se generan cuando se inicia la ejecución de la tarea de estadísticas de columnas.
- Los eventos para `“detail_type”:“Glue Statistics Task Succeeded”` se generan cuando la ejecución de la tarea de estadísticas de columnas finaliza correctamente.
- Los eventos para `“detail_type”:“Glue Statistics Task Failed”` se generan cuando falla la ejecución de la tarea de estadísticas de columnas.

- Se generan eventos de `"detail-type":"Glue Data Catalog Database State Change"` para `CreateDatabase`, `DeleteDatabase`, `CreateTable`, `DeleteTable` y `BatchDeleteTable`. Por ejemplo, si se crea o elimina una tabla, se envía una notificación a EventBridge. Tenga en cuenta que no puede escribir un programa que dependa del orden o de la existencia de eventos de notificación, ya que pueden no estar ordenados o faltar. Los eventos se emiten en la medida de lo posible. En los detalles de la notificación:
  - `typeOfChange` contiene el nombre de una operación API.
  - `databaseName` contiene el nombre de la base de datos afectada.
  - `changedTables` contiene hasta 100 nombres de tablas afectadas por notificación. Cuando los nombres de las tablas son largos, podrían crearse varias notificaciones.
- Se generan eventos de `"detail-type":"Glue Data Catalog Table State Change"` para `UpdateTable`, `CreatePartition`, `BatchCreatePartition`, `UpdatePartition`, `DeletePartition`, `BatchUpdatePartition` y `BatchDeletePartition`. Por ejemplo, si se actualiza una tabla o partición, se envía una notificación a EventBridge. Tenga en cuenta que no puede escribir un programa que dependa del orden o de la existencia de eventos de notificación, ya que pueden no estar ordenados o faltar. Los eventos se emiten en la medida de lo posible. En los detalles de la notificación:
  - `typeOfChange` contiene el nombre de una operación API.
  - `databaseName` contiene el nombre de la base de datos que contiene los recursos afectados.
  - `tableName` contiene el nombre de la tabla afectada.
  - `changedPartitions` especifica hasta 100 particiones afectadas en una notificación. Cuando los nombres de las particiones son largos, podrían crearse varias notificaciones.

    Por ejemplo, si hay dos claves de partición, `Year` y `Month`, `"2018,01", "2018,02"` modifica la partición donde `"Year=2018" and "Month=01"` y la partición donde `"Year=2018" and "Month=02"`.

```
{
    "version":"0",
    "id":"abcdef00-1234-5678-9abc-def012345678",
    "detail-type":"Glue Data Catalog Table State Change",
    "source":"aws.glue",
    "account":"123456789012",
    "time":"2017-09-07T18:57:21Z",
    "region":"us-west-2",
    "resources":["arn:aws:glue:us-west-2:123456789012:database/default/foo"],
    "detail":{
```

```
        "changedPartitions": [
            "2018,01",
            "2018,02"
        ],
        "databaseName": "default",
        "tableName": "foo",
        "typeOfChange": "BatchCreatePartition"
        }
}
```

Para obtener más información, consulte la Guía del usuario de los Eventos de Amazon CloudWatch. Para eventos específicos de AWS Glue consulte Eventos de AWS Glue.

Monitorización de recursos de AWS Glue

AWS Glue tiene límites de servicio para proteger a los clientes de un aprovisionamiento excesivo inesperado y de acciones malintencionadas destinadas a aumentar la factura. Los límites también protegen el servicio. Al iniciar sesión en la consola de Service Quotas de AWS, los clientes pueden ver sus límites de recursos actuales y solicitar un aumento (si procede).

AWS Glue permite ver el uso de los recursos del servicio como un porcentaje en Amazon CloudWatch y configurar las alarmas de CloudWatch para supervisar el uso. Amazon CloudWatch supervisa los recursos de AWS y las aplicaciones de los clientes que se ejecutan en la infraestructura de Amazon. Las métricas son gratuitas para usted. Las siguientes métricas son compatibles:

- Número de flujos de trabajo por cuenta
- Número de disparadores por cuenta
- Número de trabajos por cuenta
- Número de ejecuciones de flujo de trabajo simultáneas por cuenta
- Número de esquemas por cuenta
- Número de sesiones interactivas por cuenta

Configuración y uso de métricas de recursos

Para utilizar esta característica, puede ir a la consola de Amazon CloudWatch para ver las métricas y configurar las alarmas. Las métricas se encuentran en el espacio de nombres AWS/Glue y son un porcentaje del recuento real de uso de recursos dividido por la cuota de recursos. Las métricas de

CloudWatch se envían a sus cuentas, lo que no supondrá ningún costo. Por ejemplo, si ha creado 10 flujos de trabajo y la cuota de servicio permite tener 200 flujos de trabajo como máximo, el uso es de 10/200 = 5 % y, en el gráfico, verá un punto de datos de 5 como porcentaje. Para ser más específicos:

```
Namespace: AWS/Glue
Metric name: ResourceUsage
Type: Resource
Resource: Workflow (or Trigger, Job, JobRun, Blueprint, InteractiveSession)
Service: Glue
Class: None
```

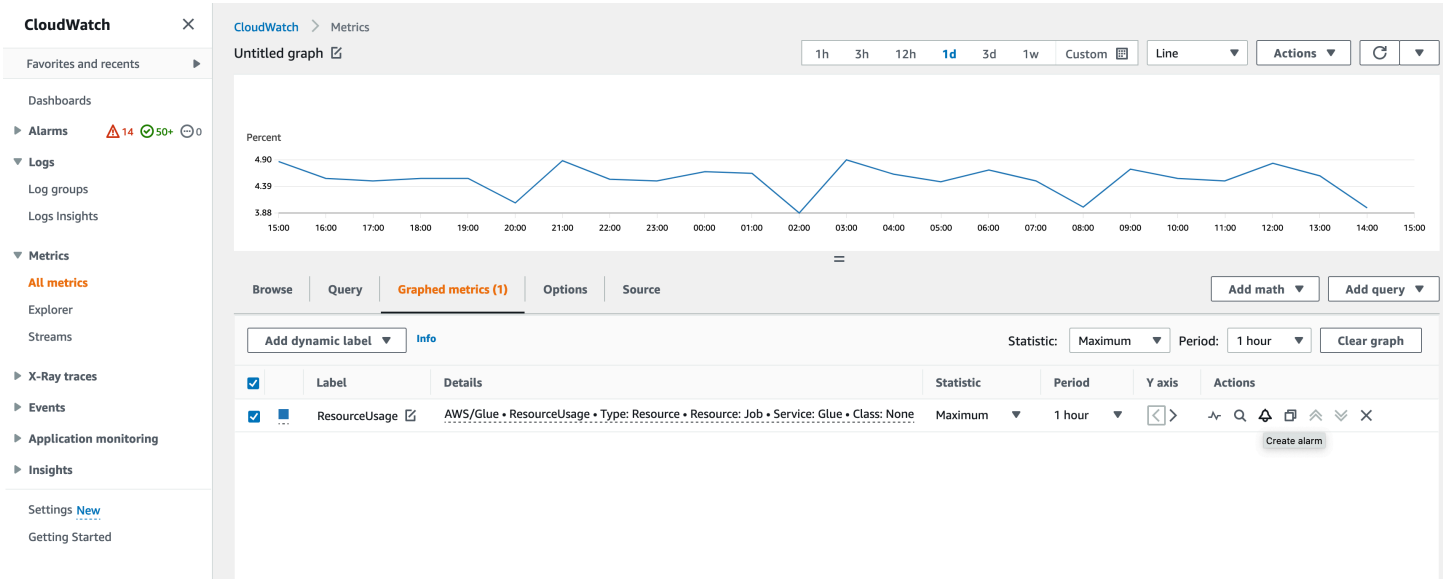

Creación de una alarma en una métrica en la consola de CloudWatch:

1. Una vez que haya localizado la métrica, vaya a Métricas gráficas.
2. Haga clic en Crear alarma en Acciones.
3. Configure la alarma según sea necesario.

Emitimos métricas cada vez que se produce un cambio en el uso de los recursos (por ejemplo, un aumento o una disminución). Sin embargo, si el uso de sus recursos no cambia, emitimos métricas cada hora para que tenga un gráfico continuo de CloudWatch. Para evitar que falten puntos de datos, no recomendamos que configure un periodo inferior a 1 hora.

También puede configurar las alarmas con AWS CloudFormation, tal como en el siguiente ejemplo. En este ejemplo, cuando el uso de los recursos del flujo de trabajo alcanza el 80 %, activa una

alarma para enviar un mensaje al tema de SNS existente, donde puede suscribirse para recibir notificaciones.

```
{
 "Type": "AWS::CloudWatch::Alarm",
 "Properties": {
  "AlarmName": "WorkflowUsageAlarm",
  "ActionsEnabled": true,
  "OKActions": [],
  "AlarmActions": [
   "arn:aws:sns:af-south-1:085425700061:Default_CloudWatch_Alarms_Topic"
  ],
  "InsufficientDataActions": [],
  "MetricName": "ResourceUsage",
  "Namespace": "AWS/Glue",
  "Statistic": "Maximum",
  "Dimensions": [{
    "Name": "Type",
    "Value": "Resource"
   },
   {
    "Name": "Resource",
    "Value": "Workflow"
   },
   {
    "Name": "Service",
    "Value": "Glue"
   },
   {
    "Name": "Class",
    "Value": "None"
   }
  ],
  "Period": 3600,
  "EvaluationPeriods": 1,
  "DatapointsToAlarm": 1,
  "Threshold": 80,
  "ComparisonOperator": "GreaterThanThreshold",
  "TreatMissingData": "notBreaching"
 }
}
```

Registrar llamadas a la API de AWS Glue con AWS CloudTrail

AWS Glue se integra con AWS CloudTrail, un servicio que proporciona un registro de las acciones hechas por un usuario, un rol o un servicio de AWS en AWS Glue. CloudTrail captura todas las llamadas a la API de AWS Glue como eventos. Las llamadas capturadas incluyen las llamadas desde la consola de AWS Glue y las llamadas desde el código a las operaciones de la API de AWS Glue. Si crea un registro de seguimiento, puede habilitar la entrega continua de eventos de CloudTrail a un bucket de Amazon S3, incluidos los eventos para AWS Glue. Si no configura un registro de seguimiento, puede ver los eventos más recientes en la consola de CloudTrail en el Historial de eventos. Mediante la información recopilada por CloudTrail, puede determinar la solicitud que se realizó a AWS Glue, la dirección IP desde la que se realizó, quién la realizó y cuándo, etc.

Para obtener más información sobre CloudTrail, consulte la Guía del usuario de AWS CloudTrail.

Información de AWS Glue en CloudTrail

CloudTrail se habilita en su cuenta de AWS cuando la crea. Cuando se produce una actividad en AWS Glue, esa actividad se registra en un evento de CloudTrail junto con otros eventos de servicio de AWS en Historial de eventos. Puede ver, buscar y descargar los últimos eventos de la cuenta de AWS. Para obtener más información, consulte Visualización de eventos con el historial de eventos de CloudTrail.

Para mantener un registro continuo de eventos en la cuenta de AWS, incluidos los eventos de AWS Glue, cree un registro de seguimiento. Un registro de seguimiento permite a CloudTrail enviar archivos de registro a un bucket de Amazon S3. De manera predeterminada, cuando se crea un registro de seguimiento en la consola, el registro de seguimiento se aplica a todas las regiones de AWS. El registro de seguimiento registra los eventos de todas las regiones de la partición de AWS y envía los archivos de registro al bucket de Amazon S3 especificado. También es posible configurar otros servicios de AWS para analizar en profundidad y actuar en función de los datos de eventos recopilados en los registros de CloudTrail. Para más información, consulte los siguientes temas:

- Creación de un seguimiento para su cuenta de AWS
- Servicios e integraciones compatibles con CloudTrail
- Configuración de notificaciones de Amazon SNS para CloudTrail
- Recepción de archivos de registro de CloudTrail de varias regiones y Recepción de archivos de registro de CloudTrail de varias cuentas

CloudTrail registra todas las acciones de AWS Glue y se documentan en API de AWS Glue. Por ejemplo, las llamadas a las acciones `CreateDatabase`, `CreateTable` y `CreateScript` generan entradas en los archivos de registros de CloudTrail.

Cada entrada de registro o evento contiene información sobre quién generó la solicitud. La información de identidad del usuario lo ayuda a determinar lo siguiente:

- Si la solicitud se realizó con las credenciales raíz o del usuario de IAM.
- Si la solicitud se realizó con credenciales de seguridad temporales de un rol o fue un usuario federado.
- Si la solicitud la realizó otro servicio de AWS.

Para obtener más información, consulte el Elemento userIdentity de CloudTrail.

Sin embargo, CloudTrail no registra toda la información referente a las llamadas. Por ejemplo, no registra determinada información confidencial como `ConnectionProperties`, que se utiliza en las solicitudes de conexión, y registra `null` en lugar de las respuestas que envían las API siguientes:

```
BatchGetPartition       GetCrawlers          GetJobs          GetTable
CreateScript            GetCrawlerMetrics    GetJobRun        GetTables
GetCatalogImportStatus  GetDatabase          GetJobRuns       GetTableVersions
GetClassifier           GetDatabases         GetMapping       GetTrigger
GetClassifiers          GetDataflowGraph     GetObjects       GetTriggers
GetConnection           GetDevEndpoint       GetPartition     GetUserDefinedFunction
GetConnections          GetDevEndpoints      GetPartitions    GetUserDefinedFunctions
GetCrawler              GetJob               GetPlan
```

Descripción de las entradas de los archivos de registro de AWS Glue

Un registro de seguimiento es una configuración que permite la entrega de eventos como archivos de registro a un bucket de Amazon S3 que especifique. Los archivos de registro de CloudTrail pueden contener una o varias entradas de registro. Un evento representa una solicitud específica realizada desde un origen cualquiera y contiene información sobre la acción solicitada, la fecha y la hora de la acción, los parámetros de la solicitud, etc. Los archivos de registro de CloudTrail no rastrean el orden en la pila de las llamadas públicas a la API, por lo que estas no aparecen en ningún orden específico.

En el siguiente ejemplo, se muestra una entrada de registro de CloudTrail que ilustra la acción `DeleteCrawler`.

```
{
  "eventVersion": "1.05",
  "userIdentity": {
    "type": "IAMUser",
    "principalId": "AKIAIOSFODNN7EXAMPLE",
    "arn": "arn:aws:iam::123456789012:user/johndoe",
    "accountId": "123456789012",
    "accessKeyId": "AKIAIOSFODNN7EXAMPLE",
    "userName": "johndoe"
  },
  "eventTime": "2017-10-11T22:29:49Z",
  "eventSource": "glue.amazonaws.com",
  "eventName": "DeleteCrawler",
  "awsRegion": "us-east-1",
  "sourceIPAddress": "72.21.198.64",
  "userAgent": "aws-cli/1.11.148 Python/3.6.1 Darwin/16.7.0 botocore/1.7.6",
  "requestParameters": {
    "name": "tes-alpha"
  },
  "responseElements": null,
  "requestID": "b16f4050-aed3-11e7-b0b3-75564a46954f",
  "eventID": "e73dd117-cfd1-47d1-9e2f-d1271cad838c",
  "eventType": "AwsApiCall",
  "recipientAccountId": "123456789012"
}
```


Este ejemplo muestra una entrada de registro de CloudTrail que ilustra la acción `CreateConnection`.


```
{
  "eventVersion": "1.05",
  "userIdentity": {
    "type": "IAMUser",
    "principalId": "AKIAIOSFODNN7EXAMPLE",
    "arn": "arn:aws:iam::123456789012:user/johndoe",
    "accountId": "123456789012",
    "accessKeyId": "AKIAIOSFODNN7EXAMPLE",
    "userName": "johndoe"
  },
  "eventTime": "2017-10-13T00:19:19Z",
  "eventSource": "glue.amazonaws.com",
  "eventName": "CreateConnection",
  "awsRegion": "us-east-1",
```

```
  "sourceIPAddress": "72.21.198.66",
  "userAgent": "aws-cli/1.11.148 Python/3.6.1 Darwin/16.7.0 botocore/1.7.6",
  "requestParameters": {
    "connectionInput": {
      "name": "test-connection-alpha",
      "connectionType": "JDBC",
      "physicalConnectionRequirements": {
        "subnetId": "subnet-323232",
        "availabilityZone": "us-east-1a",
        "securityGroupIdList": [
          "sg-12121212"
        ]
      }
    }
  },
  "responseElements": null,
  "requestID": "27136ebc-afac-11e7-a7d6-ab217e5c3f19",
  "eventID": "e8b3baeb-c511-4597-880f-c16210c60a4a",
  "eventType": "AwsApiCall",
  "recipientAccountId": "123456789012"
}
```

Transmisión de AWS Glue

La transmisión de AWS Glue, un componente de AWS Glue, le permite gestionar de manera eficiente los datos de transmisión casi en tiempo real, lo que le da la posibilidad de llevar a cabo tareas cruciales como la ingesta de datos, el procesamiento y el machine learning. Mediante el uso del marco de transmisión de Apache Spark, la transmisión de AWS Glue proporciona un servicio sin servidor que puede gestionar datos de transmisión a gran escala. AWS Glue proporciona varias optimizaciones además de Apache Spark, como la infraestructura sin servidor, el escalado automático, el desarrollo visual de los trabajos, los cuadernos instantáneos para los trabajos de transmisión y otras mejoras de rendimiento.

Casos de uso de la transmisión

Algunos casos de uso comunes para la transmisión de AWS Glue son los siguientes:

Procesamiento de datos casi en tiempo real: la transmisión de AWS Glue permite a las organizaciones procesar los datos de transmisión casi en tiempo real, lo que les da la posibilidad de obtener información y tomar decisiones oportunas en función de la información más reciente.

Detección de fraudes: puede usar la transmisión de AWS Glue para analizar en tiempo real los datos de transmisión, lo que lo convierte en una herramienta valiosa para detectar actividades fraudulentas, como el fraude con tarjetas de crédito, la intrusión en la red o las estafas en línea. Al procesar y analizar continuamente los datos entrantes, puede identificar rápidamente patrones o anomalías sospechosos.

Análisis de redes sociales: la transmisión de AWS Glue puede procesar datos de redes sociales en tiempo real, como tuits, publicaciones o comentarios, lo que permite a las organizaciones supervisar las tendencias, analizar las opiniones y gestionar la reputación de la marca en tiempo real.

Análisis del Internet de las cosas (IoT): la transmisión de AWS Glue es adecuado para gestionar y analizar los flujos de datos de alta velocidad que se generan en dispositivos, sensores y maquinaria conectada de IoT. Permite la supervisión en tiempo real, la detección de anomalías, el mantenimiento predictivo y otros casos de uso de análisis de IoT.

Análisis del flujo de clics: la transmisión de AWS Glue puede procesar y analizar los datos del flujo de clics procedentes de sitios web o aplicaciones móviles en tiempo real. Esto permite a las empresas obtener información acerca del comportamiento de los usuarios, personalizar las experiencias de los usuarios y optimizar las campañas de marketing según los datos del flujo de clics en tiempo real.

Supervisión y análisis de registros: la transmisión de AWS Glue puede procesar y analizar de manera continua los datos del registro de servidores, aplicaciones o dispositivos de red en tiempo real. Esto ayuda a detectar anomalías, solucionar problemas y supervisar el estado y el rendimiento del sistema.

Sistemas de recomendación: la transmisión de AWS Glue puede procesar los datos de actividad de los usuarios en tiempo real y actualizar los modelos de recomendación de forma dinámica. Esto permite realizar recomendaciones personalizadas y en tiempo real en función del comportamiento y las preferencias de los usuarios.

Estos son algunos ejemplos de la amplia gama de casos de uso en los que se puede aplicar la transmisión de AWS Glue. Su integración con el ecosistema de AWS y los servicios administrados lo convierten en una opción práctica para el procesamiento y el análisis de flujos en tiempo real en la nube.

¿Cuáles son los beneficios de usar la transmisión de AWS Glue?

Los beneficios de usar la transmisión de AWS Glue son los siguientes:

- Trabajo sin servidor: la transmisión de AWS Glue no tiene servidores, lo que elimina la necesidad de administrar la infraestructura. Esto reduce la sobrecarga operativa y permite a los usuarios centrarse en el procesamiento de datos y las tareas de análisis en lugar de la administración de la infraestructura.
- Escalado automático: la transmisión de AWS Glue proporciona capacidades de escalado automático, que ajustan dinámicamente la capacidad de procesamiento en función de la carga de trabajo. Se escala o reduce horizontalmente de manera automática para gestionar las fluctuaciones en el volumen de datos, lo que garantiza un rendimiento y un uso de los recursos óptimos.
- Desarrollo visual: el desarrollo de trabajos de transmisión puede resultar complejo. La transmisión de AWS Glue aborda este desafío al ofrecer AWS Glue Studio, una herramienta de creación visual. AWS Glue Studio simplifica el proceso de creación de flujos de trabajo de transmisión y permite a los desarrolladores diseñar y gestionar aplicaciones de transmisión de forma visual, lo que reduce la curva de aprendizaje y aumenta la productividad.
- Rentabilidad: al ser un servicio sin servidor, la transmisión de AWS Glue ofrece rentabilidad al eliminar la necesidad de aprovisionar y mantener la infraestructura. A los usuarios se les factura en función de los recursos consumidos durante la ejecución de los trabajos de transmisión, lo que permite optimizar los costos y escalarlos en función del uso real.

- Gestión de cargas de trabajo complejas: la transmisión de AWS Glue está diseñado para gestionar cargas de trabajo de transmisión complejas. Puede procesar y analizar grandes volúmenes de datos en tiempo real, soportar transformaciones avanzadas e integrarse con otros servicios de AWS, lo que da lugar a canalizaciones de datos de transmisión y flujos de trabajo analíticos sofisticados.
- Independencia: la transmisión de AWS Glue proporciona flexibilidad y evita la dependencia de un proveedor. Los usuarios pueden aprovechar la transmisión de AWS Glue como parte de un ecosistema de AWS más amplio, ya que pueden integrarlo con otros servicios de AWS sin problemas. Esto permite una fácil integración con los orígenes de datos, las aplicaciones y los servicios existentes sin estar atados a una tecnología o plataforma específica.

¿Cuándo conviene usar la transmisión de AWS Glue?

Hay muchas opciones en lo que respecta a los casos de uso de la transmisión. Recomendamos el uso de la transmisión de AWS Glue en las siguientes situaciones:

1. Si ya usa AWS Glue o Spark para el procesamiento por lotes, la transmisión de AWS Glue es la opción ideal para usted. Proporciona una transición perfecta a la creación de trabajos de transmisión sin necesidad de aprender un nuevo lenguaje o marco. Al aprovechar los conocimientos y la infraestructura existentes, la transmisión de AWS Glue simplifica el proceso de desarrollo de trabajos y le permite ampliar fácilmente sus capacidades de procesamiento de datos a escenarios de transmisión en tiempo real.
2. Si necesita un servicio o producto unificado para gestionar las cargas de trabajo por lotes, de transmisión y basadas en eventos, la transmisión de AWS Glue es la solución para usted. Con la transmisión de AWS Glue, puede consolidar sus necesidades de procesamiento de datos en un único marco, lo que elimina la complejidad de administrar varios sistemas. Esto permite el desarrollo y el mantenimiento eficientes de diversos flujos de trabajo de datos y, al mismo tiempo, garantiza la coherencia y la compatibilidad entre los diferentes tipos de carga de trabajo.
3. La transmisión de AWS Glue es adecuado para escenarios que implican volúmenes de datos de transmisión extremadamente grandes y transformaciones complejas, como uniones entre flujos o bases de datos relacionales. Puede procesar y analizar flujos de datos masivos de manera eficiente, lo que le permite abordar cargas de trabajo exigentes con facilidad. Tanto si se trata de una ingesta de datos de alta velocidad como de una manipulación de datos compleja, la escalabilidad y las capacidades de procesamiento avanzadas de la transmisión de AWS Glue garantizan un rendimiento óptimo y unos resultados precisos.

4. Si prefiere un enfoque visual para crear trabajos de transmisión, AWS Glue ofrece AWS Glue Studio, con el que puede diseñar y gestionar visualmente las aplicaciones de transmisión, lo que simplifica el proceso de desarrollo. Esta interfaz intuitiva permite a los desarrolladores crear, configurar y supervisar los flujos de trabajo de transmisión mediante una interfaz visual, lo que reduce la curva de aprendizaje y aumenta la productividad.
5. La transmisión de AWS Glue es una excelente opción para casos de uso casi en tiempo real en los que existen acuerdos de nivel de servicio (SLA) estrictos que duran más de 10 segundos.
6. Si desea crear un lago de datos transaccional con Apache Iceberg, Apache Hudi o Delta Lake, la transmisión de AWS Glue ofrece soporte nativo para estos formatos de tabla abiertos. Esta perfecta integración le permite procesar los datos de transmisión directamente desde estos lagos de datos transaccionales, lo que garantiza la coherencia, integridad y compatibilidad de los datos.
7. Si necesita ingerir datos de transmisión para una variedad de destinos de datos, la transmisión de AWS Glue proporciona destinos nativos a una variedad de destinos de datos como Amazon Redshift, Amazon RDS, Amazon Aurora, Oracle, SQL Server y otros destinos.

Orígenes de datos admitidos

La transmisión de AWS Glue admite los siguientes orígenes de datos:

- Amazon Kinesis
- Amazon MSK (Managed Streaming para Apache Kafka)
- Apache Kafka autoadministrado

Destinos de datos admitidos

La transmisión de AWS Glue admite una variedad de destinos de datos, como los siguientes:

- Destinos de datos compatibles con el Catálogo de datos de AWS Glue
- Amazon S3
- Amazon Redshift
- MySQL
- PostgreSQL
- Oracle
- Microsoft SQL Server

- Snowflake
- Cualquier base de datos a la que se pueda conectar mediante JDBC
- Apache Iceberg, Delta y Apache Hudi
- Conectores del AWS Glue Marketplace

Tutorial: Cree su primera carga de trabajo de transmisión con AWS Glue Studio

En este tutorial, aprenderá a crear un trabajo de transmisión con AWS Glue Studio. AWS Glue Studio es una interfaz visual para crear trabajos de AWS Glue.

Puede crear trabajos de extracción, transformación y carga (ETL) de transmisión que se ejecuten de forma continua y consuman datos de los orígenes de transmisión como Amazon Kinesis Data Streams, Apache Kafka y Amazon Managed Streaming para Apache Kafka (Amazon MSK).

Requisitos previos

Para seguir este tutorial, necesitará un usuario con permisos de consola de AWS para usar AWS Glue, Amazon Kinesis, Amazon S3, Amazon Athena, AWS CloudFormation, AWS Lambda y Amazon Cognito.

Consumir datos de transmisión desde Amazon Kinesis

Temas

- Generación de datos simulados con Kinesis Data Generator
- Creación de un trabajo de transmisión de AWS Glue con AWS Glue Studio
- Transformación y almacenamiento del resultado transformado en Amazon S3

Generación de datos simulados con Kinesis Data Generator

Puede generar sintéticamente datos de muestra en formato JSON mediante Kinesis Data Generator (KDG). Encontrará instrucciones y detalles completos en la documentación de la herramienta.

1. Para empezar, haga clic en

   para ejecutar una plantilla de AWS CloudFormation en su entorno de AWS.

> **Note**
>
> Es posible que se produzca un error en la plantilla de CloudFormation porque algunos recursos, como el usuario de Amazon Cognito para Kinesis Data Generator, ya existen en su cuenta de AWS. Esto puede deberse a que ya la configuró en otro tutorial o blog. Para solucionar este problema, puede probar la plantilla en una cuenta de AWS nueva para empezar de cero o explorar una región de AWS diferente. Estas opciones le permiten ejecutar el tutorial sin que entre en conflicto con los recursos existentes.

La plantilla aprovisiona un flujo de datos de Kinesis y una cuenta de Kinesis Data Generator. También crea un bucket de Amazon S3 para almacenar los datos y un rol de servicio de Glue con los permisos necesarios para este tutorial.

2. Introduzca un nombre de usuario y una contraseña que KDG usará para autenticarse. Tome nota del nombre de usuario y la contraseña para su uso posterior.
3. Seleccione Siguiente hasta el último paso. Acepte la creación de recursos de IAM. Compruebe si hay algún error en la parte superior de la pantalla, como que la contraseña no cumple los requisitos mínimos, e implemente la plantilla.
4. Navegue hasta la pestaña Salidas de la pila. Una vez implementada la plantilla, mostrará la propiedad generada KinesisDataGeneratorUrl. Haga clic en esa URL.
5. Ingrese el nombre de usuario y la contraseña que anotó.
6. Seleccione la región que está usando y elija Kinesis Stream `GlueStreamTest-{AWS::AccountId}`.
7. Escriba la siguiente plantilla:

```
{
    "ventilatorid": {{random.number(100)}},
    "eventtime": "{{date.now("YYYY-MM-DD HH:mm:ss")}}",
    "serialnumber": "{{random.uuid}}",
    "pressurecontrol": {{random.number(
        {
            "min":5,
            "max":30
        }
    )}},
    "o2stats": {{random.number(
        {
```

```
            "min":92,
            "max":98
        }
    )}},
    "minutevolume": {{random.number(
        {
            "min":5,
            "max":8
        }
    )}},
    "manufacturer": "{{random.arrayElement(
        ["3M", "GE","Vyaire", "Getinge"]
    )}}"
}
```

Ahora puede ver los datos simulados con la plantilla de prueba e incorporarlos a Kinesis con Enviar datos.

8. Haga clic en Enviar datos y genere entre 5 y 10 000 registros en Kinesis.

Creación de un trabajo de transmisión de AWS Glue con AWS Glue Studio

1. Navegue hasta AWS Glue en la consola en la misma región.
2. Seleccione Trabajos de ETL en la barra de navegación del lado izquierdo, en Integración de datos y ETL.
3. Cree un trabajo de AWS Glue a través de Visual con un lienzo en blanco.

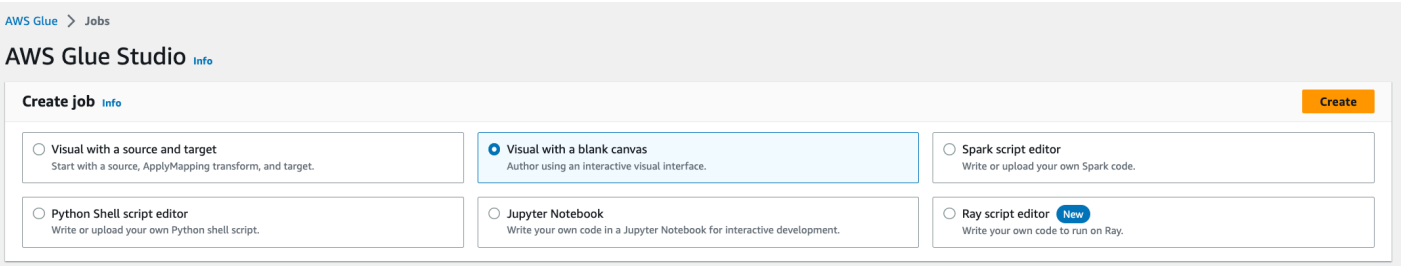

4. Vaya a la pestaña Detalles del trabajo.
5. Para el nombre del trabajo de AWS Glue, escriba `DemoStreamingJob`.
6. Para el rol de IAM, seleccione el rol aprovisionado en la plantilla de CloudFormation, `glue-tutorial-role-${AWS::AccountId}`.
7. En Versión de Glue, seleccione Glue 3.0. Deje todas las demás opciones en sus valores predeterminados.

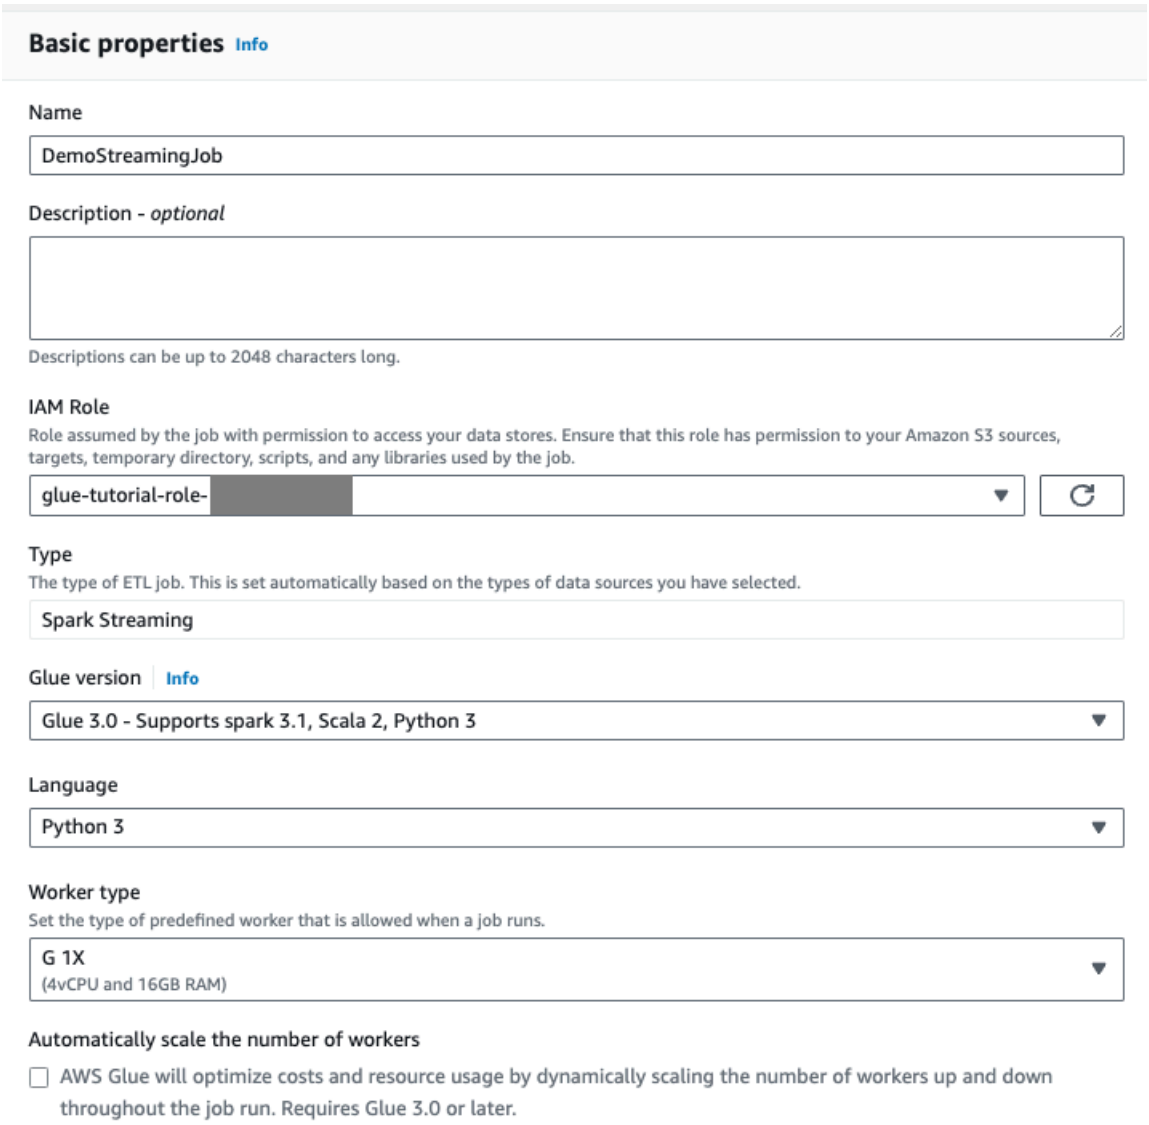

8. Navegue hasta la pestaña Visual.
9. Haga clic en el icono del signo más. Escriba Kinesis en la barra de búsqueda. Seleccione el origen de datos de Amazon Kinesis.

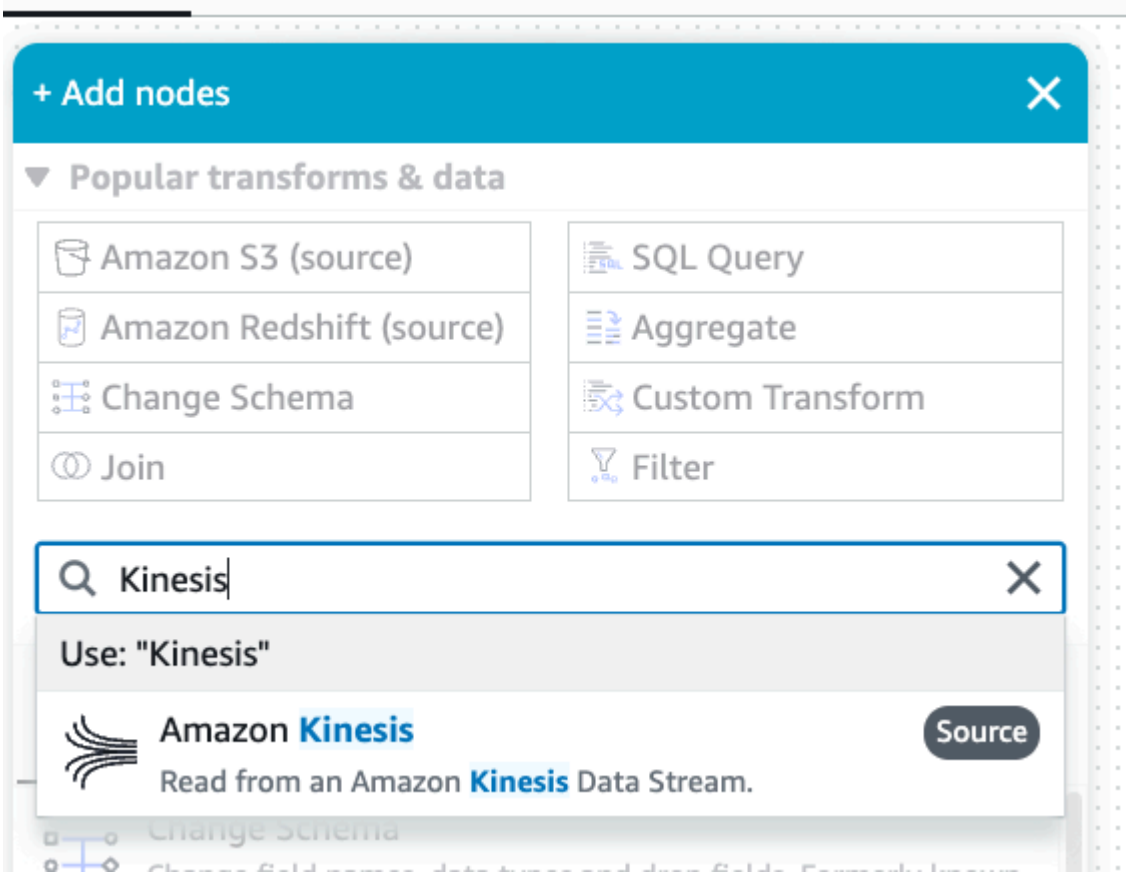

10. Seleccione Detalles del flujo para Origen de Amazon Kinesis en la pestaña Propiedades del origen de datos: flujo de Kinesis.
11. Seleccione El flujo se encuentra en mi cuenta para ver la Ubicación del flujo de datos.
12. Seleccione la región que está usando.
13. Seleccione el flujo de `GlueStreamTest-{AWS::AccountId}`.
14. Mantenga todas las otras opciones de configuración predeterminadas.

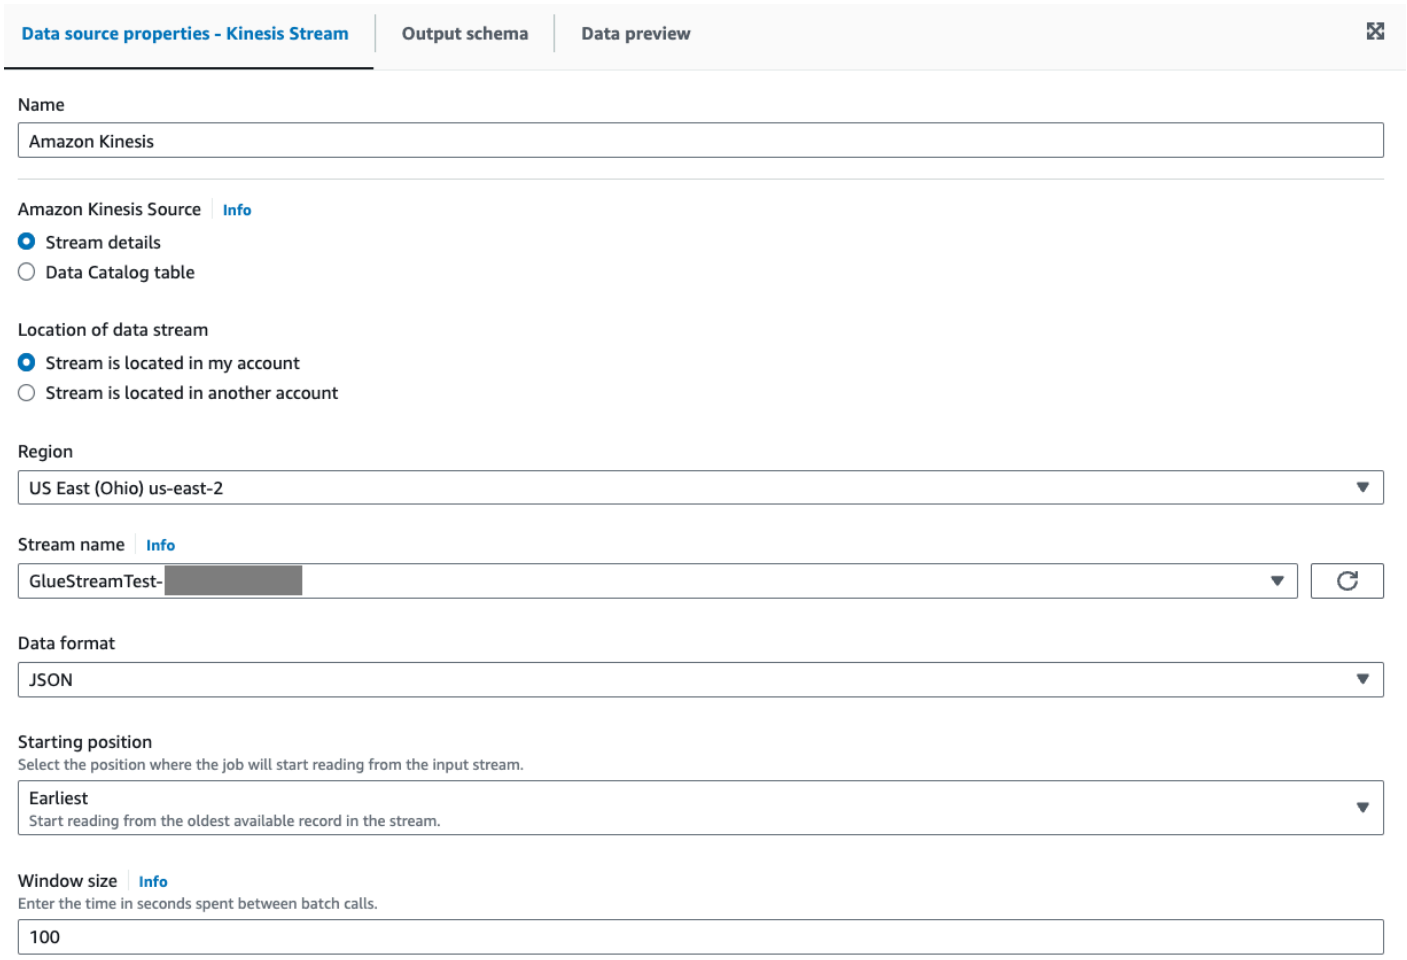

15. Navegue a la pestaña Vista previa de datos.
16. Haga clic en Iniciar sesión de vista previa de datos, la cual muestra una vista previa de los datos simulados generados por KDG. Elija el rol de servicio de Glue que creó anteriormente para el trabajo de transmisión de AWS Glue.

    Los datos de vista previa tardan entre 30 y 60 segundos en aparecer. Si aparece No hay datos para mostrar, haga clic en el icono con forma de engranaje y cambie el número de filas que desea muestrear a `100`.

    Puede ver los datos de muestra de la siguiente manera:

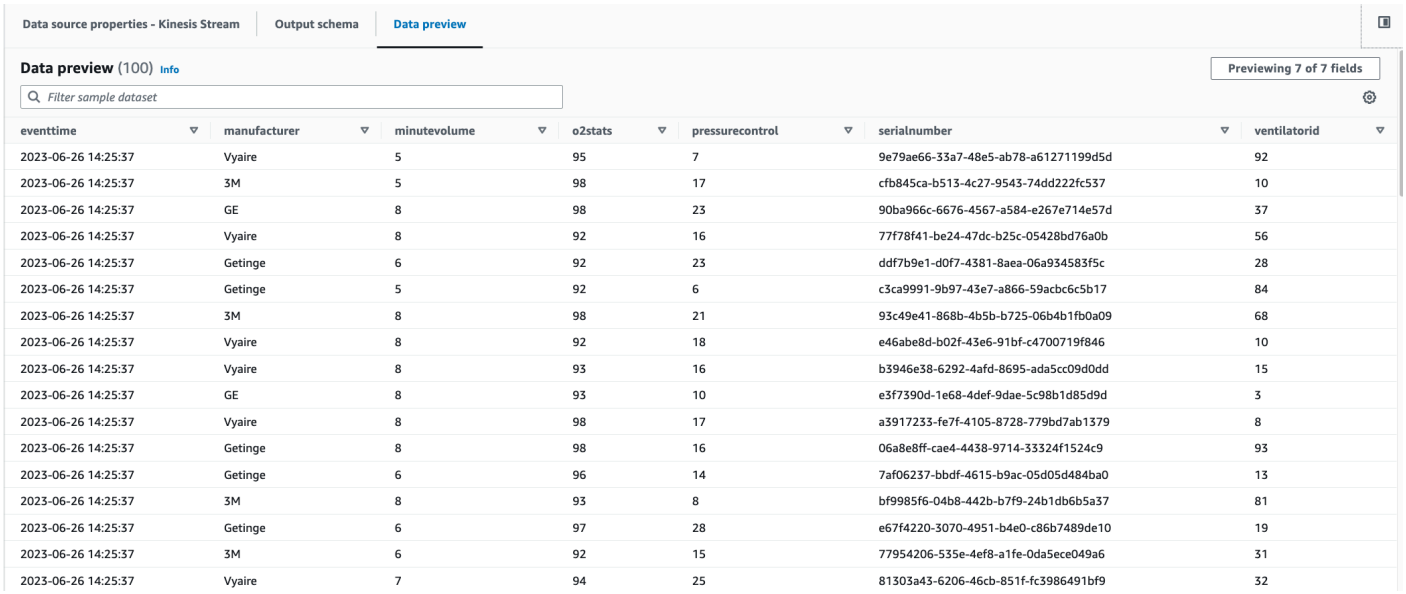

Data source properties - Kinesis Stream | Output schema | Data preview

Data preview (100) Info

Previewing 7 of 7 fields

Filter sample dataset

eventtime	manufacturer	minutevolume	o2stats	pressurecontrol	serialnumber	ventilatorid
2023-06-26 14:25:37	Vyaire	5	95	7	9e79ae66-33a7-48e5-ab78-a61271199d5d	92
2023-06-26 14:25:37	3M	5	98	17	cfb845ca-b513-4c27-9543-74dd222fc537	10
2023-06-26 14:25:37	GE	8	98	23	90ba966c-6676-4567-a584-e267e714e57d	37
2023-06-26 14:25:37	Vyaire	8	92	16	77f78f41-be24-47dc-b25c-05428bd76a0b	56
2023-06-26 14:25:37	Getinge	6	92	23	ddf7b9e1-d0f7-4381-8aea-06a934583f5c	28
2023-06-26 14:25:37	Getinge	5	92	6	c3ca9991-9b97-43e7-a866-59acbc6c5b17	84
2023-06-26 14:25:37	3M	8	98	21	93c49e41-868b-4b5b-b725-06b4b1fb0a09	68
2023-06-26 14:25:37	Vyaire	8	92	18	e46abe8d-b02f-43e6-91bf-c4700719f846	10
2023-06-26 14:25:37	Vyaire	8	93	16	b3946e38-6292-4afd-8695-ada5cc09d0dd	15
2023-06-26 14:25:37	GE	8	93	10	e3f7390d-1e68-4def-9dae-5c98b1d85d9d	3
2023-06-26 14:25:37	Vyaire	8	98	17	a3917233-fe7f-4105-8728-779bd7ab1379	8
2023-06-26 14:25:37	Getinge	8	98	16	06a8e8ff-cae4-4438-9714-33324f1524c9	93
2023-06-26 14:25:37	Getinge	6	96	14	7af06237-bbdf-4615-b9ac-05d05d484ba0	13
2023-06-26 14:25:37	3M	8	93	8	bf9985f6-04b8-442b-b7f9-24b1db6b5a37	81
2023-06-26 14:25:37	Getinge	6	97	28	e67f4220-3070-4951-b4e0-c86b7489de10	19
2023-06-26 14:25:37	3M	6	92	15	77954206-535e-4ef8-a1fe-0da5ece049a6	31
2023-06-26 14:25:37	Vyaire	7	94	25	81303a43-6206-46cb-851f-fc3986491bf9	32

También puede ver el esquema inferido en la pestaña Esquema de salida.

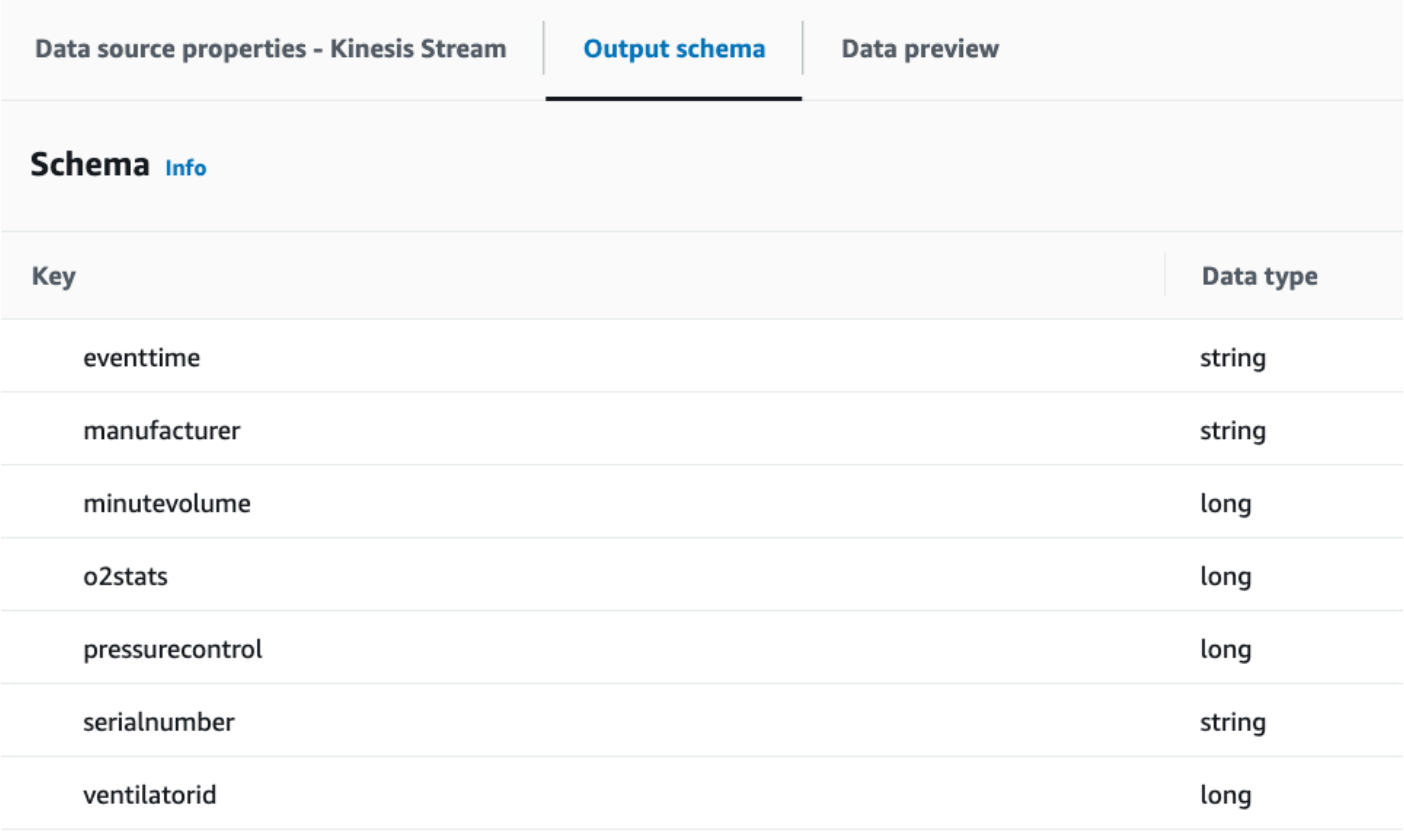

Data source properties - Kinesis Stream | Output schema | Data preview

Schema Info

Key	Data type
eventtime	string
manufacturer	string
minutevolume	long
o2stats	long
pressurecontrol	long
serialnumber	string
ventilatorid	long

Transformación y almacenamiento del resultado transformado en Amazon S3

1. Con el nodo de origen seleccionado, haga clic en el icono con el signo más, situado en la parte superior izquierda, para agregar un paso de transformación.
2. Seleccione el paso Cambiar esquema.

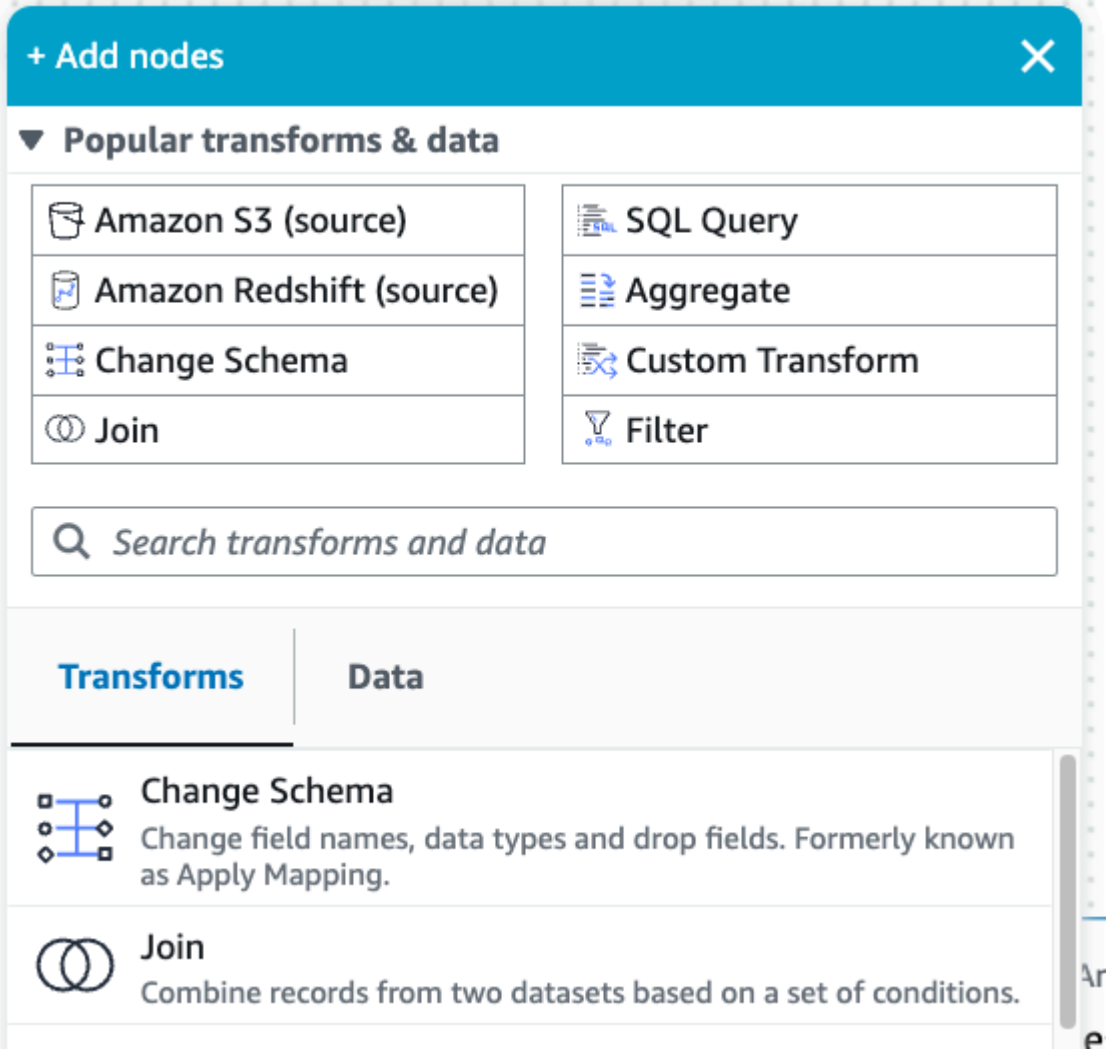

3. En este paso, puede cambiar el nombre de los campos y convertir el tipo de datos de los campos. Cambie el nombre de la columna `o2stats` a `OxygenSaturation` y convierta todos los tipos de datos de `long` a `int`.

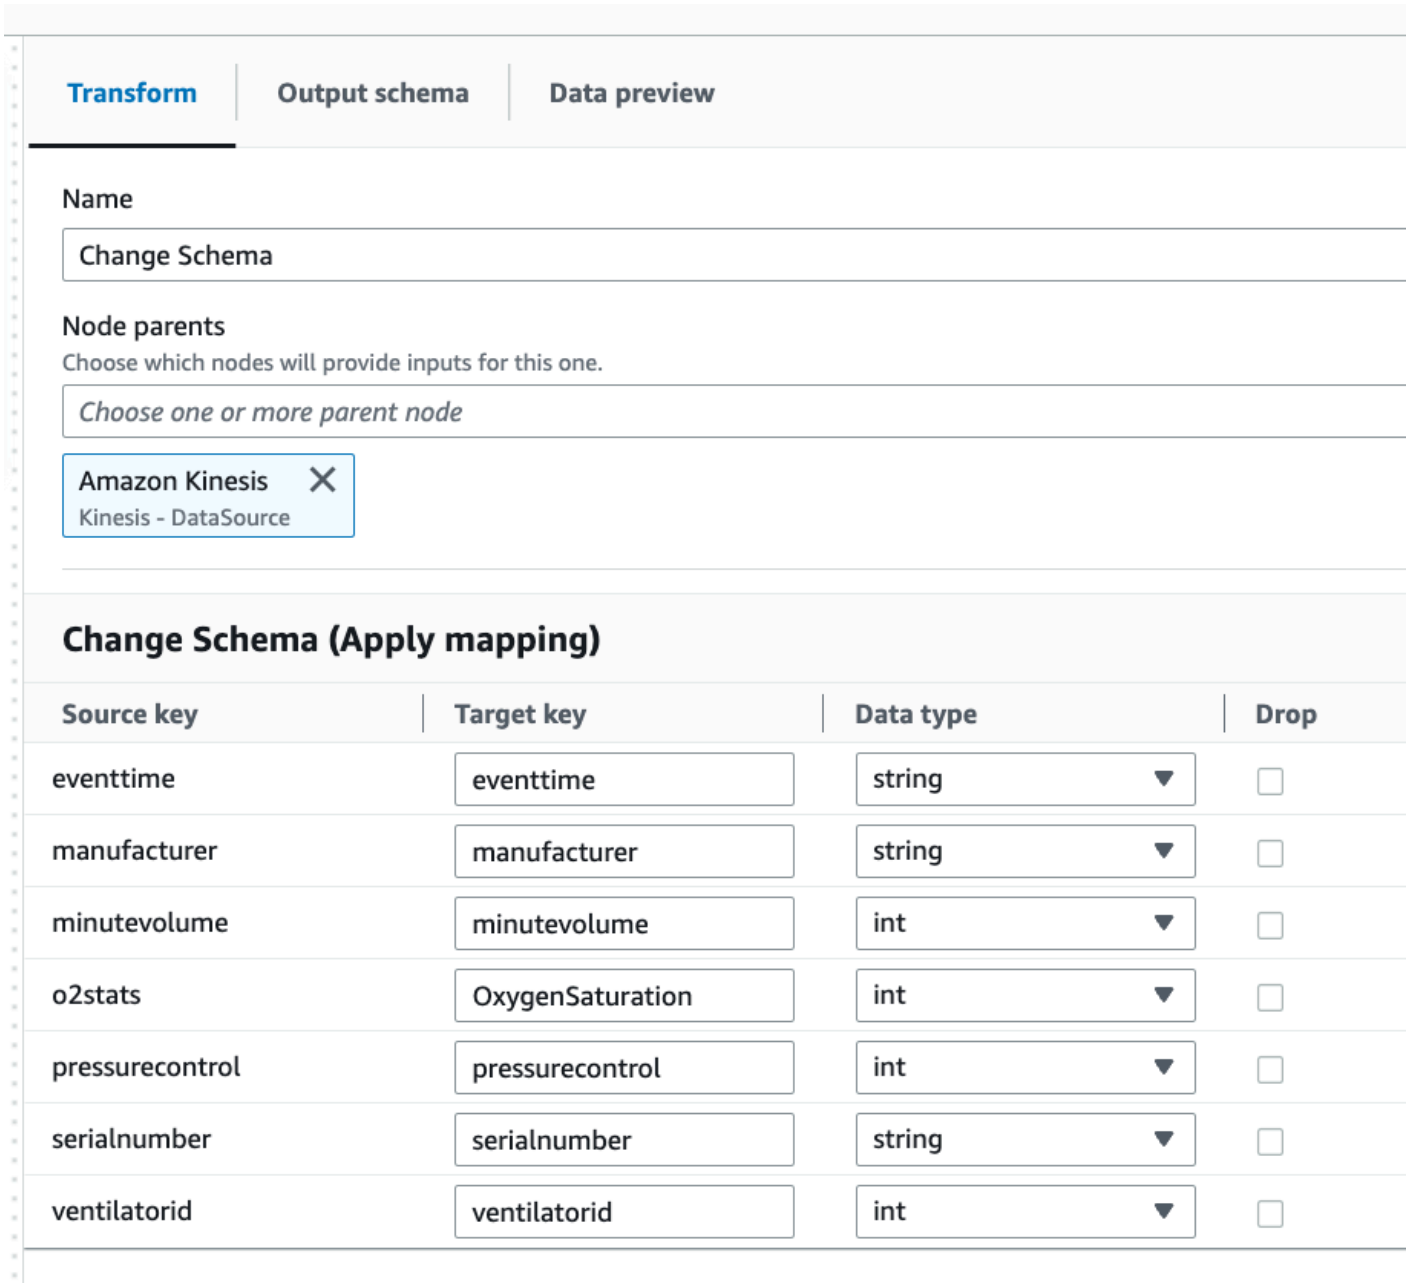

4. Haga clic en el icono con el signo más para agregar un destino de Amazon S3. Introduzca S3 en el cuadro de búsqueda y seleccione el paso de transformación Amazon S3: destino.

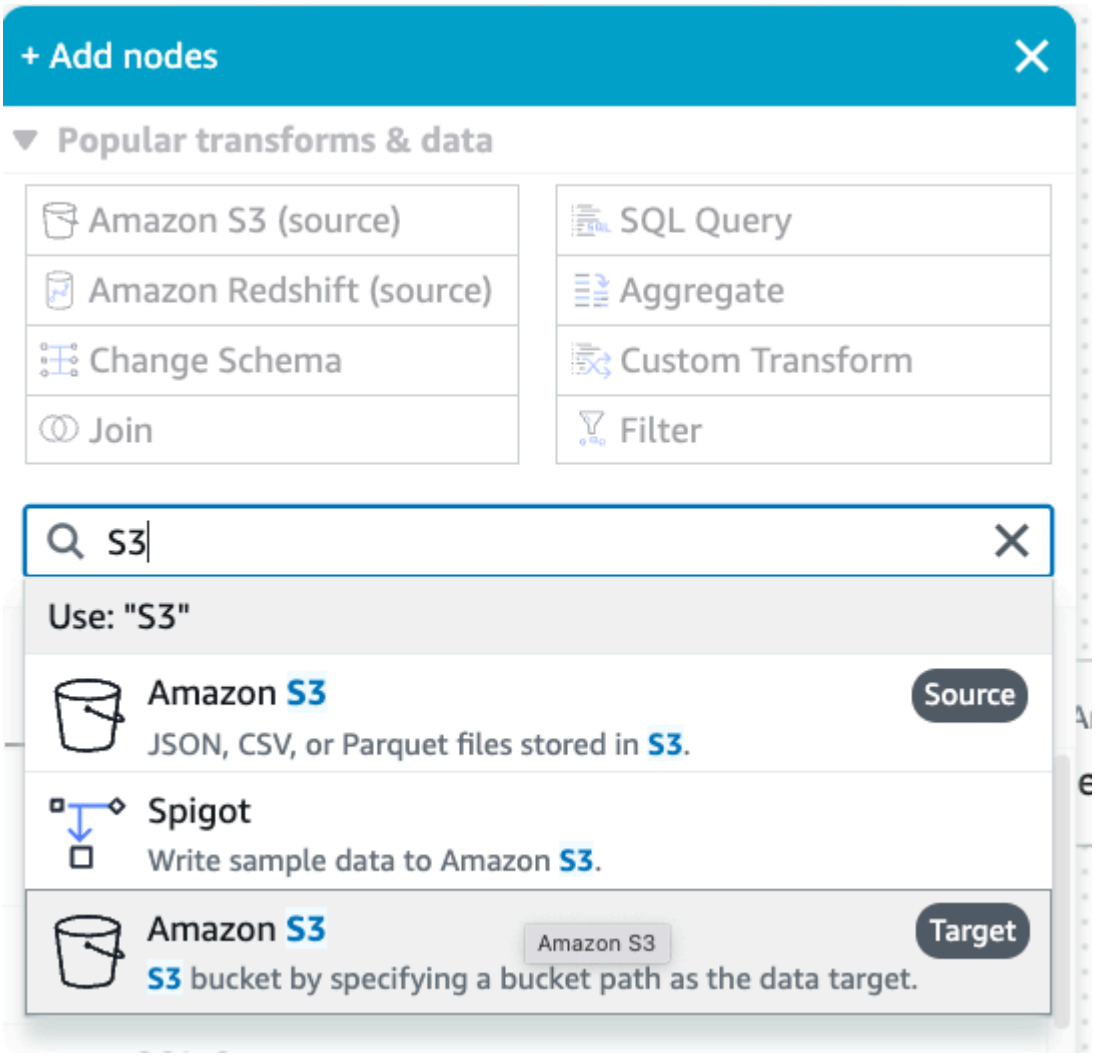

5. Seleccione Parquet como formato de archivo de destino.
6. Seleccione Snappy como tipo de compresión.
7. Introduzca una ubicación de destino de S3 creada por la plantilla de CloudFormation, `streaming-tutorial-s3-target-{AWS::AccountId}`.
8. Seleccione Crear una tabla en el Catálogo de datos y, en las ejecuciones posteriores, actualizar el esquema y agregar nuevas particiones.
9. Introduzca la base de datos de destino y el nombre de la tabla para almacenar el esquema de la tabla de destino de Amazon S3.

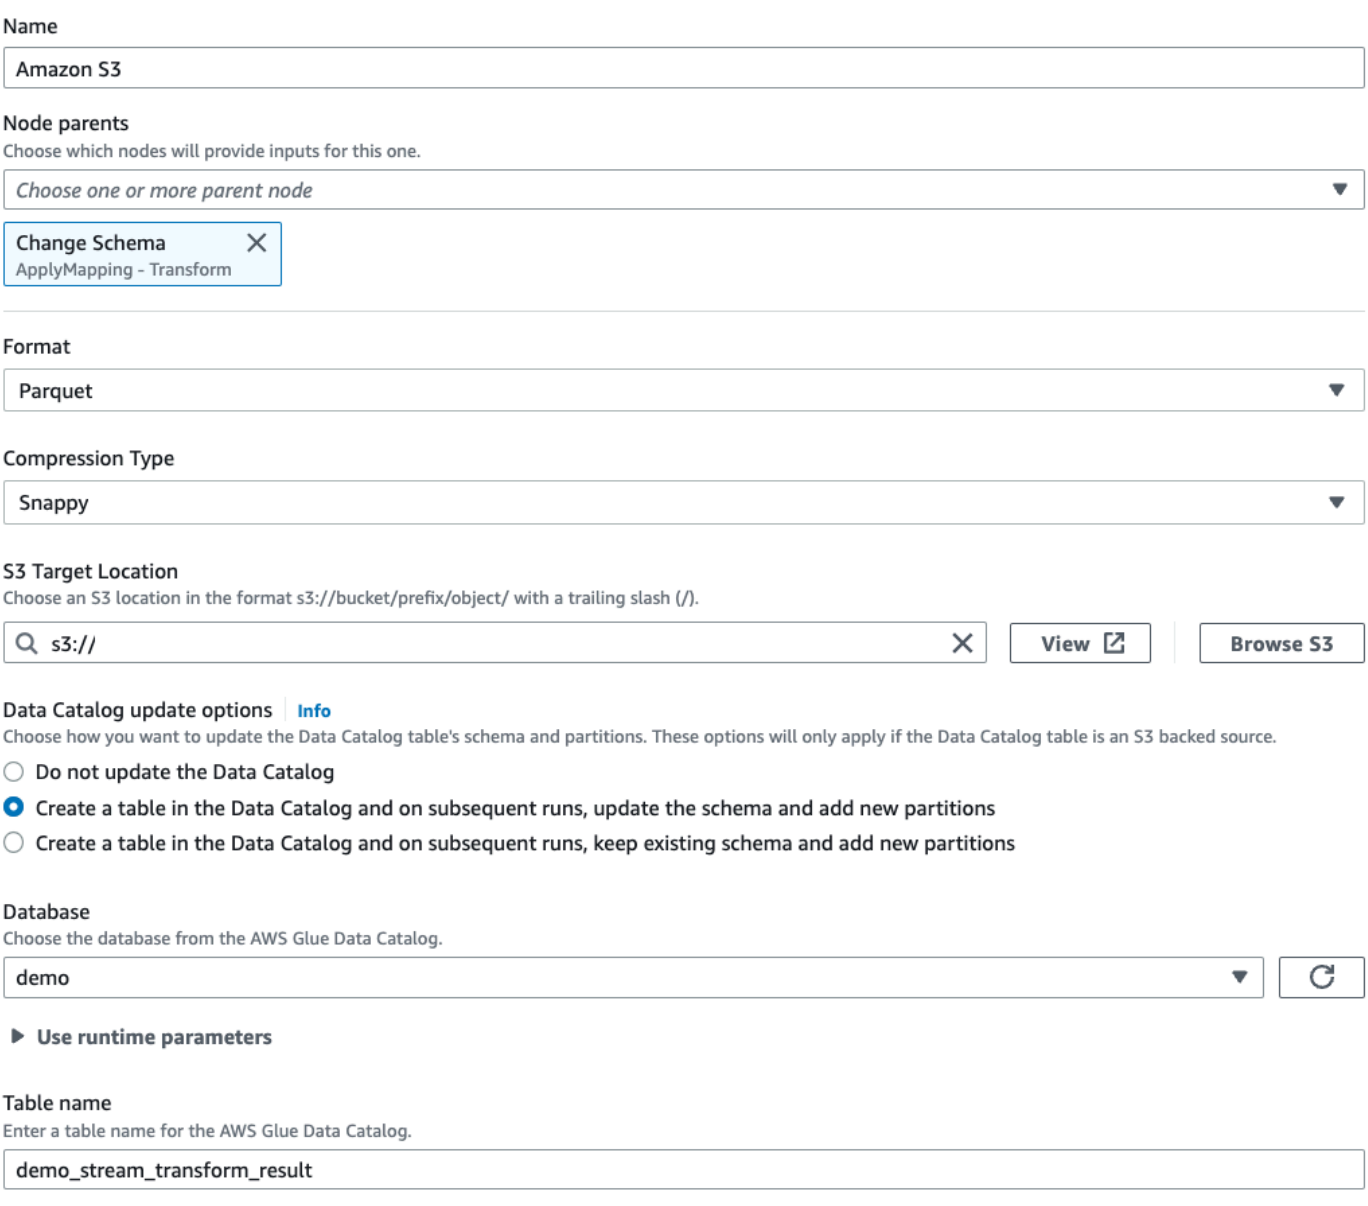

10. Haga clic en la pestaña Script para ver el código generado.
11. Haga clic en Guardar en la parte superior derecha para guardar el código ETL y, a continuación, haga clic en Ejecutar para iniciar el trabajo de transmisión de AWS Glue.

    Puede encontrar el estado de ejecución en la pestaña Ejecuciones. Deje que el trabajo se ejecute entre 3 y 5 minutos y, a continuación, deténgalo.

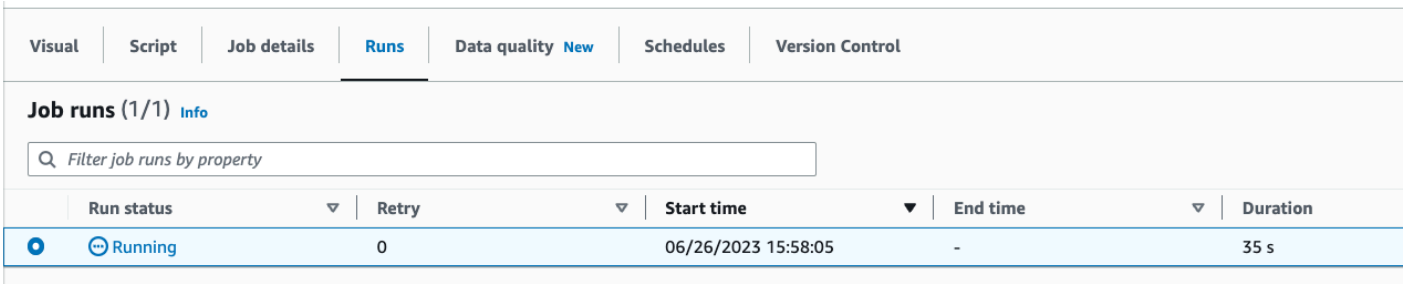

12. Compruebe la nueva tabla creada en Amazon Athena.

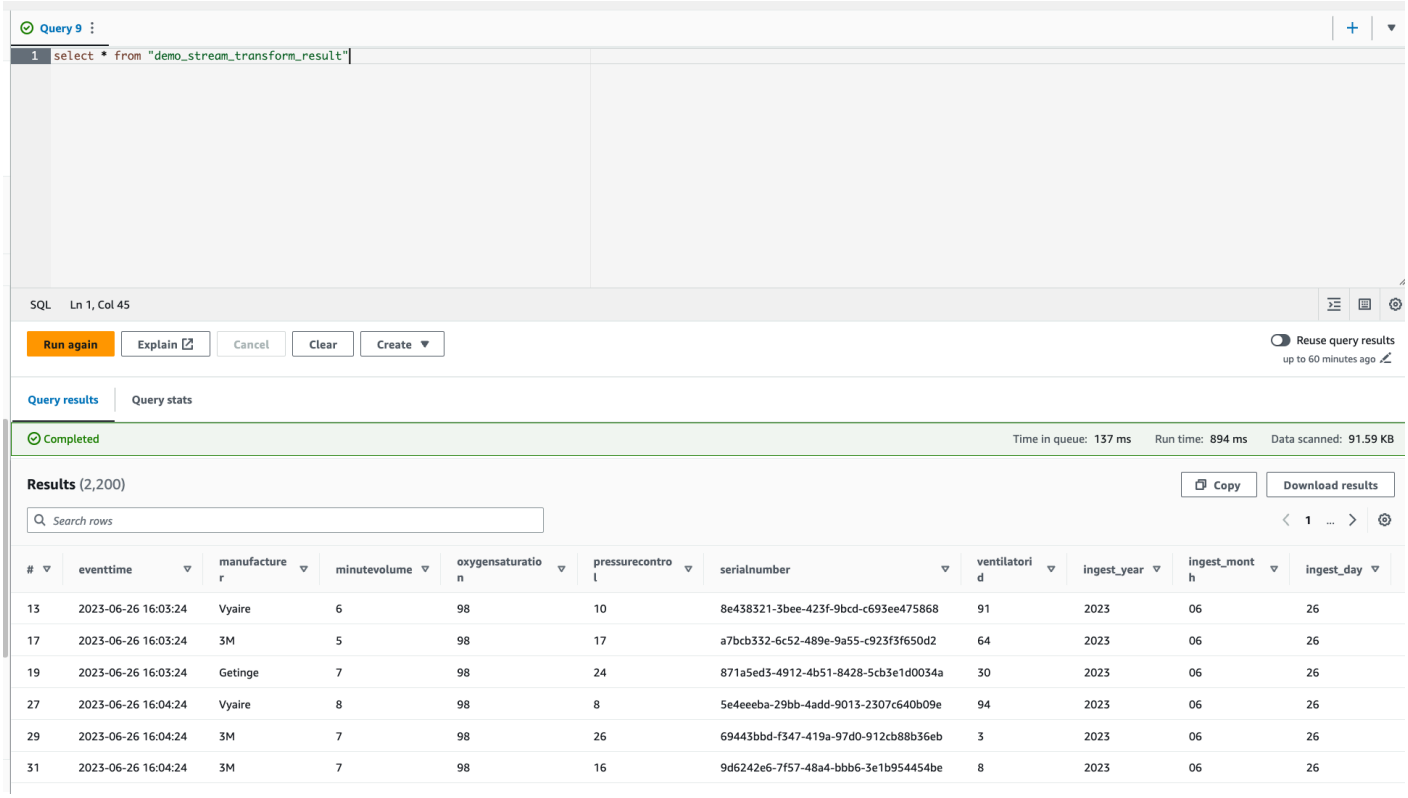

Tutorial: Cree su primera carga de trabajo de transmisión con los cuadernos de AWS Glue Studio

En este tutorial, explorará cómo aprovechar los cuadernos de AWS Glue Studio a fin de crear y refinar de forma interactiva sus trabajos de ETL para el procesamiento de datos casi en tiempo real. Si acaba de empezar a usar AWS Glue o si desea mejorar sus habilidades, esta guía le mostrará el proceso y le permitirá aprovechar todo el potencial de los cuadernos de las sesiones interactivas de AWS Glue.

Con la transmisión de AWS Glue, puede crear trabajos de extracción, transformación y carga (ETL) de transmisión que se ejecuten de forma continua y consuman datos de los orígenes de transmisión como Amazon Kinesis Data Streams, Apache Kafka y Amazon Managed Streaming para Apache Kafka (Amazon MSK).

Requisitos previos

Para seguir este tutorial, necesitará un usuario con permisos de consola de AWS para usar AWS Glue, Amazon Kinesis, Amazon S3, Amazon Athena, AWS CloudFormation, AWS Lambda y Amazon Cognito.

Consumir datos de transmisión desde Amazon Kinesis

Temas

- Generación de datos simulados con Kinesis Data Generator
- Creación de un trabajo de transmisión de AWS Glue con AWS Glue Studio
- Limpieza
- Conclusión

Generación de datos simulados con Kinesis Data Generator

> **Note**
>
> Si ya ha completado la sección anterior Tutorial: Cree su primera carga de trabajo de transmisión con AWS Glue Studio, ya tiene Kinesis Data Generator instalado en su cuenta, por lo que puede omitir los pasos 1 a 8 que aparecen a continuación y pasar a la sección Creación de un trabajo de transmisión de AWS Glue con AWS Glue Studio.

Puede generar sintéticamente datos de muestra en formato JSON mediante Kinesis Data Generator (KDG). Encontrará instrucciones y detalles completos en la documentación de la herramienta.

1. Para empezar, haga clic en

   para ejecutar una plantilla de AWS CloudFormation en su entorno de AWS.

> **Note**
>
> Es posible que se produzca un error en la plantilla de CloudFormation porque algunos recursos, como el usuario de Amazon Cognito para Kinesis Data Generator, ya existen en su cuenta de AWS. Esto puede deberse a que ya la configuró en otro tutorial o blog. Para solucionar este problema, puede probar la plantilla en una cuenta de AWS nueva para empezar de cero o explorar una región de AWS diferente. Estas opciones le permiten ejecutar el tutorial sin que entre en conflicto con los recursos existentes.

La plantilla aprovisiona un flujo de datos de Kinesis y una cuenta de Kinesis Data Generator.

2. Introduzca un nombre de usuario y una contraseña que KDG usará para autenticarse. Tome nota del nombre de usuario y la contraseña para su uso posterior.
3. Seleccione Siguiente hasta el último paso. Acepte la creación de recursos de IAM. Compruebe si hay algún error en la parte superior de la pantalla, como que la contraseña no cumple los requisitos mínimos, e implemente la plantilla.
4. Navegue hasta la pestaña Salidas de la pila. Una vez implementada la plantilla, mostrará la propiedad generada KinesisDataGeneratorUrl. Haga clic en esa URL.
5. Ingrese el nombre de usuario y la contraseña que anotó.
6. Seleccione la región que está usando y elija Kinesis Stream `GlueStreamTest-{AWS::AccountId}`.
7. Escriba la siguiente plantilla:

```
{
    "ventilatorid": {{random.number(100)}},
    "eventtime": "{{date.now("YYYY-MM-DD HH:mm:ss")}}",
    "serialnumber": "{{random.uuid}}",
    "pressurecontrol": {{random.number(
        {
            "min":5,
            "max":30
        }
    )}},
    "o2stats": {{random.number(
        {
            "min":92,
            "max":98
```

```
        }
    )}},
    "minutevolume": {{random.number(
        {
            "min":5,
            "max":8
        }
    )}},
    "manufacturer": "{{random.arrayElement(
        ["3M", "GE","Vyaire", "Getinge"]
    )}}"
}
```

Ahora puede ver los datos simulados con la plantilla de prueba e incorporarlos a Kinesis con Enviar datos.

8. Haga clic en Enviar datos y genere entre 5 y 10 000 registros en Kinesis.

Creación de un trabajo de transmisión de AWS Glue con AWS Glue Studio

AWS Glue Studio es una interfaz visual que simplifica el proceso de diseño, organización y supervisión de las canalizaciones de integración de datos. Permite a los usuarios crear canalizaciones de transformación de datos sin necesidad de escribir un código extenso. Además de la experiencia visual de creación de trabajos, AWS Glue Studio también incluye un cuaderno de Jupyter respaldado por sesiones interactivas de AWS Glue, que usará en el resto de este tutorial.

Configure el trabajo de sesiones interactivas de la transmisión de AWS Glue

1. Descargue el archivo del cuaderno proporcionado y guárdelo en un directorio local.
2. Abra la consola de AWS Glue y, en el panel izquierdo, haga clic en Cuadernos > Cuaderno de Jupyter > Cargar y editar un cuaderno existente. Cargue el cuaderno del paso anterior y haga clic en Crear.

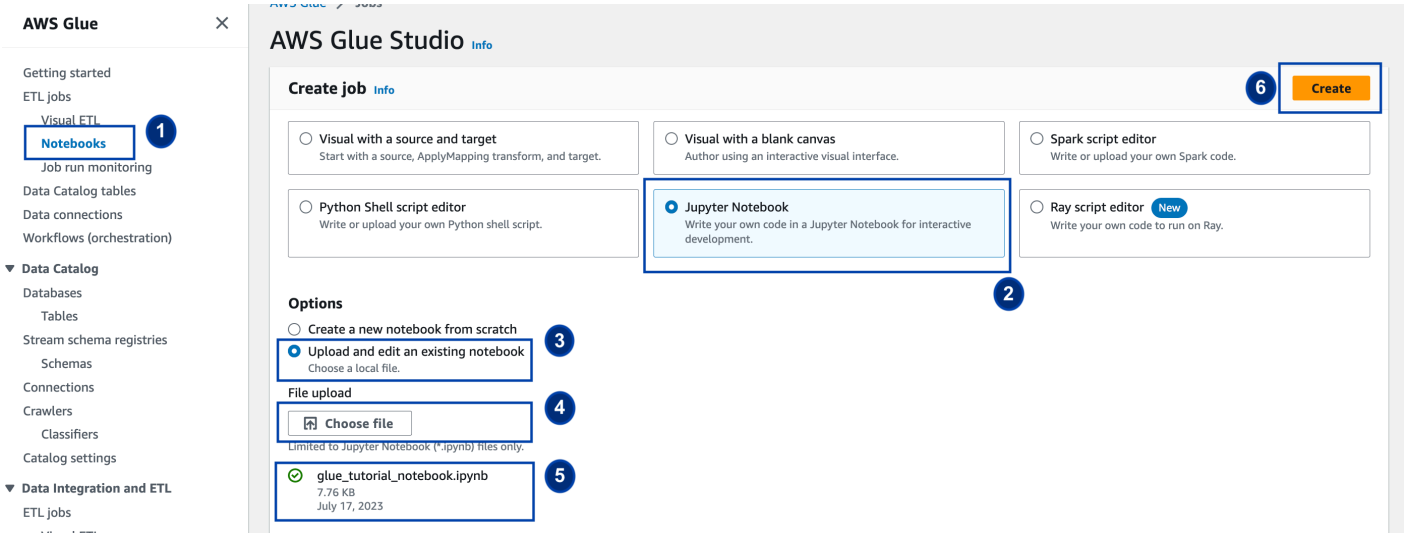

3. Proporcione un nombre y un rol al trabajo y seleccione el kernel de Spark predeterminado. A continuación, haga clic en Iniciar cuaderno. Para el rol de IAM, seleccione el rol aprovisionado en la plantilla de CloudFormation. Puede verlo en la pestaña Salidas de CloudFormation.

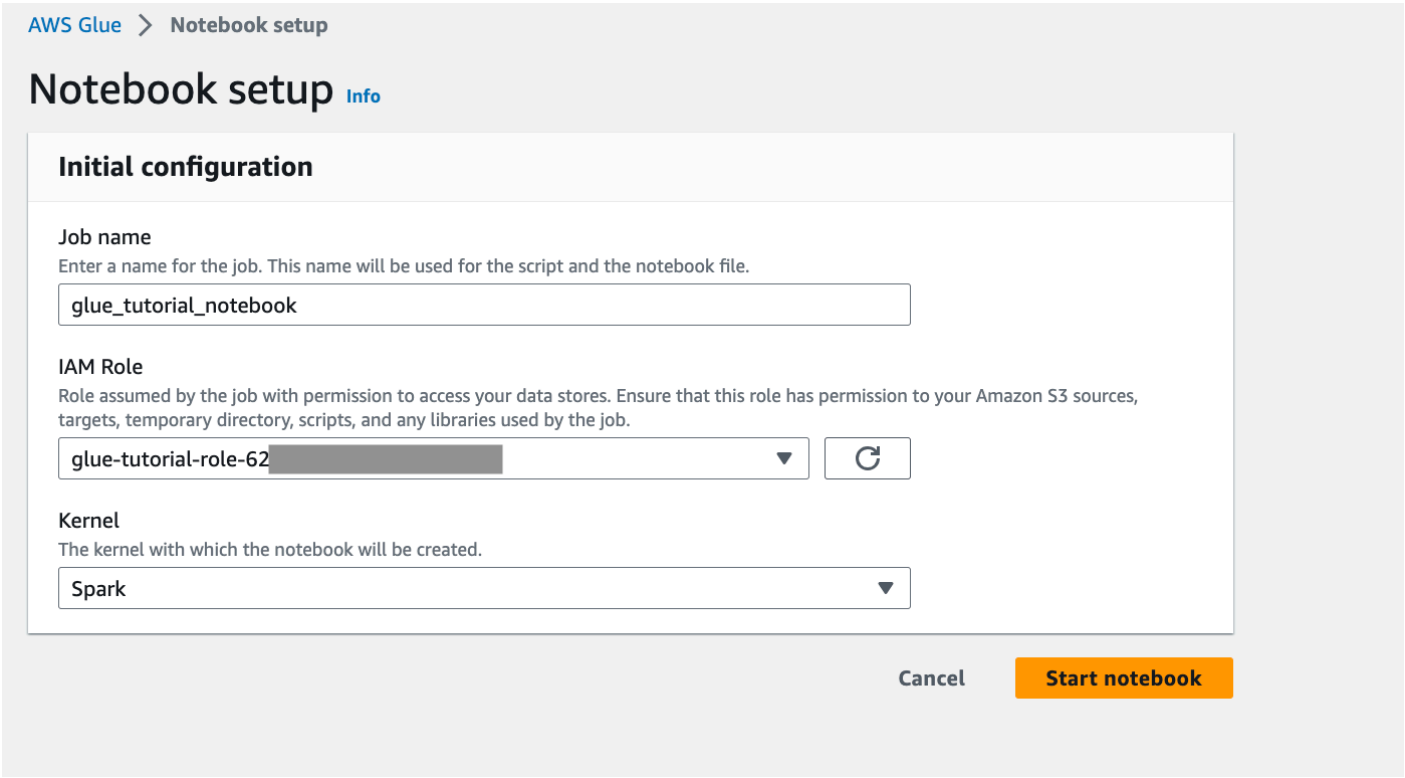

El cuaderno tiene todas las instrucciones necesarias para continuar con el tutorial. Puede ejecutar las instrucciones en el cuaderno o seguir este tutorial para continuar con el desarrollo del trabajo.

Ejecute las celdas del cuaderno

1. (Opcional) La primera celda de código `%help` muestra todos los comandos mágicos disponibles del cuaderno. Puede saltarse esta celda por ahora, pero no dude en explorarla.
2. Empiece con el siguiente bloque de código `%streaming`. Este comando mágico define el tipo de trabajo como transmisión, lo que le permite desarrollar, depurar e implementar un trabajo de ETL de transmisión de AWS Glue.
3. Ejecute la siguiente celda para crear una sesión interactiva de AWS Glue. La celda de salida tiene un mensaje que confirma la creación de la sesión.

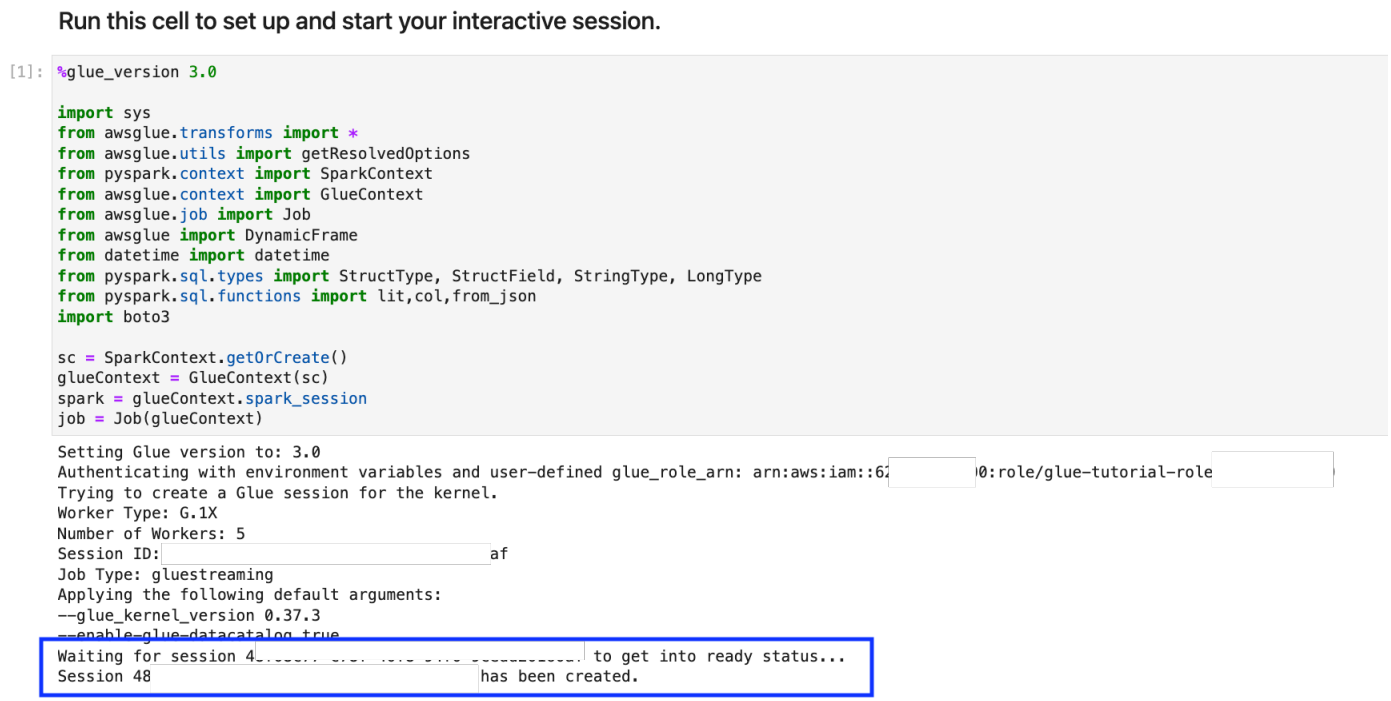

4. La siguiente celda define las variables. Sustituya los valores por otros adecuados para su trabajo y ejecute la celda. Por ejemplo:

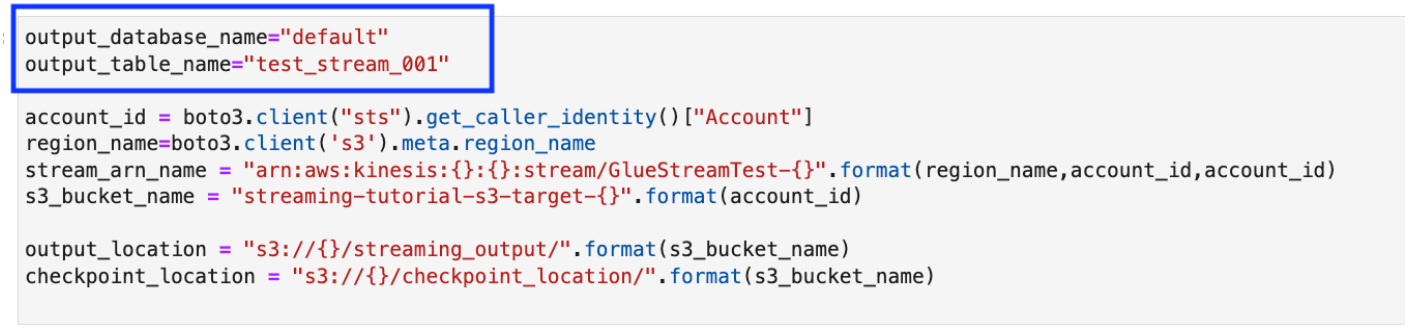

5. Como los datos ya se están transmitiendo a Kinesis Data Streams, la siguiente celda consumirá los resultados del flujo. Ejecute la siguiente celda. Como no hay instrucciones de impresión, no se espera ningún resultado de esta celda.

6. En la siguiente celda, se explora el flujo entrante tomando un conjunto de muestra e imprimiendo su esquema y los datos reales. Por ejemplo:

Sample and print the incoming records

the sampling is for debugging purpose. You may comment off the entire code cell below, before deploying the actual code

[4]:
```
options = {
    "pollingTimeInMs": "20000",
    "windowSize": "5 seconds"
}
sampled_dynamic_frame = glueContext.getSampleStreamingDynamicFrame(data_frame, options, None)

count_of_sampled_records = sampled_dynamic_frame.count()

print(count_of_sampled_records)

sampled_dynamic_frame.printSchema()

sampled_dynamic_frame.toDF().show(10,False)
```

```
100
root
|-- eventtime: string
|-- manufacturer: string
|-- minutevolume: long
|-- o2stats: long
|-- pressurecontrol: long
|-- serialnumber: string
|-- ventilatorid: long

+-------------------+------------+------------+-------+---------------+------------------------------------+------------+
|eventtime          |manufacturer|minutevolume|o2stats|pressurecontrol|serialnumber                        |ventilatorid|
+-------------------+------------+------------+-------+---------------+------------------------------------+------------+
|2023-07-18 10:20:11|3M          |6           |92     |24             |a3e860ba-24b9-41c4-bc10-91c6b35e1406|6           |
|2023-07-18 10:20:11|Vyaire      |6           |95     |6              |96101dca-3e88-457f-b390-e3291df48a81|26          |
|2023-07-18 10:20:12|Getinge     |8           |96     |24             |18f3d448-1dee-4c80-835b-1a0daa818915|22          |
|2023-07-18 10:20:12|Getinge     |7           |98     |30             |25f425cd-b978-4953-9a03-4d607a639364|91          |
|2023-07-18 10:20:12|GE          |5           |93     |25             |2cd7cdc2-f5f5-4ff2-ae32-45e5a8922d53|93          |
```

7. A continuación, defina la lógica de transformación de datos real. La celda consiste en el método `processBatch` que se activa durante cada microlote. Ejecute la celda. En un nivel superior, haga lo siguiente con el flujo entrante:

   a. Seleccione un subconjunto de las columnas de entrada.

   b. Cambie el nombre de una columna (o2stats a oxygen_stats).

   c. Derive columnas nuevas (serial_identifier, ingest_year, ingest_month e ingest_day).

   d. Almacene los resultados en un bucket de Amazon S3 y también cree una tabla de catálogo de AWS Glue particionada.

8. En la última celda, active el proceso por lotes cada 10 segundos. Ejecute la celda y espere unos 30 segundos para que llene el bucket de Amazon S3 y la tabla del catálogo de AWS Glue.

9. Por último, explore los datos almacenados con el editor de consultas de Amazon Athena. Puede ver la columna a la que se le ha cambiado el nombre y también las nuevas particiones.

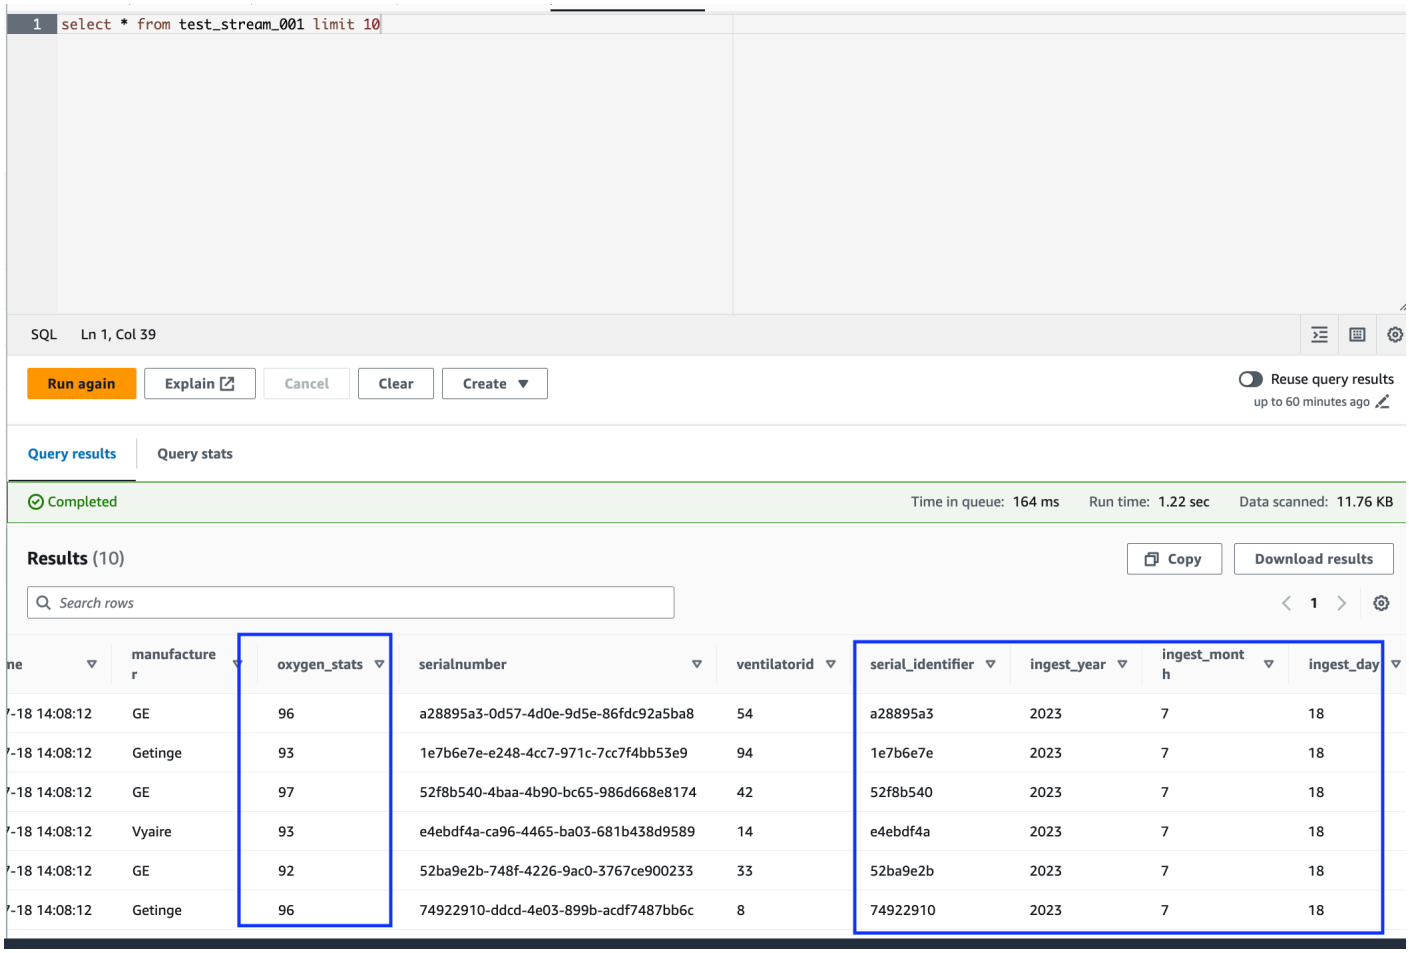

El cuaderno tiene todas las instrucciones necesarias para continuar con el tutorial. Puede ejecutar las instrucciones en el cuaderno o seguir este tutorial para continuar con el desarrollo del trabajo.

Guarde y ejecute el trabajo de AWS Glue

Una vez que haya completado el desarrollo y las pruebas de su aplicación con el cuaderno de sesiones interactivas, haga clic en Guardar en la parte superior de la interfaz del cuaderno. Una vez guardado, también puede ejecutar la aplicación como un trabajo.

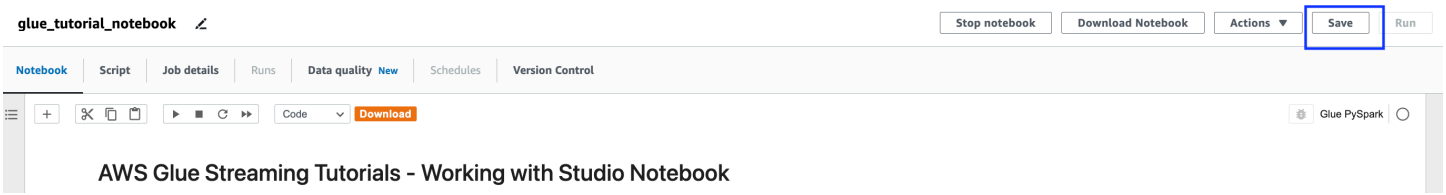

Limpieza

Para evitar incurrir en cargos adicionales en su cuenta, detenga el trabajo de transmisión que inició siguiendo las instrucciones. Puede hacerlo cerrando el cuaderno, lo que finalizará la sesión. Vacíe el bucket de Amazon S3 y elimine la pila de AWS CloudFormation que aprovisionó anteriormente.

Conclusión

En este tutorial, mostramos cómo usar el cuaderno de AWS Glue Studio para hacer lo siguiente:

- Crear un trabajo de ETL de transmisión con cuadernos
- Previsualizar los flujos de datos entrantes
- Codificar y solucionar problemas sin tener que publicar los trabajos de AWS Glue
- Revisar el código de trabajo de principio a fin, eliminar cualquier error e imprimir las instrucciones o celdas del cuaderno
- Publicar el código como un trabajo de AWS Glue

El objetivo de este tutorial es proporcionarle experiencia práctica al trabajar con la transmisión de AWS Glue y las sesiones interactivas. Le recomendamos que lo use como referencia para sus casos de uso individuales de transmisión de AWS Glue. Para obtener más información, consulte Introducción a las sesiones interactivas de AWS Glue.

Conceptos de la transmisión de AWS Glue

En las siguientes secciones, se ofrece información acerca del los conceptos de la transmisión de AWS Glue.

Temas

- Anatomía de un trabajo de transmisión de AWS Glue

Anatomía de un trabajo de transmisión de AWS Glue

Los trabajos de transmisión de AWS Glue funcionan según el paradigma de transmisión de Spark y aprovechan la transmisión estructurada del marco de trabajo de Spark. Los trabajos de transmisión sondean constantemente el origen de datos de transmisión, en un intervalo específico, para obtener

los registros en forma de microlotes. En las siguientes secciones, se examinan las distintas partes de un trabajo de transmisión de AWS Glue.

forEachBatch

El método `forEachBatch` es el punto de entrada de la ejecución de un trabajo de transmisión de AWS Glue. Los trabajos de transmisión de AWS Glue usan el método `forEachBatch` para sondear los datos, lo cual funciona como un iterador que permanece activo durante la duración del trabajo de transmisión y sondea periódicamente el origen de transmisión en busca de nuevos datos y procesa los datos más recientes en microlotes.

```
glueContext.forEachBatch(
    frame=dataFrame_AmazonKinesis_node1696872487972,
    batch_function=processBatch,
    options={
        "windowSize": "100 seconds",
        "checkpointLocation": args["TempDir"] + "/" + args["JOB_NAME"] + "/
checkpoint/",
    },
)
```

Configure la propiedad `frame` de `forEachBatch` para especificar un origen de transmisión. En este ejemplo, el nodo de origen que creó en el lienzo en blanco durante la creación del trabajo se rellena con el DataFrame predeterminado del trabajo. Defina la propiedad `batch_function` como la `function` que decida invocar para cada operación de microlotes. Debe definir una función para gestionar la transformación por lotes de los datos entrantes.

Origen

En el primer paso de la función `processBatch`, el programa verifica el recuento de registros del DataFrame que usted definió como propiedad del marco de `forEachBatch`. El programa agrega una marca de tiempo de ingesta a un DataFrame que no esté vacío. La cláusula `data_frame.count()>0` determina si el último microlote no está vacío y está listo para su posterior procesamiento.

```
def processBatch(data_frame, batchId):
    if data_frame.count() >0:
        AmazonKinesis_node1696872487972 = DynamicFrame.fromDF(
            glueContext.add_ingestion_time_columns(data_frame, "hour"),
            glueContext,
            "from_data_frame",
        )
```

Correspondencia

La siguiente sección del programa consiste en aplicar la asignación. El método `Mapping.apply` de un DataFrame de Spark le permite definir una regla de transformación en torno a los elementos de datos. Por lo general, puede cambiar el nombre y el tipo de datos o aplicar una función personalizada en la columna de datos de origen y asignarla a las columnas de destino.

```
    #Script generated for node ChangeSchema
    ChangeSchema_node16986872679326 = ApplyMapping.apply(
        frame =  AmazonKinesis_node1696872487972,
        mappings = [
            ("eventtime", "string", "eventtime", "string"),
            ("manufacturer", "string", "manufacturer", "string"),
            ("minutevolume", "long", "minutevolume", "int"),
            ("o2stats", "long", "OxygenSaturation", "int"),
```

```
            ("pressurecontrol", "long", "pressurecontrol", "int"),
            ("serialnumber", "string", "serialnumber", "string"),
            ("ventilatorid", "long", "ventilatorid", "long"),
            ("ingest_year", "string", "ingest_year", "string"),
            ("ingest_month", "string", "ingest_month", "string"),
            ("ingest_day", "string", "ingest_day", "string"),
            ("ingest_hour", "string", "ingest_hour", "string"),
        ],
        transformation_ctx="ChangeSchema_node16986872679326",
    )
        )
```

Receptor

En esta sección, el conjunto de datos entrantes del origen de transmisión se almacena en una ubicación de destino. En este ejemplo, escribiremos los datos en una ubicación de Amazon S3. Los detalles de la propiedad `AmazonS3_node_path` se rellenan automáticamente según lo determinado por la configuración que usó durante la creación del trabajo desde el lienzo. Puede configurar el `updateBehavior` en función de su caso de uso y decidir no actualizar la tabla del catálogo de datos o crear un catálogo de datos y actualizar el esquema del catálogo de datos en las ejecuciones posteriores, o bien crear una tabla de catálogo y no actualizar la definición del esquema en las ejecuciones posteriores.

La propiedad `partitionKeys` define la opción de partición de almacenamiento. El comportamiento predeterminado es particionar los datos según el `ingestion_time_columns` que estaba disponible en la sección de origen. La propiedad `compression` permite configurar el algoritmo de compresión que se aplicará durante la escritura de destino. Tiene la opción de configurar Snappy, LZO o GZIP como la técnica de compresión. La propiedad `enableUpdateCatalog` controla si es necesario actualizar la tabla del catálogo de AWS Glue. Las opciones disponibles para esta propiedad son `True` o `False`.

```
    #Script generated for node Amazon S3
    AmazonS3_node1696872743449 = glueContext.getSink(
        path =  AmazonS3_node1696872743449_path,
        connection_type = "s3",
        updateBehavior = "UPDATE_IN_DATABASE",
        partitionKeys = ["ingest_year", "ingest_month", "ingest_day", "ingest_hour"],
        compression = "snappy",
        enableUpdateCatalog = True,
```

```
        transformation_ctx = "AmazonS3_node1696872743449",
    )
```

Receptor del catálogo de AWS Glue

Esta sección del trabajo controla el comportamiento de actualización de la tabla del catálogo de AWS Glue. Defina las propiedades `catalogDatabase` y `catalogTableName` según el nombre de la base de datos de su catálogo de AWS Glue y el nombre de la tabla asociada al trabajo de AWS Glue que está diseñando. Puede definir el formato de archivo de los datos de destino mediante la propiedad `setFormat`. Para este ejemplo, almacenaremos los datos en formato parquet.

Una vez que haya configurado y ejecutado el trabajo de transmisión de AWS Glue siguiendo este tutorial, los datos de transmisión producidos en Amazon Kinesis Data Streams se almacenarán en la ubicación de Amazon S3 en formato parquet con una compresión rápida. Si el trabajo de transmisión se ejecuta correctamente, podrá consultar los datos a través de Amazon Athena.

```
AmazonS3_node1696872743449 = setCatalogInfo(
    catalogDatabase =  "demo", catalogTableName = "demo_stream_transform_result"
)
AmazonS3_node1696872743449.setFormat("glueparquet")
AmazonS3_node1696872743449.writeFormat("ChangeSchema_node16986872679326")
)
```

Conexiones de AWS Glue Streaming

En las siguientes secciones se proporciona información sobre cómo utilizar las conexiones en AWS Glue Streaming.

Temas

- Uso de conexiones de Kafka
- Uso de conexiones de Kinesis

Uso de conexiones de Kafka

Puede utilizar una conexión de Kafka para leer y escribir en los flujos de datos de Kafka mediante información almacenada en una tabla del catálogo de datos o si proporciona información para acceder directamente al flujo de datos. La conexión admite un clúster de Kafka o un clúster de Amazon Managed Streaming para Apache Kafka. Puede leer la información de Kafka en un DataFrame de Spark para luego convertirla en un DynamicFrame de AWS Glue. Puede escribir los DynamicFrame en Kafka en un formato JSON. Si accede directamente a la secuencia de datos, utilice estas opciones para proporcionar información sobre cómo acceder a la secuencia de datos.

Si utiliza `getCatalogSource` o `create_data_frame_from_catalog` para consumir los registros de un origen de streaming de Kafka, o `getCatalogSink` o `write_dynamic_frame_from_catalog` para escribir registros en Kafka, el trabajo cuenta con la base de datos del Catálogo de datos y la información del nombre de la tabla, lo cual se puede utilizar para obtener algunos parámetros básicos para la lectura de un origen de streaming de Kafka. Si utiliza `getSource`, `getCatalogSink`, `getSourceWithFormat`, `getSinkWithFormat`, `createDataFrameFromOptions`, `create_data_frame_from_options` o `write_dynamic_frame_from_catalog`, debe especificar estos parámetros básicos con las opciones de conexión que se describen aquí.

Puede especificar las opciones de conexión para Kafka con los argumentos que se mencionan a continuación para los métodos especificados en la clase `GlueContext`.

- Scala
  - `connectionOptions`: se debe utilizar con `getSource`, `createDataFrameFromOptions` y `getSink`
  - `additionalOptions`: se debe utilizar con `getCatalogSource`, `getCatalogSink`
  - `options`: se debe utilizar con `getSourceWithFormat`, `getSinkWithFormat`
- Python
  - `connection_options`: se debe utilizar con `create_data_frame_from_options`, `write_dynamic_frame_from_options`
  - `additional_options`: se debe utilizar con `create_data_frame_from_catalog`, `write_dynamic_frame_from_catalog`
  - `options`: se debe utilizar con `getSource`, `getSink`

Para obtener notas y conocer las restricciones sobre los trabajos de ETL de transmisión, consulte the section called “Notas y restricciones de ETL de streaming”.

Configurar Kafka

No hay requisitos previos AWS para conectarse a las transmisiones de Kafka disponibles a través de Internet.

Puede crear una conexión Glue Kafka AWS para gestionar sus credenciales de conexión. Para obtener más información, consulte the section called “Crear una conexión para un flujo de datos Kafka”. En la configuración del trabajo de Glue AWS, proporcione *connectionName* como conexión de red adicional y, a continuación, en la llamada al método, proporcione *connectionName* al parámetro `connectionName`.

En algunos casos, tendrá que configurar requisitos previos adicionales:

- Si utiliza Amazon Managed Streaming for Apache Kafka con autenticación de IAM, necesitará una configuración de IAM adecuada.
- Si utiliza Amazon Managed Streaming for Apache Kafka con una Amazon VPC, necesitará una configuración de Amazon VPC adecuada. Deberá crear una conexión a AWS Glue que proporcione información de conexión de Amazon VPC. Necesitará que la configuración de su trabajo incluya la conexión Glue AWS como conexión de red adicional.

Para obtener más información sobre los requisitos previos del trabajo de ETL de Streaming, consulte the section called “Trabajos ETL de streaming”.

Ejemplo: leer desde transmisiones de Kafka

Se utiliza junto con the section called “forEachBatch”.

Ejemplo de origen de streaming de Kafka:

```
kafka_options =
    { "connectionName": "ConfluentKafka",
      "topicName": "kafka-auth-topic",
      "startingOffsets": "earliest",
      "inferSchema": "true",
      "classification": "json"
    }
data_frame_datasource0 =
 glueContext.create_data_frame.from_options(connection_type="kafka",
 connection_options=kafka_options)
```

Ejemplo: escritura a flujos de Kafka

Ejemplos de escritura a Kafka:

Ejemplo con el método `getSink`:

```
data_frame_datasource0 =
glueContext.getSink(
 connectionType="kafka",
 connectionOptions={
  JsonOptions("""{
   "connectionName": "ConfluentKafka",
   "classification": "json",
   "topic": "kafka-auth-topic",
   "typeOfData": "kafka"}
  """)},
 transformationContext="dataframe_ApacheKafka_node1711729173428")
 .getDataFrame()
```

Ejemplo con el método `write_dynamic_frame.from_options`:

```
kafka_options =
    { "connectionName": "ConfluentKafka",
      "topicName": "kafka-auth-topic",
      "classification": "json"
    }
data_frame_datasource0 =
 glueContext.write_dynamic_frame.from_options(connection_type="kafka",
 connection_options=kafka_options)
```

Referencia de opciones de conexión de Kafka

Al leer, utilice las opciones de conexión con `"connectionType": "kafka"` a continuación:

- `"bootstrap.servers"` (obligatorio): una lista de direcciones URL Bootstrap, por ejemplo, como `b-1.vpc-test-2.o4q88o.c6.kafka.us-east-1.amazonaws.com:9094`. Esta opción debe especificarse en la llamada a la API o definirse en los metadatos de la tabla en el Data Catalog.
- `"security.protocol"` (obligatorio): el protocolo que se utiliza para la comunicación con los agentes. Los valores posibles son `"SSL"` o.`"PLAINTEXT"`
- `"topicName"` (Obligatorio) Lista separada por comas de temas a los que suscribirse. Debe especificar solo una opción de `"topicName"`, `"assign"` o `"subscribePattern"`.

- `"assign"`: (Obligatorio) Una cadena JSON que especifica el valor de `TopicPartitions` para consumir. Debe especificar solo una opción de `"topicName"`, `"assign"` o `"subscribePattern"`.

  Ejemplo: “{“temaA”:[0,1],“temaB”:[2,4]}”

- `"subscribePattern"`: (obligatorio) cadena de expresiones regulares de Java que identifica la lista de temas a la que desea suscribirse. Debe especificar solo una opción de `"topicName"`, `"assign"` o `"subscribePattern"`.

  Ejemplo: “tema.*”

- `"classification"` (Obligatorio) El formato de archivo utilizado por los datos del registro. Obligatorio a menos que se proporcione a través del catálogo de datos.

- `"delimiter"` (Opcional) El separador de valores que se utiliza cuando `classification` es CSV. El valor predeterminado es “`,`”.

- `"startingOffsets"`: (opcional) posición inicial en el tema de Kafka para leer los datos. Los valores posibles son `"earliest"` o.`"latest"` El valor predeterminado es `"latest"`.

- `"startingTimestamp"`: (Opcional, solo compatible con la versión 4.0 o posterior de Glue AWS) La marca de tiempo del registro en el tema de Kafka para leer los datos. Los valores posibles son una cadena de marca de tiempo en formato UTC en el patrón `yyyy-mm-ddTHH:MM:SSZ` (donde `Z` representa un desplazamiento de zona horaria UTC con un +/-. Por ejemplo, “2023-04-04T08:00:00-04:00”).

  Nota: Solo una de las opciones 'startingOffsets' o 'startingTimestamp' puede estar presente en la lista de opciones de conexión del script de streaming de AWS Glue, incluir estas dos propiedades producirá un error en el trabajo.

- `"endingOffsets"`: (opcional) el punto final cuando finaliza una consulta por lotes. Los valores posibles son `"latest"` o una cadena JSON que especifica una compensación final para cada `TopicPartition`.

  Para la cadena JSON, el formato es `{"topicA":{"0":23,"1":-1},"topicB":{"0":-1}}`. El valor `-1` como compensación representa `"latest"`.

- `"pollTimeoutMs"`: (opcional) tiempo de espera en milisegundos para sondear datos de Kafka en ejecutores de trabajos de Spark. El valor predeterminado es `600000`.

- `"numRetries"`: (opcional) el número de veces que se reintenta antes de no obtener las compensaciones de Kafka. El valor predeterminado es `3`.

- `"retryIntervalMs"`: (opcional) tiempo en milisegundos para esperar antes de volver a intentar obtener compensaciones Kafka. El valor predeterminado es `10`.
- `"maxOffsetsPerTrigger"`: (opcional) el límite de velocidad en el número máximo de compensaciones que se procesan por intervalo de desencadenador. El número total de compensaciones especificado se divide de forma proporcional entre `topicPartitions` de diferentes volúmenes. El valor predeterminado es nulo, lo que significa que el consumidor lee todos las compensaciones hasta la última compensación conocida.
- `"minPartitions"`: (opcional) el número mínimo deseado de particiones para leer desde Kafka. El valor predeterminado es nulo, lo que significa que el número de particiones de Spark es igual al número de particiones de Kafka.
- `"includeHeaders"`: (opcional) si se deben incluir los encabezados de Kafka. Cuando la opción se establece en “verdadero”, la salida de datos contendrá una columna adicional denominada “glue_streaming_kafka_headers” con el tipo `Array[Struct(key: String, value: String)]`. El valor predeterminado es “false”. Esta opción se encuentra disponible en la versión 3.0 o posterior de AWS Glue.
- `"schema"`: (Obligatorio cuando inferSchema se establece en false) Esquema que se va a utilizar para procesar la carga. Si la clasificación es `avro`, el esquema proporcionado debe estar en el formato de esquema Avro. Si la clasificación no es `avro`, el esquema proporcionado debe estar en el formato de esquema DDL.

  A continuación, se muestran algunos ejemplos de esquemas.

  Example in DDL schema format

  ```
  'column1' INT, 'column2' STRING , 'column3' FLOAT
  ```

  Example in Avro schema format

  ```
  {
  "type":"array",
  "items":
  {
  "type":"record",
  "name":"test",
  "fields":
  [
    {
      "name":"_id",
      "type":"string"
  ```

```
  },
  {
    "name":"index",
    "type":
    [
      "int",
      "string",
      "float"
    ]
  }
]
}
}
```

- `"inferSchema"`: (opcional) El valor predeterminado es “false”. Si se establece en “true”, el esquema se detectará durante el tiempo de ejecución desde la carga dentro de `foreachbatch`.
- `"avroSchema"`: (obsoleto) Parámetro utilizado para especificar un esquema de datos Avro cuando se utiliza el formato Avro. Este parámetro se ha quedado obsoleto. Utilice el parámetro `schema`.
- `"addRecordTimestamp"`: (opcional) cuando esta opción se establece en “true”, la salida de datos contendrá una columna adicional denominada “__src_timestamp” que indica la hora en la que el tema recibió el registro correspondiente. El valor predeterminado es “false”. Esta opción es compatible con la versión 4.0 o posterior de AWS Glue.
- `"emitConsumerLagMetrics"`: (opcional) cuando esta opción se establece en “true”, para cada lote, emitirá las métricas correspondientes al período comprendido entre el registro más antiguo recibido por el tema y el momento en que llegue a AWS Glue en CloudWatch. El nombre de la métrica es “glue.driver.streaming.maxConsumerLagInMs”. El valor predeterminado es “false”. Esta opción es compatible con la versión 4.0 o posterior de AWS Glue.

Al escribir, utilice las opciones de conexión con `"connectionType": "kafka"` a continuación:

- `"connectionName"` (Obligatorio) Nombre de la conexión de AWS Glue utilizada para conectar al clúster de Kafka (similar al origen de Kafka).
- `"topic"` (Obligatorio) Si existe una columna de temas, su valor se utiliza como el tema al momento de la escritura de la fila en Kafka, a menos que esté establecida la opción de configuración de temas. Es decir, la opción de configuración de `topic` anula la columna de temas.
- `"partition"` (Opcional) Si se especifica un número válido de partición, esta `partition` se utilizará cuando se envíe el registro.

Si no se especifica ninguna partición pero hay una `key`, se elegirá una partición con el hash de la clave.

Si no hay ni una `key` ni una `partition`, se elegirá una partición según la partición sticky de esos cambios cuando al menos se produzcan bytes de batch.size en la partición.

- `"key"` (Opcional) Utilizado para la partición si la `partition` es nula.
- `"classification"` (Opcional) El formato de archivo utilizado por los datos en el registro. Solo se admiten los formatos JSON, CSV y Avro.

  Con el formato Avro, podemos brindar un AvroSchema personalizado para la serialización, pero tenga en cuenta que también se tiene que brindar en el origen para la deserialización. Si no, se utilizará de manera predeterminada el AvroSchema de Apache para la serialización.

Además, puede ajustar los receptores de Kafka según sea necesario al actualizar los parámetros de configuración de productor de Kafka. Tenga en cuenta que no hay una lista de permisos en las opciones de conexión; todos los pares clave-valor se conservan en el receptor como se encuentran.

Sin embargo, existe una pequeña lista de opciones de rechazos que no tendrá efecto. Para obtener más información, consulte las Configuraciones específicas de Kafka.

Uso de conexiones de Kinesis

Puede utilizar una conexión de Kafka para leer y escribir en Amazon Kinesis Data Streams mediante información almacenada en una tabla del catálogo de datos o si proporciona información para acceder directamente al flujo de datos. Puede leer la información de Kinesis en un DataFrame de Spark y, a continuación, convertirla en un DynamicFrame de AWS Glue. Puede escribir DynamicFrames en Kinesis en formato JSON. Si accede directamente a la secuencia de datos, utilice estas opciones para proporcionar información sobre cómo acceder a la secuencia de datos.

Si utiliza `getCatalogSource` o `create_data_frame_from_catalog` para consumir registros de una fuente de streaming de Kinesis, el trabajo tiene la base de datos de Data Catalog y la información del nombre de la tabla, y puede utilizarla para obtener algunos parámetros básicos para la lectura de la fuente de streaming de Kinesis. Si utiliza `getSource`, `getSourceWithFormat`, `createDataFrameFromOptions` o `create_data_frame_from_options` debe especificar estos parámetros básicos mediante las opciones de conexión descritas aquí.

Puede especificar las opciones de conexión para Kinesis al utilizar los siguientes argumentos para los métodos especificados en la clase `GlueContext`.

- Scala
  - `connectionOptions`: se debe utilizar con `getSource`, `createDataFrameFromOptions` y `getSink`
  - `additionalOptions`: se debe utilizar con `getCatalogSource`, `getCatalogSink`
  - `options`: se debe utilizar con `getSourceWithFormat`, `getSinkWithFormat`
- Python
  - `connection_options`: se debe utilizar con `create_data_frame_from_options`, `write_dynamic_frame_from_options`
  - `additional_options`: se debe utilizar con `create_data_frame_from_catalog`, `write_dynamic_frame_from_catalog`
  - `options`: se debe utilizar con `getSource`, `getSink`

Para obtener notas y restricciones sobre los trabajos de ETL de Streaming, consulte the section called “Notas y restricciones de ETL de streaming”.

Configurar Kinesis

Para conectarse desde un flujo de datos de Kinesis en un trabajo de AWS Glue Spark, necesitará algunos requisitos previos:

- Si está leyendo, el trabajo de AWS Glue debe tener permisos de IAM de nivel de acceso de lectura para el flujo de datos de Kinesis.
- Si está escribiendo, el trabajo de AWS Glue debe tener permisos de IAM de nivel de acceso de escritura para el flujo de datos de Kinesis.

En algunos casos, tendrá que configurar requisitos previos adicionales:

- Si su trabajo de AWS Glue está configurado con conexiones de red adicionales (normalmente para conectarse a otros conjuntos de datos) y una de esas conexiones proporciona opciones de red de Amazon VPC, esto indicará que su trabajo se comunique a través de Amazon VPC. En este caso, también tendrá que configurar el flujo de datos de Kinesis para que se comunique a través de Amazon VPC. Puede hacerlo mediante la creación de un punto de conexión de VPC de tipo interfaz entre la Amazon VPC y el flujo de datos de Kinesis. Para obtener más información, consulte Uso de Kinesis de Amazon Kinesis Data Streams con puntos de conexión de VPC de interfaz.

- Al especificar Amazon Kinesis Data Streams en otra cuenta, debe configurar los roles y las políticas para permitir el acceso entre cuentas. Para obtener más información, consulte Ejemplo: leer desde un flujo de Kinesis en una cuenta diferente.

Para obtener más información sobre los requisitos previos del trabajo de ETL de Streaming, consulte the section called “Trabajos ETL de streaming”.

Lea desde Kinesis

Ejemplo: lectura de transmisiones desde Kinesis

Se utiliza junto con the section called “forEachBatch”.

Ejemplo de origen de streaming de Amazon Kinesis:

```
kinesis_options =
   { "streamARN": "arn:aws:kinesis:us-east-2:777788889999:stream/fromOptionsStream",
     "startingPosition": "TRIM_HORIZON",
     "inferSchema": "true",
     "classification": "json"
   }
data_frame_datasource0 =
 glueContext.create_data_frame.from_options(connection_type="kinesis",
 connection_options=kinesis_options)
```

Escribir en Kinesis

Ejemplo: escribir en flujos de Kinesis

Se utiliza junto con the section called “forEachBatch”. El DynamicFrame se escribirá en el flujo en formato JSON. Si el trabajo no se puede escribir después de varios intentos, fallará. De forma predeterminada, cada registro de DynamicFrame se enviará al flujo de Kinesis de forma individual. Puede configurar este comportamiento mediante `aggregationEnabled` y los parámetros asociados.

Ejemplo de escritura en Amazon Kinesis desde un trabajo de transmisión:

Python

```
glueContext.write_dynamic_frame.from_options(
```

```
    frame=frameToWrite
    connection_type="kinesis",
    connection_options={
        "partitionKey": "part1",
        "streamARN": "arn:aws:kinesis:us-east-1:111122223333:stream/streamName",
    }
)
```

Scala

```
glueContext.getSinkWithFormat(
                connectionType="kinesis",
                options=JsonOptions("""{
                    "streamARN": "arn:aws:kinesis:us-
east-1:111122223333:stream/streamName",
                    "partitionKey": "part1"
                }"""),
            )
            .writeDynamicFrame(frameToWrite)
```

Parámetros de conexión de Kinesis

Designa opciones de conexión para Amazon Kinesis Data Streams.

Utilice las siguientes opciones de conexión para los orígenes de datos de streaming de Kinesis:

- `"streamARN"`: (Obligatorio) Se utiliza para leer/escribir. El ARN de flujo de datos de Kinesis.
- `"classification"`: (Obligatorio para lectura) Se utiliza para leer. El formato de archivo utilizado por los datos del registro. Obligatorio a menos que se proporcione a través del catálogo de datos.
- `"streamName"`: (Opcional) Se usa para leer. Nombre de un flujo de datos de Kinesis para leer. Utilizado con `endpointUrl`.
- `"endpointUrl"`: (Opcional) Se usa para leer. Predeterminado: “https://kinesis.us-east-1.amazonaws.com”. El punto de conexión de AWS del flujo de Kinesis. No es necesario cambiar esto a menos que se conecte a una región especial.
- `"partitionKey"`: (Opcional) Se usa para escribir. La clave de partición de Kinesis que se utiliza al producir registros.
- `"delimiter"`: (Opcional) Se usa para leer. El separador de valores que se utiliza cuando `classification` es CSV. El valor predeterminado es “`,`”.

- `"startingPosition"`: (Opcional) Se usa para leer. La posición inicial en el flujo de datos de Kinesis para leer los datos. Los valores posibles son `"latest"`, `"trim_horizon"`, `"earliest"` o una cadena de marca de tiempo en formato UTC en el patrón `yyyy-mm-ddTHH:MM:SSZ` (donde `Z` representa un desplazamiento de zona horaria UTC con un +/-. Por ejemplo, “04-04-2023 T 08:00:00-04:00”). El valor predeterminado es `"latest"`. Nota: La cadena de marca de tiempo en formato UTC para `"startingPosition"` solo es compatible con la versión 4.0 o posterior de Glue AWS.
- `"failOnDataLoss"`: (Opcional) No se realizará el trabajo si falta o ha caducado alguna partición activa. El valor predeterminado es `"false"`.
- `"awsSTSRoleARN"`: (Opcional) Se usa para escribir/leer. El nombre de recurso de Amazon (ARN) del rol de que se asumirá mediante AWS Security Token Service (AWS STS). Este rol debe tener permisos para describir o leer operaciones de registros del flujo de datos de Kinesis. Debe utilizar este parámetro para acceder a un flujo de datos de otra cuenta. Se utiliza junto con `"awsSTSSessionName"`.
- `"awsSTSSessionName"`: (Opcional) Se usa para escribir/leer. Un identificador para la sesión que asume el rol mediante AWS STS. Debe utilizar este parámetro para acceder a un flujo de datos de otra cuenta. Se utiliza junto con `"awsSTSRoleARN"`.
- `"awsSTSEndpoint"`: (Opcional) El punto de conexión de AWS STS que se utilizará al conectarse a Kinesis con un rol asumido. Esto permite usar el punto de conexión regional de AWS STS en una VPC, lo que no es posible con el punto de conexión global predeterminado.
- `"maxFetchTimeInMs"`: (Opcional) Se usa para leer. El tiempo máximo que le tomó al ejecutor del trabajo leer los registros del lote actual en el flujo de datos de Kinesis, especificado en milisegundos (ms). Pueden realizarse varias llamadas a la API de `GetRecords` durante este tiempo. El valor predeterminado es `1000`.
- `"maxFetchRecordsPerShard"`: (Opcional) Se usa para leer. El número máximo de registros que se recuperará por partición en el flujo de datos de Kinesis por microlote. Nota: El cliente puede exceder este límite si el trabajo de streaming ya leyó registros adicionales de Kinesis (en la misma llamada de obtención de registros). Si `maxFetchRecordsPerShard` tiene que ser preciso, entonces tiene que ser un múltiplo de `maxRecordPerRead`. El valor predeterminado es `100000`.
- `"maxRecordPerRead"`: (Opcional) Se usa para leer. El número máximo de registros que se recuperará del flujo de datos de Kinesis en cada operación `getRecords`. El valor predeterminado es `10000`.
- `"addIdleTimeBetweenReads"`: (Opcional) Se usa para leer. Agrega un retardo de tiempo entre dos operaciones `getRecords` consecutivas. El valor predeterminado es `"False"`. Esta opción sólo se puede configurar para Glue versión 2.0 y superior.

- `"idleTimeBetweenReadsInMs"`: (Opcional) Se usa para leer. El tiempo mínimo de retraso entre dos operaciones `getRecords` consecutivas, especificado en ms. El valor predeterminado es `1000`. Esta opción sólo se puede configurar para Glue versión 2.0 y superior.
- `"describeShardInterval"`: (Opcional) Se usa para leer. El intervalo mínimo de tiempo entre dos llamadas a la API `ListShards` para que su script considere cambios en los fragmentos. Para obtener más información, consulte Estrategias para cambios en los fragmentos en la Guía para desarrolladores de Amazon Kinesis Data Streams. El valor predeterminado es `1s`.
- `"numRetries"`: (Opcional) Se usa para leer. El número máximo de reintentos para las solicitudes de la API de Kinesis Data Streams. El valor predeterminado es `3`.
- `"retryIntervalMs"`: (Opcional) Se usa para leer. El periodo de enfriamiento (especificado en ms) antes de volver a intentar la llamada a la API de Kinesis Data Streams. El valor predeterminado es `1000`.
- `"maxRetryIntervalMs"`: (Opcional) Se usa para leer. El periodo de enfriamiento máximo (especificado en ms) entre dos intentos de llamada a la API de Kinesis Data Streams. El valor predeterminado es `10000`.
- `"avoidEmptyBatches"`: (Opcional) Se usa para leer. Evita crear un trabajo de microlotes vacío al comprobar si hay datos no leídos en el flujo de datos de Kinesis antes de que se inicie el lote. El valor predeterminado es `"False"`.
- `"schema"`: (Obligatorio cuando inferSchema se establece en false) Se utiliza para leer. El esquema que se utilizará para procesar la carga útil. Si la clasificación es `avro`, el esquema proporcionado debe estar en el formato de esquema Avro. Si la clasificación no es `avro`, el esquema proporcionado debe estar en el formato de esquema DDL.

  A continuación, se muestran algunos ejemplos de esquemas.

  Example in DDL schema format

  ```
  `column1` INT, `column2` STRING , `column3` FLOAT
  ```

  Example in Avro schema format

  ```
  {
    "type":"array",
    "items":
    {
      "type":"record",
      "name":"test",
      "fields":
  ```

```
    [
      {
        "name":"_id",
        "type":"string"
      },
      {
        "name":"index",
        "type":
        [
          "int",
          "string",
          "float"
        ]
      }
    ]
  }
}
```

- `"inferSchema"`: (Opcional) Se usa para leer. El valor predeterminado es “false”. Si se establece en “true”, el esquema se detectará durante el tiempo de ejecución desde la carga dentro de `foreachbatch`.
- `"avroSchema"`: (Obsoleto) Se usa para leer. Parámetro utilizado para especificar un esquema de datos Avro cuando se utiliza el formato Avro. Este parámetro se ha quedado obsoleto. Utilice el parámetro `schema`.
- `"addRecordTimestamp"`: (Opcional) Se usa para leer. Cuando esta opción se establece en “true”, la salida de datos contendrá una columna adicional denominada “__src_timestamp” que indica la hora en la que el flujo recibió el registro correspondiente. El valor predeterminado es “false”. Esta opción es compatible con la versión 4.0 o posterior de AWS Glue.
- `"emitConsumerLagMetrics"`: (Opcional) Se usa para leer. Cuando la opción se establece en “verdadera”, para cada lote, emitirá las métricas correspondientes al periodo comprendido entre el registro más antiguo recibido por el flujo y el momento en que llegue a AWS Glue en CloudWatch. El nombre de la métrica es “glue.driver.streaming.maxConsumerLagInMs”. El valor predeterminado es “false”. Esta opción es compatible con la versión 4.0 o posterior de AWS Glue.
- `"fanoutConsumerARN"`: (Opcional) Se usa para leer. El ARN de un consumidor de un flujo de Kinesis para el flujo especificado en `streamARN`. Se utiliza para habilitar el modo de distribución mejorada para la conexión de Kinesis. Para obtener más información sobre cómo consumir una transmisión de Kinesis con una distribución mejorada, consulte the section called “Uso de una distribución mejorada en los trabajos de streaming de Kinesis”.

- `"recordMaxBufferedTime"`: (Opcional) Se usa para escribir. Predeterminado: 1000 (ms). Tiempo máximo que un registro permanece almacenado en búfer mientras espera a ser escrito.
- `"aggregationEnabled"`: (Opcional) Se usa para escribir. Valor predeterminado: verdadero. Especifica si los registros deben agregarse antes de enviarlos a Kinesis.
- `"aggregationMaxSize"`: (Opcional) Se usa para escribir. Predeterminado: 51 200 (bytes). Si un registro supera este límite, omitirá el agregador. Nota: Kinesis impone un límite de 50 KB en el tamaño del registro. Si lo establece por encima de 50 KB, Kinesis rechazará los registros de gran tamaño.
- `"aggregationMaxCount"`: (Opcional) Se usa para escribir. Predeterminado: 4294967295. Número máximo de elementos a empaquetar en un registro agregado.
- `"producerRateLimit"`: (Opcional) Se usa para escribir. Predeterminado: 150 (%). Limita el rendimiento por partición enviado desde un solo productor (por ejemplo, su trabajo), como porcentaje del límite de backend.
- `"collectionMaxCount"`: (Opcional) Se usa para escribir. Predeterminado: 500. Número máximo de elementos a incluir en una solicitud de PutRecords.
- `"collectionMaxSize"`: (Opcional) Se usa para escribir. Predeterminado: 5 242 880 (bytes). Cantidad máxima de datos para enviar con una solicitud de PutRecords.

Escalado automático de la transmisión de AWS Glue

Los trabajos de ETL de AWS Glue Streaming consumen continuamente datos de los orígenes de streaming, limpian y transforman los datos durante el proceso y los ponen a disposición para su análisis. Al supervisar cada etapa de la ejecución del trabajo, el escalado automático de AWS Glue puede desconectar a los trabajadores cuando están inactivos o agregar trabajadores si es posible un procesamiento paralelo adicional.

En las siguientes secciones, se ofrece información acerca del escalado automático de la transmisión de AWS Glue.

Habilitar Auto Scaling en AWS Glue Studio

En la página Job details (Detalles del trabajo) en AWS Glue Studio, elija el tipo como Spark o Spark Streaming y Glue version (Versión de Glue) como **`Glue 3.0`** o **`Glue 4.0`**. A continuación, se mostrará una casilla de verificación debajo de Worker type (Tipo de empleado).

- Seleccione la opción Automatically scale the number of workers (Escalar automáticamente el número de empleados).
- Establezca el Maximum number of workers (Número máximo de empleados) para definir el número máximo de empleados que se pueden asignar a la ejecución de trabajos.

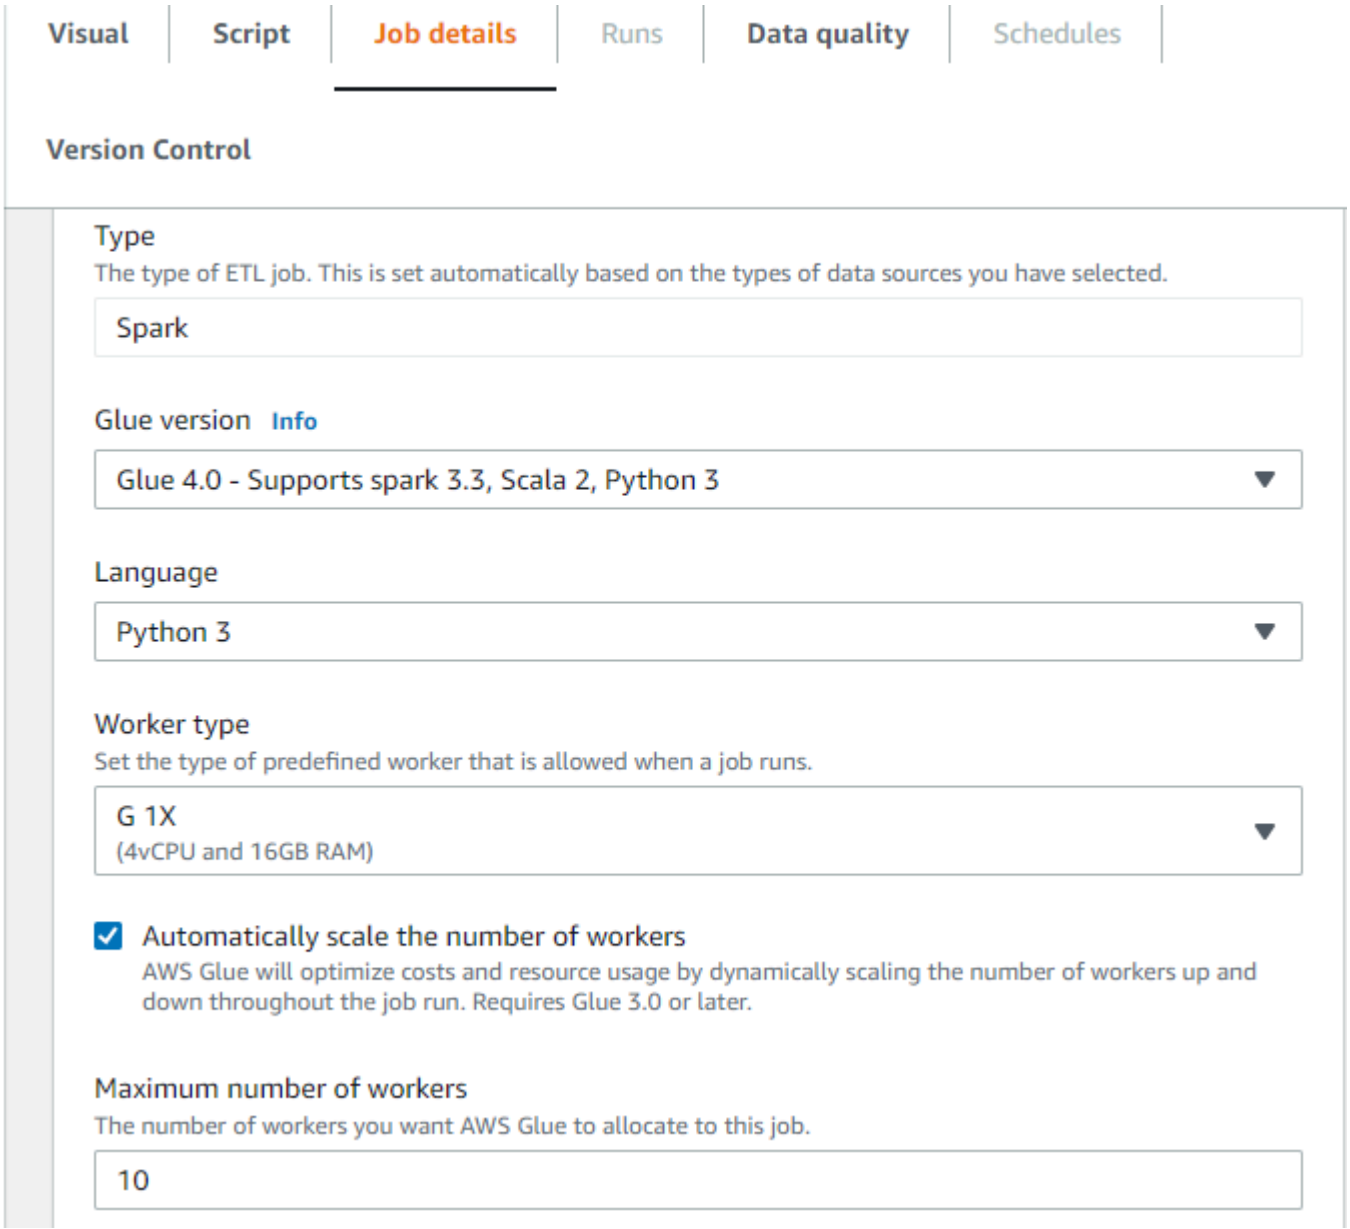

Habilitación de Auto Scaling con AWS CLI o SDK

Para habilitar Auto Scaling desde la AWS CLI para la ejecución de un trabajo, ejecute `start-job-run` con la siguiente configuración:

```
{
    "JobName": "<your job name>",
    "Arguments": {
        "--enable-auto-scaling": "true"
    },
    "WorkerType": "G.2X", // G.1X, G.2X, G.4X, G.8X, G.12X, G.16X, R.1X, R.2X, R.4X,
 and R.8X are supported for Auto Scaling Jobs
    "NumberOfWorkers": 20, // represents Maximum number of workers
    ...other job run configurations...
}
```

Una vez que haya finalizado la ejecución de un trabajo de ETL, también puede llamar a `get-job-run` para comprobar el uso real de recursos de la ejecución del trabajo en segundos de DPU. Nota: El nuevo campo DPUSeconds solo se mostrará para los trabajos por lotes en AWS Glue 3.0 o posterior con el escalado automático habilitado. Este campo no es compatible con trabajos de streaming.

```
$ aws glue get-job-run --job-name your-job-name --run-id jr_xx --endpoint https://
glue.us-east-1.amazonaws.com --region us-east-1
{
    "JobRun": {
        ...
        "GlueVersion": "3.0",
        "DPUSeconds": 386.0
    }
}
```

También se pueden configurar ejecuciones de trabajos con Auto Scaling mediante el AWS Glue SDK con la misma configuración.

Funcionamiento

Escalado entre microlotes

El siguiente ejemplo se usa para describir cómo funciona el escalado automático.

- Tiene un trabajo de AWS Glue que comienza con 50 DPU.
- El escalado automático está habilitado.

En este ejemplo, AWS Glue analiza la métrica “batchProcessingTimeInMs” de algunos microlotes y determina si los trabajos se están completando dentro del tamaño de ventana que ha establecido. Si sus trabajos se completan antes y en función de la rapidez con la que se terminen, es posible que AWS Glue se reduzca verticalmente. Esta métrica, trazada con “numberAllExecutors”, se puede supervisar en Amazon CloudWatch para ver cómo funciona el escalado automático.

El número de ejecutores se escala o reduce verticalmente de manera exponencial solo después de que se complete cada microlote. Como puede ver en el registro de supervisión de Amazon CloudWatch, AWS Glue analiza la cantidad de ejecutores necesarios (línea naranja) y escala los ejecutores (línea azul) para que coincidan automáticamente con esa cantidad.

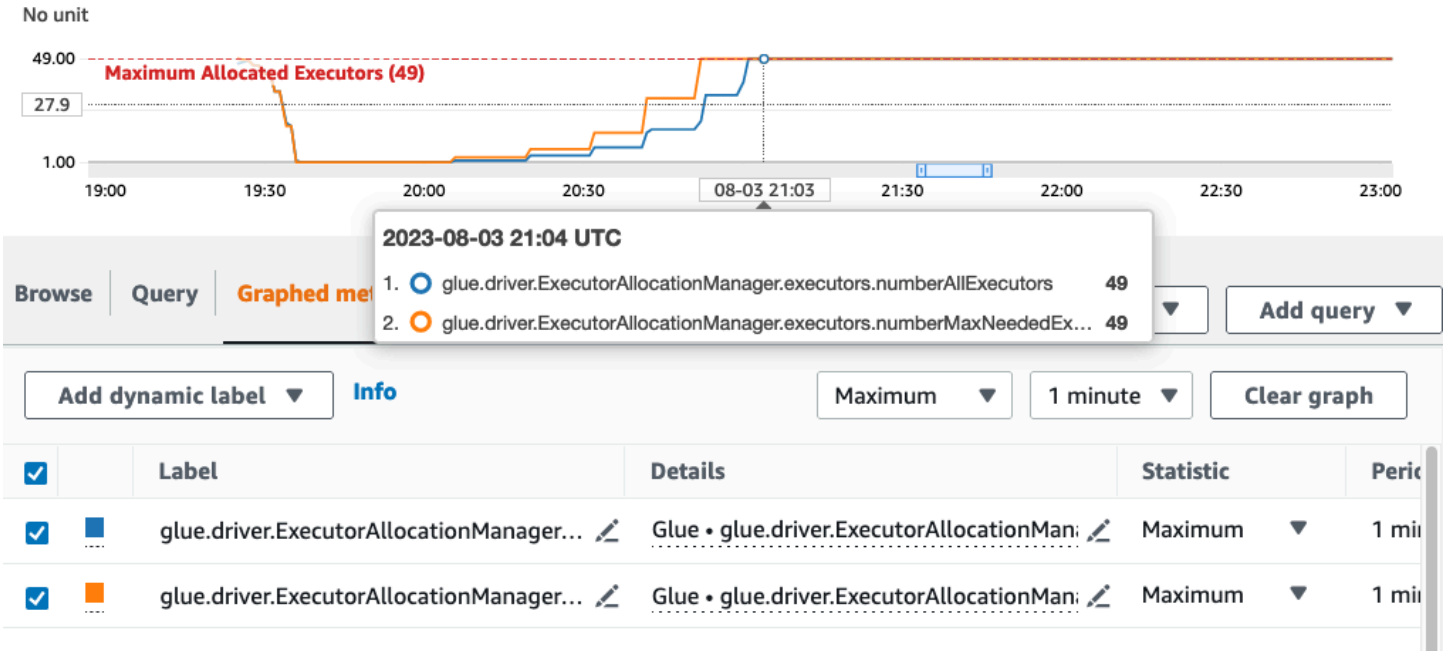

Una vez que AWS Glue reduzca verticalmente el número de ejecutores y observe que los volúmenes de datos aumentan y, en consecuencia, aumenta el tiempo de procesamiento de los microlotes, AWS Glue escalará verticalmente hasta los 50 DPU, que es el límite máximo especificado.

Escalado dentro de microlotes

En el ejemplo anterior, el sistema supervisa algunos microlotes completados para tomar una decisión acerca de si escalarlos o reducirlos verticalmente. Las ventanas más largas requieren un escalado automático para responder de manera más rápida dentro del microlote en vez de esperar unos pocos microlotes. En estos casos, puede usar la configuración adicional `--auto-scaIe-within-microbatch` como `true`. Puede agregarla a las propiedades del trabajo de AWS Glue en AWS Glue Studio como se muestra a continuación.

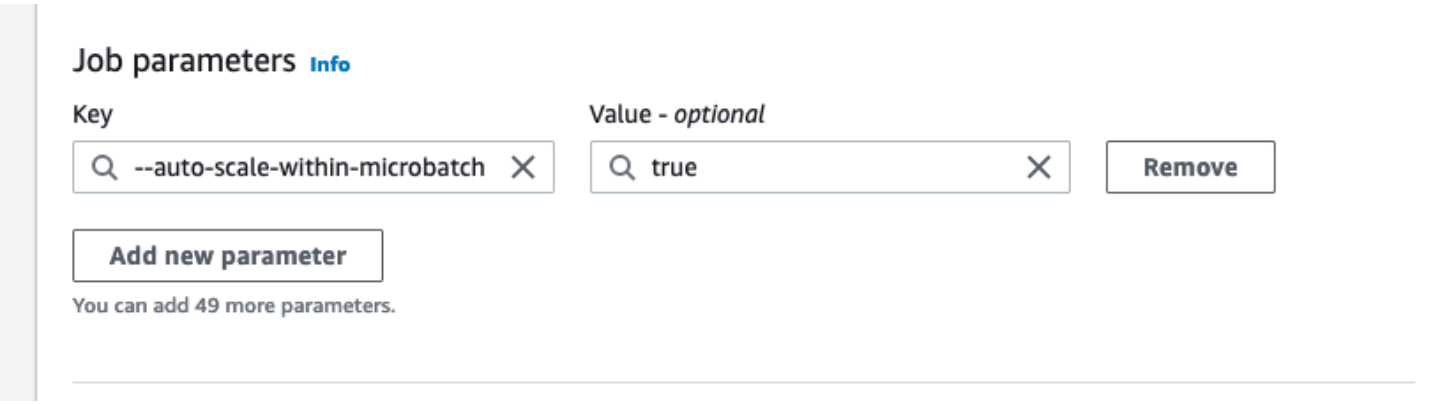

Ventanas de mantenimiento para AWS Glue Streaming

AWS Glue lleva a cabo actividades de mantenimiento de forma periódica. Durante estos períodos de mantenimiento, AWS Glue tendrá que reiniciar sus trabajos de streaming. Para controlar cuándo se reinician los trabajos, puede especificar los periodos de mantenimiento. En esta sección, explicamos dónde puede configurar el periodo de mantenimiento y los comportamientos específicos que debe tener en cuenta.

Temas

- Configuración de un periodo de mantenimiento
- Comportamiento del periodo de mantenimiento
- Supervisión de trabajos
- Gestión de la pérdida de datos

Configuración de un periodo de mantenimiento

Puede configurar un periodo de mantenimiento mediante AWS Glue Studio o las API.

Configuración de un periodo de mantenimiento en AWS Glue Studio

Puede especificar un periodo de mantenimiento en la página Detalles del trabajo de su trabajo de AWS Glue Streaming. Puede especificar el día y la hora en GMT. AWS Glue reiniciará el trabajo dentro del intervalo de tiempo especificado.

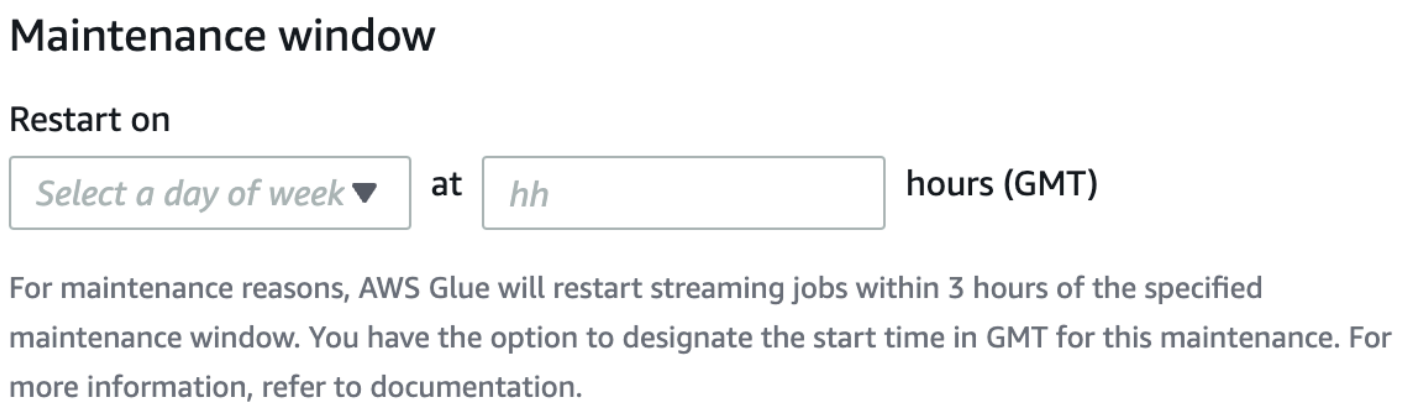

Configuración de un periodo de mantenimiento en la API

También puede configurar el periodo de mantenimiento en la API Create Job. A continuación, se muestra un ejemplo de configuración de un periodo de mantenimiento mediante la API.

```
aws glue create-job –name jobName –role roleArnForTheJob –command
 Name=gluestreaming,ScriptLocation=s3-path-to-the-script --maintenance-window="Sun:10"
```

Un ejemplo de comando es el siguiente:

```
aws glue create-job –name testMaintenance –role arn:aws:iam::012345678901:role/
Glue_DefaultRole –command Name=gluestreaming,ScriptLocation=s3://glue-example-test/
example.py –maintenance-window="Sun:10
```

Comportamiento del periodo de mantenimiento

AWS Glue sigue una serie de pasos para decidir cuándo reiniciar un trabajo:

1. Cuando se inicia un nuevo trabajo de streaming, AWS Glue comprueba primero si hay un tiempo de espera asociado a la ejecución del trabajo. Un tiempo de espera permite configurar la hora de finalización del trabajo. Si el tiempo de espera es inferior a 7 días, el trabajo no se reiniciará.
2. Si el tiempo de espera es superior a 7 días, AWS Glue comprueba si el periodo de mantenimiento está configurado para el trabajo. Si es así, se abre esa ventana y se asigna a la ejecución del trabajo. AWS Glue reiniciará el trabajo en un plazo de 3 horas a partir del periodo de mantenimiento especificado. Por ejemplo, si configura el período de mantenimiento para el lunes a las 10:00 h GMT, sus trabajos se reiniciarán entre las 10:00 h GMT y las 13:00 h GMT.

3. Si el periodo de mantenimiento no está configurado, AWS Glue establece automáticamente la hora de reinicio en 7 días después de la hora de inicio de la ejecución de la tarea. Por ejemplo, si inició el trabajo el 1 de julio de 2024 a las 12:00 h GMT y no especificó los periodos de mantenimiento, el trabajo se configurará para que se reinicie el 8 de julio de 2024 a las 12:00 h GMT.

> **Note**
>
> Si ya está efectuando tareas de streaming, este cambio le afectará a partir del 1 de julio de 2024. Tendrá tiempo hasta el 30 de junio para configurar sus periodos de mantenimiento. Después del 1 de julio, cualquier trabajo de streaming que inicie se reiniciará según esta documentación. Si necesita asistencia adicional, puede contactar con AWS Support.

4. A veces, es posible que AWS Glue no pueda reiniciar el trabajo, especialmente cuando el microlote en curso no se procesa. En estos casos, el trabajo no se interrumpirá. En estos casos, AWS Glue reiniciará el trabajo después de 14 días y, en este caso, no se respetará el periodo de mantenimiento.

Supervisión de trabajos

Puede supervisar los trabajos en la página Supervisión de AWS Glue Studio.

Para ver la hora prevista para el próximo reinicio de los trabajos de streaming, muestre la columna de la tabla Ejecuciones de trabajos en la página Supervisión.

1. Haga clic en el icono con forma de engranaje situado en la parte superior derecha de la tabla.

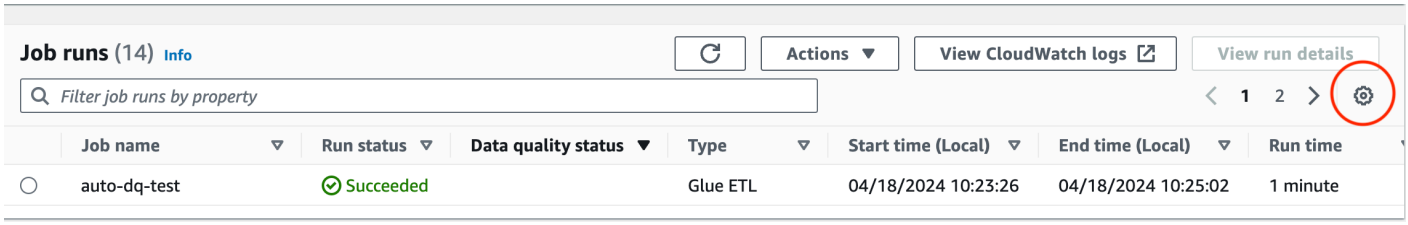

2. Desplácese hacia abajo y active la columna Hora de reinicio esperado. Están disponibles las opciones UTC y hora local.

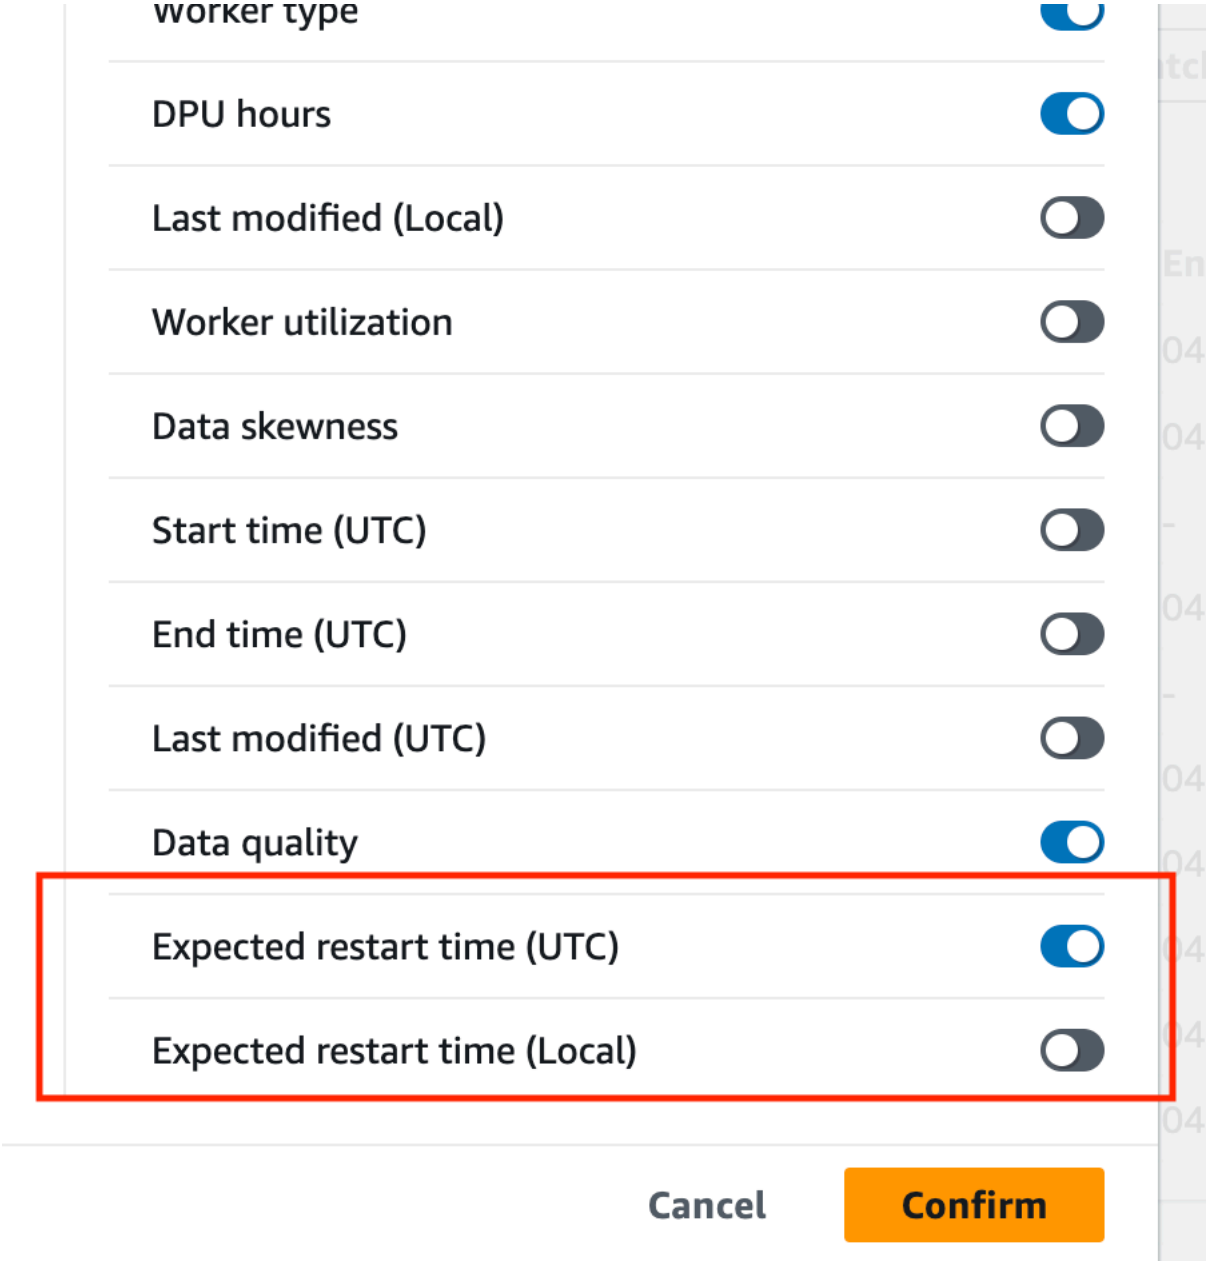

3. A continuación, puede ver las columnas de la tabla.

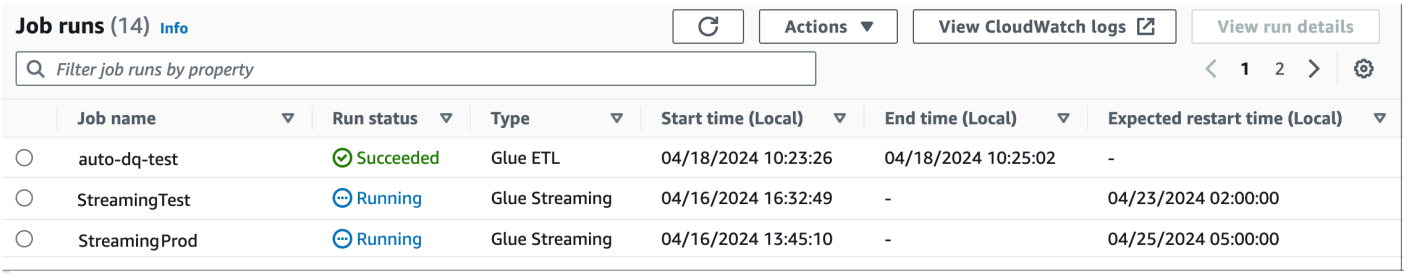

El trabajo original tendrá el estado “CADUCADO” y la nueva instancia de trabajo tendrá el estado “EN EJECUCIÓN”. La nueva ejecución del trabajo que se reinició tendrá un ID de ejecución de trabajo como una concatenación del ID de ejecución del trabajo inicial más el prefijo “restart_”, que representa el recuento de reinicios. Por ejemplo, si el ID de ejecución del trabajo inicial es `jr_1234`, la ejecución del trabajo reiniciada tendrá el ID `jr1234_restart_1` del primer reinicio. El segundo reinicio será `jr1234_restart_2` para el segundo reinicio y así sucesivamente.

El reintento no se verá afectado por los reinicios. Si se produce un error en una ejecución y se inicia una nueva debido a un reintento automático, el contador de reinicios volverá a empezar desde 1. Por ejemplo, si se produce un error en una ejecución en `jr_1234_attempt_3_restart_5`, al reintentarlo automáticamente, se iniciará una nueva ejecución con un identificador: `jr_id1_attempt_4` y, si este intento se reinicia transcurridos 7 días, se iniciará con el nuevo ID de ejecución `jr_id1_attempt_4_restart_1`.

Gestión de la pérdida de datos

Durante los reinicios por mantenimiento, AWS Glue Streaming sigue un proceso que garantiza la integridad y la coherencia de los datos entre la ejecución del trabajo anterior y la ejecución del trabajo reiniciado. Tenga en cuenta que AWS Glue no garantiza la integridad ni la coherencia de los datos entre los reinicios de los trabajos, por lo que recomendamos tener en cuenta la arquitectura para gestionar los datos duplicados en los trabajos de streaming.

1. Detección de las condiciones de reinicio por mantenimiento: AWS Glue Streaming supervisa las condiciones que indican cuándo debe activarse un reinicio por mantenimiento, por ejemplo, cuando se alcanza un periodo de mantenimiento después de 7 días o si es necesario reiniciar por completo después de 14 días.
2. Invocación de una finalización correcta: cuando se cumplen las condiciones de reinicio por mantenimiento, AWS Glue Streaming inicia un proceso de finalización correcta para la tarea que se está ejecutando actualmente. Este proceso incluye los siguientes pasos:
   a. Detención de la ingesta de nuevos datos: el trabajo de streaming deja de consumir nuevos datos de los orígenes de entrada (por ejemplo, temas de Kafka, transmisiones de Kinesis o archivos).
   b. Procesamiento de datos pendientes: el trabajo continúa procesando todos los datos que ya estén presentes en sus búferes o colas internos.
   c. Consignación de compensaciones y puntos de control: el trabajo envía las últimas compensaciones o puntos de control a sistemas externos (por ejemplo, Kafka, Kinesis o

Amazon S3) para garantizar que la tarea reiniciada pueda continuar desde el punto en el que la dejó el trabajo anterior.

3. Reinicio del trabajo: una vez finalizado el proceso de finalización correcto, AWS Glue Streaming reinicia el trabajo con el estado y los puntos de control conservados. El trabajo reiniciado retoma el procesamiento desde el último punto de control o compensación comprometido, lo que garantiza que no se pierdan ni dupliquen datos.
4. Reanudación del procesamiento de datos: el trabajo reiniciado reanuda el procesamiento de datos desde el punto en el que lo dejó el trabajo anterior. Continúa ingiriendo nuevos datos de los orígenes de entrada, a partir del último desfase o punto de control registrado, y procesa los datos de acuerdo con la lógica de ETL definida.

Conceptos avanzados de la transmisión de AWS Glue

En las aplicaciones contemporáneas basadas en datos, la importancia de los datos disminuye con el tiempo y su valor pasa de ser predictivo a reactivo. Como resultado, los clientes desean procesar los datos en tiempo real para tomar decisiones más rápidas. Cuando se trata de fuentes de datos en tiempo real, como las de los sensores de IoT, es posible que los datos lleguen desordenados o que se produzcan retrasos en el procesamiento debido a la latencia de la red y a otros fallos relacionados con el origen durante la ingesta. Como parte de la plataforma de AWS Glue, la transmisión de AWS Glue aprovecha estas capacidades para ofrecer ETL de transmisión escalable y sin servidor, con tecnología de transmisión estructurado de Apache Spark, que permite a los usuarios procesar datos en tiempo real.

En este tema, exploraremos los conceptos y capacidades avanzados de la transmisión de AWS Glue.

Consideraciones de tiempo a la hora de procesar los trabajos de transmisión

Al procesar los trabajos de transmisión, hay cuatro nociones de tiempo:

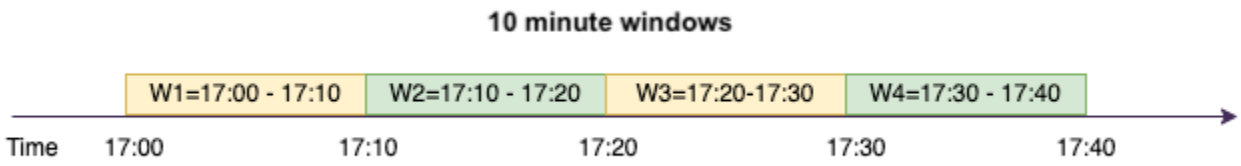

- Hora del evento: la marca temporal de cuando se produjo el evento. En la mayoría de los casos, este campo está incrustado en los propios datos del evento, en el origen.
- Ventana de tiempo de evento: el intervalo entre dos horas de un evento. Como se muestra en el diagrama anterior, W1 es una ventana de tiempo de evento que va desde las 17:00 h hasta las 17:10 h. Cada ventana de tiempo de evento es una agrupación de varios eventos.
- Hora de activación: la hora de activación controla la frecuencia con la que se procesan los datos y se actualizan los resultados. Este es el momento en que el procesamiento del microlote comenzó.
- Tiempo de ingesta: el momento en que los datos de transmisión se ingirieron en el servicio de transmisión. Si la hora del evento no está integrada en el propio evento, en algunos casos se puede usar como ventana.

Creación de ventanas

La creación de ventanas es una técnica en la que se agrupan y agregan varios eventos por ventana de tiempo de evento. En los siguientes ejemplos, analizaremos las ventajas de la creación de ventanas y cuándo usarla.

Según el caso de uso empresarial, Spark admite tres tipos de ventanas de tiempo.

- Ventana de saltos de tamaño constante: una serie de ventanas de tiempo de evento con tamaño fijo que no se superponen y que se agregan.
- Ventana deslizante: son similares a las ventanas de saltos de tamaño constante, ya que tienen un “tamaño fijo”, pero las ventanas pueden superponerse o deslizarse siempre que la duración del deslizamiento sea inferior a la duración de la propia ventana.
- Ventana de sesión: comienza con un evento de datos de entrada y continúa expandiéndose mientras reciba información dentro de un intervalo o periodo de inactividad. Una ventana de sesión puede tener un tamaño estático o dinámico igual a la longitud de la ventana, en función de las entradas.

Ventana de saltos de tamaño constante

La ventana de saltos de tamaño constante es una serie de ventanas de tiempo de evento con tamaño fijo que no se superponen y que se agregan. Vamos a entender esto con un ejemplo del mundo real.

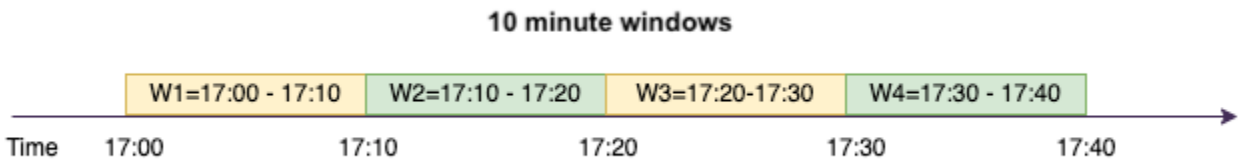

La empresa ABC Auto desea realizar una campaña de marketing para una nueva marca de coches deportivos. Quiere elegir una ciudad donde haya la mayor cantidad de fanáticos de los coches deportivos. Para lograr este objetivo, muestra un breve anuncio de 15 segundos que presenta el coche en su sitio web. Todos los “clics” y la “ciudad” correspondiente se graban y se transmiten a Amazon Kinesis Data Streams. Queremos contar el número de clics en un intervalo de 10 minutos y agruparlo por ciudad para ver qué ciudad tiene la mayor demanda. El siguiente valor es el resultado de la agregación.

window_start_time	window_end_time	ciudad	total_clicks
2023-07-10 17:00:00	2023-07-10 17:10:00	Dallas	75
2023-07-10 17:00:00	2023-07-10 17:10:00	Chicago	10
2023-07-10 17:20:00	2023-07-10 17:30:00	Dallas	20
2023-07-10 17:20:00	2023-07-10 17:30:00	Chicago	50

Como se explicó anteriormente, estas ventanas de tiempo de evento son diferentes de los intervalos de tiempo de activación. Por ejemplo, aunque el tiempo de activación sea cada minuto, los resultados de la salida solo mostrarán ventanas de agregación de 10 minutos que no se superponen. Para la optimización, es mejor alinear el intervalo de activación con la ventana de tiempo de evento.

En la tabla anterior, Dallas registró 75 clics en la ventana de 17:00 h a 17:10 h, mientras que Chicago tuvo 10 clics. Además, no hay datos para la ventana de 17:10 h a 17:20 h de ninguna ciudad, por lo que se omite esta ventana.

Ahora puede realizar un análisis más detallado de estos datos en la aplicación de análisis posterior para determinar cuál es la mejor ciudad para llevar a cabo la campaña de marketing.

Uso de ventanas de saltos de tamaño constante en AWS Glue

1. Cree un DataFrame de Amazon Kinesis Data Streams y léalo. Ejemplo:

```
parsed_df = kinesis_raw_df \
                .selectExpr('CAST(data AS STRING)') \
                .select(from_json("data", ticker_schema).alias("data")) \
                .select('data.event_time','data.ticker','data.trade','data.volume',
 'data.price')
```

2. Procese los datos en una ventana de saltos de tamaño constante. En el siguiente ejemplo, los datos se agrupan en función del campo de entrada “event_time” en ventanas de tamaño constante de 10 minutos y escriben la salida en un lago de datos de Amazon S3.

```
grouped_df = parsed_df \
                .groupBy(window("event_time", "10 minutes"), "city") \
                .agg(sum("clicks").alias("total_clicks"))

summary_df = grouped_df \
                .withColumn("window_start_time", col("window.start")) \
                .withColumn("window_end_time", col("window.end")) \
                .withColumn("year", year("window_start_time")) \
                .withColumn("month", month("window_start_time")) \
                .withColumn("day", dayofmonth("window_start_time")) \
                .withColumn("hour", hour("window_start_time")) \
                .withColumn("minute", minute("window_start_time")) \
                .drop("window")

write_result = summary_df \
                .writeStream \
                .format("parquet") \
                .trigger(processingTime="10 seconds") \
                .option("checkpointLocation", "s3a://bucket-stock-stream/stock-
stream-catalog-job/checkpoint/") \
                .option("path", "s3a://bucket-stock-stream/stock-stream-catalog-
job/summary_output/") \
                .partitionBy("year", "month", "day") \
                .start()
```

Ventana deslizante

Las ventanas deslizantes son similares a las de saltos de tamaño constante, ya que tienen un "tamaño fijo", pero las ventanas pueden superponerse o deslizarse siempre que la duración del deslizamiento sea menor que la duración de la propia ventana. Debido a la naturaleza del deslizamiento, una entrada se puede vincular a varias ventanas.

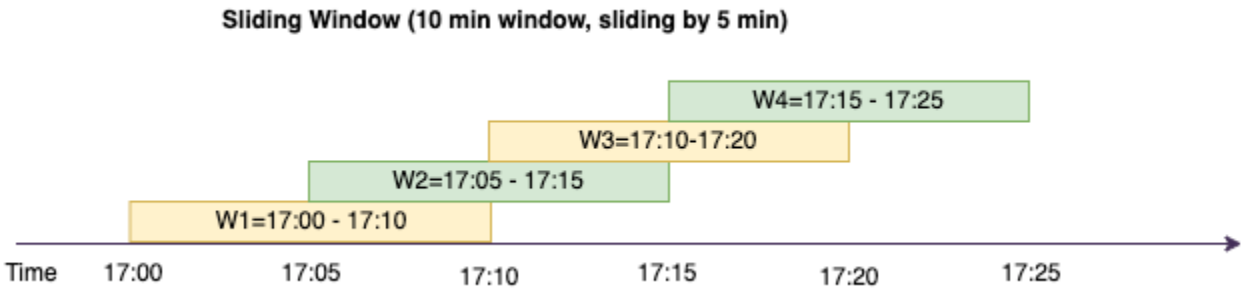

Para entenderlo mejor, consideremos el ejemplo de un banco que quiere detectar posibles fraudes con tarjetas de crédito. Una aplicación de transmisión podría supervisar un flujo continuo de transacciones con tarjetas de crédito. Estas transacciones podrían agruparse en ventanas de 10 minutos de duración y, cada 5 minutos, la ventana se deslizaría hacia adelante, eliminando los 5 minutos de datos más antiguos y agregando los últimos 5 minutos de datos nuevos. Dentro de cada ventana, las transacciones podrían agruparse por país para detectar patrones sospechosos, como una transacción en EE. UU. seguida inmediatamente de otra en Australia. Para simplificar, clasificaremos estas transacciones como fraude cuando el importe total de las transacciones sea superior a 100 USD. Si se detecta un patrón de este tipo, es señal de un posible fraude y la tarjeta puede congelarse.

El sistema de procesamiento de tarjetas de crédito envía una serie de transacciones a Kinesis para cada identificador de tarjeta junto con el país. Un trabajo de AWS Glue ejecuta el análisis y produce el siguiente resultado agregado.

window_start_time	window_end_time	card_last_four	país	total_amount
2023-07-10 17:00:00	2023-07-10 17:10:00	6544	EE. UU.	85
2023-07-10 17:00:00	2023-07-10 17:10:00	6544	Australia	10

window_start_time	window_end_time	card_last_four	país	total_amount
2023-07-10 17:05:45	2023-07-10 17:15:45	6544	EE. UU.	50
2023-07-10 17:10:45	2023-07-10 17:20:45	6544	EE. UU.	50
2023-07-10 17:10:45	2023-07-10 17:20:45	6544	Australia	150

Según la agregación anterior, puede ver que el intervalo de 10 minutos se desliza cada 5 minutos, sumado por el importe de la transacción. La anomalía se detecta en el intervalo de 17:10 h a 17:20 h, donde hay un valor atípico, es decir, una transacción de 150 USD en Australia. AWS Glue puede detectar esta anomalía y activar un evento de alarma con la clave infractora en un tema de SNS mediante boto3. Además, una función de Lambda puede suscribirse a este tema y tomar medidas.

Datos de proceso en una ventana deslizante

La cláusula `group-by` y la función de ventana se usan para implementar la ventana deslizante, como se muestra a continuación.

```
grouped_df = parsed_df \
            .groupBy(window(col("event_time"), "10 minute", "5 min"), "country",
 "card_last_four") \
            .agg(sum("tx_amount").alias("total_amount"))
```

Ventana de sesión

A diferencia de las dos ventanas anteriores, que tienen un tamaño fijo, la ventana de sesión puede tener un tamaño estático o dinámico de la longitud de la ventana, según las entradas. Una ventana de sesión comienza con un evento de datos de entrada y continúa expandiéndose mientras reciba información dentro de un intervalo o periodo de inactividad.

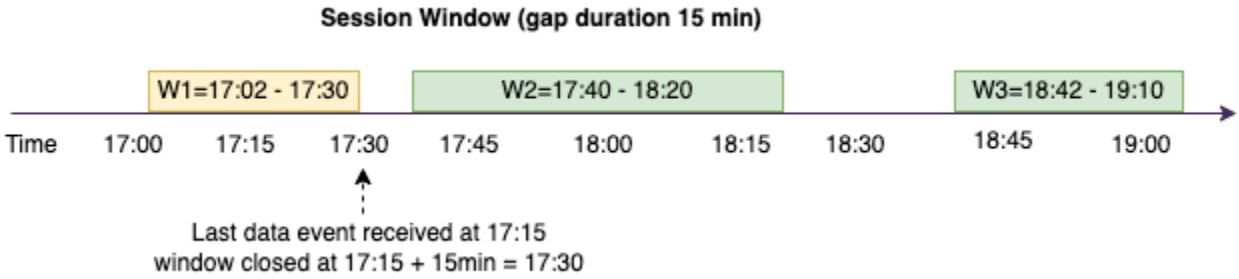

Tomemos un ejemplo. La empresa ABC Hotel quiere saber cuál es el momento más concurrido de la semana y ofrecer mejores ofertas a sus huéspedes. En cuanto un huésped se registra, se abre una ventana de sesión y Spark mantiene un estado de agregación para esa ventana de tiempo de evento. Cada vez que un invitado se registra, se genera un evento y se envía a Amazon Kinesis Data Streams. El hotel decide que, si no se hacen registros de entrada durante un periodo de 15 minutos, se puede cerrar la ventana de tiempo de evento. La siguiente ventana de tiempo de evento volverá a comenzar cuando haya un nuevo registro. El resultado es el siguiente.

window_start_time	window_end_time	ciudad	total_checkins
2023-07-10 17:02:00	2023-07-10 17:30:00	Dallas	50
2023-07-10 17:02:00	2023-07-10 17:30:00	Chicago	25
2023-07-10 17:40:00	2023-07-10 18:20:00	Dallas	75
2023-07-10 18:50:45	2023-07-10 19:15:45	Dallas	20

El primer registro se produjo con event_time a las 17:02 h. La ventana de tiempo del evento de agregación comenzará a las 17:02 h. Esta agregación continuará mientras recibamos los eventos dentro de los 15 minutos de duración. En el ejemplo anterior, el último evento que recibimos fue a las 17:15 h y, durante los siguientes 15 minutos, no hubo ningún evento. Como resultado, Spark cerró la ventana de tiempo del evento a las 17:15 h, más 15 minutos = 17:30 h, y la estableció entre las 17:02 h y las 17:30 h. Comenzó una nueva ventana de tiempo de evento a las 17:47 h cuando recibió un nuevo evento con los datos de registro.

Datos de proceso en una ventana de sesión

La cláusula `group-by` y la función de ventana se usan para implementar la ventana deslizante.

```
grouped_df = parsed_df \
            .groupBy(session_window(col("event_time"), "10 minute"), "city") \
            .agg(count("check_in").alias("total_checkins"))
```

Modos de salida

El modo de salida es el modo en el que los resultados de la tabla ilimitada se escriben en el receptor externo. Hay tres modos disponibles. En el siguiente ejemplo, contamos las apariciones de una palabra a medida que se transmiten y se procesan líneas de datos en cada microlote.

- Modo completo: toda la tabla de resultados se escribirá en el receptor después de cada procesamiento por microlotes, aunque el recuento de palabras no se haya actualizado en la ventana de tiempo del evento actual.
- Modo de adición: este es el modo predeterminado, en el que solo se escribirán en el receptor las palabras o filas nuevas que se hayan agregado a la tabla de resultados desde la última activación. Este modo es adecuado para la transmisión sin estado de consultas como map, flatMap, filter, etc.
- Modo de actualización: solo se escribirán en el receptor las palabras o filas de la tabla de resultados que se hayan actualizado o agregado desde la última activación.

> **Note**
>
> Modo de salida = las ventanas de sesión no admiten la opción de actualización.

Manejo de datos tardíos y marcas de agua

Cuando se trabaja con datos en tiempo real, es posible que se produzcan retrasos en la llegada de los datos debido a la latencia de la red y a fallos en las fases iniciales, por lo que necesitamos un mecanismo para volver a realizar la agregación en la ventana de tiempo de evento omitida. Sin embargo, para ello, es necesario mantener el estado. Al mismo tiempo, es necesario limpiar los datos más antiguos para limitar el tamaño del estado. En la versión 2.1 de Spark se agregó compatibilidad con una característica llamada “marca de agua” que mantiene el estado y permite al usuario especificar el umbral para los datos tardíos.

Con referencia al ejemplo anterior acerca de la cotización bursátil, consideremos que el límite permitido para los datos tardíos es de no más de 10 minutos. Para simplificar las cosas,

supondremos que es una ventana de saltos de tamaño constante, que la cotización es AMZ y que la operación es BUY.

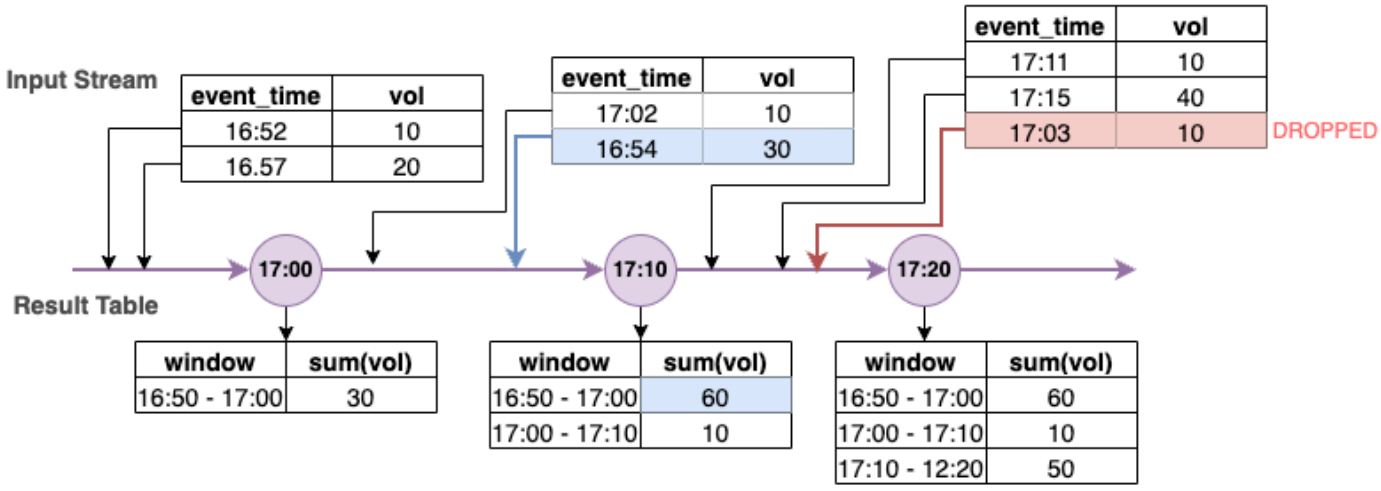

En el diagrama anterior, calculamos el volumen total en una ventana de saltos de tamaño constante de 10 minutos. Tenemos la activación a las 17:00 h, a las 17:10 h y a las 17:20 h. Sobre la flecha de la línea temporal, tenemos el flujo de datos de entrada y debajo está la tabla de resultados ilimitada.

En la primera ventana de saltos de tamaño constante de 10 minutos, agregamos en función de event_time, y total_volume se calculó como 30. En la segunda ventana de tiempo de evento, Spark obtuvo el primer evento de datos con event_time a las 17:02 h. Como este es el tiempo máximo de evento registrado hasta ahora por Spark, el umbral de la marca de agua se ha establecido 10 minutos antes (es decir, watermark_event_time es 16:52 h). Cualquier evento de datos con event_time posterior a las 16:52 h se tendrá en cuenta para la agregación con un límite de tiempo y cualquier evento de datos anterior a esa fecha se descartará. Esto permite a Spark mantener un estado intermedio durante 10 minutos adicionales para adaptarse a los datos tardíos. Alrededor de las 17:08 h, Spark recibió un evento con event_time a las 16:54 h, lo cual estaba dentro del umbral. Por lo tanto, Spark recalculó la ventana de tiempo de evento entre las 16:50 h y las 17:00 h, y el volumen total pasó de 30 a 60.

Sin embargo, en la hora de activación de las 17:20 h, cuando Spark recibió un evento con event_time a las 17:15 h, se estableció watermark_event_time a las 17:05 h. Por lo tanto, el evento de datos tardío con event_time a las 17:03 h se consideró “demasiado tarde” y se ignoró.

```
Watermark Boundary = Max(Event Time) - Watermark Threshold
```

Uso de marcas de agua en AWS Glue

Spark no emitirá ni escribirá los datos en el receptor externo hasta que se supere el límite de la marca de agua. Para implementar una marca de agua en AWS Glue, consulte el siguiente ejemplo.

```
grouped_df = parsed_df \
                .withWatermark("event_time", "10 minutes") \
                .groupBy(window("event_time", "5 minutes"), "ticker") \
                .agg(sum("volume").alias("total_volume"))
```

Acerca de la supervisión de los trabajos de AWS Glue Streaming

Supervisar el trabajo de transmisión es una parte fundamental de la creación de su canalización de ETL. Además de usar la interfaz de usuario de Spark, también puede usar Amazon CloudWatch para supervisar las métricas. A continuación se muestra una lista de las métricas de transmisión que emite el marco de AWS Glue. Para obtener una lista completa de todas las métricas de AWS Glue, consulte Supervisión de AWS Glue mediante métricas de Amazon CloudWatch.

AWS Glue usa un marco de transmisión estructurado para procesar los eventos de entrada. Puede usar la API de Spark directamente en el código o aprovechar `ForEachBatch` que proporciona `GlueContext`, que publica estas métricas. Para entender estas métricas, primero debemos entender `windowSize`.

windowSize: `windowSize` es el intervalo de microlotes que usted proporciona. Si especifica un tamaño de ventana de 60 segundos, el trabajo de transmisión de AWS Glue esperará 60 segundos (o más si el lote anterior no se ha completado para entonces) antes de leer los datos de un lote procedentes del origen de transmisión y aplicar las transformaciones incluidas en `ForEachBatch`. Esto también se denomina intervalo de activación.

Revisemos las métricas con más detalle para comprender las características de estado y rendimiento.

> **Note**
>
> Estas métricas se emiten cada 30 segundos. Si `windowSize` tiene menos de 30 segundos, las métricas informadas son una agregación. Por ejemplo, supongamos que `windowSize` tiene 10 segundos y que está procesando 20 registros de forma constante por microlote. En este escenario, el valor métrico emitido de numRecords sería 60.

No se emite una métrica si no hay datos disponibles para ella. Además, en el caso de la métrica de retraso de consumo, debe habilitar la característica para obtener las métricas correspondientes.

Visualización de métricas de AWS Glue Streaming

Para trazar métricas visuales:

1. Vaya a Métricas en la consola de Amazon CloudWatch y, a continuación, seleccione la pestaña Examinar. Luego elija Glue en “Espacios de nombres personalizados”.

2. Seleccione Métricas de trabajo para ver las métricas de todos sus trabajos.
3. Filtre las métricas en función de JobName=glue-feb-monitoring y, a continuación, JobRunId=ALL. Puede hacer clic en el signo “+”, como se muestra en la siguiente figura, para agregarlo al filtro de búsqueda.
4. Seleccione la casilla de verificación de las métricas que le interesen. En la siguiente figura, hemos seleccionado `numberAllExecutors` y `numberMaxNeededExecutors`.

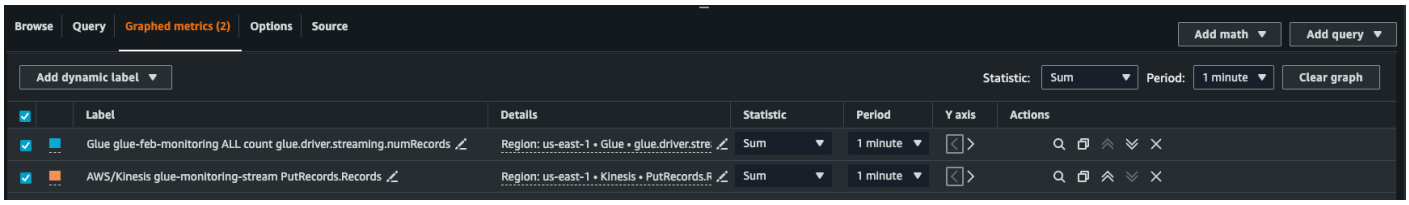

5. Una vez que haya seleccionado estas métricas, puede ir a la pestaña Métricas diagramadas y aplicarlas.
6. Como las métricas se emiten cada minuto, puede aplicar el “promedio” a lo largo de un minuto para obtener `batchProcessingTimeInMs` y `maxConsumerLagInMs`. Para `numRecords`, puede aplicar la “suma” a cada minuto.
7. Puede agegar una anotación horizontal de `windowSize` a su gráfico mediante la pestaña Opciones.

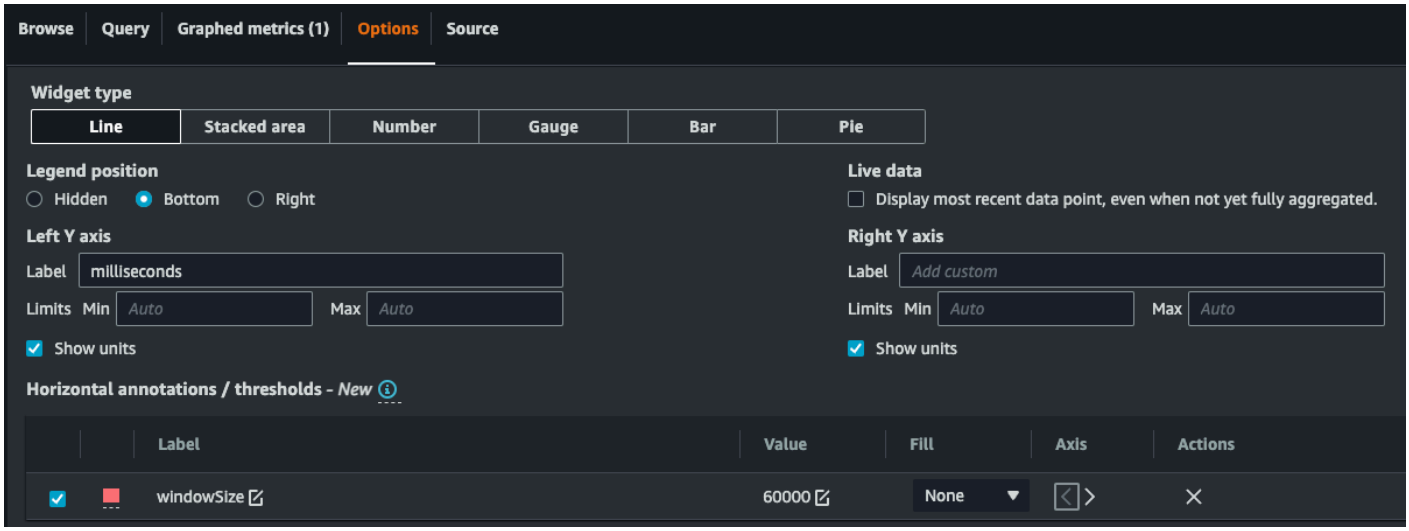

8. Una vez que haya seleccionado las métricas, cree un panel y agréguelo. A continuación, se ofrece un panel de ejemplo.

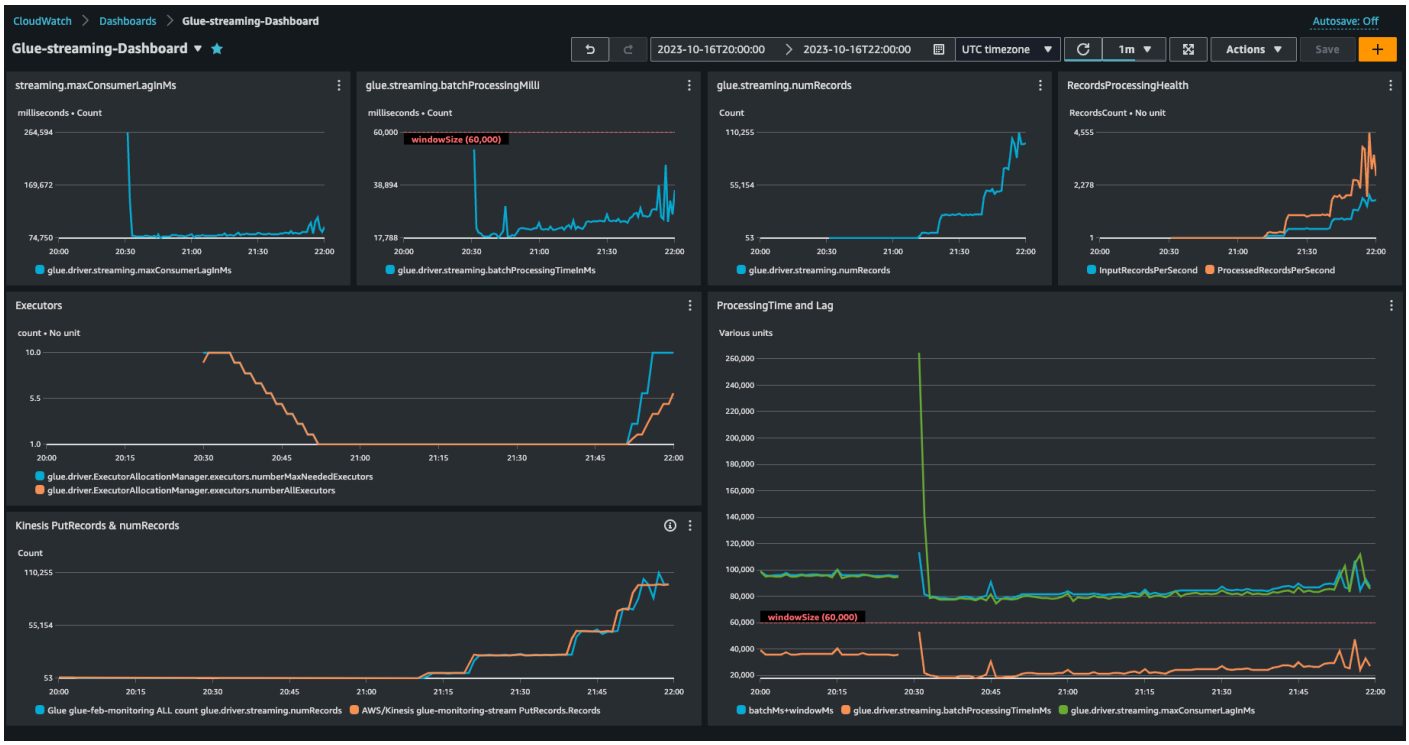

Uso de métricas de AWS Glue Streaming

En esta sección, se describe cada una de las métricas y cómo se relacionan entre sí.

Número de registros (métrica: streaming.numRecords)

Esta métrica indica cuántos registros se están procesando.

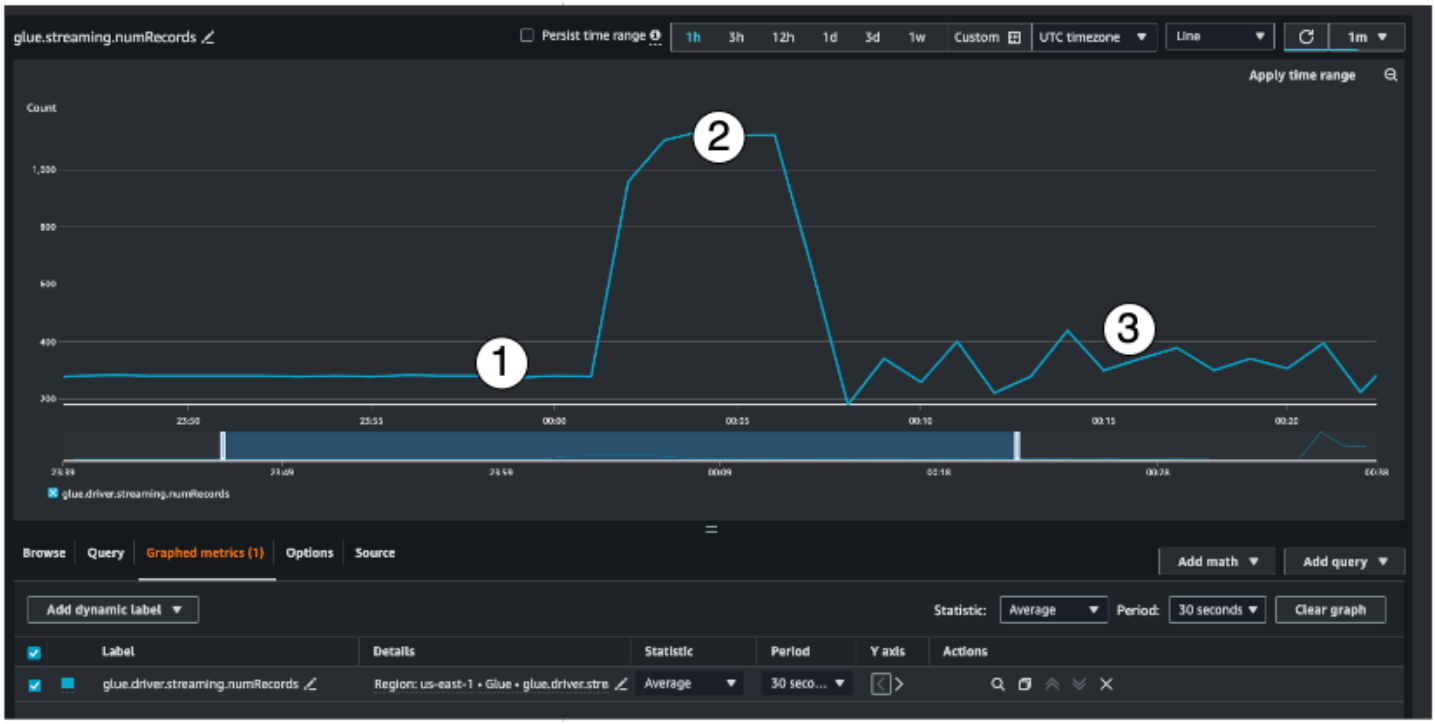

Esta métrica de transmisión proporciona la visibilidad del número de registros que se están procesando en una ventana. Además de la cantidad de registros que se están procesando, también lo ayudará a comprender el comportamiento del tráfico de entrada.

- El indicador n.º 1 es un ejemplo de un tráfico estable sin ráfagas. Por lo general, se trata de aplicaciones como los sensores de IoT que recopilan datos en intervalos regulares y los envían al origen de transmisión.
- El indicador n.º 2 es un ejemplo de una ráfaga repentina de tráfico en una carga que, por lo demás, es estable. Esto podría ocurrir en una aplicación de secuencias de clics cuando se lleva a cabo un evento de marketing, como el Black Friday, y se produce un aumento en el número de clics.
- El indicador n.º 3 es un ejemplo de tráfico impredecible. El tráfico impredecible no significa que hay un problema. Es simplemente la naturaleza de los datos de entrada. Volviendo al ejemplo de los sensores de IoT, puede pensar en cientos de sensores que envían eventos de cambio climático al origen de transmisión. Como el cambio climático no es predecible, tampoco lo son los datos. Comprender el patrón de tráfico es clave para ajustar el tamaño de los ejecutores. Si la entrada tiene muchos picos, puede considerar usar el escalado automático (hablaremos de esto más adelante).

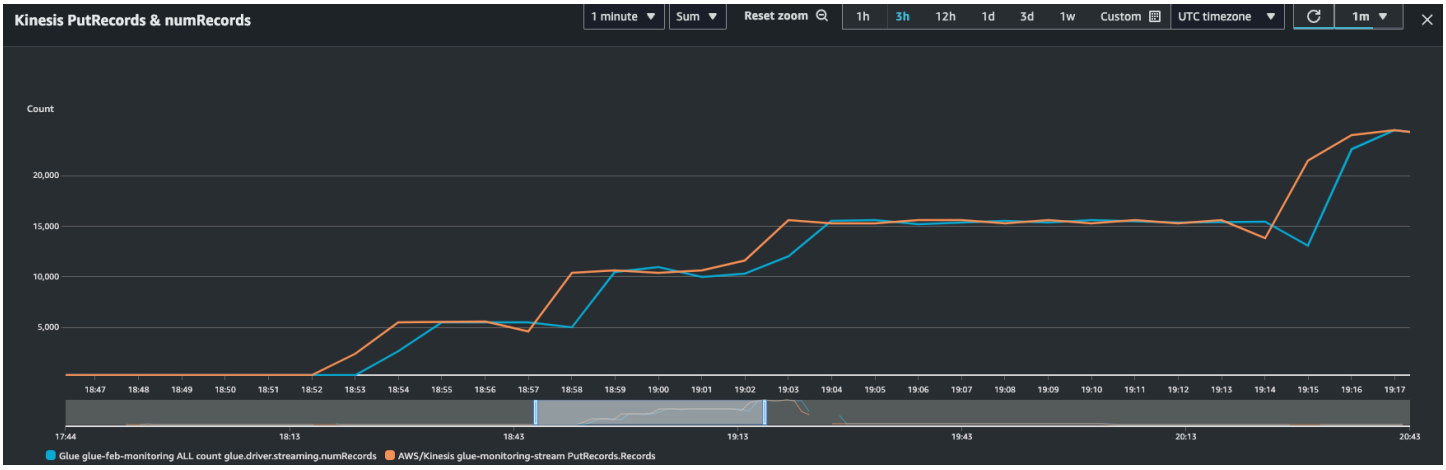

Puede combinar esta métrica con la métrica PutRecords de Kinesis para asegurarse de que el número de eventos que se ingiere y el número de registros que se leen son prácticamente iguales. Esto es útil en especial cuando se trata de entender el retraso. A medida que aumenta la tasa de ingesta, también lo hace la lectura de `numRecords` por parte de AWS Glue.

Tiempo de procesamiento por lotes (métrica: streaming.batchProcessingTimeInMs)

La métrica del tiempo de procesamiento por lotes lo ayuda a determinar si el clúster está infra o sobreaprovisionado.

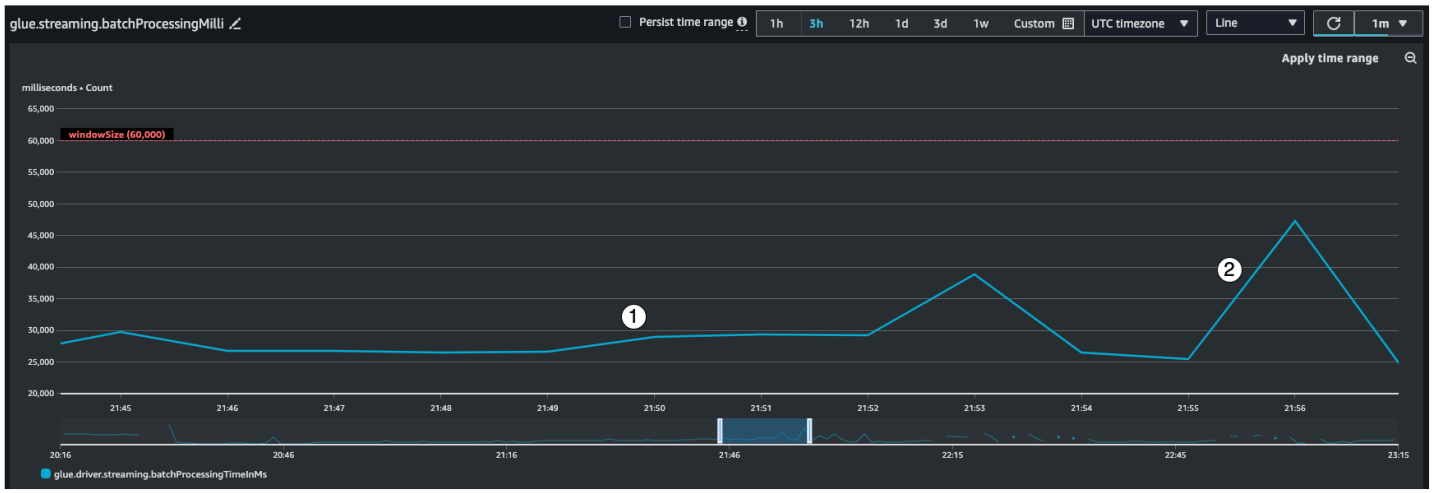

Esta métrica indica el número de milisegundos que se tardó en procesar cada microlote de registros. El objetivo principal aquí es supervisar este tiempo para asegurarse de que sea inferior al intervalo de `windowSize`. No hay problema si `batchProcessingTimeInMs` se suspende temporalmente, siempre y cuando se recupere en el siguiente intervalo. El indicador n.º 1 representa un tiempo más o menos estable que se tarda en procesar el trabajo. Sin embargo, si el número de registros de entrada aumenta, el tiempo necesario para procesar el trabajo aumentará, tal como se muestra en

el indicador n.º 2. Si `numRecords` no aumenta, pero el tiempo de procesamiento sí, entonces tendrá que analizar más a fondo el procesamiento de los trabajos en los ejecutores. Es una buena práctica establecer un umbral y una alarma para garantizar que `batchProcessingTimeInMs` no supere el 120 % durante más de 10 minutos. Para obtener más información acerca de la configuración de alarmas, consulte Uso de alarmas de Amazon CloudWatch.

Retraso de consumo (métrica: streaming.maxConsumerLagInMs)

La métrica de retraso de consumo lo ayuda a comprender si hay un retraso en el procesamiento de los eventos. Si el retraso es demasiado alto, es posible que no cumpla con el SLA de procesamiento del que depende su empresa, aunque tenga un windowSize correcto. Tiene que habilitar estas métricas de forma explícita mediante la opción de conexión de `emitConsumerLagMetrics`. Para obtener más información, consulte KinesisStreamingSourceOptions.

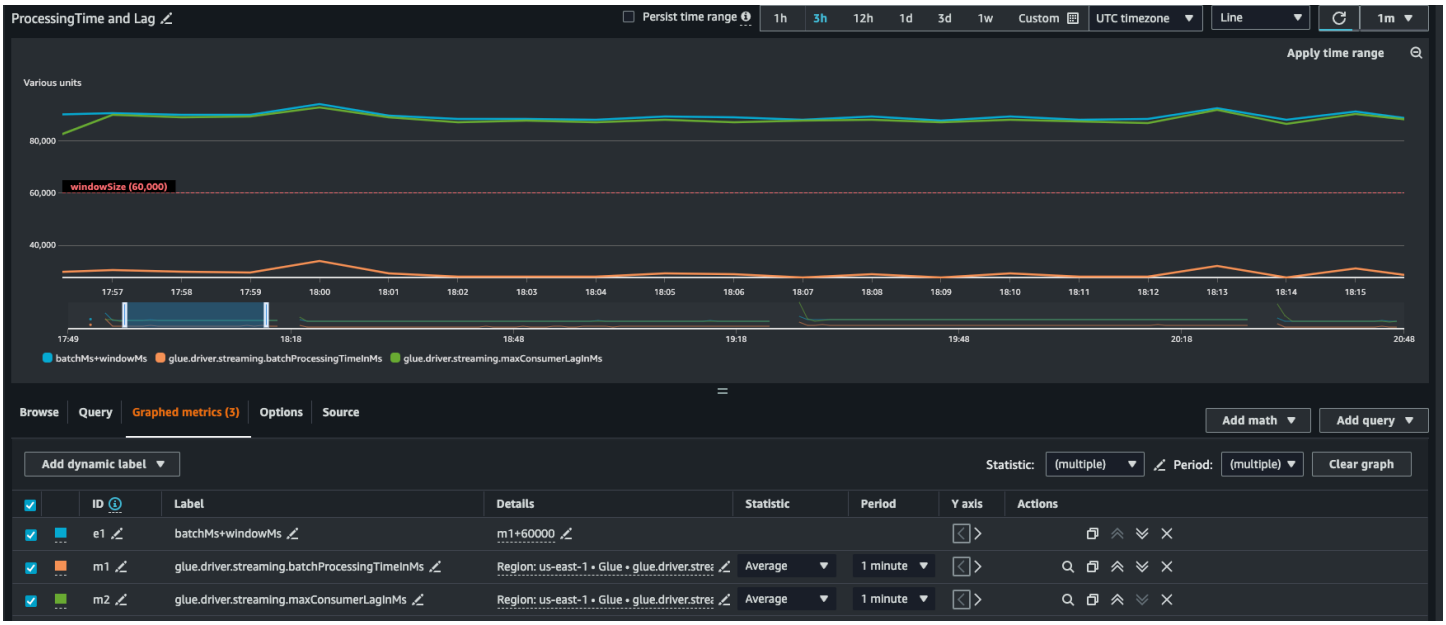

Métricas derivadas

Para obtener información más detallada, puede crear métricas derivadas para comprender mejor sus trabajos de transmisión en Amazon CloudWatch.

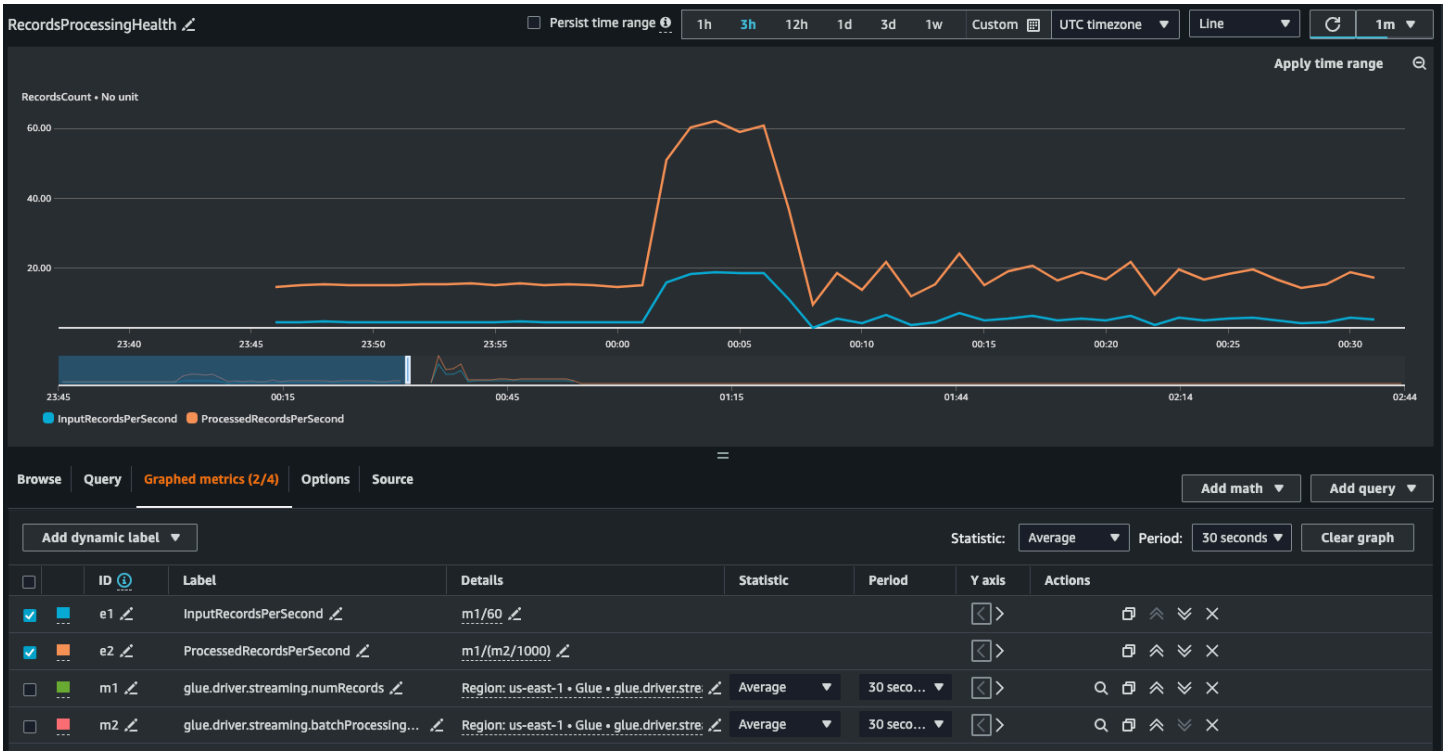

Puede crear un gráfico con métricas derivadas para decidir si necesita usar más DPU. Si bien el escalado automático lo ayuda a hacerlo automáticamente, puede usar métricas derivadas para determinar si el escalado automático funciona de manera eficaz.

- InputRecordsPerSecond indica la velocidad a la que se obtienen los registros de entrada. Se deriva de la siguiente manera: número de registros de entrada (glue.driver.streaming.numRecords)/ WindowSize.
- ProcessingRecordsPerSecond indica la velocidad a la que se procesan los registros. Se deriva de la siguiente manera: número de registros de entrada (glue.driver.streaming.numRecords)/ batchProcessingTimeInMs.

Si la velocidad de entrada es superior a la velocidad de procesamiento, es posible que necesite agregar más capacidad para procesar el trabajo o aumentar el paralelismo.

Métricas de escalado automático

Si el tráfico de entrada tiene picos, debería considerar la posibilidad de habilitar el escalado automático y especificar el número máximo de trabajos. Con eso, obtiene dos métricas adicionales: `numberAllExecutors` y `numberMaxNeededExecutors`.

- numberAllExecutors es el número de ejecutores de trabajo que se ejecutan activamente.

- numberMaxNeededExecutors es el número máximo de ejecutores de trabajos (en ejecución activa y pendientes) necesarios para satisfacer la carga actual.

Estas dos métricas lo ayudarán a entender si el escalado automático funciona correctamente.

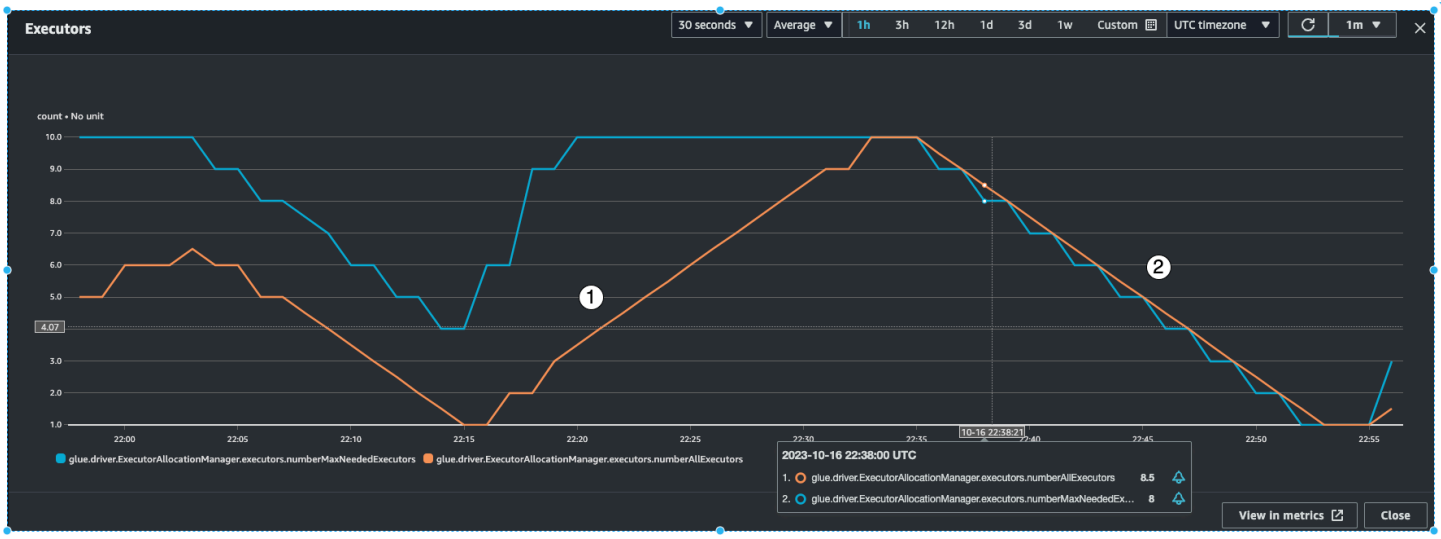

AWS Glue supervisará la métrica `batchProcessingTimeInMs` en unos pocos microlotes y hará una de las siguientes dos cosas: Si `batchProcessingTimeInMs` está más cerca de `windowSize`, escalará horizontalmente los ejecutores; si `batchProcessingTimeInMs` es inferior a `windowSize`, reducirá horizontalmente los ejecutores. Además, usará un algoritmo para escalar de forma escalonada los ejecutores.

- El indicador n.º 1 representa cómo los ejecutores activos se escalaron verticalmente a fin de alcanzar el máximo número de ejecutores necesarios para procesar la carga.
- El indicador n.º 2 representa cómo se redujeron horizontalmente los ejecutores activos debido a que `batchProcessingTimeInMs` era inferior.

Puede usar estas métricas para supervisar el paralelismo actual a nivel de ejecutor y ajustar el número máximo de trabajos en la configuración de escalado automático en consecuencia.

Cómo obtener el mejor rendimiento

Spark intentará crear una tarea por fragmento para poder leerla en el flujo de Amazon Kinesis. Los datos de cada fragmento se convierten en una partición. Luego, distribuirá estas tareas entre los ejecutores o trabajos, en función del número de núcleos de cada trabajo (el número de núcleos por trabajo depende del tipo de trabajo que seleccione, como `G.025X`, `G.1X`, etc.). Sin embargo, la

forma en que se distribuyen las tareas no es determinista. Todas las tareas se ejecutan en paralelo en sus respectivos núcleos. Si hay más fragmentos que el número de núcleos ejecutores disponibles, las tareas se ponen en cola.

Puede usar una combinación de las métricas anteriores y el número de fragmentos para aprovisionar los ejecutores a fin de garantizar una carga estable con espacio para las ráfagas. Se recomienda realizar algunas iteraciones del trabajo para determinar el número aproximado de trabajos. Para una carga de trabajo inestable o con picos, puede hacer lo mismo al configurar el escalado automático y el número máximo de trabajos.

Configure `windowSize` de acuerdo con los requisitos de SLA de su empresa. Por ejemplo, si su empresa exige que los datos procesados no puedan estar inactivos durante más de 120 segundos, configure `windowSize` en al menos 60 segundos, de forma que el retraso promedio de consumo sea inferior a 120 segundos (consulte la sección anterior acerca del retraso de consumo). A partir de ahí, en función de `numRecords` y del número de fragmentos, planifique la capacidad de las DPU asegurándose de que `batchProcessingTimeInMs` sea inferior al 70 % de `windowSize` la mayor parte del tiempo.

> **Note**
>
> Los fragmentos activos pueden distorsionar los datos, lo que significa que algunos fragmentos o particiones son mucho más grandes que otros. Esto puede provocar que algunas tareas que se ejecutan en paralelo tarden más tiempo, lo que genera que las tareas queden rezagadas. Como resultado, el siguiente lote no puede comenzar hasta que se hayan completado todas las tareas del anterior, lo que afectará `batchProcessingTimeInMillis` y el retraso máximo.

Integraciones sin ETL

Sin ETL es un conjunto de integraciones totalmente administrado por AWS y que minimiza la necesidad de crear canalizaciones de datos de ETL para casos de uso comunes de ingesta y replicación. Hace que los datos de Amazon SageMaker Lakehouse y Amazon Redshift estén disponibles desde varios orígenes operativos, transaccionales y de aplicaciones. Con la integración sin ETL, dispondrá de datos más actualizados para el análisis, la inteligencia artificial y el aprendizaje automático y la elaboración de informes. Obtendrá información más precisa y oportuna para casos de uso, como paneles empresariales, una experiencia de juego optimizada, la supervisión de la calidad de los datos y el análisis del comportamiento de los clientes. Puede hacer predicciones basadas en datos con más confianza, mejorar las experiencias de los clientes y promover información basada en datos en toda la empresa.

Amazon RedShift es un servicio de almacenamiento de datos de escala de petabyte rápido, totalmente administrado, que hace que sea simple y rentable analizar de manera eficiente todos sus datos utilizando sus herramientas de inteligencia empresariales existentes.

Amazon SageMaker Lakehouse unifica todos sus datos entre los lagos de datos de Amazon Simple Storage Service (S3) y los almacenes de datos de Amazon Redshift, lo que le permite crear potentes aplicaciones de análisis e IA/ML en una sola copia de datos. SageMaker Lakehouse le ofrece la flexibilidad de acceder a sus datos y consultarlos in situ gracias a todas las herramientas y motores compatibles con Apache Iceberg. Con SageMaker Lakehouse, también tiene la flexibilidad de acceder a sus datos y consultarlos in situ gracias a las herramientas y motores compatibles con Apache Iceberg. Además, puede proteger sus datos con controles de acceso integrados y detallados, que se aplican a todos sus datos en todas las herramientas y motores de análisis. Defina los permisos una única vez y comparta los datos con confianza en toda su organización.

Capacidades sin ETL en AWS Glue

Las integraciones sin ETL en AWS Glue simplifican la replicación e ingesta de datos desde servicios de datos de AWS, aplicaciones de terceros y bases de datos autoadministradas hacia destinos de AWS.

Los servicios de AWS compatibles como orígenes zero-ETL en AWS Glue incluyen:

- Amazon DynamoDB

Las aplicaciones de terceros compatibles como orígenes zero-ETL en AWS Glue incluyen:

- Facebook Ads
- Publicidad en Instagram
- Salesforce
- Salesforce Marketing Cloud Account Engagement
- SAP OData
- ServiceNow
- Zendesk
- Zoho CRM

Las bases de datos autoadministradas compatibles como orígenes zero-ETL en AWS Glue incluyen:

- Oracle
- SQL Server
- MySQL
- PostgreSQL

Para obtener más información sobre las integraciones sin ETL procedentes de fuentes autoadministradas, consulte AWS zero-ETL integration for self-managed database sources.

Los servicios de AWS compatibles con destinos zero-ETL en AWS Glue incluyen:

- Amazon Redshift
- Amazon SageMaker Lakehouse

> **Note**
>
> Al crear una integración sin ETL con un origen de Amazon DynamoDB en AWS Glue, Amazon SageMaker Lakehouse admite el destino.

Requisitos previos para configurar una integración sin ETL

La configuración de una integración entre el origen y el destino requiere algunos requisitos previos, como la configuración de los roles de IAM, que AWS Glue utiliza para acceder a los datos del origen y escribir en el destino, y el uso de claves KMS para cifrar los datos en la ubicación intermedia o de destino.

Temas

- Configuración de los recursos de origen
- Configuración de los recursos de destino
- Creación de un almacenamiento de datos de Amazon Redshift
- Configuración de una VPC en su integración sin ETL
- Configuración de una integración sin ETL entre cuentas

Configuración de los recursos de origen

Realice en el origen las siguientes tareas de configuración según sea necesario.

Configuración del rol de origen

En esta sección se describe cómo se transfiere un rol de origen para permitir que la integración sin ETL acceda a la conexión. Esto también se aplica solo a los orígenes de SaaS.

> **Note**
>
> Para restringir el acceso a unas pocas conexiones, primero puede crear la conexión para obtener el ARN de conexión. Consulte Configuración de un origen para una integración sin ETL.

Cree un rol que tenga permisos para que la integración acceda a la conexión:

JSON

```
{
    "Version":"2012-10-17",
    "Statement": [
```

```
        {
            "Sid": "GlueConnections",
            "Effect": "Allow",
            "Action": [
                "glue:GetConnections",
                "glue:GetConnection"
            ],
            "Resource": [
       "arn:aws:glue:*:111122223333:catalog",
       "arn:aws:glue:us-east-1:111122223333:connection/*"
            ]
        },
        {
            "Sid": "GlueActionBasedPermissions",
            "Effect": "Allow",
            "Action": [
                "glue:ListEntities",
                "glue:RefreshOAuth2Tokens"
            ],
            "Resource": [
                "*"
            ]
        }
    ]
}
```

Política de confianza:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Principal": {
        "Service": [
          "glue.amazonaws.com"
        ]
      },
      "Action": "sts:AssumeRole"
    }
```

```
  ]
}
```

Configuración de los recursos de destino

Realice las siguientes tareas de configuración según sea necesario para el destino de integración del almacén de datos de AWS Glue Data Catalog o de Amazon Redshift.

Para integraciones con un destino de base de datos de AWS Glue:

- Configuración de una base de datos de AWS Glue
- Cómo proporcionar una política de acceso basado en recursos (RBAC) al catálogo
- Creación de un rol de IAM de destino

Para integraciones con un destino de almacén de datos de Amazon Redshift:

- https://docs.aws.amazon.com/glue/latest/dg/zero-etl-prerequisites.html#zero-etl-setup-target-redshift-data-warehouse

Configuración de una base de datos de AWS Glue

Para las integraciones que utilizan una base de datos de AWS Glue:

Para configurar una base de datos de destino en el catálogo de datos de AWS Glue con una ubicación de Amazon S3:

1. En la página de inicio de la consola de AWS Glue, seleccione Base de datos en el catálogo de datos.
2. Seleccione Añadir base de datos en la parte superior derecha. Si ya ha creado una base de datos, asegúrese de que la ubicación con el URI de Amazon S3 esté configurada para la base de datos.
3. Introduzca un nombre y una ubicación (URI de Amazon S3). Tenga en cuenta que la ubicación es necesaria para la integración sin ETL. Haga clic en Crear base de datos cuando haya terminado.

> **Note**
>
> El bucket de Amazon S3 debe estar en la misma región que la base de datos de AWS Glue.

Para obtener información sobre cómo crear una nueva base de datos en AWS Glue, consulte Introducción al catálogo de datos de AWS Glue.

También puede usar la CLI de `create-database` para crear la base de datos en AWS Glue. Tenga en cuenta que es necesario incluir `LocationUri` en `--database-input`.

Optimización de las tablas de Iceberg

Una vez que AWS Glue cree una tabla en la base de datos de destino, puede habilitar la compactación para acelerar las consultas en Amazon Athena. Para obtener información sobre cómo configurar los recursos (rol de IAM) para la compactación, consulte los requisitos previos de optimización de la tabla.

Para obtener más información sobre cómo configurar la compactación en la tabla de AWS Glue que creó la integración, consulte Optimización de las tablas de Iceberg.

Cómo proporcionar una política de acceso basado en recursos (RBAC) al catálogo

En el caso de las integraciones que utilizan una base de datos de AWS Glue, añada los siguientes permisos a la política de RBAC del catálogo para permitir las integraciones entre el origen y el destino.

> **Note**
>
> Para las integraciones entre cuentas, tanto la política de roles de Alice (el usuario que crea la integración) como la política de recursos del catálogo deben permitir `glue:CreateInboundIntegration` en el recurso. En el caso de que sean las mismas cuentas, basta con una política de recursos o una política de roles que permita `glue:CreateInboundIntegration` en el recurso. Aun así, es necesario que ambos escenarios permitan `glue.amazonaws.com` en `glue:AuthorizeInboundIntegration`.

Puede acceder a la configuración del catálogo en Catálogo de datos. A continuación, proporcione los siguientes permisos y rellene la información que falta.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
```

```
    {
      "Principal": {
        "AWS": [
         "arn:aws:iam::123456789012:user/Alice"
        ]
      },
      "Effect": "Allow",
      "Action": [
        "glue:CreateInboundIntegration"
      ],
      "Resource": [
       "arn:aws:glue:us-east-1:111122223333:catalog",
    "arn:aws:glue:us-east-1:111122223333:database/DatabaseName"
      ],
      "Condition": {
        "StringLike": {
        "aws:SourceArn": "arn:aws:dynamodb:us-east-1:444455556666:table/<table-
name>"
        }
      }
    },
    {
      "Principal": {
        "Service": [
          "glue.amazonaws.com"
        ]
      },
      "Effect": "Allow",
      "Action": [
        "glue:AuthorizeInboundIntegration"
      ],
      "Resource": [
       "arn:aws:glue:us-east-1:111122223333:catalog",
    "arn:aws:glue:us-east-1:111122223333:database/DatabaseName"
      ],
      "Condition": {
        "StringEquals": {
        "aws:SourceArn": "arn:aws:dynamodb:us-east-1:444455556666:table/<table-
name>"
        }
      }
    }
  ]
```

```
}
```

Creación de un rol de IAM de destino

Cree un rol de IAM de destino con los siguientes permisos y relaciones de confianza:

JSON

```
{
    "Version":"2012-10-17",
    "Statement": [
        {
            "Action": "s3:ListBucket",
            "Resource": "arn:aws:s3:::amzn-s3-demo-bucket",
            "Effect": "Allow"
        },
        {
            "Action": [
                "s3:GetObject",
                "s3:PutObject",
                "s3:DeleteObject"
            ],
            "Resource": "arn:aws:s3:::amzn-s3-demo-bucket/prefix/*",
            "Effect": "Allow"
        },
        {
            "Action": [
                "glue:GetDatabase"
            ],
            "Resource": [
                "arn:aws:glue:us-east-1:111122223333:catalog",
                "arn:aws:glue:us-east-1:111122223333:database/DatabaseName"
            ],
            "Effect": "Allow"
        },
        {
            "Action": [
                "glue:CreateTable",
                "glue:GetTable",
                "glue:GetTables",
                "glue:DeleteTable",
                "glue:UpdateTable",
```

```
                "glue:GetTableVersion",
                "glue:GetTableVersions",
                "glue:GetResourcePolicy"
            ],
            "Resource": [
                "arn:aws:glue:us-east-1:111122223333:catalog",
                "arn:aws:glue:us-east-1:111122223333:database/DatabaseName",
                "arn:aws:glue:us-east-1:111122223333:table/DatabaseName/*"
            ],
            "Effect": "Allow"
        },
        {
            "Action": [
                "cloudwatch:PutMetricData"
            ],
            "Resource": "*",
            "Condition": {
                "StringEquals": {
                    "cloudwatch:namespace": "AWS/Glue/ZeroETL"
                }
            },
            "Effect": "Allow"
        },
        {
            "Action": [
                "logs:CreateLogGroup",
                "logs:CreateLogStream",
                "logs:PutLogEvents"
            ],
            "Resource": "*",
            "Effect": "Allow"
        }
    ]
}
```

Agregue la siguiente política de confianza para permitir que el servicio AWS Glue asuma el rol:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
```

```
    {
      "Effect": "Allow",
      "Principal": {
        "Service": "glue.amazonaws.com"
      },
      "Action": "sts:AssumeRole"
    }
  ]
}
```

Creación de un almacenamiento de datos de Amazon Redshift

Si su destino de integración sin ETL es un almacenamiento de datos de Amazon Redshift, cree el almacenamiento de datos si aún no tiene uno. Para crear un grupo de trabajo de Amazon Redshift sin servidor, consulte Creación de un grupo de trabajo con un espacio de nombres. Para crear un clúster de Amazon Redshift, consulte Creación de un clúster.

Para que la integración funcione, el clúster o el grupo de trabajo de Amazon Redshift de destino debe tener el parámetro `enable_case_sensitive_identifier` activado. Para obtener más información sobre cómo habilitar la distinción entre mayúsculas y minúsculas, consulte Turn on case sensitivity for your data warehouse en la Guía de administración de Amazon Redshift.

Una vez completada la configuración del grupo de trabajo o clúster de Amazon Redshift, debe configurar el almacén de datos. Para obtener más información, consulte Introducción a las integraciones sin ETL en la Guía de administración de Amazon Redshift.

Configuración de una VPC en su integración sin ETL

Para configurar una VPC en su integración sin ETL:

1. Vaya a VPC > Sus VPC y seleccione Crear VPC.
   a. Seleccione VPC y más.
   b. Establezca el nombre de la VPC.
   c. Configure el CIDR de IPv4: 10.0.0.0/16.
   d. Establezca el número de AZ en 1.
   e. Establezca el número de subredes públicas y privadas en 1.
   f. Establezca las puertas de enlace NAT en Ninguna.
   g. Establezca los puntos de conexión de VPC en Puerta de enlace de S3.

h. Habilite los nombres de host DNS y la resolución de DNS.

2. Vaya a Puntos de conexión y elija Crear punto de conexión.
3. Cree puntos de conexión para estos servicios en la subred privada de su VPC (utilice el grupo de seguridad predeterminado):
   a. com.amazonaws.us-east-1.lambda
   b. com.amazonaws.us-east-1.glue
   c. com.amazonaws.us-east-1.sts

Creación de la conexión de AWS Glue

1. Vaya a AWS Glue > Conexiones de datos y seleccione Crear conexión.
2. Elija Red.
3. Seleccione la VPC, la subred (privada) y el grupo de seguridad predeterminado que creó.

Configuración del rol de destino para la VPC

El rol de destino debe tener los siguientes permisos (además del resto de permisos que requieren las integraciones sin ETL):

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Sid": "CustomerVpc",
      "Effect": "Allow",
      "Action": [
        "ec2:CreateTags",
        "ec2:DeleteTags",
        "ec2:DescribeRouteTables",
        "ec2:DescribeVpcEndpoints",
        "ec2:DescribeSecurityGroups",
        "ec2:DescribeSubnets",
        "ec2:CreateNetworkInterface",
        "ec2:DeleteNetworkInterface",
        "glue:GetConnection"
```

```
      ],
      "Resource": [
        "*"
      ]
    }
  ]
}
```

Configuración de las propiedades de los recursos del tramo de destino

Si utiliza la CLI, establezca las propiedades de recursos del tramo de destino en la base de datos de AWS Glue de destino que creó. Pase el ARN del rol de destino, así como el nombre de la conexión de AWS Glue.

```
aws glue create-integration-resource-property \
--resource-arn arn:aws:glue:us-east-1:<account-id>:database/exampletarget \
--target-processing-properties '{"RoleArn" : "arn:aws:iam::<account-id>:role/example-role", "ConnectionName":"example-vpc-3"}' \
--endpoint-url https://example.amazonaws.com --region us-east-1
```

Posibles errores de cliente

A continuación, se muestra una serie de posibles errores de cliente para una integración que se haya configurado con una VPC.

Mensaje de error	Acción requerida
El rol proporcionado no está autorizado para ejecutar glue:GetConnection en la conexión. Agregue este permiso a la política de roles y, a continuación, espere a que se recupere la integración.	Actualización de la política de roles
El rol proporcionado no tiene permiso para ejecutar ec2:DescribeSubnets. Agregue este permiso a la política de roles y, a continuación, espere a que se recupere la integración.	Actualización de la política de roles

Mensaje de error	Acción requerida
El rol proporcionado no está autorizado para ejecutar ec2:DescribeSecurityGroups. Agregue este permiso a la política de roles y, a continuación, espere a que se recupere la integración.	Actualización de la política de roles
El rol proporcionado no está autorizado para ejecutar ec2:DescribeVpcEndpoints. Agregue este permiso a la política de roles y, a continuación, espere a que se recupere la integración.	Actualización de la política de roles
El rol proporcionado no está autorizado para ejecutar ec2:DescribeRouteTables. Agregue este permiso a la política de roles y, a continuación, espere a que se recupere la integración.	Actualización de la política de roles
El rol proporcionado no está autorizado para ejecutar ec2:CreateTags. Agregue este permiso a la política de roles y, a continuación, espere a que se recupere la integración.	Actualización de la política de roles
El rol proporcionado no está autorizado para ejecutar ec2:CreateNetworkInterface. Agregue este permiso a la política de roles y, a continuación, espere a que se recupere la integración.	Actualización de la política de roles
La subred de conexión proporcionada no contiene un punto de conexión S3 o una puerta de enlace NAT válidos. Actualice la subred y, a continuación, espere a que se recupere la integración.	Actualización de los puntos de conexión de la subred de la VPC

Mensaje de error	Acción requerida
No se encontró la subred de conexión. Actualice la subred de la conexión y, a continuación, espere a que se recupere la integración.	Actualizar la conexión de AWS Glue
No se encontró el grupo de seguridad de conexión. Actualice el grupo de seguridad de la conexión y, a continuación, espere a que se recupere la integración.	Actualizar la conexión de AWS Glue
No se puede conectar a S3 a través de la conexión de VPC proporcionada. Actualice las configuraciones de la subred y, a continuación, espere a que se recupere la integración.	Actualización de los puntos de conexión de la subred de la VPC
No se puede conectar a Lambda a través de la conexión de VPC proporcionada. Actualice las configuraciones de la subred y, a continuación, espere a que se recupere la integración.	Actualización de los puntos de conexión de la subred de la VPC

Configuración de una integración sin ETL entre cuentas

Para configurar una integración sin ETL entre cuentas:

1. Configure una política de recursos de destino, tal como se describe en Cómo proporcionar una política de acceso basado en recursos (RBAC) al catálogo. Asegúrese de que el rol de la cuenta de origen esté explícitamente permitido en el recurso de destino.
2. Compruebe que el rol de la cuenta de origen (el rol que se utiliza para crear la integración) tenga lo siguiente:

   JSON

```
{
    "Version":"2012-10-17",
    "Statement": [
        {
```

```
            "Sid": "Stmt123456789012",
            "Action": [
                "glue:CreateInboundIntegration"
            ],
            "Effect": "Allow",
            "Resource": [
             "arn:aws:glue:us-east-1:111122223333:catalog",
       "arn:aws:glue:us-east-1:111122223333:database/DatabaseName"
            ]
        }
    ]
}
```

3. Cree la integración, tal y como se describe en Creación de una integración.

Configuración de un origen para una integración sin ETL

Compatibilidad con entidades SAP especiales

AWS Glue zero-ETL es compatible con las entidades OData de SAP que utilizan el marco de aprovisionamiento de datos operativos (ODP) de SAP, así como aquellas que no utilizan el marco ODP (entidades que no son ODP). La lista de entidades compatibles incluye: ODP_SAP (Business Warehouse o extractores de BW), ODP_CDS (Core Data Services o CDS Views) y servicios OData no basados en ODP para las API de SAP. AWS Glue zero-ETL es compatible con la captura completa de datos de cambios incrementales y de forma instantánea para entidades de SAP ODP y no ODP. En el caso de las entidades ODP, los cambios incrementales se capturan mediante enlaces delta. En el caso de las entidades no ODP, si se selecciona un campo consultable que se pueda utilizar para la ingesta basada en marcas de tiempo, zero-ETL utilizará ese campo para la ingesta incremental.

Al ingerir datos de entidades de SAP mediante AWS Glue zero-ETL se debe tener en cuenta lo siguiente:

- Zero-ETL solo puede ingerir entidades de SAP que se hayan configurado para el método GET_ENTITYSET en SAP.
- En el caso de las entidades SAP no ODP, si no se selecciona un campo de marca de tiempo para las actualizaciones incrementales, AWS Glue zero-ETL permite la extracción y replicación completas de los datos únicamente con upserts (sin eliminaciones).

- En el caso de las entidades extractoras ODP, determinamos los conjuntos de claves principales válidos durante el procesamiento de los datos. Otras entidades de SAP requieren un paso adicional para proporcionar el conjunto de claves principales válido como entrada, específicamente las entidades de SAP que comienzan por `Entity0f`. Cuando se selecciona una entidad `Entity0f`, se le indicará que proporcione el conjunto de claves principales.

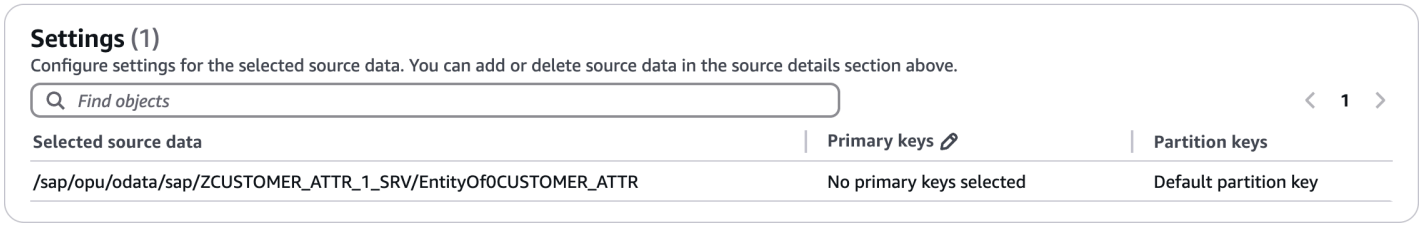

Configuración de un origen de Amazon DynamoDB

Para acceder a los datos de la tabla del origen de Amazon DynamoDB, AWS Glue necesita obtener acceso para describir la tabla y exportar los datos de esta. Amazon DynamoDB introdujo recientemente una característica que permite configurar una política de acceso basado en recursos (RBAC).

En el siguiente ejemplo de política de acceso basado en recursos (RBAC) se utiliza un comodín (*) para la integración:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Sid": "1111",
      "Effect": "Allow",
      "Principal": {
        "Service": "glue.amazonaws.com"
      },
      "Resource": "*",
      "Action": [
        "dynamodb:ExportTableToPointInTime",
        "dynamodb:DescribeTable",
        "dynamodb:DescribeExport"
      ],
```

```
      "Condition": {
        "StringEquals": {
          "aws:SourceAccount": "111122223333"
        },
        "ArnLike": {
          "aws:SourceArn": "arn:aws:glue:us-east-1:111122223333:integration:*"
        }
      }
    }
  ]
}
```

1. Según la instancia de DynamoDB que desee replicar, pegue la plantilla de política de RBAC anterior en la tabla Política basada en recursos y rellene los campos.
2. Si desea que la política sea restrictiva, debe actualizarla después de crear la integración y especificar `integrationArn` al completo y usar la condición `StringEquals` en lugar de `StringLike`.
3. Compruebe que haya habilitado la recuperación en un momento dado (PITR) para la tabla de Amazon DynamoDB.
4. Asegúrese de añadir `Describe Export` a la política de acceso basado en recursos (RBAC).

También puede añadir la política de RBAC a la tabla mediante el siguiente comando:

```
aws dynamodb put-resource-policy \
--resource-arn arn:aws:dynamodb:<region>:<account-id>:table/<ddb-table-name> \
--policy file://resource-policy-with-condition.json \
--region <region>
```

Para comprobar que la política se aplica correctamente, utilice el siguiente comando para obtener la política de recursos de una tabla:

```
aws dynamodb get-resource-policy \
--resource-arn arn:aws:dynamodb:<region>:<account-id>:table/<ddb-table-name>
--region <region>
```

Configuración de un origen de Salesforce

Para crear una conexión de un origen de Salesforce, consulte Conexión a Salesforce.

Una vez que haya creado la conexión, puede especificar los datos de origen que se van a replicar.

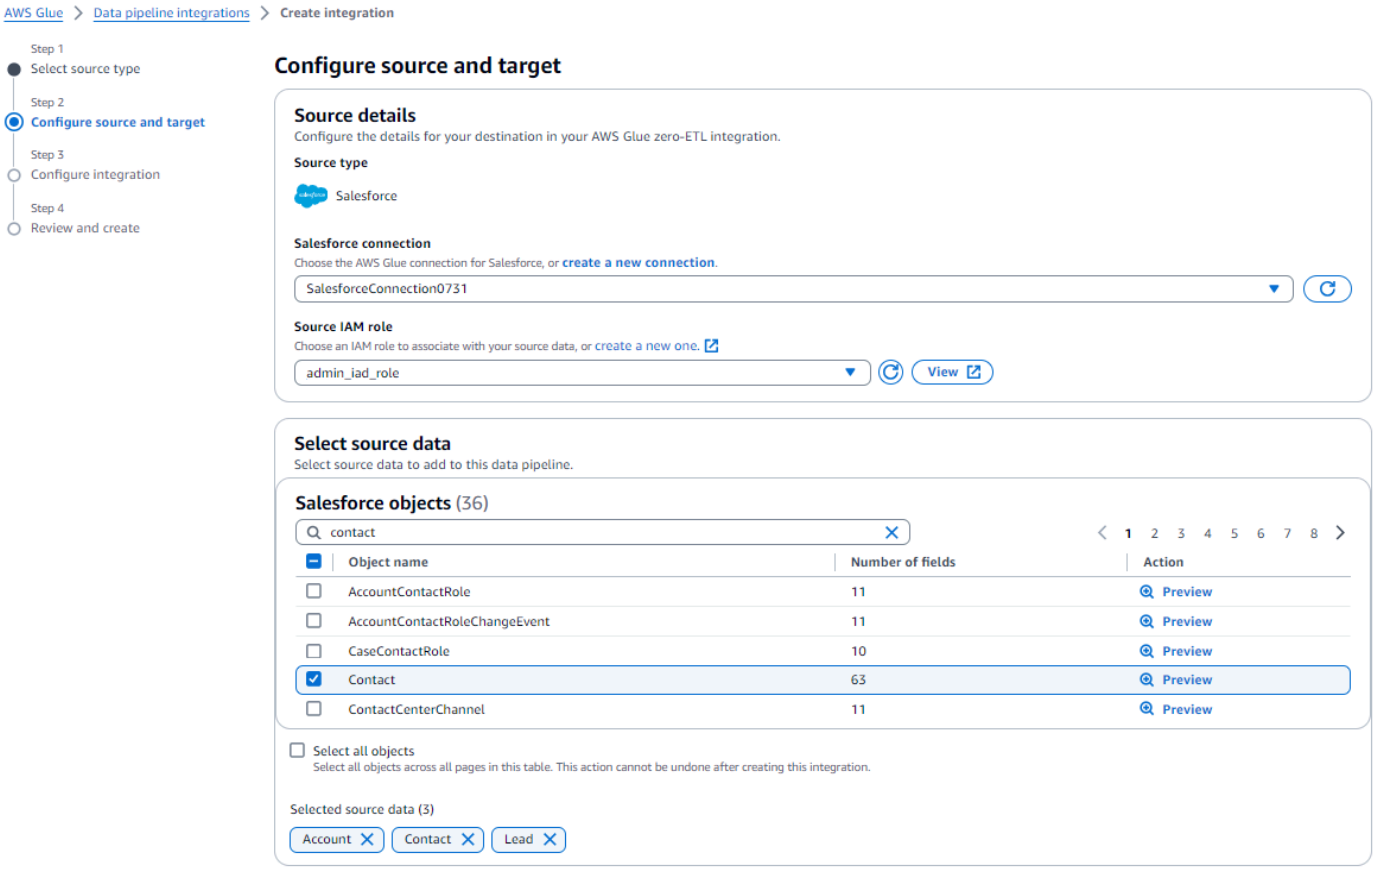

Mediante su integración sin ETL, puede realizar operaciones de DDL en las entidades compatibles. Para obtener una lista de las entidades que no son compatibles, consulte Entidades y campos de Salesforce no admitidos.

Configuración de un origen de Salesforce Marketing Cloud Account Engagement

Para crear una conexión para un origen de Salesforce Marketing Cloud Account Engagement, consulte Conexión a Salesforce Marketing Cloud Account Engagement .

Mediante su integración sin ETL, puede realizar operaciones de DDL en las siguientes entidades compatibles:

Etiqueta de entidad	Nombre de la entidad
Campaña	campaña

Etiqueta de entidad	Nombre de la entidad
Enumeración	list
Dynamic Content	dynamic-content
Suscripción al listado	list-membership
Posible cliente	prospect
Usuario	usuario
EmailTemplate	email-template
EngagementStudioProgram	engagement-studio-program
Página de destino	landing-page
Correo electrónico de listado	list-email

Configuración adicional de Salesforce

Salesforce Zero-ETL necesita el permiso de Lake Formation en la base de datos de Glue; de lo contrario, obtendrá `IngestionFailed` del registro con el siguiente error:

```
"errorMessage": "Insufficient lake formation permissions on Target Glue database."
```

Configuración de un origen de SAP OData

Para crear una conexión de un origen de SAP OData, consulte Conexión a SAP OData .

Las integraciones sin ETL con un origen de SAP OData ahora admiten entidades que comiencen por `EntityOf`. Actualmente, la capacidad de anular la clave principal solo se admite en los objetos SAPOData EntityOf. Una vez establecida esta propiedad, no se puede modificar.

Configuración de un origen de ServiceNow

Para crear una conexión de un origen de ServiceNow, consulte Conexión a ServiceNow .

Configuración de un origen de Zendesk

Para crear una conexión de un origen de Zendesk, consulte Conexión a Zendesk.

Mediante su integración sin ETL, puede realizar operaciones de DDL en las entidades compatibles:

Etiqueta de entidad	Nombre de la entidad	Crear admitidos	Actualizar admitidos	Eliminar admitidos
Tickets	tickets	S	S	S
Usuario	usuarios	S	S	S
Calificación de satisfacción	satisfaction-rating	S	S	N
Artículos	artículos	S	S	N
Organization	organizaciones	S	S	S
Calls	llamadas	S	S	N
Tramos de llamadas	tramos	S	S	N

Configuración de un origen de Zoho CRM

Para crear una conexión de un origen de Zoho CRM, consulte Conexión a Zoho CRM.

Mediante su integración sin ETL, puede realizar operaciones de DDL en las entidades compatibles:

Etiqueta de entidad	Nombre de la entidad	Compatible con DML-Insert	Compatible con DML-Modify	Compatible con DML-Delete	Compatible con DDL-Insert	Compatible con DDL-Modify	Compatible con DDL-Delete
Leads	lead	S	S	S	S	S	S
Cuentas	inscrita	S	S	S	S	S	S

Etiqueta de entidad	Nombre de la entidad	Compatible con DML-Insert	Compatible con DML-Modify	Compatible con DML-Delete	Compatible con DDL-Insert	Compatible con DDL-Modify	Compatible con DDL-Delete
Contactos	contacto	S	S	S	S	S	S
Campaigns (Campañas)	campaña	S	S	S	S	S	S
Tareas	tarea	S	S	S	S	S	S
Eventos	event	S	S	S	S	S	S
Calls	call	S	S	S	S	S	S
Soluciones	solución	S	S	S	S	S	S
Productos	producto	S	S	S	S	S	S
Proveedores	proveedor	S	S	S	S	S	S
Cuotas	quote	S	S	S	S	S	S
Pedidos de ventas	sales-order	S	S	S	S	S	S
Órdenes de compra	purchase-order	S	S	S	S	S	S
Facturas	factura	S	S	S	S	S	S
Casos	caso	S	S	S	S	S	S

Etiqueta de entidad	Nombre de la entidad	Compatible con DML-Insert	Compatible con DML-Modify	Compatible con DML-Delete	Compatible con DDL-Insert	Compatible con DDL-Modify	Compatible con DDL-Delete
Libros de precios	price-book	S	S	S	S	S	S

Configuración de un origen de Facebook Ads

Para crear una conexión de un origen de Facebook Ads, consulte Conexión a Anuncios de Facebook .

Mediante su integración sin ETL, puede realizar operaciones de DDL en las entidades compatibles:

Etiqueta de entidad	Nombre de la entidad	Crear admitidos	Actualizar admitidos	Eliminar admitidos
Conjunto de anuncios	*/adsets	S	S	S
Campaña	*/campaigns	S	S	S
Anuncios	*/ads	S	S	S

Configuración de un origen de Instagram Ads

Para crear una conexión de un origen de Instagram Ads, consulte Conexión a Anuncios de Instagram .

Mediante su integración sin ETL, puede realizar operaciones de DDL en las entidades compatibles:

Nombre de la entidad	Crear admitidos	Actualizar admitidos	Eliminar admitidos
*/adsets	S	S	S
*/campaigns	S	S	S

Nombre de la entidad	Crear admitidos	Actualizar admitidos	Eliminar admitidos
*/ads	S	S	S

Entidades y campos de Salesforce no admitidos

No se admite el uso de los siguientes entidades o campos de Salesforce en una integración sin ETL con un origen de Salesforce.

```
AccountChangeEvent, AccountContactRoleChangeEvent, AccountHistory, AccountShare,
 ActiveFeatureLicenseMetric, ActivePermSetLicenseMetric, ActiveProfileMetric,
 ActivityFieldHistory, amzsec__asi_Telemetry_Data_Store__ChangeEvent,
 amzsec__asi_Telemetry_Data_Store__History, amzsec__asi_Telemetry_Data_Store__Share,
 amzsec__asi_Telemetry_Job_Log__ChangeEvent, amzsec__asi_Telemetry_Job_Log__History,
 amzsec__asi_Telemetry_Job_Log__Share, amzsec__asi_Telemetry_Requirement__ChangeEvent,
 amzsec__asi_Telemetry_Requirement__History, amzsec__asi_Telemetry_Requirement__Share,
 ApexClass, ApexComponent, ApexLog, ApexPage, ApexTestQueueItem, ApexTestResult,
 ApexTrigger, AssetChangeEvent, AssetHistory, AssetRelationshipHistory,
 AssetShare, AssignmentRule, AssociatedLocationHistory, AsyncApexJob,
 AuditTrailFileExportShare, AuthorizationFormConsentChangeEvent,
 AuthorizationFormConsentHistory, AuthorizationFormConsentShare,
 AuthorizationFormDataUseHistory, AuthorizationFormDataUseShare,
 AuthorizationFormHistory, AuthorizationFormShare, AuthorizationFormTextHistory,
 AuthProvider, AuthSession, BatchJobHistory, BatchJobPartFailedRecordHistory,
 BatchJobPartHistory, BatchJobShare, BrandTemplate, BriefcaseAssignmentChangeEvent,
 BriefcaseDefinitionChangeEvent, BusinessBrandShare, BusinessHours,
 BusinessProcess, CalcMatrixColumnRangeHistory, CalcProcStepRelationshipHistory,
 CalculationMatrixColumnHistory, CalculationMatrixHistory, CalculationMatrixRowHistory,
 CalculationMatrixShare, CalculationMatrixVersionHistory, CalculationProcedureHistory,
 CalculationProcedureShare, CalculationProcedureStepHistory,
 CalculationProcedureVariableHistory, CalculationProcedureVersionHistory, Calendar,
 CalendarViewShare, CallCenter, CallCoachConfigModifyEvent, CampaignChangeEvent,
 CampaignHistory, CampaignMemberChangeEvent, CampaignMemberStatusChangeEvent,
 CampaignShare, CaseChangeEvent, CaseHistory, CaseHistory2 CaseHistory2ChangeEvent,
 CaseRelatedIssueChangeEvent, CaseRelatedIssueHistory, CaseShare, CaseStatus,
 CaseTeamMember, CaseTeamRole, CaseTeamTemplate, CaseTeamTemplateMember,
 CaseTeamTemplateRecord, CategoryNode, ChangeRequestChangeEvent, ChangeRequestHistory,
 ChangeRequestRelatedIssueChangeEvent, ChangeRequestRelatedIssueHistory,
 ChangeRequestRelatedItemChangeEvent, ChangeRequestRelatedItemHistory,
 ChangeRequestShare, ChatRetirementRdyMetrics, ChatterActivity, ClientBrowser,
 CollaborationGroup, CollaborationGroupMember, CollaborationGroupMemberRequest,
```

```
CollaborationInvitation, CommSubscriptionChannelTypeHistory,
CommSubscriptionChannelTypeShare, CommSubscriptionConsentChangeEvent,
CommSubscriptionConsentHistory, CommSubscriptionConsentShare, CommSubscriptionHistory,
CommSubscriptionShare, CommSubscriptionTimingHistory, Community, ConnectedApplication,
ContactChangeEvent, ContactHistory, ContactPointAddressChangeEvent,
ContactPointAddressHistory, ContactPointAddressShare, ContactPointConsentChangeEvent,
ContactPointConsentHistory, ContactPointConsentShare, ContactPointEmailChangeEvent,
ContactPointEmailHistory, ContactPointEmailShare, ContactPointPhoneChangeEvent,
ContactPointPhoneHistory, ContactPointPhoneShare, ContactPointTypeConsentChangeEvent,
ContactPointTypeConsentHistory, ContactPointTypeConsentShare, ContactRequestShare,
ContactShare, ContentDocumentChangeEvent, ContentDocumentHistory,
ContentDocumentLink, ContentDocumentLinkChangeEvent, ContentDocumentSubscription,
ContentFolderItem, ContentFolderLink, ContentFolderMember, ContentNote,
ContentNotification, ContentTagSubscription, ContentUserSubscription,
ContentVersionChangeEvent, ContentVersionComment, ContentVersionHistory,
ContentVersionRating, ContentWorkspace, ContentWorkspaceMember,
ContentWorkspacePermission, ContentWorkspaceSubscription, ContractChangeEvent,
ContractHistory, ContractLineItemChangeEvent, ContractLineItemHistory,
ContractStatus, Conversation, ConversationParticipant, CronJobDetail,
CronTrigger, CustomBrand, CustomBrandAsset, CustomerShare, CustomHttpHeader,
DashboardComponent, DataUseLegalBasisHistory, DataUseLegalBasisShare,
DataUsePurposeHistory, DataUsePurposeShare, DecisionTableRecordset, DeleteEvent,
DocumentAttachmentMap, Domain, DomainSite, DTRecordsetReplicaShare, EmailBounceEvent,
EmailMessageChangeEvent, EmailServicesAddress, EmailServicesFunction,
EmailTemplate, EmailTemplateChangeEvent, EngagementAttendeeChangeEvent,
EngagementAttendeeHistory, EngagementChannelTypeHistory, EngagementChannelTypeShare,
EngagementInteractionChangeEvent, EngagementInteractionHistory,
EngagementInteractionShare, EngagementInterface, EngagementTopicChangeEvent,
EngagementTopicHistory, EntitlementChangeEvent, EntitlementHistory,
EntitlementTemplate, EntityMilestoneHistory, EntitySubscription, EventChangeEvent,
EventRelationChangeEvent, EventRelayConfigChangeEvent, ExpressionSetHistory,
ExpressionSetShare, ExpressionSetVersionHistory, ExternalEventMappingShare,
FeedAttachment, FeedLike, FeedPollChoice, FeedPollVote, FeedSignal,
FieldPermissions, FieldSecurityClassification, FiscalYearSettings,
FlowInterviewLogShare, FlowInterviewShare, FlowOrchestrationEvent,
FlowOrchestrationInstanceShare, FlowOrchestrationStageInstanceShare,
FlowOrchestrationStepInstanceShare, FlowOrchestrationWorkItemShare,
FlowRecordShare, FlowRecordVersionChangeEvent, FlowTestResultShare, Folder,
Group, GroupMember, Holiday, IdeaComment, IdpEventLog, ImageHistory, ImageShare,
IncidentChangeEvent, IncidentHistory, IncidentRelatedItemChangeEvent,
IncidentRelatedItemHistory, IncidentShare, IndividualChangeEvent,
IndividualHistory, IndividualShare, KnowledgeableUser, LeadChangeEvent, LeadHistory,
LeadShare, LeadStatus, LightningExitByPageMetrics, LightningToggleMetrics,
LightningUsageByAppTypeMetrics, LightningUsageByBrowserMetrics,
```

```
LightningUsageByFlexiPageMetrics, LightningUsageByPageMetrics, ListEmailChangeEvent,
ListEmailShare, ListView, LocationChangeEvent, LocationHistory, LocationShare,
LocationTrustMeasureShare, LoginHistory, LoginIp, MacroChangeEvent,
MacroHistory, MacroInstructionChangeEvent, MacroShare, MacroUsageShare,
ManagedContentVariantChangeEvent, MessagingEndUserHistory, MessagingEndUserShare,
MessagingSessionHistory, MessagingSessionShare, MilestoneType, MLEngagementEvent,
ObjectPermissions, OpportunityChangeEvent, OpportunityContactRoleChangeEvent,
OpportunityFieldHistory, OpportunityLineItemChangeEvent, OpportunityShare,
OpportunityStage, OrderChangeEvent, OrderHistory, OrderItemChangeEvent,
OrderItemHistory, OrderShare, OrderStatus, Organization, OrgEmailAddressSecurity,
OrgWideEmailAddress, OutgoingEmail, OutgoingEmailRelation, PackageLicense,
PartnerRole, PartyConsentChangeEvent, PartyConsentHistory, PartyConsentShare,
Period, PermissionSet, PermissionSetAssignment, PermissionSetTabSetting,
Pricebook2ChangeEvent, Pricebook2History, PricebookEntryChangeEvent,
PricebookEntryHistory, PrivacyJobSessionShare, PrivacyObjectSessionShare,
PrivacyRTBFRequestHistory, PrivacyRTBFRequestShare, PrivacySessionRecordFailureShare,
ProblemChangeEvent, ProblemHistory, ProblemIncidentChangeEvent,
ProblemIncidentHistory, ProblemRelatedItemChangeEvent, ProblemRelatedItemHistory,
ProblemShare, ProcessDefinition, ProcessExceptionEvent, ProcessExceptionShare,
ProcessInstanceChangeEvent, ProcessInstanceStep, ProcessInstanceStepChangeEvent,
ProcessNode, Product2ChangeEvent, Product2History, ProductEntitlementTemplate,
Profile, ProfileSkillEndorsementHistory, ProfileSkillHistory,
ProfileSkillShare, ProfileSkillUserHistory, PromptActionShare, PromptErrorShare,
QueueSobject, QuickTextChangeEvent, QuickTextHistory, QuickTextShare,
QuickTextUsageShare, RecentlyViewed, RecommendationChangeEvent,
RecordActionHistory, RecordAlertHistory, RecordAlertShare, RecordType,
ScorecardShare, SellerHistory, SellerShare, ServiceContractChangeEvent,
ServiceContractHistory, ServiceContractShare, SetupAuditTrail, SetupEntityAccess,
SharingRecordCollectionShare, Site, SiteHistory, SiteRedirectMapping,
SocialPersonaHistory, SocialPostChangeEvent, SocialPostHistory, SocialPostShare,
SolutionHistory, SolutionStatus, StaticResource, StreamingChannelShare,
TableauHostMappingShare, TaskChangeEvent, TaskPriority, TaskStatus,
ThreatDetectionFeedback, TimelineObjectDefinitionChangeEvent, TodayGoalShare,
Topic, TopicUserEvent, Translation, User, UserAppMenuCustomizationShare,
UserChangeEvent, UserDefinedLabelAssignmentShare, UserDefinedLabelShare,
UserEmailPreferredPersonShare, UserLicense, UserLogin, UserPackageLicense,
UserPreference, UserPrioritizedRecordShare, UserProvisioningRequestShare,
UserRole, UserShare, VideoCallChangeEvent, VideoCallParticipantChangeEvent,
VideoCallRecordingChangeEvent, VideoCallShare, VisualforceAccessMetrics,
VoiceCallChangeEvent, VoiceCallRecordingChangeEvent, VoiceCallShare, Vote,
WebLink, WorkAccessShare, WorkBadgeDefinitionHistory, WorkBadgeDefinitionShare,
WorkOrderChangeEvent, WorkOrderHistory, WorkOrderLineItemChangeEvent,
WorkOrderLineItemHistory, WorkOrderLineItemStatus, WorkOrderShare, WorkOrderStatus,
WorkPlanChangeEvent, WorkPlanHistory, WorkPlanShare, WorkPlanTemplateChangeEvent,
```

```
 WorkPlanTemplateEntryChangeEvent, WorkPlanTemplateEntryHistory,
 WorkPlanTemplateHistory, WorkPlanTemplateShare, WorkStepChangeEvent, WorkStepHistory,
 WorkStepStatus, WorkStepTemplateChangeEvent, WorkStepTemplateHistory,
 WorkStepTemplateShare, WorkThanksShare
```

Tipos de entidad no compatibles con SAP

No se admite el uso de los siguientes tipos de entidades de SAP en una integración sin ETL con un origen de SAP.

```
ODP_HANA (HANA calculation views), ODP_SLT (SLT Replication Server)
```

Entidades y campos de ServiceNow no admitidos

No se admite el uso de los siguientes entidades o campos de ServiceNow en una integración sin ETL con un origen de ServiceNow.

```
ais_acl_overrides, ais_async_genius_result, ais_async_request, ais_connection,
 ais_genius_result_configuration_parameters, ais_partition_health,
 ais_partition_health_response, ais_publish_history, ais_relevancy_training_execution,
 ais_relevancy_training_staging, ais_search_profile_relevancy_model,
 catalog_draft_entities, clone_log, clone_log0000, clone_log0001, clone_log0002,
 clone_log0003, clone_log0004, clone_log0005, clone_log0006, clone_log0007,
 cmdb_ie_context, cmdb_ie_log, cmdb_ie_run, cmdb_ire_partial_payloads_index,
 cmdb_qb_result_base$par1, cmdb$par1, discovery_log, discovery_log0000,
 discovery_log0001, discovery_log0002, discovery_log0003, discovery_log0004,
 discovery_log0005, discovery_log0006, discovery_log0007, ecc_agent_log,
 entitlement_data, entl_subscription_map, gs_entitlement_plugin_mapping,
 ih_transaction_exclusion, import_log, import_log0000, import_log0001, import_log0002,
 import_log0003, import_log0004, import_log0005, import_log0006, import_log0007,
 jrobin_archive, jrobin_database, jrobin_datasource, jrobin_definition, jrobin_graph,
 jrobin_graph_line, jrobin_graph_set, jrobin_graph_set_member, jrobin_shard,
 jrobin_shard_location, license_role_discovery_run, logger_configuration_validation,
 m2m_analytics_event_logger, m2m_user_consent_info, ml_artifact_object_store,
 np$sys_gen_ai_filter_sample, np$sys_ui_element, np$sys_ui_list_element,
 one_api_service_plan_feature_invocation, one_api_service_plan_invocation,
 open_nlu_predict_log, open_nlu_predict_log0000, open_nlu_predict_log0001,
 open_nlu_predict_log0002, open_nlu_predict_log0003, open_nlu_predict_log0004,
 open_nlu_predict_log0005, open_nlu_predict_log0006, open_nlu_predict_log0007,
 pa_diagnostic_log, pa_diagnostic_log0000, pa_diagnostic_log0001,
 pa_diagnostic_log0002, pa_diagnostic_log0003, pa_diagnostic_log0004,
 pa_diagnostic_log0005, pa_diagnostic_log0006, pa_diagnostic_log0007, pa_favorites,
```

```
pa_job_log_rows, pa_job_log_rows0000, pa_job_log_rows0001, pa_job_log_rows0002,
pa_job_log_rows0003, pa_job_log_rows0004, pa_job_log_rows0005, pa_job_log_rows0006,
pa_job_log_rows0007, pa_migration_ignored_scores, pa_scores_l1, pa_scores_l2,
pa_scores_migration_groups, par_dashboard_conversion_backup, promin_log,
promin_log0000, promin_log0001, promin_log0002, promin_log0003, promin_log0004,
promin_log0005, promin_log0006, promin_log0007, promin_request_object,
proposed_change_verification_log, proposed_change_verification_log0000,
proposed_change_verification_log0001, proposed_change_verification_log0002,
proposed_change_verification_log0003, proposed_change_verification_log0004,
proposed_change_verification_log0005, proposed_change_verification_log0006,
proposed_change_verification_log0007, protected_table_log, protected_table_log0000,
protected_table_log0001, protected_table_log0002, protected_table_log0003,
protected_table_log0004, protected_table_log0005, protected_table_log0006,
protected_table_log0007, pwd_history, qb_query_results, scan_log,
scan_log0000, scan_log0001, scan_log0002, scan_log0003, scan_log0004,
scan_log0005, scan_log0006, scan_log0007, schema_validator_error,
sla_repair_log_entry, sla_repair_log_entry0000, sla_repair_log_entry0001,
sla_repair_log_entry0002, sla_repair_log_entry0003, sla_repair_log_entry0004,
sla_repair_log_entry0005, sla_repair_log_entry0006, sla_repair_log_entry0007,
sla_repair_log_message, sla_repair_log_message0000, sla_repair_log_message0001,
sla_repair_log_message0002, sla_repair_log_message0003, sla_repair_log_message0004,
sla_repair_log_message0005, sla_repair_log_message0006, sla_repair_log_message0007,
sn_bm_client_activity, sn_ci_analytics_st_actionable_notifs,
sn_ci_analytics_st_conv_completion_by_cat, sn_ci_analytics_st_conv_dynamic_property,
sn_ci_analytics_st_conversation, sn_ci_analytics_st_count_by_date,
sn_ci_analytics_st_event_occurrence, sn_ci_analytics_st_event_property_value_trend,
sn_ci_analytics_st_issue_auto_resolution, sn_ci_analytics_st_no_clicks,
sn_ci_analytics_st_no_results, sn_ci_analytics_st_property_summary_by_event,
sn_ci_analytics_st_session_count_per_locale, sn_ci_analytics_st_session_duration,
sn_ci_analytics_st_spokes_usage, sn_ci_analytics_st_topic_execution_stats,
sn_ci_analytics_st_topic_occurrence, sn_ci_analytics_st_trending_content,
sn_ci_analytics_st_trending_queries, sn_ci_analytics_st_users,
sn_cs_plugin_signatures, sn_cs_telemetry_log, sn_dfc_application, sn_dfc_product,
sn_employee_position, sn_entitlement_st_subscription_application_family,
sn_entitlement_st_subscription_application_users, sn_hr_sp_st_relevant_for_you,
sn_instance_clone_log, sn_instance_clone_log0000, sn_instance_clone_log0001,
sn_instance_clone_log0002, sn_instance_clone_log0003, sn_instance_clone_log0004,
sn_instance_clone_log0005, sn_instance_clone_log0006, sn_instance_clone_log0007,
sn_km_mr_st_kb_knowledge, sn_me_st_topic, sn_rf_conditional_definition,
sn_rf_evaluation_type, sn_rf_evaluation_type_input, sn_rf_recommendation_action,
sn_rf_recommendation_experience, sn_rf_recommendation_history,
sn_rf_recommendation_rule, sn_rf_record_display_configuration, sn_rf_trend_definition,
sn_sub_man_st_account_level_entitlement, sn_sub_man_st_gen_ai_metadata,
sn_sub_man_st_instance_used_assist_count, sn_sub_man_st_now_assist_creator_instances,
```

```
sn_sub_man_st_now_assists_aggregate, sn_sub_man_st_subscribed_groups,
sn_sub_man_st_subscription_insights, sn_sub_man_st_subscription_license_detail_metric,
sn_sub_man_st_unallocated_group_recommendation, sn_sub_man_st_unconfirmed_user_group,
sn_wn_user_app_activity, sn_wn_user_content_activity, snc_monitorable_item,
snpar_sched_export_v_scheduled_export_visualization, spotlight,
spotlight_audit, spotlight_copy_log_row, spotlight_copy_log_row0000,
spotlight_copy_log_row0001, spotlight_copy_log_row0002, spotlight_copy_log_row0003,
spotlight_copy_log_row0004, spotlight_copy_log_row0005, spotlight_copy_log_row0006,
spotlight_copy_log_row0007, spotlight_job_log_row, spotlight_job_log_row0000,
spotlight_job_log_row0001, spotlight_job_log_row0002, spotlight_job_log_row0003,
spotlight_job_log_row0004, spotlight_job_log_row0005, spotlight_job_log_row0006,
spotlight_job_log_row0007, st_dfc_performance_metric, st_license_detail_metric,
st_on_call_hour, st_sc_wizard_question, st_sys_catalog_items_and_variable_sets,
st_sys_design_system_icon, subscription_instance_stats, svc_container_config,
svc_environment_config, svc_layer_config, svc_model_assoc_ci,
svc_model_checkpoint_attr, svc_model_obj_cluster, svc_model_obj_constraint,
svc_model_obj_deployable, svc_model_obj_element, svc_model_obj_impact,
svc_model_obj_impactrule, svc_model_obj_package, svc_model_obj_path,
svc_model_obj_relation, svc_model_obj_service, sys_administrative_script_transaction,
sys_amb_message, sys_amb_processor, sys_analytics_batch_state,
sys_analytics_config, sys_analytics_data_points_error, sys_analytics_event,
sys_analytics_logger, sys_analytics_logger_field, sys_app_payload_loader_rule,
sys_app_payload_unloader_rule, sys_app_scan_payload, sys_app_scan_variable,
sys_app_scan_variable_type, sys_archive_destroy_log, sys_archive_destroy_run,
sys_archive_log, sys_archive_run, sys_atf_transaction_log, sys_attachment_doc,
sys_attachment_doc_v2, sys_attachment_soft_deleted, sys_audit, sys_audit_relation,
sys_auth_policy_api_allowed, sys_aw_registered_scripting_modal,
sys_cache_flush, sys_data_egress_source, sys_dm_delete_count,
sys_export_set_log, sys_export_set_log0000, sys_export_set_log0001,
sys_export_set_log0002, sys_export_set_log0003, sys_export_set_log0004,
sys_export_set_log0005, sys_export_set_log0006, sys_export_set_log0007,
sys_flow_compiled_flow, sys_flow_compiled_flow_chunk, sys_flow_context_chunk,
sys_flow_context_chunk_archive, sys_flow_context_inputs_chunk,
sys_flow_execution_history, sys_flow_log, sys_flow_log0000, sys_flow_log0001,
sys_flow_log0002, sys_flow_log0003, sys_flow_plan_context_binding,
sys_flow_report_doc, sys_flow_report_doc_chunk, sys_flow_report_doc_chunk_archive,
sys_flow_runtime_state_chunk, sys_flow_runtime_value_chunk,
sys_flow_subflow_plan_chunk, sys_flow_trigger_plan_chunk, sys_flow_val_listener,
sys_flow_value, sys_flow_value_chunk, sys_gen_ai_config_example,
sys_gen_ai_feature_mapping, sys_gen_ai_strategy_mapping, sys_gen_ai_usage_log,
sys_generative_ai_capability_definition, sys_generative_ai_log,
sys_generative_ai_response_validator, sys_generative_ai_validator,
sys_geo_routing, sys_geo_routing_config, sys_hop_token, sys_hub_action_plan_chunk,
sys_hub_snapshot_chunk, sys_journal_field, sys_journal_field_edit, sys_json_chunk,
```

```
sys_kaa_policy, sys_kaa_subidentity_assertion, sys_kaa_user_policy_mapping,
sys_mapplication, sys_mass_encryption_job, sys_notification_execution_log,
sys_notification_execution_log0000, sys_notification_execution_log0001,
sys_notification_execution_log0002, sys_notification_execution_log0003,
sys_notification_execution_log0004, sys_notification_execution_log0005,
sys_notification_execution_log0006, sys_notification_execution_log0007,
sys_nowmq_message, sys_nowmq_provider_param_definition, sys_orchestrator_action,
sys_pd_asset_configuration, sys_pd_context_chunk, sys_pd_context_log,
sys_pd_snapshot_chunk, sys_pd_trigger_license, sys_processing_framework_job,
sys_query_index_hint, sys_query_rewrite, sys_query_string_log,
sys_replication_queue, sys_replication_queue0, sys_replication_queue1,
sys_replication_queue2, sys_replication_queue3, sys_replication_queue4,
sys_replication_queue5, sys_replication_queue6, sys_replication_queue7,
sys_request_performance, sys_rollback_blacklisted, sys_rollback_conflict,
sys_rollback_incremental, sys_rollback_log, sys_rollback_log0000,
sys_rollback_log0001, sys_rollback_log0002, sys_rollback_log0003,
sys_rollback_log0004, sys_rollback_log0005, sys_rollback_log0006,
sys_rollback_log0007, sys_rollback_run, sys_rollback_schema_change,
sys_rollback_schema_conflict, sys_rollback_sequence, sys_scheduler_assignment,
sys_scheduler_memory_pressure_job_log, sys_script_adapter_rule,
sys_script_batch_adapter_rule, sys_search_source_filter, sys_service_authentication,
sys_signing_job, sys_suggestion_reader, sys_sync_history_review, sys_trend,
sys_unreferenced_preview, sys_unreferenced_record_rule, sys_upgrade_manifest,
sys_upgrade_state, sys_ux_asset_cache_buster, sys_ux_lib_component_prop,
sys_ux_lib_presource, sys_ux_page_action, sys_ux_page_action_binding,
sysevent_queue_runtime, syslog, syslog_app_scope0000, syslog_app_scope0001,
syslog_app_scope0002, syslog_app_scope0003, syslog_app_scope0004,
syslog_app_scope0005, syslog_app_scope0006, syslog_app_scope0007, syslog_email0000,
syslog_email0001, syslog_email0002, syslog_email0003, syslog_email0004,
syslog_email0005, syslog_email0006, syslog_email0007, syslog_transaction,
syslog_transaction0000, syslog_transaction0001, syslog_transaction0002,
syslog_transaction0003, syslog_transaction0004, syslog_transaction0005,
syslog_transaction0006, syslog_transaction0007, syslog0000, syslog0001, syslog0002,
syslog0003, syslog0004, syslog0005, syslog0006, syslog0007, ts_attachment,
ts_c_1_0, ts_c_1_1, ts_c_1_2, ts_c_1_3, ts_c_1_4, ts_c_1_5, ts_c_1_6, ts_c_1_7,
ts_c_1_8, ts_c_1_9, ts_c_10_0, ts_c_10_1, ts_c_10_2, ts_c_10_3, ts_c_10_4,
ts_c_10_5, ts_c_10_6, ts_c_10_7, ts_c_10_8, ts_c_10_9, ts_c_11_0, ts_c_11_1,
ts_c_11_2, ts_c_11_3, ts_c_11_4, ts_c_11_5, ts_c_11_6, ts_c_11_7, ts_c_11_8,
ts_c_11_9, ts_c_2_0, ts_c_2_1, ts_c_2_2, ts_c_2_3, ts_c_2_4, ts_c_2_5, ts_c_2_6,
ts_c_2_7, ts_c_2_8, ts_c_2_9, ts_c_3_0, ts_c_3_1, ts_c_3_2, ts_c_3_3, ts_c_3_4,
ts_c_3_5, ts_c_3_6, ts_c_3_7, ts_c_3_8, ts_c_3_9, ts_c_39_0, ts_c_39_1, ts_c_39_2,
ts_c_39_3, ts_c_39_4, ts_c_39_5, ts_c_39_6, ts_c_39_7, ts_c_39_8, ts_c_39_9,
ts_c_40_0, ts_c_40_1, ts_c_40_2, ts_c_40_3, ts_c_40_4, ts_c_40_5, ts_c_40_6,
ts_c_40_7, ts_c_40_8, ts_c_40_9, ts_c_41_0, ts_c_41_1, ts_c_41_2, ts_c_41_3,
```

```
ts_c_41_4, ts_c_41_5, ts_c_41_6, ts_c_41_7, ts_c_41_8, ts_c_41_9, ts_c_42_0,
ts_c_42_1, ts_c_42_2, ts_c_42_3, ts_c_42_4, ts_c_42_5, ts_c_42_6, ts_c_42_7,
ts_c_42_8, ts_c_42_9, ts_c_43_0, ts_c_43_1, ts_c_43_2, ts_c_43_3, ts_c_43_4,
ts_c_43_5, ts_c_43_6, ts_c_43_7, ts_c_43_8, ts_c_43_9, ts_c_44_0, ts_c_44_1,
ts_c_44_2, ts_c_44_3, ts_c_44_4, ts_c_44_5, ts_c_44_6, ts_c_44_7, ts_c_44_8,
ts_c_44_9, ts_c_45_0, ts_c_45_1, ts_c_45_2, ts_c_45_3, ts_c_45_4, ts_c_45_5,
ts_c_45_6, ts_c_45_7, ts_c_45_8, ts_c_45_9, ts_c_6_0, ts_c_6_1, ts_c_6_2,
ts_c_6_3, ts_c_6_4, ts_c_6_5, ts_c_6_6, ts_c_6_7, ts_c_6_8, ts_c_6_9, ts_c_7_0,
ts_c_7_1, ts_c_7_2, ts_c_7_3, ts_c_7_4, ts_c_7_5, ts_c_7_6, ts_c_7_7, ts_c_7_8,
ts_c_7_9, ts_c_8_0, ts_c_8_1, ts_c_8_2, ts_c_8_3, ts_c_8_4, ts_c_8_5, ts_c_8_6,
ts_c_8_7, ts_c_8_8, ts_c_8_9, ts_c_attachment, ts_chain, ts_deleted_doc,
ts_document, ts_field, ts_index_stats, ts_phrase, ts_search_stats, ts_v4_attachment,
ts_word, ua_app_metadata, ua_audit_stats, ua_extra_page, ua_monitor_property,
ua_monitor_property_audit, ua_shared_service, ua_sn_table_inventory, ua_sp_known_bot,
ua_upload_log, v_ais_result_improvement_rule_condition_builder_values,
v_cluster_nodes, v_cxs_search_resource, v_db_index, v_db_trigger, v_file_load_order,
v_interaction_context, v_iostats, v_mysql_proclist, v_mysql_status, v_mysql_variables,
v_on_call_report_cache, v_pa_par_combined_dashboard, v_pd_activity_condition_to_run,
v_pd_activity_start_rule_with_condition, v_pd_lane_condition_to_run,
v_sql_debug, v_st_kb_category, v_st_kb_most_viewed, v_st_kb_recently_viewed,
v_st_km_genai_mra_similar_task, v_st_popular_item, v_st_recent_item, v_st_sc_cat_item,
v_st_sc_catalog, v_st_sc_category, validator_run_summary, vtb_card_history,
wf_log, wf_log0000, wf_log0001, wf_log0002, wf_log0003, wf_log0004, wf_log0005,
wf_log0006, wf_log0007, spotlight_criteria, pa_snapshots, pa_widget_indicators,
pa_widgets, sn_cim_register, global, gsw_change_log, gsw_content, gsw_content_group,
gsw_content_information, gsw_status_of_content, multi_factor_browser_fingerprint,
multi_factor_criteria, pa_filters, password_policy, plan_execution,
plan_mysql, plan_oracle, plan_postgres, sc_rest_api_without_access_policy,
sn_actsub_activity, sn_actsub_activity_fanout, sn_actsub_activity_stream,
sn_actsub_activity_type, sn_actsub_atype_attributes, sn_actsub_atype_notif_pref,
sn_actsub_module, sn_actsub_notif_object, sn_actsub_subobject_stream,
sn_actsub_subscribable_object, sn_actsub_subscription_notif_pref,
sn_actsub_user_stream, sn_appclient_store_outbound_http_quota,
sn_appcreator_app_template, sn_critical_update, sn_docker_spoke_images,
sn_employee_app, sn_employee_app_access, sn_employee_app_access_criteria,
sn_entitlement_genai_assist_counts, sn_entitlement_genai_creator_user_counts,
sn_entitlement_genai_creator_users, sn_mif_instance, sn_mif_sync_data,
sn_mif_sync_status, sn_mif_table_registration, sn_mif_trust_config,
sn_vsc_best_practice_configurations, sn_vsc_best_practice_goals,
sn_vsc_changed_hardening_settings, sn_vsc_changed_scan_findings,
sn_vsc_check_security_area, sn_vsc_elevation_event, sn_vsc_event,
sn_vsc_export_event, sn_vsc_export_setting, sn_vsc_harc_compliance_status_lookup,
sn_vsc_hardening_compliance_scores, sn_vsc_impersonation_event,
sn_vsc_instance_hardening_settings, sn_vsc_login_event,
```

```
sn_vsc_scan_comparisons, sn_vsc_scan_summary, sn_vsc_security_check_categories,
sn_vsc_security_check_configurations, sn_vsc_security_configuration_groups,
sn_vsc_security_privacy_capabilities, sn_vsc_updated_settings,
sn_vsc_user_comparisons, sys_app_hash_inventory, sys_coalesce_strategy_deferred,
sys_flow_secure_data, sys_formula_function, sys_geocoding_request,
sys_global_file_hash, sys_import_set_row, sys_index, sys_index_explain,
sys_installation_schedule, sys_installation_schedule_item, sys_offline_app,
sys_package, sys_package_dependency_item, sys_package_dependency_m2m,
sys_plugins, sys_querystat, sys_reap_package, sys_scoped_plugin,
sys_stage_storage_alias, sys_storage_alias, sys_storage_table_alias, sys_store_app,
sys_table_partition, sys_upgrade_history_log, sys_user_public_credential,
sys_webauthn_authentication_request, sys_webauthn_registration_request,
syslog_app_scope, syslog_email, syslog_page_timing, ua_instance_state_config,
v_expression_cache, v_private_cache, v_shared_cache, sys_amb_message0002,
sys_amb_message0004, sys_amb_message0005, sys_metadata, v_par_unified_report_viz
```

Configuración de un destino de integración sin ETL

Al configurar un destino de una integración sin ETL, AWS ofrece varias opciones. El destino puede ser un almacén de datos cifrado de Amazon Redshift o un catálogo de Amazon SageMaker Lakehouse.

Antes de seleccionar el destino para la integración sin ETL, debe configurar uno de los siguientes recursos de destino.

Las opciones de configuración de un destino en una integración sin ETL incluyen:

- Un catálogo y una base de datos de Amazon SageMaker Lakehouse configurados con el almacenamiento regular de Amazon S3. Consulte Configuración de un catálogo de Amazon SageMaker Lakehouse con el almacenamiento regular de S3.
- Un catálogo y una base de datos de Amazon SageMaker Lakehouse configurados con el bucket de Tablas de Amazon S3. Consulte Configuración de las tablas de Amazon S3 como destino.
- Un catálogo y una base de datos de Amazon SageMaker Lakehouse configurados con el almacenamiento administrado de Amazon Redshift. Consulte Configuración de un catálogo de Amazon SageMaker Lakehouse con el almacenamiento administrado de Amazon Redshift.
- Un almacenamiento de datos de Amazon Redshift identificado por un espacio de nombres de Redshift. Consulte Configuración de un destino de almacén de datos de Amazon Redshift.

> **Note**
>
> No puede modificar el destino de una integración sin ETL después de su creación.

Configuración de un catálogo de Amazon SageMaker Lakehouse con el almacenamiento regular de S3

En esta sección se describen los requisitos previos y los pasos de configuración para configurar un bucket de Amazon S3 regular como almacenamiento para el destino del catálogo de Amazon SageMaker Lakehouse en una integración sin ETL.

Requisitos previos para configurar una integración

Antes de crear una integración sin ETL con un catálogo de Amazon SageMaker Lakehouse mediante el uso del almacenamiento regular de S3, debe completar las siguientes tareas de configuración:

1. Configurar una base de datos de AWS Glue
2. Proporcionar la política de RBAC del catálogo
3. Crear el rol de IAM de destino

Tras configurar el catálogo de Amazon SageMaker Lakehouse con el almacenamiento regular de Amazon S3, puede ir a Configuración de la integración con su destino para completar la configuración de la integración.

Configuración de las tablas de Amazon S3 como destino

En esta sección se describen los requisitos previos y los pasos de configuración para configurar las tablas de Amazon S3 como destino para su integración sin ETL.

Requisitos previos para configurar una integración

Antes de crear una integración sin ETL con las tablas de Amazon S3 como destino, debe completar las siguientes tareas de configuración:

1. Configurar el bucket de las tablas de Amazon S3
2. Proporcionar la política de RBAC del catálogo
3. Crear el rol de IAM de destino

Configurar el bucket de las tablas de Amazon S3

1. Cree un bucket de las tablas de S3 en su cuenta siguiendo las instrucciones de Introducción a las tablas de Amazon S3.
2. Habilite las integraciones de análisis con el bucket de las tablas de S3 siguiendo estas instrucciones: Integración de los servicios de AWS con las tablas de Amazon S3.

Proporcionar la política de RBAC del catálogo

Los siguientes permisos deben añadirse a la política de RBAC del catálogo para permitir las integraciones entre el origen y el destino del catálogo de las tablas de Amazon S3.

La política de recursos del catálogo de AWS Glue de destino debe incluir los permisos del Servicio Glue para AuthorizeInboundIntegration. Además, se requiere el permiso CreateInboundIntegration en la entidad principal de origen que crea la integración o en la política de recursos de AWS Glue de destino.

> **Note**
>
> En un escenario con varias cuentas, tanto la entidad de origen como la política de recursos del catálogo de AWS Glue de destino deben incluir los permisos glue:CreateInboundIntegration en el recurso.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Principal": {
        "AWS": [
         "arn:aws:iam::123456789012:user/Alice"
        ]
      },
      "Effect": "Allow",
      "Action": [
        "glue:CreateInboundIntegration"
```

```
      ],
      "Resource": [
       "arn:aws:glue:us-east-1:111122223333:catalog/<s3tablescatalog>/*"
      ],
      "Condition": {
        "StringLike": {
        "aws:SourceArn": "arn:aws:dynamodb:us-east-1:444455556666:table/<table-
name>"
        }
      }
    },
    {
      "Principal": {
        "Service": [
          "glue.amazonaws.com"
        ]
      },
      "Effect": "Allow",
      "Action": [
        "glue:AuthorizeInboundIntegration"
      ],
      "Resource": [
      "arn:aws:glue:us-east-1:111122223333:catalog/<s3tablescatalog>/*"
      ],
      "Condition": {
        "StringEquals": {
        "aws:SourceArn": "arn:aws:dynamodb:us-east-1:444455556666:table/<table-
name>"
        }
      }
    }
  ]
}
```

> **Note**
>
> Reemplace <s3tablescatalog> con el nombre del catálogo de sus tablas de S3.

Crear el rol de IAM de destino

Cree un rol de IAM de destino con los siguientes permisos y relaciones de confianza:

Política de IAM de ejemplo:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Action": [
        "s3tables:ListTableBuckets",
        "s3tables:GetTableBucket",
        "s3tables:GetTableBucketEncryption",
        "s3tables:GetNamespace",
        "s3tables:CreateNamespace",
        "s3tables:ListNamespaces",
        "s3tables:CreateTable",
        "s3tables:GetTable",
        "s3tables:GetTableEncryption",
        "s3tables:ListTables",
        "s3tables:GetTableMetadataLocation",
        "s3tables:UpdateTableMetadataLocation",
        "s3tables:GetTableData",
        "s3tables:PutTableData"
      ],
      "Resource": "arn:aws:s3tables:us-east-1:111122223333:bucket/*",
      "Effect": "Allow"
    },
    {
      "Action": [
        "cloudwatch:PutMetricData"
      ],
      "Resource": "*",
      "Condition": {
        "StringEquals": {
          "cloudwatch:namespace": "AWS/Glue/ZeroETL"
        }
      },
      "Effect": "Allow"
    },
    {
      "Action": [
        "logs:CreateLogGroup",
        "logs:CreateLogStream",
```

```
        "logs:PutLogEvents"
      ],
      "Resource": "*",
      "Effect": "Allow"
    }
  ]
}
```

Agregue la siguiente política de confianza en el rol de IAM de destino para permitir que el servicio AWS Glue asuma el rol:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Principal": {
        "Service": "glue.amazonaws.com"
      },
      "Action": "sts:AssumeRole"
    }
  ]
}
```

> **Note**
>
> Asegúrese de que no haya una declaración DENY explícita para este rol de IAM de destino en la política de recursos del bucket de las tablas de S3. Una declaración DENY explícita anularía cualquier permiso ALLOW e impediría que la integración funcionara correctamente.

Configuración de un catálogo de Amazon SageMaker Lakehouse con el almacenamiento administrado de Amazon Redshift

En esta sección se describen los requisitos previos y los pasos de configuración para configurar un catálogo de Amazon SageMaker Lakehouse con almacenamiento administrado de Amazon Redshift (RMS) como destino para la integración sin ETL.

Requisitos previos para configurar una integración

Antes de crear una integración sin ETL con un catálogo de Amazon SageMaker Lakehouse mediante el uso del almacenamiento administrado de Redshift, debe completar las siguientes tareas de configuración:

1. Configurar un grupo de trabajo sin servidor o clúster de Amazon Redshift
2. Registrar la integración de Amazon Redshift con Lake Formation
3. Crear un catálogo administrado en Lake Formation
4. Configurar los permisos de IAM

Configuración del almacenamiento administrado de Amazon Redshift

Para configurar un almacenamiento administrado de Amazon Redshift para su integración sin ETL:

1. Cree o utilice un grupo de trabajo sin servidor o un clúster de Amazon Redshift existente. Asegúrese de que el clúster o el grupo de trabajo de Amazon Redshift de destino tenga el parámetro `enable_case_sensitive_identifier` activado para que la integración se complete correctamente. Para obtener más información sobre cómo habilitar la distinción entre mayúsculas y minúsculas, consulte Turn on case sensitivity for your data warehouse en la Guía de administración de Amazon Redshift.
2. Registre una integración de Redshift en el catálogo de AWS Lake Formation. Consulte Registering Amazon Redshift clusters and namespaces to the AWS Glue Data Catalog.
3. Cree un catálogo federado o administrado en AWS Lake Formation. Para obtener más información, consulte:
   - Bringing Amazon Redshift data into the AWS Glue Data Catalog
   - Creating an Amazon Redshift managed catalog in the AWS Glue Data Catalog
4. Configure los permisos de IAM para el rol de destino. El rol necesita permisos para acceder a los recursos de Redshift y Lake Formation. El rol debe tener, como mínimo, lo siguiente:

- Permisos para acceder al clúster o al grupo de trabajo de Redshift
- Permisos para acceder al catálogo de Lake Formation
- Permisos para crear y administrar tablas en el catálogo
- Permisos de los registros de CloudWatch y CloudWatch para la supervisión

Tras configurar el catálogo de Amazon SageMaker Lakehouse con el almacenamiento administrado de Amazon Redshift, puede ir a Configuración de la integración con su destino para completar la configuración de la integración.

Configuración de un destino de almacén de datos de Amazon Redshift

En esta sección se describen los requisitos previos y los pasos de configuración para configurar un almacén de datos de Amazon Redshift como destino para su integración sin ETL.

Requisitos previos para configurar una integración

Antes de crear una integración sin ETL con un destino del almacén de datos de Amazon Redshift, debe completar las siguientes tareas de configuración:

1. Configurar un grupo de trabajo sin servidor o clúster de Amazon Redshift
2. Configurar la distinción entre mayúsculas y minúsculas
3. Configurar los permisos de IAM

Configuración del almacén de datos de Amazon Redshift

Para configurar un almacén de datos de Amazon Redshift en su integración sin ETL:

1. Navegue a la consola de Amazon Redshift y haga clic en Crear clúster o use un clúster existente. Para Amazon Redshift sin servidor, haga clic en Crear grupo de trabajo.
2. Si va a crear un clúster nuevo, elija un tamaño de clúster adecuado y asegúrese de que el clúster esté cifrado. Para el servicio sin servidor, ajuste la configuración del grupo de trabajo según sus requisitos.
3. Asegúrese de que el clúster o el grupo de trabajo de Amazon Redshift de destino tenga el parámetro `enable_case_sensitive_identifier` activado para que la integración se complete correctamente. Para obtener más información sobre cómo habilitar la distinción entre mayúsculas y minúsculas, consulte Turn on case sensitivity for your data warehouse en la Guía de administración de Amazon Redshift.

4. Configure los permisos de IAM para permitir que la integración sin ETL acceda a su almacén de datos de Amazon Redshift. Deberá crear un rol de IAM con los siguientes permisos:
   - Permisos para acceder al clúster o al grupo de trabajo de Amazon Redshift
   - Permisos para crear y administrar bases de datos y tablas en Amazon Redshift
   - Permisos de los registros de CloudWatch y Amazon CloudWatch para la supervisión
5. Una vez completada la configuración del grupo de trabajo o clúster de Amazon Redshift, debe configurar el almacén de datos para las integraciones sin ETL. Para obtener más información, consulte Introducción a las integraciones sin ETL en la Guía de administración de Amazon Redshift.

> **Note**
>
> Cuando se utiliza un almacén de datos de Amazon Redshift como destino, la integración crea un esquema en la base de datos especificada para almacenar los datos replicados. El nombre del esquema proviene del nombre de la integración.

Tras configurar el almacén de datos de Amazon Redshift, puede ir a Configuración de la integración con su destino para completar la configuración de la integración.

Configuración de la integración con su destino

Tras configurar los recursos de destino, seleccionar la conexión y especificar un rol de IAM de origen, siga estos pasos para completar la configuración de la integración:

1. Especifique el destino que ha configurado en los pasos anteriores.
2. Seleccione la opción de AWS Glue Solucionarlo por mí. Para el destino Amazon Redshift, hará lo siguiente:
   - Aplicar una entidad principal autorizada al grupo de trabajo sin servidor o al clúster de Amazon Redshift.
   - Aplicar un ARN de origen de AWS Glue autorizado al grupo de trabajo sin servidor o al clúster de Amazon Redshift.
   - Asociar un nuevo grupo de parámetros con `enable_case_sensitive_identifier = true`.

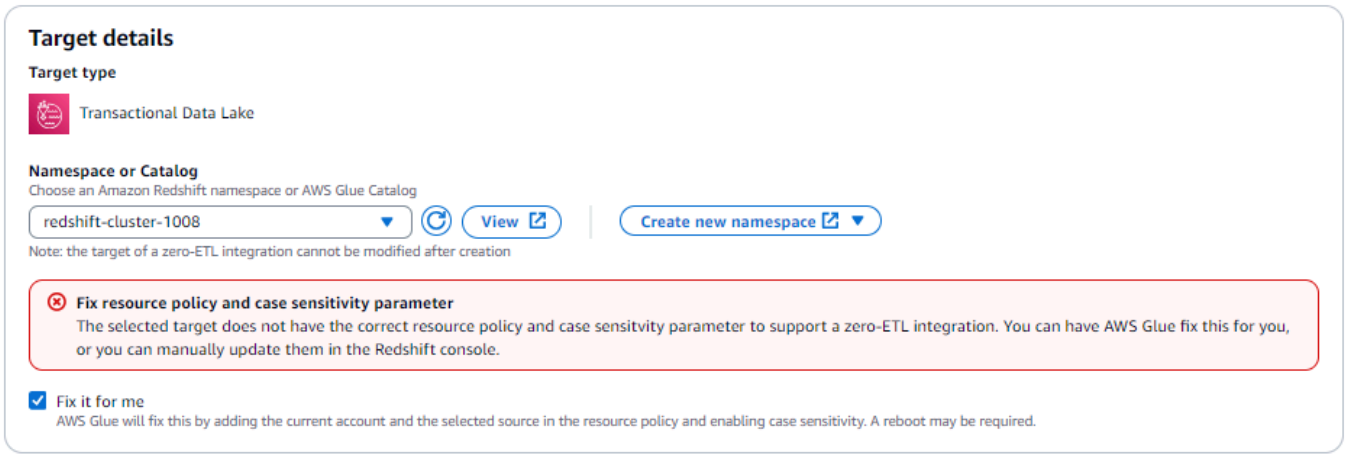

3. Proporcione el nombre de la integración y elija Crear e iniciar la integración.
4. Una vez que la integración esté activa, vaya a la página de detalles de la integración y seleccione Crear una base de datos a partir de la integración.
5. Por último, puede ir al editor de consultas de Redshift y conectarse a su base de datos para validar la instantánea y los datos incrementales.

> **Note**
>
> Recuerde que solo puede utilizar caracteres alfanuméricos en minúscula y guiones bajos en el nombre del espacio de nombres o del catálogo. Esto es diferente de lo que permite el catálogo de datos de AWS Glue al crear una base de datos con cualquier nombre (incluidos caracteres especiales).

Guía de desanidamiento de esquemas y especificación de particiones

Cuando se trabaja con orígenes de datos NoSQL, como DynamoDB y aplicaciones SaaS, los datos suelen presentar desafíos únicos para el análisis:

1. Los registros de la misma tabla pueden tener un esquema diferente
2. Los registros anidados de la misma tabla se pueden representar de forma diferente
3. Las estructuras anidadas complejas, como los mapas y las matrices, requieren una transformación para que las consultas sean eficientes

4. Se necesita una organización de datos óptima para garantizar el rendimiento de las consultas a escala

Las integraciones sin ETL de AWS Glue abordan estos desafíos a través de dos potentes capacidades:

- Desanidamiento de esquemas: Aplana automáticamente estructuras de datos anidadas complejas en formatos compatibles con el análisis, con niveles de desanidamiento configurables para equilibrar la conservación de la estructura de datos y optimizarla a fin de simplificar las consultas.
- Particionamiento de datos: Organiza los datos en particiones lógicas en función de columnas específicas o dimensiones basadas en el tiempo, lo que mejora el rendimiento de las consultas y reduce los costos, ya que permite la eliminación de particiones durante la ejecución de las consultas.

Para poder consultar dichos orígenes de datos de forma eficaz, las integraciones sin ETL de AWS Glue proporciona esquemas listos para usar de partición y manipulación de esquemas para los datos de origen que se replican en la base de datos de destino de AWS Glue. Puede configurar los ajustes de partición y desanidamiento de esquemas para cada tabla a través de la API CreateIntegrationTableProperty, lo que permite un control preciso de cómo se estructuran y organizan los datos para las cargas de trabajo de análisis.

Comportamiento predeterminado de desanidamiento y partición

1. Las integraciones sin ETL de AWS Glue usa de forma predeterminada FULL Unnest cuando no se proporcionan opciones de desanidamiento para la tabla de destino
2. Las integraciones sin ETL de AWSGlue utiliza de forma predeterminada la partición de buckets cuando no se proporcionan especificaciones de partición para la tabla de destino

Desanidamiento de esquemas

Cuando integra servicios de análisis a través de la integración sin ETL, puede elegir cómo se representan las estructuras anidadas en las tablas de destino. AWS La integración sin ETL de Glue proporciona opciones de desanidamiento de esquemas para aplanar estructuras de datos complejas en formatos más sencillos para el análisis.

Opciones de desanidamiento

Cuando crea una integración sin ETL con un origen, puede elegir entre las siguientes opciones de desanidamiento. Estas opciones corresponden a valores de enumeración específicos que utilizará cuando llame a la API CreateIntegrationTableProperty.

Sin desanidamiento (predeterminado)

Valor de la API: **`NO_UNNEST`**

Conserva la estructura anidada original de los elementos de DynamoDB. Los mapas y las listas se almacenan como columnas estructuradas en el destino.

Ideal para: conservar la estructura exacta de los datos de DynamoDB cuando las herramientas de análisis pueden trabajar con datos anidados.

Desanidar un nivel

Valor de la API: **`TOP_LEVEL`**

Aplana el nivel superior de los mapas anidados en columnas individuales. Las estructuras de listas permanecen anidadas.

Ideal para: equilibrar la conservación de la estructura de datos y la simplicidad de las consultas cuando los elementos de DynamoDB tienen un esquema coherente.

Desanidar todos los niveles

Valor de la API: **`FULL`**

Aplana de forma recursiva todas las estructuras anidadas (mapas y listas) en columnas individuales con notación de puntos para los nombres.

Ideal para: maximizar la simplicidad de las consultas cuando se trabaja con estructuras muy anidadas y herramientas de análisis que prefieren esquemas planos.

> **Note**
>
> El desanidamiento completo puede generar tablas muy anchas con muchas columnas si los datos de DynamoDB tienen estructuras variables o muy anidadas.

Example Uso de opciones de desanidamiento en la API

Cuando configure el desanidamiento de esquemas mediante la API CreateIntegrationTableProperty, especifique la opción de desanidamiento en el parámetro UnnestSpec:

```
aws glue create-integration-table-property
  --resource-arn "arn:aws:glue:us-east-1:123456789012:integration/my-integration"
  --table-name "my-table"
  --cli-input-json '{
      "TargetTableConfig": {
          "UnnestSpec": "FULL",
          "TargetTableName": "my-target-table",
      }
  }'
```

Ejemplos de desanidamiento

Considere un elemento de DynamoDB con la siguiente estructura:

```
{
  "ProductId": "P12345",
  "ProductDetails": {
    "Name": "Smartphone",
    "Brand": "TechCo",
    "Specifications": {
      "Color": "Black",
      "Storage": "128GB"
    }
  },
  "Reviews": [
    {
      "Rating": 5,
      "Comment": "Great product!"
    },
    {
      "Rating": 4,
      "Comment": "Good value."
    }
  ]
}
```

No hay ejemplos de desanidamiento

Si no se realiza el desanidamiento, la tabla de destino tendría las siguientes columnas:

- ProductId (cadena)
- ProductDetails (estructura)
- Reviews (matriz de estructuras)

Las consultas necesitarían usar patrones de acceso a estructuras y matrices:

```
SELECT
  ProductId,
  ProductDetails.Name,
  ProductDetails.Specifications.Color
FROM product_table;
```

Ejemplo de desanidamiento de un nivel

Si se realiza el desanidamiento de un nivel, la tabla de destino tendría las siguientes columnas:

- ProductId (cadena)
- ProductDetails_Name (cadena)
- ProductDetails_Brand (cadena)
- ProductDetails_Specifications (estructura)
- Reviews (matriz de estructuras)

Las consultas se simplificarían para el primer nivel:

```
SELECT
  ProductId,
  ProductDetails_Name,
  ProductDetails_Specifications.Color
FROM product_table;
```

Ejemplo de desanidamiento en todos los niveles

Si se realiza el desanidamiento de todos los niveles, la tabla de destino tendría los siguientes valores y columnas:

Nombre de columna (Tipo)	Valor
ProductId (cadena)	P12345
ProductDetails_Name (cadena)	Smartphone
ProductDetails_Brand (cadena)	TechCo
ProductDetails_Specifications_Color (cadena)	Black
ProductDetails_Specifications_Storage (cadena)	128 GB
Reviews_0_Rating (número)	5
Reviews_0_Comment (cadena)	¡Un gran producto!
Reviews_1_Rating (número)	4
Reviews_1_Comment (cadena)	Buena relación calidad-precio.

Las consultas quedarían completamente aplanadas:

```
SELECT
  ProductId,
  ProductDetails_Name,
  ProductDetails_Specifications_Color
FROM product_table;
```

Particiones de datos

¿Qué es la partición de datos?

La partición de datos es una técnica que divide grandes conjuntos de datos en segmentos más pequeños y gestionables denominados particiones. En el contexto de las integraciones sin ETL de AWS Glue, la partición organiza los datos en la ubicación de destino en función de valores de columna específicos o de las transformaciones de esos valores.

Ventajas de la partición de datos

La partición efectiva de los datos ofrece varios beneficios clave para las cargas de trabajo de análisis:

- Mayor rendimiento de las consultas: Las consultas pueden omitir particiones irrelevantes (poda de particiones), lo que reduce la cantidad de datos que deben analizarse.
- Costos reducidos: Mediante el análisis de datos, puede reducir los costos informáticos y de E/S de sus consultas de análisis.
- Mayor escalabilidad: La partición permite el procesamiento paralelo de los segmentos de datos, lo que permite un escalado más eficiente de las cargas de trabajo de análisis.
- Gestión simplificada del ciclo de vida de los datos: Puede gestionar las políticas de retención a nivel de partición, lo que facilita el archivado o la eliminación de datos antiguos.

Conceptos clave relacionados con la partición

Columnas de partición

Columnas en sus datos que se utilizan para determinar cómo se organizan los registros en particiones. Las columnas de partición efectivas deben alinearse con los patrones de consulta comunes y tener la cardinalidad adecuada.

Funciones de partición

Las transformaciones que se aplican a los valores de las columnas de partición para crear los límites de partición reales. Algunos ejemplos son la identidad (usando el valor bruto) y funciones basadas en el tiempo (año, mes, día, hora).

Utilizar la poda de particiones

El proceso en el que el motor de consultas identifica y omite las particiones que no contienen datos relevantes para una consulta, lo que mejora considerablemente el rendimiento.

Grado de detalle de la partición

El nivel de detalle con el que se particionan los datos. Una granularidad más fina (más particiones) puede mejorar el rendimiento de las consultas, pero puede aumentar la sobrecarga de metadatos. Una granularidad más gruesa (menos particiones) reduce la sobrecarga de metadatos, pero puede resultar en el análisis de más datos de los necesarios.

Partición en integraciones sin ETL de AWS Glue

Las integraciones sin ETL de AWS Glue utilizan el formato de tabla Apache Iceberg, que proporciona capacidades avanzadas de partición. Cuando crea una integración sin ETL, puede hacer lo siguiente:

- Utilizar estrategias de partición predeterminadas optimizadas para su origen de datos
- Definir especificaciones de partición personalizadas adaptadas a sus patrones de consulta
- Aplicar transformaciones a las columnas de partición (en especial, esto es útil para particiones basadas en marcas de tiempo)
- Combinar varias estrategias de partición para crear particiones de varios niveles

Las configuraciones de partición se especifican a través de la API de `CreateIntegrationTableProperty` cuando se configura la integración sin ETL. Una vez configurada, AWS Glue aplica automáticamente estas estrategias de partición para organizar sus datos en la ubicación de destino.

Referencia de la API de especificación de particiones

Utilice los siguientes parámetros en la API CreateIntegrationTableProperties para configurar el particionamiento:

PartitionSpec

Una matriz de especificaciones de partición que define cómo se particionan los datos en la ubicación de destino.

```
{
  "partitionSpec": [
    {
      "fieldName": "timestamp_col",
      "functionSpec": "month",
      "conversionSpec": "epoch_milli"
    },
    {
      "fieldName": "category",
      "functionSpec": "identity"
    }
  ]
}
```

FieldName

Cadena UTF-8 (de 1 a 128 bytes) que especifica el nombre de la columna que se va a utilizar para el particionamiento.

FunctionSpec

Especifica la función de particionamiento. Valores válidos:

- `identity`: Utiliza los valores de origen directamente sin transformarlos
- `year`: Extrae el año de los valores de marca de tiempo (por ejemplo, 2023)
- `month`: Extrae el mes de los valores de marca de tiempo (por ejemplo, 2023-01)
- `day`: Extrae el día de los valores de la marca de tiempo (por ejemplo, 2023-01-15)
- `hour`: Extrae la hora de los valores de la marca de tiempo (por ejemplo, 2023-01-15-14)

> **Note**
>
> Las funciones basadas en el tiempo (`year`, `month`, `day`, `hour`) requieren que el parámetro `ConversionSpec` especifique el formato de la marca de tiempo de origen.

ConversionSpec

Cadena UTF-8 que especifica el formato de marca de tiempo de los datos de origen. Los valores válidos son:

- `epoch_sec`: marca de tiempo en formato de época Unix (segundos)
- `epoch_milli`: marca de tiempo en formato de época Unix (milisegundos)
- `iso`: marca de tiempo en formato ISO 8601

Estrategias de partición

Particionamiento predeterminado

Cuando no se especifica una columna de partición, la integración sin ETL de AWS Glue aplica estrategias de partición predeterminadas optimizadas para su origen de datos:

- Partición basada en la clave principal: En el caso de los orígenes con claves principales (como las tablas de DynamoDB), la integración sin ETL de AWS Glue divide automáticamente los datos mediante la clave principal con agrupamientos para evitar la explosión de la partición.

La partición predeterminada está diseñada para funcionar bien con los patrones de consulta más comunes sin necesidad de una configuración manual. Sin embargo, para patrones de consulta o requisitos de rendimiento específicos, es posible que desee definir estrategias de partición personalizadas.

Estrategias de partición definidas por el usuario

La integración sin ETL de AWS Glue le permite definir estrategias de partición personalizadas con el parámetro `PartitionSpec`. Puede especificar una o más columnas de partición y aplicar diferentes funciones de partición a cada columna.

La partición de identidad utiliza los valores sin procesar de una columna para crear particiones. Esta estrategia es útil para las columnas con cardinalidad baja a media, como los campos de categoría, región o estado.

Example Ejemplo de partición de identidad

```
{
  "partitionSpec": [
    {
      "fieldName": "category",
      "functionSpec": "identity"
    }
  ]
}
```

Esto crea particiones independientes para cada valor único de la columna “categoría”.

> **Warning**
>
> Evite el uso de la partición de identidad con columnas de alta cardinalidad (como claves principales o marcas de tiempo), ya que puede provocar una explosión de particiones, lo que degradaría el rendimiento y aumentaría la sobrecarga de metadatos.

La partición basada en el tiempo organiza los datos según los valores de la marca de tiempo en diferentes granularidades (año, mes, día u hora). Esta estrategia es ideal para datos de serie temporal y permite realizar consultas eficientes en intervalos de tiempo.

Mediante el uso de la partición basada en el tiempo, la integración sin ETL e AWS Glue puede convertir automáticamente varios formatos de marcas de tiempo a un formato estandarizado antes de aplicar la función de partición. Esta conversión se especifica con el parámetro `ConversionSpec`.

Example Ejemplo de partición basada en el tiempo

```
{
  "partitionSpec": [
    {
      "fieldName": "created_at",
      "functionSpec": "month",
      "conversionSpec": "epoch_milli"
    }
  ]
}
```

Esto divide los datos por mes en función de la columna “created_at”, que contiene las marcas de tiempo en formato de época Unix en milisegundos.

La integración sin ETL de AWS Glue admite las siguientes funciones de partición basadas en el tiempo:

- año: Divide los datos por año (por ejemplo, 2023, 2024)
- mes: Divide los datos por mes (por ejemplo, 2023-01, 2023-02)
- día: Divide los datos por día (por ejemplo, 2023-01-01, 2023-01-02)
- hora: Divide los datos por hora (por ejemplo, 2023-01-01-01, 2023-01-01-02)

La integración sin ETL de AWS Glue admite los siguientes formatos de marca de tiempo a través del parámetro: `ConversionSpec`

- epoch_sec: Marcas de tiempo en formato de época Unix en segundos
- epoch_milli: Marcas de tiempo en formato de época Unix en milisegundos
- iso: Marcas de tiempo en formato ISO 8601

> **Note**
>
> Los valores de las columnas originales permanecerán sin cambios en los datos de origen. AWS Glue solo transforma los valores de las columnas de partición al tipo marca de tiempo

en la tabla de la base de datos de destino. Las transformaciones solo se aplican al proceso de partición.

La partición de varios niveles combina varias estrategias de partición para crear un esquema de partición jerárquico. Esto resulta útil para optimizar diferentes tipos de consultas en el mismo conjunto de datos.

Example Ejemplo de partición de varios niveles

```
{
  "partitionSpec": [
    {
      "fieldName": "created_at",
      "functionSpec": "month",
      "conversionSpec": "iso"
    },
    {
      "fieldName": "region",
      "functionSpec": "identity"
    }
  ]
}
```

Esto crea un esquema de partición de tres niveles: primero por mes (desde la columna “created_at”), y luego por región. Esto permite realizar consultas eficientes que se filtran por intervalos de fechas, regiones específicas o cualquier combinación de estas dimensiones.

Cuando diseñe esquemas de partición de varios niveles, tenga en cuenta lo siguiente:

- Coloque las columnas de mayor selectividad en primer lugar en la jerarquía de particiones
- Equilibre la granularidad de la partición con la cantidad de particiones
- Alinee el esquema de particiones con los patrones de consulta más comunes

Prácticas recomendadas

Selección de la columna de partición

- No utilice columnas de alta cardinalidad con la función de partición `identity`. El uso de columnas de alta cardinalidad con particionamiento por identidad crea muchas particiones pequeñas, lo

que puede degradar significativamente el rendimiento de la ingestión. Las columnas de alta cardinalidad pueden incluir:

- Claves principales
- Campos de marca de tiempo (como `LastModifiedTimestamp`, `CreatedDate`)
- Marcas de tiempo generadas por el sistema

- No seleccione varias particiones de marca de tiempo en la misma columna. Por ejemplo:

```
"partitionSpec": [
      {"fieldName": "col1", "functionSpec": "year", "conversionSpec" :
 "epoch_milli"},
      {"fieldName": "col1", "functionSpec": "month", "conversionSpec" :
 "epoch_milli"},
      {"fieldName": "col1", "functionSpec": "day", "conversionSpec" : "epoch_milli"},
      {"fieldName": "col1", "functionSpec": "hour", "conversionSpec" : "epoch_milli"}
]
```

Selección de FunctionSpec y ConversionSpec para particionamiento

- Especifique el ConversionSpec correcto (epoch_sec | epoch_milli | iso) que representa el formato de los valores de columna seleccionados para el particionamiento basado en marca de tiempo al usar funciones de partición basadas en marca de tiempo. AWS Glue sin ETL usa este parámetro para transformar correctamente los datos de origen al formato de marca de tiempo antes de aplicar la partición.
- Utilice el nivel de detalle adecuado (año/mes/día/hora) en función del volumen de datos.
- Tenga en cuenta las implicaciones de la zona horaria al utilizar las marcas de tiempo en formato ISO. AWS Glue sin ETL completa todos los valores de registro de la columna de marca de tiempo elegida con la zona horaria UTC.

Gestión de errores

Estado NEEDS_ATTENTION

Una integración pasa al estado NEEDS_ATTENTION cuando:

- Las columnas de partición especificadas no existen en el origen
- La conversión a marca de tiempo falla en las columnas de partición

Limitaciones

Limitaciones de partición

- Las especificaciones de las particiones no pueden modificarse una vez que se crea la integración. Para usar una estrategia de partición diferente, debe crear una nueva integración.
- La cantidad máxima de columnas de partición está limitada a 10.

Limitaciones de integración entre cuentas

- Durante la creación de integraciones entre cuentas, la Consola de AWS Glue tiene una limitación que no le permite invocar la API CreateIntegrationTableProperty para configurar UnnestSpec y PartitionSpec para las tablas de destino de AWS Glue que están alojadas en la cuenta donde no existe la integración.

  Solución: El cliente debe invocar la API CreateIntegrationTableProperty desde la cuenta en la que se encuentra la base de datos de destino.

Limitaciones de múltiples integraciones

- Si necesita replicar la misma fuente con diferentes configuraciones de desanidamiento o partición del esquema, es necesario crear una nueva base de datos AWS Glue para cada integración por separado. Posteriormente, invoque CreateIntegrationTableProperty para cada tabla de la base de datos AWS Glue individual con las configuraciones de desanidamiento y partición del esquema deseadas.

Tareas de integración comunes

Creación de una integración

En esta sección se describen los pasos generales para crear una integración. En este ejemplo, se utiliza Amazon DynamoDB como origen.

1. En la página de inicio de la consola de AWS Glue, seleccione integraciones sin ETL.
2. Puede ver todas sus integraciones en la página de inicio de integraciones sin ETL. Para crear una nueva integración, seleccione Crear una integración sin ETL.

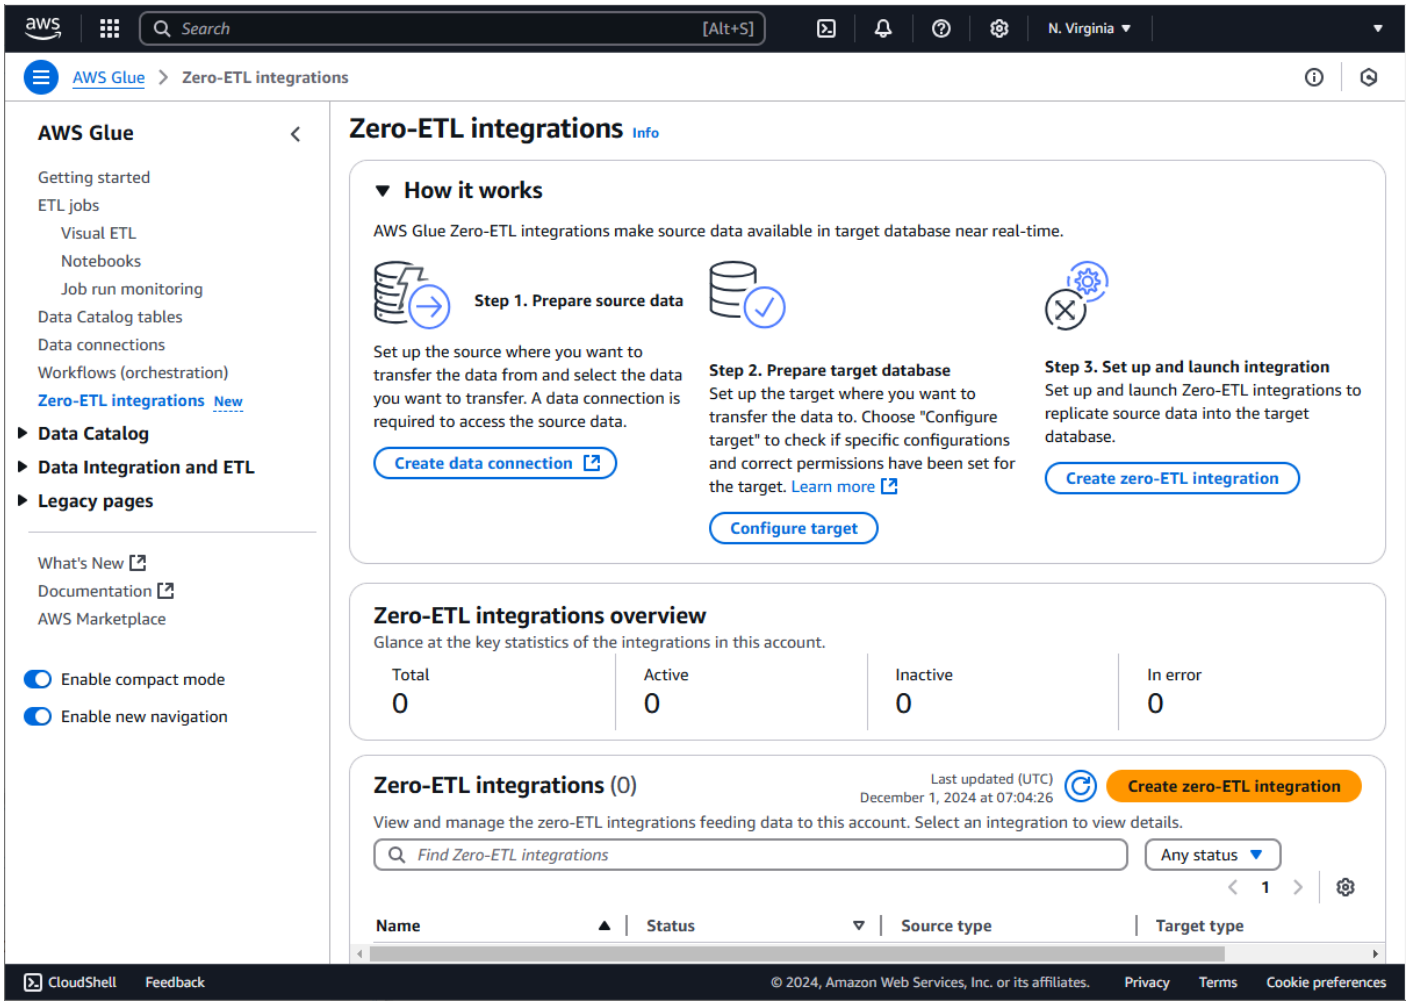

3. Se le solicitará que seleccione un tipo de origen. Seleccione el origen y haga clic en Siguiente. Consulte las secciones de configuración del origen para ver los orígenes de integración de SaaS.
4. En la página Configurar origen y destino, seleccione las tablas o entidades que desee replicar. En Amazon DynamoDB, asegúrese de que las políticas de PITR y RBAC estén configuradas.
5. Especifique su destino de integración:
   - Para un destino de catálogo de datos de AWS Glue, seleccione la base de datos de AWS Glue en la que desee replicar los datos.
   - Para un destino de almacenamiento de datos de Amazon Redshift, seleccione el espacio de nombres del clúster de Redshift o el espacio de nombres del grupo de trabajo de Redshift sin servidor.

   Para obtener más información, consulte Configuración de la integración con su destino.
6. Indique el rol de IAM de destino que creó en los requisitos previos.

7. Si desea configurar una clave KMS de destino opcional para los datos que se almacenan en el destino, proporcione una clave KMS habilitada. Del mismo modo, si desea configurar una conexión de red de destino, seleccione una conexión de AWS Glue.
8. El botón Fijar destino configura algunos de los pasos de la sección de requisitos previos de esta documentación. Es decir, 1) proporcionará una política RBAC para el catálogo y 2) si no se proporciona un URI de Amazon S3, generará uno para usted; de lo contrario, utilizará el URI proporcionado.
9. En el caso de las integraciones con un objetivo de almacenamiento de datos de Redshift:
10. En la sección Configuración de salida de la página Configurar origen y destino, seleccione la opción para quitar del anidamiento el esquema que desee para sus datos en el destino. Si desea utilizar las claves de partición del cliente para sus datos, seleccione Especificar claves de partición personalizadas y proporcione hasta 10 claves. De lo contrario, simplemente puede usar las claves de partición asignadas a la tabla de DynamoDB que se está replicando.
11. En la sección Seguridad y cifrado de datos, puede proporcionar una clave KMS que se utilizará en el proceso intermedio de replicación de los datos en el destino. De lo contrario, se utilizará una clave KMS administrada por AWS. Actualmente, solo se admite una configuración de replicación de 15 minutos. Introduzca un nombre para la integración sin ETL en los detalles de la integración.
12. Revise y asegúrese de que todos los detalles proporcionados sean correctos. Haga clic en Crear e iniciar la integración una vez que se haya confirmado todo.
13. En la página de inicio Sin ETL, puede seleccionar la integración que haya creado para ver los detalles de esta. El campo “Estado” indica el estado de la integración.

Modificación de una integración

Puede modificar una integración existente.

1. Seleccione Editar en la esquina superior derecha de la página de detalles de la integración.
2. En la página Editar origen y destino, puede cambiar el rol de IAM de destino y la conexión de red de destino. El resto de campos no se pueden editar tras la creación de la integración. Haga clic en Next (Siguiente).
3. También puede editar el nombre y la descripción de la integración en la página Editar integración y configuración. Haga clic en Next (Siguiente).
4. Revise las modificaciones y, una vez confirmadas, haga clic en Actualizar integración.

Eliminación de una integración

La eliminación es un estado terminal de una integración. Una vez que se elimina, la integración no se puede reactivar. Al eliminar una integración, se borran todos los metadatos internos y cualquier dato intermedio almacenado.

Durante este proceso, se finaliza cualquier tarea en ejecución que consista en escribir datos en una tabla de destino. AWS Glue no eliminará ni limpiará la base de datos de AWS Glue de destino (en el catálogo de datos) ni los datos asociados en el bucket de Amazon S3 de su cuenta. Si es necesario, debe eliminarlos de forma explícita.

Para eliminar una integración:

1. En la página de detalles de la integración, haga clic en Eliminar.
2. Introduzca “Eliminar” y haga clic en Eliminar. Nota: Esta es una acción irreversible.
3. En la página de detalles de la integración, el estado muestra el mensaje “Eliminando”. Una vez que se elimine realmente la integración, dejará de aparecer en la página de inicio de la integración sin ETL.

Creación de integraciones mediante las API

Puede usar las siguientes API para crear y administrar integraciones sin ETL en AWS Glue:

- CreateIntegration
- CreateIntegrationTableProperties
- CreateIntegrationResourceProperty
- UpdateIntegrationTableProperties
- UpdateIntegrationResourceProperty
- ModifyingIntegration
- DeleteIntegration
- DeleteIntegrationTableProperties
- DescribeIntegrations
- DescribeInboundIntegrations
- GetIntegrationTableProperties
- GetIntegrationResourceProperty

Para obtener más información, consulte API de integración en AWS Glue.

Supervisión de una integración

Estados de integración

Los siguientes estados de integración describen la integración:

- `Creating`: la integración se está creando.
- `Active`: la integración envía datos transaccionales al destino.
- `Modifying`: la integración se está modificando.
- `Syncing`: la integración detectó un error recuperable y vuelve a propagar los datos.
- `Needs attention`: la integración detectó un evento o error que requiere la intervención manual para su resolución. Para solucionar el problema, siga las instrucciones del mensaje de error que aparece en los detalles de la integración.
- `Failed`: la integración detectó un evento o error irrecuperable. Debe eliminar y volver a crear la integración.
- `Deleting`: la integración se está eliminando.

Visualización de los registros de Amazon CloudWatch para una integración

Las integraciones sin ETL de AWS Glue generan registros de Amazon CloudWatch para obtener visibilidad del movimiento de datos. Los eventos de registro relacionados con cada ingesta exitosa o cualquier fallo debido a registros de datos problemáticos en el origen, errores de escritura de datos por cambios en el esquema o permisos insuficientes se envían a un grupo de registros predeterminado creado en la cuenta del cliente.

Para cada integración creada, los eventos de registro de esa integración se recopilarán en `/aws-glue/zeroETL-integrations/logs/` dentro de Amazon CloudWatch. Dentro del grupo de registro, los mensajes de registro se dividirán en flujos de registros. Cada integración creada tiene un flujo de registro dedicado donde se escriben todos los registros de esa integración. Por ejemplo, los registros de una integración con IntegrationArn `arn:aws:glue:us-east-1:123456789012:integration:03cabe77-79e7-4b7a-b3da-8c160bea6bbf` se pueden encontrar en /aws-glue/zeroETL-integrations/logs/03cabe77-79e7-4b7a-b3da-8c160bea6bbf. {IntegrationId} se puede obtener a partir de {integrationArn}, generado cuando se crea una integración.

> **Note**
>
> En un escenario de uso entre cuentas, los registros de procesamiento del origen se generan en la cuenta de origen donde existe la integración, y los registros de procesamiento del destino se generan en la cuenta de destino donde se encuentra la base de datos de destino.

Permisos de IAM necesarios para habilitar el registro

Al crear la integración, los siguientes permisos de IAM son necesarios para los roles de origen y destino a fin de habilitar el registro en CloudWatch para una integración. Las integraciones sin ETL de AWS Glue utilizan estos permisos asignados en los roles de origen y destino para enviar registros de CloudWatch a las cuentas de los clientes.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "logs:CreateLogGroup",
        "logs:CreateLogStream",
        "logs:PutLogEvents"
      ],
      "Resource": [
        "*"
      ]
    }
  ]
}
```

Mensajes de registro

Formato de registro: las integraciones sin ETL generan cuatro tipos de mensajes de registro:

```
// Ingestion started
{
```

```
"integrationArn": "arn:aws:glue:us-east-2:123456789012:integration/1a012bba-123a-1bba-
ab1c-173de3b12345",
...
    "messageType": "IngestionStarted",
    "details": {
        "tableName": "testDDBTable",
        "message": "Ingestion Job started"
    }
}
// Data processing stats on successful table ingestion
{
...
    "messageType": "IngestionProcessingStats",
    "details": {
        "tableName": "testDDBTable",
        "insert_count": 100,
        "update_count": 10,
        "delete_count": 10
    }
}
// Ingestion failure logs for failed table-processing
{
...
    "messageType": "IngestionFailed",
    "details": {
        "tableName": "testDDBTable",
        "errorMessage": "Failed to ingest data with error: Target Glue database not
 found.",
        "error_code" : "client_error"
    }
}
// Ingestion completed notification with lastSyncedTimestamp
{
...
    "messageType": "IngestionCompleted",
    "details": {
        "tableName": "testDDBTable",
        "message": "Ingestion Job completed"
        "lastSyncedTimestamp": "1132344255745"
    }
}
```

Visualización de métricas de Amazon CloudWatch para una integración

Una vez que se complete la integración, podrá ver estas métricas de Amazon CloudWatch generadas en su cuenta para cada ejecución de trabajo de AWS Glue:

Espacio de nombres de métricas de CloudWatch: “AWS/Glue/ZeroETL”

Dimensiones de las métricas:

- `integrationArn`
- `loadType`
- `tableName`

Nombres de métricas:

- `InsertCount`: número de registros insertados en la tabla Iceberg de destino.
- `UpdateCount`: número de registros actualizados en la tabla Iceberg de destino.
- `DeleteCount`: número de registros eliminados de la tabla Iceberg de destino.
- `IngestionSucceeded`: cuente 1, si la ingestión se realizó correctamente para la integración.
- `IngestionFailed`: cuente 1, si la ingestión no se realizó correctamente para la integración.
- `LastSyncTimestamp`: marca de tiempo hasta la cual se sincronizó el origen con el destino.

Administración de notificaciones de eventos con Amazon EventBridge

Las integraciones sin ETL utilizan Amazon EventBridge para administrar notificaciones de eventos y mantenerlo informado sobre los cambios en las integraciones. Amazon EventBridge es un servicio conductor de eventos sin servidor que se puede utilizar para conectar las aplicaciones con datos de varios orígenes. En este caso, el origen de eventos es AWS Glue. Los eventos, que son cambios supervisados en un entorno, se envían automáticamente a EventBridge desde AWS Glue. Los eventos se envían casi en tiempo real.

EventBridge proporciona un entorno para escribir reglas de eventos, que pueden especificar las acciones que se deben realizar para eventos específicos. También puede configurar destinos, que son recursos a los que EventBridge puede enviar un evento. Un objetivo puede incluir un destino de API, un grupo de registro de Amazon CloudWatch, etc. Para obtener más información sobre reglas, consulte Reglas de Amazon EventBridge. Para obtener más información sobre destinos, consulte Destinos de Amazon EventBridge.

Para capturar todas las notificaciones sin ETL, cree una regla en EventBridge que coincida con lo siguiente:

```
{
  "source": [{
    "prefix": "aws.glue-zero-etl“
  }],
  "detail-type": [{
    "prefix": "Glue Zero ETL“
  }]
}
```

En la siguiente tabla se incluyen eventos de integración sin ETL con metadatos adicionales:

Tipo de detalle orientado al cliente	Explicación
Se completó la ingesta sin ETL de AWS Glue	La ejecución individual de una entidad se completó correctamente.
Se produjo un error en la ingesta sin ETL de AWS Glue	La ejecución individual de una entidad no se completó correctamente (ya sea por un error del cliente o del sistema).
Se resincronizó la integración sin ETL de AWS Glue	La integración ha sido resincronizada.
Se produjo un error en la integración sin ETL de AWS Glue	El estado de la integración ha cambiado a FALLIDO debido a un error.
La integración sin ETL de AWS Glue necesita atención	El estado de la integración ha cambiado a REQUIERE ATENCIÓN debido a un error.
Ingesta sin ETL de AWS Glue en curso	La ejecución individual de una entidad avanzó parcialmente hacia su finalización.

Limitaciones

A continuación, se muestran las limitaciones o consideraciones generales sobre las integraciones sin ETL:

- Las propiedades de los recursos tienen una relación uno a uno con el recurso correspondiente. En consecuencia, todas las integraciones creadas con ese recurso deben cumplir con la propiedad de recurso singular. Por lo tanto, la modificación de una propiedad de recurso afectará a todas las integraciones asociadas a ese recurso.
- Las propiedades de las tablas tienen una relación uno a uno con la tabla u objeto correspondiente dentro de un recurso. Como resultado, todas las integraciones que procesan la misma tabla hacia o desde el mismo recurso deben cumplir con la propiedad de tabla singular.
- No se puede cambiar el nombre de una columna en el origen. Si cambia el nombre de una columna, no hay garantía de que AWS Glue realice con precisión la detección del esquema y las repercusiones que esto tenga en la integración no estarán definidas.
- La siguiente consideración se aplica al funcionamiento de la integración con las tablas administradas por AWS Lake Formation: de forma predeterminada, se utiliza la política de IAM/ AWS Glue para administrar las tablas y las bases de datos.
- Si desea utilizar AWS Lake Formation para administrar la creación de tablas en esa base de datos, debe asegurarse de que el rol cuente con los permisos suficientes de Lake Formation para crear, modificar y eliminar la tabla y la base de datos.
- La página de resumen zero-ETL no contiene ninguna métrica en este momento.

A continuación, se muestran las limitaciones específicas del origen de las integraciones sin ETL:

- Las integraciones sin ETL con un origen de SAP OData admiten entidades que comiencen por `Entity0f`. Actualmente, la capacidad de anular la clave principal solo se admite en los objetos SAPOData `Entity0f`. Una vez establecida esta propiedad, no se puede modificar.
- Las integraciones sin ETL de Amazon DynamoDB a Amazon SageMaker Lakehouse (a través de S3) admiten un tamaño máximo de tabla de DynamoDB de 50 TB.
- La tabla de origen de DynamoDB debe estar cifrada con una clave de AWS administrada por el cliente o que sea propiedad de Amazon. El cifrado administrado por Amazon no es compatible con la tabla de DynamoDB de origen.
- SAP OData funciona con un token delta, en el que la combinación de un cliente OAuth más una entidad, o la autenticación básica más una entidad, solo puede tener un único token delta. Evite utilizar la misma entidad en dos integraciones diferentes con el mismo cliente.
- No se admite el uso de los siguientes entidades o campos de Salesforce en una integración sin ETL con un origen de Salesforce.

```
AccountChangeEvent, AccountContactRoleChangeEvent, AccountHistory, AccountShare,
 ActiveFeatureLicenseMetric, ActivePermSetLicenseMetric, ActiveProfileMetric,
 ActivityFieldHistory, amzsec__asi_Telemetry_Data_Store__ChangeEvent,
 amzsec__asi_Telemetry_Data_Store__History, amzsec__asi_Telemetry_Data_Store__Share,
 amzsec__asi_Telemetry_Job_Log__ChangeEvent, amzsec__asi_Telemetry_Job_Log__History,
 amzsec__asi_Telemetry_Job_Log__Share,
 amzsec__asi_Telemetry_Requirement__ChangeEvent,
 amzsec__asi_Telemetry_Requirement__History,
 amzsec__asi_Telemetry_Requirement__Share, ApexClass, ApexComponent, ApexLog,
 ApexPage, ApexTestQueueItem, ApexTestResult, ApexTrigger, AssetChangeEvent,
 AssetHistory, AssetRelationshipHistory, AssetShare, AssignmentRule,
 AssociatedLocationHistory, AsyncApexJob, AuditTrailFileExportShare,
 AuthorizationFormConsentChangeEvent, AuthorizationFormConsentHistory,
 AuthorizationFormConsentShare, AuthorizationFormDataUseHistory,
 AuthorizationFormDataUseShare, AuthorizationFormHistory, AuthorizationFormShare,
 AuthorizationFormTextHistory, AuthProvider, AuthSession, BatchJobHistory,
 BatchJobPartFailedRecordHistory, BatchJobPartHistory, BatchJobShare,
 BrandTemplate, BriefcaseAssignmentChangeEvent, BriefcaseDefinitionChangeEvent,
 BusinessBrandShare, BusinessHours, BusinessProcess, CalcMatrixColumnRangeHistory,
 CalcProcStepRelationshipHistory, CalculationMatrixColumnHistory,
 CalculationMatrixHistory, CalculationMatrixRowHistory, CalculationMatrixShare,
 CalculationMatrixVersionHistory, CalculationProcedureHistory,
 CalculationProcedureShare, CalculationProcedureStepHistory,
 CalculationProcedureVariableHistory, CalculationProcedureVersionHistory, Calendar,
 CalendarViewShare, CallCenter, CallCoachConfigModifyEvent, CampaignChangeEvent,
 CampaignHistory, CampaignMemberChangeEvent, CampaignMemberStatusChangeEvent,
 CampaignShare, CaseChangeEvent, CaseHistory, CaseHistory2 CaseHistory2ChangeEvent,
 CaseRelatedIssueChangeEvent, CaseRelatedIssueHistory, CaseShare, CaseStatus,
 CaseTeamMember, CaseTeamRole, CaseTeamTemplate, CaseTeamTemplateMember,
 CaseTeamTemplateRecord, CategoryNode, ChangeRequestChangeEvent,
 ChangeRequestHistory, ChangeRequestRelatedIssueChangeEvent,
 ChangeRequestRelatedIssueHistory, ChangeRequestRelatedItemChangeEvent,
 ChangeRequestRelatedItemHistory, ChangeRequestShare, ChatRetirementRdyMetrics,
 ChatterActivity, ClientBrowser, CollaborationGroup, CollaborationGroupMember,
 CollaborationGroupMemberRequest, CollaborationInvitation,
 CommSubscriptionChannelTypeHistory, CommSubscriptionChannelTypeShare,
 CommSubscriptionConsentChangeEvent, CommSubscriptionConsentHistory,
 CommSubscriptionConsentShare, CommSubscriptionHistory, CommSubscriptionShare,
 CommSubscriptionTimingHistory, Community, ConnectedApplication, ContactChangeEvent,
 ContactHistory, ContactPointAddressChangeEvent, ContactPointAddressHistory,
 ContactPointAddressShare, ContactPointConsentChangeEvent,
 ContactPointConsentHistory, ContactPointConsentShare,
 ContactPointEmailChangeEvent, ContactPointEmailHistory, ContactPointEmailShare,
```

```
ContactPointPhoneChangeEvent, ContactPointPhoneHistory, ContactPointPhoneShare,
ContactPointTypeConsentChangeEvent, ContactPointTypeConsentHistory,
ContactPointTypeConsentShare, ContactRequestShare, ContactShare,
ContentDocumentChangeEvent, ContentDocumentHistory, ContentDocumentLink,
ContentDocumentLinkChangeEvent, ContentDocumentSubscription, ContentFolderItem,
ContentFolderLink, ContentFolderMember, ContentNote, ContentNotification,
ContentTagSubscription, ContentUserSubscription, ContentVersionChangeEvent,
ContentVersionComment, ContentVersionHistory, ContentVersionRating,
ContentWorkspace, ContentWorkspaceMember, ContentWorkspacePermission,
ContentWorkspaceSubscription, ContractChangeEvent, ContractHistory,
ContractLineItemChangeEvent, ContractLineItemHistory, ContractStatus,
Conversation, ConversationParticipant, CronJobDetail, CronTrigger, CustomBrand,
CustomBrandAsset, CustomerShare, CustomHttpHeader, DashboardComponent,
DataUseLegalBasisHistory, DataUseLegalBasisShare, DataUsePurposeHistory,
DataUsePurposeShare, DecisionTableRecordset, DeleteEvent, DocumentAttachmentMap,
Domain, DomainSite, DTRecordsetReplicaShare, EmailBounceEvent,
EmailMessageChangeEvent, EmailServicesAddress, EmailServicesFunction,
EmailTemplate, EmailTemplateChangeEvent, EngagementAttendeeChangeEvent,
EngagementAttendeeHistory, EngagementChannelTypeHistory, EngagementChannelTypeShare,
EngagementInteractionChangeEvent, EngagementInteractionHistory,
EngagementInteractionShare, EngagementInterface, EngagementTopicChangeEvent,
EngagementTopicHistory, EntitlementChangeEvent, EntitlementHistory,
EntitlementTemplate, EntityMilestoneHistory, EntitySubscription, EventChangeEvent,
EventRelationChangeEvent, EventRelayConfigChangeEvent, ExpressionSetHistory,
ExpressionSetShare, ExpressionSetVersionHistory, ExternalEventMappingShare,
FeedAttachment, FeedLike, FeedPollChoice, FeedPollVote, FeedSignal,
FieldPermissions, FieldSecurityClassification, FiscalYearSettings,
FlowInterviewLogShare, FlowInterviewShare, FlowOrchestrationEvent,
FlowOrchestrationInstanceShare, FlowOrchestrationStageInstanceShare,
FlowOrchestrationStepInstanceShare, FlowOrchestrationWorkItemShare,
FlowRecordShare, FlowRecordVersionChangeEvent, FlowTestResultShare, Folder,
Group, GroupMember, Holiday, IdeaComment, IdpEventLog, ImageHistory, ImageShare,
IncidentChangeEvent, IncidentHistory, IncidentRelatedItemChangeEvent,
IncidentRelatedItemHistory, IncidentShare, IndividualChangeEvent,
IndividualHistory, IndividualShare, KnowledgeableUser, LeadChangeEvent, LeadHistory,
LeadShare, LeadStatus, LightningExitByPageMetrics, LightningToggleMetrics,
LightningUsageByAppTypeMetrics, LightningUsageByBrowserMetrics,
LightningUsageByFlexiPageMetrics, LightningUsageByPageMetrics, ListEmailChangeEvent,
ListEmailShare, ListView, LocationChangeEvent, LocationHistory, LocationShare,
LocationTrustMeasureShare, LoginHistory, LoginIp, MacroChangeEvent,
MacroHistory, MacroInstructionChangeEvent, MacroShare, MacroUsageShare,
ManagedContentVariantChangeEvent, MessagingEndUserHistory, MessagingEndUserShare,
MessagingSessionHistory, MessagingSessionShare, MilestoneType, MLEngagementEvent,
ObjectPermissions, OpportunityChangeEvent, OpportunityContactRoleChangeEvent,
```

```
OpportunityFieldHistory, OpportunityLineItemChangeEvent, OpportunityShare,
OpportunityStage, OrderChangeEvent, OrderHistory, OrderItemChangeEvent,
OrderItemHistory, OrderShare, OrderStatus, Organization, OrgEmailAddressSecurity,
OrgWideEmailAddress, OutgoingEmail, OutgoingEmailRelation,
PackageLicense, PartnerRole, PartyConsentChangeEvent, PartyConsentHistory,
PartyConsentShare, Period, PermissionSet, PermissionSetAssignment,
PermissionSetTabSetting, Pricebook2ChangeEvent, Pricebook2History,
PricebookEntryChangeEvent, PricebookEntryHistory, PrivacyJobSessionShare,
PrivacyObjectSessionShare, PrivacyRTBFRequestHistory, PrivacyRTBFRequestShare,
PrivacySessionRecordFailureShare, ProblemChangeEvent, ProblemHistory,
ProblemIncidentChangeEvent, ProblemIncidentHistory, ProblemRelatedItemChangeEvent,
ProblemRelatedItemHistory, ProblemShare, ProcessDefinition, ProcessExceptionEvent,
ProcessExceptionShare, ProcessInstanceChangeEvent, ProcessInstanceStep,
ProcessInstanceStepChangeEvent, ProcessNode, Product2ChangeEvent, Product2History,
ProductEntitlementTemplate, Profile, ProfileSkillEndorsementHistory,
ProfileSkillHistory, ProfileSkillShare, ProfileSkillUserHistory, PromptActionShare,
PromptErrorShare, QueueSobject, QuickTextChangeEvent, QuickTextHistory,
QuickTextShare, QuickTextUsageShare, RecentlyViewed, RecommendationChangeEvent,
RecordActionHistory, RecordAlertHistory, RecordAlertShare, RecordType,
ScorecardShare, SellerHistory, SellerShare, ServiceContractChangeEvent,
ServiceContractHistory, ServiceContractShare, SetupAuditTrail, SetupEntityAccess,
SharingRecordCollectionShare, Site, SiteHistory, SiteRedirectMapping,
SocialPersonaHistory, SocialPostChangeEvent, SocialPostHistory, SocialPostShare,
SolutionHistory, SolutionStatus, StaticResource, StreamingChannelShare,
TableauHostMappingShare, TaskChangeEvent, TaskPriority, TaskStatus,
ThreatDetectionFeedback, TimelineObjectDefinitionChangeEvent, TodayGoalShare,
Topic, TopicUserEvent, Translation, User, UserAppMenuCustomizationShare,
UserChangeEvent, UserDefinedLabelAssignmentShare, UserDefinedLabelShare,
UserEmailPreferredPersonShare, UserLicense, UserLogin, UserPackageLicense,
UserPreference, UserPrioritizedRecordShare, UserProvisioningRequestShare,
UserRole, UserShare, VideoCallChangeEvent, VideoCallParticipantChangeEvent,
VideoCallRecordingChangeEvent, VideoCallShare, VisualforceAccessMetrics,
VoiceCallChangeEvent, VoiceCallRecordingChangeEvent, VoiceCallShare, Vote,
WebLink, WorkAccessShare, WorkBadgeDefinitionHistory, WorkBadgeDefinitionShare,
WorkOrderChangeEvent, WorkOrderHistory, WorkOrderLineItemChangeEvent,
WorkOrderLineItemHistory, WorkOrderLineItemStatus, WorkOrderShare,
WorkOrderStatus, WorkPlanChangeEvent, WorkPlanHistory, WorkPlanShare,
WorkPlanTemplateChangeEvent, WorkPlanTemplateEntryChangeEvent,
WorkPlanTemplateEntryHistory, WorkPlanTemplateHistory, WorkPlanTemplateShare,
WorkStepChangeEvent, WorkStepHistory, WorkStepStatus, WorkStepTemplateChangeEvent,
WorkStepTemplateHistory, WorkStepTemplateShare, WorkThanksShare
```

- No se admite el uso de los siguientes entidades o campos de ServiceNow en una integración sin ETL con un origen de ServiceNow.

```
ais_acl_overrides, ais_async_genius_result, ais_async_request,
 ais_connection, ais_genius_result_configuration_parameters,
 ais_partition_health, ais_partition_health_response, ais_publish_history,
 ais_relevancy_training_execution, ais_relevancy_training_staging,
 ais_search_profile_relevancy_model, catalog_draft_entities, clone_log,
 clone_log0000, clone_log0001, clone_log0002, clone_log0003, clone_log0004,
 clone_log0005, clone_log0006, clone_log0007, cmdb_ie_context, cmdb_ie_log,
 cmdb_ie_run, cmdb_ire_partial_payloads_index, cmdb_qb_result_base
$par1, cmdb$par1, discovery_log, discovery_log0000, discovery_log0001,
 discovery_log0002, discovery_log0003, discovery_log0004, discovery_log0005,
 discovery_log0006, discovery_log0007, ecc_agent_log, entitlement_data,
 entl_subscription_map, gs_entitlement_plugin_mapping, ih_transaction_exclusion,
 import_log, import_log0000, import_log0001, import_log0002, import_log0003,
 import_log0004, import_log0005, import_log0006, import_log0007, jrobin_archive,
 jrobin_database, jrobin_datasource, jrobin_definition, jrobin_graph,
 jrobin_graph_line, jrobin_graph_set, jrobin_graph_set_member, jrobin_shard,
 jrobin_shard_location, license_role_discovery_run, logger_configuration_validation,
 m2m_analytics_event_logger, m2m_user_consent_info, ml_artifact_object_store,
 np$sys_gen_ai_filter_sample, np$sys_ui_element, np$sys_ui_list_element,
 one_api_service_plan_feature_invocation, one_api_service_plan_invocation,
 open_nlu_predict_log, open_nlu_predict_log0000, open_nlu_predict_log0001,
 open_nlu_predict_log0002, open_nlu_predict_log0003, open_nlu_predict_log0004,
 open_nlu_predict_log0005, open_nlu_predict_log0006, open_nlu_predict_log0007,
 pa_diagnostic_log, pa_diagnostic_log0000, pa_diagnostic_log0001,
 pa_diagnostic_log0002, pa_diagnostic_log0003, pa_diagnostic_log0004,
 pa_diagnostic_log0005, pa_diagnostic_log0006, pa_diagnostic_log0007, pa_favorites,
 pa_job_log_rows, pa_job_log_rows0000, pa_job_log_rows0001, pa_job_log_rows0002,
 pa_job_log_rows0003, pa_job_log_rows0004, pa_job_log_rows0005, pa_job_log_rows0006,
 pa_job_log_rows0007, pa_migration_ignored_scores, pa_scores_l1, pa_scores_l2,
 pa_scores_migration_groups, par_dashboard_conversion_backup, promin_log,
 promin_log0000, promin_log0001, promin_log0002, promin_log0003, promin_log0004,
 promin_log0005, promin_log0006, promin_log0007, promin_request_object,
 proposed_change_verification_log, proposed_change_verification_log0000,
 proposed_change_verification_log0001, proposed_change_verification_log0002,
 proposed_change_verification_log0003, proposed_change_verification_log0004,
 proposed_change_verification_log0005, proposed_change_verification_log0006,
 proposed_change_verification_log0007, protected_table_log, protected_table_log0000,
 protected_table_log0001, protected_table_log0002, protected_table_log0003,
 protected_table_log0004, protected_table_log0005, protected_table_log0006,
 protected_table_log0007, pwd_history, qb_query_results, scan_log,
 scan_log0000, scan_log0001, scan_log0002, scan_log0003, scan_log0004,
 scan_log0005, scan_log0006, scan_log0007, schema_validator_error,
 sla_repair_log_entry, sla_repair_log_entry0000, sla_repair_log_entry0001,
```

```
sla_repair_log_entry0002, sla_repair_log_entry0003, sla_repair_log_entry0004,
sla_repair_log_entry0005, sla_repair_log_entry0006, sla_repair_log_entry0007,
sla_repair_log_message, sla_repair_log_message0000, sla_repair_log_message0001,
sla_repair_log_message0002, sla_repair_log_message0003, sla_repair_log_message0004,
sla_repair_log_message0005, sla_repair_log_message0006, sla_repair_log_message0007,
sn_bm_client_activity, sn_ci_analytics_st_actionable_notifs,
sn_ci_analytics_st_conv_completion_by_cat, sn_ci_analytics_st_conv_dynamic_property,
sn_ci_analytics_st_conversation, sn_ci_analytics_st_count_by_date,
sn_ci_analytics_st_event_occurrence, sn_ci_analytics_st_event_property_value_trend,
sn_ci_analytics_st_issue_auto_resolution, sn_ci_analytics_st_no_clicks,
sn_ci_analytics_st_no_results, sn_ci_analytics_st_property_summary_by_event,
sn_ci_analytics_st_session_count_per_locale, sn_ci_analytics_st_session_duration,
sn_ci_analytics_st_spokes_usage, sn_ci_analytics_st_topic_execution_stats,
sn_ci_analytics_st_topic_occurrence, sn_ci_analytics_st_trending_content,
sn_ci_analytics_st_trending_queries, sn_ci_analytics_st_users,
sn_cs_plugin_signatures, sn_cs_telemetry_log, sn_dfc_application, sn_dfc_product,
sn_employee_position, sn_entitlement_st_subscription_application_family,
sn_entitlement_st_subscription_application_users, sn_hr_sp_st_relevant_for_you,
sn_instance_clone_log, sn_instance_clone_log0000, sn_instance_clone_log0001,
sn_instance_clone_log0002, sn_instance_clone_log0003, sn_instance_clone_log0004,
sn_instance_clone_log0005, sn_instance_clone_log0006, sn_instance_clone_log0007,
sn_km_mr_st_kb_knowledge, sn_me_st_topic, sn_rf_conditional_definition,
sn_rf_evaluation_type, sn_rf_evaluation_type_input, sn_rf_recommendation_action,
sn_rf_recommendation_experience, sn_rf_recommendation_history,
sn_rf_recommendation_rule, sn_rf_record_display_configuration,
sn_rf_trend_definition, sn_sub_man_st_account_level_entitlement,
sn_sub_man_st_gen_ai_metadata, sn_sub_man_st_instance_used_assist_count,
sn_sub_man_st_now_assist_creator_instances, sn_sub_man_st_now_assists_aggregate,
sn_sub_man_st_subscribed_groups, sn_sub_man_st_subscription_insights,
sn_sub_man_st_subscription_license_detail_metric,
sn_sub_man_st_unallocated_group_recommendation,
sn_sub_man_st_unconfirmed_user_group, sn_wn_user_app_activity,
sn_wn_user_content_activity, snc_monitorable_item,
snpar_sched_export_v_scheduled_export_visualization, spotlight,
spotlight_audit, spotlight_copy_log_row, spotlight_copy_log_row0000,
spotlight_copy_log_row0001, spotlight_copy_log_row0002, spotlight_copy_log_row0003,
spotlight_copy_log_row0004, spotlight_copy_log_row0005, spotlight_copy_log_row0006,
spotlight_copy_log_row0007, spotlight_job_log_row, spotlight_job_log_row0000,
spotlight_job_log_row0001, spotlight_job_log_row0002, spotlight_job_log_row0003,
spotlight_job_log_row0004, spotlight_job_log_row0005, spotlight_job_log_row0006,
spotlight_job_log_row0007, st_dfc_performance_metric, st_license_detail_metric,
st_on_call_hour, st_sc_wizard_question, st_sys_catalog_items_and_variable_sets,
st_sys_design_system_icon, subscription_instance_stats,
svc_container_config, svc_environment_config, svc_layer_config,
```

```
svc_model_assoc_ci, svc_model_checkpoint_attr, svc_model_obj_cluster,
svc_model_obj_constraint, svc_model_obj_deployable, svc_model_obj_element,
svc_model_obj_impact, svc_model_obj_impactrule, svc_model_obj_package,
svc_model_obj_path, svc_model_obj_relation, svc_model_obj_service,
sys_administrative_script_transaction, sys_amb_message, sys_amb_processor,
sys_analytics_batch_state, sys_analytics_config, sys_analytics_data_points_error,
sys_analytics_event, sys_analytics_logger, sys_analytics_logger_field,
sys_app_payload_loader_rule, sys_app_payload_unloader_rule, sys_app_scan_payload,
sys_app_scan_variable, sys_app_scan_variable_type, sys_archive_destroy_log,
sys_archive_destroy_run, sys_archive_log, sys_archive_run, sys_atf_transaction_log,
sys_attachment_doc, sys_attachment_doc_v2, sys_attachment_soft_deleted, sys_audit,
sys_audit_relation, sys_auth_policy_api_allowed, sys_aw_registered_scripting_modal,
sys_cache_flush, sys_data_egress_source, sys_dm_delete_count,
sys_export_set_log, sys_export_set_log0000, sys_export_set_log0001,
sys_export_set_log0002, sys_export_set_log0003, sys_export_set_log0004,
sys_export_set_log0005, sys_export_set_log0006, sys_export_set_log0007,
sys_flow_compiled_flow, sys_flow_compiled_flow_chunk, sys_flow_context_chunk,
sys_flow_context_chunk_archive, sys_flow_context_inputs_chunk,
sys_flow_execution_history, sys_flow_log, sys_flow_log0000, sys_flow_log0001,
sys_flow_log0002, sys_flow_log0003, sys_flow_plan_context_binding,
sys_flow_report_doc, sys_flow_report_doc_chunk, sys_flow_report_doc_chunk_archive,
sys_flow_runtime_state_chunk, sys_flow_runtime_value_chunk,
sys_flow_subflow_plan_chunk, sys_flow_trigger_plan_chunk, sys_flow_val_listener,
sys_flow_value, sys_flow_value_chunk, sys_gen_ai_config_example,
sys_gen_ai_feature_mapping, sys_gen_ai_strategy_mapping, sys_gen_ai_usage_log,
sys_generative_ai_capability_definition, sys_generative_ai_log,
sys_generative_ai_response_validator, sys_generative_ai_validator,
sys_geo_routing, sys_geo_routing_config, sys_hop_token, sys_hub_action_plan_chunk,
sys_hub_snapshot_chunk, sys_journal_field, sys_journal_field_edit, sys_json_chunk,
sys_kaa_policy, sys_kaa_subidentity_assertion, sys_kaa_user_policy_mapping,
sys_mapplication, sys_mass_encryption_job, sys_notification_execution_log,
sys_notification_execution_log0000, sys_notification_execution_log0001,
sys_notification_execution_log0002, sys_notification_execution_log0003,
sys_notification_execution_log0004, sys_notification_execution_log0005,
sys_notification_execution_log0006, sys_notification_execution_log0007,
sys_nowmq_message, sys_nowmq_provider_param_definition, sys_orchestrator_action,
sys_pd_asset_configuration, sys_pd_context_chunk, sys_pd_context_log,
sys_pd_snapshot_chunk, sys_pd_trigger_license, sys_processing_framework_job,
sys_query_index_hint, sys_query_rewrite, sys_query_string_log,
sys_replication_queue, sys_replication_queue0, sys_replication_queue1,
sys_replication_queue2, sys_replication_queue3, sys_replication_queue4,
sys_replication_queue5, sys_replication_queue6, sys_replication_queue7,
sys_request_performance, sys_rollback_blacklisted, sys_rollback_conflict,
sys_rollback_incremental, sys_rollback_log, sys_rollback_log0000,
```

```
sys_rollback_log0001, sys_rollback_log0002, sys_rollback_log0003,
sys_rollback_log0004, sys_rollback_log0005, sys_rollback_log0006,
sys_rollback_log0007, sys_rollback_run, sys_rollback_schema_change,
sys_rollback_schema_conflict, sys_rollback_sequence, sys_scheduler_assignment,
sys_scheduler_memory_pressure_job_log, sys_script_adapter_rule,
sys_script_batch_adapter_rule, sys_search_source_filter, sys_service_authentication,
sys_signing_job, sys_suggestion_reader, sys_sync_history_review, sys_trend,
sys_unreferenced_preview, sys_unreferenced_record_rule, sys_upgrade_manifest,
sys_upgrade_state, sys_ux_asset_cache_buster, sys_ux_lib_component_prop,
sys_ux_lib_presource, sys_ux_page_action, sys_ux_page_action_binding,
sysevent_queue_runtime, syslog, syslog_app_scope0000, syslog_app_scope0001,
syslog_app_scope0002, syslog_app_scope0003, syslog_app_scope0004,
syslog_app_scope0005, syslog_app_scope0006, syslog_app_scope0007, syslog_email0000,
syslog_email0001, syslog_email0002, syslog_email0003, syslog_email0004,
syslog_email0005, syslog_email0006, syslog_email0007, syslog_transaction,
syslog_transaction0000, syslog_transaction0001, syslog_transaction0002,
syslog_transaction0003, syslog_transaction0004, syslog_transaction0005,
syslog_transaction0006, syslog_transaction0007, syslog0000, syslog0001,
syslog0002, syslog0003, syslog0004, syslog0005, syslog0006, syslog0007,
ts_attachment, ts_c_1_0, ts_c_1_1, ts_c_1_2, ts_c_1_3, ts_c_1_4, ts_c_1_5,
ts_c_1_6, ts_c_1_7, ts_c_1_8, ts_c_1_9, ts_c_10_0, ts_c_10_1, ts_c_10_2,
ts_c_10_3, ts_c_10_4, ts_c_10_5, ts_c_10_6, ts_c_10_7, ts_c_10_8, ts_c_10_9,
ts_c_11_0, ts_c_11_1, ts_c_11_2, ts_c_11_3, ts_c_11_4, ts_c_11_5, ts_c_11_6,
ts_c_11_7, ts_c_11_8, ts_c_11_9, ts_c_2_0, ts_c_2_1, ts_c_2_2, ts_c_2_3,
ts_c_2_4, ts_c_2_5, ts_c_2_6, ts_c_2_7, ts_c_2_8, ts_c_2_9, ts_c_3_0,
ts_c_3_1, ts_c_3_2, ts_c_3_3, ts_c_3_4, ts_c_3_5, ts_c_3_6, ts_c_3_7, ts_c_3_8,
ts_c_3_9, ts_c_39_0, ts_c_39_1, ts_c_39_2, ts_c_39_3, ts_c_39_4, ts_c_39_5,
ts_c_39_6, ts_c_39_7, ts_c_39_8, ts_c_39_9, ts_c_40_0, ts_c_40_1, ts_c_40_2,
ts_c_40_3, ts_c_40_4, ts_c_40_5, ts_c_40_6, ts_c_40_7, ts_c_40_8, ts_c_40_9,
ts_c_41_0, ts_c_41_1, ts_c_41_2, ts_c_41_3, ts_c_41_4, ts_c_41_5, ts_c_41_6,
ts_c_41_7, ts_c_41_8, ts_c_41_9, ts_c_42_0, ts_c_42_1, ts_c_42_2, ts_c_42_3,
ts_c_42_4, ts_c_42_5, ts_c_42_6, ts_c_42_7, ts_c_42_8, ts_c_42_9, ts_c_43_0,
ts_c_43_1, ts_c_43_2, ts_c_43_3, ts_c_43_4, ts_c_43_5, ts_c_43_6, ts_c_43_7,
ts_c_43_8, ts_c_43_9, ts_c_44_0, ts_c_44_1, ts_c_44_2, ts_c_44_3, ts_c_44_4,
ts_c_44_5, ts_c_44_6, ts_c_44_7, ts_c_44_8, ts_c_44_9, ts_c_45_0, ts_c_45_1,
ts_c_45_2, ts_c_45_3, ts_c_45_4, ts_c_45_5, ts_c_45_6, ts_c_45_7, ts_c_45_8,
ts_c_45_9, ts_c_6_0, ts_c_6_1, ts_c_6_2, ts_c_6_3, ts_c_6_4, ts_c_6_5,
ts_c_6_6, ts_c_6_7, ts_c_6_8, ts_c_6_9, ts_c_7_0, ts_c_7_1, ts_c_7_2, ts_c_7_3,
ts_c_7_4, ts_c_7_5, ts_c_7_6, ts_c_7_7, ts_c_7_8, ts_c_7_9, ts_c_8_0, ts_c_8_1,
ts_c_8_2, ts_c_8_3, ts_c_8_4, ts_c_8_5, ts_c_8_6, ts_c_8_7, ts_c_8_8, ts_c_8_9,
ts_c_attachment, ts_chain, ts_deleted_doc, ts_document, ts_field, ts_index_stats,
ts_phrase, ts_search_stats, ts_v4_attachment, ts_word, ua_app_metadata,
ua_audit_stats, ua_extra_page, ua_monitor_property, ua_monitor_property_audit,
ua_shared_service, ua_sn_table_inventory, ua_sp_known_bot, ua_upload_log,
```

```
v_ais_result_improvement_rule_condition_builder_values, v_cluster_nodes,
v_cxs_search_resource, v_db_index, v_db_trigger, v_file_load_order,
v_interaction_context, v_iostats, v_mysql_proclist, v_mysql_status,
v_mysql_variables, v_on_call_report_cache, v_pa_par_combined_dashboard,
v_pd_activity_condition_to_run, v_pd_activity_start_rule_with_condition,
v_pd_lane_condition_to_run, v_sql_debug, v_st_kb_category, v_st_kb_most_viewed,
v_st_kb_recently_viewed, v_st_km_genai_mra_similar_task, v_st_popular_item,
v_st_recent_item, v_st_sc_cat_item, v_st_sc_catalog, v_st_sc_category,
validator_run_summary, vtb_card_history, wf_log, wf_log0000, wf_log0001,
wf_log0002, wf_log0003, wf_log0004, wf_log0005, wf_log0006, wf_log0007,
spotlight_criteria, pa_snapshots, pa_widget_indicators, pa_widgets,
sn_cim_register, global, gsw_change_log, gsw_content, gsw_content_group,
gsw_content_information, gsw_status_of_content, multi_factor_browser_fingerprint,
multi_factor_criteria, pa_filters, password_policy, plan_execution,
plan_mysql, plan_oracle, plan_postgres, sc_rest_api_without_access_policy,
sn_actsub_activity, sn_actsub_activity_fanout, sn_actsub_activity_stream,
sn_actsub_activity_type, sn_actsub_atype_attributes, sn_actsub_atype_notif_pref,
sn_actsub_module, sn_actsub_notif_object, sn_actsub_subobject_stream,
sn_actsub_subscribable_object, sn_actsub_subscription_notif_pref,
sn_actsub_user_stream, sn_appclient_store_outbound_http_quota,
sn_appcreator_app_template, sn_critical_update, sn_docker_spoke_images,
sn_employee_app, sn_employee_app_access, sn_employee_app_access_criteria,
sn_entitlement_genai_assist_counts, sn_entitlement_genai_creator_user_counts,
sn_entitlement_genai_creator_users, sn_mif_instance, sn_mif_sync_data,
sn_mif_sync_status, sn_mif_table_registration, sn_mif_trust_config,
sn_vsc_best_practice_configurations, sn_vsc_best_practice_goals,
sn_vsc_changed_hardening_settings, sn_vsc_changed_scan_findings,
sn_vsc_check_security_area, sn_vsc_elevation_event, sn_vsc_event,
sn_vsc_export_event, sn_vsc_export_setting, sn_vsc_harc_compliance_status_lookup,
sn_vsc_hardening_compliance_scores, sn_vsc_impersonation_event,
sn_vsc_instance_hardening_settings, sn_vsc_login_event,
sn_vsc_scan_comparisons, sn_vsc_scan_summary, sn_vsc_security_check_categories,
sn_vsc_security_check_configurations, sn_vsc_security_configuration_groups,
sn_vsc_security_privacy_capabilities, sn_vsc_updated_settings,
sn_vsc_user_comparisons, sys_app_hash_inventory, sys_coalesce_strategy_deferred,
sys_flow_secure_data, sys_formula_function, sys_geocoding_request,
sys_global_file_hash, sys_import_set_row, sys_index, sys_index_explain,
sys_installation_schedule, sys_installation_schedule_item, sys_offline_app,
sys_package, sys_package_dependency_item, sys_package_dependency_m2m,
sys_plugins, sys_querystat, sys_reap_package, sys_scoped_plugin,
sys_stage_storage_alias, sys_storage_alias, sys_storage_table_alias, sys_store_app,
sys_table_partition, sys_upgrade_history_log, sys_user_public_credential,
sys_webauthn_authentication_request, sys_webauthn_registration_request,
syslog_app_scope, syslog_email, syslog_page_timing, ua_instance_state_config,
```

```
v_expression_cache, v_private_cache, v_shared_cache, sys_amb_message0002,
sys_amb_message0004, sys_amb_message0005, sys_metadata, v_par_unified_report_viz
```

Calidad de datos de AWS Glue

Calidad de datos de AWS Glue permite medir y supervisar la calidad de los datos para que se puedan tomar buenas decisiones empresariales. Creado a partir del marco de DeeQu de código abierto, Calidad de los datos de AWS Glue proporciona una experiencia administrada y sin servidor. AWS Glue Calidad de datos funciona con el lenguaje de definición de calidad de datos (DQDL), que es un lenguaje específico de un dominio que se utiliza para definir las reglas de calidad de datos. Para obtener más información sobre el DQDL y los tipos de reglas compatibles, consulte Referencia del lenguaje de definición de calidad de datos (DQDL).

Para conocer los detalles adicionales del producto y los precios, consulte la página de servicio de Calidad de datos de AWS Glue.

Beneficios y características principales

Los beneficios y las características clave de la calidad de los datos de AWS Glue incluyen:

- Sin servidor: no requiere instalación, aplicación de parches ni mantenimiento.
- Comience rápidamente: Calidad de datos de AWS Glue analiza rápidamente sus datos y crea reglas de calidad de datos para usted. Puede empezar con dos clics: “Crear reglas de calidad de datos → Recomendar reglas”.
- Detección de problemas de calidad de los datos: use el machine learning (ML) para detectar anomalías y problemas de calidad de los datos difíciles de detectar.
- Improvise sus reglas: con más de 25 reglas de calidad de datos listas para usar con las que empezar, puede crear reglas que se adapten a sus necesidades específicas.
- Evalúe la calidad y tome decisiones empresariales con confianza: una vez que evalúe las reglas, obtendrá una puntuación de calidad de los datos que proporciona una visión general del estado de sus datos. Utilice la puntuación de calidad de los datos para tomar decisiones empresariales fiables.
- Céntrese en los datos incorrectos: Calidad de datos de AWS Glue ayuda a identificar los registros exactos que provocaron la caída de sus puntajes de calidad. Identifíquelos fácilmente, póngalos en cuarentena y corríjalos.
- Pago por uso: no necesita licencias anuales para utilizar calidad de los datos de AWS Glue.
- Sin restricciones: Calidad de datos de AWS Glue se basa en DeeQu de código abierto, lo que permite mantener las reglas que crea en un lenguaje abierto.

- Controles de calidad de los datos: puede aplicar controles de calidad de los datos en los procesos ETL de Data Catalog y AWS Glue, lo que permitirá administrar la calidad de los datos en reposo y en tránsito.
- Detección de calidad de datos basada en ML: use el machine learning (ML) para detectar anomalías y problemas de calidad de los datos difíciles de detectar.
- Lenguaje abierto para expresar las reglas: garantiza que las reglas de calidad de los datos se creen de forma coherente y sencilla. Los usuarios empresariales pueden expresar fácilmente las reglas de calidad de datos en un lenguaje sencillo que puedan entender. Para los ingenieros, este lenguaje proporciona la flexibilidad necesaria para generar código, implementar un control de versiones coherente y automatizar las implementaciones.

Funcionamiento

Hay dos puntos de partida para Calidad de datos de AWS Glue: los trabajos ETL AWS Glue Data Catalog y AWS Glue. En esta sección se proporciona información general de los casos de uso y de las características de AWS Glue que admite cada punto de entrada.

Calidad de los datos para AWS Glue Data Catalog

Calidad de datos de AWS Glue evalúa los objetos que se almacenan en el. AWS Glue Data Catalog Ofrece a los no codificadores una forma sencilla de configurar las reglas de calidad de los datos. Entre estas personas, se incluyen administradores de datos y analistas de negocios.

Puede elegir esta opción para los siguientes casos de uso:

- Desea realizar tareas de calidad de datos en conjuntos de datos que ya ha catalogado en AWS Glue Data Catalog.
- Trabaja en la gobernanza de datos y necesita identificar o evaluar los problemas de calidad de los datos en su lago de datos de forma continua.

Puede administrar la calidad de los datos del catálogo de datos mediante las siguientes interfaces:

- La consola de administración de AWS Glue
- AWS GlueLas API de

Para empezar con Calidad de datos de AWS Glue para AWS Glue Data Catalog, consulte Introducción a AWS Glue Data Quality para el Data Catalog.

Calidad de los datos para los trabajos de ETL de AWS Glue

Calidad de datos de AWS Glue para los trabajos de AWS Glue ETL permite realizar tareas proactivas de calidad de datos. Las tareas proactivas ayudan a identificar y filtrar los datos incorrectos antes de cargar un conjunto de datos en el lago de datos.

Video: Presentación de Calidad de datos de AWS Glue para procesos ETL

Puede elegir la calidad de los datos para los trabajos de ETL en los siguientes casos de uso:

- Desea incorporar tareas de calidad de datos en sus trabajos de ETL
- Desea escribir código que defina las tareas de calidad de los datos en los scripts de ETL
- Desea administrar la calidad de los datos que fluyen en los procesos de datos visuales

Puede administrar la calidad de los datos para los trabajos de ETL mediante las siguientes interfaces:

- AWS Glue Studio, cuadernos de AWS Glue Studio y sesiones interactivas de AWS Glue
- Bibliotecas de AWS Glue para secuencias de comandos de ETL
- AWS GlueLas API de

Para empezar con la calidad de los datos para los trabajos de ETL, consulte Tutorial: Introducción a Calidad de datos en la Guía del usuario de AWS Glue Studio.

Comparación de la calidad de los datos del catálogo de datos con la calidad de los datos para los trabajos de ETL

En esta tabla se proporciona información general de las características que admite cada punto de entrada para Calidad de datos de AWS Glue.

Característica	Calidad de datos para el catálogo de datos	Calidad de los datos para los trabajos de ETL
Orígenes de datos	Orígenes de Amazon S3, Amazon Redshift y JDBC	Todos los orígenes de datos son compatibles con AWS

Característica	Calidad de datos para el catálogo de datos	Calidad de los datos para los trabajos de ETL
	compatibles con el Catálogo de datos y formatos de lagos de datos transaccionales como Apache Iceberg, Apache Hudi y Delta Lake. También se admiten formatos OTF gestionados por AWS Lake Formation con algunas limitaciones. Las vistas de Amazon Athena catalogadas en el Catálogo de datos de AWS Glue no son compatibl es. Consulte Tipos de orígenes compatibles.	Glue, incluidos los conectore s personalizados y los conectores de terceros.
Recomendaciones sobre reglas de calidad de datos	Compatible	No admitido
Crear y ejecutar reglas de DQDL	Soportado	Compatible
Auto Scaling	No admitido	Compatible
Compatibilidad con AWS Glue Flex	No admitido	Compatible
Programación	Compatible al evaluar las reglas de calidad de los datos y mediante Step Functions.	Compatible al usar Step Functions y flujos de trabajo.
Identificación de registros que no superaron las comprobac iones de calidad de los datos	No admitido	Compatible
Integración con Amazon Eventbridge	Soportado	Compatible

Característica	Calidad de datos para el catálogo de datos	Calidad de los datos para los trabajos de ETL
Integración con AWS CloudWatch	Soportado	Compatible
Escritura de resultados de calidad de datos en Amazon S3	Soportado	Compatible
Calidad de datos incremental	Compatible mediante predicados insertados	Compatible mediante marcadores de AWS Glue
Compatibilidad con AWS CloudFormation	Soportado	Compatible
Detección de anomalías basada en machine learning	No admitido	Compatible
Reglas dinámicas	No admitido	Compatible

Consideraciones

Tenga en cuenta los siguientes elementos antes de utilizar Calidad de datos de AWS Glue:

- Las reglas de calidad de datos no pueden evaluar los orígenes de datos anidados o de tipo lista. Consulte Aplanamiento de estructuras anidadas.

Terminología

En la siguiente lista se definen los términos relacionados con Calidad de datos de AWS Glue.

Lenguaje de definición de calidad de datos (DQDL)

Lenguaje específico del dominio que puede utilizar para escribir reglas de Calidad de datos de AWS Glue.

Para obtener más información sobre DQDL, consulte la guía de Referencia del lenguaje de definición de calidad de datos (DQDL).

calidad de datos

Describe qué tan bien un conjunto de datos cumple su propósito específico. AWS Glue Calidad de datos evalúa las reglas con respecto a un conjunto de datos para medir la calidad de los datos. Cada regla comprueba características específicas, como la actualización o integridad de los datos. Para cuantificar la calidad de los datos, puede utilizar una puntuación de calidad de datos.

puntuación de calidad de datos

El porcentaje de reglas de calidad de datos que cumplen (el resultado es true [verdadero]) al evaluar un conjunto de reglas con Calidad de datos de AWS Glue.

rule

Una expresión de DQDL que comprueba los datos para detectar una característica específica y devuelve un valor booleano. Para obtener más información, consulte Estructura de la regla.

analizador

Expresión DQDL que recopila estadísticas de datos. Un analizador recopila estadísticas de datos que los algoritmos de aprendizaje automático pueden utilizar para detectar anomalías y problemas de calidad de los datos difíciles de detectar a lo largo del tiempo.

conjunto de reglas

Un recurso de AWS Glue que comprende un conjunto de reglas de la calidad de los datos. El conjunto de reglas debe estar asociado a una tabla de AWS Glue Data Catalog. Al guardar un conjunto de reglas, AWS Glue asigna un nombre de recurso de Amazon (ARN) al conjunto de reglas.

puntuación de calidad de datos

El porcentaje de reglas de calidad de datos que cumplen (el resultado es true [verdadero]) al evaluar un conjunto de reglas con Calidad de datos de AWS Glue.

observación

Información no confirmada que se genera por AWS Glue cuando se analizan las estadísticas de datos recopiladas por las reglas y los analizadores a lo largo del tiempo.

Límites

Límites del servicio de Calidad de datos de AWS Glue:

- Puede tener 2000 reglas en un conjunto de reglas. Si sus conjuntos de reglas son más grandes, le recomendamos dividirlos en varios conjuntos de reglas.
- El tamaño del conjunto de reglas es de 65 KB. Si sus conjuntos de reglas son más grandes, le recomendamos dividirlos en varios conjuntos de reglas.
- Calidad de datos de AWS Glue recopila estadísticas cuando crea una regla o un analizador. El almacenamiento de estas estadísticas no supone costo alguno. Sin embargo, hay un límite de 100 000 estadísticas por cuenta, y estas estadísticas se conservarán durante un máximo de dos años.

Notas de publicación sobre Calidad de datos de AWS Glue

En este tema se describen las características introducidas en Calidad de datos de AWS Glue.

Disponibilidad general: características nuevas

Las siguientes características nuevas están disponibles con la disponibilidad general de Calidad de datos de AWS Glue:

- La capacidad de identificar qué registros no pasaron las comprobaciones de calidad de los datos ahora es compatible con AWS Glue Studio
- Nuevos tipos de reglas de calidad de los datos, como la validación de la integridad referencial de los datos entre dos conjuntos de datos, la comparación de datos entre dos conjuntos de datos y las comprobaciones del tipo de datos
- Experiencia de usuario mejorada en AWS Glue Data Catalog
- Compatibilidad con Apache Iceberg, Apache Hudi y Delta Lake
- Compatibilidad con Amazon Redshift
- Notificación simplificada con Amazon EventBridge
- Compatibilidad con AWS CloudFormation para crear conjuntos de reglas
- Mejoras en el rendimiento: opción de almacenamiento en caché en ETL y AWS Glue Studio para un rendimiento más rápido al evaluar la calidad de los datos

27 de noviembre de 2023 (Vista previa)

- Las capacidades de detección de anomalías impulsadas por ML ahora están disponibles en AWS Glue ETL y AWS Glue Studio. Con esto, ahora es posible detectar anomalías y problemas de calidad de datos difíciles de detectar.
- Las reglas dinámicas le permiten dar umbrales dinámicos (por ejemplo: `RowCount> avg(last(10))`).

12 de marzo de 2024

- Mejoras del DQDL
  - Compatibilidad con palabras clave como NULL, BLANKS y WHITESPACES_ONLY
  - Opciones para especificar cómo Calidad de datos de AWS Glue debe gestionar las reglas compuestas
  - Restricciones para que el tipo de regla ColumnValues no permita que se pasen valores NULL durante las comparaciones
  - Compatibilidad con el operador NOT en el DQDL

26 de junio de 2024

- Mejoras del DQDL
  - El DQDL ahora admite la cláusula WHERE para que pueda filtrar los datos antes de aplicar las reglas de DQ.

7 de agosto de 2024

- La detección de anomalías y las reglas dinámicas ya están disponibles con carácter general

22 de noviembre de 2024

- Las reglas compuestas complejas le permiten crear reglas empresariales más complejas con soporte anidado
- Nuevos tipos de reglas para administrar la calidad de los datos de sus archivos
  - FileFreshness

  - FileSize
  - FileUniqueness
  - FileMatch
- Comprobaciones predeterminadas de la calidad de los datos en trabajos de Visual ETL

6 de diciembre de 2024

- La calidad de datos de AWS Glue ahora admite tablas de Amazon SageMaker AI LakeHouse y AWS Lake Formation tablas de Iceberg, Delta y HUDI administradas por AWS Glue en ETL 5.0.

7 de julio de 2025

- La calidad de datos de AWS Glue ahora admite tablas de Amazon S3, RMS, LakeHouse y de Iceberg administradas por AWS Lake Formation en el Catálogo de datos de AWS Glue.

21 de noviembre de 2025

- La calidad de datos de AWS Glue ahora admite el etiquetado de reglas para mejorar la generación de informes. Puede organizar y analizar los resultados de la calidad de los datos de forma más eficaz al consultar los resultados por etiquetas específicas, lo que permite identificar reglas con fallos dentro de categorías concretas, contabilizar los resultados de las reglas por equipo o dominio y crear informes específicos para distintos grupos de interés. Para obtener más información, consulte Etiquetas.
- La calidad de datos de AWS Glue ahora admite constantes en DQDL, lo que permite definir valores constantes y hacer referencia a ellos a lo largo de todo el script. Esto ayuda a evitar problemas relacionados con los límites de tamaño de las consultas al trabajar con instrucciones SQL de gran tamaño. Para obtener más información, consulte Constantes.

Detección de anomalías en Calidad de los datos AWS Glue

Argumentos a favor del machine learning en la calidad de los datos

Los ingenieros administran cientos de canalizaciones de datos en simultáneo. Cada canalización puede extraer datos de diferentes fuentes y cargarlos en el lago de datos o en otros repositorios de datos. Para garantizar que se entreguen datos de alta calidad para la toma de decisiones, establecen

reglas de la calidad de los datos. Estas reglas evalúan los datos en función de criterios fijos que reflejan el estado actual de la empresa. Sin embargo, cuando el entorno empresarial cambia, las propiedades de los datos cambian, lo que hace que estos criterios fijos queden obsoletos y la calidad de los datos sea deficiente.

Por ejemplo, un ingeniero de datos de una empresa minorista estableció una regla que valida que las ventas diarias deben superar el umbral de un millón de dólares. Al cabo de unos meses, las ventas diarias superaron los dos millones de dólares, lo que hizo que el umbral quedara obsoleto. El ingeniero de datos no pudo actualizar las reglas para reflejar los umbrales más recientes debido a la falta de notificación y al esfuerzo necesario para analizar y actualizar la regla manualmente. Más adelante en el mes, los usuarios de la empresa notaron una caída del 25 % en sus ventas. Tras horas de investigación, los ingenieros de datos descubrieron que un canal de ETL responsable de extraer datos de algunos almacenes había fallado sin generar errores. La regla que contenía umbrales obsoletos siguió funcionando correctamente sin detectar este problema.

De forma alternativa, las alertas proactivas que pueden detectar estas anomalías podrían haber permitido a los usuarios detectar este problema. Además, el seguimiento de la estacionalidad en las empresas puede resaltar problemas importantes en la calidad de los datos. Por ejemplo, las ventas minoristas pueden ser más altas los fines de semana y durante la temporada navideña, mientras que son relativamente bajas los días de semana. La divergencia de este patrón puede indicar problemas de calidad de los datos o cambios en las circunstancias de la empresa. Las reglas de la calidad de los datos no pueden detectar los patrones estacionales, ya que esto requiere algoritmos avanzados que puedan aprender de patrones anteriores que capten la estacionalidad para detectar las desviaciones.

Por último, a los usuarios les resulta difícil crear y mantener reglas debido a la naturaleza técnica del proceso de creación de reglas y al tiempo que lleva crearlas. Como resultado, prefieren explorar primero los datos antes que definir las reglas. Los clientes necesitan la capacidad de detectar anomalías fácilmente con el fin de detectar problemas de calidad de datos de forma proactiva y tomar decisiones empresariales con seguridad.

Funcionamiento

> **Note**
>
> La detección de anomalías solo se admite en ETL de AWS Glue. No se admite en la calidad de datos basada en el Catálogo de datos.

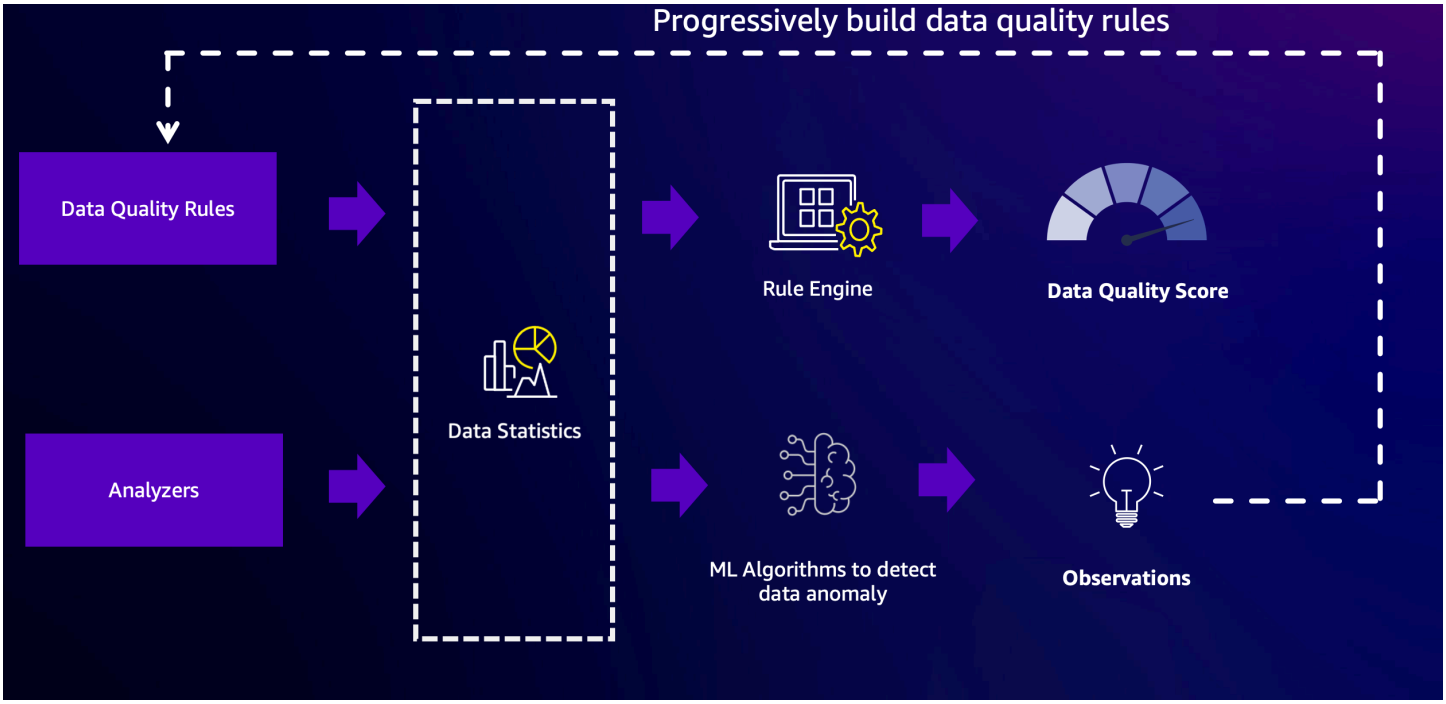

Calidad de datos de AWS Glue combina el poder de la calidad de datos basada en reglas y las capacidades de detección de anomalías para ofrecer datos de alta calidad. Para empezar, primero debe configurar reglas y analizadores y, luego, habilitar la detección de anomalías.

Reglas

Reglas: las reglas expresan las expectativas de sus datos en un lenguaje abierto denominado Lenguaje de definición de calidad de datos (DQDL). A continuación se muestra un ejemplo de la regla. Esta regla se aplicará correctamente cuando no haya valores vacíos o NULOS en la columna `passenger count`:

```
Rules = [
    IsComplete "passenger_count"
]
```

Analizadores

En situaciones en las que conoce las columnas críticas, pero es posible que no sepa lo suficiente sobre los datos como para redactar reglas específicas, puede monitorear estas columnas mediante analizadores. Los analizadores son una forma de recopilar estadísticas de datos sin definir reglas explícitas. A continuación se muestra un ejemplo de la configuración de analizadores:

```
Analyzers = [
```

```
AllStatistics "fare_amount",
DistinctValuesCount "pulocationid",
RowCount
]
```

En este ejemplo, se configuran tres analizadores:

1. El primer analizador, `AllStatistics “fare_amount”`, capturará todas las estadísticas disponibles para el campo `fare_amount`.
2. El segundo analizador, `DistinctValuesCount “pulocationid”`, capturará el recuento de valores distintos de la columna `pulocationid`.
3. El tercer analizador, `RowCount`, capturará la cantidad total de registros del conjunto de datos.

Los analizadores funcionan como una forma sencilla de recopilar estadísticas de datos relevantes sin especificar reglas complejas. Mediante el monitoreo de estas estadísticas, puede obtener información sobre la calidad de los datos e identificar posibles problemas o anomalías que pueden requerir una investigación más profunda o la creación de reglas específicas.

Estadísticas de datos

Tanto los analizadores como las reglas de Calidad de datos de AWS Glue recopilan estadísticas de datos, a las que también se las conoce como perfiles de datos. Estas estadísticas proporcionan información sobre las características y la calidad de sus datos. Las estadísticas recopiladas se almacenan a lo largo del tiempo en el servicio AWS Glue, lo que le permite realizar un seguimiento y analizar los cambios en sus perfiles de datos.

Puede recuperar fácilmente estas estadísticas y escribirlas en Amazon S3 para analizarlas con mayor profundidad, o almacenarlas a largo plazo mediante la invocación de las API correspondientes. Esta funcionalidad le permite integrar la creación de perfiles de datos en sus flujos de trabajo de procesamiento de datos y aprovechar las estadísticas recopiladas para diversos fines, como el monitoreo de la calidad de los datos y la detección de anomalías.

Al almacenar los perfiles de datos en Amazon S3, puede aprovechar la escalabilidad, durabilidad y rentabilidad del servicio de almacenamiento de objetos de Amazon. Además, puede aprovechar otros servicios de AWS o herramientas de terceros para analizar y visualizar los perfiles de datos, lo que le permitirá obtener información más exhaustiva sobre la calidad de los datos y tomar decisiones informadas sobre la administración y gobernanza de los datos.

A continuación se muestra un ejemplo de estadísticas de datos almacenadas a lo largo del tiempo.

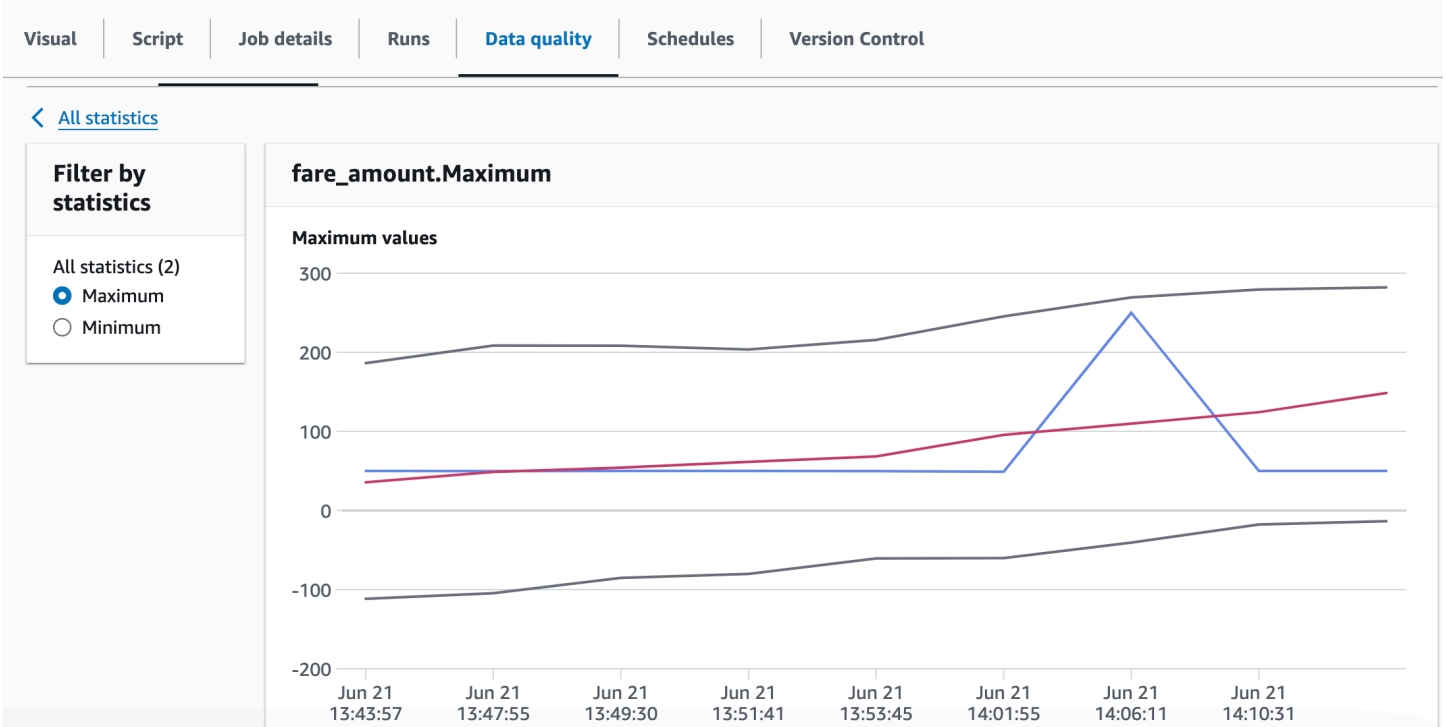

> **Note**
>
> Calidad de datos de AWS Glue recopilará estadísticas solo una vez, incluso si tiene Regla y Analizador para las mismas columnas, lo que hace que el proceso de generación de estadísticas sea eficiente.

Detección de anomalías

Calidad de datos de AWS Glue requiere un mínimo de tres puntos de datos para detectar anomalías. Utiliza un algoritmo de machine learning para aprender de las tendencias pasadas y, luego, predecir los valores futuros. Cuando el valor real no se encuentra dentro del rango previsto, Calidad de datos de AWS Glue crea una Observación de anomalía. Proporciona una representación visual del valor real y de las tendencias. En el siguiente gráfico se muestran cuatro valores.

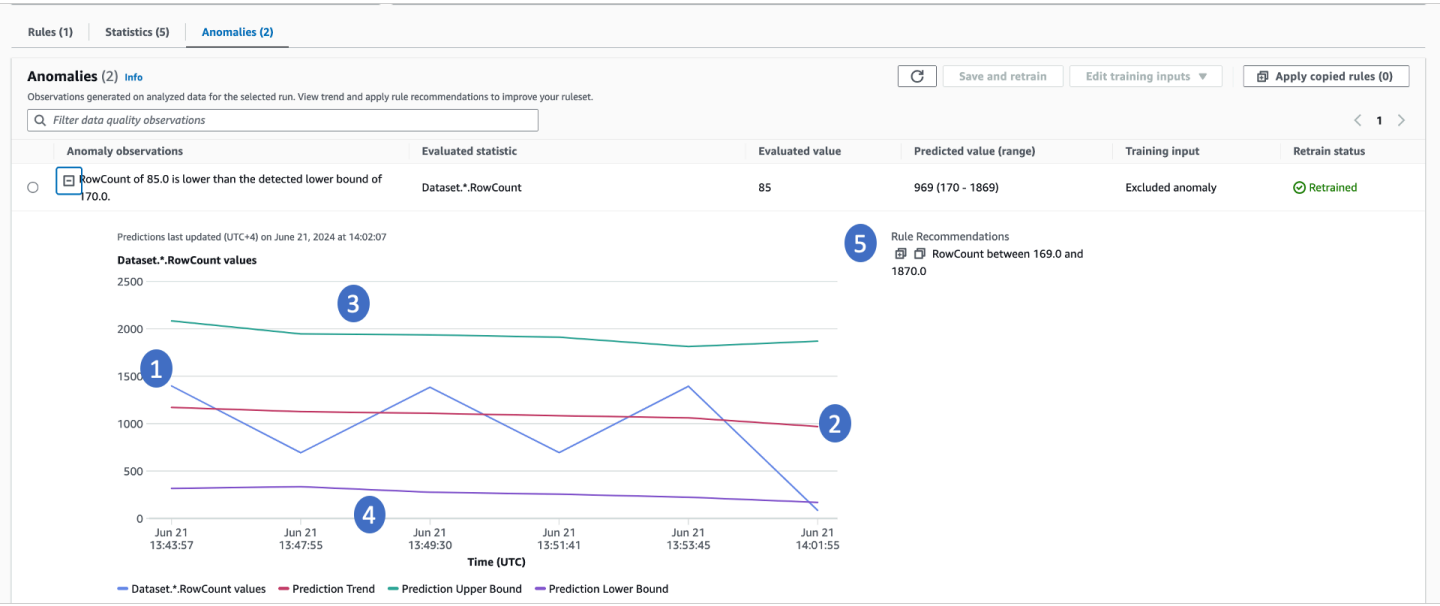

1. La estadística real y su tendencia a lo largo del tiempo.
2. Una tendencia derivada a partir del aprendizaje de la tendencia real. Es útil para entender la dirección de la tendencia.
3. El límite superior posible de la estadística.
4. El límite inferior posible de la estadística.
5. Reglas de calidad de datos recomendadas que pueden detectar estos problemas en el futuro.

Hay algunos puntos importantes que se deben tener en cuenta en relación con las anomalías:

- Cuando se generan anomalías, las puntuaciones de la calidad de los datos no se ven afectadas.
- Cuando se detecta una anomalía, se considera normal para las ejecuciones posteriores. El algoritmo de machine learning considerará este valor anómalo como entrada, a menos que se excluya explícitamente.

Reentrenamiento

Reentrenar el modelo de detección de anomalías es fundamental para detectar las anomalías correctas. Cuando se detectan anomalías, Calidad de datos de AWS Glue incluye la anomalía en el modelo como un valor normal. Para garantizar que la detección de anomalías funcione con precisión, es importante proporcionar comentarios para reconocer o rechazar la anomalía. AWS Calidad de datos de Glue proporciona mecanismos tanto en AWS Glue Studio como en las API para

brindar comentarios al modelo. Para obtener más información, consulte los documentos sobre la configuración de Detección de anomalías en las canalizaciones ETL de AWS Glue.

Detalles del algoritmo de Detección de anomalías

- El algoritmo de Detección de anomalías examina las estadísticas de datos a lo largo del tiempo. El algoritmo considera todos los puntos de datos disponibles e ignora las estadísticas que se excluyen explícitamente.
- Estas estadísticas de datos se almacenan en el servicio de AWS Glue, y usted puede proporcionar claves de AWS KMS para cifrarlas. Consulte la Guía de seguridad sobre cómo proporcionar claves de AWS KMS para cifrar las estadísticas de Calidad de datos de AWS Glue.
- El componente temporal es fundamental para el algoritmo de Detección de anomalías. En función de los valores anteriores, Calidad de datos de AWS Glue determina los límites superior e inferior. Durante esta determinación, tiene en cuenta el componente temporal. Los límites varían para los mismos valores en un intervalo de un minuto, un intervalo de una hora o un intervalo diario.

Captura de la estacionalidad

El algoritmo de detección de anomalías de Calidad de datos de AWS Glue puede capturar patrones estacionales. Por ejemplo, puede entender que los patrones de los días de semana difieren de los patrones de los fines de semana. Esto se puede ver en el siguiente ejemplo, donde Calidad de datos de AWS detecta una tendencia estacional en los valores de los datos. No tiene que tomar medidas específicas para habilitar esta capacidad. Con el tiempo, Calidad de datos de AWS Glue aprende las tendencias estacionales y detecta anomalías cuando estos patrones se rompen.

Costo

Se le cobrará en función del tiempo que se tarde en detectar las anomalías. Se cobra 1 DPU por el tiempo que se demore en detectar anomalías para cada estadística. Consulte los Precios de AWS Glue para ver ejemplos detallados.

Consideraciones clave

Almacenar las estadísticas no supone costo alguno. Sin embargo, hay un límite de 100 000 estadísticas por cuenta. Estas estadísticas se almacenarán durante un máximo de dos años.

Permisos de IAM para Calidad de datos de AWS Glue

En este tema se proporciona información para comprender las acciones y los recursos que usted, un administrador de IAM, puede utilizar en una política (de IAM) de AWS Identity and Access Management para Calidad de datos de AWS Glue. También incluye ejemplos de políticas de IAM con los permisos mínimos que necesita para usar Calidad de los datos de AWS Glue con el Catálogo de datos de AWS Glue.

Para obtener más información sobre la seguridad en Glue de AWS, consulte Seguridad en AWS Glue.

Permisos de IAM para Calidad de los datos de AWS Glue

En la siguiente tabla, se enumeran los permisos necesita un usuario para poder llevar a cabo operaciones específicas de la Calidad de datos de AWS Glue. Para establecer una autorización detallada para Calidad de datos de AWS Glue, puede especificar estas acciones en el elemento `Action` de una instrucción de política de IAM.

Acciones de Calidad de datos de AWS Glue

Acción	Descripción	Tipos de recurso
`glue:CreateDataQualityRuleset`	Concede permiso para crear un conjunto de reglas de calidad de datos.	`::dataQualityRuleset/<name>`
`glue:DeleteDataQualityRuleset`	Concede permiso para eliminar un conjunto de reglas de calidad de datos.	`::dataQualityRuleset/<name>`
`glue:GetDataQualityRuleset`	Concede permiso para recuperar un conjunto de reglas de calidad de datos.	`::dataQualityRuleset/<name>`
`glue:ListDataQualityRulesets`	Concede permiso para recuperar todos los conjuntos de reglas de calidad de datos.	`::dataQualityRuleset/*`
`glue:UpdateDataQualityRuleset`	Concede permiso para actualizar un conjunto de reglas de calidad de datos.	`::dataQualityRuleset/<name>`
`glue:GetDataQualityResult`	Concede permiso para recuperar un resultado de la ejecución de tareas de calidad de datos. Esta acción de IAM también proporciona permisos a las siguientes API: • `BatchGetDataQualityQualityResult`	`::dataQualityRuleset/<name>`

Acción	Descripción	Tipos de recurso
	• ListDataQualityStatistics • ListDataQualityStatisticAnnotations	
glue:ListDataQualityResults	Concede permiso para recuperar todos los resultados de la ejecución de tareas de calidad de datos.	::dataQualityRuleset/*
glue:CancelDataQualityRuleRecommendationRun	Concede permiso para detener una ejecución en curso de tareas de recomendación de calidad de datos.	::dataQualityRuleset/*
glue:GetDataQualityRuleRecommendationRun	Concede permiso para recuperar una ejecución de tareas de recomendación de calidad de datos.	::dataQualityRuleset/*
glue:ListDataQualityRuleRecommendationRuns	Concede permiso para recuperar todas las ejecuciones de tareas de recomendación de calidad de datos.	::dataQualityRuleset/*
glue:StartDataQualityRuleRecommendationRun	Concede permiso para iniciar una ejecución de tareas de recomendación de calidad de datos.	::dataQualityRuleset/*
glue:CancelDataQualityRulesetEvaluationRun	Concede permiso para detener una ejecución en curso de tareas de calidad de datos.	::dataQualityRuleset/*

Acción	Descripción	Tipos de recurso
glue:GetDataQualityRulesetEvaluationRun	Concede permiso para recuperar una ejecución de tareas de calidad de datos.	::dataQualityRuleset/*
glue:ListDataQualityRulesetEvaluationRuns	Concede permiso para recuperar todas las ejecuciones de tareas de calidad de datos.	::dataQualityRuleset/*
glue:StartDataQualityRulesetEvaluationRun	Concede permiso para iniciar una ejecución de tareas de calidad de datos.	::dataQualityRuleset/<name>
glue:PublishDataQuality	Concede permiso para publicar los resultados de calidad de datos	::dataQualityRuleset/<name>
glue:GetDataQualityModel	Concede permiso para recuperar un modelo de calidad de datos	::dataQualityRuleset/<name>, ::job/<name>
glue:GetDataQualityModelResult	Concede permiso para recuperar un resultado de modelo de calidad de datos	::dataQualityRuleset/<name>, ::job/<name>
glue:PutDataQualityStatisticAnnotation	Concede permiso para agregar anotaciones a Estadísticas. Esta acción de IAM también proporciona permisos a las siguientes API: • BatchPutDataQualityStatisticAnnotation	::dataQualityRuleset/<name>, ::job/<name>

Acción	Descripción	Tipos de recurso
`glue:PutDataQualityProfileAnnotation`	Concede permiso para incluir anotaciones en todas las estadísticas de un perfil.	`::dataQualityRuleset/<name>, ::job/<name>`

Se requiere una configuración de IAM para programar las ejecuciones de evaluación

Permisos de IAM

Para realizar ejecuciones programadas de evaluación de Calidad de los datos, debe agregar la acción `IAM:PassRole` a la política de permisos.

Permisos necesarios para AWS EventBridge Scheduler

Acción	Descripción	Tipos de recurso
`iam:PassRole`	Otorga permiso a IAM para que el usuario pueda pasar las funciones aprobadas.	ARN del rol utilizado para llamar `StartDataQualityRulesetEvaluationRun`

Sin estos permisos, se produce el siguiente error:

```
"errorCode": "AccessDenied"
"errorMessage": "User: arn:aws:sts::account_id:assumed-role/AWSGlueServiceRole is not
authorized to perform: iam:PassRole on resource: arn:aws:iam::account_id:role/service-
role/AWSGlueServiceRole
because no identity-based policy allows the iam:PassRole action"
```

Entidades de confianza de IAM

Los servicios de AWS Glue y AWS EventBridge Scheduler deben figurar en las entidades de confianza para poder crear y ejecutar una `StartDataQualityEvaluationRun` programada.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Principal": {
        "Service": "glue.amazonaws.com"
      },
      "Action": "sts:AssumeRole"
    },
    {
      "Effect": "Allow",
      "Principal": {
        "Service": "scheduler.amazonaws.com"
      },
      "Action": "sts:AssumeRole"
    }
  ]
}
```

Ejemplos de políticas de IAM

Un rol de IAM para Calidad de los datos de AWS Glue necesita los siguientes tipos de permisos:

- Permisos para las operaciones de Calidad de los datos de AWS Glue, de modo que pueda obtener las reglas de calidad de datos recomendadas y ejecutar una tarea de calidad de datos en una tabla del Catálogo de datos de AWS Glue. Los ejemplos de políticas de IAM de esta sección incluyen los permisos mínimos necesarios para las operaciones de Calidad de los datos de AWS Glue.
- Permisos que otorgan acceso a la tabla del Catálogo de datos y a los datos subyacentes. Estos permisos varían en función de su caso de uso. Por ejemplo, para los datos que cataloga en Amazon S3, los permisos deben incluir el acceso a Amazon S3.

> **Note**
>
> Debe configurar los permisos de Amazon S3 además de los permisos descritos en esta sección.

Permisos mínimos para obtener las reglas de calidad de datos recomendadas

Esta política de ejemplo incluye los permisos que necesita para generar las reglas de calidad de datos recomendadas.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Sid": "AllowGlueRuleRecommendationRunActions",
      "Effect": "Allow",
      "Action": [
        "glue:GetDataQualityRuleRecommendationRun",
        "glue:PublishDataQuality",
        "glue:CreateDataQualityRuleset"
      ],
      "Resource": "arn:aws:glue:us-east-1:111122223333:dataQualityRuleset/*"
    },
 {
     "Sid": "AllowCatalogPermissions",
     "Effect": "Allow",
     "Action": [
        "glue:GetPartitions",
        "glue:GetTable"
      ],
      "Resource": [
        "*"
      ]
    },
    {
      "Sid": "AllowS3GetObjectToRunRuleRecommendationTask",
      "Effect": "Allow",
      "Action": [
        "s3:GetObject"
      ],
      "Resource": "arn:aws:s3:::aws-glue-*"
    },
  {
   "Sid": "AllowPublishingCloudwatchLogs",
   "Effect": "Allow",
   "Action": [
```

```
      "logs:CreateLogStream",
      "logs:CreateLogGroup",
      "logs:PutLogEvents"
    ],
    "Resource": "*"
     }
  ]
}
```

Permisos mínimos para ejecutar una tarea de calidad de datos

Esta política de ejemplo incluye los permisos que necesita para ejecutar una tarea de evaluación de calidad de los datos.

Las siguientes instrucciones de políticas son opcionales en función de su caso de uso:

- `AllowCloudWatchPutMetricDataToPublishTaskMetrics`: es obligatoria para publicar las métricas de ejecución de calidad de datos en Amazon CloudWatch.
- `AllowS3PutObjectToWriteTaskResults`: es obligatoria para escribir los resultados de ejecución de calidad de datos en Amazon S3.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Sid": "AllowGlueGetDataQualityRuleset",
      "Effect": "Allow",
      "Action": [
        "glue:GetDataQualityRuleset"
      ],
      "Resource": "arn:aws:glue:us-east-1:111122223333:dataQualityRuleset/YOUR-
RULESET-NAME"
    },
    {
      "Sid": "AllowGlueRulesetEvaluationRunActions",
      "Effect": "Allow",
      "Action": [
        "glue:GetDataQualityRulesetEvaluationRun",
```

```
        "glue:PublishDataQuality"
      ],
      "Resource": "arn:aws:glue:us-east-1:111122223333:dataQualityRuleset/*"
    },
    {
      "Sid": "AllowCatalogPermissions",
      "Effect": "Allow",
      "Action": [
        "glue:GetPartitions",
        "glue:GetTable"
      ],
      "Resource": [
        "*"
      ]
    },
    {
      "Sid": "AllowS3GetObjectForRulesetEvaluationRun",
      "Effect": "Allow",
      "Action": [
        "s3:GetObject"
      ],
      "Resource": "arn:aws:s3:::aws-glue-*"
    },
    {
      "Sid": "AllowCloudWatchPutMetricDataToPublishTaskMetrics",
      "Effect": "Allow",
      "Action": [
        "cloudwatch:PutMetricData"
      ],
      "Resource": "*",
      "Condition": {
        "StringEquals": {
          "cloudwatch:namespace": "Glue Data Quality"
        }
      }
    },
    {
      "Sid": "AllowS3PutObjectToWriteTaskResults",
      "Effect": "Allow",
      "Action": [
        "s3:PutObject*"
      ],
      "Resource": "arn:aws:s3:::amzn-s3-demo-bucket/*"
    }
```

```
  ]
}
```

Permisos mínimos para ejecutar un trabajo de ETL de calidad de datos

Esta política de ejemplo incluye los permisos que necesita para ejecutar un trabajo de ETL de calidad de los datos.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Sid": "AllowGluePublishDataQualityResult",
      "Effect": "Allow",
      "Action": [
        "glue:PublishDataQuality"
      ],
      "Resource": "arn:aws:glue:us-east-1:111122223333:dataQualityRuleset/*"
    },
    {
      "Sid": "AllowGlueGetDataQualityResult",
      "Effect": "Allow",
      "Action": [
        "glue:GetDataQualityResult"
      ],
      "Resource": "arn:aws:glue:us-east-1:111122223333:dataQualityRuleset/*"
    },
    {
      "Sid": "AllowGlueDataQualityStatisticAnnotation",
      "Effect": "Allow",
      "Action": [
        "glue:PutDataQualityStatisticAnnotation"
      ],
      "Resource": [
        "arn:aws:glue:us-east-1:111122223333:dataQualityRuleset/*",
        "arn:aws:glue:us-east-1:111122223333::job/{JobName}"
      ]
    },
    {
```

```
      "Sid": "AllowGlueDataQualityProfileAnnotation",
      "Effect": "Allow",
      "Action": [
        "glue:PutDataQualityProfileAnnotation"
      ],
      "Resource": [
        "arn:aws:glue:us-east-1:111122223333:dataQualityRuleset/*",
        "arn:aws:glue:us-east-1:111122223333::job/{JobName}"
      ]
    }
 ]
}
```

Introducción a AWS Glue Data Quality para el Data Catalog

En esta sección de introducción se incluyen instrucciones para ayudarlo a empezar a utilizar AWS Glue Data Quality en la consola de AWS Glue. Aprenderá a completar tareas esenciales, como generar recomendaciones de reglas de la calidad de los datos y evaluar un conjunto de reglas en función de sus datos.

Temas

- Requisitos previos
- Ejemplo paso a paso
- Generar recomendaciones de reglas
- Recomendaciones de reglas de monitoreo
- Edición de los conjuntos de reglas recomendados
- Creación de un nuevo conjunto de reglas
- Ejecute un conjunto de reglas para evaluar la calidad de los datos
- Visualice la puntuación de la calidad de los datos y los resultados
- Uso de consultas de preprocesamiento
- Tipos de orígenes compatibles
- Temas relacionados

Requisitos previos

Antes de usar AWS Glue Data Quality, debe estar familiarizado con el uso del Data Catalog y de los rastreadores en AWS Glue. Con AWS Glue Data Quality, puede evaluar la calidad de las tablas de una base de datos de un Data Catalog. También necesitará lo siguiente:

- Una tabla en el Data Catalog para evaluar su conjunto de reglas de la calidad de los datos.
- Un rol de IAM para AWS Glue que se proporciona al generar recomendaciones de reglas o ejecutar una tarea de calidad de datos. Este rol debe tener permiso para acceder a los recursos que requieren diversos procesos de AWS Glue Data Quality para ejecutarse en su nombre. Entre estos recursos, se incluyen AWS Glue, Amazon S3 y CloudWatch. Para ver ejemplos de políticas que incluyen los permisos mínimos para AWS Glue Data Quality, consulte Ejemplos de políticas de IAM.

  Para obtener más información sobre los roles de IAM para AWS Glue, consulte Creación de una política de IAM para el servicio de AWS Glue y Creación de un rol de IAM para el servicio AWS Glue. También puede ver una lista de todos los permisos de AWS Glue específicos para la calidad de los datos en Autorización para acciones de AWS Glue Data Quality.
- Una base de datos con al menos una tabla que contiene una variedad de datos. La tabla utilizada en este tutorial lleva el nombre `yyz-tickets`, junto con la tabla `tickets`. Estos datos son una recopilación de información de disponibilidad pública de la ciudad de Toronto sobre multas de estacionamiento. Si crea su propia tabla, asegúrese de rellenarla con una variedad de datos válidos para obtener el mejor conjunto de reglas recomendadas.

Ejemplo paso a paso

Para ver un ejemplo paso a paso con conjuntos de datos de muestra, consulte la entrada del blog de Calidad de datos de AWS Glue.

Generar recomendaciones de reglas

Las recomendaciones de reglas facilitan la introducción a la calidad de los datos sin necesidad de escribir código. Con Calidad de datos de AWS Glue, puede analizar sus datos, identificar reglas y crear un conjunto de reglas que puede evaluar en una tarea de calidad de datos. Las ejecuciones de recomendaciones se eliminan automáticamente después de 90 días.

Para generar recomendaciones sobre reglas de calidad de datos

1. Abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. Elija Tables (Tablas) en el panel de navegación. A continuación, elija la tabla para generar recomendaciones de reglas de la calidad de los datos.
3. En la página de detalles de la tabla, seleccione la pestaña Calidad de los datos para acceder a las reglas y configuraciones de la Calidad de datos de AWS Glue para la tabla.
4. En la pestaña Calidad de los datos, seleccione Agregar reglas y supervisar la calidad de los datos.
5. En la página Generador de conjuntos de reglas, una alerta en la parte superior de la página pedirá que inicie una tarea de recomendación si no se ejecuta ninguna recomendación de reglas.
6. Seleccione Recomendar reglas para abrir el modal e ingrese sus parámetros para la tarea de recomendación.
7. Elija un rol de IAM con acceso a AWS Glue. Este rol debe tener permiso para acceder a los recursos que requieren diversos procesos de Calidad de datos de AWS Glue para ejecutarse en su nombre.
8. Una vez completados los campos según sus preferencias, seleccione Recomendar reglas para iniciar la ejecución de la tarea de recomendación. Si las ejecuciones recomendadas están en curso o ya se completaron, puede gestionar las ejecuciones en esta alerta. Puede que tenga que actualizar la alerta para ver el cambio de estado. Las tareas de recomendación completadas y en curso aparecen en la página Historial de ejecuciones, que muestra todas las ejecuciones de recomendaciones de los últimos 90 días.

Qué significan las reglas recomendadas

Calidad de datos de AWS Glue genera reglas basadas en los datos de cada columna de la tabla de entrada. Utiliza las reglas para identificar los posibles límites por los que se pueden filtrar los datos para mantener los requisitos de calidad. La siguiente lista de reglas generadas incluye ejemplos que son útiles para entender qué significan las reglas y qué podrían hacer cuando se apliquen a los datos.

Para obtener una lista completa de los tipos de reglas del lenguaje de definición de calidad de datos (DQDL) generados, consulte la referencia de tipos de reglas del DQDL.

- `IsComplete "SET_FINE_AMOUNT"` -La regla `IsComplete` verifica que la columna esté rellenada en cualquier fila determinada. Use esta regla para etiquetar las columnas como no opcionales en los datos.
- `Uniqueness "TICKET_NUMBER" > 0.95` -La regla `Uniqueness` verifica que los datos de la columna cumplan con algún umbral de unicidad. En este ejemplo, se determinó que los datos que rellenan una fila para `"TICKET_NUMBER"` tenían, como máximo, un 95 % de contenido idéntico al de todas las demás filas, que es lo que sugiere esta regla.
- `ColumnValues "PROVINCE" in ["ON", "QC", "AB", "NY",...]` -La regla `ColumnValues` define valores válidos para la columna en función del contenido de la columna existente. En este ejemplo, los datos de cada fila son una matrícula de dos letras para un estado o una provincia.
- `ColumnLength "INFRACTION_DESCRIPTION" between 15 and 31` -La regla `ColumnLength` impone una restricción de longitud a los datos de una columna. Esta regla se genera a partir de los datos de la muestra en función de las longitudes mínima y máxima registradas para una columna de cadenas.

Recomendaciones de reglas de monitoreo

Cuando se ejecuten las recomendaciones de reglas de calidad de los datos, la página Agregar reglas y supervisar la calidad de los datos muestra información y acciones adicionales que puede realizar en la barra superior.

Cuando las recomendaciones de reglas estén en curso, puede seleccionar Detener la ejecución antes de que finalice la tarea de recomendación. Mientras la tarea esté en curso, verá el estado, en curso y la fecha y hora en que se inició la ejecución.

Cuando se hayan completado las recomendaciones de reglas, la barra de recomendaciones de reglas mostrará el número de reglas recomendadas, el estado de la última ejecución de la recomendación y la fecha y hora en que finalizó.

Para agregar reglas recomendadas, seleccione Insertar recomendación de regla. Para ver las reglas recomendadas anteriormente, selecciona una fecha específica. Para ejecutar una nueva recomendación, seleccione Más acciones y, a continuación, elija Reglas recomendadas.

Establezca la configuración predeterminada mediante la selección de Administrar la configuración de usuario. Puede establecer la ruta predeterminada de Amazon S3 para almacenar conjuntos de reglas o configurar un rol predeterminado para ejecutar el Data Catalog.

Edición de los conjuntos de reglas recomendados

Como Calidad de datos de AWS Glue genera reglas basadas en los datos existentes que tiene disponibles, es posible que vea algunas reglas inesperadas o no deseadas en las sugerencias automatizadas. Para aprovechar al máximo los conjuntos de reglas recomendados, debe evaluarlos y modificarlos. En este paso del tutorial, debe tomar las reglas generadas en el paso anterior y ajustarlas para aplicar características más restrictivas a algunos datos. También flexibiliza otras reglas para garantizar que más adelante se puedan agregar datos correctos y únicos.

Editar un conjunto de reglas sugerido

1. En la consola de AWS Glue, elija Data Catalog y, a continuación, seleccione Tablas de bases de datos en el panel de navegación. Elija la tabla `tickets`.
2. En la página de detalles de la tabla, seleccione la pestaña Calidad de los datos para acceder a las opciones de la calidad de los datos de AWS Glue para la tabla.
3. En la sección Conjuntos de reglas, seleccione el conjunto de reglas generado en Generar recomendaciones de reglas.
4. Elija Acciones y, a continuación, elija Editar en la ventana de la consola. El editor de conjuntos de reglas se carga en la consola. Incluye un panel de edición para las reglas y una referencia rápida para el DQDL.
5. Elimine la línea 2 del guion. Esto flexibiliza el requisito de limitar el tamaño de la base de datos a un número determinado de filas. Tras la edición, el archivo debe contener lo siguiente en las líneas 1 a 3:

```
Rules = [
    IsComplete "TAG_NUMBER_MASKED",
    ColumnLength "TAG_NUMBER_MASKED" between 6 and 9,
```

6. Elimine la línea 25 del guion. Esto flexibiliza el requisito de que el 96 % de las provincias registradas estén ON. Tras la edición, el archivo debe contener lo siguiente desde la línea 24 hasta el final del conjunto de reglas:

```
ColumnValues "PROVINCE" in ["ON", "QC", "AB", "NY", "AZ", "NS", "BC", "MI", "PQ",
 "MB", "PA", "FL", "SK", "NJ", "OH", "NB", "IL", "MA", "CA",
    "VA", "TX", "NF", "MD", "PE", "CT", "NC", "GA", "IN", "OR", "MN", "TN", "WI",
 "KY", "MO", "WA", "NH", "SC", "CO", "OK", "VT", "RI", "ME", "AL",
    "YT", "IA", "DE", "AR", "LA", "XX", "WV", "MT", "KS", "NT", "DC", "NV", "NE",
 "UT", "MS", "NM", "ID", "SD", "ND", "AK", "NU", "GO", "WY", "HI"],
```

```
ColumnLength "PROVINCE" = 2
]
```

7. Cambie la línea 14 por lo siguiente:

```
IsComplete "TIME_OF_INFRACTION",
```

   Esto refuerza el requisito de la columna al limitar la base de datos únicamente a los tickets que contengan una fecha de infracción registrada. En este conjunto de datos, siempre debe considerar que los tickets sin una hora de infracción registrada son datos no válidos. Esto es diferente a las situaciones en las que la partición o la transformación podrían ser más adecuadas para seguir utilizando los datos o inspeccionándolos a fin de determinar una regla de calidad.

8. Seleccione Actualizar conjunto de reglas en la parte inferior de la página de la consola.

Creación de un nuevo conjunto de reglas

Un conjunto de reglas es un grupo de reglas de la calidad de los datos que se evalúa en relación con los datos. En la consola de AWS Glue, puede crear conjuntos de reglas personalizados mediante el lenguaje de definición de calidad de los datos (DQDL).

Para crear un conjunto de reglas de calidad de datos

1. En la consola de AWS Glue, elija Data Catalog, luego Bases de datos y, a continuación, Tablas en el panel de navegación. Seleccione la tabla `tickets`.
2. Abra la pestaña Data quality (Calidad de datos).
3. En la sección Conjuntos de reglas, elija Crear regla. El editor DQDL se inicia en la consola. Cuenta con un área de texto para la edición directa y una referencia rápida para las reglas del DQDL y el esquema de la tabla.
4. Comience a agregar reglas al área de texto del editor DQDL. Puede escribir reglas directamente desde este tutorial o utilizar la característica generador de reglas DQDL del editor de reglas de calidad de datos.

> **Note**
>
> Cómo usar el generador de reglas DQDL
>
> 1. Seleccione un tipo de regla de la lista y elija el signo más para insertar un ejemplo de sintaxis en el panel del editor.
> 2. Intercambie los nombres de las columnas del marcador de posición por sus propios nombres de columna. Los nombres de las columnas de la tabla están disponibles en la pestaña Esquema.
> 3. Actualice el parámetro de expresión como crea conveniente. Para obtener una lista completa de las expresiones que admite DQDL, consulte Expresiones.

Por ejemplo, las siguientes reglas son restricciones para la validación de datos de la columna `ticket_number` de la tabla `tickets`. Para agregar las siguientes reglas, utilice el generador de reglas DQDL o edite directamente el conjunto de reglas:

```
IsComplete "ticket_number",
IsUnique "ticket_number",
ColumnValues "ticket_number" > 9000000000
```

5. Proporcione un nombre para su nuevo conjunto de reglas en el campo Nombre del conjunto de reglas.
6. Seleccione Guardar conjunto de reglas.

Evaluación de la calidad de los datos en varios conjuntos de datos

Puede configurar reglas de calidad de datos en varios conjuntos de datos mediante los conjuntos de reglas ReferentialIntegrity y DatasetMatch. ReferentialIntegrity comprueba si los datos del conjunto de datos principal están presentes en otros conjuntos de datos.

Para agregar un conjunto de datos de referencia, seleccione la pestaña Esquema y, a continuación, seleccione Actualizar tablas de referencia. Se pedirá que seleccione una base de datos y una tabla. Puede agregar la tabla y, a continuación, configurar las reglas de calidad de los datos. Los tipos de reglas como AggregateMatch, RowCountMatch, ReferentialIntegrity, SchemaMatch y DatasetMatch permiten realizar comprobaciones de calidad de datos en varios conjuntos de datos.

Ejecute un conjunto de reglas para evaluar la calidad de los datos

Al ejecutar una tarea de calidad de datos, Calidad de datos de AWS Glue evalúa un conjunto de reglas mediante la comparación con los datos y calcula una puntuación de la calidad de los datos. Esta puntuación representa el porcentaje de reglas de la calidad de los datos que se aprobaron para la entrada.

Para ejecutar una tarea de calidad de datos

1. En la consola de AWS Glue, elija Data Catalog, luego Bases de datos y, a continuación, Tablas en el panel de navegación. Seleccione la tabla `tickets`.
2. Seleccione la pestaña Calidad de los datos.
3. En la lista Conjuntos de reglas, elija el conjunto de reglas que quiere evaluar con respecto a la tabla. Para este paso, recomendamos que utilice un conjunto de reglas que ya haya escrito o modificado en lugar de generar reglas. Seleccione Ejecutar.
4. En el modal, elija su rol de IAM. Este rol debe tener permiso para acceder a los recursos que requieren diversos procesos de Calidad de datos de AWS Glue para ejecutarse en su nombre. Puede guardar el rol de IAM como predeterminado o modificarlo desde la página de Ajuste predeterminado.
5. En Data quality actions (Acciones de calidad de datos), elija si quiere publicar las métricas en Amazon CloudWatch. Cuando se selecciona esta opción, Calidad de datos de AWS Glue publica métricas que indican la cantidad de reglas que se aprobaron y la cantidad de reglas con errores. Para tomar medidas con respecto a las métricas almacenadas de esta forma, puede utilizar las alarmas de CloudWatch. También se publican las métricas clave en Amazon EventBridge para que pueda configurar las alertas. Para obtener más información, consulte Configurar alertas, implementaciones y programación.
6. En Frecuencia de ejecución, seleccione Ejecutar bajo demanda o programa el conjunto de reglas. Al programar un conjunto de reglas, se solicitará el nombre de la tarea. La programación se creará en Amazon EventBridge. Puede editar su horario en Amazon EventBridge.
7. Para guardar los resultados de calidad de datos en Amazon S3, elija una Ubicación de resultados de calidad de datos. El rol de IAM que seleccionó anteriormente para esta tarea debe tener acceso de escritura a esta ubicación.
8. En Configuraciones adicionales, ingrese la cantidad solicitada de trabajadores que quiere que AWS Glue asigne a su tarea de calidad de datos.
9. Si lo desea, puede configurar un filtro en el origen de datos. Esto lo ayuda a reducir los datos que lee. También puede usar un filtro para ejecutar validaciones incrementales al seleccionar la

información de la partición y pasarla como parámetros mediante llamadas a la API. Para mejorar el rendimiento, puede proporcionar un predicado de partición.

10. Seleccione Ejecutar. Debería ver la nueva tarea en la lista Data quality task runs (Ejecuciones de tareas de calidad de datos). Cuando la columna de estado de ejecución de la tarea aparezca como Completada, podrá ver los resultados de la puntuación de calidad. Puede que tenga que actualizar la ventana de la consola para que el estado se actualice correctamente.
11. Para ver la columna con los detalles de los resultados de calidad de los datos, seleccione el icono “+” para expandir el conjunto de reglas. Los resultados muestran las reglas que se aprobaron y las que no se aprobaron en la evaluación, además del motivo del fallo de la regla.

Visualice la puntuación de la calidad de los datos y los resultados

Para ver la última ejecución de todos los conjuntos de reglas creados

1. En la consola de AWS Glue, seleccione Tables (Tablas) en el panel de navegación. A continuación, elija la tabla para ejecutar una tarea de calidad de datos.
2. Seleccione la pestaña Calidad de los datos.
3. La instantánea de la calidad de los datos muestra una tendencia general de las ejecuciones a lo largo del tiempo. De forma predeterminada, se muestran las últimas 10 ejecuciones de todos los conjuntos de reglas. Para filtrar por conjunto de reglas, seleccione el que desee en la lista desplegable. Si hay menos de 10 ejecuciones, se muestran todas las ejecuciones completadas disponibles.
4. En la tabla de calidad de los datos, se muestra cada conjunto de reglas con su última ejecución (si la hay), junto con la puntuación. Al expandir el conjunto de reglas, se muestran las reglas que están en ese conjunto de reglas, junto con los resultados de las reglas de esa ejecución.

Para ver la última ejecución de un conjunto de reglas concreto

1. En la consola de AWS Glue, seleccione Tables (Tablas) en el panel de navegación. A continuación, elija la tabla para ejecutar una tarea de calidad de datos.
2. Seleccione la pestaña Calidad de los datos.
3. En la tabla calidad de los datos, elija un conjunto de reglas específico.
4. En la página detalles del conjunto de reglas, seleccione la pestaña Historial de ejecuciones.

Todas las ejecuciones de evaluación de este conjunto de reglas en particular se muestran en la tabla de esta pestaña. Puede ver el historial de las puntuaciones y el estado de las ejecuciones.

5. Para ver más información sobre una ejecución concreta, elija el ID de ejecución para ir a la página de detalles de la ejecución de evaluación. En esta página, puede ver información específica sobre la ejecución y más detalles sobre el estado de los resultados de las reglas individuales.

Uso de consultas de preprocesamiento

La calidad de datos de AWS Glue admite consultas de preprocesamiento que le permiten transformar sus datos antes de ejecutar comprobaciones de calidad de los datos. Esta característica le permite:

- Crear columnas derivadas para la validación de la calidad de los datos.
- Filtrar los datos en función de condiciones específicas.
- Realizar cálculos o transformaciones para los controles de calidad.
- Validar las relaciones entre columnas.

> **Note**
>
> Esta característica solo es compatible con las API y no está disponible a través de la consola.

Uso de consultas de preprocesamiento con la CLI y el SDK

Ejecuciones de recomendaciones

En los siguientes ejemplos, se muestra cómo usar consultas de preprocesamiento con ejecuciones de recomendaciones.

AWS CLI:

```
aws glue start-data-quality-rule-recommendation-run \
  --data-source '{"DataQualityGlueTable": { \
    "DatabaseName": "mydatabase", \
    "TableName": "mytable", \
    "PreProcessingQuery": "SELECT sepal_length, sepal_width, petal_length, petal_width,
 class, (sepal_length + sepal_width) as sepal_total FROM `mydatabase.mytable`" \
```

```
  }}' \
  --role "arn:aws:iam::123456789012:role/GlueDataQualityRole" \
  --created-ruleset-name "my-ruleset-with-preprocessing"
```

SDK de Java:

```
StartDataQualityRuleRecommendationRunRequest request = new
 StartDataQualityRuleRecommendationRunRequest()
    .withDataSource(new DataSource()
        .withDataQualityGlueTable(new DataQualityGlueTable()
            .withDatabaseName("mydatabase")
            .withTableName("mytable")
            .withPreProcessingQuery("SELECT sepal_length, sepal_width, " +
                "(sepal_length + sepal_width) as sepal_total " +
                "FROM `mydatabase.mytable`")))
    .withRole("arn:aws:iam::123456789012:role/GlueDataQualityRole")
    .withCreatedRulesetName("my-ruleset-with-preprocessing");

glueClient.startDataQualityRuleRecommendationRun(request);
```

Ejecuciones de evaluación de conjuntos de reglas

En los siguientes ejemplos se muestra cómo usar consultas de preprocesamiento con ejecuciones de evaluación de conjuntos de reglas.

AWS CLI:

```
aws glue start-data-quality-ruleset-evaluation-run \
  --data-source '{"DataQualityGlueTable": { \
    "DatabaseName": "mydatabase", \
    "TableName": "mytable", \
    "PreProcessingQuery": "SELECT order_id, amount, (tax + shipping) as total_fees FROM
 `mydatabase.mytable`" \
  }}' \
  --role "arn:aws:iam::123456789012:role/GlueDataQualityRole" \
  --ruleset-names '["my-ruleset"]'
```

SDK de Java:

```
StartDataQualityRulesetEvaluationRunRequest request = new
 StartDataQualityRulesetEvaluationRunRequest()
    .withDataSource(new DataSource()
        .withDataQualityGlueTable(new DataQualityGlueTable()
```

```
            .withDatabaseName("mydatabase")
            .withTableName("mytable")
            .withPreProcessingQuery("SELECT order_id, amount, " +
                "(tax + shipping) as total_fees " +
                "FROM `mydatabase.mytable`")))
    .withRole("arn:aws:iam::123456789012:role/GlueDataQualityRole")
    .withRulesetNames(Arrays.asList("my-ruleset"));

glueClient.startDataQualityRulesetEvaluationRun(request);
```

Consideraciones al crear consultas de preprocesamiento

Al escribir una consulta de preprocesamiento:

- La referencia de la tabla debe estar formateada de forma que `` `databaseName.tableName` `` utilice comillas invertidas.
- La consulta debe ser una instrucción SELECT válida.
- Los nombres de las columnas del resultado de la consulta se utilizarán para las reglas de calidad de los datos.

En el siguiente ejemplo, se muestra una consulta de preprocesamiento:

```
SELECT
    sepal_length,
    sepal_width,
    petal_length,
    petal_width,
    class,
    (sepal_length + sepal_width) as sepal_total
FROM `mydatabase.mytable`
```

Limitaciones

- La consulta debe hacer referencia a la tabla usando comillas invertidas y el formato `` `databaseName.tableName` `` completo.
- La longitud máxima de la consulta es de 51 200 caracteres.
- La consulta debe devolver al menos una fila de datos.
- Todas las columnas a las que se hace referencia en el conjunto de reglas deben estar presentes en el resultado de la consulta.

Tipos de orígenes compatibles

Compatibilidad con tipos de tabla según la configuración de AWS Lake Formation

Tipo de tabla	AWS Lake Formation: acceso total a las tablas	AWS Lake Formation habilitado con columnas	AWS Lake Formation habilitado con filtros de datos	Compatibilidad de AWS Lake Formation entre cuentas: acceso total a las tablas	AWS Lake Formation Disabled (Desactivado)
Parquet	Compatible	No es compatible	No es compatible	Soportado	Compatible
ORC	Compatible	No es compatible	No es compatible	Soportado	Compatible
CSV, JSON, TSV	Compatible	No es compatible	No es compatible	Soportado	Compatible
Avro	Compatible	No es compatible	No es compatible	Soportado	Compatible
JSON	Compatible	No es compatible	No es compatible	Soportado	Compatible
Iceberg	Compatible	No es compatible	No es compatible	Soportado	Compatible
HUDI	No es compatible	No es compatible	No es compatible	No es compatible	Compatible
Delta	No es compatible	No es compatible	No es compatible	No es compatible	Compatible
RMS	Compatible*	Compatible*	Compatible*	No es compatible	No es compatible

Tipo de tabla	AWS Lake Formation: acceso total a las tablas	AWS Lake Formation habilitado con columnas	AWS Lake Formation habilitado con filtros de datos	Compatibilidad de AWS Lake Formation entre cuentas: acceso total a las tablas	AWS Lake Formation Disabled (Desactivado)
Tablas de Amazon S3	Compatible*	No es compatible	No es compatible	No aplicable	Compatible
Amazon RDS y Aurora	No aplicable	No aplicable	No aplicable	No aplicable	No es compatible
JDBC	No aplicable	No aplicable	No aplicable	No aplicable	Compatible

* La consola de AWS Glue no es compatible con las tablas de Amazon S3 y SageMaker Lakehouse. Actualmente, las ejecuciones de recomendación de catálogos de datos y las ejecuciones de evaluación de la calidad de los datos de catálogos de datos de tablas de Amazon S3 y de SageMaker Lakehouse solo se admiten mediante la CLI.

Otras limitaciones conocidas

- Tablas Symlink de Delta Lake: no se admiten en las ejecuciones de recomendación de calidad de datos ni en las ejecuciones de evaluación de la calidad de los datos del Catálogo de datos de AWS Glue.
- Publicación de recursos de tablas de Amazon S3 en SageMaker Unified Studio: actualmente, la publicación de tablas de Amazon S3 como recursos en SageMaker Unified Studio no está disponible; por lo tanto, no es posible visualizar las ejecuciones de calidad de los datos de las tablas de Amazon S3 desde SageMaker Unified Studio.

Temas relacionados

- Referencia de tipo de regla de DQDL
- Referencia del lenguaje de definición de calidad de datos (DQDL)

Evaluación de la calidad de los datos con AWS Glue Studio

Calidad de datos de AWS Glue evalúa y supervisa la calidad de sus datos en función de las reglas que defina. Esto facilita la identificación de los datos que requieren acción. En AWS Glue Studio, puede agregar nodos de calidad de datos a su trabajo visual para crear reglas de calidad de datos en las tablas del catálogo de datos. Puede monitorear y evaluar los cambios aplicados en sus conjuntos de datos a medida que evolucionan. Para obtener información general sobre cómo trabajar con Data Quality de AWS Glue en AWS Glue Studio, consulte el siguiente vídeo.

A continuación se indican los pasos generales para trabajar con Calidad de datos de AWS Glue:

1. Cree reglas de calidad de datos: cree un conjunto de reglas de calidad de datos con el generador de DQDL; para ello, seleccione los conjuntos de reglas integrados que configure.
2. Configure un trabajo de calidad de datos: defina acciones en función de los resultados de calidad de los datos y las opciones de salida.
3. Guarde y ejecute un trabajo de calidad de datos: cree y ejecute un trabajo. Al guardar el trabajo, se guardarán los conjuntos de reglas que creó para el trabajo.
4. Supervise y revise los resultados de calidad de los datos: revise los resultados de calidad de los datos una vez finalizada la ejecución del trabajo. Si lo desea, programe el trabajo para una fecha futura.

Ventajas

Los analistas de datos, ingenieros de datos y científicos de datos pueden utilizar el nodo de evaluación de la calidad de los datos en AWS Glue Studio para analizar, configurar, supervisar y mejorar la calidad de los datos desde el editor de trabajos visuales. Las ventajas de utilizar el nodo de calidad de datos incluyen lo siguiente:

- Puede detectar problemas de calidad de los datos: puede crear reglas que comprueben las características de los conjuntos de datos para determinar si hay problemas.
- Empezar a trabajar es fácil: puede empezar con reglas y acciones prediseñadas.
- Integración estrecha: puede utilizar nodos de calidad de datos en AWS Glue Studio porque Calidad de datos de AWS Glue se ejecuta sobre el Catálogo de datos de AWS Glue.

Evaluación de la calidad de los datos para los trabajos de ETL en AWS Glue Studio

En este tutorial, empezará a utilizar la calidad AWS Glue de los datos en AWS Glue Studio. Aprenderá a realizar lo siguiente:

- El conjunto de reglas se crea mediante lenguaje de definición de calidad de datos (DQDL).
- Especificar las acciones de calidad de datos, los datos que se van a generar y la ubicación de la salida de los resultados de calidad de datos.
- Revisar los resultados de calidad de datos.

Para practicar con un ejemplo, consulte la entrada del blog Introducción a la calidad de los datos AWS para tuberías ETL.

Paso 1: agregar el nodo de transformación de evaluación de Calidad de datos al trabajo visual

En este paso, agrega el nodo de evaluación de Calidad de datos al editor de trabajos visuales.

Para agregar el nodo de calidad de datos

1. En la consola AWS Glue Studio, seleccione Visual con un origen y un destino en la sección Crear trabajo y, luego, seleccione Crear.
2. Elija un nodo al que desee aplicar la transformación de calidad de los datos. Normalmente será un nodo de transformación o un origen de datos.
3. Abra el panel de recursos de la izquierda mediante la selección del icono “+”. También puede escribir calidad de los datos en la barra de búsqueda y, luego, elegir Evaluar la calidad de los datos en los resultados de la búsqueda.
4. El editor de trabajos visual mostrará el nodo de transformación Evaluar la calidad de los datos ramificándose a partir del nodo que seleccionó. En la parte derecha de la consola, la pestaña Transform (Transformación) se abre automáticamente. Si necesita cambiar el nodo principal, seleccione la pestaña Propiedades del nodo y, luego, elija el nodo principal en el menú desplegable.

   Al elegir un nuevo nodo principal, se establece una nueva conexión entre el nodo principal y el nodo Evaluate Data Quality (Evaluar la calidad de los datos). Elimine los nodos principales no

deseados. Solo se puede conectar un nodo principal a un nodo Evaluate Data Quality (Evaluar la calidad de los datos).

5. La transformación de evaluación de la calidad de los datos admite varias fuentes, por lo que puede validar las reglas de calidad de los datos en varios conjuntos de datos. Entre las reglas que admiten varios conjuntos de datos se incluyen ReferentialIntegrity, DatasetMatch, SchemaMatch, RowCountMatch y AggregateMatch.

   Al agregar varias entradas a la transformación de evaluación de la calidad de los datos, debe seleccionar la entrada “principal”. La entrada principal es el conjunto de datos para el que desea validar la calidad de los datos. Todos los demás nodos o entradas se tratan como referencias.

   Puede utilizar la transformación de evaluación de la calidad de los datos para identificar registros específicos que no superaron las comprobaciones de calidad de los datos. Recomendamos que elija el conjunto de datos principal, ya que las nuevas columnas que indican los registros incorrectos se agregan al conjunto de datos principal.

6. Puede especificar alias para los orígenes de datos de entrada. Los alias proporcionan otra forma de hacer referencia al origen de entrada cuando se utiliza la regla de ReferentialIntegrity. Ya que solo se puede designar un origen de datos como fuente principal, cada origen de datos adicional que agregue necesitará un alias.

   En el siguiente ejemplo, la regla ReferentialIntegrity especifica el origen de datos de entrada por el nombre del alias y realiza una comparación uno a uno con el origen de datos principal.

```
Rules = [
 ReferentialIntegrity “Aliasname.name” = 1
]
```

Paso 2: crear una regla con DQDL

En este paso, va a crear una regla con DQDL. Para este tutorial, creará una sola regla con el tipo de regla Integridad. Este tipo de regla comprueba el porcentaje de valores completos (no nulos) de una columna con respecto a una expresión determinada. Para obtener más información sobre cómo usar DQDL, consulte DQDL.

1. En la pestaña Transformación, haga clic en el botón de inserción para agregar un tipo de regla. De esta forma, se agrega el tipo de regla al editor de reglas, donde puede ingresar los parámetros de la regla.

> **Note**
>
> Al editar las reglas, asegúrese de que estén entre corchetes y separadas por comas. Por ejemplo, una expresión de regla completa tendrá el siguiente aspecto:
>
> ```
> Rules= [
>     Completeness "year">0.8, Completeness "month">0.8
> ]
> ```
>
> En este ejemplo se especifica el parámetro de integridad de las columnas denominadas “año” y “mes”. Estas columnas deben estar “completas” en más del 80 % o tener datos en más del 80 % de las instancias de cada columna correspondiente para que la regla se apruebe.

En este ejemplo, busque e inserte el tipo de regla Completeness (Integridad). De esta forma, se agregará el tipo de regla al editor de reglas. Este tipo de regla tiene la siguiente sintaxis: `Completeness <COL_NAME> <EXPRESSION>`.

La mayoría de los tipos de reglas requieren que proporcione una expresión como parámetro para crear una respuesta booleana. Para obtener más información sobre las expresiones de DQDL admitidas, consulte Expresiones de DQDL. A continuación, agregará el nombre de la columna.

2. En el generador de reglas de DQDL, haga clic en la pestaña Esquema. Utilice la barra de búsqueda para localizar el nombre de la columna en el esquema de entrada. El esquema de entrada muestra el nombre de la columna y el tipo de datos.
3. En el editor de reglas, haga clic a la derecha del tipo de regla para insertar el cursor en el lugar en el que se insertará la columna. También puede escribir el nombre de la columna en la regla.

   Por ejemplo, en la lista de columnas de la lista del esquema de entrada, haga clic en el botón de inserción situado junto a la columna (en este ejemplo, year). De esta forma, se agregará la columna a la regla.
4. A continuación, en el editor de reglas, agregue una expresión para evaluar la regla. Dado que el tipo de regla Integridad compara el porcentaje de valores completos (no nulos) de una columna

con una expresión determinada, ingrese una expresión como `> 0.8`. Esta regla comprobará la columna si tiene más del 80 % de valores completos (no nulos).

Paso 3: configurar las acciones y la salida de Calidad de datos

Tras crear las reglas de calidad de los datos, puede seleccionar opciones adicionales para especificar la salida del nodo de calidad de datos.

1. En Data quality transform output (Salida de la transformación de calidad de datos), elija una de las siguientes opciones:

   - Datos originales: elija generar los datos de entrada originales. Al elegir esta opción, se agrega un nuevo nodo secundario, “rowLevelOutcomes”, al trabajo. El esquema coincide con el esquema del conjunto de datos principal que se pasó como entrada a la transformación. Esta opción es útil si solo quieres pasar los datos y fallar en el trabajo cuando se producen problemas de calidad.

     Otro caso de uso es cuando se desean detectar registros defectuosos que no superaron las comprobaciones de calidad de los datos. Para detectar registros incorrectos, elija la opción Agregar nuevas columnas para indicar errores en la calidad de los datos. Esta acción agrega cuatro columnas nuevas al esquema de la transformación “rowLevelOutcomes”.

     - DataQualityRulesPass (Matriz de cadenas): proporciona una serie de reglas que han superado las comprobaciones de calidad de los datos.
     - DataQualityRulesFail (Matriz de cadenas): proporciona una serie de reglas que no superaron las comprobaciones de calidad de los datos.
     - DataQualityRulesSkip (Matriz de cadenas): proporciona una serie de reglas que se omitieron. Las siguientes reglas no pueden identificar los registros de errores, ya que se aplican a nivel de conjunto de datos.
       - AggregateMatch
       - ColumnCount
       - ColumnExists
       - ColumnNamesMatchPattern
       - CustomSql
       - RowCount
       - RowCountMatch

    - StandardDeviation
    - Media
    - ColumnCorrelation
  - DataQualityEvaluationResult: proporciona el estado “Aprobado” o “Fallido” a nivel de fila. Tenga en cuenta que los resultados generales pueden ser FALLA, pero es posible que se apruebe un registro determinado. Por ejemplo, es posible que la regla RowCount haya fallado, pero es posible que todas las demás reglas se hayan aplicado correctamente. En esos casos, el estado de este campo es “Aprobado”.

2. Resultados de calidad de datos: elija generar las reglas configuradas y el estado correspondiente que indique que han aprobado o suspendido. Esta opción es útil para escribir los resultados en Amazon S3 u otras bases de datos.
3. Configuración de la salida de calidad de datos (Opcional): elija la Configuración de la salida de calidad de datos para mostrar el campo Ubicación del resultado de calidad de datos. Luego, haga clic en Explorar para buscar una ubicación de Amazon S3 y establecerla como destino de la salida de la calidad de los datos.

Paso 4. Configurar acciones de calidad de datos

Las acciones permiten publicar métricas en CloudWatch o detener trabajos en función de criterios específicos. Las acciones solo están disponibles después de crear una regla. Al elegir esta opción, también se publican las mismas métricas en Amazon EventBridge. Puedes usar estas opciones para crear alertas para las notificaciones.

- En caso de error en un conjunto de reglas: puede elegir qué hacer si un conjunto de reglas falla mientras se ejecuta el trabajo. Si desea que el trabajo no se apruebe si la calidad de los datos no es buena, elija cuándo no debe aprobarse el trabajo mediante la selección de una de las siguientes opciones. De forma predeterminada, esta acción no está seleccionada y el trabajo finalizará su ejecución incluso si las reglas de calidad de los datos no aprueban.
  - Ninguno: si selecciona Ninguno (opción predeterminada), el trabajo no se aprobará y seguirá ejecutándose a pesar de los errores del conjunto de reglas.
  - Error en el trabajo después de cargar los datos en el destino: se produce un error en el trabajo y no se guarda ningún dato. Para guardar los resultados, elija una ubicación de Amazon S3 en la que se guarden los resultados de calidad de los datos.

- Trabajo erróneo sin cargar los datos de destino: esta opción anula el trabajo inmediatamente cuando se produce un error en la calidad de los datos. No carga ningún destino de datos, incluidos los resultados de la transformación de la calidad de los datos.

Paso 5: ver resultados de calidad de datos

Después de ejecutar el trabajo, elija la pestaña Calidad de los datos para ver los resultados de calidad de los datos.

1. Para cada trabajo ejecutado, consulte los resultados de Calidad de datos. Cada nodo muestra un estado de calidad de datos y detalles del estado. Haga clic en un nodo para ver todas las reglas y el estado de cada una de ellas.
2. Haga clic en Descargar resultados para descargar un archivo CSV que contenga información sobre la ejecución del trabajo y los resultados de calidad de datos.
3. Si ha ejecutado más de un trabajo con resultados de calidad de los datos, puede filtrar los resultados por intervalo de fechas y horas. Haga clic en Filtrar por intervalo de fechas y horas para expandir la ventana de filtros.
4. Elija un intervalo relativo o un intervalo absoluto. En el caso de los intervalos absolutos, utilice el calendario para seleccionar una fecha e ingrese valores para la hora de inicio y la hora de finalización. Cuando haya finalizado, elija Aplicar cambios.

Calidad de datos automática

Al crear un trabajo de ETL de AWS Glue con Amazon S3 como destino, ETL de AWS Glue activa automáticamente una regla de calidad de datos que comprueba si los datos que se están cargando tienen al menos una columna. Esta regla está diseñada para garantizar que los datos que cargue no estén vacíos ni dañados. Sin embargo, si esta regla devuelve un error, el trabajo no dejará de realizarse; en su lugar, notará una reducción en la puntuación de calidad de los datos. Además, la detección de anomalías está habilitada de forma predeterminada, por lo que puede supervisar el número de columnas de los datos. Si hay alguna variación o elemento anómalo en el recuento de columnas, ETL de AWS Glue le informará sobre estas anomalías. Esta característica le permite identificar posibles problemas con los datos y a tomar las medidas adecuadas. Para ver la regla de calidad de los datos y su configuración, puede hacer clic en el destino de Amazon S3 en su trabajo de ETL de AWS Glue. Se mostrará la configuración de la regla, tal como se muestra en la captura de pantalla que puede ver aquí.

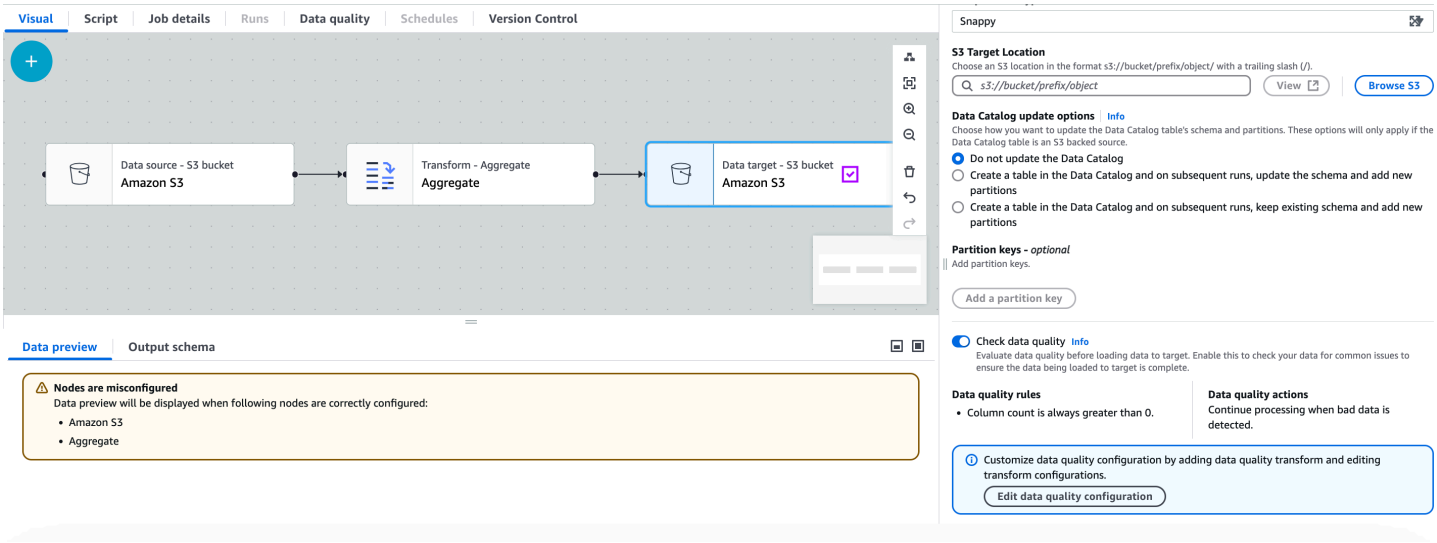

Puede añadir reglas de calidad de datos adicionales seleccionando Editar la configuración de calidad de los datos.

Métrica general

Es posible que necesite métricas generales, como la cantidad de registros que se aprobaron, fallaron o se omitieron a nivel de regla o a nivel de conjunto de reglas, para crear paneles. Para obtener las métricas generales y las métricas de regla para cada regla, primero habilite las métricas generales; para ello, agregue la opción `publishAggregatedMetrics` a su función `EvaluateDataQuality`.

Las opciones posibles para `additional_options` `publishAggregatedMetrics` son `ENABLED` y `DISABLED`. Por ejemplo:

```
EvaluateDataQualityMultiframe = EvaluateDataQuality().process_rows(
    frame=medicare_dyf,
    ruleset=EvaluateDataQuality_ruleset,
    publishing_options={
        "dataQualityEvaluationContext": "EvaluateDataQualityMultiframe",
        "enableDataQualityCloudWatchMetrics": False,
        "enableDataQualityResultsPublishing": False,
    },
    additional_options={"publishAggregatedMetrics.status": "ENABLED"},
)
```

Si no se especifica, `publishAggregatedMetrics.status` está `DISABLED` de forma predeterminada y ahora se calcularán las métricas de regla y las métricas generales. Esta

característica se admite actualmente en las sesiones interactivas de AWS Glue y en los trabajos de ETL de Glue. No se admite en las API de calidad de datos del catálogo de Glue.

Recuperación de resultados de métricas generales

Cuando `additionalOptions` está `"publishAggregatedMetrics.status": "ENABLED"`, puede obtener los resultados en dos lugares:

1. Se devuelven `AggregatedMetrics` y `RuleMetrics` a través de `GetDataQualityResult()` cuando se proporciona `resultId` donde `AggregatedMetrics` y `RuleMetrics` incluyen:

   Métrica general:

   - Total de filas procesadas
   - Total de filas aprobadas
   - Total de filas fallidas
   - Total de reglas procesadas
   - Total de reglas aprobadas
   - Total de reglas fallidas

```
[redacted] % aws --region us-east-1 glue get-data-quality-result --result-id "dqresult-09655f0234b3e3d129381bd162d0347ed25d1c05"
{
    "ResultId": "dqresult-09655f0234b3e3d129381bd162d0347ed25d1c05",
    "ProfileId": "dqprofile-[redacted]",
    "Score": 0.6666666666666666,
    "RulesetName": "EvaluateDataQuality_node1741974822533",
    "EvaluationContext": "EvaluateDataQuality_node1741974822533",
    "StartedOn": 1750687515.374,
    "CompletedOn": 1750687537.485,
    "JobName": "[redacted]_aggregatedmetrics_test",
    "JobRunId": "jr_[redacted]",
    "RuleResults": [
        {
            "Name": "Rule_1",
            "Description": "IsUnique \"customer_identifier\"",
            "Result": "PASS",
            "EvaluatedMetrics": {
                "Column.customer_identifier.Uniqueness": 1.0
            },
            "EvaluatedRule": "IsUnique \"customer_identifier\"",
            "RuleMetrics": {
                "rows_passed": 10.0,
                "rows_failed": 0.0,
                "rows_skipped": 0.0,
                "total_rows": 10.0
            }
        },
        {
            "Name": "Rule_2",
            "Description": "RowCount > 10",
            "EvaluationMessage": "Value: 10 does not meet the constraint requirement!",
            "Result": "FAIL",
            "EvaluatedMetrics": {
                "Dataset.*.RowCount": 10.0
            },
            "EvaluatedRule": "RowCount > 10",
            "RuleMetrics": {
                "rows_passed": 0.0,
                "rows_failed": 0.0,
                "rows_skipped": 10.0,
                "total_rows": 10.0
            }
        },
        {
            "Name": "Rule_3",
            "Description": "Completeness \"customer_identifier\" > 0.5",
            "Result": "PASS",
            "EvaluatedMetrics": {
                "Column.customer_identifier.Completeness": 1.0
            },
            "EvaluatedRule": "Completeness \"customer_identifier\" > 0.5",
            "RuleMetrics": {
                "rows_passed": 10.0,
                "rows_failed": 0.0,
                "rows_skipped": 0.0,
                "total_rows": 10.0
            }
        }
    ],
    "AggregatedMetrics": {
        "TotalRowsProcessed": 10.0,
        "TotalRowsPassed": 10.0,
        "TotalRowsFailed": 0.0,
        "TotalRulesProcessed": 3.0,
        "TotalRulesPassed": 2.0,
        "TotalRulesFailed": 1.0
    }
}
```

Además, a nivel de regla, se proporcionan las siguientes métricas:

Métricas de regla:

- Filas aprobadas
- Filas fallidas
- Fila omitida
- Total de filas procesadas

2. Se devuelve `AggregatedMetrics` como un marco de datos adicional y se amplía el marco de datos `RuleOutcomes` para incluir `RuleMetrics`.

Despliegue de ejemplo

En el siguiente ejemplo se muestra cómo desplegar métricas generales en Scala:

```
// Script generated for node Evaluate Data Quality
val EvaluateDataQuality_node1741974822533_ruleset = """
  # Example rules: Completeness "colA" between 0.4 and 0.8, ColumnCount > 10
  Rules = [
      IsUnique "customer_identifier",
      RowCount > 10,
      Completeness "customer_identifier" > 0.5
  ]
"""

val EvaluateDataQuality_node1741974822533 =
 EvaluateDataQuality.processRows(frame=ChangeSchema_node1742850392012,
 ruleset=EvaluateDataQuality_node1741974822533_ruleset,
 publishingOptions=JsonOptions("""{"dataQualityEvaluationContext":
 "EvaluateDataQuality_node1741974822533", "enableDataQualityCloudWatchMetrics":
 "true", "enableDataQualityResultsPublishing": "true"}"""),
 additionalOptions=JsonOptions("""{"compositeRuleEvaluation.method":"ROW","observations.scope":
 "publishAggregatedMetrics.status": "ENABLED"}""" ))

println("---------------------------------ROW LEVEL
 OUTCOMES---------------------------------")
val rowLevelOutcomes_node = EvaluateDataQuality_node1741974822533("rowLevelOutcomes")

rowLevelOutcomes_node.show(10)

 println("---------------------------------RULE LEVEL
 OUTCOMES---------------------------------")

val ruleOutcomes_node = EvaluateDataQuality_node1741974822533("ruleOutcomes")

ruleOutcomes_node.show()

 println("---------------------------------AGGREGATED
 METRICS---------------------------------")

val aggregatedMetrics_node = EvaluateDataQuality_node1741974822533("aggregatedMetrics")
```

```
aggregatedMetrics_node.show()
```

Resultados de ejemplo

Los resultados se devuelven de la siguiente manera:


```
{
    "Rule": "IsUnique \"customer_identifier\"",
    "Outcome": "Passed",
    "FailureReason": null,
    "EvaluatedMetrics": {
        "Column.customer_identifier.Uniqueness": 1
    },
    "EvaluatedRule": "IsUnique \"customer_identifier\"",
    "PassedCount": 10,
    "FailedCount": 0,
    "SkippedCount": 0,
    "TotalCount": 10
}
{
    "Rule": "RowCount > 10",
    "Outcome": "Failed",
    "FailureReason": "Value: 10 does not meet the constraint requirement!",
    "EvaluatedMetrics": {
        "Dataset.*.RowCount": 10
    },
    "EvaluatedRule": "RowCount > 10",
    "PassedCount": 0,
    "FailedCount": 0,
    "SkippedCount": 10,
    "TotalCount": 10
}
{
    "Rule": "Completeness \"customer_identifier\" > 0.5",
    "Outcome": "Passed",
    "FailureReason": null,
    "EvaluatedMetrics": {
        "Column.customer_identifier.Completeness": 1
    },
    "EvaluatedRule": "Completeness \"customer_identifier\" > 0.5",
    "PassedCount": 10,
    "FailedCount": 0,
    "SkippedCount": 0,
```

```
    "TotalCount": 10
}
```

Las métricas generales son las siguientes:

```
{ "TotalRowsProcessed": 10, "PassedRows": 10, "FailedRows": 0, "TotalRulesProcessed":
 3, "RulesPassed": 2, "RulesFailed": 1 }
```

Generador de reglas de Calidad de datos

Con el generador de reglas del lenguaje de definición de calidad de datos (DQDL), puede crear reglas de calidad de datos para evaluar sus datos. Para empezar, seleccione un tipo de regla y, a continuación, especifique los parámetros en el editor de reglas. El editor de reglas también muestra cualquier error y advertencia a medida que cree las reglas.

En la Guía de DQDL, se proporciona documentación completa sobre cómo crear reglas mediante la sintaxis de DQDL, tipos de reglas integrados y ejemplos.

Nodo de evaluación de Calidad de datos

Cuando trabaje con el nodo de transformación Evaluar la calidad de los datos y el generador de reglas de DQDL, puede expandir el espacio de trabajo.

- A fin de expandir la pestaña Transformación para que ocupe toda la pantalla, seleccione el icono de expansión situado en la esquina superior derecha del panel de detalles del nodo.
- Para expandir el editor de reglas de DQDL, seleccione el icono **<<** para expandir el editor de reglas y contraer las pestañas Tipos de reglas y Esquema.

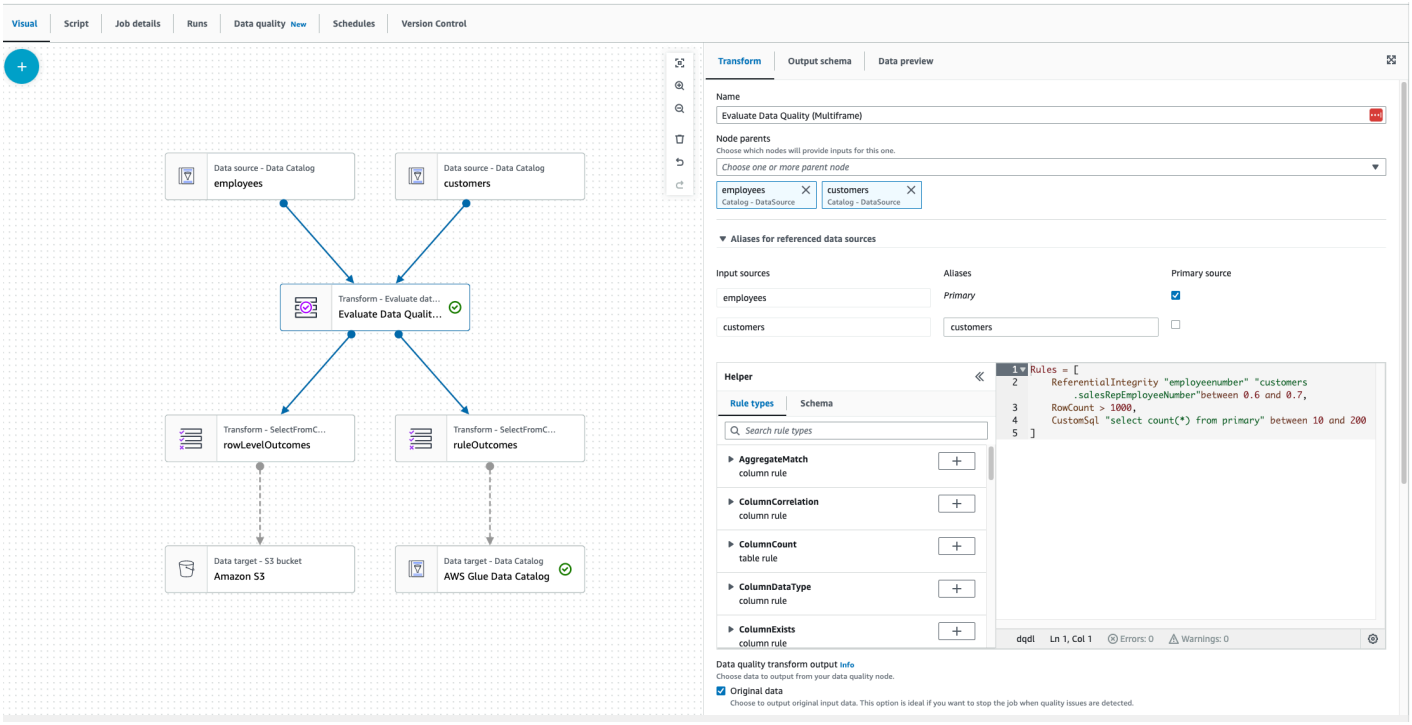

Componentes

Hay 26 tipos de reglas integrados en AWS Glue Studio. Cada tipo de regla tiene una descripción y ejemplos de cómo se puede utilizar.

Tipos de reglas de calidad de datos

AWS Glue Studio proporciona tipos de reglas integrados para facilitar la creación de una regla. Para obtener más información sobre los tipos de reglas, consulte la referencia sobre los tipos de reglas de DQDL.

Esquema

En la pestaña Schema (Esquema), se muestran los nombres de las columnas y el tipo de datos del nodo principal. Se muestran los esquemas de varios nodos. Puede ver el esquema de entrada, buscar por nombre de columna e insertar la columna en el editor de reglas.

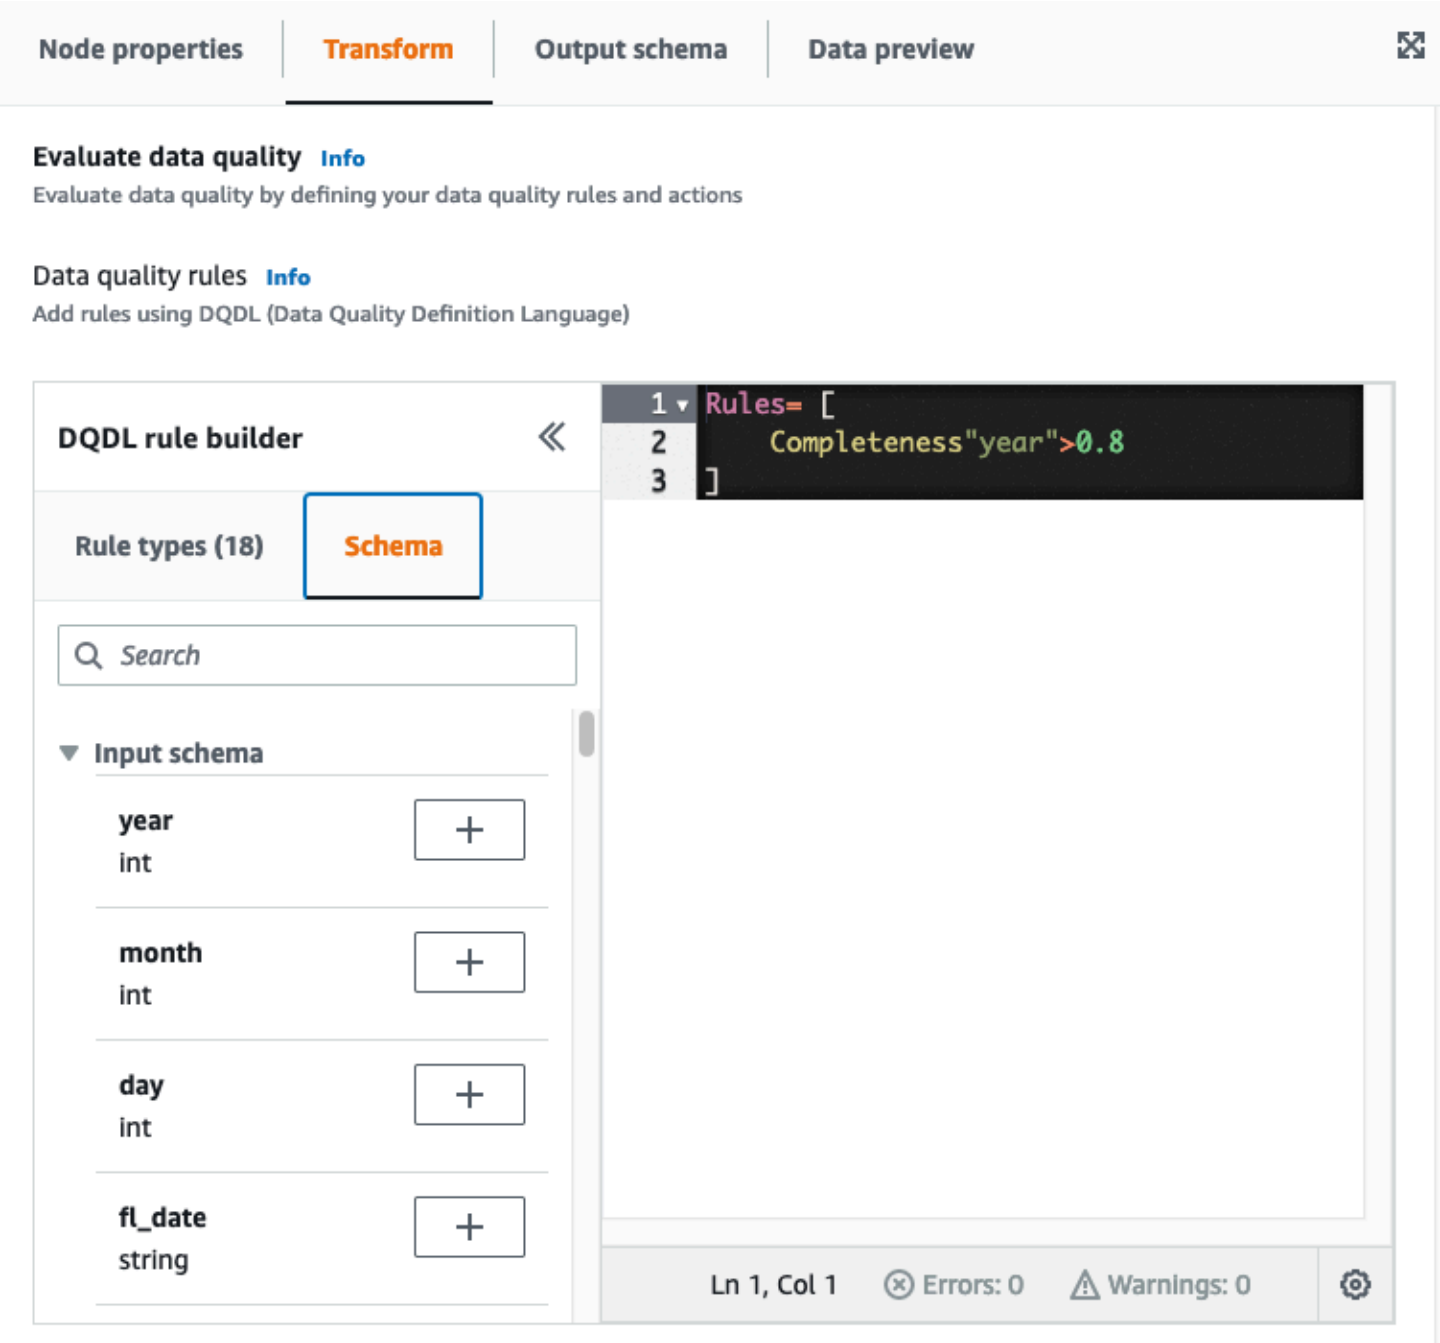

Editor de reglas

El editor de reglas es un editor de texto en el que puede escribir y editar reglas. Si selecciona un tipo de regla en el generador de reglas de DQDL, el tipo de regla se agrega al editor de reglas. A continuación, puede especificar parámetros, agregar y editar reglas según sea necesario, para lo que debe modificar el texto. AWS Glue Studio valida las reglas en el editor de reglas y muestra los errores y advertencias en caso de que haya alguna.

Errores y advertencias

Si una regla no sigue la sintaxis de las reglas de DQDL, el editor de reglas muestra varios indicadores visuales para señalar que hay un error:

- El editor de reglas muestra un icono de error en rojo en la línea que tiene el error.
- El editor de reglas muestra el número de errores junto al icono de error rojo.
- Al seleccionar la línea que tiene el error, se muestran descripciones del error y la ubicación (línea y columna) en la parte inferior del editor de reglas.

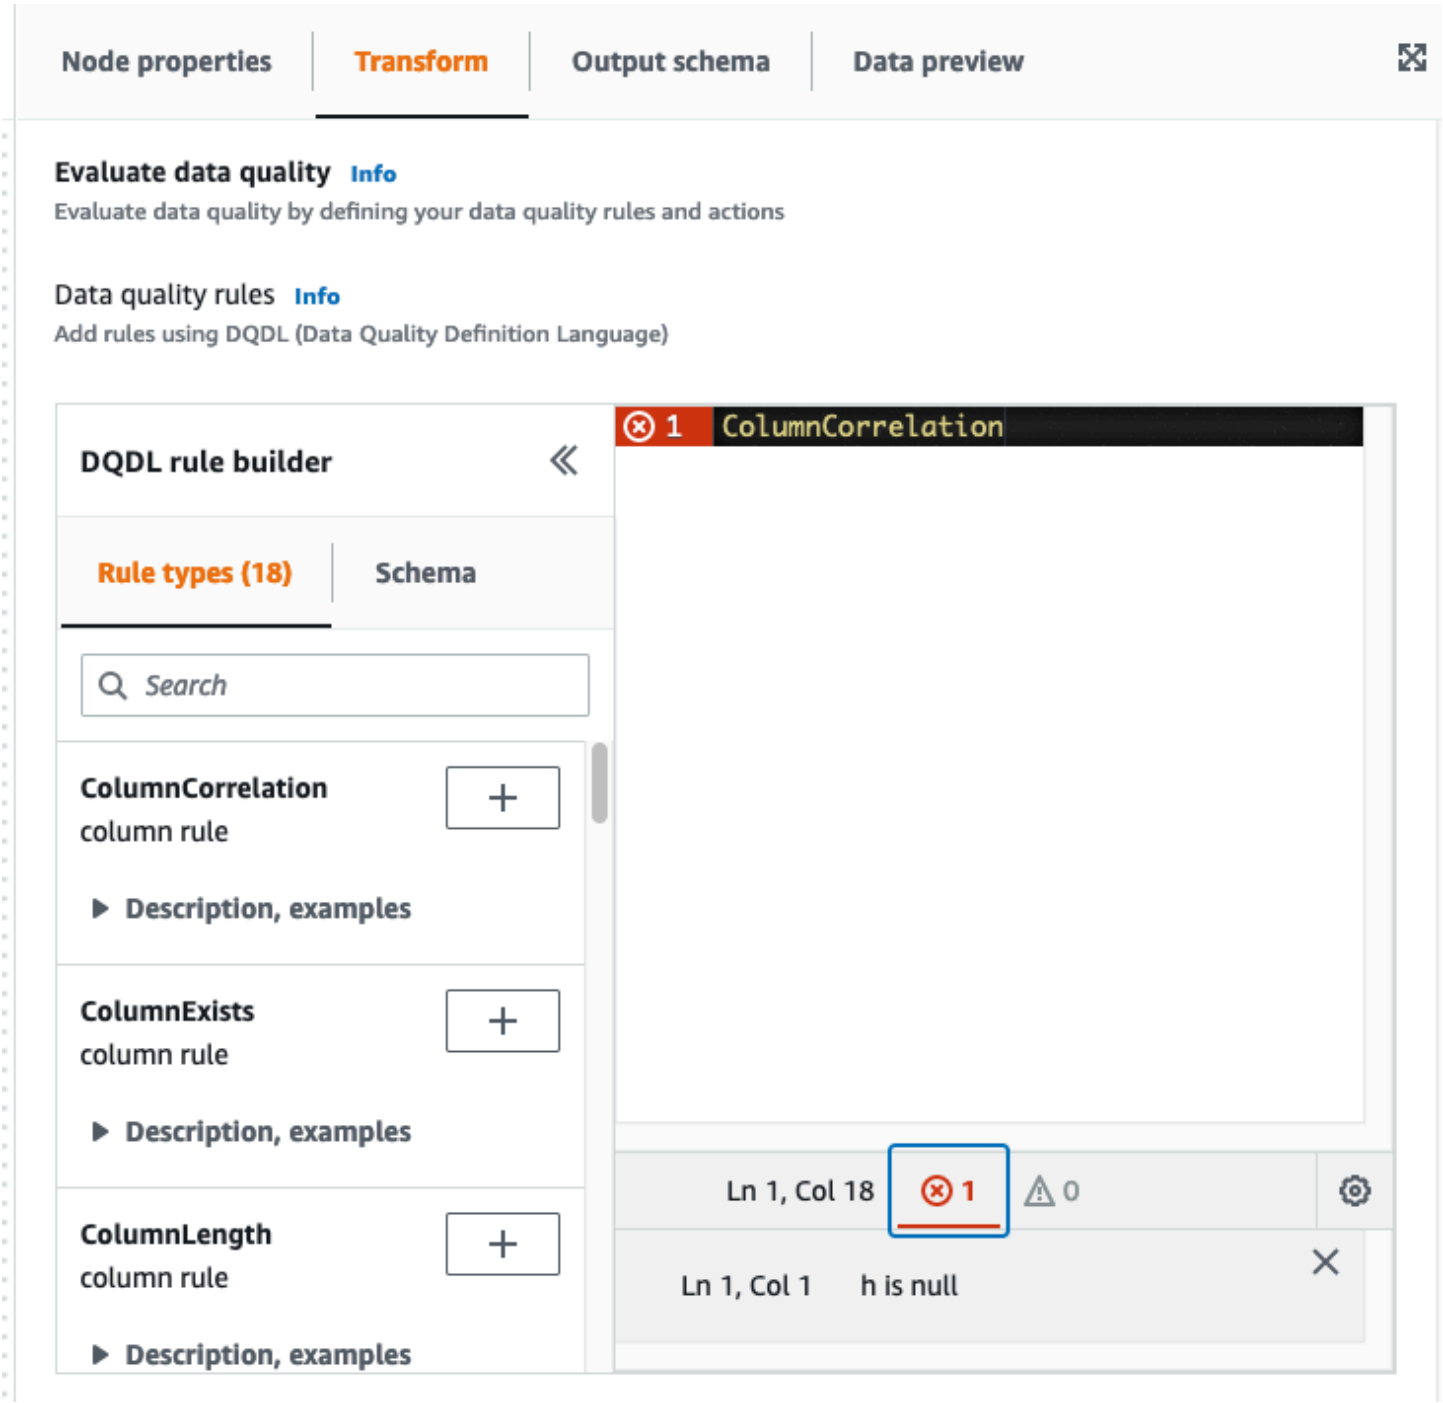

Acciones de calidad de datos

De forma predeterminada, esta acción no está seleccionada y el trabajo finalizará su ejecución incluso si las reglas de calidad de los datos no aprueban.

Elija entre las siguientes acciones. Puede utilizar acciones para publicar resultados en CloudWatch o detener trabajos en función de criterios específicos. Las acciones solo están disponibles después de crear una regla.

- Publicar los resultados en CloudWatch: cuando ejecute un trabajo, agregue los resultados a CloudWatch.
- Producir un error en el trabajo cuando se produzca un error en la calidad de los datos: si se produce un error en las reglas de calidad de los datos, también se producirá un error en el trabajo como resultado.

Salida de la transformación de calidad de datos

- Datos originales: elija generar los datos de entrada originales. Esta opción es ideal si desea detener el trabajo cuando se detecten problemas de calidad.
- Métricas de calidad de datos: elija generar las reglas configuradas y el estado correspondiente que indique que han aprobado o suspendido. Esta opción es útil si desea llevar a cabo una acción personalizada.

Configuración de la salida de calidad de datos

Para establecer la ubicación de los resultados de calidad de los datos, especifica la ubicación de Amazon S3 como destino de la salida de calidad de los datos.

Configuración de la detección de anomalías en los trabajos de ETL de AWS Glue

Para empezar con la detección de anomalías en AWS Glue Studio, abra un trabajo de AWS Glue Studio y haga clic en la transformación Evaluar la calidad de los datos.

Si habilita esta característica, Calidad de datos de AWS Glue analizará sus datos a lo largo del tiempo para detectar anomalías. Proporciona valiosas estadísticas y observaciones sobre sus datos, lo que le permite tomar medidas ante cualquier anomalía identificada.

Consulte la documentación de Detección de anomalías para comprender el funcionamiento interno de esta característica.

Cómo habilitar la detección de anomalías

Para habilitar la detección de anomalías en AWS Glue Studio:

1. Elija el nodo de calidad de datos de su trabajo y, a continuación, elija la pestaña Detección de anomalías. Habilite la opción Activar la detección de anomalías.

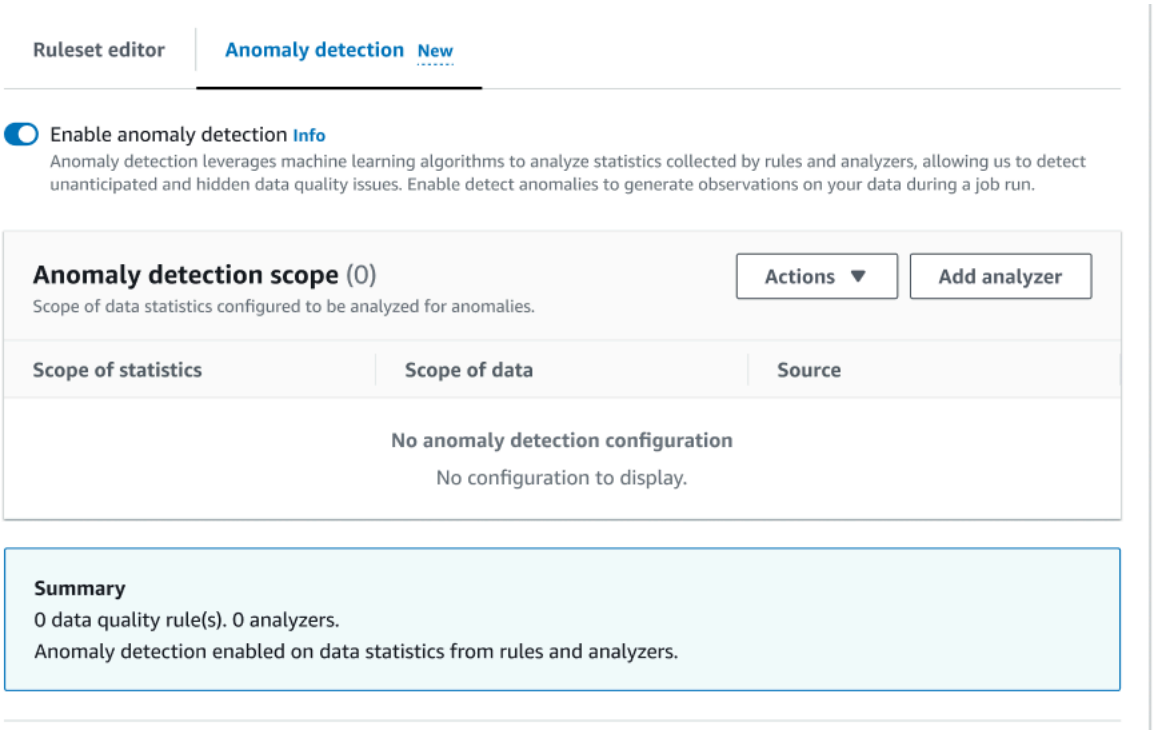

2. Defina los datos que se van a monitorizar en busca de anomalías seleccionando Añadir analizador. Hay dos campos que puede rellenar: Estadísticas y Datos.

   - Las estadísticas incluyen información sobre la forma de los datos y otras propiedades. Puede elegir una o varias estadísticas a la vez, o elegir Todas las estadísticas. Las estadísticas incluyen: integridad, unicidad, media, suma, desviación estándar, entropía, distinctValuesCount, uniqueValueRatio y más. Consulte la documentación Analizadores para obtener más información.
   - Los datos incluyen las columnas del conjunto de datos. Puede elegir todas las columnas o columnas individuales.

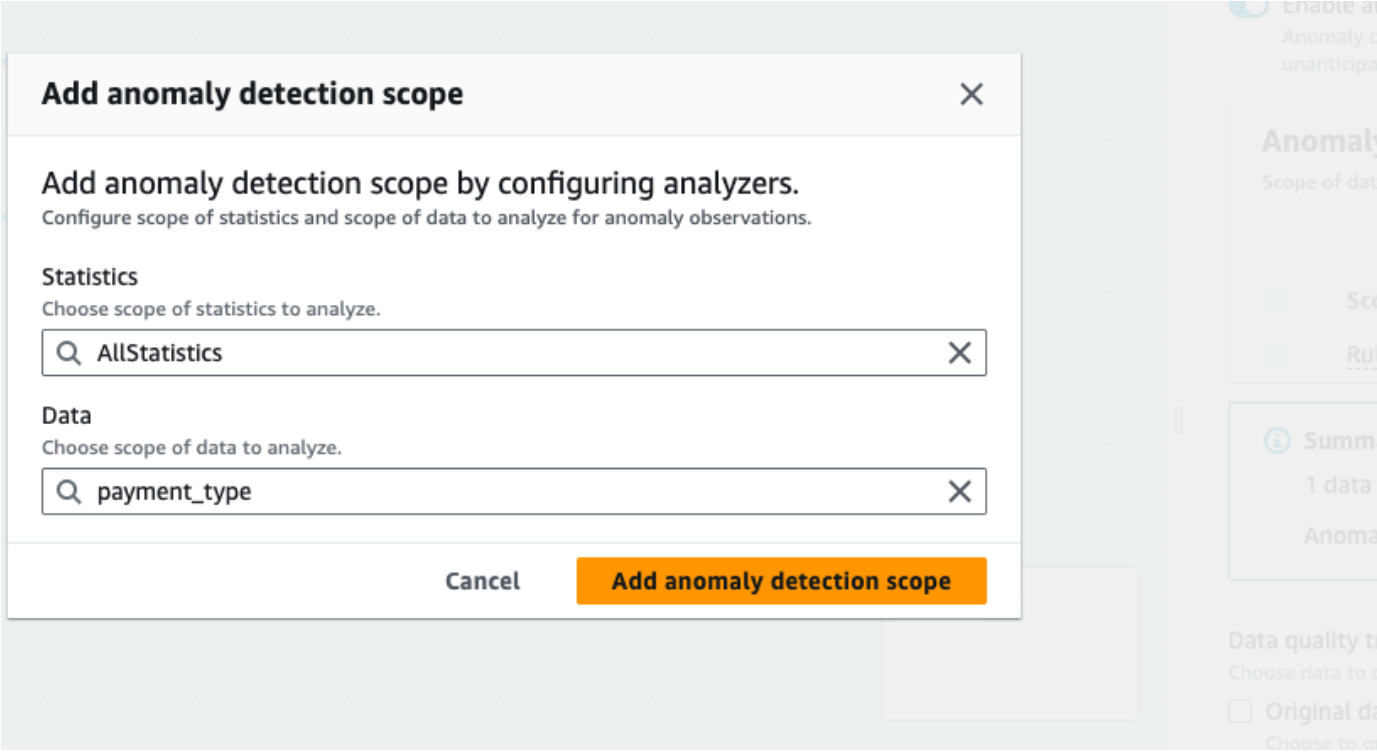

3. Elija Agregar alcance de detección de anomalías para guardar los cambios. Cuando haya agregado los analizadores, podrá verlos en la sección Alcance de la detección de anomalías.

   También puede utilizar el menú Acciones para editar los analizadores, o elegir la pestaña del Editor de conjuntos de reglas y editar el analizador directamente en el bloc de notas del editor de conjuntos de reglas. Verá los analizadores que guardó debajo de las reglas que creó.

```
Rules = [

]

Analyzers = [
    Completeness “id”
]
```

Una vez configurados el conjunto de reglas y los analizadores actualizados, Calidad de datos de AWS monitorea continuamente los flujos de datos entrantes. Puede detectar posibles anomalías mediante alertas o interrupciones del trabajo, según la configuración. Este monitoreo proactivo ayuda a garantizar la calidad y la integridad de los datos en todas las canalizaciones de datos.

En la siguiente sección, aprenderá a monitorear de forma eficaz las anomalías identificadas por el sistema. También aprenderá a ver y analizar las estadísticas de datos recopiladas por Calidad de datos de AWS Glue. Además, aprenderá cómo enviar comentarios al modelo de machine learning que alimenta la característica de Detección de anomalías. Este circuito de comentarios es fundamental para mejorar la precisión del modelo y garantizar que pueda detectar eficazmente las anomalías que se ajustan a los requisitos empresariales y los patrones de datos específicos de su empresa.

Visualización de puntuaciones de calidad de datos y anomalías

En esta sección, analizaremos el panel de calidad de los datos y las diferentes funcionalidades que ofrece.

Visualice y comprenda las métricas y tendencias generales de calidad de datos

Una vez que complete su trabajo, elija la pestaña Calidad de datos para ver las puntuaciones y las anomalías de la calidad de los datos.

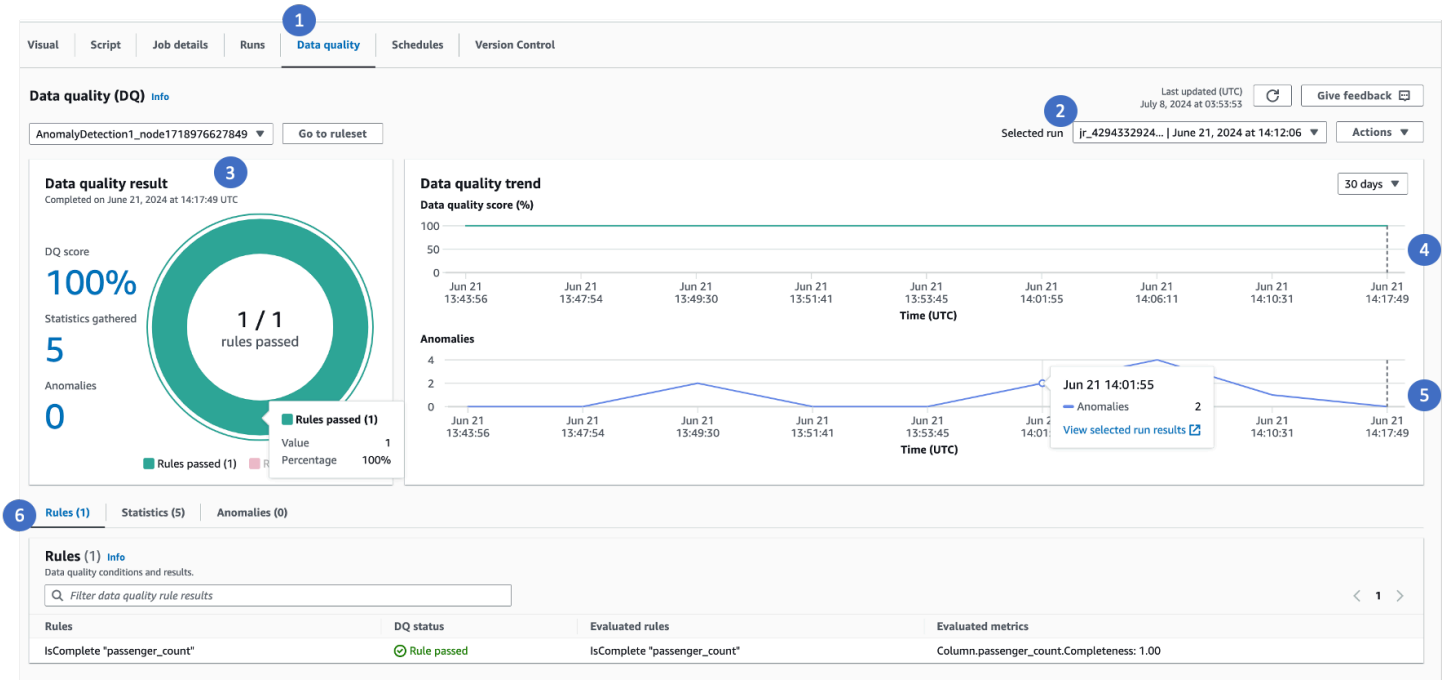

Los siguientes componentes de la pestaña Calidad de datos proporcionan información útil.

1. Seleccione la pestaña Calidad de datos para ver las métricas de calidad de los datos.
2. Seleccione un ID de ejecución de trabajo específico para ver la puntuación de calidad de los datos.

3. En este panel se muestran tres datos importantes. Puede elegir cada uno de ellos para ir a tablas específicas y ver anomalías, estadísticas de datos o reglas.
   - Puntuación de calidad de los datos cuando se configuran reglas.
   - Cantidad de estadísticas recopiladas por Reglas y Analizadores.
   - La cantidad total de anomalías detectadas.
4. En este gráfico de tendencias se muestra la evolución de la calidad de los datos a lo largo del tiempo. Puede pasar el ratón sobre la tendencia e ir a un momento específico en el que las puntuaciones de calidad de los datos hayan empeorado.
5. Las tendencias de las anomalías a lo largo del tiempo le mostrarán la cantidad de anomalías detectadas a lo largo del tiempo.
6. Pestañas:
   - La pestaña Reglas es la pestaña predeterminada en la que se muestra una lista de todas las reglas y los estados. Las reglas evaluadas son útiles en el caso de las reglas dinámicas para ver el valor real con el que se evaluó la regla.
   - En la pestaña Estadísticas se muestran todas las estadísticas, lo que le permite ver las métricas y las tendencias a lo largo del tiempo.
   - En la pestaña Anomalías se muestra la lista de anomalías detectadas.

Visualización de anomalías y entrenamiento del algoritmo de detección de anomalías

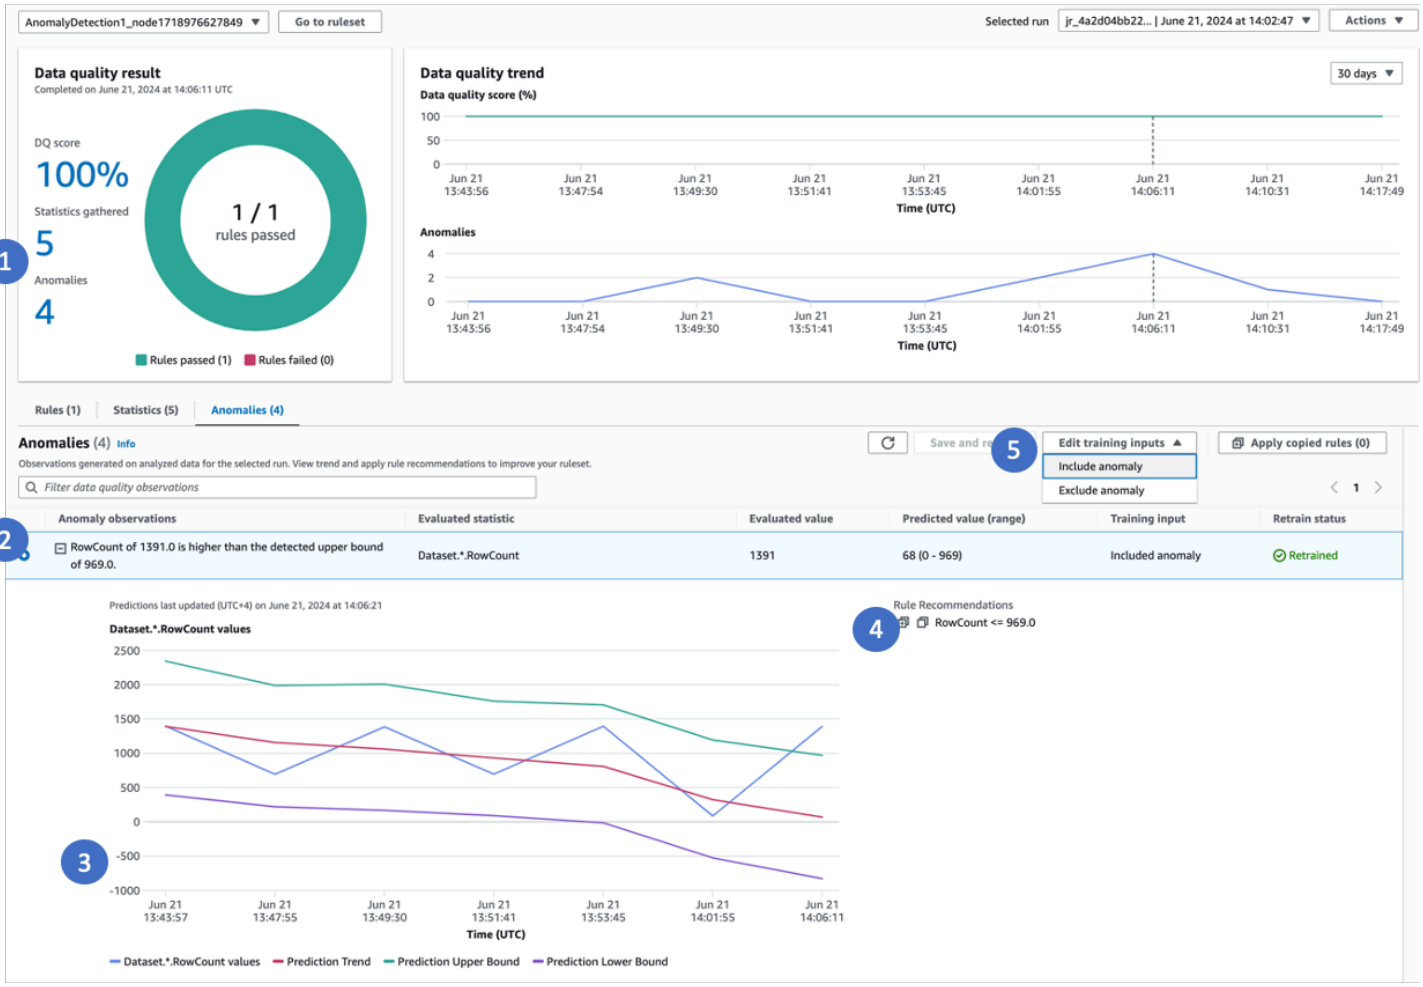

Indicaciones para la imagen de arriba:

1. Cuando se detecten anomalías, haga clic en la anomalía o seleccione la pestaña Anomalías
2. Calidad de datos de AWS Glue proporciona una explicación detallada de la anomalía, el valor real y el rango previsto
3. Calidad de datos de AWS Glue muestra una línea de tendencia. Tiene el valor real, una tendencia derivada basada en los valores reales (línea roja), el límite superior y el límite inferior
4. Calidad de datos de AWS Glue recomienda reglas de calidad de datos que se pueden utilizar para capturar los patrones para el futuro. Puede copiar todas las reglas que se le recomienden y aplicarlas a su nodo de calidad de datos para capturar estos patrones de forma eficaz.
5. Puede proporcionar entradas al modelo de machine learning (ML) para excluir valores anómalos y garantizar que las ejecuciones futuras detecten las anomalías con precisión. Si no excluye las anomalías de forma explícita, Calidad de datos de AWS Glue las considerará automáticamente

como parte del modelo para futuras predicciones. Es importante tener en cuenta que solo la última ejecución reflejará las entradas del modelo que proporcione. Por ejemplo, si retrocedió y excluyó los puntos anómalos de algunas ejecuciones anteriores, el modelo no reflejará esos cambios a menos que visualice y actualice las entradas del modelo en la última ejecución. El modelo seguirá utilizando las entradas proporcionadas anteriormente hasta que realice los ajustes necesarios en la ejecución más reciente. Mediante la gestión activa de la exclusión de valores anómalos, puede ajustar la comprensión del modelo de ML sobre lo que constituye una anomalía para adaptarla a sus requisitos y patrones de datos específicos, lo que permite detectar las anomalías con más precisión a lo largo del tiempo.

Visualización de las estadísticas de datos a lo largo del tiempo y suministro de entradas de entrenamiento

En algunas ocasiones, puede ver las estadísticas de datos o los perfiles de datos para saber cómo progresan a lo largo del tiempo. Para ello, elija Estadísticas o abra la pestaña Estadísticas. Podrá ver las últimas estadísticas de datos recopiladas por Calidad de datos de AWS Glue.

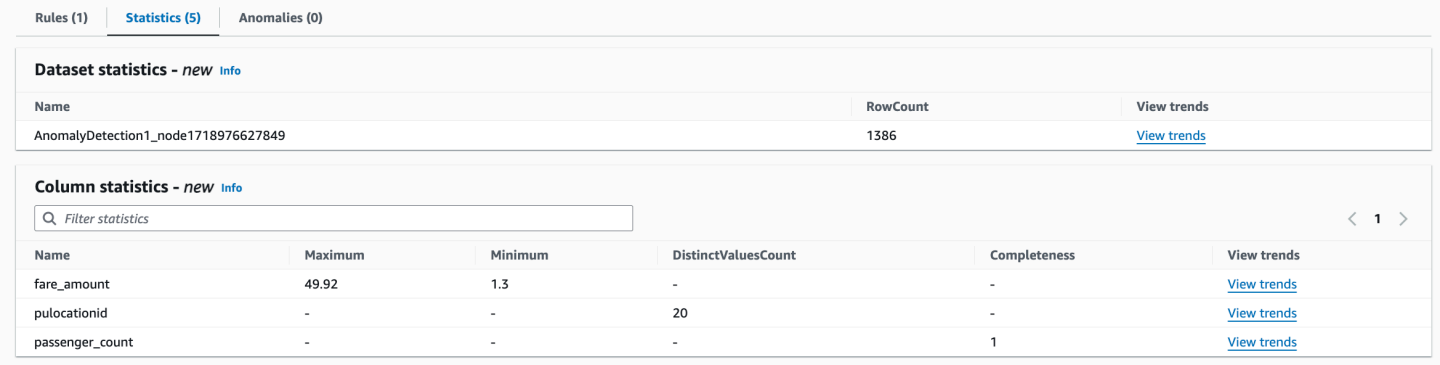

Al hacer clic en Ver tendencias, se muestra el progreso de cada una de las estadísticas a lo largo del tiempo.

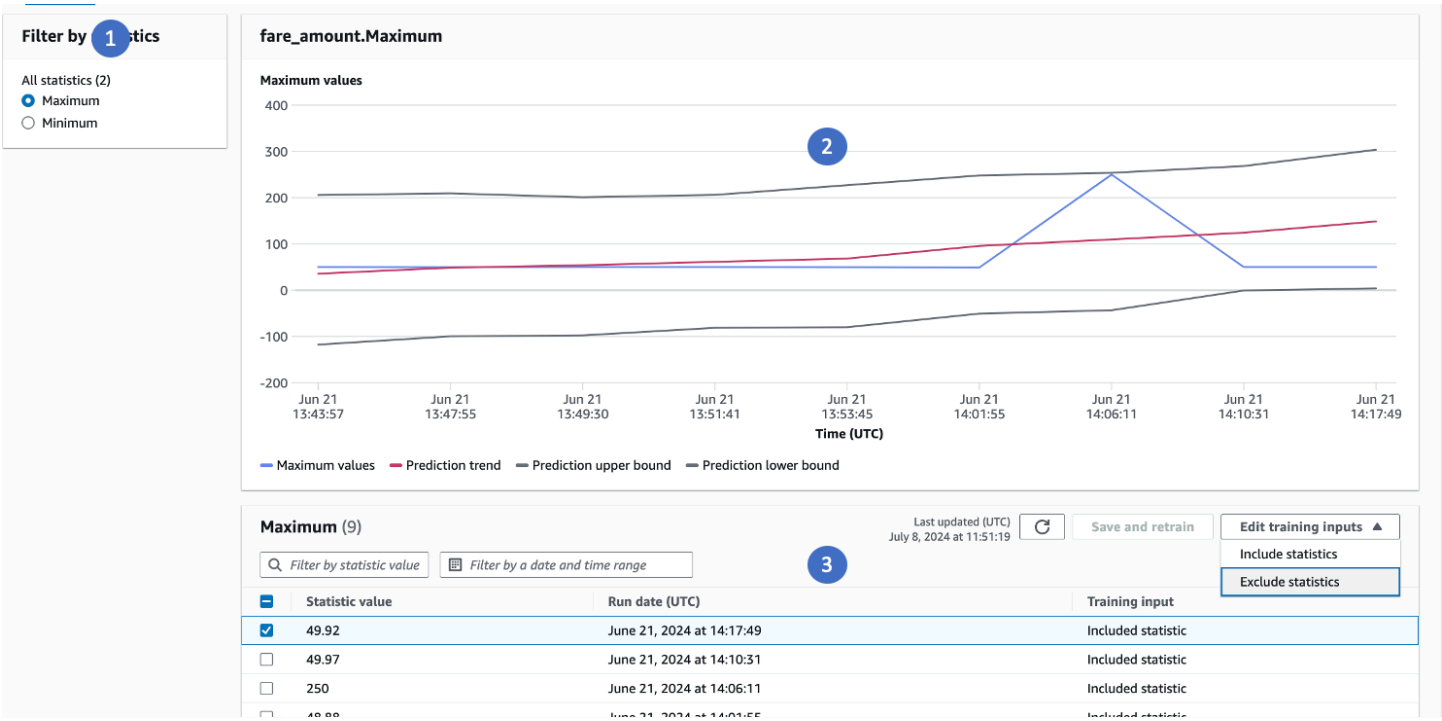

1. Puede seleccionar la estadística de una columna específica
2. Puede ver cómo progresan las tendencias
3. Puede seleccionar valores anómalos y optar por excluirlos o incluirlos. Al proporcionar esta información, el algoritmo excluirá o incluirá los puntos de datos anómalos identificados y volverá a entrenar el modelo. Este proceso de reentrenamiento garantiza una detección precisa de las anomalías en el futuro, ya que el modelo aprende a partir de los comentarios que usted proporciona acerca de qué valores deben considerarse anómalos o no.

   Gracias a este ciclo de comentarios, podrá refinar la comprensión del algoritmo sobre lo que constituye una anomalía para adaptarla a sus patrones de datos y requisitos empresariales específicos. Al excluir valores que no deberían marcarse como anomalías o incluir valores que no se hayan detectado, el modelo rediseñado podrá diferenciar mejor entre los puntos de datos esperados y los verdaderamente anómalos.

Calidad de los datos para los trabajos de ETL en los blocs de notas de AWS Glue Studio

En este tutorial, aprenderá a utilizar la calidad de datos de AWS Glue para trabajos de extracción, transformación y carga (ETL) en cuadernos de AWS Glue Studio.

Puede utilizar cuadernos en AWS Glue Studio para editar los guiones de los trabajos y ver el resultado sin tener que ejecutar un trabajo completo. También puede agregar anotaciones y guardar libretas como archivos `.ipynb` y guiones de trabajo. Tenga en cuenta que puede iniciar un cuaderno sin instalar software en forma local ni administrar servidores. Cuando esté satisfecho con el código, puede utilizar AWS Glue Studio para convertir fácilmente el cuaderno en un trabajo de AWS Glue.

El conjunto de datos que utiliza en este ejemplo está formado por datos de pago de Medicare Provider que se descargaron de dos sitios de Data.CMS.gov, conjuntos de datos: "Inpatient Prospective Payment System Provider Summary for the Top 100 Diagnosis-Related Groups - FY2011" e "Inpatient Charge Data FY 2011".

Después de descargar los datos, modificamos el conjunto de datos para presentar un par de registros erróneos al final del archivo. Este archivo modificado se encuentra en un bucket público de Amazon S3 en `s3://awsglue-datasets/examples/medicare/Medicare_Hospital_Provider.csv`.

Requisitos previos

- AWS GlueRol de con permiso de Amazon S3 para escribir en el bucket de Amazon S3 de destino
- Un cuaderno nuevo (consulte Introducción a los cuadernos en AWS Glue Studio)

Crear un trabajo de ETL en AWS Glue Studio

Para crear un trabajo de ETL

1. Cambie la versión de la sesión a AWS Glue 3.0.

   Para ello, elimine todas las celdas de código repetitivo con la siguiente magia y ejecute la celda. Tenga en cuenta que este código repetitivo se proporciona automáticamente en la primera celda cuando se crea un nuevo cuaderno.

   ```
   %glue_version 3.0
   ```

2. Copie el siguiente contenido y ejecútelo en la celda.

   ```
   import sys
   from awsglue.transforms import *
   from awsglue.utils import getResolvedOptions
   from pyspark.context import SparkContext
   ```

```
from awsglue.context import GlueContext
from awsglue.job import Job

sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)
spark = glueContext.spark_session
job = Job(glueContext)
```

3. En la celda siguiente, importe la clase de `EvaluateDataQuality` que evalúa la calidad de los datos de AWS Glue.

```
from awsgluedq.transforms import EvaluateDataQuality
```

4. En la celda siguiente, lea los datos de origen mediante el archivo.csv que está almacenado en el bucket público de Amazon S3.

```
medicare = spark.read.format(
"csv").option(
"header", "true").option(
"inferSchema", "true").load(
's3://awsglue-datasets/examples/medicare/Medicare_Hospital_Provider.csv')
medicare.printSchema()
```

5. Convertir los datos en un DynamicFrame de AWS Glue.

```
from awsglue.dynamicframe import DynamicFrame
medicare_dyf = DynamicFrame.fromDF(medicare,glueContext,"medicare_dyf")
```

6. Cree el conjunto de reglas mediante el lenguaje de definición de calidad de datos (DQDL).

```
EvaluateDataQuality_ruleset = """
    Rules = [
        ColumnExists "Provider Id",
        IsComplete "Provider Id",
        ColumnValues  " Total Discharges " > 15
]
    ]
"""
```

7. Valide el conjunto de datos según el conjunto de reglas.

```
EvaluateDataQualityMultiframe = EvaluateDataQuality().process_rows(
    frame=medicare_dyf,
    ruleset=EvaluateDataQuality_ruleset,
    publishing_options={
        "dataQualityEvaluationContext": "EvaluateDataQualityMultiframe",
        "enableDataQualityCloudWatchMetrics": False,
        "enableDataQualityResultsPublishing": False,
    },
    additional_options={"performanceTuning.caching": "CACHE_NOTHING"},
)
```

8. Revise los resultados.

```
ruleOutcomes = SelectFromCollection.apply(
    dfc=EvaluateDataQualityMultiframe,
    key="ruleOutcomes",
    transformation_ctx="ruleOutcomes",
)

ruleOutcomes.toDF().show(truncate=False)
```

Salida:

```
-------------------------------------+-------
+-----------------------------------------------------
+-----------------------------------------+
|Rule                                 |Outcome|FailureReason
                  |EvaluatedMetrics                           |
+-------------------------------------+-------
+-----------------------------------------------------
+-----------------------------------------+
|ColumnExists "Provider Id"           |Passed |null
                  |{}                                         |
|IsComplete "Provider Id"             |Passed |null
                  |{Column.Provider Id.Completeness -> 1.0}   |
```

```
|ColumnValues " Total Discharges " > 15|Failed |Value: 11.0 does not meet the
 constraint requirement!|{Column. Total Discharges .Minimum -> 11.0}|
+-------------------------------------+-------
+-------------------------------------------------
+-----------------------------------------+
```

9. Filtre las filas aprobadas y revise las filas fallidas a partir de los resultados según el nivel de fila de calidad de los datos.

```
owLevelOutcomes = SelectFromCollection.apply(
dfc=EvaluateDataQualityMultiframe,
key="rowLevelOutcomes",
transformation_ctx="rowLevelOutcomes",
)

rowLevelOutcomes_df = rowLevelOutcomes.toDF() # Convert Glue DynamicFrame to
 SparkSQL DataFrame
rowLevelOutcomes_df_passed =
 rowLevelOutcomes_df.filter(rowLevelOutcomes_df.DataQualityEvaluationResult ==
 "Passed") # Filter only the Passed records.
rowLevelOutcomes_df.filter(rowLevelOutcomes_df.DataQualityEvaluationResult ==
 "Failed").show(5, truncate=False) # Review the Failed records
```

Salida:

```
+-----------------------------------------+-----------
+-------------------------------------+-------------------------+-------------
+--------------+-----------------+-----------------------------------
+------------------+-------------------------+-----------------------
+--------------------------+-------------------------
+-----------------------------------------+---------------------------
+---------------------------+
|DRG Definition                            |Provider Id|Provider Name
           |Provider Street Address   |Provider City|Provider State|Provider Zip
 Code|Hospital Referral Region Description| Total Discharges | Average Covered
 Charges | Average Total Payments |Average Medicare Payments|DataQualityRulesPass
      |DataQualityRulesFail                     |DataQualityRulesSkip        |
DataQualityEvaluationResult|
+-----------------------------------------+-----------
+-------------------------------------+-------------------------+-------------
+--------------+-----------------+-----------------------------------
```

```
+-----------------+-------------------------+----------------------
+-------------------------+-------------------------
+----------------------------------------+--------------------------
+--------------------------+
|039 - EXTRACRANIAL PROCEDURES W/O CC/MCC|10005      |MARSHALL MEDICAL CENTER SOUTH
        |2505 U S HIGHWAY 431 NORTH|BOAZ         |AL            |35957
 |AL - Birmingham                      |14               |$15131.85
  |$5787.57               |$4976.71                 |[IsComplete "Provider Id"]|
[ColumnValues " Total Discharges " > 15]|[ColumnExists "Provider Id"]|Failed
              |
|039 - EXTRACRANIAL PROCEDURES W/O CC/MCC|10046      |RIVERVIEW REGIONAL MEDICAL
 CENTER    |600 SOUTH THIRD STREET    |GADSDEN      |AL            |35901
   |AL - Birmingham                      |14               |$67327.92
   |$5461.57               |$4493.57                 |[IsComplete "Provider Id"]|
[ColumnValues " Total Discharges " > 15]|[ColumnExists "Provider Id"]|Failed
              |
|039 - EXTRACRANIAL PROCEDURES W/O CC/MCC|10083      |SOUTH BALDWIN REGIONAL
 MEDICAL CENTER|1613 NORTH MCKENZIE STREET|FOLEY        |AL            |36535
        |AL - Mobile                          |15               |$25411.33
         |$5282.93               |$4383.73                 |[IsComplete "Provider
 Id"]|[ColumnValues " Total Discharges " > 15]|[ColumnExists "Provider Id"]|Failed
                   |
|039 - EXTRACRANIAL PROCEDURES W/O CC/MCC|30002      |BANNER GOOD SAMARITAN MEDICAL
 CENTER |1111 EAST MCDOWELL ROAD   |PHOENIX      |AZ            |85006
 |AZ - Phoenix                         |11               |$34803.81
  |$7768.90               |$6951.45                 |[IsComplete "Provider Id"]|
[ColumnValues " Total Discharges " > 15]|[ColumnExists "Provider Id"]|Failed
              |
|039 - EXTRACRANIAL PROCEDURES W/O CC/MCC|30010      |CARONDELET ST  MARYS HOSPITAL
        |1601 WEST ST MARY'S ROAD  |TUCSON       |AZ            |85745
 |AZ - Tucson                          |12               |$35968.50
  |$6506.50               |$5379.83                 |[IsComplete "Provider Id"]|
[ColumnValues " Total Discharges " > 15]|[ColumnExists "Provider Id"]|Failed
              |
+----------------------------------------+----------
+-----------------------------------+-------------------------+-------------
+--------------+-----------------+-----------------------------------
+-----------------+-------------------------+----------------------
+-------------------------+-------------------------
+----------------------------------------+--------------------------
+--------------------------+
only showing top 5 rows
```

Tenga en cuenta que la calidad de datos de AWS Glue agregó cuatro columnas nuevas (DataQualityRulesPass, DataQualityRulesFail, DataQualityRulesSkip y DataQualityEvaluationResult). Esto indica los registros que se aprobaron, los registros que fallaron, las reglas omitidas para la evaluación a nivel de fila y los resultados generales a nivel de fila.

10. Escriba el resultado en un bucket de Amazon S3 para analizar los datos y visualizar los resultados.

```
#Write the Passed records to the destination.

glueContext.write_dynamic_frame.from_options(
       frame = rowLevelOutcomes_df_passed,
       connection_type = "s3",
       connection_options = {"path": "s3://glue-sample-target/output-dir/
medicare_parquet"},
       format = "parquet")
```

Referencia del lenguaje de definición de calidad de datos (DQDL)

El lenguaje de definición de calidad de datos (DQDL) es un lenguaje específico de un dominio que se utiliza para definir las reglas de Calidad de datos de AWS Glue.

En esta guía, se presentan los conceptos clave de DQDL para entender el lenguaje. También proporciona una referencia para los tipos de reglas de DQDL con sintaxis y ejemplos. Antes de utilizar esta guía, le recomendamos que se familiarice con Calidad de datos de AWS Glue. Para obtener más información, consulte Calidad de datos de AWS Glue.

> **Note**
>
> Las reglas dinámicas solo se admiten en ETL de AWS Glue.

Contenido

- Sintaxis de DQDL
  - Estructura de la regla
  - Reglas compuestas

    - Funcionamiento de las reglas compuestas
  - Expresiones
    - Palabras clave para NULL, EMPTY y WHITESPACES_ONLY
    - Filtrado con la cláusula Where
  - Constantes
  - Etiquetas
    - Sintaxis de las etiquetas de DQDL
      - Restricciones del etiquetado
    - Recuperación de etiquetas de DQDL
      - Resultados de la regla
      - Resultados a nivel de fila
      - Respuesta de la API
  - Reglas dinámicas
  - Analizadores
  - Comentarios
- Referencia de tipo de regla de DQDL
  - AggregateMatch
  - ColumnCorrelation
  - ColumnCount
  - ColumnDataType
  - ColumnExists
  - ColumnLength
  - ColumnNamesMatchPattern
  - ColumnValues
  - Integridad
  - CustomSQL
  - DataFreshness
  - DataSetMatch
  - DistinctValuesCount
  - Entropía

- IsComplete
- IsPrimaryKey
- IsUnique
- Media
- ReferentialIntegrity
- RowCount
- RowCountMatch
- StandardDeviation
- Sum
- SchemaMatch
- Singularidad
- UniqueValueRatio
- DetectAnomalies
- FileFreshness
- FileMatch
- FileUniqueness
- FileSize

Sintaxis de DQDL

Un documento de DQDL distingue entre mayúsculas y minúsculas y contiene un conjunto de reglas que agrupa las reglas individuales de la calidad de los datos. Para crear un conjunto de reglas, debe crear una lista denominada `Rules` (en mayúscula), delimitada por un par de corchetes. La lista debe contener una o más reglas de DQDL separadas por comas, como en el ejemplo siguiente.

```
Rules = [
   IsComplete "order-id",
   IsUnique "order-id"
]
```

Estructura de la regla

La estructura de una regla de DQDL depende del tipo de regla. Sin embargo, las reglas de DQDL se suelen ajustar al siguiente formato.

```
<RuleType> <Parameter> <Parameter> <Expression>
```

`RuleType` es el nombre que distingue entre mayúsculas y minúsculas del tipo de regla que quiere configurar. Por ejemplo, `IsComplete`, `IsUnique` o `CustomSql`. Los parámetros de la regla son diferentes para cada tipo de regla. Para obtener una referencia completa de los tipos de reglas de DQDL y sus parámetros, consulte Referencia de tipo de regla de DQDL.

Reglas compuestas

DQDL admite los siguientes operadores lógicos que puede utilizar para combinar las reglas. Estas reglas se denominan reglas compuestas.

y

El operador lógico `and` da como resultado `true`, siempre y cuando las reglas que conecta sean `true`. De lo contrario, la regla combinada da como resultado `false`. Cada regla que conecte con el operador `and` debe estar entre paréntesis.

El siguiente ejemplo usa el operador `and` para combinar dos reglas de DQDL.

```
(IsComplete "id") and (IsUnique "id")
```

o

El operador lógico `or` da como resultado `true`, siempre y cuando una o varias de las reglas que conecta sean `true`. Cada regla que conecte con el operador `or` debe estar entre paréntesis.

El siguiente ejemplo usa el operador `or` para combinar dos reglas de DQDL.

```
(RowCount "id" > 100) or (IsPrimaryKey "id")
```

Puede utilizar el mismo operador para conectar varias reglas, por lo que se permite la siguiente combinación de reglas.

```
(Mean "Star_Rating" > 3) and (Mean "Order_Total" > 500) and (IsComplete "Order_Id")
```

Puede combinar los operadores lógicos en una sola expresión. Por ejemplo:

```
(Mean "Star_Rating" > 3) and ((Mean "Order_Total" > 500) or (IsComplete "Order_Id"))
```

También puede crear reglas anidadas más complejas.

```
(RowCount > 0) or ((IsComplete "colA") and (IsUnique "colA"))
```

Funcionamiento de las reglas compuestas

De manera predeterminada, las reglas compuestas son evaluadas como reglas individuales a lo largo de todo el conjunto de datos y de la tabla y luego se combinan los resultados. En otras palabras, primero evalúan toda la columna y, a continuación, aplican el operador. Este comportamiento predeterminado se explica a continuación con un ejemplo:

```
# Dataset

+------+------+
|myCol1|myCol2|
+------+------+
|     2|     1|
|     0|     3|
+------+------+

# Overall outcome

+-------------------------------------------------------------+-------+
|Rule                                                         |Outcome|
+-------------------------------------------------------------+-------+
|(ColumnValues "myCol1" > 1) OR (ColumnValues "myCol2" > 2)|Failed |
+-------------------------------------------------------------+-------+
```

En el ejemplo anterior, AWS Glue Data Quality primero evalúa `(ColumnValues "myCol1" > 1)`, lo cual resultará en una falla. Luego evaluará `(ColumnValues "myCol2" > 2)`, que también fallará. La combinación de los dos resultados se indicará como fallida.

Sin embargo, si prefiere SQL como el comportamiento en caso de que necesite evaluar una fila entera, tiene que establecer de manera explícita el parámetro `ruleEvaluation.scope` como se muestra en `additionalOptions`, en el fragmento de código a continuación.

```
object GlueApp {
  val datasource = glueContext.getCatalogSource(
    database="<db>",
    tableName="<table>",
    transformationContext="datasource"
```

```
  ).getDynamicFrame()

  val ruleset = """
    Rules = [
        (ColumnValues "age" >= 26) OR (ColumnLength "name" >= 4)
    ]
  """

  val dq_results = EvaluateDataQuality.processRows(
    frame=datasource,
    ruleset=ruleset,
    additionalOptions=JsonOptions("""
        {
          "compositeRuleEvaluation.method":"ROW"
        }
      """
    )
  )
}
```

En Catálogo de datos de AWS Glue, puede configurar fácilmente esta opción en la interfaz de usuario, como se muestra a continuación.

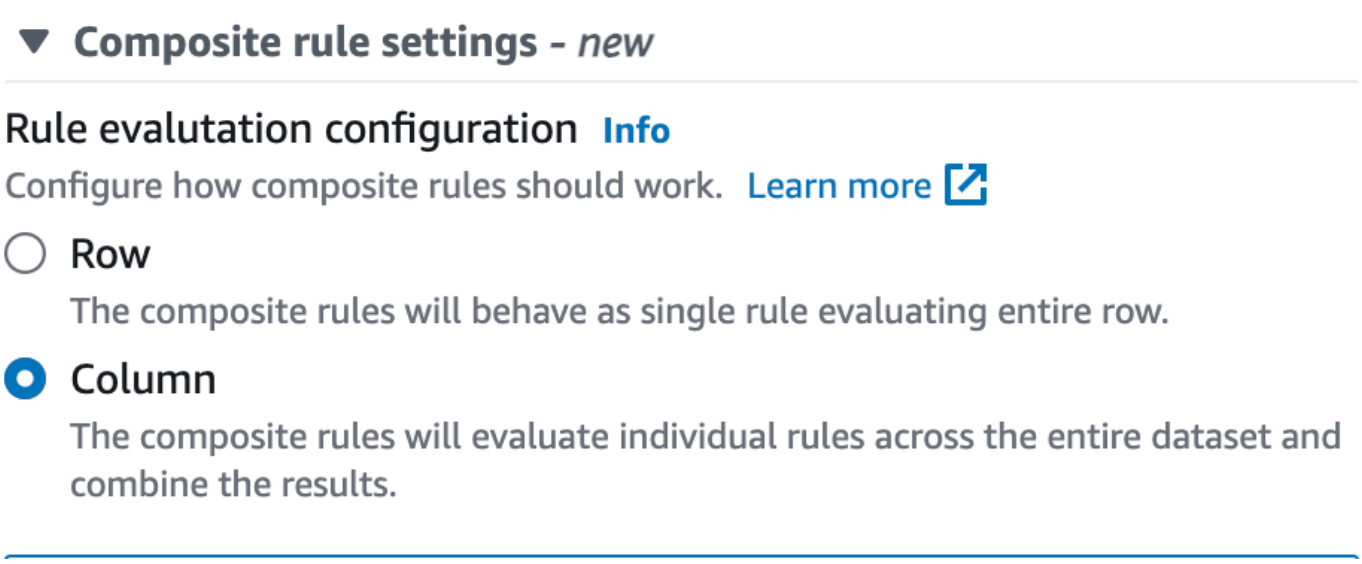

Una vez establecidas, las reglas compuestas se comportarán como una regla única que evalúa la fila en su totalidad. En el ejemplo a continuación se muestra este comportamiento.

```
# Row Level outcome

+------+------+------------------------------------------------------------
+---------------------------+
|myCol1|myCol2|DataQualityRulesPass                                        |
DataQualityEvaluationResult|
+------+------+------------------------------------------------------------
+---------------------------+
|2     |1     |[(ColumnValues "myCol1" > 1) OR (ColumnValues "myCol2" > 2)]|Passed
               |
|0     |3     |[(ColumnValues "myCol1" > 1) OR (ColumnValues "myCol2" > 2)]|Passed
               |
+------+------+------------------------------------------------------------
+---------------------------+
```

Algunas reglas no son compatibles con esta característica debido a que los resultados generales se basan en umbrales o proporciones. Estas regulas se enumeran a continuación.

Reglas que se basan en las proporciones:

- Integridad
- DataSetMatch
- ReferentialIntegrity
- Singularidad

Reglas que se basan en los umbrales:

Cuando las reglas que se mencionan a continuación incluyen con un umbral, no son compatibles. Sin embargo, las reglas que no incluyen `with threshold` sí mantienen la compatibilidad.

- ColumnDataType
- ColumnValues
- CustomSQL

Expresiones

Si un tipo de regla no produce una respuesta booleana, debe proporcionar una expresión como parámetro para crear una respuesta booleana. Por ejemplo, la siguiente regla compara la media (promedio) de todos los valores de una columna con una expresión para obtener un resultado true (verdadero) o false (falso).

```
Mean "colA" between 80 and 100
```

Algunos tipos de reglas, como `IsUnique` y `IsComplete` ya producen una respuesta booleana.

En la tabla siguiente, se enumeran las expresiones que puede utilizar en las reglas de DQDL.

Expresiones de DQDL admitidas

Expresión	Descripción	Ejemplo
=*x*	Se resuelve en `true` si la respuesta del tipo de regla es igual que *x*.	`Completeness "colA" = "1.0", ColumnValues "colA" = "2022-06-30"`
!=*x*	Se resuelve en verdadero si la respuesta del tipo de regla es igual a *x*.	`ColumnValues "colA" != "a", ColumnValues "colA" != "2022-06-30"`
> *x*	Se resuelve en `true` si la respuesta del tipo de regla es mayor que *x*.	`ColumnValues "colA" > 10`
< *x*	Se resuelve en `true` si la respuesta del tipo de regla es menor que *x*.	`ColumnValues "colA" < 1000, ColumnValues "colA" < "2022-06-30"`
>= *x*	Se resuelve en `true` si la respuesta del tipo de regla es mayor o igual que *x*.	`ColumnValues "colA" >= 10`

Expresión	Descripción	Ejemplo
<= x	Se resuelve en `true` si la respuesta del tipo de regla es menor o igual que *x*.	`ColumnValues "colA" <= 1000`
entre *x* e *y*	Se resuelve en `true` si la respuesta del tipo de regla se encuentra en un rango especificado (exclusivo). Solo debe utilizar este tipo de expresión para los tipos numéricos y de datos.	`Mean "colA" between 8 and 100, ColumnValues "colA" between "2022-05-31" and "2022-06-30"`
no está entre *x* e *y*	Se resuelve en verdadero si la respuesta del tipo de regla no se encuentra en un rango especificado (inclusivo). Solo debe utilizar este tipo de expresión para los tipos numéricos y de fecha.	`ColumnValues "colA" not between "2022-05-31" and "2022-06-30"`
en [*a, b, c, ...*]	Se resuelve en `true` si la respuesta del tipo de regla se encuentra en el conjunto especificado.	`ColumnValues "colA" in [ 1, 2, 3 ], ColumnValues "colA" in [ "a", "b", "c" ]`
no está en [*a, b, c,...*]	Se resuelve en `true` si la respuesta del tipo de regla no se encuentra en el conjunto especificado.	`ColumnValues "colA" not in [ 1, 2, 3 ], ColumnValues "colA" not in [ "a", "b", "c" ]`
coincide con */ab+c/i*	Se resuelve en `true` si la respuesta del tipo de regla coincide con una expresión regular.	`ColumnValues "colA" matches "[a-zA-Z]*"`

Expresión	Descripción	Ejemplo
no coincide con */ab+c/i*	Se resuelve en `true` si la respuesta del tipo de regla no coincide con una expresión regular.	`ColumnValues "colA" not matches "[a-zA-Z]*"`
`now()`	Solo funciona con el tipo de regla `ColumnValues` para crear una expresión de fecha.	`ColumnValues "load_date" > (now() - 3 days)`

en/coincide con [...] / no está en/no coincide con [...] `with threshold`	Indica el porcentaje de valores que coinciden con las condiciones de la regla. Solo funciona con los tipos de regla `ColumnValues` , `ColumnDataType` y `CustomSQL` .	`ColumnValues "colA" in ["A", "B"] with threshold > 0.8,`
		`ColumnValues "colA" matches "[a-zA-Z]*" with threshold between 0.2 and 0.9`
		`ColumnDataType "colA" = "Timestamp" with threshold > 0.9`

Palabras clave para NULL, EMPTY y WHITESPACES_ONLY

Para validar si una columna de cadenas contiene una cadena nula, vacía o solo con espacios en blanco, puede utilizar las palabras clave a continuación:

- NULL/null: esta palabra clave se resuelve como verdadera para un valor `null` en una columna de cadenas.

  `ColumnValues "colA" != NULL with threshold > 0.5` devolvería el valor verdadero si más del 50 % de los datos no tienen valores nulos.

  `(ColumnValues "colA" = NULL) or (ColumnLength "colA" > 5)` devolvería el valor verdadero para todas las filas que tengan un valor nulo o una longitud superior a 5. Tenga en cuenta que esto requiere que se utilice la opción “compositeRuleEvaluation.method” = “ROW”.
- EMPTY/empty: esta palabra clave se resuelve como verdadera para un valor de cadena vacío (“”) en una columna de cadenas. Algunos formatos de datos transforman los valores nulos de una

columna de cadenas en cadenas vacías. Esta palabra clave ayuda a remover las cadenas vacías en los datos.

`(ColumnValues "colA" = EMPTY) or (ColumnValues "colA" in ["a", "b"])` devolvería el valor verdadero si una fila está vacía, “a” o “b”. Tenga en cuenta que esto requiere que se utilice la opción “compositeRuleEvaluation.method” = “ROW”.

- WHITESPACES_ONLY/whitespaces_only: esta palabra clave se resuelve como verdadera para una cadena que solo tiene un valor de espacios en blanco (“ ”) en una columna de cadenas.

  `ColumnValues "colA" not in ["a", "b", WHITESPACES_ONLY]` devolvería el valor verdadero si una fila no es ni “a” ni “b” ni solo contiene espacios en blanco.

  Reglas admitidas:

  - ColumnValues

Puede utilizar las palabras clave a continuación para validar si una columna contiene un valor nulo al trabajar con expresiones numéricas o basadas en fechas.

- NULL/null: esta palabra clave se resuelve como verdadera para un valor nulo en una columna de cadenas.

  `ColumnValues "colA" in [NULL, "2023-01-01"]` devolvería el valor verdadero si una fecha de la columna es `2023-01-01` o nula.

  `(ColumnValues "colA" = NULL) or (ColumnValues "colA" between 1 and 9)` devolvería el valor verdadero para todas las filas que tengan un valor nulo o cuyos valores sean entre 1 y 9. Tenga en cuenta que esto requiere que se utilice la opción “compositeRuleEvaluation.method” = “ROW”.

  Reglas admitidas:

  - ColumnValues

Filtrado con la cláusula Where

> **Note**
>
> La cláusula Where solo es compatible con AWS Glue 4.0.

Puede filtrar sus datos durante la creación de reglas. Esto resulta útil cuando se quieren aplicar reglas condicionales.

```
<DQDL Rule> where "<valid SparkSQL where clause> "
```

El filtro debe especificarse con la palabra clave `where`, seguida de una instrucción de SparkSQL válida entre comillas (`""`).

Si desea agregar la cláusula Where a una regla que tiene un umbral, la cláusula Where debe especificarse antes de la condición de umbral.

```
<DQDL Rule> where "valid SparkSQL statement>" with threshold <threshold condition>
```

Con esta sintaxis, puede escribir reglas como las siguientes.

```
Completeness "colA" > 0.5 where "colB = 10"
ColumnValues "colB" in ["A", "B"] where "colC is not null" with threshold > 0.9
ColumnLength "colC" > 10 where "colD != Concat(colE, colF)"
```

Comprobaremos si la instrucción de SparkSQL proporcionada es válida. Si no es válida, la evaluación de la regla fallará y mostrará el error `IllegalArgumentException` con el siguiente formato:

```
Rule <DQDL Rule> where "<invalid SparkSQL>" has provided an invalid where clause :
<SparkSQL Error>
```

Comportamiento de la cláusula Where cuando la identificación del registro de errores a nivel de la fila está activada

Con Calidad de datos de AWS Glue, puede identificar registros específicos que fallaron. Al aplicar una cláusula Where a las reglas que admiten resultados a nivel de la fila, etiquetaremos las filas filtradas por la cláusula Where como `Passed`.

Si prefiere etiquetar por separado las filas filtradas como `SKIPPED`, puede configurar las siguientes `additionalOptions` para el trabajo de ETL.

```
object GlueApp {
  val datasource = glueContext.getCatalogSource(
```

```
    database="<db>",
    tableName="<table>",
    transformationContext="datasource"
  ).getDynamicFrame()

  val ruleset = """
    Rules = [
       IsComplete "att2" where "att1 = 'a'"
    ]
  """

  val dq_results = EvaluateDataQuality.processRows(
    frame=datasource,
    ruleset=ruleset,
    additionalOptions=JsonOptions("""
        {
          "rowLevelConfiguration.filteredRowLabel":"SKIPPED"
        }
      """
    )
  )
}
```

Como ejemplo, consulte la siguiente regla y el marco de datos:

```
IsComplete att2 where "att1 = 'a'"
```

id	att1	att2	Resultados a nivel de la fila (predeter minado)	Resultados a nivel de la fila (opción omitida)	Comentarios
1	a	f	PASSED	PASSED	
2	b	d	PASSED	SKIPPED	La fila está filtrada, ya que `att1` no es `"a"`
3	a	null	ERROR	ERROR	

id	att1	att2	Resultados a nivel de la fila (predeterminado)	Resultados a nivel de la fila (opción omitida)	Comentarios
4	a	f	PASSED	PASSED	
5	b	null	PASSED	SKIPPED	La fila está filtrada, ya que `att1` no es `"a"`
6	a	f	PASSED	PASSED	

Constantes

En DQDL, puede definir valores constantes y hacer referencia a ellos a lo largo de todo el script. Esto ayuda a evitar problemas relacionados con los límites de tamaño de las consultas, por ejemplo, al trabajar con instrucciones SQL de gran tamaño que podrían superar los límites permitidos. Al asignar estos valores a las constantes, puede simplificar el DQDL y evitar sobrepasar esos límites.

En el siguiente ejemplo, se muestra cómo definir y utilizar una constante:

```
mySql = "select count(*) from primary"

Rules = [
    CustomSql $mySql between 0 and 100
]
```

En este ejemplo, la consulta SQL se asigna a la constante `mySql`, que luego se referencia en la regla mediante el prefijo `$`.

Etiquetas

Las etiquetas ofrecen una forma eficaz de organizar y analizar los resultados de calidad de los datos. Puede consultar los resultados por etiquetas específicas para identificar reglas fallidas dentro de categorías concretas, contar los resultados de las reglas por equipo o dominio y crear informes específicos para distintas partes interesadas.

Por ejemplo, puede aplicar a todas las reglas relacionadas con el equipo de finanzas una etiqueta `"team=finance"` y generar un informe personalizado para mostrar métricas de calidad específicas del equipo de finanzas. Puede etiquetar las reglas de alta prioridad con `"criticality=high"` para priorizar las tareas de remediación. Las etiquetas se pueden crear como parte del DQDL. Puede consultar las etiquetas como parte de los resultados de las reglas, los resultados a nivel de fila y las respuestas de la API, lo que facilita la integración con sus flujos de trabajo existentes de supervisión y generación de informes.

> **Note**
>
> Las etiquetas solo están disponibles en ETL de AWS Glue y no están disponibles en la calidad de datos basada en el catálogo de datos de AWS Glue.

Sintaxis de las etiquetas de DQDL

DQDL admite tanto etiquetas predeterminadas como etiquetas específicas de las reglas. Las etiquetas predeterminadas se definen a nivel del conjunto de reglas y se aplican automáticamente a todas las reglas incluidas en ese conjunto. Las reglas individuales también pueden tener sus propias etiquetas y, dado que las etiquetas se implementan como pares clave-valor, las etiquetas específicas de una regla pueden sustituir a las etiquetas predeterminadas cuando se utiliza la misma clave.

En el siguiente ejemplo, se muestra cómo utilizar etiquetas predeterminadas y específicas de una regla:

```
DefaultLabels=["frequency"="monthly"]

Rules = [
    // Auto includes the default label ["frequency"="monthly"]
    ColumnValues "col" > 21,
    // Add ["foo"="bar"] to default label. Labels for this rule would be
 ["frequency"="monthly", "foo"="bar"]
    Rule 1 with threshold > 0.8 labels=["foo"="bar"],
    // Override default label. Labels for this rule would be ["frequency"="daily",
 "foo"="bar"]
    Rule 2 with threshold > 0.8 labels=["foo"="bar", "frequency"="daily"]
]
```

Restricciones del etiquetado

Las etiquetas tienen las siguientes restricciones:

- Un máximo de 10 etiquetas por regla de DQDL.
- Las etiquetas se especifican como una lista de pares clave-valor.
- La clave de la etiqueta y el valor de la etiqueta distinguen entre mayúsculas y minúsculas.
- La longitud máxima de la clave de la etiqueta es de 128 caracteres. La clave de la etiqueta no debe estar vacía ni ser nula.
- La longitud máxima del valor de la etiqueta es de 256 caracteres. El valor de la etiqueta puede estar vacío o ser nulo.

Recuperación de etiquetas de DQDL

Puede recuperar las etiquetas de DQDL a partir de los resultados de las reglas, los resultados a nivel de fila y las respuestas de la API.

Resultados de la regla

Las etiquetas de DQDL siempre son visibles en los resultados de las reglas. No se necesita ninguna configuración adicional para habilitarlas.

Resultados a nivel de fila

Las etiquetas de DQDL están desactivadas de forma predeterminada en los resultados a nivel de fila, pero pueden habilitarse mediante `AdditionalOptions` en `EvaluateDataQuality`.

En el siguiente ejemplo, se muestra cómo habilitar etiquetas en resultados a nivel de fila:

```
val evaluateResult = EvaluateDataQuality.processRows(
    frame=AmazonS3_node1754591511068,
    ruleset=example_ruleset,
    publishingOptions=JsonOptions("""{
        "dataQualityEvaluationContext": "evaluateResult",
        "enableDataQualityCloudWatchMetrics": "true",
        "enableDataQualityResultsPublishing": "true"
    }"""),
    additionalOptions=JsonOptions("""{
        "performanceTuning.caching":"CACHE_NOTHING",
        "observations.scope":"ALL",
        "rowLevelConfiguration.ruleWithLabels":"ENABLED"
    }""")
)
```

Cuando están habilitadas, el marco de datos de resultados a nivel de fila incluye las etiquetas de cada regla en las columnas `DataQualityRulesPass`, `DataQualityRulesFail` y `DataQualityRulesSkip`.

Respuesta de la API

Las etiquetas de DQDL siempre son visibles en las respuestas de la API, en un nuevo campo `Labels` dentro del objeto `RuleResults`.

En el siguiente ejemplo, se muestran las etiquetas en una respuesta de la API:

```
{
    "ResultId": "dqresult-example",
    "ProfileId": "dqprofile-example",
    "Score": 0.6666666666666666,
    "RulesetName": "EvaluateDataQuality_node1754591514205",
    "EvaluationContext": "EvaluateDataQuality_node1754591514205",
    "StartedOn": "2025-08-22T19:36:10.448000+00:00",
    "CompletedOn": "2025-08-22T19:36:16.368000+00:00",
    "JobName": "anniezc-test-labels",
    "JobRunId": "jr_068f6d7a45074d9105d14e4dee09db12c3b95664b45f6ee44fa29ed7e5619ba8",
    "RuleResults": [
        {
            "Name": "Rule_0",
            "Description": "IsComplete colA",
            "EvaluationMessage": "Input data does not include column colA!",
            "Result": "FAIL",
            "EvaluatedMetrics": {},
            "EvaluatedRule": "IsComplete colA",
            "Labels": {
                "frequency": "monthly"
            }
        },
        {
            "Name": "Rule_1",
            "Description": "Rule 1 with threshold > 0.8",
            "Result": "PASS",
            "EvaluatedMetrics": {},
            "EvaluatedRule": "Rule 1 with threshold > 0.8",
            "Labels": {
                "frequency": "monthly",
                "foo": "bar"
            }
```

```
        },
        {
            "Name": "Rule_3",
            "Description": "Rule 2 with threshold > 0.8",
            "Result": "PASS",
            "EvaluatedMetrics": {},
            "EvaluatedRule": "Rule 2 with threshold > 0.8",
            "Labels": {
                "frequency": "daily",
                "foo": "bar"
            }
        }
    ]
}
```

Reglas dinámicas

> **Note**
>
> Las reglas dinámicas solo se admiten en la ETL de AWS Glue y no en el Catálogo de datos de AWS Glue.

Ahora puede crear reglas dinámicas para comparar las métricas actuales generadas por sus reglas con sus valores históricos. Estas comparaciones históricas se habilitan usando el operador `last()` en las expresiones. Por ejemplo, la regla `RowCount > last()` se aplicará correctamente cuando el número de filas de la ejecución actual sea superior al recuento de filas anterior más reciente del mismo conjunto de datos. `last()` utiliza un argumento numérico natural opcional que describe cuántas métricas anteriores se deben tener en cuenta; `last(k)` donde `k >= 1` hará referencia a las últimas métricas `k`.

- Si no hay puntos de datos disponibles, `last(k)` devolverá el valor predeterminado, 0,0.
- Si hay menos de las métricas `k` disponibles, `last(k)` devolverá todas las métricas anteriores.

Para formar expresiones válidas utilice `last(k)`, donde `k > 1` requiera una función de agregación para reducir varios resultados históricos a un solo número. Por ejemplo, `RowCount > avg(last(5))` comprobará si el recuento de filas del conjunto de datos actual es estrictamente mayor que el promedio de los últimos cinco recuentos de filas del mismo conjunto de datos.

`RowCount > last(5)` producirá un error, porque el recuento de filas del conjunto de datos actual no se puede comparar de forma significativa con una lista.

Funciones de agregación admitidas:

- `avg`
- `median`
- `max`
- `min`
- `sum`
- `std` (desviación estándar)
- `abs` (valor absoluto)
- `index(last(k), i)` permitirá seleccionar el valor en la posición `i` de los más recientes del último `k`. `i` está indexado a cero, por lo que `index(last(3), 0)` devolverá el punto de datos más reciente y `index(last(3), 3)` generará un error, ya que solo hay tres puntos de datos e intentaremos indexar el cuarto más reciente.

Ejemplos de expresiones

ColumnCorrelation

- `ColumnCorrelation "colA" "colB" < avg(last(10))`

DistinctValuesCount

- `DistinctValuesCount "colA" between min(last(10))-1 and max(last(10))+1`

La mayoría de los tipos de reglas con condiciones o umbrales numéricos admiten reglas dinámicas; consulte la tabla dada, Analizadores y reglas, para determinar si las reglas dinámicas son compatibles con su tipo de regla.

Exclusión de las estadísticas de las reglas dinámicas

En ocasiones, tendrá que excluir las estadísticas de datos de los cálculos de las reglas dinámicas. Supongamos que ha efectuado una carga de datos históricos y no quiere que eso afecte a sus promedios. Para ello, abra el trabajo en la ETL de AWS Glue y seleccione la pestaña Calidad de los

datos; a continuación, seleccione Estadísticas y seleccione las estadísticas que desee excluir. Podrá ver un gráfico de tendencias junto con una tabla de estadísticas. Seleccione los valores que desee excluir y elija Excluir estadísticas. Ahora las estadísticas que estén excluidas no se incluirán en los cálculos de las reglas dinámicas.

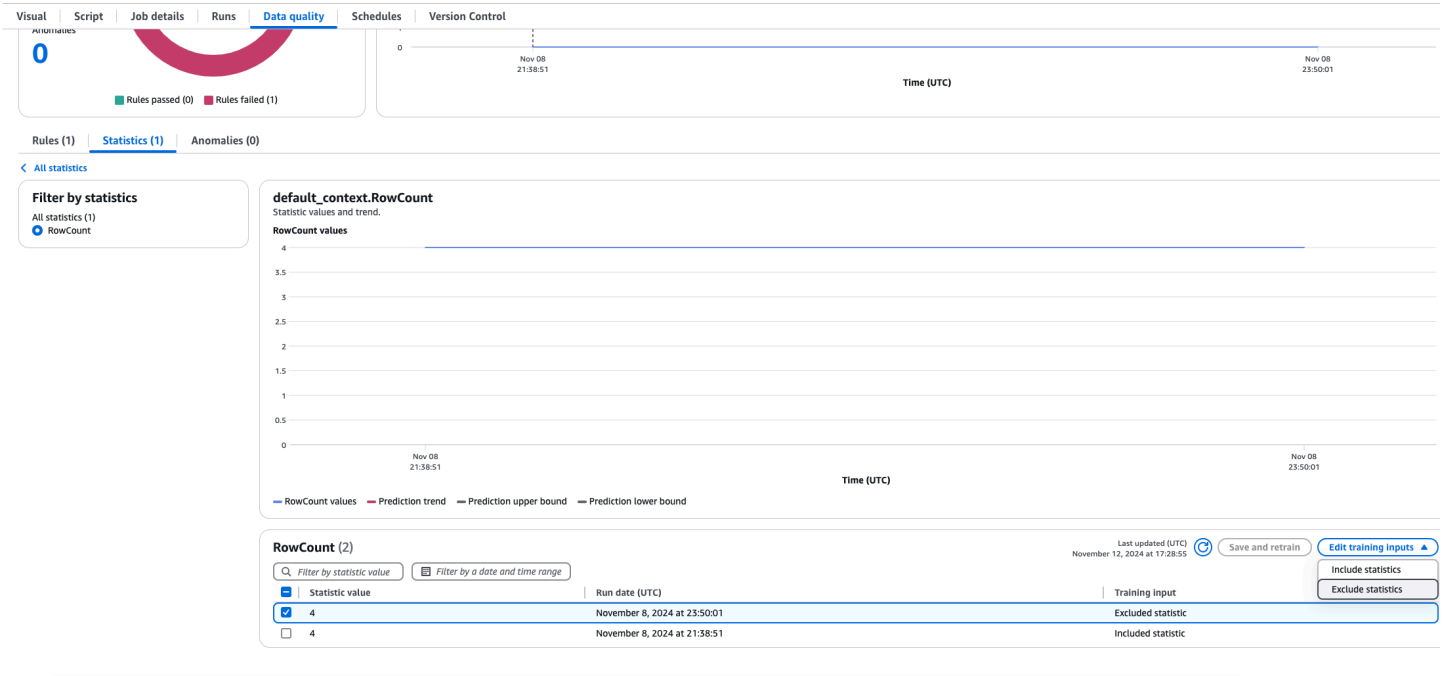

Analizadores

> **Note**
>
> El Catálogo de datos de AWS Glue no es compatible con los analizadores.

Las reglas de DQDL usan funciones denominadas analizadores para recopilar información sobre los datos. La expresión booleana de una regla hace uso de esta información para determinar si la regla debe funcionar correctamente o no. Por ejemplo, la regla RowCount `RowCount > 5` usará un analizador de recuento de filas para descubrir el número de filas del conjunto de datos y compararlo con la expresión `> 5`, para comprobar si existen más de cinco filas en el conjunto de datos actual.

A veces, en lugar de crear reglas, recomendamos crear analizadores y luego hacer que generen estadísticas que puedan usarse para detectar anomalías. Para estos casos, puede crear analizadores. Los analizadores se diferencian de las reglas en estas formas.

Característica	Analizadores	Reglas
Parte del conjunto de reglas	Sí	Sí
Genera estadísticas	Sí	Sí
Genera observaciones	Sí	Sí
Puede evaluar y hacer valer una condición	No	Sí
Puede configurar acciones como detener los trabajos por fallas o continuar procesando el trabajo	No	Sí

Los analizadores pueden existir de forma independiente sin reglas, por lo que es posible configurarlos rápidamente y crear progresivamente reglas de calidad de datos.

Algunos tipos de reglas se pueden introducir en el bloque `Analyzers` del conjunto de reglas para ejecutar las reglas necesarias para los analizadores y recopilar información sin comprobar ninguna condición. Algunos analizadores no están asociados a las reglas y solo se pueden introducir en el bloque `Analyzers`. La siguiente tabla indica si cada elemento se admite como regla o como analizador independiente, junto con información adicional para cada tipo de regla.

Ejemplos de conjunto de reglas con el analizador

El siguiente conjunto de reglas usa:

- una regla dinámica para comprobar si un conjunto de datos está creciendo por arriba de su media final en las últimas tres ejecuciones de tareas,
- un analizador `DistinctValuesCount` para registrar la cantidad de valores distintos de la columna del conjunto de datos de `Name`,
- un analizador `ColumnLength` para rastrear el tamaño mínimo y máximo de `Name` a lo largo del tiempo.

Los resultados de las métricas del analizador pueden verse en la pestaña Calidad de los datos durante la ejecución del trabajo.

```
Rules = [
   RowCount > avg(last(3))
]
Analyzers = [
   DistinctValuesCount "Name",
   ColumnLength "Name"
]
```

Calidad de datos de AWS Glue es compatible con los siguientes analizadores.

Nombre del analizador	Funcionalidad
`RowCount`	Calcula los recuentos de filas de un conjunto de datos
`Completeness`	Calcula el porcentaje de integridad de una columna
`Uniqueness`	Calcula el porcentaje de exclusividad de una columna
`Mean`	Calcula la media de una columna numérica
`Sum`	Calcula la suma de una columna numérica
`StandardDeviation`	Calcula la desviación estándar de una columna numérica
`Entropy`	Calcula la entropía de una columna numérica
`DistinctValuesCount`	Calcula el número de valores distintos de una columna
`UniqueValueRatio`	Calcula la relación de valores únicos de una columna
`ColumnCount`	Calcula el número de columnas de un conjunto de datos

Nombre del analizador	Funcionalidad
`ColumnLength`	Calcula la longitud de una columna
`ColumnValues`	Calcula el mínimo y el máximo para las columnas numéricas Calcula la longitud mínima de la columna y la longitud máxima de la columna para las columnas no numéricas
`ColumnCorrelation`	Calcula las correlaciones de columnas para las columnas dadas
`CustomSql`	Calcula las estadísticas que devuelve CustomSQL
`AllStatistics`	Calcula las siguientes estadísticas: • RowCount, ColumnCount • Cada columna: integridad, exclusividad • Numérica: mínimo, máximo, entropía, media, desarrollo estándar, suma • Cadena: longitud mínima, longitud máxima

Comentarios

Puede utilizar el carácter “#” para agregar un comentario al documento DQDL. DQDL ignorará todo lo que figure a continuación del “#” hasta el final de la línea.

```
Rules = [
    # More items should generally mean a higher price, so correlation should be
 positive
    ColumnCorrelation "price" "num_items" > 0
]
```

Referencia de tipo de regla de DQDL

En esta sección, se proporciona una referencia para cada tipo de regla que admite Calidad de datos de AWS Glue.

> **Note**
>
> - En la actualidad, DQDL no admite datos de columnas anidadas o de tipo lista.
> - Los valores entre corchetes de la siguiente tabla se sustituirán por la información dada en los argumentos de la regla.
> - Por lo general, las reglas requieren un argumento adicional para la expresión.

RuleType	Descripción	Arguments	Métricas informadas	¿Se admite como regla?	¿Se admite como analizador?	¿Devuelve los resultados de nivel de fila?	¿Soporte para reglas dinámicas?	Genera observaciones	¿Admite la cláusula Where?
AggregateMatch	Compruebe si dos conjuntos de datos coinciden mediante la comparación de métricas resumidas, como el importe total de ventas. Es útil	Una o más agregaciones	Cuando los nombres de la primera y la segunda columna de agregación son los mismos: `Column.[Column].AggregateMatch`	Sí	No	No	No	No	No

RuleTyp	Descripc ón	Argumer s	Métricas informad s	¿Se admite como regla?	¿Se admite como analizad r?	¿Devuel los resultad s de nivel de fila?	¿Soporte para reglas dinámica ?	Genera observac ones	¿Admite la cláusula Where?
	para que las instituci ones financier as compare si todos los datos proviene de los sistemas de origen.		Cuando los nombres de la primera y la segunda columna de agregaci n son distintos : `Column. [C olumn1, lumn2]. gregate tch`						

RuleTyp	Descripc ón	Argumer s	Métricas informad s	¿Se admite como regla?	¿Se admite como analizad r?	¿Devuel los resultad s de nivel de fila?	¿Soporte para reglas dinámica ?	Genera observac ones	¿Admite la cláusula Where?

AllStatis tics	Analizad r independ ente que recopila varias métricas para la columna dada de un conjunto de datos.	El nombre de una sola columna	Para las columna de todos los tipos:
			`Dataset .RowCou`
			`Column. [C olumn]. mpleter s`
			`Column. [C olumn]. iquenes`
			Métricas adicional es para columna con valores
				No	Sí	No	No	No	No

RuleTyp	Descripc ón	Argumer s	Métricas informad s	¿Se admite como regla?	¿Se admite como analizad r?	¿Devuel los resultad s de nivel de fila?	¿Soporte para reglas dinámica ?	Genera observac ones	¿Admite la cláusula Where?
			de cadena: `ColumnL gth metrics` Métricas adicional es para columna con valores numéric : `Column ues metrics`						
ColumnC relation	Compru lo bien que se correlaci onan dos columna	Exactam te dos columna de nombres	`Multic mn. [Colum n1,Colu 2].Colu Correla on`	Sí	Sí	No	Sí	No	Sí

RuleTyp	Descripc ón	Argumer s	Métricas informad s	¿Se admite como regla?	¿Se admite como analizad r?	¿Devuel los resultad s de nivel de fila?	¿Soporte para reglas dinámica ?	Genera observac ones	¿Admite la cláusula Where?
ColumnC nt	Compru si se ha eliminad alguna columna	Ninguno	`Datase .Colum unt`	Sí	Sí	No	Sí	Sí	No
ColumnD aType	Compru si una columna es compatib e con un tipo de datos.	Exactam te un nombre de columna	`Column [C olumn]. lumnDa ype.Co iance`	Sí	No	No	Sí, en la expresió de umbral a nivel de fila	No	Sí

RuleTyp	Descripc ón	Argumer s	Métricas informad s	¿Se admite como regla?	¿Se admite como analizad r?	¿Devuel los resultad s de nivel de fila?	¿Soporte para reglas dinámica ?	Genera observac ones	¿Admite la cláusula Where?
ColumnE sts	Compru si existen columna en un conjunto de datos. Esto les permite a los clientes crear platafor as de datos de autoserv cio para garantiz r que determin das columna estén	Exactam te un nombre de columna	N/A	Sí	No	No	No	No	No

RuleTyp	Descripc ón	Argumer s	Métricas informad s	¿Se admite como regla?	¿Se admite como analizad r?	¿Devuel los resultad s de nivel de fila?	¿Soporte para reglas dinámica ?	Genera observac ones	¿Admite la cláusula Where?
	disponibl es.								

ColumnL gth	Compru si la longitud de los datos es coherent .	Exactam te un nombre de columna	`Column. [C olumn]. ximumLe th`
			
			`Column. [C olumn]. nimumLe th`
			
			Métrica adicional cuando se da un umbral a nivel de fila:
			
			`Column. [C olumn]. lumnVa s.Comp nce`
				Sí	Sí	Sí, cuando se da un umbral a nivel de fila	No	Sí. Solo genera observac ones analizan o la longitud mínima y máxima	Sí

RuleTyp	Descripc ón	Argumer s	Métricas informad s	¿Se admite como regla?	¿Se admite como analizad r?	¿Devuel los resultad s de nivel de fila?	¿Soporte para reglas dinámica ?	Genera observac ones	¿Admite la cláusula Where?
ColumnN esMatch ttern	Compru si los nombres de las columna coincide con patrones definidos . Es útil para que los equipos de gobierno refuerce la coheren a de los nombres de las columna	Una expresió regular para los nombres de las columna	`Datase .Colum mesPat nMatchF io`	Sí	No	No	No	No	No

RuleTyp	Descripc ón	Argumer s	Métricas informad s	¿Se admite como regla?	¿Se admite como analizad r?	¿Devuel los resultad s de nivel de fila?	¿Soporte para reglas dinámica ?	Genera observac ones	¿Admite la cláusula Where?

ColumnV ues	Compru si los datos son coherent s según los valores definido . Esta regla admite expresio es regulare .	Exactam te un nombre de columna	`Column [C olumn] ximum`
			
			`Column [C olumn] nimum`
			
			Métrica adicional cuando se da un umbral a nivel de fila:
			
			`Column [C olumn] lumnVa s.Comp nce`
				Sí	Sí	Sí, cuando se da un umbral a nivel de fila	No	Sí. Solo genera observac ones analizan o los valores mínimo y máximo	Sí

RuleTyp	Descripc ón	Argumer s	Métricas informad s	¿Se admite como regla?	¿Se admite como analizad r?	¿Devuel los resultad s de nivel de fila?	¿Soporte para reglas dinámica ?	Genera observac ones	¿Admite la cláusula Where?
Integrida d	Compru si hay espacios en blanco o CEROS en los datos.	Exactam te un nombre de columna	`Column [C olumn] mpleter s`	Sí	Sí	Sí	Sí	Sí	Sí

CustomS	Los clientes pueden implem ar prácticar ente cualquie tipo de control de calidad de datos en SQL.	Una instrucci ón SQL
		
		(Opciona) Un umbral a nivel de fila
			`Dataset .Custor L`
			
			Métrica adicional cuando se da un umbral a nivel de fila:
			
			`Dataset .Custor L.Compl nce`
				Sí	No	Sí, cuando se da un umbral a nivel de fila	Sí	No	No

RuleTyp	Descripc ón	Argumer s	Métricas informad s	¿Se admite como regla?	¿Se admite como analizad r?	¿Devuel los resultad s de nivel de fila?	¿Soporte para reglas dinámica ?	Genera observac ones	¿Admite la cláusula Where?
DataFres ness	Compru si los datos están actualiza dos.	Exactam te un nombre de columna	`Column [C olumn]. taFresh ss.Comp ance`	Sí	No	Sí	No	No	Sí
DataSetM tch	Compara dos conjunto de datos e identific a si están sincroniz ados.	Nombre de un conjunto de datos de referenci a Un mapeo de columna (Opciona) Columna para comprob si hay coincide cias	`Dataset [ Referer Dataset ias].Da setMatc`	Sí	No	Sí	Sí	No	No

RuleTyp	Descripc ón	Argumer s	Métricas informad s	¿Se admite como regla?	¿Se admite como analizad r?	¿Devuel los resultad s de nivel de fila?	¿Soporte para reglas dinámica ?	Genera observac ones	¿Admite la cláusula Where?
DistinctV aluesCo t	Compru si hay valores duplicad s.	Exactam te un nombre de columna	`Column [C olumn] stinct\ uesCour`	Sí	Sí	Sí	Sí	Sí	Sí
DetectAr malies	Compru la presenci de anomalí en las métricas notific as por otro tipo de regla.	Un tipo de regla	Métricas informad s por el argumen del tipo de regla	Sí	No	No	No	No	No
Entropía	Compru la entropía de los datos.	Exactam te un nombre de columna	`Column [C olumn] tropy`	Sí	Sí	No	Sí	No	Sí

RuleTyp	Descripc ón	Argumer s	Métricas informad s	¿Se admite como regla?	¿Se admite como analizad r?	¿Devuel los resultad s de nivel de fila?	¿Soporte para reglas dinámica ?	Genera observac ones	¿Admite la cláusula Where?
IsComple e	Compru si el 100 % de los datos está complet .	Exactam te un nombre de columna	`Column [C olumn] mpleter s`	Sí	No	Sí	No	No	Sí

RuleTyp	Descripc ón	Argumer s	Métricas informad s	¿Se admite como regla?	¿Se admite como analizad r?	¿Devuel los resultad s de nivel de fila?	¿Soporte para reglas dinámica ?	Genera observac ones	¿Admite la cláusula Where?
IsPrimar Key	Compru si una columna es una clave principal (no NULA y única).	Exactam te un nombre de columna	Para una sola columna `Column [C olumn] iquene` Para múltiples columna `Multic mn. [Comma Delimi Column Uniquer s`	Sí	No	Sí	No	No	Sí
IsUnique	Compru si el 100 % de los datos es único.	Exactam te un nombre de columna	`Column [C olumn] iquene`	Sí	No	Sí	No	No	Sí

RuleTyp	Descripc ón	Argumer s	Métricas informad s	¿Se admite como regla?	¿Se admite como analizad r?	¿Devuel los resultad s de nivel de fila?	¿Soporte para reglas dinámica ?	Genera observac ones	¿Admite la cláusula Where?
Media	Compru si la media coincide con el umbral estableci do.	Exactam te un nombre de columna	`Column [C olumn] an`	Sí	Sí	Sí	Sí	No	Sí
Referent alIntegri ty	Compru si dos conjunto de datos tienen integrida d referenci al.	Una o más columna del conjunto de datos Uno o más nombres de columna del conjunto de datos de referenci a	`Column [R eferen ataset/ as].Re ential egrity`	Sí	No	Sí	Sí	No	No

RuleTyp	Descripc ón	Argumer s	Métricas informad s	¿Se admite como regla?	¿Se admite como analizad r?	¿Devuel los resultad s de nivel de fila?	¿Soporte para reglas dinámica ?	Genera observac ones	¿Admite la cláusula Where?
RowCou	Comprue si los recuento de registros coincider con un umbral.	Ninguno	`Datase .RowCou`	Sí	Sí	No	Sí	Sí	Sí
RowCou atch	Comprue si los recuento de registros entre dos conjunto de datos coincider .	Alias del conjunto de datos de referenci a	`Datase [ Refere Datase ias].Rc ountMa`	Sí	No	No	Sí	No	No

RuleTyp	Descripc ón	Argumer s	Métricas informad s	¿Se admite como regla?	¿Se admite como analizad r?	¿Devuel los resultad s de nivel de fila?	¿Soporte para reglas dinámica ?	Genera observac ones	¿Admite la cláusula Where?
Standarc eviation	Compru si la desviaci n estánda coincide con el umbral.	Exactam te un nombre de columna	`Column [C olumn]. andardD iation`	Sí	Sí	Sí	Sí	No	Sí
Schema ch	Compru si el esquem entre dos conjunto de datos coincide.	Alias del conjunto de datos de referenci a	`Datase [ Refere Datase ias].Sc maMatc`	Sí	No	No	Sí	No	No
Sum	Compru si la suma coincide con un umbral estableci do.	Exactam te un nombre de columna	`Column [C olumn]. m`	Sí	Sí	No	Sí	No	Sí

RuleTyp	Descripc ón	Argumer s	Métricas informad s	¿Se admite como regla?	¿Se admite como analizad r?	¿Devuel los resultad s de nivel de fila?	¿Soporte para reglas dinámica ?	Genera observac ones	¿Admite la cláusula Where?
Singulari dad	Compru si la unicidad del conjunto de datos coincide con el umbral.	Exactam te un nombre de columna	`Column [C olumn] iquene`	Sí	Sí	Sí	Sí	No	Sí
UniqueV ueRatio	Compru si la relación de valores únicos coincide con el umbral.	Exactam te un nombre de columna	`Column [C olumn] iqueVa Ratio`	Sí	Sí	Sí	Sí	No	Sí

RuleTyp	Descripc ón	Argumer s	Métricas informad s	¿Se admite como regla?	¿Se admite como analizad r?	¿Devuel los resultad s de nivel de fila?	¿Soporte para reglas dinámica ?	Genera observac ones	¿Admite la cláusula Where?

FileFresh ness	Compru si los archivos de Amazon S3 están actualiza dos.	Ruta del archivo o carpeta y un umbral.	`Datase .FileF hness.C pliance`
			
			`Datase .FileC t`
				Sí	No	No	No	No	No

RuleTyp	Descripc ón	Argumer s	Métricas informad s	¿Se admite como regla?	¿Se admite como analizad r?	¿Devuel los resultad s de nivel de fila?	¿Soporte para reglas dinámica ?	Genera observac ones	¿Admite la cláusula Where?
FileMatc	Compru si el conteni del archivo coincide con una suma de comprob ión o con otro archivo. Esta regla usa sumas de comprob ión para validar si dos archivos son iguales.	Ruta del archivo o carpeta de origen y ruta del archivo o carpeta de destino.	No se genera ninguna estadísti ca.	Sí	No	No	No	No	No

RuleTyp	Descripc ón	Argumer s	Métricas informad s	¿Se admite como regla?	¿Se admite como analizad r?	¿Devuel los resultad s de nivel de fila?	¿Soporte para reglas dinámica ?	Genera observac ones	¿Admite la cláusula Where?

FileSize	Compru si el tamaño de un archivo coincide con una condició especific ada.	Ruta del archivo o carpeta y umbral.	`Datase .FileSi .Compli ce`
			`Datase .FileC t`
			`Datase .Maxim ileSiz`
			`Datase .Minim ileSiz`
				Sí	No	No	No	No	No

FileUniqu eness	Compru si los archivos son únicos mediant sumas de comprob ión.	Ruta del archivo o carpeta y umbral.	`Datase .FileU uenessF io` `Datase .FileC t`	Sí	No	No	No	No	No

Temas

- AggregateMatch
- ColumnCorrelation
- ColumnCount
- ColumnDataType
- ColumnExists
- ColumnLength
- ColumnNamesMatchPattern
- ColumnValues
- Integridad
- CustomSQL
- DataFreshness
- DataSetMatch
- DistinctValuesCount
- Entropía
- IsComplete
- IsPrimaryKey
- IsUnique
- Media
- ReferentialIntegrity
- RowCount
- RowCountMatch
- StandardDeviation
- Sum
- SchemaMatch
- Singularidad
- UniqueValueRatio
- DetectAnomalies
- FileFreshness
- FileMatch
- FileUniqueness

- FileSize

AggregateMatch

Comprueba la relación de dos agregaciones de columnas con respecto a una expresión determinada. Este tipo de regla funciona en varios conjuntos de datos. Se evalúan las agregaciones de dos columnas y se obtiene una relación al dividir el resultado de la agregación de la primera columna por el resultado de la agregación de la segunda columna. La relación se comprueba con la expresión proporcionada para producir una respuesta booleana.

Sintaxis

Agregación de columnas

```
AggregateMatch <AGG_OPERATION> (<OPTIONAL_REFERENCE_ALIAS>.<COL_NAME>)
```

- AGG_OPERATION: la operación que se debe utilizar para la agregación. `sum` y `avg` se admiten en la actualidad.

  Tipos de columnas compatibles: byte, decimal, doble, flotante, entero, largo, corto
- OPTIONAL_REFERENCE_ALIAS: este parámetro debe proporcionarse si la columna proviene de un conjunto de datos de referencia y no del conjunto de datos principal. Si utiliza esta regla en el Catálogo de datos de AWS Glue, su alias de referencia debe tener el formato "<database_name>.<table_name>.<column_name>

  Tipos de columnas compatibles: byte, decimal, doble, flotante, entero, largo, corto
- COL_NAME: el nombre de la columna que se va a agregar.

  Tipos de columnas compatibles: byte, decimal, doble, flotante, entero, largo, corto

Ejemplo: promedio

```
"avg(rating)"
```

Ejemplo: suma

```
"sum(amount)"
```

Ejemplo: promedio de la columna en el conjunto de datos de referencia

```
"avg(reference.rating)"
```

Regla

```
AggregateMatch <AGG_EXP_1> <AGG_EXP_2> <EXPRESSION>
```

- AGG_EXP_1: la agregación de la primera columna.

  Tipos de columnas compatibles: byte, decimal, doble, flotante, entero, largo, corto

  Tipos de columnas compatibles: byte, decimal, doble, flotante, entero, largo, corto
- AGG_EXP_2: la agregación de la segunda columna.

  Tipos de columnas compatibles: byte, decimal, doble, flotante, entero, largo, corto

  Tipos de columnas compatibles: byte, decimal, doble, flotante, entero, largo, corto
- EXPRESSION: una expresión que se ejecuta en función de la respuesta del tipo de regla para producir un valor booleano. Para obtener más información, consulte Expresiones.

Ejemplo: coincidencia agregada mediante suma

La siguiente regla de ejemplo comprueba si la suma de los valores en la columna `amount` es exactamente igual a la suma de los valores en la columna `total_amount`.

```
AggregateMatch "sum(amount)" "sum(total_amount)" = 1.0
```

Ejemplo: coincidencia agregada mediante promedio

La siguiente regla de ejemplo comprueba si el promedio de los valores en la columna `ratings` es igual al 90 %, como mínimo, del promedio de los valores en la columna `ratings` en el conjunto de datos `reference`. El conjunto de datos de referencia se proporciona como origen de datos adicional en la experiencia ETL o el Catálogo de datos.

En AWS Glue ETL, puede usar:

```
AggregateMatch "avg(ratings)" "avg(reference.ratings)" >= 0.9
```

En el Catálogo de datos de AWS Glue, puede usar:

```
AggregateMatch "avg(ratings)" "avg(database_name.tablename.ratings)" >= 0.9
```

Comportamiento nulo

La regla `AggregateMatch` ignorará las filas con valores nulos al momento de calcular los métodos de agregación (suma/media). Por ejemplo:

```
+---+-----------+
|id |units      |
+---+-----------+
|100|0          |
|101|null       |
|102|20         |
|103|null       |
|104|40         |
+---+-----------+
```

La media de la columna `units` será (0 + 20 + 40) / 3 = 20. Las filas 101 y 103 no se tienen en cuenta para este cálculo.

ColumnCorrelation

Comprueba la correlación entre dos columnas con una expresión dada. AWS Calidad de datos de Glue utiliza el coeficiente de correlación de Pearson para medir la correlación lineal entre dos columnas. El resultado es un número entre -1 y 1 que mide la fuerza y la dirección de la relación.

Sintaxis

```
ColumnCorrelation <COL_1_NAME> <COL_2_NAME> <EXPRESSION>
```

- COL_1_NAME: el nombre de la primera columna con la que quiere evaluar la regla de la calidad de los datos.

  Tipos de columnas compatibles: byte, decimal, doble, flotante, entero, largo, corto
- COL_2_NAME: el nombre de la segunda columna con la que quiere evaluar la regla de la calidad de los datos.

  Tipos de columnas compatibles: byte, decimal, doble, flotante, entero, largo, corto

- EXPRESSION: una expresión que se ejecuta en función de la respuesta del tipo de regla para producir un valor booleano. Para obtener más información, consulte Expresiones.

Ejemplo: correlación de columnas

La siguiente regla de ejemplo comprueba si el coeficiente de correlación entre las columnas `height` y `weight` tiene una correlación positiva fuerte (un valor de coeficiente superior a 0,8).

```
ColumnCorrelation "height" "weight" > 0.8
```

```
ColumnCorrelation "weightinkgs" "Salary" > 0.8 where "weightinkgs > 40"
```

Muestra de reglas dinámicas

- `ColumnCorrelation "colA" "colB" between min(last(10)) and max(last(10))`
- `ColumnCorrelation "colA" "colB" < avg(last(5)) + std(last(5))`

Comportamiento nulo

La regla `ColumnCorrelation` ignorará las filas con los valores `NULL` al momento de calcular la correlación. Por ejemplo:

```
+---+-----------+
|id |units      |
+---+-----------+
|100|0          |
|101|null       |
|102|20         |
|103|null       |
|104|40         |
+---+-----------+
```

Las filas 101 y 103 se ignorarán y la `ColumnCorrelation` será 1.0.

ColumnCount

Comprueba el recuento de columnas del conjunto de datos principal con respecto a una expresión determinada. En la expresión, puede indicar el número de columnas o un rango de columnas mediante operadores como > y <.

Sintaxis

```
ColumnCount <EXPRESSION>
```

- EXPRESSION: una expresión que se ejecuta en función de la respuesta del tipo de regla para producir un valor booleano. Para obtener más información, consulte Expresiones.

Ejemplo: comprobación numérica del recuento de columnas

La siguiente regla de ejemplo comprueba si el recuento de columnas se encuentra dentro de un rango determinado.

```
ColumnCount between 10 and 20
```

Muestra de reglas dinámicas

- `ColumnCount >= avg(last(10))`
- `ColumnCount between min(last(10))-1 and max(last(10))+1`

ColumnDataType

Comprueba si los valores de una columna determinada se pueden convertir en Apache Spark al tipo proporcionado. Acepta una expresión `with threshold` para comprobar si hay un subconjunto de los valores en la columna.

Sintaxis

```
ColumnDataType <COL_NAME> = <EXPECTED_TYPE>
```

- COL_NAME: el nombre de la columna con la que quiere evaluar la regla de la calidad de los datos.

  Tipos de columnas compatibles: tipo cadena

  Tipos de columnas compatibles: byte, decimal, doble, flotante, entero, largo, corto
- EXPECTED_TYPE: el tipo esperado de los valores en la columna.

  Valores admitidos: booleano, fecha, marca de tiempo, entero, doble, flotante, largo

  Tipos de columnas compatibles: byte, decimal, doble, flotante, entero, largo, corto

- EXPRESIÓN: una expresión opcional para especificar el porcentaje de valores que deben ser del tipo esperado.

  Tipos de columnas compatibles: byte, decimal, doble, flotante, entero, largo, corto

Ejemplo: números enteros del tipo de datos de columna como cadenas

La siguiente regla de ejemplo comprueba si los valores de la columna dada, que es de tipo cadena, pueden convertirse a enteros.

```
ColumnDataType "colA" = "INTEGER"
```

Ejemplo: los números enteros del tipo de datos de las columnas como cadenas comprueban un subconjunto de los valores

La siguiente regla de ejemplo comprueba si más del 90 % de los valores de la columna dada, que es de tipo cadena, pueden convertirse a enteros.

```
ColumnDataType "colA" = "INTEGER" with threshold > 0.9
```

ColumnExists

Comprueba si existe una columna.

Sintaxis

```
ColumnExists <COL_NAME>
```

- COL_NAME: el nombre de la columna con la que quiere evaluar la regla de la calidad de los datos.

  Tipos de columnas compatibles: cualquier tipo de columna

Ejemplo: la columna existe

La siguiente regla de ejemplo comprueba si existe la columna denominada `Middle_Name`.

```
ColumnExists "Middle_Name"
```

ColumnLength

Comprueba si la longitud de cada fila de una columna se ajusta a una expresión dada.

Sintaxis

```
ColumnLength <COL_NAME><EXPRESSION>
```

- COL_NAME: el nombre de la columna con la que quiere evaluar la regla de la calidad de los datos.

  Tipos de columnas compatibles: cadena
- EXPRESSION: una expresión que se ejecuta en función de la respuesta del tipo de regla para producir un valor booleano. Para obtener más información, consulte Expresiones.

Ejemplo: longitud de la fila de la columna

La siguiente regla de ejemplo comprueba si el valor de cada fila de la columna denominada `Postal_Code` tiene 5 caracteres.

```
ColumnLength "Postal_Code" = 5
ColumnLength "weightinkgs" = 2 where "weightinkgs > 10"
```

Comportamiento nulo

La regla `ColumnLength` considera a los valores `NULL` como cadenas con una longitud de 0. Para una fila `NULL`:

```
ColumnLength "Postal_Code" > 4 # this will fail
```

```
ColumnLength "Postal_Code" < 6 # this will succeed
```

El ejemplo de regla compuesta a continuación presenta una manera de fallar de manera explícita un valor `NULL`:

```
(ColumnLength "Postal_Code" > 4) AND (ColumnValues "Postal_Code" != NULL)
```

ColumnNamesMatchPattern

Comprueba si los nombres de todas las columnas del conjunto de datos principal coinciden con la expresión regular dada.

Sintaxis

```
ColumnNamesMatchPattern <PATTERN>
```

- PATRÓN: el patrón contra el que desea evaluar la regla de calidad de los datos.

  Tipos de columnas compatibles: byte, decimal, doble, flotante, entero, largo, corto

Ejemplo: los nombres de las columnas coinciden con el patrón

La siguiente regla de ejemplo comprueba si todas las columnas comienzan con el prefijo “aws_”

```
ColumnNamesMatchPattern "aws_.*"
ColumnNamesMatchPattern "aws_.*" where "weightinkgs > 10"
```

ColumnValues

Ejecuta una expresión con los valores de una columna.

Sintaxis

```
ColumnValues <COL_NAME> <EXPRESSION>
```

- COL_NAME: el nombre de la columna con la que quiere evaluar la regla de la calidad de los datos.

  Tipos de columnas compatibles: cualquier tipo de columna
- EXPRESSION: una expresión que se ejecuta en función de la respuesta del tipo de regla para producir un valor booleano. Para obtener más información, consulte Expresiones.

Ejemplo: valores permitidos

El ejemplo de regla a continuación controla que cada valor en la columna específica se encuentre en un conjunto de valores permitidos (incluidos los valores nulos y las cadenas que solo contienen espacios en blanco).

```
ColumnValues "Country" in [ "US", "CA", "UK", NULL, EMPTY, WHITESPACES_ONLY ]
ColumnValues "gender" in ["F", "M"] where "weightinkgs < 10"
```

Ejemplo: expresión regular

La siguiente regla de ejemplo compara los valores de una columna con una expresión regular.

```
ColumnValues "First_Name" matches "[a-zA-Z]*"
```

Ejemplo: valores de fecha

La siguiente regla de ejemplo compara los valores de una columna de fecha con una expresión de fecha.

```
ColumnValues "Load_Date" > (now() - 3 days)
```

Ejemplo: valores numéricos

La siguiente regla de ejemplo comprueba si los valores de las columnas coinciden con una restricción numérica determinada.

```
ColumnValues "Customer_ID" between 1 and 2000
```

Comportamiento nulo

Para todas las reglas `ColumnValues` (además de `!=` y `NOT IN`), las filas `NULL` fallarán la regla. Si la regla falla debido a un valor nulo, la razón de la falla se mostrará de la siguiente manera:

```
Value: NULL does not meet the constraint requirement!
```

El ejemplo de regla compuesta a continuación presenta una manera de permitir de manera explícita los valores `NULL`:

```
(ColumnValues "Age" > 21) OR (ColumnValues "Age" = NULL)
```

Las reglas ColumnValues negadas que utilicen la sintaxis `!=` y `not in` se considerarán filas `NULL`. Por ejemplo:

```
ColumnValues "Age" != 21
```

```
ColumnValues "Age" not in [21, 22, 23]
```

Los ejemplos a continuación presentan una manera de fallar de manera explícita los valores NULL

```
(ColumnValues "Age" != 21) AND (ColumnValues "Age" != NULL)
```

```
ColumnValues "Age" not in [21, 22, 23, NULL]
```

Integridad

Comprueba el porcentaje de valores completos (no nulos) de una columna con respecto a una expresión determinada.

Sintaxis

```
Completeness <COL_NAME> <EXPRESSION>
```

- COL_NAME: el nombre de la columna con la que quiere evaluar la regla de la calidad de los datos.

  Tipos de columnas compatibles: cualquier tipo de columna
- EXPRESSION: una expresión que se ejecuta en función de la respuesta del tipo de regla para producir un valor booleano. Para obtener más información, consulte Expresiones.

Ejemplo: porcentaje de valor nulo

Las siguientes reglas de ejemplo comprueban si más del 95 % de los valores de una columna están completos.

```
Completeness "First_Name" > 0.95
Completeness "First_Name" > 0.95 where "weightinkgs > 10"
```

Muestra de reglas dinámicas

- `Completeness "colA" between min(last(5)) - 1 and max(last(5)) + 1`

- `Completeness "colA" <= avg(last(10))`

Comportamiento nulo

Nota sobre los formatos de datos CSV: las filas en blanco en las columnas de CSV pueden demostrar distintos comportamientos.

- Si una columna es del tipo `String`, la fila en blanco se reconocerá como una cadena vacía y no fallará la regla `Completeness`.
- Si una columna es de otro tipo de dato, como `Int`, la fila en blanco se reconocerá como `NULL` y fallará la regla `Completeness`.

CustomSQL

Este tipo de regla se ha ampliado para admitir dos casos de uso:

- Ejecutar una instrucción SQL personalizada contra un conjunto de datos y comprobar el valor que se produce con respecto a una expresión dada.
- Ejecutar una instrucción SQL personalizada en la que especifique un nombre de columna en la instrucción SELECT contra el que compararlo con alguna condición para obtener resultados a nivel de fila.

Sintaxis

```
CustomSql <SQL_STATEMENT> <EXPRESSION>
```

- SQL_STATEMENT: una instrucción SQL que devuelve un solo valor numérico, entre comillas dobles.
- EXPRESSION: una expresión que se ejecuta en función de la respuesta del tipo de regla para producir un valor booleano. Para obtener más información, consulte Expresiones.

Ejemplo: SQL personalizado para recuperar el resultado general de una regla

Esta regla de ejemplo usa una instrucción SQL para recuperar el recuento de registros de un conjunto de datos. A continuación, la regla comprueba que el recuento de registros esté comprendido entre 10 y 20.

```
CustomSql "select count(*) from primary" between 10 and 20
```

Ejemplo: SQL personalizado para recuperar los resultados a nivel de fila

Esta regla de ejemplo utiliza una instrucción SQL en la que se especifica un nombre de columna en la instrucción SELECT con el que se compara con alguna condición para obtener resultados a nivel de fila. Una expresión de condición de umbral define un umbral del número de registros que deben fallar para que falle toda la regla. Tenga en cuenta que una regla no puede contener una condición y una palabra clave juntas.

```
CustomSql "select Name from primary where Age  > 18"
```

o

```
CustomSql "select Name from primary where Age > 18" with threshold  > 3
```

> **Important**
>
> El alias `primary` representa el nombre del conjunto de datos que quiere evaluar. Al trabajar con trabajos de ETL visuales en la consola, `primary` siempre representa el elemento `DynamicFrame` que se pasa a la transformación de `EvaluateDataQuality.apply()`. Cuando se utiliza el Catálogo de datos de AWS Glue para ejecutar tareas de calidad de datos en una tabla, `primary` representa la tabla.

Si está en el Catálogo de datos de AWS Glue, también puede usar los nombres reales de las tablas:

```
CustomSql "select count(*) from database.table" between 10 and 20
```

También puede combinar varias tablas para comparar diferentes elementos de datos:

```
CustomSql "select count(*) from database.table inner join database.table2 on id1 = id2"
 between 10 and 20
```

En ETL de AWS Glue, CustomSQL puede identificar los registros que no superaron las comprobaciones de calidad de datos. Para que esto funcione, debe devolver los registros que forman parte de la tabla principal para la que evalúa la calidad de los datos. Los registros que se producen

como parte de la consulta se consideran correctos y aquellos que no se producen se consideran fallidos. Esto funciona uniendo el resultado de la consulta CustomSQL con el conjunto de datos original. Puede haber implicaciones de rendimiento en función de la complejidad de su consulta SQL.

Para ello:

- Debe seleccionar al menos una columna de la tabla principal.
  - `select count(*) from primary` es una consulta válida para la regla OVERALL de CustomSQL DQ, pero no para el SQL personalizado a nivel de fila.
  - Esta regla generará un error durante la evaluación: `The output from CustomSQL must contain at least one column that matches the input dataset for AWS Glue Data Quality to provide row level results. The SQL query is a valid query but the columns from the SQL result are not present in the Input Dataset. Ensure that matching columns are returned from the SQL.`
- En su consulta SQL, seleccione una `Clave principal` de su tabla o seleccione un conjunto de columnas que formen una clave compuesta. No hacerlo puede generar resultados inconsistentes debido a la coincidencia de filas duplicadas y en un rendimiento degradado.
- Seleccione claves SOLO de su tabla principal y no de sus tablas de referencia.

La siguiente regla garantizará que los registros con una antigüedad inferior a 100 años se identifiquen como correctos y que aquellos anteriores se marquen como fallidos.

```
CustomSql "select id from primary where age < 100"
```

Esta regla CustomSQL se aprobará cuando el 50 % de los registros tengan más 10 años de antigüedad y también identificará los registros que fallaron. Los registros que este CustomSQL produce se considerarán aprobados, mientras que los que no se producen se considerarán fallidos.

```
CustomSQL "select ID, CustomerID from primary where age > 10" with threshold > 0.5
```

Nota: La regla CustomSQL fallará si usted produce registros que no están disponibles en el conjunto de datos.

DataFreshness

Comprueba la actualización de los datos de una columna mediante la evaluación de la diferencia entre la hora actual y los valores de una columna de fecha. Puede indicar una expresión basada

en el tiempo para este tipo de regla para asegurarse de que los valores de las columnas estén actualizados.

Sintaxis

```
DataFreshness <COL_NAME> <EXPRESSION>
```

- COL_NAME: el nombre de la columna con la que quiere evaluar la regla de la calidad de los datos.

  Tipos de columnas compatibles: fecha
- EXPRESSION: una expresión numérica en horas o días. Debe indicar la unidad de tiempo en la expresión.

Ejemplo: actualización de los datos

Las siguientes reglas de ejemplo comprueban la actualización de los datos.

```
DataFreshness "Order_Date" <= 24 hours
DataFreshness "Order_Date" between 2 days and 5 days
```

Comportamiento nulo

Las reglas `DataFreshness` fallarán para las filas con valores `NULL`. Si la regla falla debido a un valor nulo, la razón de la falla se mostrará de la siguiente manera:

```
80.00 % of rows passed the threshold
```

donde el 20 % de las filas que fallaron incluyen las filas con valores `NULL`.

El ejemplo de regla compuesta a continuación presenta una manera de permitir de manera explícita los valores `NULL`:

```
(DataFreshness "Order_Date" <= 24 hours) OR (ColumnValues "Order_Date" = NULL)
```

Actualización de datos para objetos de Amazon S3

En ocasiones, tendrá que validar la actualización de los datos en función del tiempo de creación del archivo de Amazon S3. Para ello, puede usar el siguiente código para obtener la marca temporal y añadirla a su marco de datos y, a continuación, aplicar las comprobaciones de actualización de los datos.

```
df = glueContext.create_data_frame.from_catalog(database = "default", table_name =
 "mytable")
df = df.withColumn("file_ts", df["_metadata.file_modification_time"])

Rules = [
 DataFreshness "file_ts" < 24 hours
]
```

DataSetMatch

Compruebe si los datos del conjunto de datos principal coinciden con los datos de un conjunto de datos de referencia. Los dos conjuntos de datos se combinan mediante las asignaciones de columnas clave proporcionadas. Se pueden proporcionar asignaciones de columnas adicionales si desea comprobar la igualdad de los datos solo en esas columnas. Tenga en cuenta que para que DataSetMatch funcione, sus claves de unión deben ser únicas y no NULA (debe ser una clave principal). Si no cumple estas condiciones, recibirá el siguiente mensaje de error: “La asignación de teclas proporcionada no es adecuada para determinados marcos de datos”. En los casos en los que no pueda contar con claves combinadas que sean únicas, considere usar otros tipos de reglas, como AggregateMatch, para que coincidan en los datos resumidos.

Sintaxis

```
DatasetMatch <REFERENCE_DATASET_ALIAS> <JOIN CONDITION WITH
 MAPPING> <OPTIONAL_MATCH_COLUMN_MAPPINGS> <EXPRESSION>
```

- REFERENCE_DATASET_ALIAS: el alias del conjunto de datos de referencia con el que se comparan los datos del conjunto de datos principal.
- KEY_COLUMN_MAPPINGS: una lista de nombres de columnas separados por comas que forman una clave en los conjuntos de datos. Si los nombres de las columnas no son los mismos en ambos conjuntos de datos, debe separarlos con un `->`
- OPTIONAL_MATCH_COLUMN_MAPPINGS: puede proporcionar este parámetro si desea comprobar si hay datos coincidentes solo en determinadas columnas. Utiliza la misma sintaxis que las asignaciones de columnas clave. Si no se proporciona este parámetro, haremos coincidir los datos en todas las columnas restantes. Las columnas restantes, que no son clave, deben tener los mismos nombres en ambos conjuntos de datos.
- EXPRESSION: una expresión que se ejecuta en función de la respuesta del tipo de regla para producir un valor booleano. Para obtener más información, consulte Expresiones.

Ejemplo: haga coincidir los conjuntos de datos mediante la columna de ID

La siguiente regla de ejemplo comprueba que más del 90 % del conjunto de datos principal coincide con el conjunto de datos de referencia, mediante el uso de la columna “ID” para unir los dos conjuntos de datos. En este caso, compara todas las columnas.

```
DatasetMatch "reference" "ID" >= 0.9
```

Ejemplo: haga coincidir conjuntos de datos mediante varias columnas clave

En el siguiente ejemplo, el conjunto de datos principal y el conjunto de datos de referencia tienen nombres diferentes para las columnas clave. `ID_1` y `ID_2` juntos forman una clave compuesta en el conjunto de datos principal. `ID_ref1` y `ID_ref2` juntos forman una clave compuesta en el conjunto de datos de referencia. En este escenario, puede usar la sintaxis especial para proporcionar los nombres de las columnas.

```
DatasetMatch "reference" "ID_1->ID_ref1,ID_ref2->ID_ref2" >= 0.9
```

Ejemplo: haga coincidir conjuntos de datos mediante varias columnas clave y compruebe que una columna específica coincida

Este ejemplo se basa en el ejemplo anterior. Queremos comprobar que solo coincide la columna que contiene los importes. Esta columna se denomina `Amount1` en el conjunto de datos principal y `Amount2` en el conjunto de datos de referencia. Quiere una coincidencia exacta.

```
DatasetMatch "reference" "ID_1->ID_ref1,ID_2->ID_ref2" "Amount1->Amount2" >= 0.9
```

DistinctValuesCount

Compara la cantidad de valores distintos de una columna con una expresión dada.

Sintaxis

```
DistinctValuesCount <COL_NAME> <EXPRESSION>
```

- COL_NAME: el nombre de la columna con la que quiere evaluar la regla de la calidad de los datos.

  Tipos de columnas compatibles: cualquier tipo de columna

- EXPRESSION: una expresión que se ejecuta en función de la respuesta del tipo de regla para producir un valor booleano. Para obtener más información, consulte Expresiones.

Ejemplo: recuento de valores distintos de columnas

La siguiente regla de ejemplo comprueba que la columna denominada `State` contenga más de 3 valores distintos.

```
DistinctValuesCount "State" > 3
DistinctValuesCount "Customer_ID" < 6  where "Customer_ID < 10"
```

Muestra de reglas dinámicas

- `DistinctValuesCount "colA" between avg(last(10))-1 and avg(last(10))+1`
- `DistinctValuesCount "colA" <= index(last(10),2) + std(last(5))`

Entropía

Comprueba si el valor de entropía de una columna coincide con una expresión dada. La entropía mide el nivel de información que contiene un mensaje. Dada la distribución de probabilidad entre los valores de una columna, la entropía describe cuántos bits se necesitan para identificar un valor.

Sintaxis

```
Entropy <COL_NAME> <EXPRESSION>
```

- COL_NAME: el nombre de la columna con la que quiere evaluar la regla de la calidad de los datos.

  Tipos de columnas compatibles: cualquier tipo de columna
- EXPRESSION: una expresión que se ejecuta en función de la respuesta del tipo de regla para producir un valor booleano. Para obtener más información, consulte Expresiones.

Ejemplo: entropía de columna

La siguiente regla de ejemplo comprueba que la columna denominada `Feedback` tiene un valor de entropía superior a uno.

```
Entropy "Star_Rating" > 1
```

```
Entropy "First_Name" > 1  where "Customer_ID < 10"
```

Muestra de reglas dinámicas

- `Entropy "colA" < max(last(10))`
- `Entropy "colA" between min(last(10)) and max(last(10))`

IsComplete

Comprueba si todos los valores de una columna están completos (no nulos).

Sintaxis

```
IsComplete <COL_NAME>
```

- COL_NAME: el nombre de la columna con la que quiere evaluar la regla de la calidad de los datos.

  Tipos de columnas compatibles: cualquier tipo de columna

Ejemplo: valores nulos

El siguiente ejemplo comprueba si todos los valores de una columna denominada `email` no son nulos.

```
IsComplete "email"
IsComplete "Email" where "Customer_ID between 1 and 50"
IsComplete "Customer_ID"  where "Customer_ID < 16 and Customer_ID != 12"
IsComplete "passenger_count" where "payment_type<>0"
```

Comportamiento nulo

Nota sobre los formatos de datos CSV: las filas en blanco en las columnas de CSV pueden demostrar distintos comportamientos.

- Si una columna es del tipo `String`, la fila en blanco se reconocerá como una cadena vacía y no fallará la regla `Completeness`.
- Si una columna es de otro tipo de dato, como `Int`, la fila en blanco se reconocerá como `NULL` y fallará la regla `Completeness`.

IsPrimaryKey

Comprueba si una columna contiene una clave principal. Una columna contiene una clave principal si todos los valores de la columna son únicos y completos (no nulos). También puede comprobar las claves principales con varias columnas.

Sintaxis

```
IsPrimaryKey <COL_NAME>
```

- COL_NAME: el nombre de la columna con la que quiere evaluar la regla de la calidad de los datos.

  Tipos de columnas compatibles: cualquier tipo de columna

Ejemplo: clave principal

La siguiente regla de ejemplo comprueba si la columna denominada `Customer_ID` contiene una clave principal.

```
IsPrimaryKey "Customer_ID"
IsPrimaryKey "Customer_ID" where "Customer_ID < 10"
```

Ejemplo: clave principal con múltiples columnas. Cualquiera de los ejemplos siguientes son válidos.

```
IsPrimaryKey "colA" "colB"
IsPrimaryKey "colA" "colB" "colC"
IsPrimaryKey colA "colB" "colC"
```

IsUnique

Comprueba si todos los valores de una columna son únicos y devuelve un valor booleano.

Sintaxis

```
IsUnique <COL_NAME>
```

- COL_NAME: el nombre de la columna con la que quiere evaluar la regla de la calidad de los datos.

  Tipos de columnas compatibles: cualquier tipo de columna

Ejemplos

La siguiente regla de ejemplo comprueba si todos los valores de una columna denominada `email` son únicos.

```
IsUnique "email"
IsUnique "Customer_ID" where "Customer_ID < 10"]
```

La siguiente regla de ejemplo verifica varias columnas.

```
IsUnique "vendorid" "tpep_pickup_datetime"
```

Media

Comprueba si la media (promedio) de todos los valores de una columna coincide con una expresión dada.

Sintaxis

```
Mean <COL_NAME> <EXPRESSION>
```

- COL_NAME: el nombre de la columna con la que quiere evaluar la regla de la calidad de los datos.

  Tipos de columnas compatibles: byte, decimal, doble, flotante, entero, largo, corto
- EXPRESSION: una expresión que se ejecuta en función de la respuesta del tipo de regla para producir un valor booleano. Para obtener más información, consulte Expresiones.

Ejemplo: valor promedio

La siguiente regla de ejemplo comprueba si el promedio de todos los valores de una columna supera un umbral.

```
Mean "Star_Rating" > 3
Mean "Salary" < 6200 where "Customer_ID < 10"
```

Muestra de reglas dinámicas

- `Mean "colA" > avg(last(10)) + std(last(2))`

- `Mean "colA" between min(last(5)) - 1 and max(last(5)) + 1`

Comportamiento nulo

La regla `Mean` ignorará las filas con valores `NULL` al momento de calcular la media. Por ejemplo:

```
+---+-----------+
|id |units      |
+---+-----------+
|100|0          |
|101|null       |
|102|20         |
|103|null       |
|104|40         |
+---+-----------+
```

La media de la columna `units` será (0 + 20 + 40) / 3 = 20. Las filas 101 y 103 no se tienen en cuenta para este cálculo.

ReferentialIntegrity

Comprueba en qué medida los valores de un conjunto de columnas en el conjunto de datos principal son un subconjunto de los valores de un conjunto de columnas en un conjunto de datos de referencia.

Sintaxis

```
ReferentialIntegrity <PRIMARY_COLS> <REFERENCE_DATASET_COLS> <EXPRESSION>
```

- PRIMARY_COLS: una lista de nombres de columnas separados por comas en el conjunto de datos principal.

  Tipos de columnas compatibles: byte, decimal, doble, flotante, entero, largo, corto
- REFERENCE_DATASET_COLS: este parámetro contiene dos partes separadas por un punto. La primera parte es el alias del conjunto de datos de referencia. La segunda parte es la lista de nombres de columnas separados por comas en el conjunto de datos de referencia entre corchetes.

  Tipos de columnas compatibles: byte, decimal, doble, flotante, entero, largo, corto
- EXPRESSION: una expresión que se ejecuta en función de la respuesta del tipo de regla para producir un valor booleano. Para obtener más información, consulte Expresiones.

Ejemplo: compruebe la integridad referencial de una columna de código postal

La siguiente regla de ejemplo comprueba que más del 90 % de los valores en la columna `zipcode` en el conjunto de datos principal estén presentes en la columna `zipcode` en el conjunto de datos de `reference`.

```
ReferentialIntegrity "zipcode" "reference.zipcode" >= 0.9
```

Ejemplo: compruebe la integridad referencial de las columnas de ciudad y estado

En el siguiente ejemplo, las columnas que contienen información sobre la ciudad y el estado existen en el conjunto de datos principal y en el conjunto de datos de referencia. Los nombres de las columnas son diferentes en ambos conjuntos de datos. La regla comprueba si el conjunto de valores de las columnas en el conjunto de datos principal es exactamente igual al conjunto de valores de las columnas en el conjunto de datos de referencia.

```
ReferentialIntegrity "city,state" "reference.{ref_city,ref_state}" = 1.0
```

Muestra de reglas dinámicas

- `ReferentialIntegrity "city,state" "reference.{ref_city,ref_state}" > avg(last(10))`
- `ReferentialIntegrity "city,state" "reference.{ref_city,ref_state}" between min(last(10)) - 1 and max(last(10)) + 1`

RowCount

Compara el recuento de filas de un conjunto de datos con una expresión determinada. En la expresión, puede indicar el número de filas o un rango de filas mediante operadores como > y <.

Sintaxis

```
RowCount <EXPRESSION>
```

- EXPRESSION: una expresión que se ejecuta en función de la respuesta del tipo de regla para producir un valor booleano. Para obtener más información, consulte Expresiones.

Ejemplo: comprobación numérica del recuento de filas

La siguiente regla de ejemplo comprueba si el recuento de filas se encuentra dentro de un rango determinado.

```
RowCount between 10 and 100
RowCount between 1 and 50 where "Customer_ID < 10"
```

Muestra de reglas dinámicas

```
RowCount > avg(last(10)) *0.8
```

RowCountMatch

Comprueba la relación entre el recuento de filas del conjunto de datos principal y el recuento de filas de un conjunto de datos de referencia con respecto a la expresión dada.

Sintaxis

```
RowCountMatch <REFERENCE_DATASET_ALIAS> <EXPRESSION>
```

- REFERENCE_DATASET_ALIAS: el alias del conjunto de datos de referencia con el que se comparan los recuentos de filas.

  Tipos de columnas compatibles: byte, decimal, doble, flotante, entero, largo, corto
- EXPRESSION: una expresión que se ejecuta en función de la respuesta del tipo de regla para producir un valor booleano. Para obtener más información, consulte Expresiones.

Ejemplo: comparación del recuento de filas con un conjunto de datos de referencia

La siguiente regla de ejemplo comprueba si el recuento de filas del conjunto de datos principal es al menos el 90 % del recuento de filas del conjunto de datos de referencia.

```
RowCountMatch "reference" >= 0.9
```

StandardDeviation

Comprueba la desviación estándar de todos los valores de una columna con respecto a una expresión determinada.

Sintaxis

```
StandardDeviation <COL_NAME> <EXPRESSION>
```

- COL_NAME: el nombre de la columna con la que quiere evaluar la regla de la calidad de los datos.

  Tipos de columnas compatibles: byte, decimal, doble, flotante, entero, largo, corto
- EXPRESSION: una expresión que se ejecuta en función de la respuesta del tipo de regla para producir un valor booleano. Para obtener más información, consulte Expresiones.

Ejemplo: desviación estándar

La siguiente regla de ejemplo comprueba si la desviación estándar de los valores de una columna denominada `colA` es inferior a un valor especificado.

```
StandardDeviation "Star_Rating" < 1.5
StandardDeviation "Salary" < 3500 where "Customer_ID < 10"
```

Muestra de reglas dinámicas

- `StandardDeviation "colA" > avg(last(10) + 0.1`
- `StandardDeviation "colA" between min(last(10)) - 1 and max(last(10)) + 1`

Comportamiento nulo

La regla `StandardDeviation` ignorará las filas con valores `NULL` al momento de calcular la desviación estándar. Por ejemplo:

```
+---+-----------+-----------+
|id |units1     |units2     |
+---+-----------+-----------+
|100|0          |0          |
|101|null       |0          |
|102|20         |20         |
|103|null       |0          |
|104|40         |40         |
+---+-----------+-----------+
```

La desviación estándar de la columna `units1` no tendrá en cuenta las filas 101 y 103 y su resultado será 16.33. La desviación estándar de la columna `units2` dará como resultado 16.

Sum

Comprueba la suma de todos los valores de una columna con respecto a una expresión determinada.

Sintaxis

```
Sum <COL_NAME> <EXPRESSION>
```

- COL_NAME: el nombre de la columna con la que quiere evaluar la regla de la calidad de los datos.

  Tipos de columnas compatibles: byte, decimal, doble, flotante, entero, largo, corto
- EXPRESSION: una expresión que se ejecuta en función de la respuesta del tipo de regla para producir un valor booleano. Para obtener más información, consulte Expresiones.

Ejemplo: suma

La siguiente regla de ejemplo comprueba si la suma de todos los valores de una columna supera un umbral dado.

```
Sum "transaction_total" > 500000
Sum "Salary" < 55600 where "Customer_ID < 10"
```

Muestra de reglas dinámicas

- `Sum "ColA" > avg(last(10))`
- `Sum "colA" between min(last(10)) - 1 and max(last(10)) + 1`

Comportamiento nulo

La regla `Sum` ignorará las filas con valores `NULL` al momento de calcular la suma. Por ejemplo:

```
+---+-----------+
|id |units      |
+---+-----------+
|100|0          |
|101|null       |
|102|20         |
|103|null       |
```

```
|104|40         |
+---+-----------+
```

La suma de la columna `units` no considerará las filas 101 y 103 y su resultado será (0 + 20 + 40) = 60.

SchemaMatch

Comprueba si el esquema del conjunto de datos principal coincide con el esquema de un conjunto de datos de referencia. La verificación del esquema se realiza columna por columna. El esquema de dos columnas coincide si los nombres son idénticos y los tipos son idénticos. El orden de las columnas del archivo no importa.

Sintaxis

```
SchemaMatch <REFERENCE_DATASET_ALIAS> <EXPRESSION>
```

- REFERENCE_DATASET_ALIAS: el alias del conjunto de datos de referencia con el que se comparan los esquemas.

  Tipos de columnas compatibles: byte, decimal, doble, flotante, entero, largo, corto
- EXPRESSION: una expresión que se ejecuta en función de la respuesta del tipo de regla para producir un valor booleano. Para obtener más información, consulte Expresiones.

Ejemplo: SchemaMatch

La siguiente regla de ejemplo comprueba si el esquema del conjunto de datos principal coincide exactamente con el esquema de un conjunto de datos de referencia.

```
SchemaMatch "reference" = 1.0
```

Singularidad

Comprueba el porcentaje de valores únicos de una columna con respecto a una expresión determinada. Los valores únicos aparecen exactamente una vez.

Sintaxis

```
Uniqueness <COL_NAME> <EXPRESSION>
```

- COL_NAME: el nombre de la columna con la que quiere evaluar la regla de la calidad de los datos.

  Tipos de columnas compatibles: cualquier tipo de columna
- EXPRESSION: una expresión que se ejecuta en función de la respuesta del tipo de regla para producir un valor booleano. Para obtener más información, consulte Expresiones.

Ejemplo

La siguiente regla de ejemplo comprueba si el porcentaje de valores únicos de una columna coincide con ciertos criterios numéricos.

```
Uniqueness "email" = 1.0
Uniqueness "Customer_ID" != 1.0 where "Customer_ID < 10"
```

La siguiente regla de ejemplo verifica varias columnas.

```
Uniqueness "vendorid" "tpep_pickup_datetime" = 1
```

Muestra de reglas dinámicas

- `Uniqueness "colA" between min(last(10)) and max(last(10))`
- `Uniqueness "colA" >= avg(last(10))`

UniqueValueRatio

Comprueba la relación de valores únicos de una columna con respecto a una expresión determinada. Una relación de valores únicos es la fracción de valores únicos dividida entre el número de todos los valores distintos de una columna. Los valores únicos aparecen exactamente una vez, mientras que los valores distintos aparecen al menos una vez.

Por ejemplo, el conjunto `[a, a, b]` contiene un valor único (b) y dos valores distintos (a y b). Por lo tanto, la relación de valores únicos del conjunto es ½ = 0,5.

Sintaxis

```
UniqueValueRatio <COL_NAME> <EXPRESSION>
```

- COL_NAME: el nombre de la columna con la que quiere evaluar la regla de la calidad de los datos.

  Tipos de columnas compatibles: cualquier tipo de columna
- EXPRESSION: una expresión que se ejecuta en función de la respuesta del tipo de regla para producir un valor booleano. Para obtener más información, consulte Expresiones.

Ejemplo: relación de valores únicos

En este ejemplo, se comprueba la relación de valores única de una columna frente a un rango de valores.

```
UniqueValueRatio "test_score" between 0 and 0.5
UniqueValueRatio "Customer_ID" between 0 and 0.9 where "Customer_ID < 10"
```

Muestra de reglas dinámicas

- `UniqueValueRatio "colA" > avg(last(10))`
- `UniqueValueRatio "colA" <= index(last(10),2) + std(last(5))`

DetectAnomalies

Detecta anomalías en una regla de calidad de datos determinada. Cada ejecución de la regla DetectAnomalies permite guardar el valor evaluado de la regla dada. Al recopilar suficientes datos, el algoritmo de detección de anomalías toma todos los datos históricos de esa regla determinada y ejecuta la detección de anomalías. La regla DetectAnomalies falla al momento de detectar una anomalía. Puede obtener más información sobre qué anomalía se detectó en Observaciones.

Sintaxis

```
DetectAnomalies <RULE_NAME> <RULE_PARAMETERS>
```

`RULE_NAME`: nombre de la regla que quiere evaluar y detectar anomalías. Reglas admitidas:

- “RowCount”
- “Completeness”
- “Uniqueness”

- “Mean”
- “Sum”
- “StandardDeviation”
- “Entropy”
- “DistinctValuesCount”
- “UniqueValueRatio”
- “ColumnLength”
- “ColumnValues”
- “ColumnCorrelation”
- "CustomSQL"
- "ColumnCount"

`RULE_PARAMETERS`: algunas reglas requieren parámetros adicionales para poder ejecutarse. Consulte la documentación de reglas dada para ver los parámetros necesarios.

Ejemplo: Anomalías de RowCount

Por ejemplo, si queremos detectar anomalías en RowCount, damos RowCount como nombre de regla.

```
DetectAnomalies "RowCount"
```

Ejemplo: Anomalías para ColumnLength

Por ejemplo, si queremos detectar anomalías en la longitud de la columna, daremos la longitud de columna como nombre de la regla y el nombre de la columna.

```
DetectAnomalies "ColumnLength" "id"
```

FileFreshness

FileFreshness garantiza que sus archivos de datos estén actualizados en función de la condición que proporcione. Utiliza la hora de la última modificación de los archivos para garantizar que los archivos de datos o toda la carpeta estén actualizados.

Esta regla recopila dos métricas:

- El cumplimiento de FileFreshness se basa en la regla que haya configurado
- El número de archivos que ha analizado la regla

```
{"Dataset.*.FileFreshness.Compliance":1,"Dataset.*.FileCount":1}
```

La detección de anomalías no tiene en cuenta estas métricas.

Cómo comprobar si los archivos están actualizados

La siguiente regla garantiza que tickets.parquet se haya creado en las últimas 24 horas.

```
FileFreshness "s3://amzn-s3-demo-bucket/artifacts/file/tickets/tickets.parquet" >
 (now() - 24 hours)
```

Cómo comprobar si la carpeta está actualizada

La siguiente regla se aplica si todos los archivos de la carpeta se crearon o modificaron en las últimas 24 horas.

```
FileFreshness "s3://bucket/" >= (now() -1 days)
FileFreshness "s3://amzn-s3-demo-bucket/artifacts/file/tickets/" >= (now() - 24 hours)
```

Cómo comprobar si una carpeta o un archivo está actualizado (con umbral)

La siguiente regla se aplica si el 10 % de los archivos de la carpeta “tickets” se crearon o modificaron en los últimos 10 días.

```
FileFreshness "s3://amzn-s3-demo-bucket/artifacts/file/tickets/" < (now() - 10 days)
 with threshold > 0.1
```

Cómo comprobar archivos o carpetas con fechas específicas

Puede comprobar si los archivos se actualizaron en días específicos.

```
FileFreshness "s3://amzn-s3-demo-bucket/artifacts/file/tickets/" > "2020-01-01"
FileFreshness "s3://amzn-s3-demo-bucket/artifacts/file/tickets/" between "2023-01-01"
 and "2024-01-01"
```

Cómo comprobar archivos o carpetas con fechas y horas

Puede usar FileFreshness para asegurarse de que los archivos lleguen dentro de las horas previstas.

```
FileFreshness "s3://amzn-s3-demo-bucket/artifacts/file/tickets/" between now() and
 (now() - 45 minutes)
FileFreshness "s3://amzn-s3-demo-bucket/artifacts/file/tickets/" between "9:30 AM" and
 "9:30 PM"
FileFreshness "s3://amzn-s3-demo-bucket/artifacts/file/tickets/" > (now() - 10 minutes)
FileFreshness "s3://amzn-s3-demo-bucket/artifacts/file/tickets/" > now()
FileFreshness "s3://amzn-s3-demo-bucket/artifacts/file/tickets/" between (now() - 2
 hours) and (now() + 15 minutes)
FileFreshness "s3://amzn-s3-demo-bucket/artifacts/file/tickets/" between (now() - 3
 days) and (now() + 15 minutes)
FileFreshness "s3://amzn-s3-demo-bucket/artifacts/file/tickets/" between "2001-02-07"
 and (now() + 15 minutes)
FileFreshness "s3://amzn-s3-demo-bucket/artifacts/file/tickets/" > "21:45""
FileFreshness "s3://amzn-s3-demo-bucket/artifacts/file/tickets/" > "2024-01-01"
FileFreshness "s3://amzn-s3-demo-bucket/artifacts/file/tickets/" between "02:30" and
 "04:30"
FileFreshness "s3://amzn-s3-demo-bucket/artifacts/file/tickets/" between "9:30 AM" and
 "22:15"
```

Consideraciones clave:

- FileFreshness puede evaluar los archivos utilizando unidades de días, horas y minutos
- Es compatible con los formatos de tiempo AM/PM y 24 horas
- Los horarios se calculan en UTC, a menos que se especifique una anulación
- Las fechas se calculan en UTC a las 00:00 h

El análisis de FileFreshness basado en la fecha y la hora funciona de la siguiente manera:

```
FileFreshness "s3://amzn-s3-demo-bucket/artifacts/file/tickets/" > "21:45"
```

- En primer lugar, la hora “21:45” se combina con la fecha de hoy en formato UTC para crear un campo de fecha y hora
- A continuación, la fecha y la hora se convierten en la zona horaria que haya especificado
- Por último, se evalúa la regla

Etiquetas de reglas opcionales basadas en archivos:

Las etiquetas permiten controlar el comportamiento de las reglas.

recentFiles

Esta etiqueta limita el número de archivos procesados dejando primero el archivo más reciente.

```
FileFreshness "s3://amzn-s3-demo-bucket/" between (now() - 100 minutes) and (now() + 10
 minutes) with recentFiles = 1
```

timeZone

Indica las anulaciones de zonas horaria aceptadas; consulte Allowed Time Zones para ver las zonas horarias admitidas.

```
FileFreshness "s3://path/" > "21:45" with timeZone = "America/New_York"
```

```
FileFreshness "s3://path/" > "21:45" with timeZone = "America/Chicago"
```

```
FileFreshness "s3://path/" > "21:45" with timeZone = "Europe/Paris"
```

```
FileFreshness "s3://path/" > "21:45" with timeZone = "Asia/Shanghai"
```

```
FileFreshness "s3://path/" > "21:45" with timeZone = "Australia/Darwin"
```

Cómo inferir los nombres de los archivos directamente de los marcos de datos

No siempre tiene que proporcionar una ruta de archivo. Por ejemplo, al crear la regla en el catálogo de datos de AWS Glue, puede resultar difícil encontrar qué carpetas usan las tablas del catálogo. AWS Calidad de datos de Glue puede encontrar las carpetas o archivos específicos que se usan para rellenar su marco de datos y puede detectar si están actualizados.

> **Note**
>
> Esta característica solo funcionará cuando los archivos se lean correctamente en DynamicFrame o DataFrame.

```
FileFreshness > (now() - 24 hours)
```

Esta regla encontrará la ruta de la carpeta o los archivos que se usan para rellenar el marco dinámico o el marco de datos. Esto funciona para las rutas de Amazon S3 o las tablas de Catálogo de datos de AWS Glue basadas en Amazon S3. Existen algunas consideraciones:

1. En la ETL de AWS Glue, debe tener la transformación EvaluateDataQuality inmediatamente después de una transformación de Amazon S3 o del Catálogo de datos de AWS Glue.

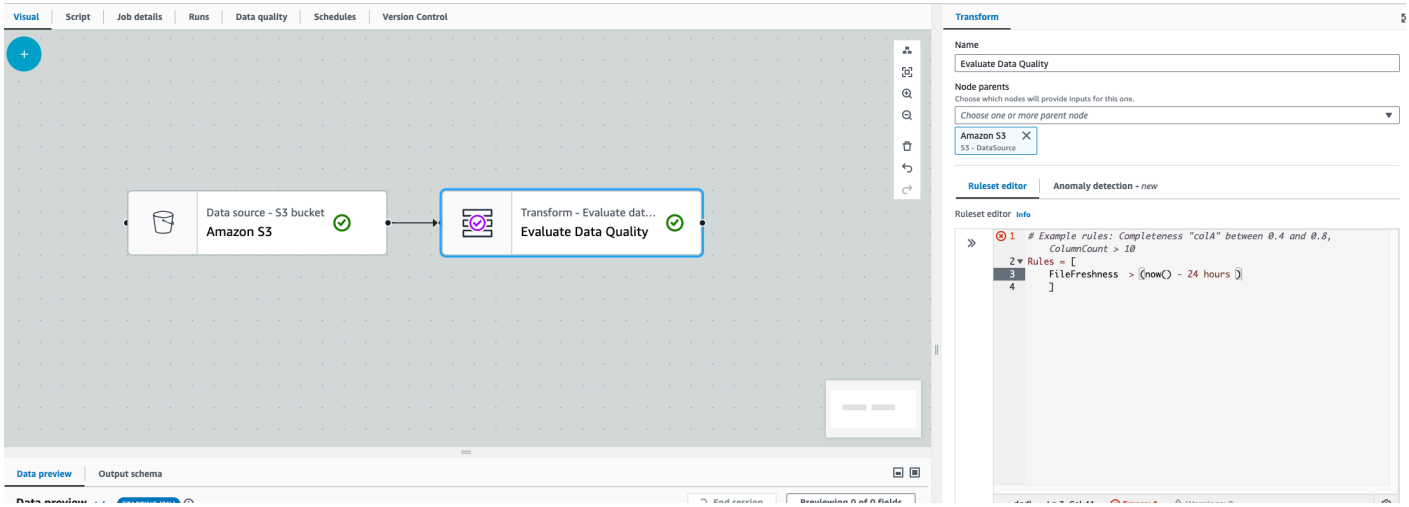

2. Esta regla no funcionará en las sesiones interactivas de AWS Glue.

Si lo intenta en ambos casos, o si AWS Glue no encuentra los archivos, AWS Glue devolverá el siguiente error: “`Unable to parse file path from DataFrame`”

FileMatch

La regla FileMatch le permite comparar archivos con otros archivos o sumas de comprobación. Esto puede ser útil en algunas situaciones:

1. Validación de archivos recibidos de fuentes externas: puede usar FileMatch para asegurarse de que haya recibido los archivos correctos de orígenes externos mediante su comparación con sumas de comprobación. Esto ayuda a validar la integridad de los datos que está ingiriendo.
2. Comparación de datos en dos carpetas diferentes: FileMatch se puede utilizar para comparar archivos entre dos carpetas.

Esta regla recopila una métrica: el número de archivos que ha analizado la regla.

```
{"Dataset.*.FileCount":1}
```

Validación de un archivo con una suma de comprobación:

FileMatch acepta un archivo y un conjunto de sumas de comprobación para garantizar que al menos una suma de comprobación coincida con el archivo.

```
FileMatch "s3://amzn-s3-demo-bucket/file.json" in ["3ee0d8617ac041793154713e5ef8f319"]
 with hashAlgorithm = "MD5"
FileMatch "s3://amzn-s3-demo-bucket/file.json" in ["3ee0d8617ac041793154713e5ef8f319"]
 with hashAlgorithm = "SHA-1"
FileMatch "s3://amzn-s3-demo-bucket/file.json" in ["3ee0d8617ac041793154713e5ef8f319"]
 with hashAlgorithm = "SHA-256"
FileMatch "s3://amzn-s3-demo-bucket/file.json" in ["3ee0d8617ac041793154713e5ef8f319"]
```

Los siguientes algoritmos estándar son compatibles:

- MD5
- SHA-1
- SHA-256

Si no proporciona ningún algoritmo, el valor predeterminado es SHA-256.

Validación de todos los archivos de una carpeta con el conjunto de sumas de comprobación:

```
FileMatch "s3://amzn-s3-demo-bucket /" in ["3ee0d8617ac041793154713e5ef8f319",
 "7e8617ac041793154713e5ef8f319"] with hashAlgorithm = "MD5"
FileMatch "s3://amzn-s3-demo-bucket /internal-folder/" in
 ["3ee0d8617ac041793154713e5ef8f319", "7e8617ac041793154713e5ef8f319"]
```

Comparación de archivos en diferentes carpetas

```
FileMatch "s3://original_bucket/" "s3://archive_bucket/"
FileMatch "s3://original_bucket/internal-folder/" "s3://original_bucket/other-folder/"
```

FileMatch comprobará el contenido de los archivos en `original_bucket` y se asegurará de que coincidan con lo que contiene `archive_bucket`. La regla fallará si no coinciden exactamente. También puede comprobar el contenido de las carpetas internas o de los archivos individuales.

FileMatch también puede comparar archivos individuales entre sí.

```
FileMatch "s3://amzn-s3-demo-bucket /file_old.json" "s3://amzn-s3-demo-bucket /
file_new.json"
```

Cómo inferir los nombres de los archivos directamente de los marcos de datos

No siempre tiene que proporcionar una ruta de archivo. Por ejemplo, al crear la regla en el Catálogo de datos de AWS Glue (respaldado por Amazon S3), puede resultar difícil encontrar qué carpetas usan las tablas del catálogo. AWS Calidad de datos de Glue puede encontrar las carpetas o archivos específicos que se usan para rellenar su marco de datos.

> **Note**
>
> Esta característica solo funcionará cuando los archivos se lean correctamente en DynamicFrame o DataFrame.

```
FileMatch in ["3ee0d8617ac041793154713e5ef8f319"] with hashAlgorithm = "MD5"
FileMatch in ["3ee0d8617ac041793154713e5ef8f319"] with hashAlgorithm = "SHA-1"
FileMatch in ["3ee0d8617ac041793154713e5ef8f319"] with hashAlgorithm = "SHA-256"
FileMatch in ["3ee0d8617ac041793154713e5ef8f319"]
```

Si la suma de comprobación proporcionada es diferente de la calculada, FileMatch le avisará de la diferencia.

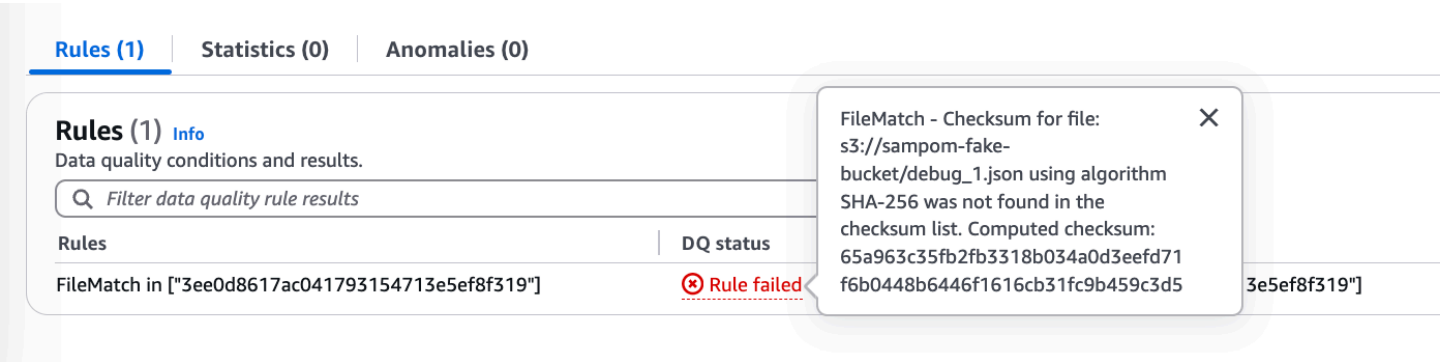

Etiquetas de reglas opcionales basadas en archivos:

Las etiquetas permiten controlar el comportamiento de las reglas.

recentFiles

Esta etiqueta limita el número de archivos procesados dejando primero el archivo más reciente.

```
FileMatch "s3://amzn-s3-demo-bucket/file.json" in ["3ee0d8617ac04179sam4713e5ef8f319"]
 with recentFiles = 1
```

matchFileName

Esta etiqueta garantiza que los archivos no tengan nombres duplicados. El comportamiento predeterminado es false.

```
FileMatch "s3://amzn-s3-demo-bucket/file.json" in ["3ee0d8617ac04179sam4713e5ef8f319"]
 with matchFileName = "true"
```

Existen algunas consideraciones:

1. En la ETL de AWS Glue, debe tener la transformación EvaluateDataQuality inmediatamente después de una transformación de Amazon S3 o del Catálogo de datos de AWS Glue.

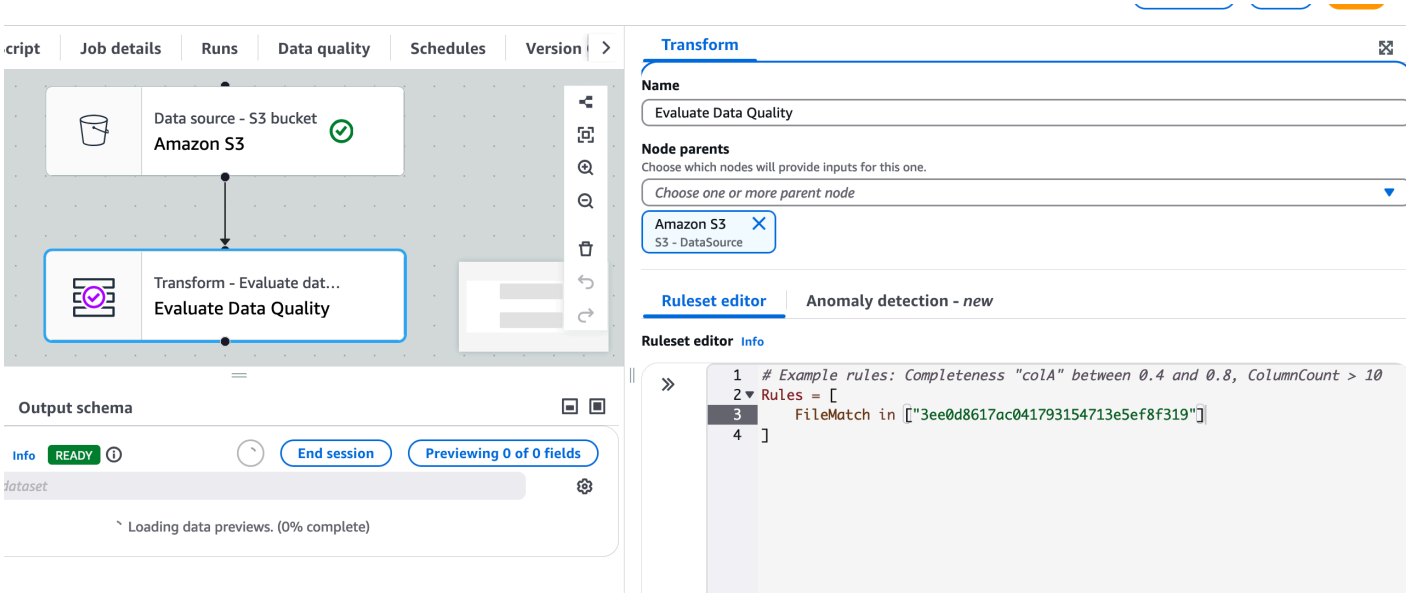

2. Esta regla no funcionará en las sesiones interactivas de AWS Glue.

FileUniqueness

FileUniqueness permite asegurarse de que no haya archivos duplicados en los datos que ha recibido de sus productores de datos.

Recopila las siguientes estadísticas de datos:

1. El número de archivos que ha analizado la regla

2. La relación de singularidad de los archivos

```
Dataset.*.FileUniquenessRatio: 1.00, Dataset.*.FileCount: 8.00
```

Cómo encontrar archivos duplicados en una carpeta:

```
FileUniqueness "s3://bucket/" > 0.5
FileUniqueness "s3://bucket/folder/" = 1
```

Cómo inferir los nombres de las carpetas directamente de los marcos de datos para detectar duplicados:

No siempre tiene que proporcionar una ruta de archivo. Por ejemplo, al crear la regla en el catálogo de datos de AWS Glue, puede resultar difícil encontrar qué carpetas usan las tablas del catálogo. AWS Calidad de datos de Glue puede encontrar las carpetas o archivos específicos que se usan para rellenar su marco de datos.

> **Note**
>
> Cuando se utiliza la inferencia, las reglas basadas en archivos solo pueden detectar los archivos leídos correctamente en DynamicFrame o DataFrame.

```
FileUniqueness > 0.5
```

Etiquetas de reglas opcionales basadas en archivos:

Las etiquetas permiten controlar el comportamiento de las reglas.

recentFiles

Esta etiqueta limita el número de archivos procesados dejando primero el archivo más reciente.

```
FileUniqueness "s3://amzn-s3-demo-bucket/" > 0.5 with recentFiles = 1
```

matchFileName

Esta etiqueta garantiza que los archivos no tengan nombres duplicados. El comportamiento predeterminado es false.

```
FileUniqueness "s3://amzn-s3-demo-bucket/" > 0.5 with matchFileName = "true"
```

Existen algunas consideraciones:

1. En la ETL de AWS Glue, debe tener la transformación EvaluateDataQuality inmediatamente después de una transformación de Amazon S3 o del Catálogo de datos de AWS Glue.
2. Esta regla no funcionará en las sesiones interactivas de AWS Glue.

FileSize

El tipo de regla FileSize le permite asegurarse de que los archivos cumplan ciertos criterios de tamaño de archivo. Esto resulta útil para los siguientes casos de uso:

1. Asegurarse de que los productores no envíen archivos vacíos o sustancialmente más pequeños para su procesamiento.
2. Asegurarse de que sus buckets de destino no tengan archivos más pequeños, lo que podría provocar problemas de rendimiento.

FileSize recopila las siguientes métricas:

1. Conformidad: devuelve el porcentaje (%) de archivos que cumplen el umbral de la regla que ha establecido
2. Recuento de archivos: el número de archivos que ha analizado la regla
3. Tamaño mínimo de archivo en bytes
4. Tamaño máximo de archivo en bytes

```
Dataset.*.FileSize.Compliance: 1.00,
Dataset.*.FileCount: 8.00,
Dataset.*.MaximumFileSize: 327413121.00,
Dataset.*.MinimumFileSize: 204558920.00
```

Estas métricas no admiten la detección de anomalías.

Validación del tamaño de los archivos

Esta regla se aplicará cuando el archivo file.dat ocupe más de 2 MB.

```
FileSize "s3://amzn-s3-demo-bucket/file.dat" > 2 MB
```

Las unidades compatibles incluyen B (bytes), MB (megabytes), GB (gigabytes) y TB (terabytes).

Validación del tamaño de los archivos en las carpetas

```
FileSize "s3://bucket/" > 5 B
FileSize "s3://bucket/" < 2 GB
```

Esta regla se aplicará si el 70 % de los archivos de s3://amzn-s3-demo-bucket tienen entre 2 GB y 1 TB.

```
FileSize "s3://amzn-s3-demo-bucket/" between 2 GB and 1 TB  with threshold > 0.7
```

Cómo inferir los nombres de los archivos directamente de los marcos de datos

No siempre tiene que proporcionar una ruta de archivo. Por ejemplo, al crear la regla en el Catálogo de datos, puede resultar difícil encontrar qué carpetas usan las tablas del catálogo. AWS Calidad de datos de Glue puede encontrar las carpetas o archivos específicos que se usan para rellenar su marco de datos.

> **Note**
>
> Esta característica solo funcionará cuando los archivos se lean correctamente en DynamicFrame o DataFrame.

```
FileSize < 10 MB with threshold > 0.7
```

Etiquetas de reglas opcionales basadas en archivos:

Las etiquetas permiten controlar el comportamiento de las reglas.

recentFiles

Esta etiqueta limita el número de archivos procesados dejando primero el archivo más reciente.

```
FileSize "s3://amzn-s3-demo-bucket/" > 5 B with recentFiles = 1
```

matchFileName

Esta etiqueta garantiza que los archivos no tengan nombres duplicados. El comportamiento predeterminado es false.

```
FileSize "s3://amzn-s3-demo-bucket/" > 5 B with matchFileName = "true"
```

Existen algunas consideraciones:

1. En la ETL de AWS Glue, debe tener la transformación EvaluateDataQuality inmediatamente después de una transformación de Amazon S3 o del Catálogo de datos.
2. Esta regla no funcionará en las sesiones interactivas de AWS Glue.

Uso de las API para medir y gestionar la calidad de los datos

En este tema, se describe cómo utilizar las API para medir y gestionar la calidad de los datos.

Contenido

- Requisitos previos
- Cómo trabajar con las recomendaciones de Calidad de datos de AWS Glue
- Trabajar con los conjuntos de reglas de Calidad de datos de AWS Glue
- Cómo trabajar con ejecuciones de Calidad de datos de AWS Glue
- Cómo trabajar con los resultados de Calidad de datos de AWS Glue

Requisitos previos

- Asegúrese de que su versión de boto3 esté actualizada para que incluya la última API de Calidad de datos de AWS Glue.
- Asegúrese de que la versión de AWS CLI esté actualizada para incluir la CLI más reciente.

Si utiliza un trabajo de AWS Glue para ejecutar estas API, puede usar la siguiente opción para actualizar la biblioteca boto3 a la última versión:

```
–additional-python-modules boto3==<version>
```

Cómo trabajar con las recomendaciones de Calidad de datos de AWS Glue

Para iniciar una recomendación de Calidad de datos de AWS Glue, ejecute lo siguiente:

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""
    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 AWS Glue client.
        """
        self.glue_client = glue_client

    def start_data_quality_rule_recommendation_run(self, database_name, table_name,
 role_arn):
        """
        Starts a recommendation run that is used to generate rules when you don't know
 what rules to write. AWS Glue Data Quality
        analyzes the data and comes up with recommendations for a potential ruleset.
 You can then triage the ruleset
        and modify the generated ruleset to your liking.

        :param database_name: The name of the AWS Glue database which contains the
 dataset.
        :param table_name: The name of the AWS Glue table against which we want a
 recommendation
        :param role_arn: The Amazon Resource Name (ARN) of an AWS Identity and Access
 Management (IAM) role that grants permission to let AWS Glue access the resources it
 needs.

        """
        try:
            response = self.client.start_data_quality_rule_recommendation_run(
                DataSource={
                    'GlueTable': {
                        'DatabaseName': database_name,
                        'TableName': table_name
                    }
                },
                Role=role_arn
            )
        except ClientError as err:
```

```
            logger.error(
                "Couldn't start data quality recommendation run %s. Here's why: %s:
 %s", name,
                err.response['Error']['Code'], err.response['Error']['Message'])
            raise
        else:
            return response['RunId']
```

Para una ejecución de recomendaciones, puede utilizar sus recomendaciones `pushDownPredicates` o `catalogPartitionPredicates` para mejorar el rendimiento y ejecutar las recomendaciones solo en particiones específicas de los orígenes de su catálogo.

```
client.start_data_quality_rule_recommendation_run(
            DataSource={
                'GlueTable': {
                    'DatabaseName': database_name,
                    'TableName': table_name,
                    'AdditionalOptions': {
                        'pushDownPredicate': "year=2022"
                    }
                }
            },
            Role=role_arn,
            NumberOfWorkers=2,
            CreatedRulesetName='<rule_set_name>'
  )
```

Para obtener los resultados de una recomendación de Calidad de datos de AWS Glue, ejecute:

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""
    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 AWS Glue client.
        """
        self.glue_client = glue_client

    def get_data_quality_rule_recommendation_run(self, run_id):
        """
        Gets the specified recommendation run that was used to generate rules.

        :param run_id: The id of the data quality recommendation run
```

```
        """
        try:
            response =
 self.client.get_data_quality_rule_recommendation_run(RunId=run_id)
        except ClientError as err:
            logger.error(
                "Couldn't get data quality recommendation run %. Here's why: %s: %s",
 run_id,
                err.response['Error']['Code'], err.response['Error']['Message'])
            raise
        else:
            return response
```

Del objeto de respuesta anterior, puede extraer el conjunto de reglas recomendado por la ejecución para usarlo en los siguientes pasos:

```
print(response['RecommendedRuleset'])

Rules = [
    RowCount between 2000 and 8000,
    IsComplete "col1",
    IsComplete "col2",
    StandardDeviation "col3" between 58138330.8 and 64258155.09,
    ColumnValues "col4" between 1000042965 and 1214474826,
    IsComplete "col5"
]
```

Para obtener una lista de todas las ejecuciones de recomendación que se puedan filtrar y enumerar:

```
response = client.list_data_quality_rule_recommendation_runs(
    Filter={
        'DataSource': {
            'GlueTable': {
                'DatabaseName': '<database_name>',
                'TableName': '<table_name>'
            }
        }
)
```

Para cancelar las tareas de recomendación de Calidad de datos de AWS Glue existentes:

```
response = client.cancel_data_quality_rule_recommendation_run(
```

```
    RunId='dqrun-d4b6b01957fdd79e59866365bf9cb0e40fxxxxxxx'
)
```

Trabajar con los conjuntos de reglas de Calidad de datos de AWS Glue

Para crear un conjunto de reglas de Calidad de datos de AWS Glue:

```
response = client.create_data_quality_ruleset(
    Name='<ruleset_name>',
    Ruleset='Rules = [IsComplete "col1", IsPrimaryKey "col2", RowCount between 2000 and
 8000]',
    TargetTable={
        'TableName': '<table_name>',
        'DatabaseName': '<database_name>'
    }
)
```

Para obtener un conjunto de reglas de calidad de datos:

```
response = client.get_data_quality_ruleset(
    Name='<ruleset_name>'
)
print(response)
```

Puede utilizar esta API para, a continuación, extraer el conjunto de reglas:

```
print(response['Ruleset'])
```

Para enumerar todos los conjuntos de reglas de calidad de datos de una tabla:

```
response = client.list_data_quality_rulesets()
```

Puedes usar la condición de filtro de la API para filtrar todos los conjuntos de reglas adjuntos a una base de datos o tabla específica:

```
response = client.list_data_quality_rulesets(
    Filter={
        'TargetTable': {
            'TableName': '<table_name>',
            'DatabaseName': '<database_name>'
        }
```

```
    },
)
```

Para actualizar un conjunto de reglas de calidad de datos:

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""
    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 AWS Glue client.
        """
        self.glue_client = glue_client

    def update_data_quality_ruleset(self, ruleset_name, ruleset_string):
        """
        Update an AWS Glue Data Quality Ruleset

        :param ruleset_name: The name of the AWS Glue Data Quality ruleset to update
        :param ruleset_string: The DQDL ruleset string to update the ruleset with

        """
        try:
            response = self.client.update_data_quality_ruleset(
                Name=ruleset_name,
                Ruleset=ruleset_string
            )
        except ClientError as err:
            logger.error(
                "Couldn't update the AWS Glue Data Quality ruleset. Here's why: %s:
 %s",
                err.response['Error']['Code'], err.response['Error']['Message'])
            raise
        else:
            return response
```

Para eliminar un conjunto de reglas de la calidad de los datos:

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""
    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 AWS Glue client.
        """
```

```
        self.glue_client = glue_client

    def delete_data_quality_ruleset(self, ruleset_name):
        """
        Delete a AWS Glue Data Quality Ruleset

        :param ruleset_name: The name of the AWS Glue Data Quality ruleset to delete

        """
        try:
            response = self.client.delete_data_quality_ruleset(
                Name=ruleset_name
            )
        except ClientError as err:
            logger.error(
                "Couldn't delete the AWS Glue Data Quality ruleset. Here's why: %s:
%s",
                err.response['Error']['Code'], err.response['Error']['Message'])
            raise
        else:
            return response
```

Cómo trabajar con ejecuciones de Calidad de datos de AWS Glue

Para iniciar una ejecución de Calidad de datos de AWS Glue:

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""
    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 AWS Glue client.
        """
        self.glue_client = glue_client

    def start_data_quality_ruleset_evaluation_run(self, database_name, table_name,
 role_name, ruleset_list):
        """
        Start an AWS Glue Data Quality evaluation run

        :param database_name: The name of the AWS Glue database which contains the
 dataset.
        :param table_name: The name of the AWS Glue table against which we want to
 evaluate.
```

```
        :param role_arn: The Amazon Resource Name (ARN) of an AWS Identity and Access
    Management (IAM) role that grants permission to let AWS Glue access the resources it
    needs.
        :param ruleset_list: The list of AWS Glue Data Quality ruleset names to
    evaluate.

        """
        try:
            response = client.start_data_quality_ruleset_evaluation_run(
                DataSource={
                    'GlueTable': {
                        'DatabaseName': database_name,
                        'TableName': table_name
                    }
                },
                Role=role_name,
                RulesetNames=ruleset_list
            )
        except ClientError as err:
            logger.error(
                "Couldn't start the AWS Glue Data Quality Run. Here's why: %s: %s",
                err.response['Error']['Code'], err.response['Error']['Message'])
            raise
        else:
            return response['RunId']
```

Recuerde que puede pasar un parámetro `pushDownPredicate` o `catalogPartitionPredicate` para garantizar que la ejecución de calidad de los datos solo se dirija a un conjunto específico de particiones de la tabla de catálogo. Por ejemplo:

```
response = client.start_data_quality_ruleset_evaluation_run(
    DataSource={
        'GlueTable': {
            'DatabaseName': '<database_name>',
            'TableName': '<table_name>',
            'AdditionalOptions': {
                'pushDownPredicate': 'year=2023'
            }
        }
    },
    Role='<role_name>',
    NumberOfWorkers=5,
    Timeout=123,
```

```
    AdditionalRunOptions={
        'CloudWatchMetricsEnabled': False
    },
    RulesetNames=[
        '<ruleset_name>',
    ]
)
```

También puede configurar cómo se evalúan las reglas compuestas de su conjunto de reglas, ya sea en el nivel de la FILA o de la COLUMNA. Para obtener más información sobre cómo funcionan las reglas compuestas, consulte Cómo funcionan las reglas compuestas en la documentación.

Ejemplo de cómo configurar el método de evaluación de reglas compuestas en su solicitud:

```
response = client.start_data_quality_ruleset_evaluation_run(
    DataSource={
        'GlueTable': {
            'DatabaseName': '<database_name>',
            'TableName': '<table_name>',
            'AdditionalOptions': {
                'pushDownPredicate': 'year=2023'
            }
        }
    },
    Role='<role_name>',
    NumberOfWorkers=5,
    Timeout=123,
    AdditionalRunOptions={
        'CompositeRuleEvaluationMethod':ROW
    },
    RulesetNames=[
        '<ruleset_name>',
    ]
)
```

Para obtener información sobre una ejecución de Calidad de datos de AWS Glue:

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""
    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 AWS Glue client.
        """
```

```
        self.glue_client = glue_client

    def get_data_quality_ruleset_evaluation_run(self, run_id):
        """
        Get details about an AWS Glue Data Quality Run

        :param run_id: The AWS Glue Data Quality run ID to look up

        """
        try:
            response = self.client.get_data_quality_ruleset_evaluation_run(
                RunId=run_id
            )
        except ClientError as err:
            logger.error(
                "Couldn't look up the AWS Glue Data Quality run ID. Here's why: %s:
 %s",
                err.response['Error']['Code'], err.response['Error']['Message'])
            raise
        else:
            return response
```

Para obtener los resultados de una ejecución de Calidad de datos de AWS Glue:

Para una ejecución de Calidad de datos de AWS Glue determinada, puede extraer los resultados de la evaluación de la ejecución mediante el siguiente método:

```
response = client.get_data_quality_ruleset_evaluation_run(
    RunId='d4b6b01957fdd79e59866365bf9cb0e40fxxxxxxx'
)

resultID = response['ResultIds'][0]

response = client.get_data_quality_result(
    ResultId=resultID
)

print(response['RuleResults'])
```

Para ver una lista de todas sus ejecuciones de Calidad de datos de AWS Glue:

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""
```

```
    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 AWS Glue client.
        """
        self.glue_client = glue_client

    def list_data_quality_ruleset_evaluation_runs(self, database_name, table_name):
        """
        Lists all the AWS Glue Data Quality runs against a given table

        :param database_name: The name of the database where the data quality runs
        :param table_name: The name of the table against which the data quality runs
 were created

        """
        try:
            response = self.client.list_data_quality_ruleset_evaluation_runs(
                Filter={
                    'DataSource': {
                        'GlueTable': {
                            'DatabaseName': database_name,
                            'TableName': table_name
                        }
                    }
                }
            )
        except ClientError as err:
            logger.error(
                "Couldn't list the AWS Glue Quality runs. Here's why: %s: %s",
                err.response['Error']['Code'], err.response['Error']['Message'])
            raise
        else:
            return response
```

Puede modificar la cláusula de filtro para que solo muestre los resultados entre tiempos específicos o si se ejecutan en tablas específicas.

Para detener una ejecución continua de Calidad de datos de AWS Glue:

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""
    def __init__(self, glue_client):
        """
```

```
        :param glue_client: A Boto3 AWS Glue client.
        """
        self.glue_client = glue_client

    def cancel_data_quality_ruleset_evaluation_run(self, result_id):
        """
        Cancels a given AWS Glue Data Quality run

        :param result_id: The result id of a AWS Glue Data Quality run to cancel

        """
        try:
            response = self.client.cancel_data_quality_ruleset_evaluation_run(
                ResultId=result_id
            )
        except ClientError as err:
            logger.error(
                "Couldn't cancel the AWS Glue Data Quality run. Here's why: %s: %s",
                err.response['Error']['Code'], err.response['Error']['Message'])
            raise
        else:
            return response
```

Cómo trabajar con los resultados de Calidad de datos de AWS Glue

Para obtener los resultados de ejecución de Calidad de datos de AWS Glue:

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""
    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 AWS Glue client.
        """
        self.glue_client = glue_client

    def get_data_quality_result(self, result_id):
        """
        Outputs the result of an AWS Glue Data Quality Result

        :param result_id: The result id of an AWS Glue Data Quality run

        """
        try:
```

```
            response = self.client.get_data_quality_result(
                ResultId=result_id
            )
        except ClientError as err:
            logger.error(
                "Couldn't get the AWS Glue Data Quality result. Here's why: %s: %s",
                err.response['Error']['Code'], err.response['Error']['Message'])
            raise
        else:
            return response
```

Para ver las estadísticas recopiladas para un resultado de calidad de datos determinado:

```
import boto3
from botocore.exceptions import ClientError
import logging

logger = logging.getLogger(__name__)
class GlueWrapper:
    """Encapsulates AWS Glue actions."""
    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 AWS Glue client.
        """
        self.glue_client = glue_client

    def get_profile_for_data_quality_result(self, result_id):
        """
        Outputs the statistic profile for a AWS Glue Data Quality Result

        :param result_id: The result id of a AWS Glue Data Quality run

        """
        try:
            response = self.glue_client.get_data_quality_result(
                ResultId=result_id
            )

            # the profile contains all statistics gathered for the result
            profile_id = response['ProfileId']
            profile = self.glue_client.list_data_quality_statistics(
                ProfileId = profile_id
            )
```

```
            return profile
        except ClientError as err:
            logger.error(
                "Couldn't retrieve Data Quality profile. Here's why: %s: %s",
                err.response['Error']['Code'], err.response['Error']['Message'])
            raise
```

Para ver las series temporales de una estadística recopilada en varias ejecuciones de calidad de datos:

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""
    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 AWS Glue client.
        """
        self.glue_client = glue_client

    def get_statistics_for_data_quality_result(self, profile_id):
        """
        Outputs an array of datapoints for each statistic in the input result.

        :param result_id: The profile id of a AWS Glue Data Quality run

        """
        try:
            profile = self.glue_client.list_data_quality_statistics(
                ProfileId = profile_id
            )
            statistics = [self.glue_client.list_data_quality_statistics(
                StatisticId = s['StatisticId']
            ) for s in profile['Statistics']]
            return statistics
        except ClientError as err:
            logger.error(
                "Couldn't retrieve Data Quality statistics. Here's why: %s: %s",
                err.response['Error']['Code'], err.response['Error']['Message'])
            raise
```

Para ver el modelo de detección de anomalías de una estadística específica:

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""
```

```
    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 AWS Glue client.
        """
        self.glue_client = glue_client

    def get_model_training_result_for_statistic(self, statistic_id, profile_id):
        """
        Outputs the details (bounds) of anomaly detection training for the given
 statistic at the given profile.

        :param statistic_id the model's statistic (the timeseries it is tracking)
        :param profile_id the profile associated with the model (a point in the
 timeseries)

        """
        try:
            model = self.glue_client.get_data_quality_model_result(
                ProfileId = profile_id, StatisticId = statistic_id
            )
            return model
        except ClientError as err:
            logger.error(
                "Couldn't retrieve Data Quality model results. Here's why: %s: %s",
                err.response['Error']['Code'], err.response['Error']['Message'])
            raise
```

Para excluir un punto de datos de la referencia de la detección de anomalías de su modelo estadístico:

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""
    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 AWS Glue client.
        """
        self.glue_client = glue_client

    def apply_exclusions_to_statistic(self, statistic_id, profile_ids):
        """
        Annotate some points along a given statistic timeseries.
```

```
        This example excludes the provided values; INCLUDE can also be used to undo
 this action.

        :param statistic_id the statistic timeseries to annotate
        :param profile_id the profiles we want to exclude (points in the timeseries)

        """

        try:
            response = self.glue_client.batch_put_data_quality_statistic_annotation(
                    InclusionAnnotations = [
                        {'ProfileId': prof_id,
                        'StatisticId': statistic_id,
                        'InclusionAnnotation': 'EXCLUDE'} for prof_id in profile_ids
                    ]
            )
            return response['FailedInclusionAnnotations']
        except ClientError as err:
            logger.error(
                "Couldn't store Data Quality annotations. Here's why: %s: %s",
                err.response['Error']['Code'], err.response['Error']['Message'])
            raise
```

Para ver el estado del entrenamiento del modelo de detección de anomalías de una estadística específica:

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""
    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 AWS Glue client.
        """
        self.glue_client = glue_client

    def get_model_training_status_for_statistic(self, statistic_id, profile_id):
        """
        Outputs the status of anomaly detection training for the given statistic at the
 given profile.

        :param statistic_id the model's statistic (the timeseries it is tracking)
        :param profile_id the profile associated with the model (a point in the
 timeseries)
```

```
        """
        try:
            model = self.glue_client.get_data_quality_model(
                ProfileId = profile_id, StatisticId = statistic_id
            )
            return model
        except ClientError as err:
            logger.error(
                "Couldn't retrieve Data Quality statistics. Here's why: %s: %s",
                err.response['Error']['Code'], err.response['Error']['Message'])
            raise
```

Para excluir todos los resultados de una ejecución de calidad de datos específica a partir de las referencias de la detección de anomalías:

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""
    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 AWS Glue client.
        """
        self.glue_client = glue_client

    def apply_exclusions_to_profile(self, profile_id):
        """
        Exclude datapoints produced by a run across statistic timeseries.

        This example excludes the provided values; INCLUDE can also be used to undo
 this action.

        :param profile_id the profiles we want to exclude (points in the timeseries)

        """
        try:
            response = self.glue_client.put_data_quality_profile_annotation(
                    ProfileId = profile_id,
                    InclusionAnnotation = "EXCLUDE"
            )
            return response
        except ClientError as err:
            logger.error(
                "Couldn't store Data Quality annotations. Here's why: %s: %s",
                err.response['Error']['Code'], err.response['Error']['Message'])
```

```
            raise
```

Para obtener los resultados de una ejecución de calidad de datos determinada y mostrarlos:

Con un `runID` de Calidad de datos de AWS Glue, puede extraer el `resultID` para obtener los resultados reales, tal y como se muestra a continuación:

```
response = client.get_data_quality_ruleset_evaluation_run(
    RunId='dqrun-abca77ee126abe1378c1da1ae0750d7dxxxx'
)

resultID = response['ResultIds'][0]

response = client.get_data_quality_result(
    ResultId=resultID
)

print(resp['RuleResults'])
```

Configuración de alertas, implementaciones y programación

En este tema se describe cómo configurar alertas, implementaciones y programación para Calidad de datos de Glue de AWS Glue.

Contenido

- Configuración de alertas y notificaciones en la integración de Amazon EventBridge
  - Opciones de configuración adicionales para el patrón de eventos
  - Formatación de notificaciones como correos electrónicos
- Configuración de alertas y notificaciones en la integración de CloudWatch
- Cómo consultar los resultados de calidad de los datos para crear paneles
- Implementación de reglas de calidad de datos mediante AWS CloudFormation
- Programación de reglas de calidad de datos

Configuración de alertas y notificaciones en la integración de Amazon EventBridge

Calidad de datos de AWS Glue es compatible con la publicación de eventos de EventBridge, que se emiten al completar una evaluación del conjunto de reglas de calidad de datos. De este modo, puede configurar fácilmente alertas cuando fallen las reglas de calidad de datos.

Este es un ejemplo de un evento al evaluar los conjuntos de reglas de calidad de los datos en el Data Catalog. Con esta información, puede revisar los datos que están disponibles con Amazon EventBridge. Puede realizar llamadas a la API adicionales para obtener más información. Por ejemplo, llama a la API `get_data_quality_result` con el ID de resultado para obtener los detalles de una ejecución concreta.

```
{
    "version":"0",
    "id":"abcdef00-1234-5678-9abc-def012345678",
    "detail-type":"Data Quality Evaluation Results Available",
    "source":"aws.glue-dataquality",
    "account":"123456789012",
    "time":"2017-09-07T18:57:21Z",
    "region":"us-west-2",
    "resources":[],
    "detail":{
        "context": {
                    "contextType": "GLUE_DATA_CATALOG",
                    "runId":"dqrun-12334567890",
                    "databaseName": "db-123",
                    "tableName": "table-123",
                    "catalogId": "123456789012"
                    },
        "resultID": "dqresult-12334567890",
        "rulesetNames": ["rulset1"],
        "state":"SUCCEEDED",
        "score": 1.00,
        "rulesSucceeded": 100,
        "rulesFailed": 0,
        "rulesSkipped": 0
    }
}
```

Este es un ejemplo de evento que se publica al evaluar los conjuntos de reglas de calidad de los datos en los blocs de notas ETL de AWS Glue o AWS Glue Studio.

```
{
    "version":"0",
    "id":"abcdef00-1234-5678-9abc-def012345678",
    "detail-type":"Data Quality Evaluation Results Available",
    "source":"aws.glue-dataquality",
    "account":"123456789012",
    "time":"2017-09-07T18:57:21Z",
    "region":"us-west-2",
    "resources":[],
    "detail":{
        "context": {
                    "contextType": "GLUE_JOB",
                    "jobId": "jr-12334567890",
                    "jobName": "dq-eval-job-1234",
                    "evaluationContext": "",
                    }
        "resultID": "dqresult-12334567890",
        "rulesetNames": ["rulset1"],
        "state":"SUCCEEDED",
        "score": 1.00
        "rulesSucceeded": 100,
        "rulesFailed": 0,
        "rulesSkipped": 0
    }
}
```

Para que la evaluación de la calidad de los datos se ejecute tanto en el Catálogo de datos como en los trabajos de ETL, la opción Publicar métricas en Amazon CloudWatch, que está seleccionada de forma predeterminada, debe permanecer seleccionada para que la publicación de EventBridge funcione.

Configuración de notificaciones de EventBridge

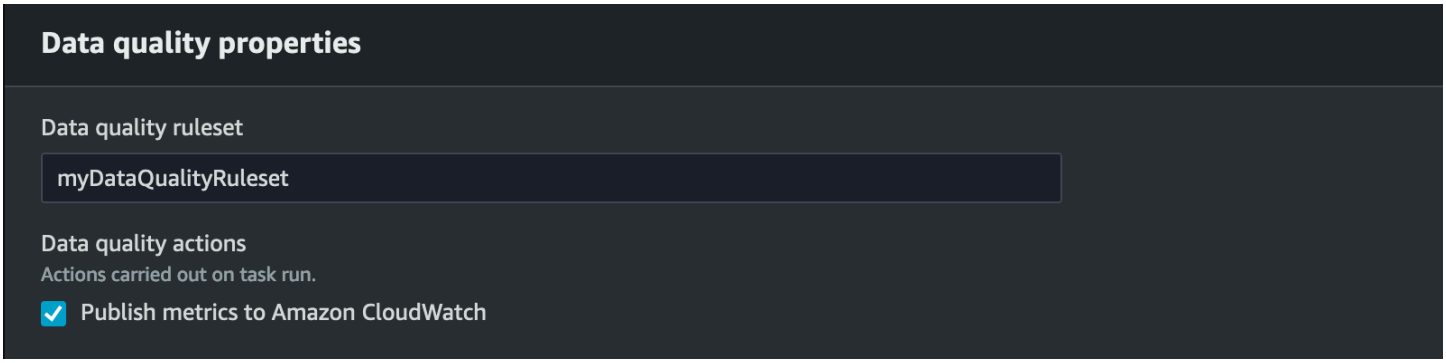

Para recibir los eventos emitidos y definir los objetivos, debe configurar las reglas de Amazon EventBridge. Para crear reglas:

1. Abra la consola de Amazon EventBridge.
2. Elija Reglas en la sección Buses de la barra de navegación.
3. Elija Create Rule.
4. En Definir los detalles de las reglas:
   a. En Nombre, escriba `myDQRule`.
   b. Ingrese la descripción (opcional).
   c. Para el bus de eventos, seleccione su bus de eventos. Si no tiene uno, déjelo como predeterminado.
   d. En Tipo de regla, seleccione Regla con un patrón de evento y luego elija Siguiente.
5. En Construir patrón de evento:
   a. En el origen del evento, seleccione Eventos de AWS o eventos de socios de EventBridge.
   b. Omita la sección de eventos de muestra.
   c. Para el método de creación, seleccione Usar forma de patrón.
   d. Para el patrón de eventos:
      i. Seleccione Servicios de AWS para el origen del evento.
      ii. Seleccione Calidad de datos de Glue para servicio de AWS.
      iii. Seleccione Resultados de la evaluación de la calidad de los datos disponibles para el tipo de evento.
      iv. Seleccione FALLA para estado(s) específico(s). A continuación, puede ver un patrón de eventos similar al siguiente:

```
  "source": ["aws.glue-dataquality"],
  "detail-type": ["Data Quality Evaluation Results Available"],
  "detail": {
    "state": ["FAILED"]
  }
}
```

v. Para más opciones de configuración, consulte Opciones de configuración adicionales para el patrón de eventos.

6. En Objetivo(s) seleccionado(s):
   a. Para Tipos de objetivos, seleccione el Servicio de AWS.
   b. Utilice el menú desplegable Seleccionar objetivo para elegir el servicio de AWS al que desee conectarse (SNS, Lambda, SQS, etc.) y, a continuación, seleccione Siguiente.
7. En Configurar etiqueta(s), haga clic en Agregar nuevas etiquetas para agregar etiquetas opcionales y, a continuación, seleccione Siguiente.
8. Aparecerá una página de resumen de todas las selecciones. Selecciona Crear regla en la parte inferior.

Opciones de configuración adicionales para el patrón de eventos

Además de filtrar el evento en función del éxito o el fracaso, puede que desee filtrar más los eventos según distintos parámetros.

Para ello, vaya a la sección Patrón de eventos y seleccione Editar patrón para especificar parámetros adicionales. Tenga en cuenta que los campos del patrón de eventos distinguen entre mayúsculas y minúsculas. A continuación, se muestran ejemplos de cómo configurar el patrón de eventos.

Para capturar eventos de una tabla en particular que evalúe conjuntos de reglas específicos, utilice este tipo de patrón:

```
{
  "source": ["aws.glue-dataquality"],
  "detail-type": ["Data Quality Evaluation Results Available"],
  "detail": {
    "context": {
      "contextType": ["GLUE_DATA_CATALOG"],
      "databaseName": "db-123",
       "tableName": "table-123",
    },
```

```
    "rulesetNames": ["ruleset1", "ruleset2"]
    "state": ["FAILED"]
  }
}
```

Para capturar eventos de trabajos específicos de la experiencia ETL, utilice este tipo de patrón:

```
{
  "source": ["aws.glue-dataquality"],
  "detail-type": ["Data Quality Evaluation Results Available"],
  "detail": {
    "context": {
      "contextType": ["GLUE_JOB"],
      "jobName": ["dq_evaluation_job1", "dq_evaluation_job2"]
    },
    "state": ["FAILED"]
  }
}
```

Para capturar eventos con una puntuación inferior a un umbral específico (por ejemplo, 70 %):

```
{
  "source": ["aws.glue-dataquality"],
  "detail-type": ["Data Quality Evaluation Results Available"],
  "detail": {
    "score": [{
      "numeric": ["<=", 0.7]
    }]
  }
}
```

Formatación de notificaciones como correos electrónicos

A veces es necesario enviar una notificación por correo electrónico con un formato adecuado a los equipos de la empresa. Puede utilizar Amazon EventBridge y AWS Lambda para conseguirlo.

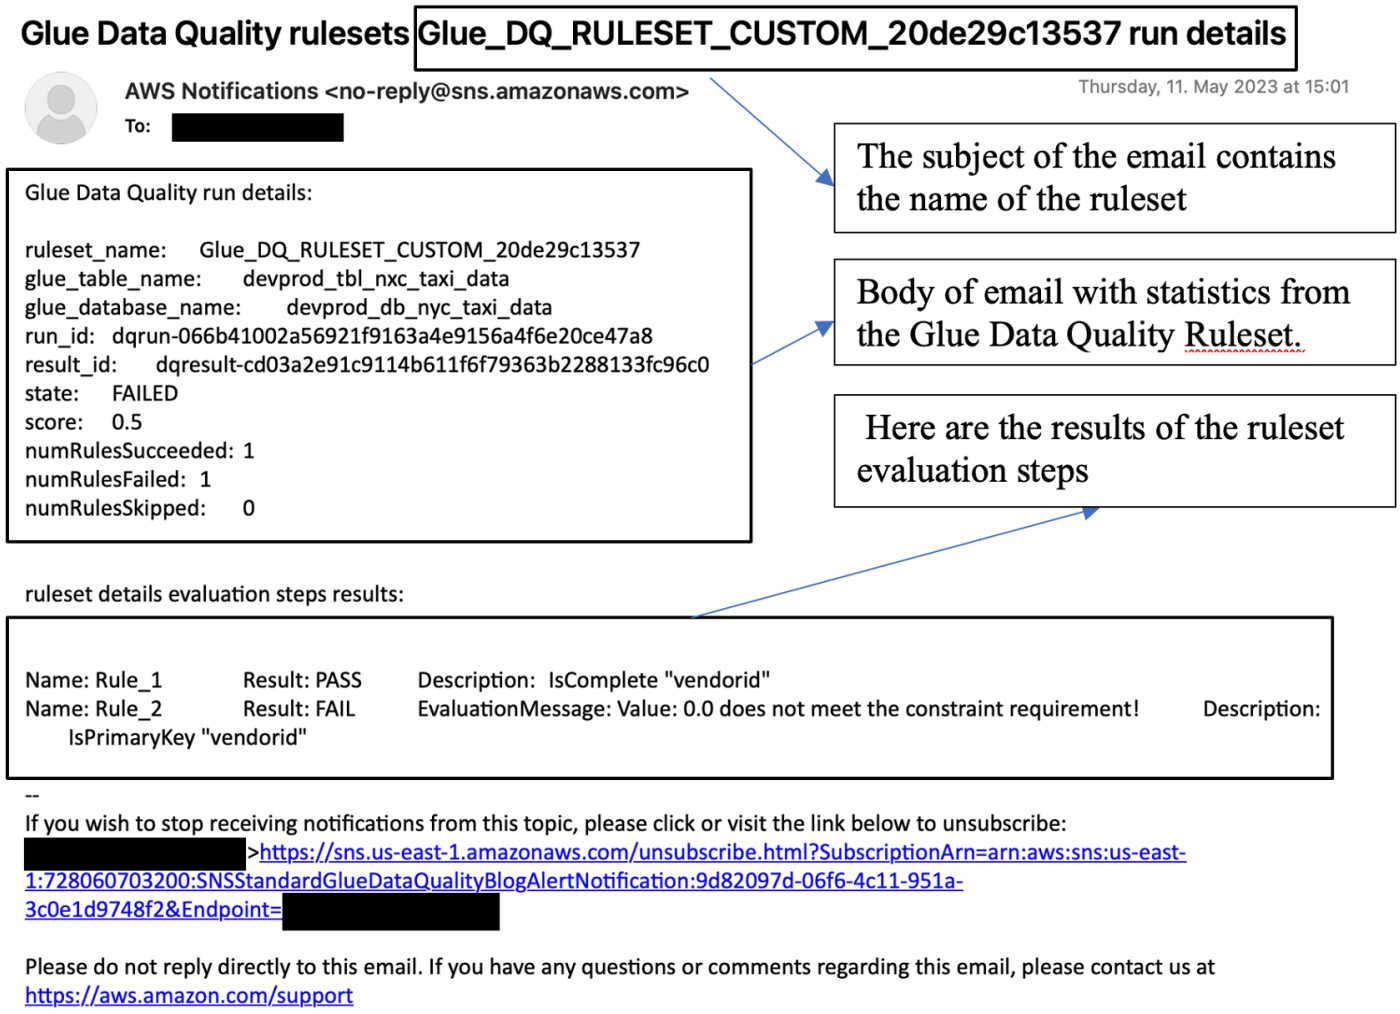

El siguiente código de ejemplo se puede utilizar para formatear las notificaciones de calidad de los datos a fin de generar correos electrónicos.

```
import boto3
import json
from datetime import datetime

sns_client = boto3.client('sns')
glue_client = boto3.client('glue')

sns_topic_arn = 'arn:aws:sns:<region-code>:<account-id>:<sns-topic-name>'



def lambda_handler(event, context):
    log_metadata = {}
```

```
    message_text = ""
    subject_text = ""

    if event['detail']['context']['contextType'] == 'GLUE_DATA_CATALOG':
        log_metadata['ruleset_name'] = str(event['detail']['rulesetNames'][0])
        log_metadata['tableName'] = str(event['detail']['context']['tableName'])
        log_metadata['databaseName'] = str(event['detail']['context']['databaseName'])
        log_metadata['runId'] = str(event['detail']['context']['runId'])
        log_metadata['resultId'] = str(event['detail']['resultId'])
        log_metadata['state'] = str(event['detail']['state'])
        log_metadata['score'] = str(event['detail']['score'])
        log_metadata['numRulesSucceeded'] = str(event['detail']['numRulesSucceeded'])
        log_metadata['numRulesFailed'] = str(event['detail']['numRulesFailed'])
        log_metadata['numRulesSkipped'] = str(event['detail']['numRulesSkipped'])

        message_text += "Glue Data Quality run details:\n"
        message_text += "ruleset_name: {}\n".format(log_metadata['ruleset_name'])
        message_text += "glue_table_name: {}\n".format(log_metadata['tableName'])
        message_text += "glue_database_name: {}\n".format(log_metadata['databaseName'])
        message_text += "run_id: {}\n".format(log_metadata['runId'])
        message_text += "result_id: {}\n".format(log_metadata['resultId'])
        message_text += "state: {}\n".format(log_metadata['state'])
        message_text += "score: {}\n".format(log_metadata['score'])
        message_text += "numRulesSucceeded:
{}\n".format(log_metadata['numRulesSucceeded'])
        message_text += "numRulesFailed: {}\n".format(log_metadata['numRulesFailed'])
        message_text += "numRulesSkipped: {}\n".format(log_metadata['numRulesSkipped'])

        subject_text = "Glue Data Quality ruleset {} run
details".format(log_metadata['ruleset_name'])

    else:
        log_metadata['ruleset_name'] = str(event['detail']['rulesetNames'][0])
        log_metadata['jobName'] = str(event['detail']['context']['jobName'])
        log_metadata['jobId'] = str(event['detail']['context']['jobId'])
        log_metadata['resultId'] = str(event['detail']['resultId'])
        log_metadata['state'] = str(event['detail']['state'])
        log_metadata['score'] = str(event['detail']['score'])

        log_metadata['numRulesSucceeded'] = str(event['detail']['numRulesSucceeded'])
        log_metadata['numRulesFailed'] = str(event['detail']['numRulesFailed'])
        log_metadata['numRulesSkipped'] = str(event['detail']['numRulesSkipped'])

        message_text += "Glue Data Quality run details:\n"
```

```
        message_text += "ruleset_name: {}\n".format(log_metadata['ruleset_name'])
        message_text += "glue_job_name: {}\n".format(log_metadata['jobName'])
        message_text += "job_id: {}\n".format(log_metadata['jobId'])
        message_text += "result_id: {}\n".format(log_metadata['resultId'])
        message_text += "state: {}\n".format(log_metadata['state'])
        message_text += "score: {}\n".format(log_metadata['score'])
        message_text += "numRulesSucceeded:
{}\n".format(log_metadata['numRulesSucceeded'])
        message_text += "numRulesFailed: {}\n".format(log_metadata['numRulesFailed'])
        message_text += "numRulesSkipped: {}\n".format(log_metadata['numRulesSkipped'])

        subject_text = "Glue Data Quality ruleset {} run
details".format(log_metadata['ruleset_name'])

    resultID = str(event['detail']['resultId'])
    response = glue_client.get_data_quality_result(ResultId=resultID)
    RuleResults = response['RuleResults']
    message_text += "\n\nruleset details evaluation steps results:\n\n"
    subresult_info = []

    for dic in RuleResults:
        subresult = "Name: {}\t\tResult: {}\t\tDescription: \t{}".format(dic['Name'],
dic['Result'], dic['Description'])
        if 'EvaluationMessage' in dic:
            subresult += "\t\tEvaluationMessage: {}".format(dic['EvaluationMessage'])
        subresult_info.append({
            'Name': dic['Name'],
            'Result': dic['Result'],
            'Description': dic['Description'],
            'EvaluationMessage': dic.get('EvaluationMessage', '')
        })
        message_text += "\n" + subresult

    log_metadata['resultrun'] = subresult_info



    sns_client.publish(
        TopicArn=sns_topic_arn,
        Message=message_text,
        Subject=subject_text
    )

    return {
```

```
        'statusCode': 200,
        'body': json.dumps('Message published to SNS topic')
    }
```

Configuración de alertas y notificaciones en la integración de CloudWatch

Nuestro enfoque recomendado es configurar alertas de calidad de datos mediante Amazon EventBridge, ya que Amazon EventBridge requiere una configuración única para alertar a los clientes. Sin embargo, algunos clientes prefieren Amazon CloudWatch por estar más familiarizados. Para estos clientes, ofrecemos la integración con Amazon CloudWatch.

Cada evaluación de Calidad de datos de AWS Glue emite un par de métricas nombradas `glue.data.quality.rules.passed` (que indican el número de reglas que se han aprobado) y `glue.data.quality.rules.failed` (que indican el número de reglas no aprobadas) por ejecución de calidad de datos. Puede usar esta métrica emitida para crear alarmas que alerten a los usuarios si una determinada cantidad de calidad de datos cae por debajo de un umbral. Para empezar a configurar una alarma que envíe un correo electrónico a través de una notificación de Amazon SNS, siga los pasos que se indican a continuación:

Para empezar a configurar una alarma que envíe un correo electrónico a través de una notificación de Amazon SNS, siga los pasos que se indican a continuación:

1. Abra la consola de Amazon CloudWatch.
2. Seleccione Todas las métricas en Métricas. Verá un espacio de nombres adicional en Espacios de nombres personalizados denominado Calidad de datos de Glue.

   > **Note**
   >
   > Al iniciar una ejecución de Calidad de datos de AWS Glue, asegúrese de que la casilla Publicar métricas en Amazon CloudWatch esté habilitada. De lo contrario, las métricas de esa ejecución concreta no se publicarán en Amazon CloudWatch.

   En el espacio de nombres `Glue Data Quality`, puede ver las métricas que se emiten por tabla y por conjunto de reglas. Para este tema, utilizaremos la `glue.data.quality.rules.failed` regla y la alarma si este valor supera 1 (lo que indica que, si vemos un número de evaluaciones de reglas fallidas superior a 1, queremos que se nos notifique).

3. Para crear la alarma, seleccione Todas las alarmas en Alarmas.
4. Elija Crear alarma.
5. Elija Seleccionar métrica.
6. Seleccione la métrica `glue.data.quality.rules.failed` correspondiente a la tabla que creó y, a continuación, elija Seleccionar métrica.
7. En la pestaña Especificar métrica y condiciones, en la sección Métricas:
   a. En Statistic (Estadística), elija Sum (Suma).
   b. Para Periodo, seleccione 1 minuto.
8. En la sección Condiciones:
   a. En Threshold type (Tipo de umbral), elija Static (Estático).
   b. Para Siempre que glue.data.quality.rules.failed sea…, seleccione Mayor que/Igual a.
   c. Para que..., ingrese 1 como valor umbral.

   Estas selecciones implican que si la métrica `glue.data.quality.rules.failed` emite un valor mayor o igual a 1, activaremos una alarma. Sin embargo, si no hay datos, los consideraremos aceptables.
9. Elija Siguiente.
10. En Acciones de configuración:
    a. Para la sección Desencadenador de estado de alarma, elija En alarma.
    b. Para la sección Enviar una notificación al siguiente tema de SNS, seleccione Crear un tema nuevo para enviar una notificación a través de un nuevo tema de SNS.
    c. En Puntos de conexión de correo electrónico que recibirán la notificación, ingrese una dirección de correo electrónico. Luego haga clic en Crear tema.
    d. Elija Siguiente.
11. En Nombre de la alarma, ingrese `myFirstDQAlarm` y, a continuación, seleccione Siguiente.
12. Aparecerá una página de resumen de todas las selecciones. Seleccione Crear alarma en la parte inferior.

Ahora puede ver la alarma que se crea desde el panel de alarmas de Amazon CloudWatch.

Cómo consultar los resultados de calidad de los datos para crear paneles

Es posible que desee crear un panel para mostrar los resultados de calidad de sus datos. Hay dos formas de hacer esto:

Configure Amazon EventBridge con el siguiente código para escribir los datos en Amazon S3:

```
import boto3
import json
from datetime import datetime


s3_client = boto3.client('s3')
glue_client = boto3.client('glue')


s3_bucket = 's3-bucket-name'

def write_logs(log_metadata):
    try:
        filename = datetime.now().strftime("%m%d%Y%H%M%S") + ".json"
        key_opts = {
            'year': datetime.now().year,
            'month': "{:02d}".format(datetime.now().month),
            'day': "{:02d}".format(datetime.now().day),
            'filename': filename
        }
        s3key = "gluedataqualitylogs/year={year}/month={month}/day={day}/
{filename}".format(**key_opts)
        s3_client.put_object(Bucket=s3_bucket, Key=s3key,
 Body=json.dumps(log_metadata))
    except Exception as e:
        print(f'Error writing logs to S3: {e}')


def lambda_handler(event, context):
    log_metadata = {}
    message_text = ""
    subject_text = ""

    if event['detail']['context']['contextType'] == 'GLUE_DATA_CATALOG':
        log_metadata['ruleset_name'] = str(event['detail']['rulesetNames'][0])
        log_metadata['tableName'] = str(event['detail']['context']['tableName'])
```

```
        log_metadata['databaseName'] = str(event['detail']['context']['databaseName'])
        log_metadata['runId'] = str(event['detail']['context']['runId'])
        log_metadata['resultId'] = str(event['detail']['resultId'])
        log_metadata['state'] = str(event['detail']['state'])
        log_metadata['score'] = str(event['detail']['score'])
        log_metadata['numRulesSucceeded'] = str(event['detail']['numRulesSucceeded'])
        log_metadata['numRulesFailed'] = str(event['detail']['numRulesFailed'])
        log_metadata['numRulesSkipped'] = str(event['detail']['numRulesSkipped'])

        message_text += "Glue Data Quality run details:\n"
        message_text += "ruleset_name: {}\n".format(log_metadata['ruleset_name'])
        message_text += "glue_table_name: {}\n".format(log_metadata['tableName'])
        message_text += "glue_database_name: {}\n".format(log_metadata['databaseName'])
        message_text += "run_id: {}\n".format(log_metadata['runId'])
        message_text += "result_id: {}\n".format(log_metadata['resultId'])
        message_text += "state: {}\n".format(log_metadata['state'])
        message_text += "score: {}\n".format(log_metadata['score'])
        message_text += "numRulesSucceeded:
{}\n".format(log_metadata['numRulesSucceeded'])
        message_text += "numRulesFailed: {}\n".format(log_metadata['numRulesFailed'])
        message_text += "numRulesSkipped: {}\n".format(log_metadata['numRulesSkipped'])

        subject_text = "Glue Data Quality ruleset {} run
details".format(log_metadata['ruleset_name'])

    else:
        log_metadata['ruleset_name'] = str(event['detail']['rulesetNames'][0])
        log_metadata['jobName'] = str(event['detail']['context']['jobName'])
        log_metadata['jobId'] = str(event['detail']['context']['jobId'])
        log_metadata['resultId'] = str(event['detail']['resultId'])
        log_metadata['state'] = str(event['detail']['state'])
        log_metadata['score'] = str(event['detail']['score'])

        log_metadata['numRulesSucceeded'] = str(event['detail']['numRulesSucceeded'])
        log_metadata['numRulesFailed'] = str(event['detail']['numRulesFailed'])
        log_metadata['numRulesSkipped'] = str(event['detail']['numRulesSkipped'])

        message_text += "Glue Data Quality run details:\n"
        message_text += "ruleset_name: {}\n".format(log_metadata['ruleset_name'])
        message_text += "glue_job_name: {}\n".format(log_metadata['jobName'])
        message_text += "job_id: {}\n".format(log_metadata['jobId'])
        message_text += "result_id: {}\n".format(log_metadata['resultId'])
        message_text += "state: {}\n".format(log_metadata['state'])
        message_text += "score: {}\n".format(log_metadata['score'])
```

```
        message_text += "numRulesSucceeded:
{}\n".format(log_metadata['numRulesSucceeded'])
        message_text += "numRulesFailed: {}\n".format(log_metadata['numRulesFailed'])
        message_text += "numRulesSkipped: {}\n".format(log_metadata['numRulesSkipped'])

        subject_text = "Glue Data Quality ruleset {} run
details".format(log_metadata['ruleset_name'])

    resultID = str(event['detail']['resultId'])
    response = glue_client.get_data_quality_result(ResultId=resultID)
    RuleResults = response['RuleResults']
    message_text += "\n\nruleset details evaluation steps results:\n\n"
    subresult_info = []

    for dic in RuleResults:
        subresult = "Name: {}\t\tResult: {}\t\tDescription: \t{}".format(dic['Name'],
dic['Result'], dic['Description'])
        if 'EvaluationMessage' in dic:
            subresult += "\t\tEvaluationMessage: {}".format(dic['EvaluationMessage'])
        subresult_info.append({
            'Name': dic['Name'],
            'Result': dic['Result'],
            'Description': dic['Description'],
            'EvaluationMessage': dic.get('EvaluationMessage', '')
        })
        message_text += "\n" + subresult

    log_metadata['resultrun'] = subresult_info

    write_logs(log_metadata)


    return {
        'statusCode': 200,
        'body': json.dumps('Message published to SNS topic')
    }
```

Después de escribir en Amazon S3, puede utilizar los rastreadores de AWS Glue para registrarse en Athena y consultar las tablas.

Configure una ubicación de Amazon S3 durante una evaluación de la calidad de los datos:

Al ejecutar tareas de calidad de datos en el Data Catalog de AWS Glue o en la ETL de AWS Glue, puede proporcionar una ubicación de Amazon S3 para escribir los resultados de calidad de los datos en Amazon S3. Puede usar la siguiente sintaxis para crear una tabla que haga referencia al objetivo para leer los resultados de calidad de los datos.

Tenga en cuenta que debe ejecutar las consultas `CREATE EXTERNAL TABLE` y `MSCK REPAIR TABLE` por separado.

```
CREATE EXTERNAL TABLE <my_table_name>(
    catalogid string,
    databasename string,
    tablename string,
    dqrunid string,
    evaluationstartedon timestamp,
    evaluationcompletedon timestamp,
    rule string,
    outcome string,
    failurereason string,
    evaluatedmetrics string)
PARTITIONED BY (
    `year` string,
    `month` string,
    `day` string)
ROW FORMAT SERDE 'org.openx.data.jsonserde.JsonSerDe'
WITH SERDEPROPERTIES (

 'paths'='catalogId,databaseName,dqRunId,evaluatedMetrics,evaluationCompletedOn,evaluationStart
STORED AS INPUTFORMAT 'org.apache.hadoop.mapred.TextInputFormat'
OUTPUTFORMAT 'org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat'
LOCATION 's3://glue-s3-dq-bucket-us-east-2-results/'
TBLPROPERTIES (
    'classification'='json',
    'compressionType'='none',
    'typeOfData'='file');
```

```
MSCK REPAIR TABLE <my_table_name>;
```

Una vez que haya creado la tabla anterior, podrá ejecutar consultas analíticas con Amazon Athena.

Implementación de reglas de calidad de datos mediante AWS CloudFormation

Puede usar AWS CloudFormation para crear reglas de calidad de datos. Para obtener más información, consulte Pilas de AWS CloudFormation para AWS Glue.

Programación de reglas de calidad de datos

Puede programar las reglas de calidad de los datos mediante los métodos siguientes:

- Programe las reglas de calidad de los datos desde el Data Catalog: los usuarios sin código pueden utilizar esta opción para programar fácilmente los escaneos de calidad de datos. AWS Calidad de datos de Glue creará la programación en Amazon EventBridge. Para programar las reglas de calidad de los datos:
  - Navegue hasta el conjunto de reglas y haga clic en Ejecutar.
  - En la Frecuencia de ejecución, seleccione la programación deseada y proporcione un Nombre de tarea. Este nombre de tarea es el nombre de su programación en EventBridge.
- Utilice Amazon EventBridge y AWS Step Functions para organizar las evaluaciones y recomendaciones de las normas de calidad de los datos.

Cifrado de datos en reposo para Calidad de datos de AWS Glue

AWS Glue Data Quality proporciona cifrado de forma predeterminada para proteger los datos en reposo confidenciales de los clientes mediante claves de cifrado propiedad de AWS.

Claves propiedad de AWS

Calidad de datos de AWS Glue utiliza estas claves para cifrar automáticamente los activos de Calidad de datos de los clientes. No puede ver, administrar ni usar las claves propiedad de AWS ni auditar su uso. Sin embargo, no necesita realizar ninguna acción ni cambiar ningún programa para proteger las claves que cifran los datos. Para obtener más información, consulte las claves propias de AWS en la Guía para desarrolladores de AWS KMS.

El cifrado de los datos en reposo de forma predeterminada ayuda a reducir la sobrecarga operativa y la complejidad que implica la protección de los datos confidenciales. Al mismo tiempo, le permite crear aplicaciones seguras que cumplen con los estrictos requisitos normativos y de conformidad con el cifrado.

Si bien no puede deshabilitar esta capa de cifrado ni seleccionar un tipo de cifrado alternativo, puede agregar una segunda capa de cifrado sobre las claves de cifrado propias de AWS. Para ello, elija una clave administrada por el cliente al crear sus recursos de Calidad de datos.

Claves administradas por el cliente

Claves administradas por el cliente: Calidad de datos de AWS Glue admite el uso de una clave simétrica administrada por el cliente que usted crea, posee y administra. Esto agrega una segunda capa de cifrado sobre el cifrado propio existente de AWS. Como usted tiene el control total de esta capa de cifrado, puede realizar tareas como las siguientes:

- Establecer y mantener políticas de claves
- Establecer y mantener concesiones y políticas de IAM
- Habilitar y deshabilitar políticas de claves
- Rotar el material criptográfico
- Agregar etiquetas.
- Crear alias de clave
- Programar la eliminación de claves

Para más información, consulte las Claves administradas por el cliente en la Guía para desarrolladores de AWS KMS.

En la siguiente tabla se resume cómo Calidad de datos de AWS Glue cifra los diferentes activos de Calidad de datos.

Tipo de datos	Cifrado de AWS de clave propia	Clave de cifrado administrada por el cliente
Conjunto de reglas de calidad de datos Cadena de conjunto de reglas de DQDL a la que hace referencia el conjunto de reglas de DQ persistente. Por ahora, estos conjuntos de reglas persistentes solo se	Habilitado	Habilitado

Tipo de datos	Cifrado de AWS de clave propia	Clave de cifrado administrada por el cliente
utilizan en la experiencia del Catálogo de datos de AWS Glue.		
Resultados del analizador o de la regla de calidad de los datos Artefactos de resultados que contienen el estado de superado o no superado de cada regla en un conjunto de reglas, así como las métricas recopiladas tanto por las reglas como por los analizadores.	Habilitado	Habilitado
Observaciones Las observaciones se generan cuando se detecta una anomalía en los datos. Contiene información sobre los límites superior e inferior esperados, y una regla sugerida basada en estos límites. Si se generan, se muestran junto con los resultados de calidad de datos.	Habilitado	Habilitado

Tipo de datos	Cifrado de AWS de clave propia	Clave de cifrado administrada por el cliente
Statistics Contiene información sobre las métricas recopiladas después de evaluar los datos según un conjunto de reglas, como el valor de la métrica (p. ej., RowCount o integridad), los nombres de las columnas y otros metadatos.	Habilitado	Habilitado
Modelos estadísticos de detección de anomalías Los modelos estadísticos contienen la serie temporal de los límites superior e inferior de una métrica determinada generada a partir de evaluacio nes anteriores de los datos de los clientes.	Habilitado	Habilitado

> **Note**
>
> Calidad de datos de AWS habilita automáticamente el cifrado en reposo utilizando claves propias de AWS para proteger los datos de identificación personal sin cargo alguno. Sin embargo, se aplicarán cargos de AWS KMS por el uso de una clave administrada por el cliente. Para obtener más información sobre los precios, consulte Precios de AWS KMS. Para obtener más información sobre AWS KMS, consulte AWS KMS.

Crear una clave administrada por el cliente

Puede crear una clave simétrica administrada por el cliente a través de la Consola de administración de AWS o las API de AWS KMS.

Para crear una clave simétrica administrada por el cliente:

- Siga los pasos para Crear claves AWS KMS de cifrado simétrico descritos en la Guía para desarrolladores de AWS Key Management Service.

Política de claves

Las políticas de clave controlan el acceso a la clave administrada por el cliente. Cada clave administrada por el cliente debe tener exactamente una política de clave, que contiene instrucciones que determinan quién puede usar la clave y cómo puede utilizarla. Cuando crea la clave administrada por el cliente, puede especificar una política de clave. Para obtener más información, consulte Políticas de claves de AWS KMS en la Guía para desarrolladores de AWS Key Management Service.

Para utilizar su clave administrada por el cliente con sus recursos de Calidad de datos, en la política de claves deben permitirse las siguientes operaciones de API:

- `kms:Decrypt`: descifra el texto cifrado que se cifró con una clave AWS KMS mediante `GenerateDataKeyWithoutPlaintext`.
- `kms:DescribeKey` – proporciona los detalles de la clave administrada por el cliente para permitir que Amazon Location valide la clave.
- `kms:GenerateDataKeyWithoutPlaintext`: devuelve una clave de datos simétrica única para usarla fuera de AWS KMS. Esta operación devuelve una clave de datos que se cifra bajo una clave KMS de cifrado simétrica especificada. Los bytes de la clave son aleatorios; no están relacionados con el intermediario ni con la clave KMS. Se utiliza para reducir las llamadas a KMS que debe realizar el cliente.
- `kms:ReEncrypt*`: descifra el texto cifrado y lo vuelve a cifrar por completo en AWS KMS. Puede utilizar esta operación para cambiar la clave KMS con la que se cifran los datos, por ejemplo, cuando rota manualmente una clave KMS o cambia la clave KMS que protege un texto cifrado. También puede usarla para volver a cifrar el texto cifrado con la misma clave KMS, por ejemplo, para cambiar el contexto de cifrado de un texto cifrado.

Los siguientes son ejemplos de declaraciones de política que puede agregar para Amazon Location:

```
"Statement" : [
    {
        "Sid" : "Allow access to principals authorized to use AWS Glue Data Quality",
        "Effect" : "Allow",
        "Principal" : {
            "AWS": "arn:aws:iam::<account_id>:role/ExampleRole"
        },
        "Action" : [
            "kms:Decrypt",
            "kms:DescribeKey",
            "kms:GenerateDataKeyWithoutPlaintext",
            "kms:ReEncrypt*"
        ],
        "Resource" : "*",
        "Condition" : {
            "StringEquals" : {
                "kms:ViaService" : "glue.amazonaws.com",
                "kms:CallerAccount" : "111122223333"
            }
        },
    {
        "Sid": "Allow access for key administrators",
        "Effect": "Allow",
        "Principal": {
            "AWS": "arn:aws:iam::111122223333:root"
          },
        "Action" : [
            "kms:*"
         ],
        "Resource": "arn:aws:kms:region:111122223333:key/key_ID"
    },
    {
        "Sid" : "Allow read-only access to key metadata to the account",
        "Effect" : "Allow",
        "Principal" : {
            "AWS" : "arn:aws:iam::111122223333:root"
        },
        "Action" : [
            "kms:Describe*",
            "kms:Get*",
            "kms:List*",
        ],
```

```
        "Resource" : "*"
    }
]
```

Notas sobre el uso de claves KMS en Calidad de datos de AWS Glue

Calidad de datos de AWS Glue no admite transiciones de clave. Esto significa que si cifra sus activos de Calidad de datos con la clave A y decide pasarse a la clave B, no volveremos a cifrar los datos cifrados con la clave A para usar la clave B. Puede cambiar a la clave B, pero tendrá que mantener el acceso a la clave A para acceder a los datos previamente cifrados con la clave A.

Para obtener más información sobre la especificación de permisos en una política, consulte Permisos para los servicios de AWS en políticas de claves en la Guía para desarrolladores de AWS Key Management Service.

Para obtener más información sobre la solución de problemas de acceso a las claves, consulte Solución de problemas de acceso a las claves en la Guía para desarrolladores de AWS Key Management Service.

Creación de una configuración de seguridad

En AWS Glue, el recurso Configuraciones de seguridad contiene las propiedades que se necesitan cuando se escriben datos cifrados.

Para cifrar sus activos de calidad de datos:

1. En Configuración de cifrado, vaya a Configuración avanzada y elija Habilitar el cifrado de calidad de datos
2. Seleccione su clave KMS o elija Crear una clave AWS KMS

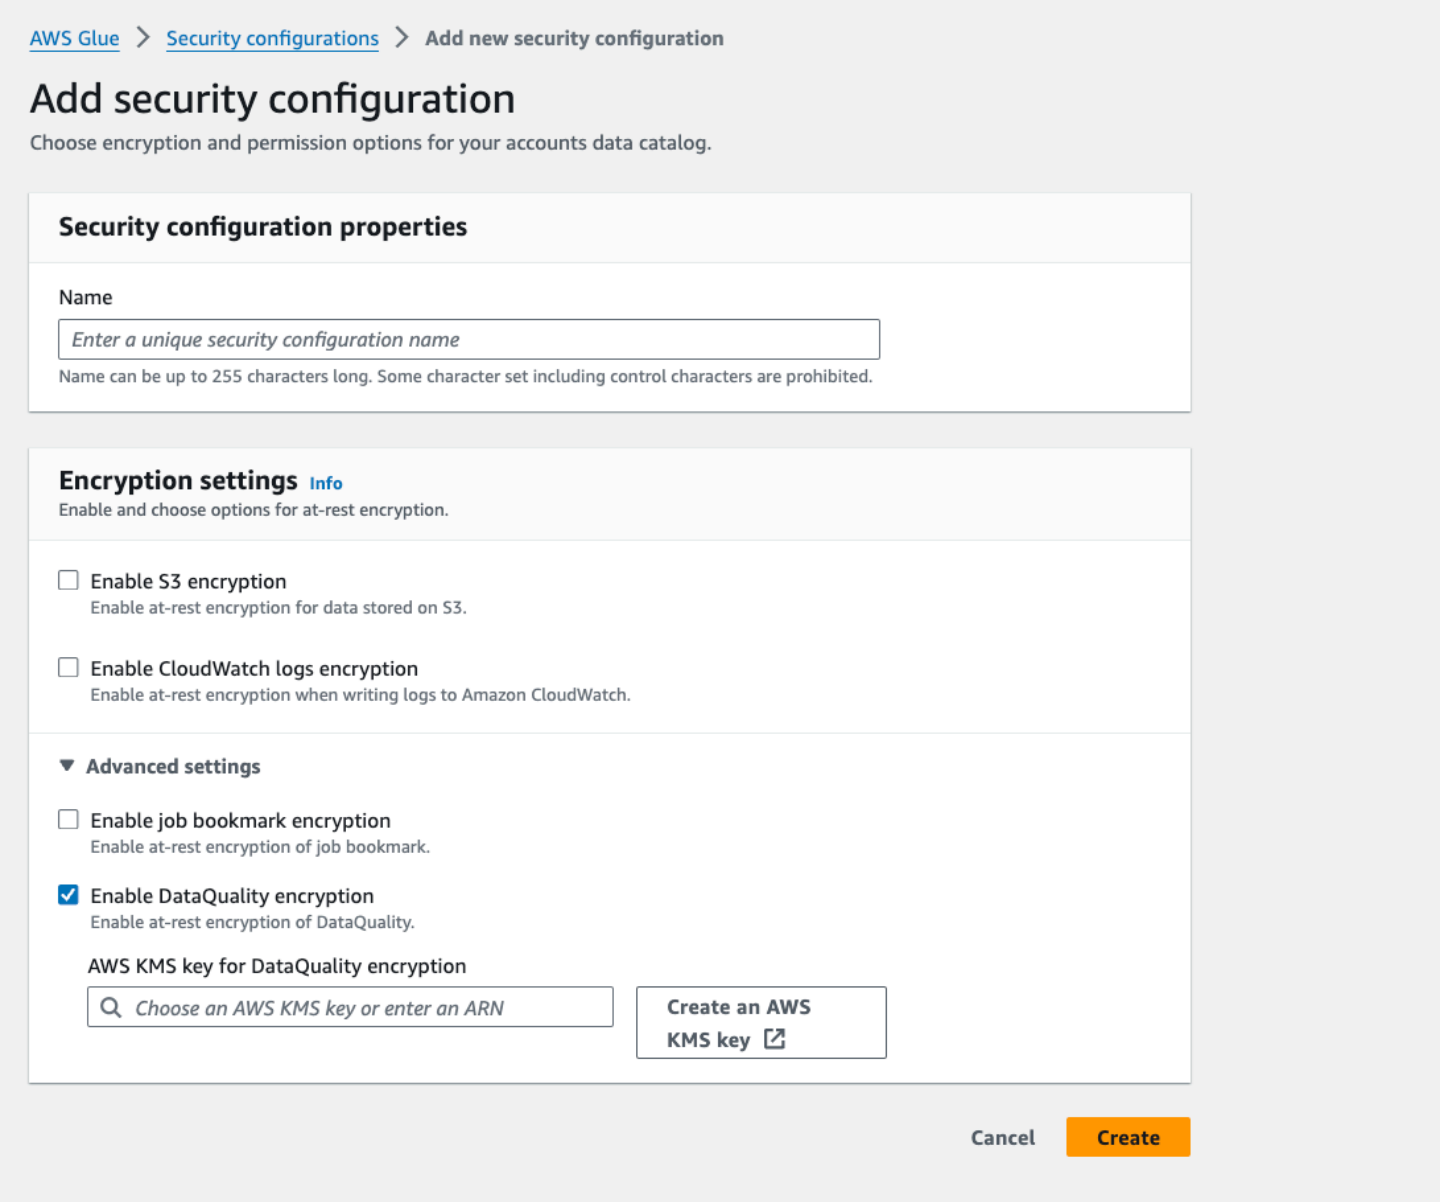

Contexto de cifrado de Calidad de datos de AWS Glue

Un contexto de cifrado es un conjunto opcional de pares clave-valor que pueden contener información contextual adicional sobre los datos.

AWS KMS utiliza el contexto de cifrado como datos autenticados adicionales para admitir el cifrado autenticado. Cuando se incluye un contexto de cifrado en una solicitud para cifrar datos, AWS KMS vincula el contexto de cifrado a los datos cifrados. Para descifrar los datos, debe incluir el mismo contexto de cifrado en la solicitud.

Ejemplo de contexto de cifrado de Calidad de datos de AWS Glue

```
"encryptionContext": {
    "kms-arn": "arn:aws:kms:us-
east-1:111122223333:key/1234abcd-12ab-34cd-56ef-123456SAMPLE",
    "branch-key-id": "111122223333+arn:aws:kms:us-
east-1:111122223333:key/1234abcd-12ab-34cd-56ef-123456SAMPLE",
    "hierarchy-version": "1",
    "aws-crypto-ec:aws:glue:securityConfiguration": "111122223333:customer-security-
configuration-name",
    "create-time": "2024-06-07T13:47:23:000861Z",
    "tablename": "AwsGlueMlEncryptionKeyStore",
    "type": "beacon:ACTIVE"
}
```

Uso del contexto de cifrado para la supervisión

Si utiliza una clave simétrica gestionada por el cliente para cifrar su rastreador o su colección de geocercas, también puede utilizar el contexto de cifrado en los registros y registros de auditoría para identificar cómo se utiliza la clave gestionada por el cliente. El contexto de cifrado también aparece en los registros generados por AWS CloudTrail o Amazon CloudWatch Logs.

Monitoreo de las claves de cifrado para Calidad de datos de AWS Glue

Cuando utiliza una clave AWS KMS administrada por el cliente con sus recursos de Calidad de datos de AWS Glue, puede utilizar AWS CloudTrail o Amazon CloudWatch Logs para realizar un seguimiento de las solicitudes que Calidad de datos de AWS Glue envía a AWS KMS.

Los siguientes ejemplos son eventos de AWS CloudTrail para que `GenerateDataKeyWithoutPlainText` y `Decrypt` monitoreen las operaciones de KMS solicitadas por Calidad de datos de AWS para acceder a los datos que se cifraron con su clave administrada por el cliente.

Decrypt

```
{
    "eventVersion": "1.09",
    "userIdentity": {
        "type": "AssumedRole",
        "arn": "arn:aws:sts::111122223333:role/CustomerRole",
        "accountId": "111122223333",
```

```
        "invokedBy": "glue.amazonaws.com"
    },
    "eventTime": "2024-07-02T20:03:10Z",
    "eventSource": "kms.amazonaws.com",
    "eventName": "Decrypt",
    "awsRegion": "us-east-1",
    "sourceIPAddress": "glue.amazonaws.com",
    "userAgent": "glue.amazonaws.com",
    "requestParameters": {
        "keyId": "arn:aws:kms:us-
east-1:111122223333:key/1234abcd-12ab-34cd-56ef-123456SAMPLE",
        "encryptionAlgorithm": "SYMMETRIC_DEFAULT",
        "encryptionContext": {
            "kms-arn": "arn:aws:kms:us-
east-1:111122223333:key/1234abcd-12ab-34cd-56ef-123456SAMPLE",
            "branch-key-id": "111122223333+arn:aws:kms:us-
east-1:111122223333:key/1234abcd-12ab-34cd-56ef-123456SAMPLE",
            "hierarchy-version": "1",
            "aws-crypto-ec:aws:glue:securityConfiguration": "111122223333:customer-
security-configuration-name",
            "create-time": "2024-06-07T13:47:23:000861Z",
            "tablename": "AwsGlueMlEncryptionKeyStore",
            "type": "branch:ACTIVE",
            "version": "branch:version:ff000af-00eb-00ce-0e00-ea000fb0fba0SAMPLE"
        }
    },
    "responseElements": null,
    "requestID": "ff000af-00eb-00ce-0e00-ea000fb0fba0SAMPLE",
    "eventID": "ff000af-00eb-00ce-0e00-ea000fb0fba0SAMPLE",
    "readOnly": true,
    "resources": [
        {
            "accountId": "111122223333",
            "type": "AWS::KMS::Key",
            "ARN": "arn:aws:kms:us-
east-1:111122223333:key/1234abcd-12ab-34cd-56ef-123456SAMPLE"
        }
    ],
    "eventType": "AwsApiCall",
    "managementEvent": true,
    "recipientAccountId": "111122223333",
    "eventCategory": "Management"
}
```

GenerateDataKeyWithoutPlaintext


```
{
    "eventVersion": "1.09",
    "userIdentity": {
        "type": "AssumedRole",
        "arn": "arn:aws:sts::111122223333:role/CustomerRole",
        "accountId": "111122223333",
        "invokedBy": "glue.amazonaws.com"
    },
    "eventTime": "2024-07-02T20:03:10Z",
    "eventSource": "kms.amazonaws.com",
    "eventName": "GenerateDataKeyWithoutPlaintext",
    "awsRegion": "us-east-1",
    "sourceIPAddress": "glue.amazonaws.com",
    "userAgent": "glue.amazonaws.com",
    "requestParameters": {
        "keyId": "arn:aws:kms:us-
east-1:111122223333:key/1234abcd-12ab-34cd-56ef-123456SAMPLE",
        "encryptionAlgorithm": "SYMMETRIC_DEFAULT",
        "encryptionContext": {
            "kms-arn": "arn:aws:kms:us-
east-1:111122223333:key/1234abcd-12ab-34cd-56ef-123456SAMPLE",
            "branch-key-id": "111122223333+arn:aws:kms:us-
east-1:111122223333:key/1234abcd-12ab-34cd-56ef-123456SAMPLE",
            "hierarchy-version": "1",
            "aws-crypto-ec:aws:glue:securityConfiguration": "111122223333:customer-
security-configuration-name",
            "create-time": "2024-06-07T13:47:23:000861Z",
            "tablename": "AwsGlueMlEncryptionKeyStore",
            "type": "branch:version:ff000af-00eb-00ce-0e00-ea000fb0fba0SAMPLE"
        }
    },
    "responseElements": null,
    "requestID": "ff000af-00eb-00ce-0e00-ea000fb0fba0SAMPLE",
    "eventID": "ff000af-00eb-00ce-0e00-ea000fb0fba0SAMPLE",
    "readOnly": true,
    "resources": [
        {
            "accountId": "111122223333",
            "type": "AWS::KMS::Key",
            "ARN": "arn:aws:kms:us-
east-1:111122223333:key/1234abcd-12ab-34cd-56ef-123456SAMPLE"
        }
```

```
    ],
    "eventType": "AwsApiCall",
    "managementEvent": true,
    "recipientAccountId": "111122223333",
    "eventCategory": "Management"
}
```

ReencyRPT

```
{
    "eventVersion": "1.09",
    "userIdentity": {
        "type": "AssumedRole",
        "arn": "arn:aws:sts::111122223333:role/CustomerRole",
        "accountId": "111122223333",
        "invokedBy": "glue.amazonaws.com"
    },
    "eventTime": "2024-07-17T21:34:41Z",
    "eventSource": "kms.amazonaws.com",
    "eventName": "ReEncrypt",
    "awsRegion": "us-east-1",
    "sourceIPAddress": "glue.amazonaws.com",
    "userAgent": "glue.amazonaws.com",
    "requestParameters": {
        "destinationEncryptionContext": {
             "kms-arn": "arn:aws:kms:us-
east-1:111122223333:key/1234abcd-12ab-34cd-56ef-123456SAMPLE",
            "branch-key-id": "111122223333+arn:aws:kms:us-
east-1:111122223333:key/1234abcd-12ab-34cd-56ef-123456SAMPLE",
            "hierarchy-version": "1",
            "aws-crypto-ec:aws:glue:securityConfiguration": "111122223333:customer-
security-configuration-name",
            "create-time": "2024-06-07T13:47:23:000861Z",
            "tablename": "AwsGlueMlEncryptionKeyStore",
            "type": "branch:ACTIVE"
            "version": "branch:version:12345678-SAMPLE"
        },
        "destinationKeyId": "arn:aws:kms:us-
east-1:111122223333:key/1234abcd-12ab-34cd-56ef-123456SAMPLE",
        "sourceAAD": "1234567890-SAMPLE+Z+lqoYOHj7VtWxJLrvh+biUFbliYDAQkobM=",
        "sourceKeyId": "arn:aws:kms:ap-southeast-2:585824196334:key/17ca05ca-a8c1-40d7-
b7fd-30abb569a53a",
        "destinationEncryptionAlgorithm": "SYMMETRIC_DEFAULT",
```

```
        "sourceEncryptionContext": {
            "kms-arn": "arn:aws:kms:us-
east-1:111122223333:key/1234abcd-12ab-34cd-56ef-123456SAMPLE",
            "branch-key-id": "111122223333+arn:aws:kms:us-
east-1:111122223333:key/1234abcd-12ab-34cd-56ef-123456SAMPLE",
            "hierarchy-version": "1",
            "aws-crypto-ec:aws:glue:securityConfiguration": "111122223333:customer-
security-configuration-name",
            "create-time": "2024-06-07T13:47:23:000861Z",
            "tablename": "AwsGlueMlEncryptionKeyStore",
            "type": "branch:version:ff000af-00eb-00ce-0e00-ea000fb0fba0SAMPLE"
        },
        "destinationAAD": "1234567890-SAMPLE",
        "sourceEncryptionAlgorithm": "SYMMETRIC_DEFAULT"
    },
    "responseElements": null,
    "requestID": "ff000af-00eb-00ce-0e00-ea000fb0fba0SAMPLE",
    "eventID": "ff000af-00eb-00ce-0e00-ea000fb0fba0SAMPLE",
    "readOnly": true,
    "resources": [
        {
            "accountId": "111122223333",
            "type": "AWS::KMS::Key",
            "ARN": "arn:aws:kms:us-
east-1:111122223333:key/1234abcd-12ab-34cd-56ef-123456SAMPLE"
        },
        {
            "accountId": "111122223333",
            "type": "AWS::KMS::Key",
            "ARN": "arn:aws:kms:us-
east-1:111122223333:key/1234abcd-12ab-34cd-56ef-123456SAMPLE"
        }
    ],
    "eventType": "AwsApiCall",
    "managementEvent": true,
    "recipientAccountId": "111122223333",
    "eventCategory": "Management"
}
```


Más información

Los siguientes recursos proporcionan más información sobre cifrado de datos en reposo.

- Para obtener más información acerca de los conceptos básicos de AWS Key Management Service, consulte la Guía para desarrolladores de AWS Key Management Service.
- Para obtener más información sobre las prácticas recomendadas de seguridad de AWS Key Management Service, consulte la Guía para desarrolladores de AWS Key Management Service.

Solución de problemas de calidad de datos de AWS Glue

Si detecta errores en la Calidad de datos de AWS Glue, utilice las siguientes soluciones como ayuda para encontrar el origen de los problemas y corregirlos.

Contenido

- Error: falta el módulo Calidad de datos de AWS Glue
- Error: permisos de AWS Lake Formation insuficientes
- Error: los conjuntos de reglas no disponen de un nombre único
- Error: tablas con caracteres especiales
- Error: error de desbordamiento con un conjunto de reglas grande
- Error: el estado general de la regla falló
- AnalysisException: no es posible verificar la existencia de la base de datos predeterminada
- Mensaje de error: el mapa de teclas proporcionado no es adecuado para determinados marcos de datos
- Excepción en la clase de usuario: java.lang.RuntimeException: no fue posible recuperar los datos. Para obtener más información, consulte los registros en CloudWatch
- ERROR DE INICIO: error al descargar desde S3 para bucket
- InvalidInputException (estado: 400): las reglas de calidad de datos no se pueden analizar
- Error: EventBridge no activa los trabajos de calidad de datos de Glue según la programación que configuré
- Errores de CustomSQL
- Reglas dinámicas
- Excepción en la Clase de usuario: org.apache.spark.sql.AnalysisException: org.apache.hadoop.hive.ql.metadata.HiveException
- UNCLASSIFIED_ERROR; IllegalArgumentException: Error de análisis: no se proporcionaron reglas ni analizadores, no hay una alternativa viable en la entrada

Error: falta el módulo Calidad de datos de AWS Glue

Mensaje de error: ningún módulo se llama “awsgluedq”.

Solución: este error se produce al ejecutar Calidad de datos de AWS Glue en una versión no compatible. AWS Calidad de datos de Glue solo es compatible con la versión 3.0 de Glue y versiones posteriores.

Error: permisos de AWS Lake Formation insuficientes

Mensaje de error: excepción en la clase de usuario: `com.amazonaws.services.glue.model.AccessDeniedException`: permisos de Lake Formation insuficientes en impact_sdg_involvement (servicio: AWS Glue; código de estado: 400; código de error: AccessDeniedException; ID de solicitud: 465ae693-b7ba-4df0-a4e4-6b17xxxxxxxx; proxy: nulo).

Solución: es necesario que dé permisos suficientes en AWS Lake Formation.

Error: los conjuntos de reglas no disponen de un nombre único

Mensaje de error: excepción en la clase de usuario: ...services.glue.model.AlreadyExistsException: ya hay otro conjunto de reglas con el mismo nombre.

Solución: los conjuntos de reglas son globales y es necesario que sean únicos.

Error: tablas con caracteres especiales

Mensaje de error: excepción en la clase de usuario: org.apache.spark.sql.AnalysisException: no se puede resolver “C” dado el conjunto de columnas de entrada: [primary.data_end_time, primary.data_start_time, primary.end_time, primary.last_updated, primary.message, primary.process_date, primary.rowhash, primary.run_by, primary.run_id, primary.start_time, primary.status]; línea 1 posición 44;.

Solución: actualmente existe una limitación que impide que Calidad de datos de AWS Glue se ejecute en tablas con caracteres especiales como “.”.

Error: error de desbordamiento con un conjunto de reglas grande

Mensaje de error: excepción en la clase de usuario: java.lang.StackOverflowError.

Solución: si tiene un conjunto de reglas grande de más de 2000 reglas, es posible que se produzca este problema. Divida sus reglas en varios conjuntos de reglas.

Error: el estado general de la regla falló

Condición de error: mi conjunto de reglas es correcto, pero el estado general de mi regla tiene errores.

Solución: lo más probable es que este error sea porque eligió la opción de publicar las métricas en Amazon CloudWatch mientras publicaba. Si su conjunto de datos está en una VPC, es posible que su VPC no permita que AWS Glue publique métricas en Amazon CloudWatch. En este caso, debe configurar un punto de conexión para que la VPC pueda acceder a Amazon CloudWatch.

AnalysisException: no es posible verificar la existencia de la base de datos predeterminada

Condición de error: AnalysisException: no se puede verificar la existencia de la base de datos predeterminada: com.amazonaws.services.glue.model.AccessDeniedException: permiso(s) de Lake Formation insuficiente(s) por defecto (servicio: AWS Glue; código de estado: 400; código de error: AccessDeniedException; ID de solicitud: XXXXXXXX-XXXX-XXXX-XXXX-XXXXXXXXXXXX; proxy: nulo)

Solución: en la integración del catálogo del trabajo de AWS Glue, AWS Glue siempre intenta comprobar si la base de datos predeterminada existe o no utiliza AWS Glue `GetDatabase API`. Cuando no se concede el permiso `DESCRIBE` de Lake Formation o se concede el permiso `GetDatabase IAM`, el trabajo falla al verificar la existencia de la base de datos predeterminada.

Para resolverlo:

1. Agregue el permiso `DESCRIBE` en Lake Formation para la base de datos predeterminada.
2. Configure el rol de IAM asociado al trabajo de AWS Glue como creador de bases de datos en Lake Formation. Esto creará automáticamente una base de datos predeterminada y otorgará los permisos de Lake Formation necesarios para el rol.
3. Deshabilite la opción `--enable-data-catalog`. (Se muestra como Usar Data Catalog como metaalmacén de Hive en AWS Glue Studio).

   Si no necesita la integración Data Catalog de Spark SQL en el trabajo, puede desactivarlo.

Mensaje de error: el mapa de teclas proporcionado no es adecuado para determinados marcos de datos

Condición de error: el mapa de teclas dado no es adecuado para determinados marcos de datos.

Solución: utiliza el tipo de regla DataSetMatch y las claves de unión están duplicadas. Las claves de unión deben ser únicas y no deben ser NULAS. En los casos en los que no pueda tener claves de unión que sean únicas, considere la posibilidad de usar otros tipos de reglas, como AggregateMatch, para hacer coincidir los datos de resumen.

Excepción en la clase de usuario: java.lang.RuntimeException: no fue posible recuperar los datos. Para obtener más información, consulte los registros en CloudWatch

Condición de error: excepción en la clase de usuario: java.lang.RuntimeException: no fue posible recuperar los datos. Para obtener más información, consulte los registros de CloudWatch.

Solución: esto sucede cuando crea reglas de calidad de datos en una tabla basada en Amazon S3 que se compara con Amazon RDS o Amazon Redshift. En estos casos, AWS Glue no puede cargar la conexión. En cambio, intente configurar la regla de calidad de datos en el conjunto de datos de Amazon Redshift o de Amazon RDS. Este es un error conocido.

ERROR DE INICIO: error al descargar desde S3 para bucket

Condición de error: ERROR DE INICIO: error durante la descarga desde S3 para bucket: `aws-glue-ml-data-quality-assets-us-east-1, key: jars/aws-glue-ml-data-quality-etl.jar.Access Denied (Service: Amazon S3; Status Code: 403; Please refer logs for details)` .

Solución: los permisos en el rol transferidos a Calidad de datos de AWS Glue deben permitir la lectura desde la ubicación de Amazon S3 previa. Esta política de IAM debe estar asociada con la función:

```
{
  "Sid": "allowS3",
  "Effect": "Allow",
  "Action": "s3:GetObject",
  "Resource": "arn:aws:s3:::aws-glue-ml-data-quality-assets-<region>/*"
```

```
}
```

Consulte la autorización de calidad de los datos para obtener información detallada sobre los permisos. Estas bibliotecas son necesarias para evaluar la calidad de los datos de sus conjuntos de datos.

InvalidInputException (estado: 400): las reglas de calidad de datos no se pueden analizar

Condición de error: InvalidInputException (estado: 400): las reglas de calidad de datos no se pueden analizar.

Solución: hay muchas posibilidades de que se produzca este error. Una posibilidad es que las reglas contengan comillas simples. Revise que sean comillas dobles. Por ejemplo:

```
Rules = [
ColumnValues "tipo_vinculo" in ["CODO", "DOCO", "COCO", "DODO"] AND "categoria" = 'ES'
    AND "cod_bandera" = 'CEP'
```

Cambie esto a:

```
Rules = [
(ColumnValues "tipovinculo" in [ "CODO", "DOCO", "COCO", "DODO"]) AND (ColumnValues
 "categoria" = "ES")
    AND (ColumnValues "codbandera" = "CEP")
]
```

Error: EventBridge no activa los trabajos de calidad de datos de Glue según la programación que configuré

Condición de error: EventBridge no activa trabajos de AWS Glue Data Quality según la programación que configuré.

Solución: es posible que el rol que activa el trabajo no tenga los permisos necesarios. Asegúrese de que el rol que usa para activar los trabajos tenga los permisos necesarios mencionados en la configuración de IAM necesaria para programar las ejecuciones de evaluación.

Errores de CustomSQL

Condición de error: `The output from CustomSQL must contain at least one column that matches the input dataset for AWS Glue Data Quality to provide row level results. The SQL query is a valid query but no columns from the SQL result are present in the Input Dataset. Ensure that matching columns are returned from the SQL`.

Solución: la consulta SQL es válida, pero asegúrese de seleccionar únicamente las columnas de la tabla principal. Se puede producir este error cuando selecciona funciones de agregación como sumar o contar en las columnas de la tabla principal.

Condición de error: `There was a problem when executing your SQL statement: cannot resolve "Col"`.

Solución: esta columna no está presente en la tabla principal.

Condición de error: `The columns that are returned from the SQL statement should only belong to the primary table. "In this case, some columns ( Col ) belong to reference table"`.

Solución: en las consultas SQL, cuando una la tabla principal con otras tablas de referencia, asegúrese de que la instrucción de selección solo contenga los nombres de las columnas de la tabla principal para generar resultados a nivel de fila para la tabla principal.

Reglas dinámicas

Condición de error: `Dynamic rules require job context, and cannot be evaluated in interactive session or data preview.`.

Causa: es posible que este mensaje de error aparezca en los resultados de la vista previa de datos o en otras sesiones interactivas cuando hay reglas de calidad de datos dinámicas en el conjunto de reglas. Las reglas dinámicas hacen referencia a métricas históricas asociadas con un nombre de trabajo y un contexto de evaluación determinados, por lo que no se pueden evaluar en sesiones interactivas.

Solución: Al ejecutar el trabajo de AWS Glue se generarán métricas históricas, a las que se podrá hacer referencia en futuras ejecuciones del mismo trabajo.

Condición de error:

- `[RuleType] rule only supports simple atomic operands in thresholds.`.
- `Function last not yet implemented for [RuleType] rule.`

Resolución: Por lo general, se aceptan reglas dinámicas para todos los tipos de reglas de DQDL en expresiones numéricas (consulte la referencia sobre DQDL). Sin embargo, algunas reglas que producen diversas métricas, como ColumnValues y ColumnLength, aún no se aceptan.

Condición de error: `Binary expression operands must resolve to a single number.`.

Causa: las reglas dinámicas aceptan expresiones binarias, como `RowCount > avg(last(5)) * 0.9`. En este caso, la expresión binaria es `avg(last(5)) * 0.9`. Esta regla es válida ya que ambos operandos, `avg(last(5))` y `0.9`, se resuelven en un solo número. Un ejemplo incorrecto es `RowCount > last(5) * 0.9`, ya que `last(5)` generará una lista que no se puede comparar de manera significativa con el recuento de filas actual.

Solución: use las funciones de agregación para reducir un operando con valores de lista a un solo número.

Condición de error:

- `Rule threshold results in list, and a single value is expected. Use aggregation functions to produce a single value. Valid example: sum(last(10)), avg(last(10)).`
- `Rule threshold results in empty list, and a single value is expected.`

Causa: es posible usar las reglas dinámicas para comparar alguna característica del conjunto de datos con sus valores históricos. La última función permite recuperar varios valores históricos, siempre que se dé un argumento entero positivo. Por ejemplo, `last(5)` recuperará los cinco últimos valores que se observaron en las ejecuciones de tareas de su regla.

Solución: es necesario utilizar una función de agregación para reducir estos valores a un solo número, para poder realizar una comparación significativa con el valor observado en la ejecución de tareas actual.

Ejemplos válidos:

- `RowCount >= avg(last(5))`

- `RowCount > last(1)`
- `RowCount < last()`

Ejemplo no válido: `RowCount > last(5)`.

Condición de error:

- `Function index used in threshold requires positive integer argument.`
- `Index argument must be an integer. Valid syntax example: RowCount > index(last(10, 2)), which means RowCount must be greater than third most recent execution from last 10 job runs.`

Solución: al crear reglas dinámicas, puede usar la función de agregación `index` para seleccionar un valor histórico de una lista. Por ejemplo, `RowCount > index(last(5)`: 1) comprobará si el recuento de filas observado en el trabajo actual es estrictamente superior al segundo recuento de filas más reciente observado en su trabajo. `index` está indexado a cero.

Condición de error: `IllegalArgumentException: Parsing Error: Rule Type: DetectAnomalies is not valid`.

Resolución: la detección de anomalías solo está disponible en la versión 4.0. de AWS Glue.

Condición de error: `IllegalArgumentException: Parsing Error: Unexpected condition for rule of type ... no viable alternative at input ...`.

Nota: `...` es dinámico. Ejemplo: `IllegalArgumentException: Parsing Error: Unexpected condition for rule of type RowCount with number return type, line 4:19 no viable alternative at input '>last'`.

Resolución: la detección de anomalías solo está disponible en la versión 4.0. de AWS Glue.

Excepción en la Clase de usuario: org.apache.spark.sql.AnalysisException: org.apache.hadoop.hive.ql.metadata.HiveException

Condición del error: `Exception in User Class: org.apache.spark.sql.AnalysisException: org.apache.hadoop.hive.ql.metadata.HiveException: Unable to fetch table mailpiece_submitted. StorageDescriptor#InputFormat cannot be null for`

`table: mailpiece_submitted (Service: null; Status Code: 0; Error Code: null; Request ID: null; Proxy: null)`

Causa: Apache Iceberg se utiliza en el Catálogo de datos de AWS Glue y el atributo de formato de entrada en el Catálogo de datos de AWS Glue está vació.

Solución: este problema se produce cuando se utiliza el tipo de regla CustomSQL en la regla de calidad de datos. Una forma de solucionarlo es utilizar “primario” o agregar el nombre del catálogo `glue_catalog.` a `<database>.<table> in Custom ruletype`.

UNCLASSIFIED_ERROR; IllegalArgumentException: Error de análisis: no se proporcionaron reglas ni analizadores, no hay una alternativa viable en la entrada

Condición del error: `UNCLASSIFIED_ERROR; IllegalArgumentException: Parsing Error: No rules or analyzers provided., no viable alternative at input`

Resolución: el DQDL no se puede analizar. Hay algunos casos en los que esto puede ocurrir. Si utiliza reglas compuestas, asegúrese de que estén entre paréntesis.

```
(RowCount >= avg(last(10)) * 0.6) and (RowCount <= avg(last(10)) * 1.4) instead of
      RowCount >= avg(last(10)) * 0.6 and RowCount <= avg(last(10)) * 1.4
```

Integración de datos de Amazon Q en AWS Glue

La integración de datos de Amazon Q en AWS Glue es una nueva capacidad de IA generativa de AWS Glue que permite a los ingenieros de datos y a los desarrolladores de ETL crear trabajos de integración de datos usando un lenguaje natural. Los ingenieros y desarrolladores pueden pedir a Amazon Q que cree trabajos, solucione problemas y responda a preguntas sobre AWS Glue y la integración de datos.

¿Qué es Amazon Q?

> **Note**
>
> Con tecnología de Amazon Bedrock: AWS implementa detección automática de abusos. Gracias a que la integración de datos de Amazon Q está integrada en Amazon Bedrock, los usuarios pueden aprovechar al máximo los controles implementados en Amazon Bedrock para reforzar la protección, la seguridad y el uso responsable de la inteligencia artificial (IA).

Amazon Q es un asistente conversacional con tecnología de inteligencia artificial (IA) generativa que puede ayudar a comprender, crear, extender y operar aplicaciones de AWS. El modelo que impulsa Amazon Q fue optimizado con contenidos de alta calidad de AWS para brindar respuestas más completas, accionables y referenciadas para acelerar la creación en AWS. Para obtener más información, consulte ¿Qué es Amazon Q?

¿En qué consiste la integración de datos de Amazon Q en AWS Glue?

La integración de datos de Amazon Q en AWS Glue incluye las siguientes capacidades:

- Chat: la integración de datos de Amazon Q en AWS Glue puede responder a preguntas en inglés en lenguaje natural sobre AWS Glue y los dominios de integración de datos, como los conectores de AWS Glue de origen y destino, los trabajos de AWS Glue ETL, el catálogo de datos, los rastreadores y AWS Lake Formation, y otras funciones, la documentación y las mejores prácticas. La integración de datos de Amazon Q en AWS Glue responde con instrucciones paso a paso e incluye referencias a sus fuentes de información.

- Generación de códigos de integración de datos: la integración de datos de Amazon Q en AWS Glue puede responder preguntas sobre los scripts de ETL de AWS Glue y generar códigos nuevos de acuerdo a una pregunta en lenguaje natural en inglés.
- Solución de problemas: la integración de datos de Amazon Q en AWS Glue está diseñada específicamente para ayudarlo aentender los errores en los trabajos de AWS Glue y presenta instrucciones paso a paso para identificar la causa y resolver los problemas.

> **Note**
>
> La integración de datos de Amazon Q en AWS Glue no usa el contexto de la conversación para generar respuestas futuras mientras dure la conversación. Cada conversación con la integración de datos de Amazon Q en AWS Glue es independiente de sus conversaciones anteriores o futuras.

¿Está trabajando con la integración de datos de Amazon Q en AWS Glue?

En el panel de Amazon Q, puede solicitarle a Amazon Q que genere un código para un script de ETL de AWS Glue o que responda una pregunta sobre las características de AWS Glue o sobre la resolución de un error. La respuesta será un script de ETL en PySpark junto a instrucciones paso a paso para personalizar, revisar y ejecutar el script. Para las preguntas, la respuesta se genera a partir de la base de conocimientos sobre integración de datos, con un resumen y una URL fuente como referencia.

Por ejemplo, puede pedir a Amazon Q que proporcione un script de Glue que lea de Snowflake, cambie el nombre de los campos y escriba en Redshift y, en respuesta, la integración de datos de Amazon Q en AWS Glue devolverá un script de trabajo de AWS Glue que puede llevar a cabo la acción solicitada. Puede revisar el código generado para asegurarse de que cumple la intención solicitada. Si cumple con lo solicitado, puede ejecutarlo como un trabajo de AWS Glue en producción. Puede solucionar los problemas de los trabajos pidiendo a la integración que explique los errores y fallos y que proponga soluciones. Amazon Q puede responder preguntas sobre AWS Glue o las prácticas recomendadas de integración de datos.

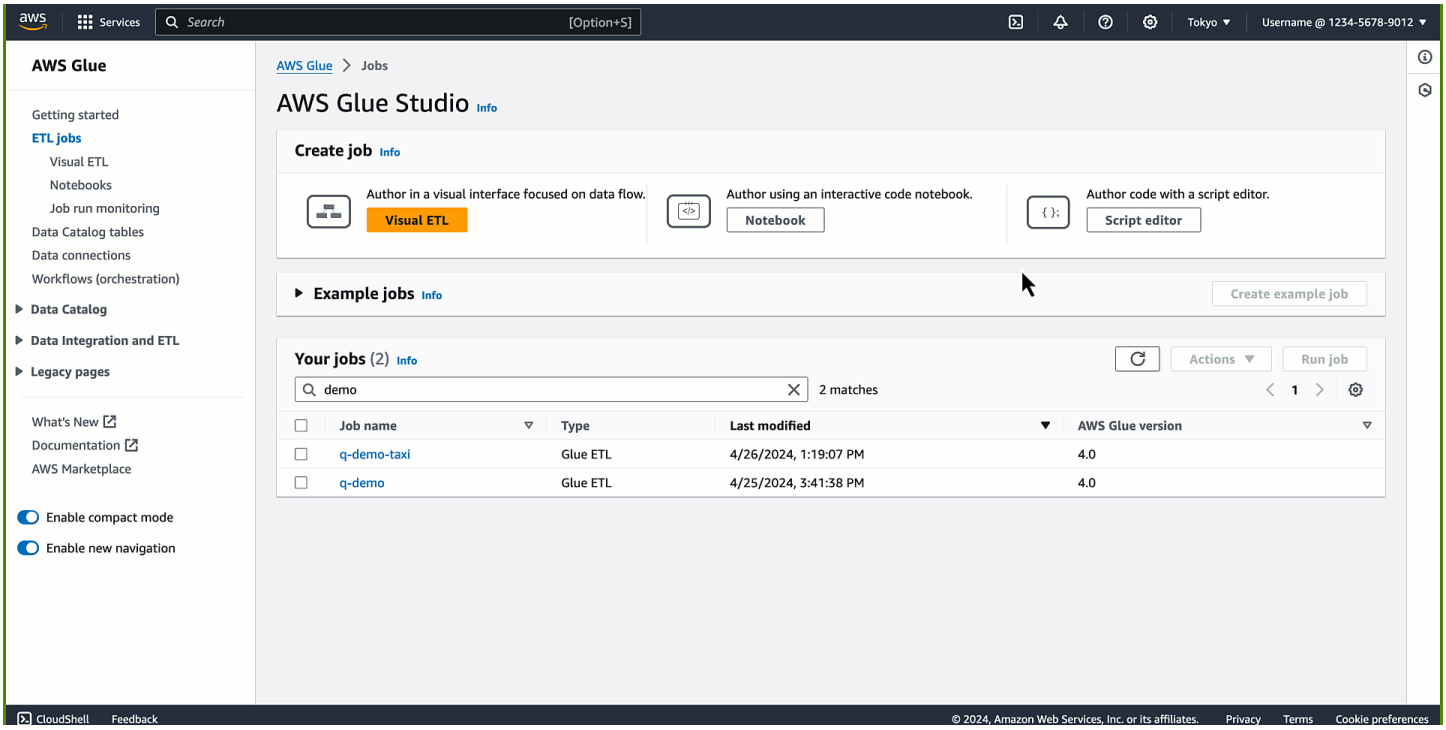

Los siguientes son ejemplos de preguntas que demuestran cómo la integración de datos de Amazon Q en AWS Glue puede ayudarlo a desarrollar AWS Glue:

Generación de código AWS Glue ETL:

- Escriba un script AWS Glue que lea JSON de S3, transforme los campos mediante la asignación de aplicaciones y escriba a Amazon Redshift
- ¿Cómo escribo un script AWS Glue para leer desde DynamoDB, aplicar la transformación DropNullFields y escribir en S3 como Parquet?
- Dame un script AWS Glue que lea desde MySQL, elimine algunos campos según mi lógica empresarial y escriba en Snowflake
- Escribir un trabajo AWS Glue para leerlo desde DynamoDB y escribir en S3 como JSON
- Ayúdame a desarrollar un script AWS Glue para el catálogo de datos de AWS Glue para S3
- Escribe un trabajo AWS Glue para leer JSON desde S3, elimina los nulos y escribe en Redshift

Explicaciones de las características de AWS Glue:

- ¿Cómo utilizo la Calidad de los datos de AWS Glue?
- ¿Cómo usar los marcadores de trabajo de AWS Glue?
- ¿Cómo habilito el escalado automático de AWS Glue?

- ¿Cuál es la diferencia entre los marcos dinámicos de AWS Glue y los marcos de datos de Spark?
- ¿Cuáles son los diferentes tipos de conexiones que AWS Glue admite?

Solución de problemas de AWS Glue:

- ¿Cómo solucionar los errores de falta de memoria (OOM) en los trabajos de AWS Glue?
- ¿Cuáles son algunos de los mensajes de error que puede ver al configurar la Calidad de los datos de AWS Glue y cómo puede solucionarlos?
- ¿Cómo arreglo un trabajo de AWS Glue con el error Acceso denegado a Amazon S3?
- ¿Cómo resuelvo problemas con la reorganización de datos en trabajos de AWS Glue?

Prácticas recomendadas para interactuar con la integración de datos de Amazon Q

Las siguientes son las prácticas recomendadas para interactuar con la integración de datos de Amazon Q:

- Cuando interactúe con la integración de datos de Amazon Q, formule preguntas específicas, repita cuando tenga solicitudes complejas y compruebe la precisión de las respuestas.
- Cuando proporcione peticiones de integración de datos en lenguaje natural, sea lo más específico posible para ayudar al asistente a entender exactamente lo que necesita. En lugar de preguntar “extraiga datos de S3”, proporcione más detalles, como “escriba un script de AWS Glue que extraiga archivos JSON de S3”.
- Revise el script generado antes de ejecutarlo para garantizar su precisión. Si el script generado contiene errores o no coincide con su intención, dé instrucciones al asistente sobre cómo corregirlo.
- La tecnología de IA generativa es nueva y puede haber errores (a veces denominados alucinaciones) en las respuestas. Pruebe y revise todo el código para detectar errores y vulnerabilidades antes de usarlo en su entorno o carga de trabajo.

Integración de datos de Amazon Q en la mejora del servicio de AWS Glue

Para ayudar a la integración de datos de Amazon Q en AWS Glue a proporcionar la información más relevante sobre los servicios de AWS, podemos utilizar cierto contenido de Amazon Q, como las preguntas que le hace a Amazon Q y sus respuestas, para mejorar el servicio.

Para obtener información sobre el contenido que utilizamos y cómo excluirlo, consulte Amazon Q Developer service improvement en la Guía del usuario para desarrolladores de Amazon Q.

Consideraciones

Tenga en cuenta los siguientes aspectos antes de utilizar la integración de datos de Amazon Q en AWS Glue:

- En la actualidad, la generación de códigos solo es compatible con el kernel de PySpark. El código generado es para trabajos de AWS Glue basados en Python Spark.
- Para obtener información sobre las combinaciones compatibles de capacidades de generación de código de la integración de datos de Amazon Q en AWS Glue, consulte Capacidades de generación de código compatibles.

Cómo configurar la integración de datos de Amazon Q en AWS Glue

En las siguientes secciones se ofrece información sobre la configuración de la integración de datos de Amazon Q en AWS Glue.

Temas

- Configuración de permisos de IAM

Configuración de permisos de IAM

En este tema se describen los permisos de IAM que se configuran para la experiencia de chat de Amazon Q y la experiencia del cuaderno AWS Glue Studio.

Temas

- Configuración de permisos de IAM para el chat de Amazon Q
- Permisos de IAM para cuadernos de AWS Glue Studio

Configuración de permisos de IAM para el chat de Amazon Q

La concesión de permisos a las API utilizadas en la integración de datos de Amazon Q en AWS Glue necesita los permisos de AWS Identity and Access Management (IAM) apropiados. Para obtener permisos, adjunte a su identidad de IAM (como el usuario, el rol o el grupo) la política de AWS personalizada que figura a continuación:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:StartCompletion",
        "glue:GetCompletion"
      ],
      "Resource": [
        "arn:aws:glue:*:*:completion/*"
      ]
    }
  ]
}
```

Permisos de IAM para cuadernos de AWS Glue Studio

Para habilitar la integración de datos de Amazon Q en los cuadernos de AWS Glue Studio, asegúrese de que el siguiente permiso esté asociado al rol de IAM de cuadernos:

> **Note**
>
> El prefijo `codewhisperer` es un nombre heredado de un servicio que se fusionó con Amazon Q Developer. Para obtener más información, consulte Amazon Q Developer rename - Resumen de cambios.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:StartCompletion",
        "glue:GetCompletion"
      ],
      "Resource": [
        "arn:aws:glue:*:*:completion/*"
      ]
    },
    {
      "Sid": "AmazonQDeveloperPermissions",
      "Effect": "Allow",
      "Action": [
        "codewhisperer:GenerateRecommendations"
      ],
      "Resource": "*"
    }
  ]
}
```

> **Note**
>
> La integración de datos de Amazon Q en AWS Glue no incluye API disponibles a través del SDK de AWS que pueda utilizar mediante programación. Las dos API siguientes se utilizan en la política de IAM para permitir esta experiencia a través del panel del chat de Amazon Q o cuadernos de AWS Glue Studio: `StartCompletion` y `GetCompletion`.

Asignación de permisos

Para dar acceso, agregue permisos a los usuarios, grupos o roles:

- Usuarios y grupos en AWS IAM Identity Center: Creación de un conjunto de permisos. Siga las instrucciones que se detallan en Creación de un conjunto de permisos en la Guía del usuario de AWS IAM Identity Center.
- Usuarios administrados en IAM a través de un proveedor de identidades: Creación de un rol para la federación de identidades. Siga las instrucciones descritas en Creación de un rol para un proveedor de identidad de terceros (federación) en la Guía del usuario de IAM.
- Usuarios de IAM:
  - Cree un rol que el usuario pueda aceptar. Siga las instrucciones descritas en Creación de un rol para un usuario de IAM en la Guía del usuario de IAM.
  - (No recomendado) Adjunte una política directamente a un usuario o añada un usuario a un grupo de usuarios. Siga las instrucciones descritas en Adición de permisos a un usuario (consola) de la Guía del usuario de IAM.

Capacidades de generación de código compatibles

A continuación se muestran las combinaciones de las capacidades de generación de código de la integración de datos de Amazon Q.

Orígenes y destinos	Transformación
S3 con los siguientes tipos de formato: json, csv, parquet, hudi, delta	Drop (Eliminar)
AWS Glue Data Catalog	Agregado
Redlake	DropDuplicates
Amazon DynamoDB	Join
MySQL	Filtro
Oracle	RenameColumns
PostgresSQL	FillNull
Microsoft SQL Server	DropNull
Amazon DocumentDB / MongoDB	WithColumns

Orígenes y destinos	Transformación
Snowflake	Consulta de SQL
Google BigQuery	Unión
Teradata	Seleccionar
Amazon OpenSearch Service	
Vertica	
SAP HANA	
Amazon Redshift	

Interacciones de muestra

La integración de datos de Amazon Q en AWS Glue le permite ingresar su pregunta en el panel de Amazon Q. Puede ingresar una pregunta sobre la funcionalidad de la integración de datos de AWS Glue. Obtendrá una respuesta detallada, junto con los documentos de referencia.

Otro caso de uso es la generación de scripts de trabajo de AWS Glue ETL. Puede preguntar cómo ejecutar un trabajo de extracción, transformación y carga de datos. Obtendrá un script de PySpark generado.

Temas

- Interacciones del chat de Amazon Q
- Interacciones del cuaderno de AWS Glue Studio

Interacciones del chat de Amazon Q

En la consola de AWS Glue, comience a crear un nuevo trabajo y pídale a Amazon Q lo siguiente: “Crear un flujo ETL de Glue, establecer la conexión con dos tablas del catálogo de Glue denominadas venue y event en mi base de datos glue_db, unir los resultados en el campo venueid de venue y e_venueid de event y, a continuación, filtrar según el estado de venue con la condición venuestate=='DC' y escribir los datos en s3://amzn-s3-demo-bucket/codegen/BDB-9999/output/ en formato CSV”.

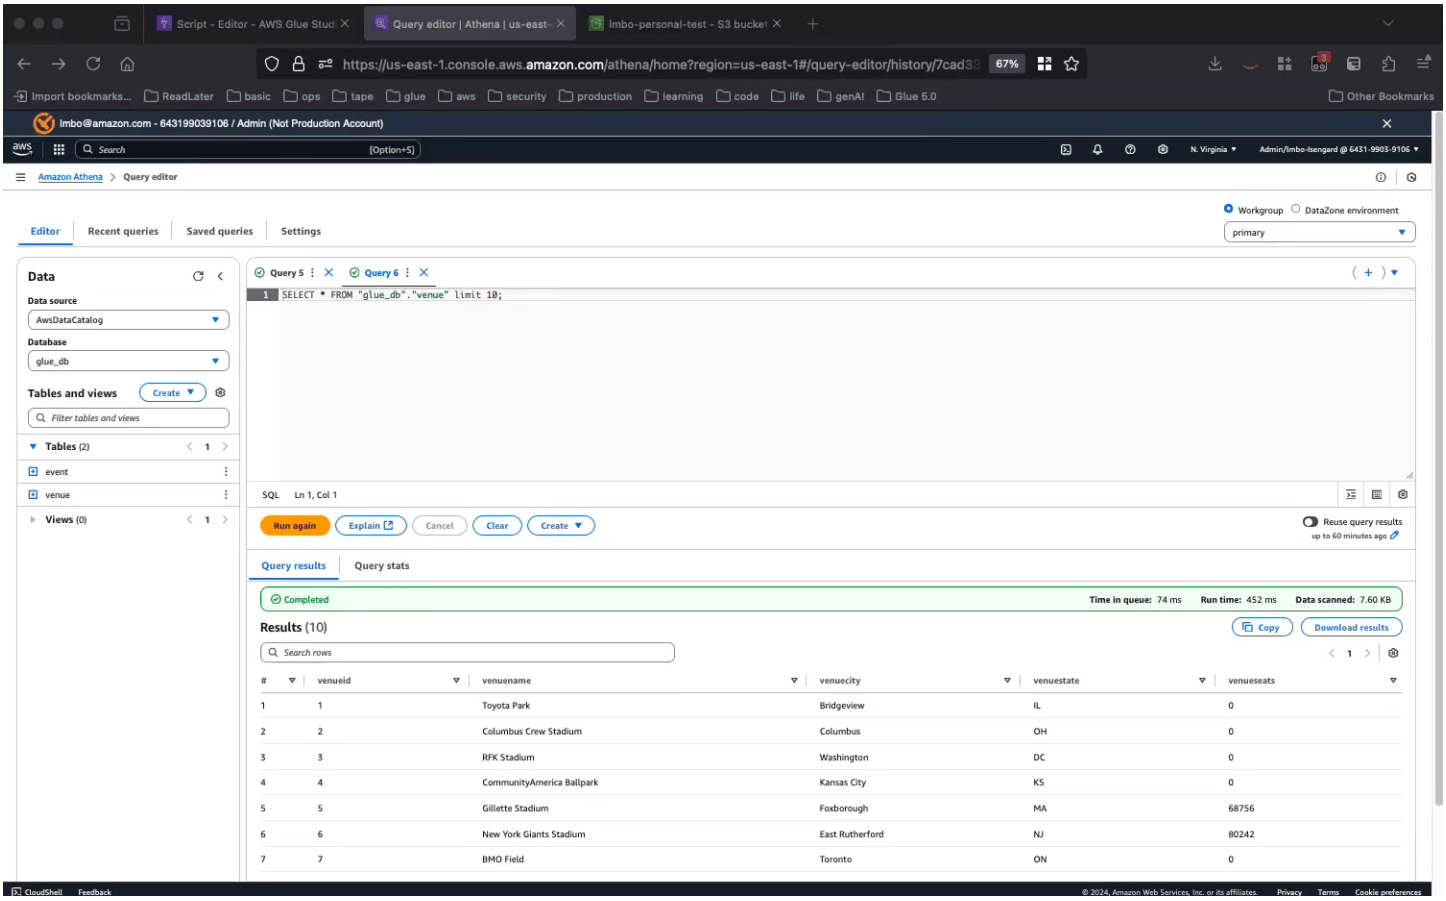

Observará que se ha generado el código. Con esta respuesta, puede aprender y comprender cómo crear código de AWS Glue para su finalidad específica. Puede copiar y pegar el código generado en el editor de scripts y configurar los marcadores de posición. Tras configurar un rol de IAM y conexiones de AWS Glue en el trabajo, guarde y ejecute el trabajo. Una vez que haya finalizado el trabajo, puede comprobar que los datos resumidos se conservan en Amazon S3 según lo previsto y que puede utilizarlos en sus cargas de trabajo posteriores.

Interacciones del cuaderno de AWS Glue Studio

> **Note**
>
> La experiencia de integración de datos de Amazon Q en el cuaderno de AWS Glue Studio sigue centrándose en el flujo de integración de datos basado en DynamicFrame.

Agregue una nueva celda e ingrese su comentario para describir lo que quiere lograr. Después de pulsar la tecla Tab e Intro, se muestra el código recomendado.

La primera intención es extraer los datos: “Deme un código que lea una tabla del Catálogo de datos de Glue”, seguido de “Deme un código para aplicar una transformación de filtro con star_rating>3” y “Deme un código que escriba el marco en S3 como Parquet”.

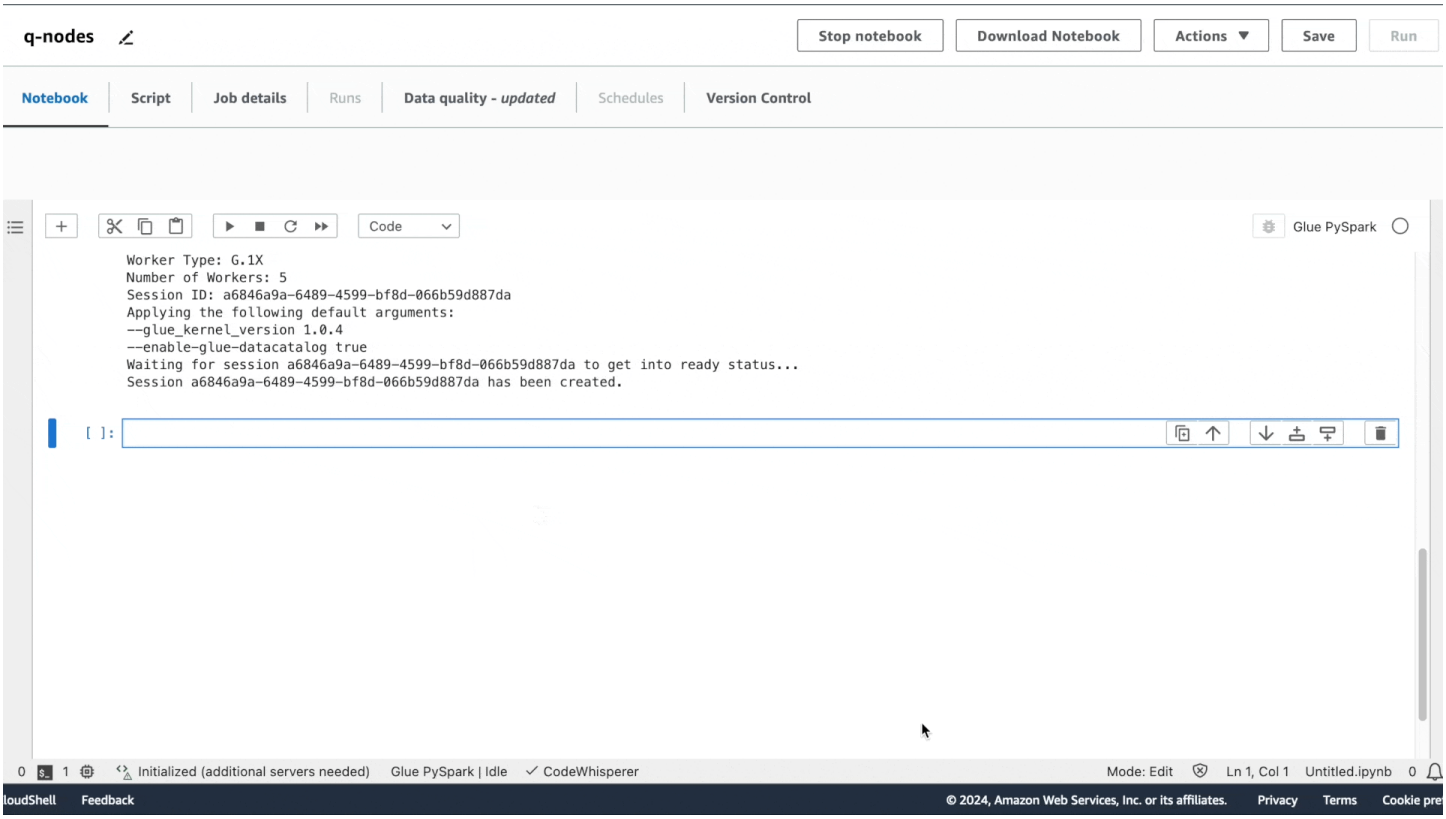

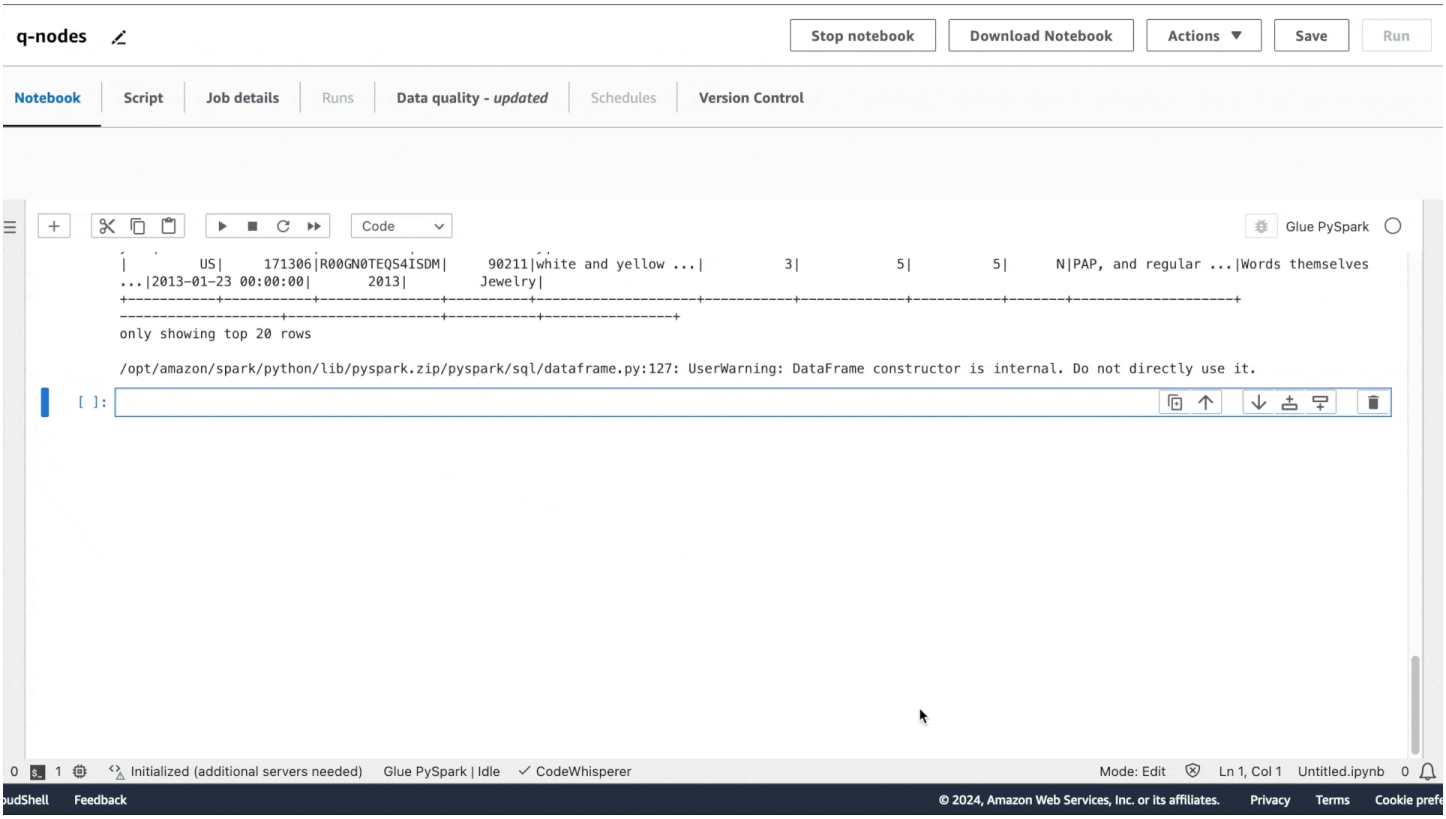
q-nodes
Stop notebook
Download Notebook
Actions
Save
Run
Notebook
Script
Job details
Runs
Data quality - updated
Schedules
Version Control
Code
Glue PySpark
only showing top 20 rows
/opt/amazon/spark/python/lib/pyspark.zip/pyspark/sql/dataframe.py:127: UserWarning: DataFrame constructor is internal. Do not directly use it.
[ ]:
Initialized (additional servers needed)
Glue PySpark | Idle
CodeWhisperer
Mode: Edit
Ln 1, Col 1
Untitled.ipynb
Feedback
© 2024, Amazon Web Services, Inc. or its affiliates.
Privacy
Terms

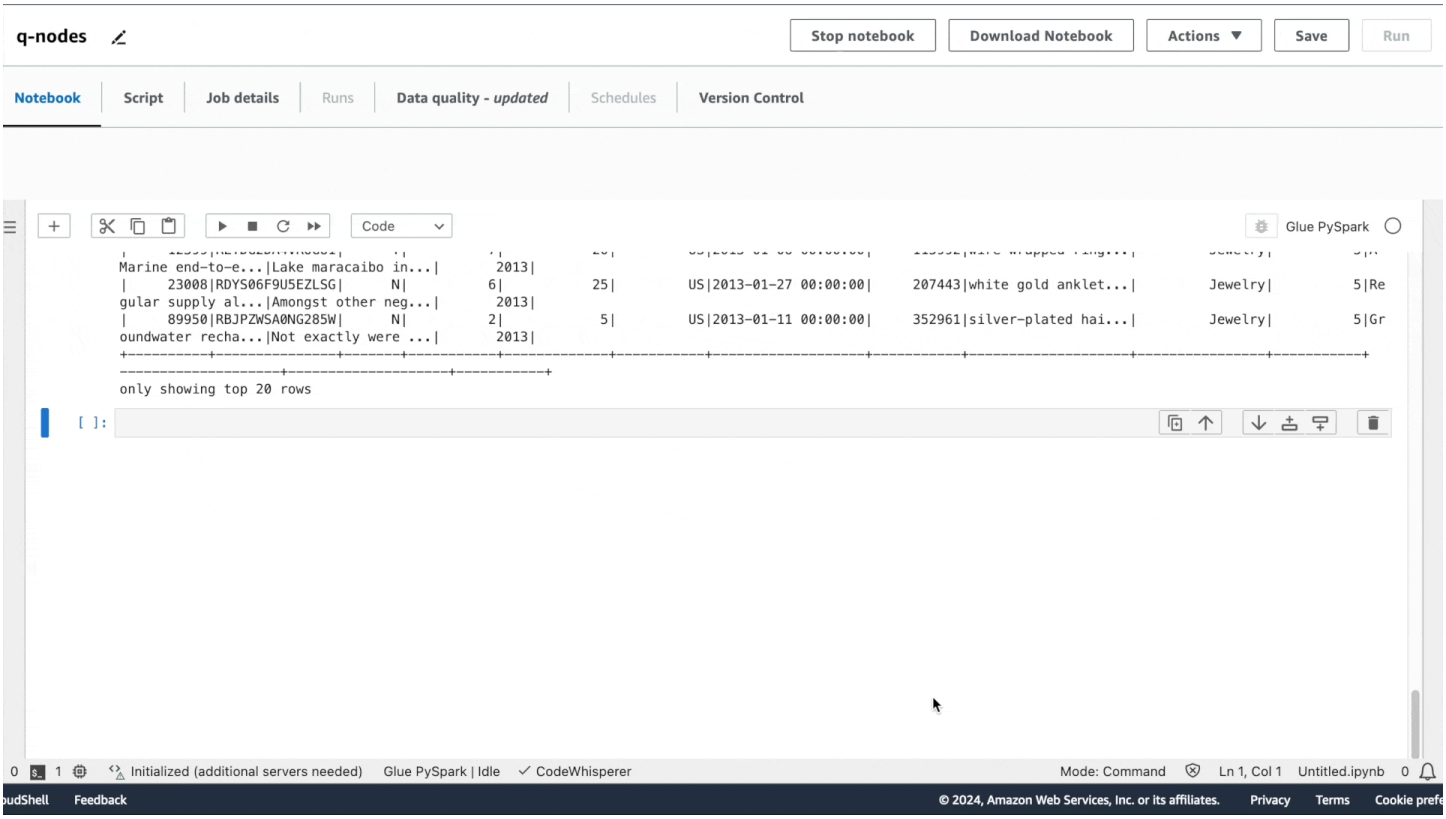
q-nodes
Stop notebook
Download Notebook
Actions
Save
Run
Notebook
Script
Job details
Runs
Data quality - updated
Schedules
Version Control
Code
Glue PySpark
only showing top 20 rows
[ ]:
Initialized (additional servers needed)
Glue PySpark | Idle
CodeWhisperer
Mode: Command
Ln 1, Col 1
Untitled.ipynb
Feedback
© 2024, Amazon Web Services, Inc. or its affiliates.
Privacy
Terms

Al igual que en la experiencia de chat de Amazon Q, se recomienda usar el código. Si presiona la tecla Tab, se elige el código recomendado.

Para ejecutar cada celda, puede rellenar las opciones apropiadas para sus orígenes en el código generado. En cualquier momento de las ejecuciones, también puede obtener una vista previa de una muestra de su conjunto de datos mediante el método `show()`.

Puede ejecutar el cuaderno como un trabajo, ya sea con la opción Ejecutar o mediante programación.

Peticiones complejas

Puede generar un script completo con una única petición compleja. “Tengo datos de JSON en S3 y datos de Oracle que es necesario combinar. Proporcione un script de Glue que lea ambos orígenes, lleve a cabo una unión y, a continuación, escriba los resultados en Redshift”.

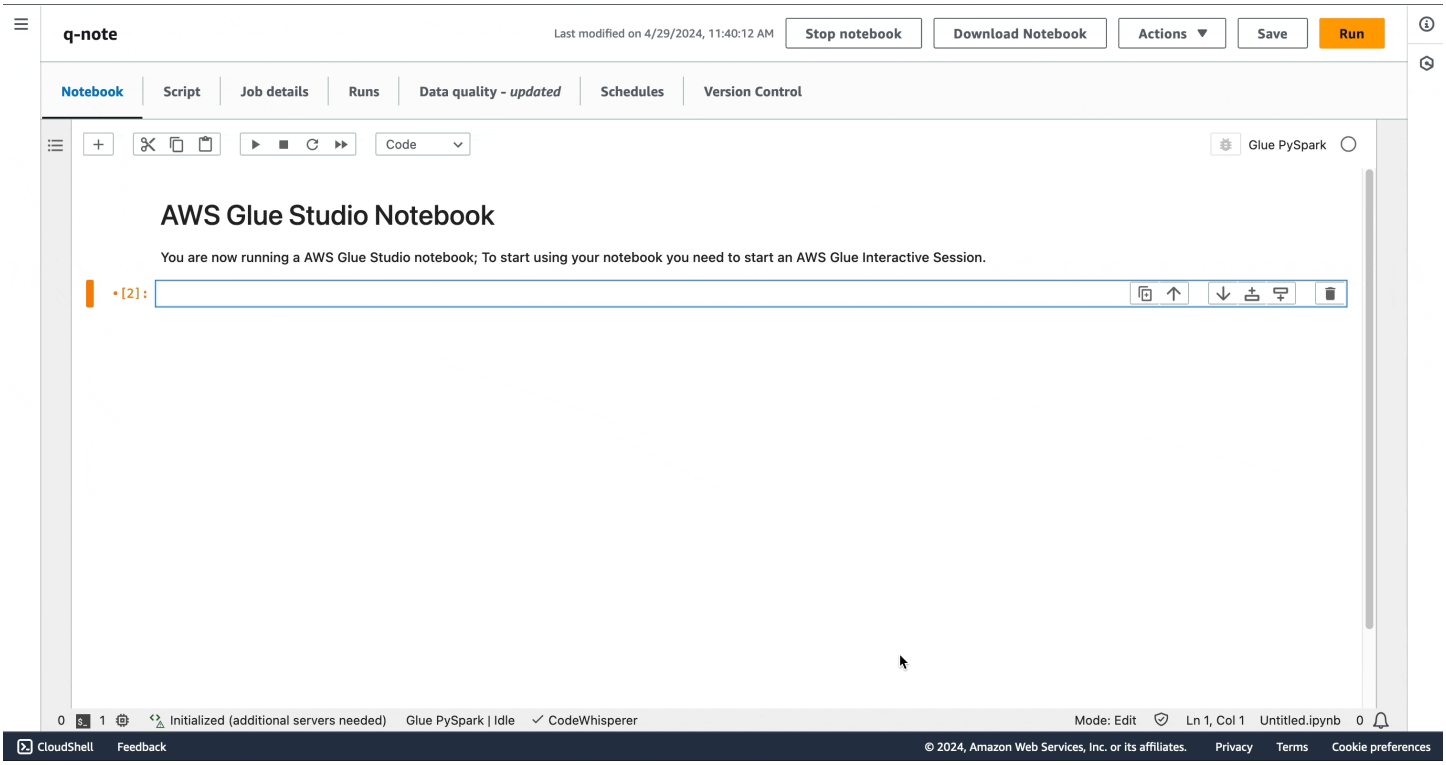

Puede observar que, en el cuaderno, la integración de datos de Amazon Q en AWS Glue generó el mismo fragmento de código que se generó en el chat de Amazon Q.

Puede ejecutar el cuaderno como un trabajo, ya sea a través de Ejecutar o mediante programación.

Uso del reconocimiento del contexto con la integración de datos de Amazon Q en AWS Glue

Ahora puede crear trabajos de procesamiento de datos de manera más eficiente mediante la generación de código DataFrame de PySpark y contextualizado basado en consultas en la integración de datos de Amazon Q. Por ejemplo, puede utilizar esta petición para generar el código de PySpark: “crear un trabajo para cargar los datos de ventas de la tabla de Redshift 'analytics.salesorder' con la conexión 'erp_conn', filtrar order_amount por debajo de 50 dólares y guardar los datos en Amazon S3 en formato parquet”.

Amazon Q generará el script en función de su petición y configurará el flujo de trabajo de integración de datos con los detalles que haya proporcionado en su pregunta, como configuraciones de conexión, detalles del esquema, nombres de bases de datos o tablas y especificaciones de columnas para transformaciones. La información confidencial, como las contraseñas de las opciones de conexión, se sigue redactando.

Si la petición no proporciona la información requerida, Amazon Q colocará marcadores de posición, para los que tendrá que actualizar el código generado con los valores adecuados antes de ejecutar el código.

A continuación, encontrará algunos ejemplos de cómo utilizar el reconocimiento del contexto.

Ejemplo: Interacciones

Lectura de un archivo de Amazon S3 y escritura en un bucket de Amazon S3

Petición: `Create an AWS Glue spark job that reads a file s3://amzn-s3-demo-bucket-input-bucket-name/input-filename.csv and saves it into the parquet file under directory s3://amzn-s3-demo-bucket-output-bucket-name/output-s3-prefix/`

```
import sys
from awsglue.transforms import *
from pyspark.context import SparkContext
from pyspark.sql import SparkSession

sc = SparkContext.getOrCreate()
spark = SparkSession.builder.getOrCreate()

# Script generated for node S3DataSource
```

```
S3DataSource_dsource1 = spark.read.format("csv").load(
    "s3://amzn-s3-demo-bucket-input-bucket-name/input-filename.csv"
)

# Script generated for node S3DataSink
S3DataSource_dsource1.write.format("parquet").mode("append").save(
    "s3://amzn-s3-demo-bucket-output-bucket-name/output-s3-prefix/"
)
```

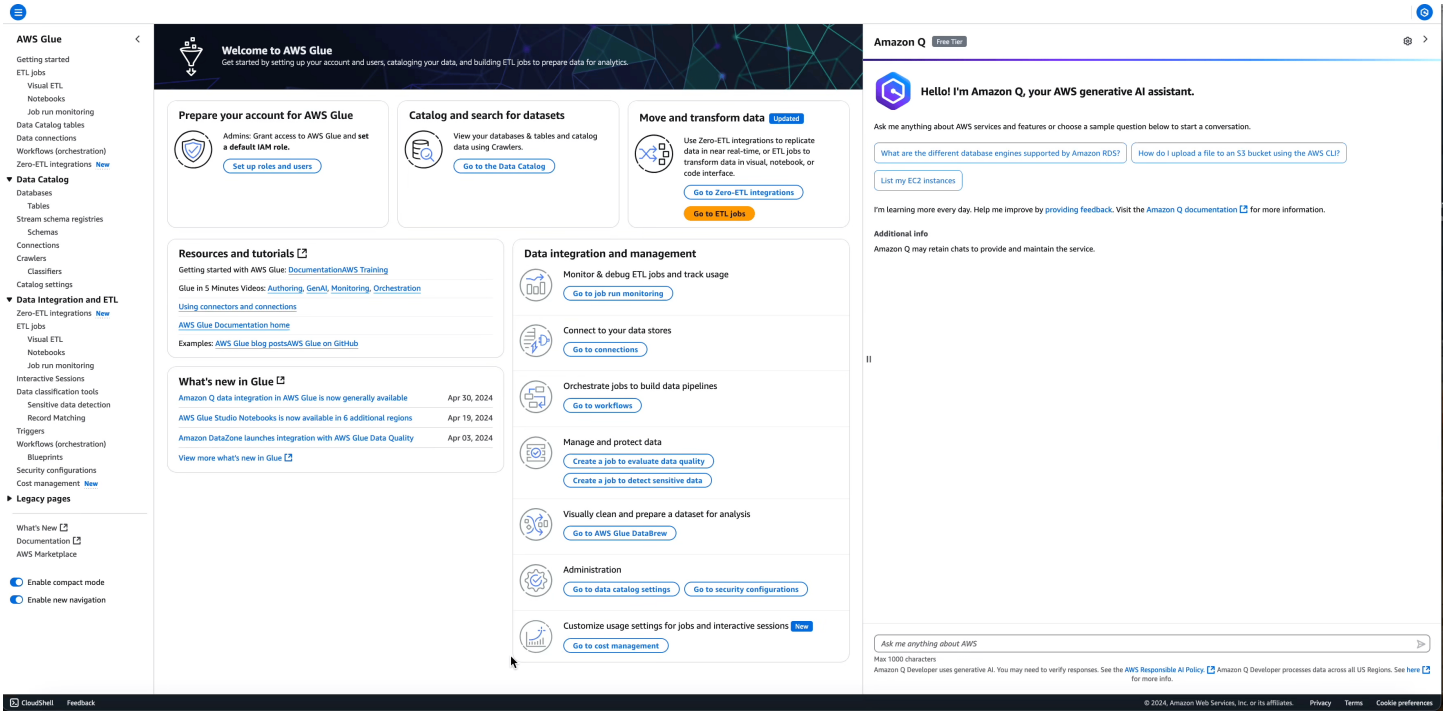

Obtención de datos de Lakehouse y escritura en una base de datos

Petición: `write an ETL script to read from a Lakehouse table my-table in database my-database and write it to a RDS MySQL table my-target-table`

En los campos en los que no se proporciona información (por ejemplo, el connectionName requerido es para el receptor de datos de MySQL y se completa de forma predeterminada con un marcador de posición <connection-name> en el código generado), se mantiene un marcador de posición para completar la información requerida antes de ejecutar el script.

Script generado:

```
import sys
from awsglue.transforms import *
from pyspark.context import SparkContext
```

```
from pyspark.sql import SparkSession
from connectivity.adapter import CatalogConnectionHelper

sc = SparkContext.getOrCreate()
spark = SparkSession.builder.getOrCreate()

# Script generated for node S3DataSource
S3DataSource_dsource1 = spark.read.format("parquet").load(
    "s3://amzn-lakehouse-demo-bucket/my-database/my-table"
)

# Script generated for node ConnectionV2DataSink
ConnectionV2DataSink_dsink1_additional_options = {"dbtable": "my-target-table"}
CatalogConnectionHelper(spark).write(
    S3DataSource_dsource1,
    "mysql",
    "<connection-name>",
    ConnectionV2DataSink_dsink1_additional_options,
)
```

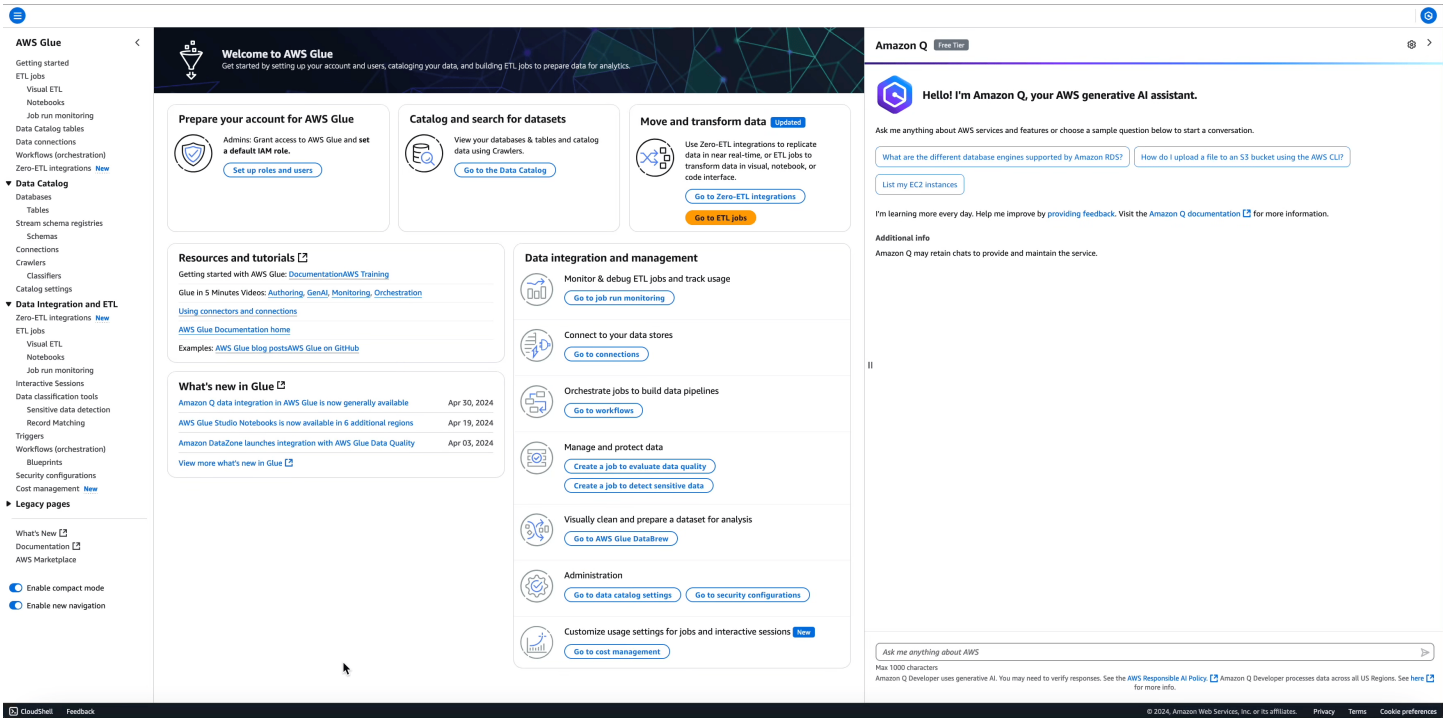

Ejemplo: Flujo de trabajo de ETL completo

En el siguiente ejemplo se muestra cómo puede pedirle a AWS Glue que cree un script de AWS Glue para completar un flujo de trabajo de ETL con la siguiente petición: `Create a AWS Glue`

`ETL Script read from two AWS Glue Data Catalog tables venue and event in my database glue_db_4fthqih3vvk1if, join the results on the field venueid, filter on venue state with condition as venuestate=='DC' after joining the results and write output to an Amazon S3 S3 location s3://amz-s3-demo-bucket/output/ in CSV format.`

El flujo de trabajo incluye la lectura de diferentes orígenes de datos (dos tablas del catálogo de datos de AWS Glue) y un par de transformaciones después de la lectura: se une el resultado de dos lecturas, se filtra en función de alguna condición y se escribe la salida transformada en un destino de Amazon S3 en formato CSV.

El trabajo generado completará la información detallada para el origen de datos, la operación de transformación y absorción de datos con la información correspondiente extraída de la pregunta del usuario, como se muestra a continuación.

```
import sys
from awsglue.transforms import *
from pyspark.context import SparkContext
from pyspark.sql import SparkSession

sc = SparkContext.getOrCreate()
spark = SparkSession.builder.getOrCreate()

# Script generated for node CatalogDataSource
CatalogDataSource_dsource1 = spark.sql("select * from
 `glue_db_4fthqih3vvk1if`.`venue`")

# Script generated for node CatalogDataSource
CatalogDataSource_dsource2 = spark.sql("select * from
 `glue_db_4fthqih3vvk1if`.`event`")

# Script generated for node JoinTransform
JoinTransform_transform1 = CatalogDataSource_dsource1.join(
    CatalogDataSource_dsource2,
    (CatalogDataSource_dsource1["venueid"] == CatalogDataSource_dsource2["venueid"]),
    "inner",
)

# Script generated for node FilterTransform
FilterTransform_transform2 = JoinTransform_transform1.filter("venuestate=='DC'")
```

```
# Script generated for node S3DataSink
FilterTransform_transform2.write.format("csv").mode("append").save(
    "s3://amz-s3-demo-bucket/output//output/"
)
```

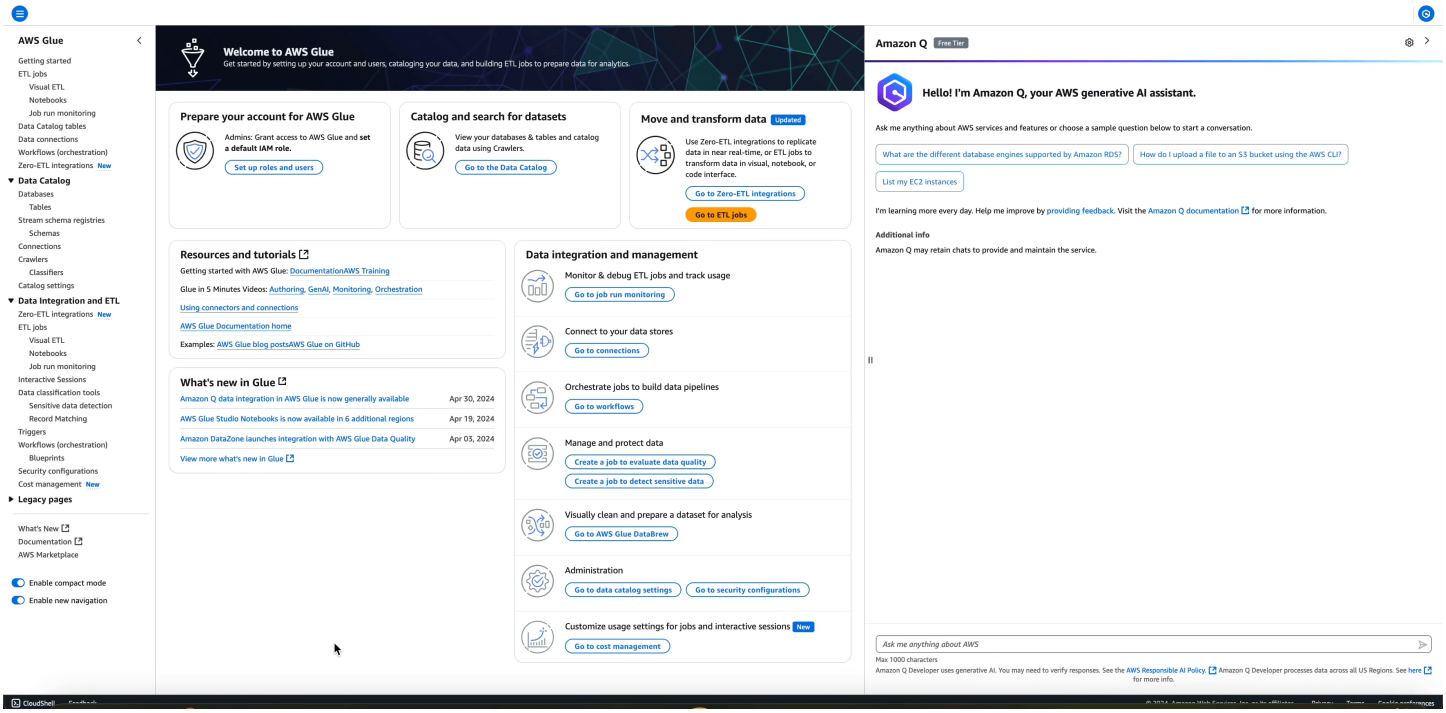

Limitaciones

- Traspaso de contexto:
  - La característica de reconocimiento del contexto solo transfiere el contexto de la consulta anterior del usuario dentro de la misma conversación. No retiene el contexto más allá de la consulta inmediatamente anterior.
- Compatibilidad para configuraciones de nodos:
  - Actualmente, el reconocimiento del contexto solo admite un subconjunto de las configuraciones requeridas de varios nodos.
  - La compatibilidad con campos opcionales está prevista en las próximas versiones.
- Disponibilidad:
  - El reconocimiento del contexto y la compatibilidad con DataFrame están disponibles en los cuadernos de Q Chat y SageMaker Unified Studio. Sin embargo, estas funciones aún no están disponibles en los cuadernos de AWS Glue Studio.

Orquestación en AWS Glue

En las siguientes secciones, se ofrece información acerca de la orquestación de los trabajos en AWS Glue.

Temas

- Inicio de trabajos y rastreadores mediante desencadenadores
- Realización de actividades de ETL complejas mediante esquemas y flujos de trabajo en AWS Glue
- Desarrollo de esquemas en AWS Glue

Inicio de trabajos y rastreadores mediante desencadenadores

En AWS Glue, puede crear objetos del Data Catalog denominados desencadenadores, que puede utilizar para iniciar en forma manual o automática uno o más rastreadores o trabajos de extracción, transformación y carga (ETL). Mediante los desencadenadores, puede diseñar una cadena de trabajos y rastreadores dependientes.

> **Note**
>
> Esto mismo se puede conseguir definiendo flujos de trabajo. Los flujos de trabajo son el método preferido para crear operaciones ETL multitarea complejas. Para obtener más información, consulte the section called “Realización de actividades de ETL complejas mediante esquemas y flujos de trabajo”.

Temas

- Disparadores de AWS Glue
- Agregado de desencadenadores
- Activación y desactivación de desencadenadores

Disparadores de AWS Glue

Cuando está activo, un desencadenador puede iniciar trabajos y rastreadores especificados. Un desencadenador se activa bajo demanda, en función de un calendario o en función de una combinación de eventos.

> **Note**
>
> Solo se pueden habilitar dos rastreadores con un solo desencadenador. Si desea rastrear varios almacenes de datos, utilice múltiples orígenes para cada rastreador en lugar de ejecutar varios rastreadores en forma simultánea.

Un desencadenador puede tener uno de varios estados. Los estados de un desencadenador son `CREATED`, `ACTIVATED` o `DEACTIVATED`. También hay estados de transición, como `ACTIVATING`. Para detener temporalmente la activación de un desencadenador, puede desactivarlo. Podrá reactivarlo más adelante.

Existen tres tipos de desencadenadores:

Programados

Un desencadenador con límite de tiempo basado en `cron`.

Puede crear un desencadenador para un conjunto de trabajos o rastreadores en función de un calendario. Puede especificar restricciones, como la frecuencia de ejecución de los trabajos o rastreadores, qué días de la semana se ejecutan y a qué hora. Estas restricciones se basan en `cron`. Al configurar un calendario para un desencadenador, debe tener en cuenta las características y limitaciones de cron. Por ejemplo, si decide ejecutar su rastreador el día 31 de cada mes, tenga en cuenta que algunos meses no tienen 31 días. Para obtener más información acerca de Cron, consulte Programaciones basadas en tiempo para trabajos y rastreadores.

Condicional

Desencadenador que se activa cuando un trabajo o rastreador anterior o varios trabajos o rastreadores satisfacen una lista de condiciones.

Cuando se crea un desencadenador condicional, se especifica una lista de trabajos y una lista de rastreadores que se deben vigilar. Para cada trabajo o rastreador vigilado, se especifica un estado de vigilancia, como éxito, error, tiempo de espera agotado, etc. El desencadenador se activa si los trabajos o los rastreadores observados terminan con los estados especificados. Puede configurar el desencadenador para que se active cuando se produzca alguno o todos los eventos observados.

Por ejemplo, podría configurar un desencadenador D1 para iniciar el trabajo T3 cuando tanto el trabajo T1 como el trabajo T2 se completen correctamente, y otro desencadenador D2 para iniciar el trabajo T4 si se produce un error en el trabajo T1 o en el trabajo T2.

En la tabla siguiente se enumeran los estados de finalización del trabajo y del rastreador (eventos) que los desencadenadores vigilan.

Estados de finalización del trabajo	Estados de finalización del rastreador
• `SUCCEEDED` • `STOPPED` • `FAILED` • `TIMEOUT`	• `SUCCEEDED` • `FAILED` • `CANCELLED`

Bajo demanda

Un desencadenador que se pone en marcha cuando se activa. Los desencadenadores bajo demanda nunca alcanzan el estado `DEACTIVATED` o `ACTIVATED`. Siempre permanecen en el estado `CREATED`.

Para que estén listos para activarse en cuanto se creen, puede configurar un indicador para activar los desencadenadores programados y condicionales en el momento de crearlos.

> **Important**
>
> Los trabajos o rastreadores que se ejecutan como resultado de la finalización de otros trabajos o rastreadores se denominan dependientes. Los trabajos o los rastreadores dependientes solo se inician si el trabajo o el rastreador que se completa se inició con un desencadenador. Todos los trabajos o rastreadores de una cadena de dependencia deben ser descendientes de un único desencadenador programado o bajo demanda.

Pasar parámetros de trabajo con desencadenadores

Un desencadenador puede pasar parámetros a los trabajos que inicia. Los parámetros incluyen argumentos de trabajo, valor de tiempo de espera y configuración de seguridad, entre otros. Si el desencadenador inicia varios trabajos, los parámetros se pasan a cada trabajo.

Estas son las reglas para los argumentos de trabajo pasados por un desencadenador:

- Si la clave del par de clave-valor coincide con un argumento de trabajo predeterminado, el argumento pasado invalida el argumento predeterminado. Si la clave no coincide con un argumento predeterminado, el argumento se pasa como un argumento adicional al trabajo.
- Si la clave del par de clave-valor coincide con un argumento no invalidable, se omite el argumento pasado.

Para obtener más información, consulte the section called “Desencadenadores” en la API de AWS Glue.

Agregado de desencadenadores

Puede agregar un desencadenador mediante la consola de AWS Glue, la AWS Command Line Interface (AWS CLI) o la API de AWS Glue.

Para agregar un desencadenador (consola)

1. Inicie sesión en la Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. En el panel de navegación, en ETL, elija Triggers (Desencadenadores). A continuación, elija Add trigger (Añadir desencadenador).
3. Proporcione las siguientes propiedades:

   Nombre

   Asigne un nombre único al disparador.

   Trigger type (Tipo de disparador)

   Especifique uno de los siguientes valores:

   - Schedule (Calendario): el desencadenador se activa a una frecuencia y hora específicas.
   - Job events (Eventos de trabajo): un desencadenador condicional. El desencadenador se activa cuando alguno o todos los trabajos de la lista coinciden con sus estados designados. Para que el desencadenador se active, un desencadenador debe haber iniciado los trabajos vigilados. Para cualquier trabajo que elija, solo puede vigilar un evento de trabajo (estado de finalización).
   - On-demand (Bajo demanda): el desencadenador se pone en marcha cuando se activa.
4. Complete el asistente para desencadenadores. En la página Review (Revisar), puede activar inmediatamente los desencadenadores de tipo Schedule (Calendario) y Job events (Eventos

de trabajo) (condicional) seleccionando Enable trigger on creation (Habilitar desencadenador al crearlo).

Para añadir un desencadenador (AWS CLI)

- Introduzca un comando similar al siguiente.

```
aws glue create-trigger --name MyTrigger --type SCHEDULED --schedule  "cron(0 12 *
 * ? *)" --actions CrawlerName=MyCrawler --start-on-creation
```

Este comando crea un desencadenador de programación llamado `MyTrigger`, que se ejecuta todos los días a las 12:00 h UTC e inicia un rastreador llamado `MyCrawler`. El desencadenador se crea en el estado activado.

Para obtener más información, consulte the section called “Disparadores de AWS Glue”.

Programaciones basadas en tiempo para trabajos y rastreadores

Puede definir programaciones basadas en tiempo para los rastreadores y los trabajos en AWS Glue. La definición de estas programaciones utiliza sintaxis cron del tipo Unix. Debe utilizar el formato de hora universal coordinada (UTC) y la precisión mínima para una programación es 5 minutos.

Para obtener más información sobre cómo configurar trabajos y rastreadores para que se ejecuten en forma programada, consulte Inicio de trabajos y rastreadores mediante desencadenadores.

Expresiones cron

Las expresiones Cron tienen seis campos obligatorios, que están separados por un espacio en blanco.

Sintaxis

```
cron(Minutes Hours Day-of-month Month Day-of-week Year)
```

Campos	Valores	Caracteres comodín
Minutos	0–59	, - * /

Campos	Valores	Caracteres comodín
Horas	0–23	, - * /
Día del mes	1–31	, - * ? / L W
Mes	1–12 o ENE-DIC	, - * /
Día de la semana	1–7 o DOM-SÁB	, - * ? / L
Año	1970-2199	, - * /

Caracteres comodín

- El carácter comodín , (coma) incluye valores adicionales. En el campo `Month`, `JAN,FEB,MAR` incluiría enero, febrero y marzo.
- El carácter comodín - (guion) especifica los intervalos. En el campo `Day`, 1-15 incluiría los días del 1 al 15 del mes especificado.
- El * (asterisco) incluye todos los valores del campo. En el campo `Hours`, * incluiría cada hora.
- El comodín / (barra inclinada) especifica incrementos. En el campo `Minutes`, puede escribir **`1/10`** para especificar cada décimo minuto, empezando desde el primer minuto de la hora (por ejemplo, los minutos 11, 21 y 31, etc.).
- El comodín ? (signo de interrogación) especifica uno u otro. En el campo `Day-of-month` puede escribir 7 y si no le importa qué día de la semana era el séptimo, podría escribir ? en el campo Day-of-week.
- El comodín L en los campos `Day-of-month` o `Day-of-week` especifica el último día del mes o de la semana.
- El comodín W en el campo `Day-of-month` especifica un día de la semana. En el campo `Day-of-month`, `3W` especifica el día más cercano al tercer día de semana del mes.

Límites

- No se pueden especificar los campos `Day-of-month` y `Day-of-week` en la misma expresión Cron. Si especifica un valor en uno de los campos, debe utilizar un ? (signo de interrogación) en el otro.
- No se admiten las expresiones Cron que producen frecuencias superiores a 5 minutos.

Ejemplos

Cuando cree una programación, puede utilizar las siguientes cadenas Cron de ejemplo.

Minutos	Horas	Día del mes	Mes	Día de la semana	Año	Significado
0	10	*	*	?	*	Ejecutar a las 10:00 h (UTC) todos los días
15	12	*	*	?	*	Ejecutar a las 12:15 h (UTC) todos los días
0	18	?	*	MON-FRI	*	Ejecutar a las 18:00 h (UTC) de lunes a viernes
0	8	1	*	?	*	Ejecutar a las 08:00 horas (UTC) todos los primeros de mes
0/15	*	*	*	?	*	Ejecutar cada 15 minutos
0/10	*	?	*	MON-FRI	*	Ejecutar cada 10

Minutos	Horas	Día del mes	Mes	Día de la semana	Año	Significado
						minutos de lunes a viernes
0/5	8-17	?	*	MON-FRI	*	Ejecutar cada 5 minutos de lunes a viernes entre las 8.00 y las 17.55 h (UTC)

Por ejemplo, para ejecutarse en un programa diario a las 12:15 UTC, especifique:

```
cron(15 12 * * ? *)
```

Activación y desactivación de desencadenadores

Puede activar o desactivar un desencadenador mediante la consola de AWS Glue, la AWS Command Line Interface (AWS CLI) o la API de AWS Glue.

Para activar o desactivar un desencadenador (consola)

1. Inicie sesión en la Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. En el panel de navegación, en ETL, elija Triggers (Desencadenadores).
3. Active la casilla de verificación situada junto al desencadenador que desee y, en el menú Action (Acción) elija Enable trigger (Activar desencadenador) para activar el desencadenador o Disable trigger (Desactivar desencadenador) para desactivarlo.

Para activar o desactivar un desencadenador (AWS CLI)

- Especifique uno de los siguientes comandos.

```
aws glue start-trigger --name MyTrigger

aws glue stop-trigger --name MyTrigger
```

  Al iniciar un desencadenador se activa y al detenerlo se desactiva. Cuando activa un desencadenador bajo demanda, este se activa inmediatamente.

Para obtener más información, consulte the section called “Disparadores de AWS Glue”.

Realización de actividades de ETL complejas mediante esquemas y flujos de trabajo en AWS Glue

Es posible que algunos de los procesos complejos del servicio ETL (extracción, transformación y carga) de su organización se implementen de mejor manera con múltiples trabajos y rastreadores dependientes de AWS Glue. Con los flujos de trabajo de AWS Glue, puede diseñar un proceso de ETL complejo de múltiples trabajos, múltiples rastreadores que AWS Glue puede ejecutar y rastrear como una sola entidad. Después de crear un flujo de trabajo y especificar los trabajos, rastreadores y desencadenadores del flujo de trabajo, puede ejecutar el flujo de trabajo bajo demanda o en función de una programación.

Temas

- Información general de los flujos de trabajo en AWS Glue
- Creación y desarrollo manual de un flujo de trabajo en AWS Glue
- Inicio de un flujo de trabajo de AWS Glue a partir de un evento de Amazon EventBridge
- Visualizar los eventos de EventBridge que iniciaron un flujo de trabajo
- Ejecución y supervisión de un flujo de trabajo en AWS Glue
- Detener una ejecución de flujo de trabajo
- Reparar y reanudar la ejecución de un flujo de trabajo
- Obtención y configuración de propiedades de ejecución de flujo de trabajo en AWS Glue
- Consulta de flujos de trabajo mediante la AWS Glue API

- Restricciones de esquemas y flujos de trabajo en AWS Glue
- Solución de errores de esquema en AWS Glue
- Permisos de personas y roles para esquemas de AWS Glue

Información general de los flujos de trabajo en AWS Glue

En AWS Glue, puede utilizar flujos de trabajo para crear y visualizar actividades de extracción, transformación y carga (ETL) complejas que implican varios rastreadores, trabajos y desencadenadores. Cada flujo de trabajo administra la ejecución y monitoreo de todos sus trabajos y rastreadores. Un flujo de trabajo registra el progreso de ejecución y el estado, ya que ejecuta cada componente. Esto le proporciona información general de la tarea de mayor envergadura y los detalles de cada paso. La consola de AWS Glue ofrece una representación visual de un flujo de trabajo en forma de gráfico.

Puede crear un flujo de trabajo desde un proyecto de AWS Glue, o puede crear manualmente un flujo de trabajo un componente a la vez mediante la herramienta Consola de administración de AWS o AWS Glue API. Para obtener más información acerca de los esquemas, consulte the section called “Información general de los esquemas”.

Los desencadenadores dentro de los flujos de trabajo pueden habilitar los trabajos y rastreadores y pueden iniciarse cuando se completan los trabajos y rastreadores. Al usar desencadenadores, puede crear grandes cadenas de trabajos y rastreadores interdependientes. Además de los desencadenadores dentro de un flujo de trabajo que definen las dependencias de los trabajos y rastreadores, cada flujo de trabajo tiene un desencadenador de inicio. Existen tres tipos de desencadenadores de inicio:

- Programación: el flujo de trabajo se inicia según la programación que defina. La programación puede ser diaria, semanal, mensual, etc., o puede ser una programación personalizada basada en una expresión `cron`.
- Bajo demanda: el flujo de trabajo se inicia manualmente desde la consola de AWS Glue, la API o AWS CLI.
- Evento de EventBridge: el flujo de trabajo se inicia cuando se produce un único evento de Amazon EventBridge o un lote de eventos de Amazon EventBridge. Con este tipo de desencadenador, AWS Glue puede ser un consumidor de eventos en una arquitectura basada en eventos. Cualquier tipo de evento de EventBridge puede iniciar un flujo de trabajo. Un caso de uso común es la llegada de un nuevo objeto en un bucket de Amazon S3 (la operación `PutObject` de S3).

Iniciar un flujo de trabajo con un lote de eventos significa esperar hasta que se haya recibido un número especificado de eventos o hasta que haya transcurrido un tiempo especificado. Al crear el desencadenador de eventos EventBridge, puede especificar condiciones de lote de forma opcional. Si especifica condiciones de lote, debe especificar el tamaño del lote (número de eventos) y puede especificar una ventana de lote (número de segundos) si lo desea. La ventana por lotes predeterminada y máxima es de 900 segundos (15 minutos). La condición del lote que se cumpla primero inicia el flujo de trabajo. La ventana del lote se inicia cuando llega el primer evento. Si no especifica las condiciones de lote al crear un desencadenador, el tamaño predeterminado del lote es 1.

Cuando se inicia el flujo de trabajo, las condiciones del lote se restablecen y el desencadenador de eventos comienza a comprobar si se cumple la siguiente condición de lote para volver a iniciar el flujo de trabajo.

En la siguiente tabla se muestra cómo el tamaño del lote y la ventana del lote funcionan juntos para habilitar un flujo de trabajo.

Tamaño de lote	Ventana del lote	Condición desencadenante resultante
10		El flujo de trabajo se desencadena ante la llegada de 10 eventos EventBridge, o 15 minutos después de la llegada del primer evento, lo que ocurra primero. (Si no se especifica el tamaño de ventana, el valor predeterm inado es de 15 minutos).
10	2 minutos	El flujo de trabajo se desencadena ante la llegada de 10 eventos EventBridge, o 2 minutos después de la llegada del primer evento, lo que ocurra primero.
1		El flujo de trabajo se desencadena ante la llegada del primer evento. El tamaño de la ventana es irrelevan te. Si no especifica las condiciones de lote al crear un desencadenador de evento EventBridge, el tamaño predeterminado del lote es 1.

La operación de la API `GetWorkflowRun` devuelve la condición de lote que desencadenó el flujo de trabajo.

Independientemente de cómo se inicie un flujo de trabajo, puede especificar el número máximo de ejecuciones concurrentes de flujo de trabajo al crear el flujo de trabajo.

Si un evento o lote de eventos inicia una ejecución de flujo de trabajo que eventualmente falla, ese evento o lote de eventos ya no se considera para iniciar una ejecución de flujo de trabajo. Una nueva ejecución de flujo de trabajo se inicia sólo cuando llega el siguiente evento o lote de eventos.

> **Important**
>
> Limite la cantidad total de trabajos, rastreadores y desencadenadores de un flujo de trabajo a 100 o menos. Si incluye más de 100, es posible que se produzcan errores al intentar reanudar o detener las ejecuciones del flujo de trabajo.

No se iniciará una ejecución de flujo de trabajo si excede el límite de concurrencia establecido para el flujo de trabajo, aunque se cumpla la condición del evento. Se aconseja ajustar los límites de concurrencia del flujo de trabajo en función del volumen de eventos esperado. AWS Glue no reintenta ejecutar los flujos de trabajo que presentan errores debido a límites de concurrencia excedidos. Del mismo modo, se aconseja ajustar los límites de concurrencia para trabajos y rastreadores dentro de flujos de trabajo en función del volumen de eventos esperado.

Propiedades de ejecución del flujo de trabajo

Para compartir y administrar el estado en toda la ejecución de flujo de trabajo, puede definir propiedades de ejecución de flujo de trabajo predeterminadas. Estas propiedades, que son pares nombre-valor, están disponibles para todos los trabajos en el flujo de trabajo. Utilice la AWS Glue API para recuperar las propiedades de ejecución de flujo de trabajo y modifíquelas para los trabajos que vengan después en el flujo de trabajo.

Gráfico del flujo de trabajo

La imagen siguiente muestra el gráfico de un flujo de trabajo básico en la consola de AWS Glue. Su flujo de trabajo podría tener decenas de componentes.

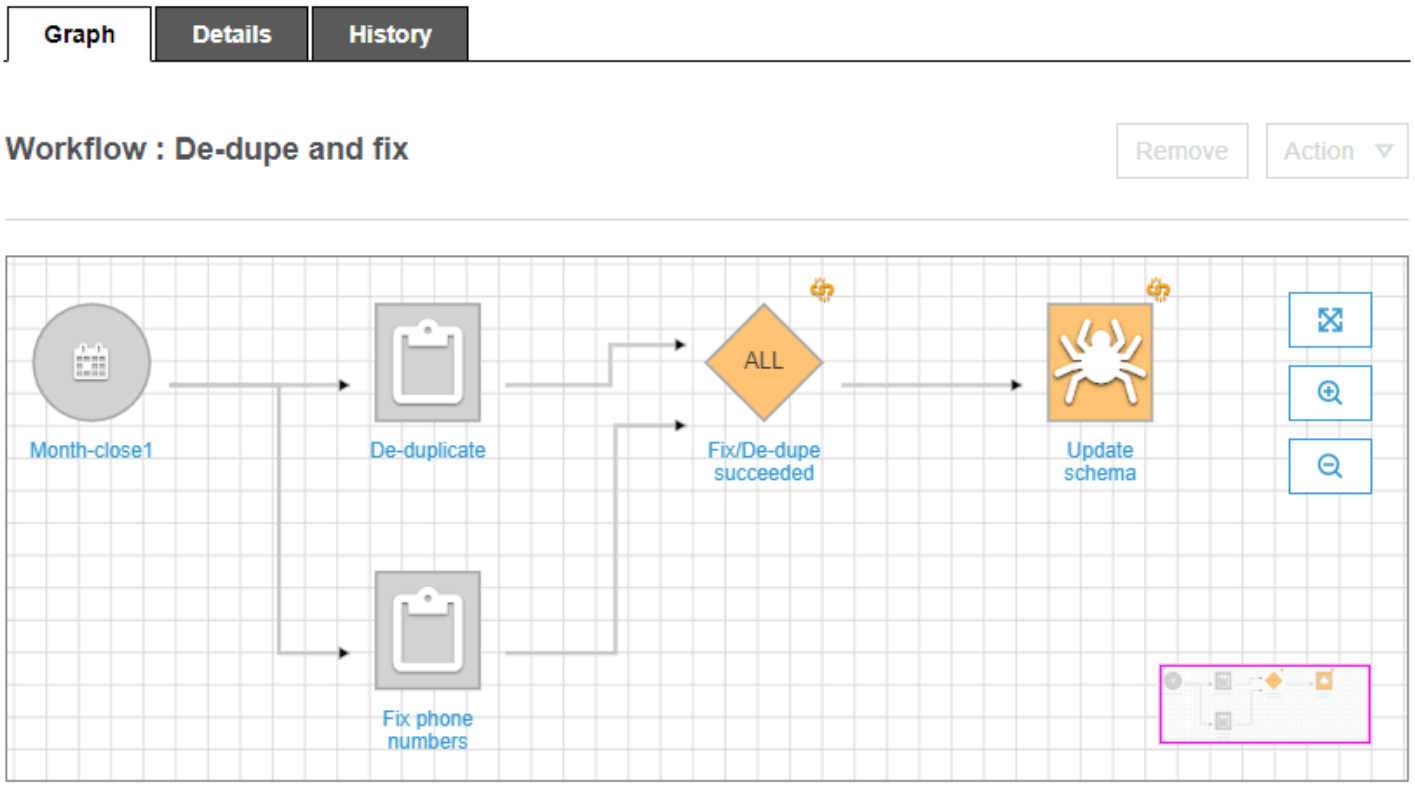

Este flujo de trabajo se inicia mediante un desencadenador de programación, `Month-close1`, que inicia dos trabajos, `De-duplicate` y `Fix phone numbers`. Tras la realización completa de ambos trabajos, un desencadenador de eventos, `Fix/De-dupe succeeded`, inicia un rastreador, `Update schema`.

Vistas de flujo de trabajo estáticas y dinámicas

Para cada flujo de trabajo hay una noción de vista estática y dinámica. La vista estática indica el diseño del flujo de trabajo. La vista dinámica es una vista de tiempo de ejecución que incluye la información de ejecución más reciente para cada uno de los trabajos y rastreadores. La información de ejecución incluye detalles sobre el error y el estado de success (correcto).

Cuando un flujo de trabajo se encuentra en ejecución, la consola muestra la vista dinámica, que indica gráficamente los trabajos completados y que todavía se tienen que ejecutar. También puede recuperar una vista dinámica de un flujo de trabajo en ejecución mediante la AWS Glue API. Para obtener más información, consulte Consulta de flujos de trabajo mediante la AWS Glue API.

Véase también

- the section called “Creación de un flujo de trabajo a partir de un esquema”

- the section called “Creación y desarrollo manual de un flujo de trabajo”
- Flujos de trabajo (para la API de flujos de trabajo)

Creación y desarrollo manual de un flujo de trabajo en AWS Glue

Puede usar la consola de AWS Glue para crear y construir un flujo de trabajo un nodo a la vez de forma manual.

Un flujo de trabajo contiene trabajos, rastreadores y desencadenadores. Antes de crear un flujo de trabajo de forma manual, cree los trabajos y rastreadores que el flujo de trabajo vaya a incluir. Es mejor especificar rastreadores de ejecución bajo demanda para los flujos de trabajo. Puede crear nuevos desencadenadores mientras se desarrolla su flujo de trabajo o puede clonar desencadenadores existentes en el flujo de trabajo. Al clonar un desencadenador, se agregan al flujo de trabajo todos los objetos del catálogo asociados al desencadenador (los trabajos o rastreadores que lo activan y los trabajos o rastreadores que lo inician).

> **Important**
>
> Limite la cantidad total de trabajos, rastreadores y desencadenadores de un flujo de trabajo a 100 o menos. Si incluye más de 100, es posible que se produzcan errores al intentar reanudar o detener las ejecuciones del flujo de trabajo.

Puede diseñar su propio flujo de trabajo añadiendo desencadenadores al gráfico de flujo de trabajo y definiendo los eventos vistos y las acciones para cada desencadenador. Comience con un desencadenador de arranque, que puede ser un desencadenador bajo demanda o programado, y complete el gráfico añadiendo desencadenadores de eventos (condicional).

Paso 1: Crear el flujo de trabajo

1. Inicie sesión en la Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. En el panel de navegación, en ETL, elija Workflows (Flujos de trabajo).
3. Seleccione Add workflow (Añadir flujo de trabajo) y complete el formulario Add a new ETL workflow (Añadir un nuevo flujo de trabajo de ETL).

Las propiedades de ejecución predeterminadas opcionales que añada estarán disponibles como argumentos para todos los trabajos en el flujo de trabajo. Para obtener más información, consulte Obtención y configuración de propiedades de ejecución de flujo de trabajo en AWS Glue.

4. Seleccione Add workflow (Añadir flujo de trabajo).

   El nuevo flujo de trabajo aparecerá en la lista en la página Workflows (Flujos de trabajo).

Paso 2: Añadir un desencadenador de arranque

1. En la página Workflows (Flujos de trabajo), seleccione el nuevo flujo de trabajo. A continuación, en la parte inferior de la página, asegúrese de seleccionar la pestaña Graph (Gráfico).
2. Seleccione Add trigger (Añadir desencadenador), y en el cuadro de diálogo Add trigger (Añadir desencadenador), realice uno de los siguientes procedimientos:

   - Elija Clone existing (Clonación existente) y seleccione un desencadenador que clonar. A continuación, elija Add (Añadir).

     El desencadenador aparece en el gráfico, junto con los trabajos y los rastreadores que ve e inicia.

     Si ha seleccionado por error el desencadenador erróneo, seleccione el desencadenador en el gráfico y, a continuación, elija Remove (Eliminar).
   - Elija Add new (Añadir nuevo) y complete el formulario Add trigger (Añadir desencadenador).
     1. Para Trigger type (Tipo de desencadenador), seleccione Schedule (Programación), On demand (Bajo demanda), o bien EventBridge event (Evento de EventBridge).

        Para el tipo de desencadenador Schedule (Programación), elija una de las opciones en Frequency (Frecuencia). Seleccione Custom (Personalizado) e ingrese una expresión `cron`.

        Para el tipo de desencadenador EventBridge, ingrese Number of events (Número de eventos) (tamaño del lote) y, opcionalmente, ingrese Time delay (Tiempo de retraso) (ventana por lotes). Si omite Time delay (Tiempo de retraso), la ventana por lotes tiene un valor predeterminado de 15 minutos. Para obtener más información, consulte Información general de los flujos de trabajo en AWS Glue.
     2. Elija Add (Agregar).

El desencadenador aparece en el gráfico, junto con un nodo de marcador de posición (con la etiqueta Add node [Añadir nodo]). En el ejemplo a continuación, el desencadenador de inicio es un desencadenador de programación denominado `Month-close1`.

En este momento, el desencadenador no está guardado aún.

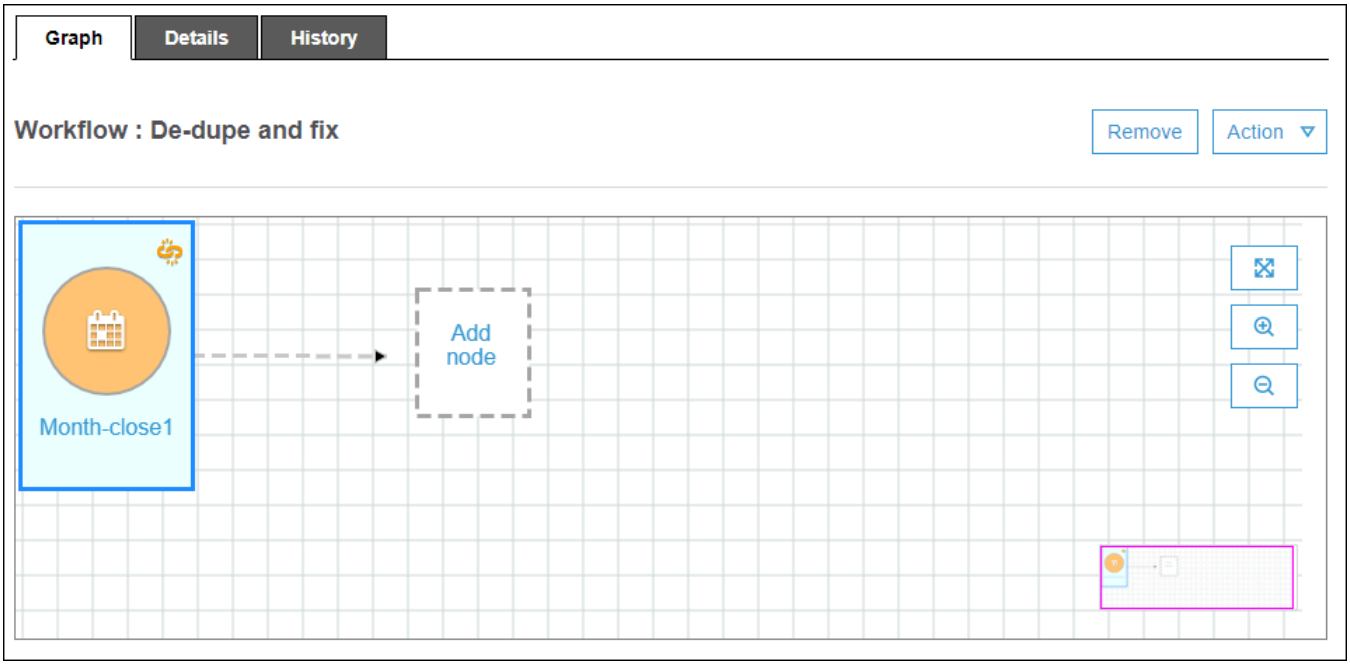

3. Si ha añadido un nuevo desencadenador, complete estos pasos:

   a. Realice una de las siguientes acciones:

      - Elija el nodo del marcador de posición (Add node [Añadir nodo]).
      - Asegúrese de que el desencadenador de arranque esté seleccionado, y en el menú Action (Acción) de arriba del gráfico, elija Add jobs/crawlers to trigger (Añadir trabajos/rastreadores al desencadenador).

   b. En el cuadro de diálogo Add jobs(s) and crawler(s) to trigger (Añadir trabajos y rastreadores al desencadenador), seleccione uno o más trabajos o desencadenadores y, a continuación, elija Add (Añadir).

      El desencadenador se guarda y los trabajos y rastreadores seleccionados aparecen en el gráfico con los conectores del desencadenador.

      Si ha añadido por error los trabajos y rastreadores erróneos, puede seleccionar el desencadenador o un conector y elegir Remove (Eliminar).

Paso 3: Agregar más desencadenadores

Continúe construyendo su flujo de trabajo al agregar más desencadenadores de tipo Event (Evento). Para ampliar o reducir la imagen, o para agrandar el lienzo del gráfico, utilice los iconos a la derecha del gráfico. Para agregar los desencadenadores, complete los siguientes pasos:

> **Note**
>
> No hay ninguna acción para guardar el flujo de trabajo. Después de agregar el último desencadenador y asignar acciones al desencadenador, el flujo de trabajo se completa y se guarda. Siempre puede volver más tarde y agregar más nodos.

1. Realice una de las siguientes acciones:

   - Para clonar un desencadenador existente, asegúrese de que no se selecciona ningún nodo en el gráfico y, en el menú Action (Acción), elija Add trigger (Añadir desencadenador).
   - Para añadir un nuevo desencadenador que vea un trabajo o rastreador determinado en el gráfico, seleccione el nodo de trabajo o rastreador y, a continuación, elija el nodo de marcador de posición Add trigger (Añadir desencadenador).

     Puede añadir más trabajos o rastreadores para ver este desencadenador en un paso posterior.
2. En el cuadro de diálogo Add trigger (Añadir desencadenador), realice una de las acciones siguientes:

   - Elija Add new (Añadir nuevo) y complete el formulario Add trigger (Añadir desencadenador). A continuación, elija Add (Añadir).

     El desencadenador aparece en el gráfico. Se completará el desencadenador en un paso posterior.
   - Elija Clone existing (Clonación existente) y seleccione un desencadenador que clonar. A continuación, elija Add (Añadir).

     El desencadenador aparece en el gráfico, junto con los trabajos y los rastreadores que ve e inicia.

     Si ha elegido por error el desencadenador erróneo, seleccione el desencadenador en el gráfico y, a continuación, elija Remove (Eliminar).

3. Si ha añadido un nuevo desencadenador, complete estos pasos:

   a. Seleccione el nuevo desencadenador.

      Como se muestra en el siguiente gráfico, se selecciona el desencadenador `De-dupe/fix succeeded`, y los nodos de marcador de posición aparecen para (1) eventos para ver y (2) acciones.

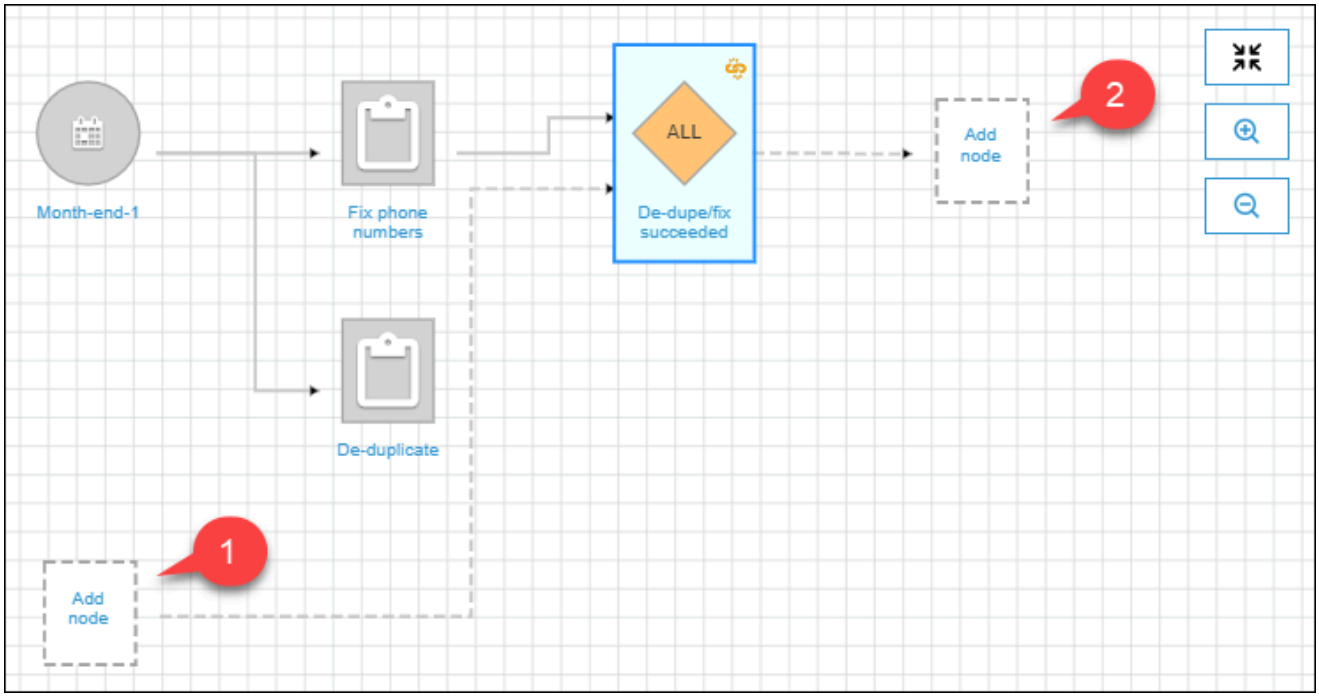

   b. (Opcional si el desencadenador ya ve un evento y desea añadir más trabajos o rastreadores que ver). Elija el nodo de marcador de posición de eventos que ver y, en el cuadro de diálogo Add job(s) and crawler(s) to watch (Añadir trabajos y rastreadores que ver), seleccione uno o más trabajos o rastreadores. Elija un evento que ver (SUCCEEDED (Correcto), FAILED (Erróneo), etc.), y elija Add (Añadir).

   c. Asegúrese de que se seleccione el desencadenador y elija el nodo de marcador de posición de acciones.

   d. En el cuadro de diálogo Add jobs(s) and crawler(s) to watch (Añadir trabajos y rastreadores que ver), seleccione uno o más trabajos o desencadenadores y, a continuación, elija Add (Añadir).

      Los trabajos y rastreadores seleccionados aparecen en el gráfico con los conectores del desencadenador.

Para obtener más información sobre flujos de trabajo y esquemas, consulte los siguientes temas.

- Información general de los flujos de trabajo en AWS Glue
- Ejecución y supervisión de un flujo de trabajo en AWS Glue
- Creación de un flujo de trabajo a partir de un esquema en AWS Glue

Inicio de un flujo de trabajo de AWS Glue a partir de un evento de Amazon EventBridge

Amazon EventBridge, también conocido como CloudWatch Events, le permite automatizar los servicios de AWS y responder automáticamente a eventos del sistema, como problemas de disponibilidad de aplicaciones o cambios de recursos. Los eventos de los servicios de AWS se envían a EventBridge casi en tiempo real. Puede crear reglas sencillas para indicar qué eventos le resultan de interés, así como qué acciones automatizadas se van a realizar cuando un evento cumple una de las reglas.

Con el soporte de EventBridge, AWS Glue puede funcionar como productor y consumidor de eventos en una arquitectura basada en eventos. Para los flujos de trabajo, AWS Glue soporta cualquier tipo de evento de EventBridge como consumidor. Es probable que el caso de uso más común sea la llegada de un nuevo objeto en un bucket de Amazon S3. Si tiene datos que llegan a intervalos irregulares o indefinidos, puede procesar estos datos lo más rápido posible luego de su llegada.

> **Note**
>
> AWS Glue no garantiza la entrega de mensajes de EventBridge. AWS Glue no realiza desduplicación si EventBridge entrega mensajes duplicados. Debe administrar la idempotencia en función del caso de uso.
> Asegúrese de configurar las reglas de EventBridge en forma correcta para evitar el envío de eventos no deseados.

Antes de empezar

Si desea iniciar un flujo de trabajo con eventos de datos de Amazon S3, debe asegurarse de que los eventos del bucket de S3 de interés se registren en AWS CloudTrail y EventBridge. Para ello, debe crear un seguimiento de CloudTrail. Para obtener más información, consulte Crear un seguimiento para su cuenta de AWS.

Para iniciar un flujo de trabajo con un evento de EventBridge

> **Note**
>
> En los siguientes comandos, sustituya:
>
> - *<workflow-name>* con el nombre que se va a asignar al flujo de trabajo.
> - *<trigger-name>* con el nombre que se va a asignar al desencadenador.
> - *<bucket-name>* con el nombre del bucket de Amazon S3.
> - *<account-id>* con un ID de cuenta de AWS válido.
> - *<region>* con el nombre de la región (por ejemplo, `us-east-1`).
> - *<rule-name>* con el nombre que se asignará a la regla de EventBridge.

1. Asegúrese de tener permisos de AWS Identity and Access Management (IAM) para crear y ver reglas y destinos de EventBridge. A continuación, se muestra una política de ejemplo que puede asociar. Es posible que desee reducir el alcance para poner límites a las operaciones y los recursos.

   JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "events:PutRule",
        "events:DisableRule",
        "events:DeleteRule",
        "events:PutTargets",
        "events:RemoveTargets",
        "events:EnableRule",
        "events:List*",
        "events:Describe*"
      ],
      "Resource": "*"
    }
  ]
```

```
}
```

2. Cree un rol de IAM que el servicio EventBridge pueda asumir al enviar un evento a AWS Glue.

   a. En la página Crear rol de la consola de IAM, elija Servicio de AWS. A continuación, elija el servicio CloudWatch Events (Eventos de CloudWatch).

   b. Finalice el asistente Create role (Creación de rol). El asistente adjunta automáticamente las políticas `CloudWatchEventsBuiltInTargetExecutionAccess` y `CloudWatchEventsInvocationAccess`.

   c. Asocie la siguiente política en línea al rol. Esta política permite que el servicio EventBridge dirija eventos a AWS Glue.

      JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:notifyEvent"
      ],
      "Resource": [
        "arn:aws:glue:us-east-1:111122223333:workflow/workflow-name"
      ]
    }
  ]
}
```

3. Ingrese el siguiente comando para crear el flujo de trabajo.

   Consulte crear flujo de trabajo en la Referencia de comandos de AWS CLI para obtener información acerca de los parámetros adicionales de línea de comandos opcionales.

```
aws glue create-workflow --name <workflow-name>
```

4. Ingrese el siguiente comando para crear un desencadenador de eventos de EventBridge para el flujo de trabajo. Este será el desencadenador de inicio del flujo de trabajo. Reemplace *<actions>* con las acciones a realizar (los trabajos y los rastreadores de inicio).

Consulte crear un desencadenador en la Referencia de comandos de AWS CLI para obtener información acerca de cómo codificar el argumento de `actions`.

```
aws glue create-trigger --workflow-name <workflow-name> --type EVENT --
name <trigger-name> --actions <actions>
```

Si desea que el flujo de trabajo se desencadene mediante un lote de eventos en lugar de un solo evento EventBridge, ingrese el siguiente comando en su lugar.

```
aws glue create-trigger --workflow-name <workflow-name> --type EVENT
 --name <trigger-name> --event-batching-condition BatchSize=<number-of-
events>,BatchWindow=<seconds> --actions <actions>
```

Para el argumento de `event-batching-condition`, se requiere el `BatchSize`, mientras que la `BatchWindow` es opcional. Si se omite `BatchWindow`, el valor predeterminado de la ventana es 900 segundos, que es el tamaño máximo de la ventana.

Example

En el ejemplo siguiente se crea un desencadenador que inicia el flujo de trabajo de `eventtest`, después de que hayan llegado tres eventos de EventBridge, o cinco minutos después de que llegue el primer evento, lo que ocurra primero.

```
aws glue create-trigger --workflow-name eventtest --type EVENT --name objectArrival
 --event-batching-condition BatchSize=3,BatchWindow=300 --actions JobName=test1
```

5. Cree una regla en Amazon EventBridge.

   a. Cree el objeto JSON para los detalles de la regla en el editor de texto que prefiera.

      El ejemplo a continuación indica que Amazon S3 es el origen del evento, `PutObject` es el nombre del evento y el nombre del bucket aparece como parámetro de solicitud. Esta regla inicia un flujo de trabajo cuando llega un nuevo objeto al bucket.

```
{
  "source": [
    "aws.s3"
  ],
  "detail-type": [
```

```
    "AWS API Call via CloudTrail"
  ],
  "detail": {
    "eventSource": [
      "s3.amazonaws.com"
    ],
    "eventName": [
      "PutObject"
    ],
    "requestParameters": {
      "bucketName": [
        "<bucket-name>"
      ]
    }
  }
}
```

Para iniciar el flujo de trabajo cuando un nuevo objeto llega a una carpeta dentro del bucket, puede sustituir el código siguiente por `requestParameters`.

```
    "requestParameters": {
      "bucketName": [
        "<bucket-name>"
      ]
      "key" : [{ "prefix" : "<folder1>/<folder2>/*"}}]
  }
```

b. Utilice su herramienta preferida para convertir el objeto JSON de regla en una cadena de escape.

```
{\n  \"source\": [\n    \"aws.s3\"\n  ],\n  \"detail-type\": [\n    \"AWS API
 Call via CloudTrail\"\n  ],\n  \"detail\": {\n    \"eventSource\": [\n
 \"s3.amazonaws.com\"\n    ],\n    \"eventName\": [\n      \"PutObject\"\n
  ],\n    \"requestParameters\": {\n      \"bucketName\": [\n        \"<bucket-
name>\"\n      ]\n    }\n  }\n}
```

c. Ejecute el siguiente comando para crear una plantilla de parámetros JSON que pueda editar para especificar los parámetros de entrada a un comando de `put-rule` posterior. Guarde el resultado en un archivo. En este ejemplo, el archivo se llama `ruleCommand`.

```
aws events put-rule --name <rule-name> --generate-cli-skeleton >ruleCommand
```

Para obtener más información sobre el parámetro `--generate-cli-skeleton`, consulte Generar esqueleto y parámetros de entrada de AWS CLI a partir de un archivo de entrada JSON o YAML en la Guía del usuario de la interfaz de línea de comandos de AWS.

El archivo resultante debe tener el siguiente aspecto.

```
{
    "Name": "",
    "ScheduleExpression": "",
    "EventPattern": "",
    "State": "ENABLED",
    "Description": "",
    "RoleArn": "",
    "Tags": [
        {
            "Key": "",
            "Value": ""
        }
    ],
    "EventBusName": ""
}
```

d. Edite el archivo para eliminar parámetros de manera opcional y para especificar como mínimo los parámetros de `Name`, `EventPattern` y `State`. Para el parámetro `EventPattern`, proporcione la cadena de escape para los detalles de la regla que creó en un paso anterior.

```
{
    "Name": "<rule-name>",
    "EventPattern": "{\n  \"source\": [\n    \"aws.s3\"\n  ],\n  \"detail-
type\": [\n    \"AWS API Call via CloudTrail\"\n  ],\n  \"detail\": {\n
 \"eventSource\": [\n      \"s3.amazonaws.com\"\n    ],\n    \"eventName\": [\n
      \"PutObject\"\n    ],\n    \"requestParameters\": {\n      \"bucketName
\": [\n        \"<bucket-name>\"\n      ]\n    }\n  }\n}",
    "State": "DISABLED",
    "Description": "Start an AWS Glue workflow upon new file arrival in an
 Amazon S3 bucket"
}
```

> **Note**
>
> Es mejor dejar la regla deshabilitada hasta que termine de crear el flujo de trabajo.

e. Ingrese el siguiente comando `put-rule`, que lee los parámetros de entrada del `ruleCommand` del archivo.

```
aws events put-rule --name <rule-name> --cli-input-json file://ruleCommand
```

El siguiente resultado indica éxito.

```
{
    "RuleArn": "<rule-arn>"
}
```

6. Ingrese el siguiente comando para adjuntar la regla a un destino. El destino es el flujo de trabajo en AWS Glue. Reemplace *<role-name>* con el rol que ha creado al principio de este procedimiento.

```
aws events put-targets --rule <rule-name> --targets
 "Id"="1","Arn"="arn:aws:glue:<region>:<account-id>:workflow/<workflow-
name>","RoleArn"="arn:aws:iam::<account-id>:role/<role-name>" --region <region>
```

El siguiente resultado indica éxito.

```
{
    "FailedEntryCount": 0,
    "FailedEntries": []
}
```

7. Confirme la conexión correcta de la regla y el destino al introducir el siguiente comando.

```
aws events list-rule-names-by-target --target-arn arn:aws:glue:<region>:<account-
id>:workflow/<workflow-name>
```

El siguiente resultado indica el éxito, donde *<rule-name>* es el nombre de la regla que creó.

```
{
    "RuleNames": [
```

```
        "<rule-name>"
    ]
}
```

8. Inicie sesión en la Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
9. Seleccione el flujo de trabajo y compruebe que el desencadenador de inicio y sus acciones (los trabajos o rastreadores que inicia) aparezcan en el gráfico del flujo de trabajo. Luego, continúe con el procedimiento en Paso 3: Agregar más desencadenadores. O agregue más componentes al flujo de trabajo mediante la API de AWS Glue o AWS Command Line Interface.
10. Cuando el flujo de trabajo esté completamente especificado, habilite la regla.

    ```
    aws events enable-rule --name <rule-name>
    ```

    El flujo de trabajo está ahora listo para ser iniciado por un evento de EventBridge o un lote de eventos.

> Véase también
>
> - Guía del usuario de Amazon EventBridge
> - Información general de los flujos de trabajo en AWS Glue
> - Creación y desarrollo manual de un flujo de trabajo en AWS Glue

Visualizar los eventos de EventBridge que iniciaron un flujo de trabajo

Puede ver el ID del evento de Amazon EventBridge que inició el flujo de trabajo. Si el flujo de trabajo se inició mediante un lote de eventos, puede ver los ID de eventos de todos los eventos del lote.

Para flujos de trabajo con un tamaño de lote mayor que uno, también puede ver qué condición de lote inició el flujo de trabajo: la llegada del número de eventos en el tamaño del lote o el vencimiento de la ventana del lote.

Para visualizar los eventos de EventBridge que iniciaron un flujo de trabajo (consola)

1. Inicie sesión en la Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.

2. En el panel de navegación, elija Workflows (Flujos de trabajo).
3. Seleccione el flujo de trabajo. Luego, en la parte inferior, elija la pestaña History (Historial).
4. Seleccione una ejecución de flujo de trabajo y, a continuación, elija View run details (Visualizar detalles de la ejecución).
5. En la página de detalles de la ejecución, localice el campo Run properties (Propiedades de la ejecución) y busque la clave was:eventIds.

   El valor de esa clave es una lista de ID de eventos de EventBridge.

Para visualizar los eventos de EventBridge que iniciaron un flujo de trabajo (API de AWS)

- Incluya el siguiente código en su script de Python.

```
workflow_params =
 glue_client.get_workflow_run_properties(Name=workflow_name,RunId=workflow_run_id)
batched_events = workflow_params['aws:eventIds']
```

  `batched_events` será una lista de cadenas, donde cada cadena es un ID de evento.

> Véase también
>
> - Guía del usuario de Amazon EventBridge
> - the section called “Descripción general de flujos de trabajo”

Ejecución y supervisión de un flujo de trabajo en AWS Glue

Si el desencadenador de inicio de un flujo de trabajo es un desencadenador bajo demanda, puede iniciar el flujo de trabajo desde la consola de AWS Glue. Siga los pasos a continuación para ejecutar y monitorear un flujo de trabajo. Si se produce un error en el flujo de trabajo, puede ver el gráfico de ejecución para determinar el nodo fallido. Para solucionar problemas, si el flujo de trabajo se creó a partir de un proyecto, puede visualizar la ejecución del proyecto para conocer los valores de parámetros del proyecto que se utilizaron para crear el flujo de trabajo. Para obtener más información, consulte the section called “Visualización de ejecuciones de esquemas”.

Puede ejecutar y monitorear un flujo de trabajo mediante la consola de AWS Glue, la API o AWS Command Line Interface (AWS CLI).

Para ejecutar y monitorear un flujo de trabajo (consola)

1. Abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. En el panel de navegación, en ETL, elija Workflows (Flujos de trabajo).
3. Seleccione un flujo de trabajo. En el menú Actions (Acciones), elija Run (Ejecutar).
4. Compruebe la columna Last run status (Estado de la última ejecución) en la lista de flujos de trabajo. Elija el botón de actualización para ver el estado del flujo de trabajo en curso.
5. Mientras el flujo de trabajo se está ejecutando o después de que se haya completado (o haya fallado), vea los detalles de ejecución a través de los pasos siguientes.

   a. Asegúrese de que se seleccione el flujo de trabajo y elija la pestaña History (Historial).

   b. Elija la ejecución del flujo de trabajo actual o más reciente y, a continuación, elija View run details (Ver detalles de la ejecución).

      El gráfico de tiempo de ejecución del flujo de trabajo muestra el estado actual de ejecución.

   c. Elija cualquier nodo del gráfico para ver los detalles y el estado del nodo.

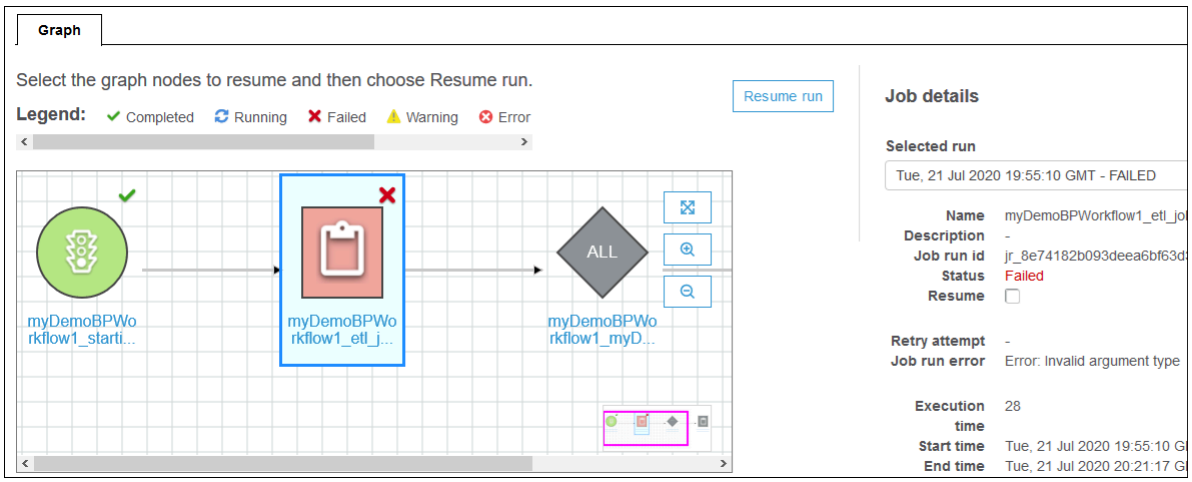

Para ejecutar y monitorear un flujo de trabajo (AWS CLI)

1. Escriba el siguiente comando. Reemplace *<workflow-name>* con el flujo de trabajo que se va a ejecutar.

```
aws glue start-workflow-run --name <workflow-name>
```

Si el flujo de trabajo se inicia correctamente, el comando devuelve el ID de ejecución.

2. Visualice el estado de ejecución del flujo de trabajo mediante el comando `get-workflow-run`. Proporcione el nombre e ID de ejecución del flujo de trabajo.

```
aws glue get-workflow-run --name myWorkflow --run-id
 wr_d2af14217e8eae775ba7b1fc6fc7a42c795aed3cbcd8763f9415452e2dbc8705
```

A continuación, se muestra un ejemplo del resultado del comando.

```
{
    "Run": {
        "Name": "myWorkflow",
        "WorkflowRunId":
 "wr_d2af14217e8eae775ba7b1fc6fc7a42c795aed3cbcd8763f9415452e2dbc8705",
        "WorkflowRunProperties": {
            "run_state": "COMPLETED",
            "unique_id": "fee63f30-c512-4742-a9b1-7c8183bdaae2"
        },
        "StartedOn": 1578556843.049,
        "CompletedOn": 1578558649.928,
        "Status": "COMPLETED",
        "Statistics": {
            "TotalActions": 11,
            "TimeoutActions": 0,
            "FailedActions": 0,
            "StoppedActions": 0,
            "SucceededActions": 9,
            "RunningActions": 0,
            "ErroredActions": 0
        }
    }
}
```

Véase también:

- the section called “Descripción general de flujos de trabajo”
- the section called “Información general de los esquemas”

Detener una ejecución de flujo de trabajo

Puede usar la consola de AWS Glue, AWS Command Line Interface (AWS CLI) o la API de AWS Glue para detener una ejecución de flujo de trabajo. Cuando detiene una ejecución de flujo de trabajo, todos los trabajos y rastreadores en ejecución finalizan inmediatamente y los trabajos y rastreadores que aún no se han iniciado nunca se llegan a iniciar. Puede tardar hasta un minuto para que todos los trabajos en ejecución y rastreadores se detengan. El estado de ejecución del flujo de trabajo pasa de Running (Ejecución) a Stopping (Detención) y cuando la ejecución del flujo de trabajo está completamente detenida, el estado pasa a Stopped (Detenido).

Después de detener la ejecución del flujo de trabajo, puede ver el gráfico de ejecución para ver qué trabajos y rastreadores se han completado y cuáles nunca se han iniciado. A continuación, puede determinar si debe realizar algún paso para garantizar la integridad de los datos. Detener una ejecución de flujo de trabajo hace que no se realicen operaciones de restauración automática.

Para detener una ejecución de flujo de trabajo (consola)

1. Abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. En el panel de navegación, en ETL, elija Workflows (Flujos de trabajo).
3. Elija un flujo de trabajo en ejecución y, a continuación, elija la pestaña History (Historial).
4. Elija la ejecución del flujo de trabajo y, a continuación, elija Stop run (Detener ejecución).

   El estado de ejecución cambia a Stopping (Detención).
5. (Opcional) seleccione la ejecución del flujo de trabajo, elija View run details (Ver detalles de la ejecución) y revise el gráfico de ejecución.

Para detener una ejecución de flujo de trabajo (AWS CLI)

- Escriba el siguiente comando. Reemplace *<workflow-name>* por el nombre del flujo de trabajo y *<run-id>* por el ID de ejecución del flujo de trabajo que se va a detener.

  ```
  aws glue stop-workflow-run --name <workflow-name> --run-id <run-id>
  ```

  A continuación, se muestra un ejemplo del comando stop-workflow-run.

  ```
  aws glue stop-workflow-run --name my-workflow --run-id
   wr_137b88917411d128081069901e4a80595d97f719282094b7f271d09576770354
  ```

Reparar y reanudar la ejecución de un flujo de trabajo

Si uno o más nodos (trabajos o rastreadores) de un flujo de trabajo no se completan en forma correcta, esto significa que el flujo de trabajo sólo se ejecutó en forma parcial. Después de encontrar las causas raíz y realizar correcciones, puede seleccionar uno o varios nodos a partir de los cuales reanudará la ejecución del flujo de trabajo y, a continuación, retomar la ejecución del flujo de trabajo. Se ejecutarán los nodos seleccionados y todos los nodos descendentes.

Temas

- Reanudar la ejecución de un flujo de trabajo: funcionamiento
- Reanudar una ejecución de flujo de trabajo
- Notas y limitaciones para reanudar las ejecuciones de flujos de trabajo

Reanudar la ejecución de un flujo de trabajo: funcionamiento

Considere el flujo de trabajo W1 en el siguiente diagrama.

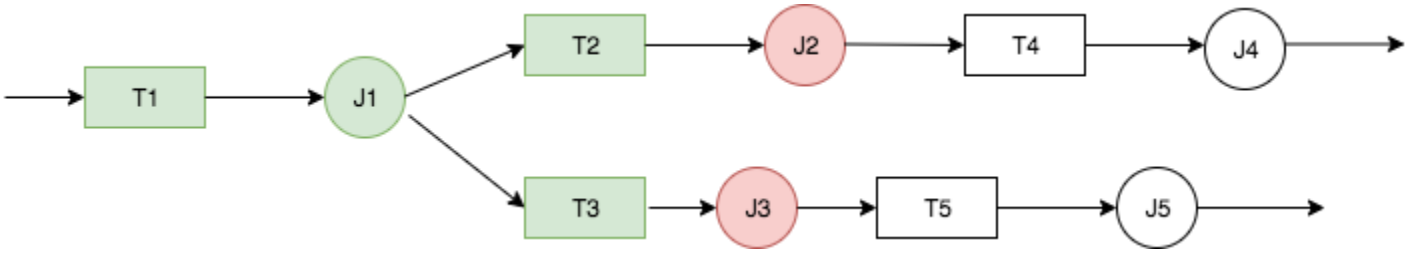

La ejecución del flujo de trabajo continúa de la siguiente manera:

1. El desencadenador T1 inicia el trabajo J1.
2. La finalización exitosa de J1 activa los desencadenadores T2 y T3, que ejecutan los trabajos J2 y J3, respectivamente.
3. Los trabajos J2 y J3 fallan.
4. Los desencadenadores T4 y T5 no se activan ya que dependen de la finalización exitosa de J2 y J3, por lo tanto, los trabajos J4 y J5 no se ejecutan. El flujo de trabajo W1 sólo se ejecuta en forma parcial.

Suponga que se corrigen los problemas que causaron que J2 y J3 fallaran. J2 y J3 se seleccionan como puntos de partida para reanudar la ejecución del flujo de trabajo.

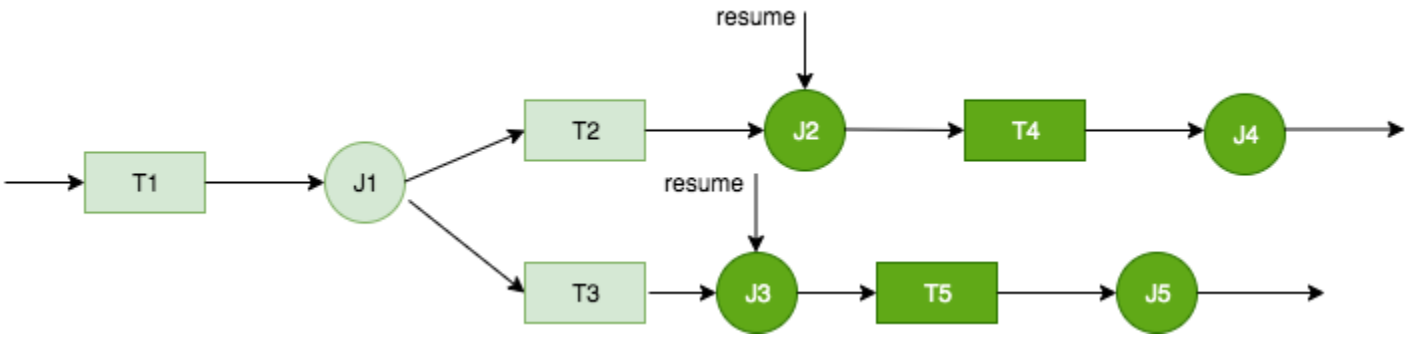

La ejecución del flujo de trabajo se reanuda de la siguiente manera:

1. Los trabajos J2 y J3 se ejecutan con éxito.
2. Se activan los desencadenadores T4 y T5.
3. Los trabajos J4 y J5 se ejecutan con éxito.

La ejecución del flujo de trabajo reanudado se realiza como una ejecución de flujo de trabajo independiente con un nuevo ID de ejecución. Cuando visualice el historial del flujo de trabajo, puede ver el ID de ejecución anterior para cualquier ejecución de flujo de trabajo. En el ejemplo de la siguiente captura de pantalla, la ejecución del flujo de trabajo con el ID de ejecución `wr_c7a22...` (segunda fila) tenía un nodo que no se completó. El usuario solucionó el problema y reanudó la ejecución del flujo de trabajo, lo que dio lugar a un ID de ejecución `wr_a07e55...` (primera fila).

> **Note**
>
> De aquí en adelante, el término “ejecución de flujo de trabajo reanudado” hace referencia a la ejecución del flujo de trabajo que se creó cuando se reanudó la ejecución del flujo de trabajo anterior. La “ejecución de flujo de trabajo original” se refiere a la ejecución del flujo de trabajo que sólo se ejecutó en forma parcial y que debió reanudarse.

Gráfico de ejecución de flujo de trabajo reanudado

En una ejecución de flujo de trabajo reanudado, aunque sólo se ejecuta un subconjunto de nodos, el gráfico de ejecución es un gráfico completo. Es decir, los nodos que no se ejecutaron en el flujo de trabajo reanudado se copian del gráfico de ejecución de flujo de trabajo original. Los nodos de trabajo y rastreador copiados que se ejecutaron en la ejecución de flujo de trabajo original incluyen detalles de la ejecución.

Considere una vez más el flujo de trabajo W1 en el diagrama anterior. Cuando se reanuda la ejecución del flujo de trabajo a partir de J2 y J3, el gráfico de ejecución de flujo de trabajo reanudado muestra todos los trabajos, de J1 a J5, y todos los desencadenadores, de T1 a T5. Los detalles de la ejecución de J1 se copian desde la ejecución de flujo de trabajo original.

Instantáneas de flujos de trabajo

Cuando se inicia una ejecución de flujo de trabajo, AWS Glue toma una instantánea del gráfico de diseño del flujo de trabajo en ese momento. Esa instantánea se utiliza durante toda la ejecución del flujo de trabajo. Si realiza cambios en los desencadenadores después de que se inicie la ejecución, esos cambios no afectan la ejecución del flujo de trabajo actual. Las instantáneas garantizan que las ejecuciones de flujo de trabajo se realicen de manera coherente.

Las instantáneas hacen que solo los desencadenadores sean inmutables. Los cambios que realice en los trabajos y rastreadores descendentes durante la ejecución del flujo de trabajo surtirán efecto para la ejecución actual.

Reanudar una ejecución de flujo de trabajo

Siga estos pasos para reanudar una ejecución de flujo de trabajo. Puede reanudar una ejecución de flujo de trabajo mediante la consola de AWS Glue, la API, o AWS Command Line Interface (AWS CLI).

Para reanudar un flujo de trabajo (consola)

1. Abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.

   Inicie sesión como usuario con permisos para visualizar flujos de trabajo y reanudar ejecuciones de flujos de trabajo.

   > **Note**
   >
   > Para reanudar ejecuciones de flujo de trabajo, necesita el permiso `glue:ResumeWorkflowRun` de AWS Identity and Access Management (IAM).

2. En el panel de navegación, elija Workflows (Flujos de trabajo).
3. Seleccione un flujo de trabajo y, a continuación, elija la pestaña History (Historial).
4. Seleccione la ejecución de flujo de trabajo que se ejecutó sólo en forma parcial y, a continuación, elija View run details (Visualizar los detalles de la ejecución).
5. En el gráfico de ejecución, seleccione el primer (o único) nodo que desea reiniciar y desde el que desea reanudar la ejecución del flujo de trabajo.
6. En el panel de detalles situado a la derecha del gráfico, seleccione la casilla de verificación Resume (Reanudar).

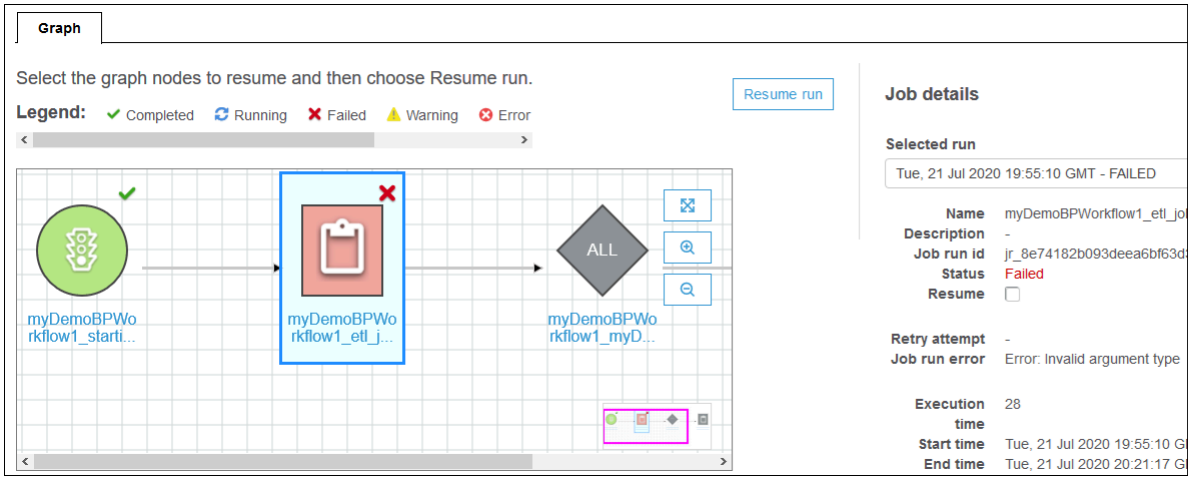

El nodo cambia de color y muestra un pequeño ícono de reanudación en la parte superior derecha.

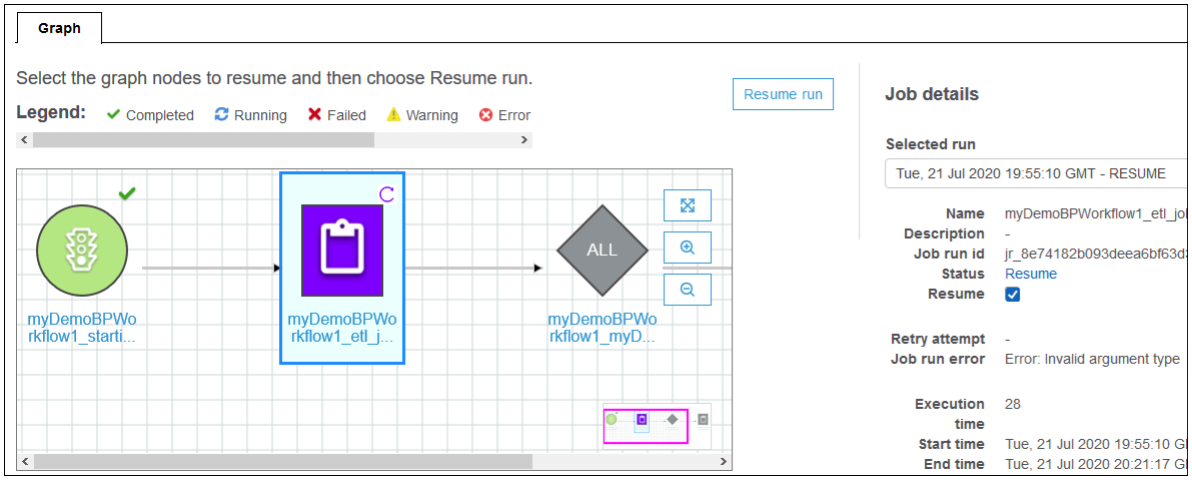

7. Complete los dos pasos anteriores para reiniciar cualquier otro nodo adicional.
8. Elija Resume run (Reanudar ejecución).

Para retomar la ejecución de un flujo de trabajo (AWS CLI)

1. Asegúrese de que dispone del permiso `glue:ResumeWorkflowRun` de IAM.
2. Recupere los ID de nodo para los nodos que desee reiniciar.

   a. Ejecute el comando `get-workflow-run` para la ejecución del flujo de trabajo original. Proporcione el nombre del flujo de trabajo y el ID de ejecución, y agregue la opción `--include-graph`, como se muestra en el ejemplo a continuación. Obtenga el ID de ejecución de la pestaña History (Historial) en la consola, o ejecute el comando `get-workflow`.

   ```
   aws glue get-workflow-run --name cloudtrailtest1 --run-id
    wr_a07e55f2087afdd415a404403f644a4265278f68b13ba3da08c71924ebe3c3a8 --include-
   graph
   ```

   El comando devuelve los nodos y los bordes del gráfico como un objeto JSON grande.

   b. Localice los nodos de interés en función de las propiedades de `Type` y `Name` de los objetos del nodo.

   A continuación, se muestra un resultado de objeto de nodo a modo de ejemplo.

   ```
   {
       "Type": "JOB",
       "Name": "test1_post_failure_4592978",
       "UniqueId":
    "wnode_d1b2563c503078b153142ee76ce545fe5ceef66e053628a786ddd74a05da86fd",
       "JobDetails": {
           "JobRuns": [
               {
                   "Id":
    "jr_690b9f7fc5cb399204bc542c6c956f39934496a5d665a42de891e5b01f59e613",
                   "Attempt": 0,
                   "TriggerName": "test1_aggregate_failure_649b2432",
                   "JobName": "test1_post_failure_4592978",
                   "StartedOn": 1595358275.375,
                   "LastModifiedOn": 1595358298.785,
                   "CompletedOn": 1595358298.785,
                   "JobRunState": "FAILED",
                   "PredecessorRuns": [],
                   "AllocatedCapacity": 0,
                   "ExecutionTime": 16,
   ```

```
                "Timeout": 2880,
                "MaxCapacity": 0.0625,
                "LogGroupName": "/aws-glue/python-jobs"
            }
        ]
    }
}
```

c. Obtenga el ID del nodo de la propiedad `UniqueId` del objeto del nodo.

3. Ejecute el comando `resume-workflow-run`. Especifique el nombre del flujo de trabajo, el ID de ejecución y la lista de ID de nodos separados por espacios, como se muestra en el siguiente ejemplo.

```
aws glue resume-workflow-run --name cloudtrailtest1 --run-id
 wr_a07e55f2087afdd415a404403f644a4265278f68b13ba3da08c71924ebe3c3a8 --node-
ids wnode_ca1f63e918fb855e063aed2f42ec5762ccf71b80082ae2eb5daeb8052442f2f3
 wnode_d1b2563c503078b153142ee76ce545fe5ceef66e053628a786ddd74a05da86fd
```

El comando arroja el ID de ejecución de la ejecución del flujo de trabajo reanudado (nuevo) y una lista de los nodos que se iniciarán.

```
{
    "RunId": "wr_2ada0d3209a262fc1156e4291134b3bd643491bcfb0ceead30bd3e4efac24de9",
    "NodeIds": [
        "wnode_ca1f63e918fb855e063aed2f42ec5762ccf71b80082ae2eb5daeb8052442f2f3"
    ]
}
```

Tenga en cuenta que aunque el comando `resume-workflow-run` de ejemplo enumeró dos nodos que se reiniciarán, el resultado de ejemplo indicaba que sólo se reiniciaría un nodo. Esto se debe a que un nodo era descendente al otro, y el nodo descendente se reiniciaría de todos modos como resultado de los pasos habituales del flujo de trabajo.

Notas y limitaciones para reanudar las ejecuciones de flujos de trabajo

Tenga en cuenta las siguientes notas y limitaciones al reanudar las ejecuciones de flujos de trabajo.

- Puede reanudar la ejecución de un flujo de trabajo sólo si se encuentra en el estado `COMPLETED`.

> **Note**
>
> Incluso si uno o más nodos en la ejecución de un flujo de trabajo no se completan, el estado de ejecución del flujo de trabajo se muestra como `COMPLETED`. Asegúrese de verificar el gráfico de ejecución para detectar los nodos que no se completaron en forma correcta.

- Puede reanudar la ejecución de un flujo de trabajo desde cualquier nodo de trabajo o rastreador que la ejecución de flujo de trabajo original haya intentado ejecutar. No se puede reanudar la ejecución de un flujo de trabajo desde un nodo de desencadenador.
- Al reiniciar un nodo no se restablece su estado. Los datos que se hayan procesado parcialmente no se revertirán.
- Puede reanudar varias veces la ejecución de un flujo de trabajo que haya fallado. Sin embargo, una ejecución reanudada solo puede reanudarse una vez más. Para reintentos adicionales, reanude la ejecución original que falló.
- Si selecciona dos nodos para reiniciar y dependen uno del otro, el nodo ascendente se ejecuta antes que el nodo descendente. De hecho, seleccionar el nodo descendente es redundante, ya que se ejecutará de acuerdo con los pasos habituales del flujo de trabajo.

Obtención y configuración de propiedades de ejecución de flujo de trabajo en AWS Glue

Utilice propiedades de ejecución de flujo de trabajo para compartir y administrar el estado entre los trabajos en su flujo de trabajo de AWS Glue. Puede definir propiedades de ejecución predeterminadas cuando cree el flujo de trabajo. Por lo tanto, a medida que se ejecutan los trabajos, puede recuperar los valores de propiedad de ejecución y modificarlos opcionalmente para la introducción en trabajos que estén después en el flujo de trabajo. Cuando un trabajo modifica una propiedad de ejecución, el nuevo valor existe solo para la ejecución del flujo de trabajo. Las propiedades de ejecución predeterminadas no se ven afectadas.

Si su trabajo de AWS Glue no forma parte de un flujo de trabajo, estas propiedades no se establecerán.

El siguiente código de Python de ejemplo de un trabajo de extracción, transformación y carga (ETL) muestra cómo obtener las propiedades de ejecución de flujo de trabajo.

```
import sys
import boto3
from awsglue.transforms import *
from awsglue.utils import getResolvedOptions
from awsglue.context import GlueContext
from pyspark.context import SparkContext

glue_client = boto3.client("glue")
args = getResolvedOptions(sys.argv, ['JOB_NAME','WORKFLOW_NAME', 'WORKFLOW_RUN_ID'])
workflow_name = args['WORKFLOW_NAME']
workflow_run_id = args['WORKFLOW_RUN_ID']
workflow_params = glue_client.get_workflow_run_properties(Name=workflow_name,
                                       RunId=workflow_run_id)["RunProperties"]

target_database = workflow_params['target_database']
target_s3_location = workflow_params['target_s3_location']
```

El siguiente código continúa con la configuración de la propiedad de ejecución `target_format` en `'csv'`.

```
workflow_params['target_format'] = 'csv'
glue_client.put_workflow_run_properties(Name=workflow_name, RunId=workflow_run_id,
 RunProperties=workflow_params)
```

Para obtener más información, consulte los siguientes temas:

- Acción GetWorkflowRunProperties (Python: get_workflow_run_properties)
- PutWorkflowRunProperties Action (Python: put_workflow_run_properties)

Consulta de flujos de trabajo mediante la AWS Glue API

AWS Glue proporciona una API enriquecida para administrar flujos de trabajo. Puede recuperar una vista estática de un flujo de trabajo o una vista dinámica de un flujo de trabajo en ejecución mediante la AWS Glue API. Para obtener más información, consulte Flujos de trabajo.

Temas

- Consulta de vistas estáticas
- Consulta de vistas dinámicas

Consulta de vistas estáticas

Utilice la operación de la API de `GetWorkflow` para obtener una vista estática que indique el diseño de un flujo de trabajo. Esta operación devuelve un gráfico dirigido que consiste en nodos y perímetros en los que el nodo representa un desencadenador, un trabajo o un rastreador. Los perímetros definen las relaciones entre nodos. Se representan mediante conectores (flechas) en el gráfico en la consola de AWS Glue.

También puede utilizar esta operación con bibliotecas de procesamiento de gráficos conocidas, como NetworkX, igraph, JGraphT y el marco de trabajo Java Universal Network/Graph (JUNG). Puesto que todas estas bibliotecas representan gráficos de forma similar, se precisan transformaciones mínimas.

La vista estática devuelta por esta API es la vista más actualizada según la última definición de desencadenadores asociados a este flujo de trabajo.

Definición de gráfico

Un gráfico de flujo de trabajo G es un par ordenador (N, E), donde N es un conjunto de nodos y E un conjunto de perímetros. Un nodo es un vértice en el gráfico identificado mediante un número único. Un nodo puede ser de tipo desencadenador, trabajo o rastreador. Por ejemplo: `{name:T1, type:Trigger, uniqueId:1}, {name:J1, type:Job, uniqueId:2}`.

Un perímetro es una tupla doble del formulario (`src, dest`), donde `src` y `dest` son los nodos y hay un perímetro dirigido desde `src` a `dest`.

Ejemplo de consulta de una vista estática

Considere un desencadenador condicional T, que desencadena el trabajo J2 una vez que se completa el trabajo J1.

```
J1 ---> T ---> J2
```

Nodos: J1, T, J2

Perímetros: (J1, T), (T, J2)

Consulta de vistas dinámicas

Utilice la operación de la API de `GetWorkflowRun` para obtener una vista dinámica de un flujo de trabajo en ejecución. Esta operación devuelve la misma vista estática del gráfico junto con metadatos relacionados con la ejecución de flujo de datos.

Para la ejecución, los nodos que representan trabajos en la llamada de `GetWorkflowRun` tienen una lista de ejecuciones de trabajo iniciadas como parte de la última ejecución del flujo de trabajo. Puede utilizar esta lista para mostrar el estado de ejecución de cada trabajo en el propio gráfico. Para dependencias descendentes que no se están ejecutando aún, este campo se establece en `null`. La información del gráfico le permitirá conocer el estado actual de cualquier flujo de trabajo en cualquier momento.

La vista dinámica devuelta por esta API se basa en la vista estática que estuviera presente cuando se inició la ejecución de flujo de trabajo.

Ejemplo de nodos de tiempo de ejecución: `{name:T1, type: Trigger, uniqueId:1}`, `{name:J1, type:Job, uniqueId:2, jobDetails:{jobRuns}}`, `{name:C1, type:Crawler, uniqueId:3, crawlerDetails:{crawls}}`

Ejemplo 1: Vista dinámica

En el siguiente ejemplo se muestra un flujo de trabajo de dos desencadenadores simple.

- Nodos: t1, j1, t2, j2
- Perímetros: (t1, j1), (j1, t2), (t2, j2)

La respuesta `GetWorkflow` contiene lo siguiente.

```
{
    Nodes : [
        {
            "type" : Trigger,
            "name" : "t1",
            "uniqueId" : 1
        },
        {
            "type" : Job,
            "name" : "j1",
            "uniqueId" : 2
```

```
        },
        {
            "type" : Trigger,
            "name" : "t2",
            "uniqueId" : 3
        },
        {
            "type" : Job,
            "name" : "j2",
            "uniqueId" : 4
        }
    ],
    Edges : [
        {
            "sourceId" : 1,
            "destinationId" : 2
        },
        {
            "sourceId" : 2,
            "destinationId" : 3
        },
        {
            "sourceId" : 3,
            "destinationId" : 4
        }
}
```

La respuesta `GetWorkflowRun` contiene lo siguiente.

```
{
    Nodes : [
        {
            "type" : Trigger,
            "name" : "t1",
            "uniqueId" : 1,
            "jobDetails" : null,
            "crawlerDetails" : null
        },
        {
            "type" : Job,
            "name" : "j1",
            "uniqueId" : 2,
            "jobDetails" : [
```

```
                {
                    "id" : "jr_12334",
                    "jobRunState" : "SUCCEEDED",
                    "errorMessage" : "error string"
                }
            ],
            "crawlerDetails" : null
        },
        {
            "type" : Trigger,
            "name" : "t2",
            "uniqueId" : 3,
            "jobDetails" : null,
            "crawlerDetails" : null
        },
        {
            "type" : Job,
            "name" : "j2",
            "uniqueId" : 4,
            "jobDetails" : [
                {
                    "id" : "jr_1233sdf4",
                    "jobRunState" : "SUCCEEDED",
                    "errorMessage" : "error string"
                }
            ],
            "crawlerDetails" : null
        }
    ],
    Edges : [
        {
            "sourceId" : 1,
            "destinationId" : 2
        },
        {
            "sourceId" : 2,
            "destinationId" : 3
        },
        {
            "sourceId" : 3,
            "destinationId" : 4
        }
}
```

Ejemplo 2: Varios trabajos con desencadenador condicional

En el siguiente ejemplo se muestra un flujo de trabajo con varios trabajos y un desencadenador condicional (t3).

```
Consider Flow:
T(t1) ---> J(j1) ---> T(t2) ---> J(j2)
             |                    |
             |                    |
             >+------> T(t3) <-----+
                        |
                        |
                      J(j3)

Graph generated:
Nodes: t1, t2, t3, j1, j2, j3
Edges: (t1, j1), (j1, t2), (t2, j2), (j1, t3), (j2, t3), (t3, j3)
```

Restricciones de esquemas y flujos de trabajo en AWS Glue

A continuación se incluyen las restricciones correspondientes a los proyectos y flujos de trabajo.

Restricciones de esquemas

Tenga en cuenta las siguientes restricciones de proyectos:

- El proyecto debe estar registrado en la misma región de AWS donde reside el bucket de Amazon S3.
- Para compartir proyectos entre cuentas de AWS debe conceder permisos de lectura en el archivo ZIP del proyecto en Amazon S3. Los clientes que tengan permiso de lectura en el archivo ZIP de un proyecto pueden registrar el proyecto en su cuenta de AWS y utilizarlo.
- El conjunto de parámetros del proyecto se almacena como un único objeto JSON. La longitud máxima de este objeto es de 128 KB.
- El tamaño máximo sin comprimir del archivo ZIP del proyecto es de 5 MB. El tamaño máximo de compresión es de 1 MB.
- Limite la cantidad total de trabajos, rastreadores y desencadenadores de un flujo de trabajo a 100 o menos. Si incluye más de 100, es posible que se produzcan errores al intentar reanudar o detener las ejecuciones del flujo de trabajo.

Restricciones del flujo de datos

Tenga en cuenta las siguientes restricciones de flujos de trabajo. Algunos de estos comentarios están dirigidos a un usuario que crea flujos de trabajo en forma manual.

- El tamaño máximo de lote para un desencadenador de eventos de Amazon EventBridge es 100. El tamaño máximo de la ventana es de 900 segundos (15 minutos).
- Un desencadenador se puede asociar solo a un flujo de trabajo.
- Solo se permite un desencadenador de arranque (bajo demanda o de programación).
- Si un desencadenador externo a un flujo de trabajo inicia un trabajo o rastreador dentro del flujo, no se activarán los desencadenadores incluidos en el flujo de trabajo que dependan de la finalización del trabajo o del rastreador (correcta o no).
- Del mismo modo, si un trabajo o rastreador de un flujo de trabajo tiene desencadenadores que dependen de la finalización del trabajo o del rastreador (correcta o no), tanto dentro del flujo de trabajo como fuera de este, si el trabajo o el rastreador se inicia desde dentro de un flujo de trabajo, solo los desencadenadores incluidos en el flujo de trabajo se activan al finalizar el trabajo o el rastreador.

Solución de errores de esquema en AWS Glue

Si detecta errores al utilizar proyectos en AWS Glue, utilice las siguientes soluciones como ayuda para encontrar la fuente de los problemas y corregirlos.

Temas

- Error: falta el módulo PySpark
- Error: falta el archivo de configuración del proyecto
- Error: falta archivo importado
- Error: no autorizado a realizar iamPassRole en el recurso
- Error: programación cron no válida
- Error: ya existe un desencadenador con ese nombre
- Error: el flujo de trabajo con el nombre: foo ya existe.
- Error: no se encontró el módulo en la ruta de LayoutGenerator especificada
- Error: error de validación en el campo Connections (Conexiones)

Error: falta el módulo PySpark

AWS Glue devuelve el error “Unknown error executing layout generator function ModuleNotFoundError: No module named 'pyspark' (Error desconocido al ejecutar la función del generador de diseño ModuleNotFounderError: no hay módulo llamado 'pyspark')”.

Cuando descomprime el archivo del proyecto, podría suceder cualquiera de los dos casos que figuran a continuación:

```
$ unzip compaction.zip
Archive:  compaction.zip
   creating: compaction/
  inflating: compaction/blueprint.cfg
  inflating: compaction/layout.py
  inflating: compaction/README.md
  inflating: compaction/compaction.py

$ unzip compaction.zip
Archive:  compaction.zip
  inflating: blueprint.cfg
  inflating: compaction.py
  inflating: layout.py
  inflating: README.md
```

En el primer caso, todos los archivos relacionados con el proyecto se colocaron en una carpeta denominada compaction y luego se convirtió en un archivo zip llamado compaction.zip.

En el segundo caso, todos los archivos necesarios para el proyecto no se incluyeron en una carpeta y se agregaron como archivos raíz en el archivo zip compaction.zip.

Se permite crear un archivo en cualquiera de los formatos anteriores. Sin embargo, asegúrese de que `blueprint.cfg` tiene la ruta correcta al nombre de la función en el script que genera el diseño.

Ejemplos

En el caso 1: `blueprint.cfg` debería tener `layoutGenerator` como lo siguiente:

```
layoutGenerator": "compaction.layout.generate_layout"
```

En el caso 2: `blueprint.cfg` debería tener `layoutGenerator` como lo siguiente

```
layoutGenerator": "layout.generate_layout"
```

Si esta ruta no se incluye en forma correcta, podría ver un error como el que se indica. Por ejemplo, si tiene la estructura de carpetas como se menciona en el caso 2 y tiene el `layoutGenerator` indicado como en el caso 1, puede ver el error anterior.

Error: falta el archivo de configuración del proyecto

AWS Glue devuelve el error “Unknown error executing layout generator function FileNotFoundError: [Errno 2] No such file or directory: '/tmp/compaction/blueprint.cfg' (Error desconocido al ejecutar la función del generador de diseño FileNotFoundError: [Errno 2] no existe tal archivo o directorio: '/tmp/compaction/blueprint.cfg')”.

El blueprint.cfg debe colocarse en el nivel raíz del archivo ZIP o dentro de una carpeta que tenga el mismo nombre que el archivo ZIP.

Cuando extraemos el archivo ZIP del proyecto, se espera que blueprint.cfg se encuentre en una de las siguientes rutas. Si no se encuentra en una de las siguientes rutas, puede ver el error anterior.

```
$ unzip compaction.zip
Archive:  compaction.zip
   creating: compaction/
  inflating: compaction/blueprint.cfg

$ unzip compaction.zip
Archive:  compaction.zip
  inflating: blueprint.cfg
```

Error: falta archivo importado

AWS Glue devuelve el error “Unknown error executing layout generator function FileNotFoundError: [Errno 2] No such file or directory:* *'demo-project/foo.py' (Error desconocido al ejecutar la función del generador de diseño FileNotFoundError: [Errno 2] no existe tal archivo o directorio:* *'demo-project/foo.py')”.

Si el script de generación de diseño tiene funcionalidad para leer otros archivos, asegúrese de proporcionar una ruta completa para el archivo que se va a importar. Por ejemplo, se puede hacer referencia al script Conversion.py en Layout.py. Para obtener más información, consulte Esquema de ejemplo.

Error: no autorizado a realizar iamPassRole en el recurso

AWS Glue devuelve el error “User: arn:aws:sts::123456789012:assumed-role/AWSGlueServiceRole/GlueSession is not authorized to perform: iam:PassRole on resource: arn:aws:iam::123456789012:role/AWSGlueServiceRole (Usuario: arn:aws:sts::123456789012:assumed-role/AWSGlueServiceRole/GlueSession no está autorizado para realizar: iam:PassRole en el recurso: arn:aws:iam:: 123456789012:role/AWSGlueServicerole)”

Si los trabajos y rastreadores del flujo de trabajo asumen el mismo rol que el rol transferido para crear el flujo de trabajo a partir del proyecto, el rol del proyecto debe incluir el permiso `iam:PassRole`.

Si los trabajos y rastreadores del flujo de trabajo asumen un rol distinto que el rol transferido para crear las entidades del flujo de trabajo a partir del proyecto, el rol del proyecto debe incluir el permiso `iam:PassRole` en ese otro rol, en lugar de en el rol del proyecto.

Para obtener más información, consulte Permisos para roles de esquema.

Error: programación cron no válida

AWS Glue devuelve el error “The schedule cron(0 0 * * * *) is invalid [El cron de programación (0 0 * * * *) no es válido]”.

Proporcione una expresión cron válida. Para obtener más información, consulte Programaciones basadas en tiempo para trabajos y rastreadores.

Error: ya existe un desencadenador con ese nombre

AWS Glue devuelve el error “Trigger with name 'foo_starting_trigger' already submitted with different configuration (Desencadenador con nombre 'foo_starting_trigger' ya enviado con una configuración diferente)”.

Un proyecto no requiere que defina desencadenadores en el script de diseño para la creación del flujo de trabajo. La creación de desencadenadores es administrada por la biblioteca de proyectos en función de las dependencias definidas entre dos acciones.

La denominación de los desencadenadores es la siguiente:

- Para el desencadenador de inicio en el flujo de trabajo, la denominación es <workflow_name>_starting_trigger.

- Para un nodo (trabajo/rastreador) en el flujo de trabajo que depende de la finalización de uno o varios nodos ascendentes; AWS Glue define un desencadenador con el nombre <workflow_name>_<node_name>_trigger

Este error significa que ya existe un desencadenador con ese nombre. Puede eliminar el desencadenador existente y volver a ejecutar la creación del flujo de trabajo.

> **Note**
>
> Al eliminar un flujo de trabajo no se eliminan los nodos del flujo de trabajo. Es posible que aunque se elimine el flujo de trabajo, los desencadenadores permanezcan. Debido a esto, es posible que no reciba un error de “workflow already exists (el flujo de trabajo ya existe)”, pero puede recibir un error de “trigger already exists (el desencadenador ya existe)” en un caso en el que cree un flujo de trabajo, lo elimine y luego intente volver a crearlo con el mismo nombre y a partir del mismo proyecto.

Error: el flujo de trabajo con el nombre: foo ya existe.

El nombre del flujo de trabajo debe ser único. Inténtelo con un nombre diferente.

Error: no se encontró el módulo en la ruta de LayoutGenerator especificada

AWS Glue devuelve el error “Unknown error executing layout generator function ModuleNotFoundError: No module named 'crawl_s3_locations' (Error desconocido al ejecutar la función del generador de diseño ModuleNotFoundError: no hay módulo llamado 'crawl_s3_locations')”.

```
layoutGenerator": "crawl_s3_locations.layout.generate_layout"
```

Por ejemplo, si tiene la ruta de acceso LayoutGenerator anterior, cuando descomprima el archivo del proyecto, debe tener el siguiente aspecto:

```
$ unzip crawl_s3_locations.zip
Archive:  crawl_s3_locations.zip
   creating: crawl_s3_locations/
  inflating: crawl_s3_locations/blueprint.cfg
  inflating: crawl_s3_locations/layout.py
  inflating: crawl_s3_locations/README.md
```

Cuando descomprime el archivo, si el archivo del proyecto se ve de la siguiente manera, entonces puede obtener el error anterior.

```
$ unzip crawl_s3_locations.zip
Archive:  crawl_s3_locations.zip
  inflating: blueprint.cfg
  inflating: layout.py
  inflating: README.md
```

Puede ver que no hay ninguna carpeta llamada `crawl_s3_locations` y cuando la ruta `layoutGenerator` se refiere al archivo de diseño a través del módulo `crawl_s3_locations`, puede obtener el error anterior.

Error: error de validación en el campo Connections (Conexiones)

AWS Glue devuelve el error “Unknown error executing layout generator function TypeError: Value ['foo'] for key Connections should be of type <class 'dict'>! (Error desconocido al ejecutar la función del generador de diseño TypeError: el valor ['foo'] para las conexiones clave debe ser de tipo <class 'dict'>!)”.

Este es un error de validación. El campo `Connections` en la clase `Job` espera un diccionario y en su lugar se proporciona una lista de valores que causan el error.

```
User input was list of values
Connections= ['string']

Should be a dict like the following
Connections*=*{'Connections': ['string']}
```

Para evitar estos errores de tiempo de ejecución al crear un flujo de trabajo a partir de un proyecto, puede validar las definiciones de flujo de trabajo, trabajo y rastreador como se describe en Realizar pruebas de un esquema.

Consulte la sintaxis en Referencia a clases de proyectos de AWS Glue para definir el trabajo, rastreador y flujo de trabajo de AWS Glue en el script de diseño.

Permisos de personas y roles para esquemas de AWS Glue

Las siguientes son las personas típicas y las políticas de permisos de AWS Identity and Access Management (IAM) sugeridas para personas y roles en relación con esquemas de AWS Glue.

Temas

- Personas para esquemas
- Permisos de personas para esquemas
- Permisos para roles de esquema

Personas para esquemas

Las siguientes son las personas generalmente involucradas en el ciclo de vida de un esquema de AWS Glue.

Persona	Descripción
AWS GlueDesarrollador de	Desarrolla, prueba y publica proyectos.
AWS GlueAdministrador de	Registra, mantiene y concede permisos para proyectos.
Analista de datos	Ejecuta proyectos para crear flujos de trabajo.

Para obtener más información, consulte the section called “Información general de los esquemas”.

Permisos de personas para esquemas

Los siguientes son los permisos sugeridos para cada persona del proyecto.

Permisos de desarrollador de AWS Glue para esquemas

El desarrollador de AWS Glue debe tener permisos de escritura en el bucket de Amazon S3 que se utiliza para publicar el esquema. A general, el desarrollador registra el proyecto después de cargarlo. En ese caso, el desarrollador necesita los permisos enumerados en the section called “Permisos de administrador de AWS Glue para esquemas”. Además, si el desarrollador desea probar el proyecto después de su registro, también necesita los permisos enumerados en the section called “Permisos de analista de datos para esquemas”.

Permisos de administrador de AWS Glue para esquemas

La política siguiente concede permisos para registrar, ver y mantener esquemas de AWS Glue.

> **Important**
>
> En la siguiente política , reemplace *<s3-bucket-name>* y *<prefix>* con la ruta de Amazon S3 a los archivos ZIP de proyecto cargados que se registrarán.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:CreateBlueprint",
        "glue:UpdateBlueprint",
        "glue:DeleteBlueprint",
        "glue:GetBlueprint",
        "glue:ListBlueprints",
        "glue:BatchGetBlueprints"
      ],
      "Resource": "*"
    },
    {
      "Effect": "Allow",
      "Action": [
        "s3:GetObject"
      ],
      "Resource": "arn:aws:s3:::amzn-s3-demo-bucket/prefix/*"
    }
  ]
}
```

Permisos de analista de datos para esquemas

La siguiente política concede permisos para ejecutar proyectos y ver el flujo de trabajo y sus componentes resultantes. También concede `PassRole` al rol que AWS Glue asume para crear el flujo de trabajo y sus componentes.

La política concede permisos sobre cualquier recurso. Si desea configurar el acceso detallado a proyectos individuales, utilice el siguiente formato para los ARN de proyecto:

```
arn:aws:glue:<region>:<account-id>:blueprint/<blueprint-name>
```

> **Important**
>
> En la siguiente política, reemplace *<account-id>* por una cuenta de AWS válida y reemplace *<role-name>* por el nombre del rol utilizado para ejecutar un proyecto. Consulte the section called “Permisos para roles de esquema” para obtener los permisos que requiere este rol.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListBlueprints",
        "glue:GetBlueprint",
        "glue:StartBlueprintRun",
        "glue:GetBlueprintRun",
        "glue:GetBlueprintRuns",
        "glue:GetCrawler",
        "glue:ListTriggers",
        "glue:ListJobs",
        "glue:BatchGetCrawlers",
        "glue:GetTrigger",
        "glue:BatchGetWorkflows",
        "glue:BatchGetTriggers",
        "glue:BatchGetJobs",
        "glue:BatchGetBlueprints",
        "glue:GetWorkflowRun",
        "glue:GetWorkflowRuns",
        "glue:ListCrawlers",
        "glue:ListWorkflows",
        "glue:GetJob",
```

```
        "glue:GetWorkflow",
        "glue:StartWorkflowRun"
      ],
      "Resource": "*"
    },
    {
      "Effect": "Allow",
      "Action": "iam:PassRole",
      "Resource": "arn:aws:iam::111122223333:role/role-name"
    }
  ]
}
```

Permisos para roles de esquema

Los siguientes son los permisos sugeridos para el rol de IAM utilizado para crear un flujo de trabajo a partir de un proyecto. El rol debe tener una relación de confianza con `glue.amazonaws.com`.

> **Important**
>
> En la siguiente política, reemplace *<account-id>* por una cuenta de AWS válida y reemplace *<role-name>* por el nombre del rol.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:CreateJob",
        "glue:GetCrawler",
        "glue:GetTrigger",
        "glue:DeleteCrawler",
        "glue:CreateTrigger",
        "glue:DeleteTrigger",
        "glue:DeleteJob",
        "glue:CreateWorkflow",
```

```
        "glue:DeleteWorkflow",
        "glue:GetJob",
        "glue:GetWorkflow",
        "glue:CreateCrawler"
      ],
      "Resource": "*"
    },
    {
      "Effect": "Allow",
      "Action": "iam:PassRole",
      "Resource": "arn:aws:iam::111122223333:role/role-name"
    }
  ]
}
```

> **Note**
>
> Si los trabajos y los rastreadores del flujo de trabajo asumen un rol distinto de este rol, esta política debe incluir el permiso `iam:PassRole` en ese otro rol en lugar de en el rol del proyecto.

Desarrollo de esquemas en AWS Glue

Es posible que su organización tenga un conjunto de casos de uso de ETL similares que podrían beneficiarse al poder parametrizar un único flujo de trabajo para manejarlos todos. Para esto, AWS Glue permite definir esquemas, que se pueden utilizar para generar flujos de trabajo. Un proyecto acepta parámetros, de modo que a partir de un único proyecto, un analista de datos puede crear diferentes flujos de trabajo para manejar casos de uso de ETL similares. Después de crear un proyecto, puede reutilizarlo para diferentes departamentos, equipos y proyectos.

Temas

- Información general de los esquemas en AWS Glue
- Desarrollo de esquemas en AWS Glue
- Registrar un esquema en AWS Glue
- Visualización de esquemas en AWS Glue
- Actualizar un esquema en AWS Glue

- Creación de un flujo de trabajo a partir de un esquema en AWS Glue
- Visualización de las ejecuciones de esquema en AWS Glue

Información general de los esquemas en AWS Glue

> **Note**
>
> En este momento, la característica de esquemas no está disponible en las siguientes regiones de la consola de AWS Glue: Asia Pacífico (Yakarta) y Medio Oriente (Emiratos Árabes Unidos).

Los esquemas de AWS Glue proporcionan una forma de crear y compartir flujos de trabajo de AWS Glue. Cuando hay un proceso de ETL complejo que podría utilizarse para casos de uso similares, en lugar de crear un flujo de trabajo de AWS Glue para cada caso de uso, puede crear un único esquema.

El proyecto especifica los trabajos y rastreadores que se incluirán en un flujo de trabajo, y especifica los parámetros que el usuario del flujo de trabajo proporciona al ejecutar el proyecto para crear un flujo de trabajo. El uso de parámetros permite que un único proyecto genere flujos de trabajo para los distintos casos de uso similares. Para obtener más información acerca de los flujos de trabajo, consulte Información general de los flujos de trabajo en AWS Glue.

A continuación, se muestran ejemplos de casos de uso de proyectos:

- El usuario desea crear una partición de un conjunto de datos existente. Los parámetros de entrada al proyecto son las rutas de origen y destino de Amazon Simple Storage Service (Amazon S3) y una lista de columnas de partición.
- El usuario desea realizar una instantánea de una tabla de Amazon DynamoDB en un almacén de datos SQL como Amazon Redshift. Los parámetros de entrada del esquema son el nombre de la tabla de DynamoDB y una conexión de AWS Glue, que designa un clúster de Amazon Redshift y una base de datos de destino.
- El usuario desea convertir datos CSV en varias rutas de Amazon S3 a Parquet. El usuario desea que el flujo de trabajo de AWS Glue incluya un rastreador y un trabajo independientes para cada ruta. Los parámetros de entrada son la base de datos de destino en el catálogo de datos de AWS Glue y una lista delimitada por comas de rutas de Amazon S3. Tenga en cuenta que, en este caso, el número de rastreadores y trabajos que crea el flujo de trabajo es variable.

Componentes del esquema

Un proyecto es un archivo ZIP que tiene los siguientes componentes:

- Un script del generador de diseño Python

  Contiene una función que especifica el diseño del flujo de trabajo: los rastreadores y trabajos que se van a crear para el flujo de trabajo, las propiedades del trabajo y del rastreador, y las dependencias entre los trabajos y los rastreadores. La función acepta los parámetros del esquema y devuelve una estructura de flujo de trabajo (objeto JSON) que AWS Glue utiliza para generar el flujo de trabajo. Dado que usted utiliza un script de Python para generar el flujo de trabajo, puede agregar su propia lógica que sea adecuada para sus casos de uso.

- Archivo de configuración

  Especifica el nombre completo de la función de Python que genera el diseño del flujo de trabajo. También especifica los nombres, tipos de datos y otras propiedades de todos los parámetros del proyecto utilizados por el script.

- (Opcional) scripts de ETL y archivos auxiliares

  Como caso de uso avanzado, puede parametrizar la ubicación de los scripts de ETL que utilizan sus trabajos. Puede incluir archivos de script de trabajo en el archivo ZIP y especificar un parámetro del proyecto para una ubicación de Amazon S3 en la que se copiarán los scripts. El script del generador de diseño puede copiar los scripts de ETL en la ubicación designada y especificar esa ubicación como propiedad de ubicación del script de trabajo. También puede incluir bibliotecas u otros archivos auxiliares, siempre que el script los maneje.

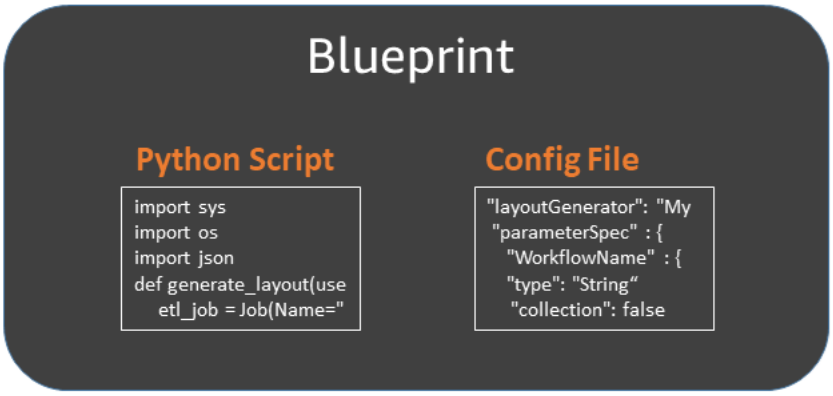

Ejecuciones del proyecto

Cuando crea un flujo de trabajo a partir de un esquema, AWS Glue ejecuta el esquema, que inicia un proceso asíncrono para crear el flujo de trabajo y los trabajos, rastreadores y desencadenadores que el flujo de trabajo encapsula. AWS Glue utiliza la ejecución del esquema para orquestar la creación del flujo de trabajo y sus componentes. Para ver el estado del proceso de creación, consulte el estado de ejecución del proyecto. La ejecución del proyecto también almacena los valores que ha proporcionado para los parámetros del proyecto.

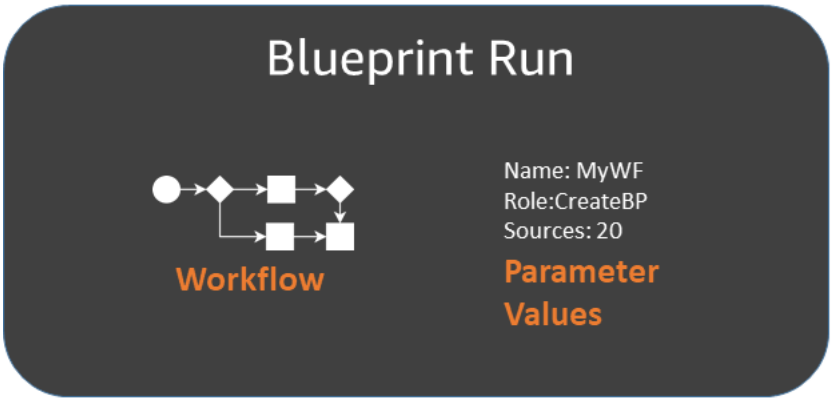

Puede visualizar ejecuciones de esquemas con la consola de AWS Glue o AWS Command Line Interface (AWS CLI). Al ver o solucionar problemas de un flujo de trabajo, siempre puede volver a la ejecución del proyecto para ver los valores de parámetro de proyecto que se utilizaron para crear el flujo de trabajo.

Ciclo de vida de un esquema

Los esquemas se desarrollan, prueban y registran con AWS Glue, y se ejecutan para crear flujos de trabajo. En general, hay tres personas involucradas en el ciclo de vida de un proyecto.

Persona	Tareas
Desarrollador de AWS Glue	• Escribe el script de diseño del flujo de trabajo y crea el archivo de configuración. • Realiza pruebas locales del esquema con las bibliotec as proporcionadas por el servicio de AWS Glue. • Crea un archivo ZIP del script, el archivo de configura ción y los archivos auxiliares, y publica el archivo en una ubicación de Amazon S3. • Agrega una política de bucket al bucket de Amazon S3 que concede permisos de lectura en objetos de bucket a la cuenta de AWS del administrador de AWS Glue.

Persona	Tareas
	• Concede permisos de lectura de IAM en el archivo ZIP de Amazon S3 al administrador de AWS Glue.
Administrador de AWS Glue	• Registra el esquema en AWS Glue. AWS Glue realiza una copia del archivo ZIP en una ubicación reservada de Amazon S3. • Otorga permisos de IAM en el proyecto a los analistas de datos.
Analista de datos	• Ejecuta el proyecto para crear un flujo de trabajo y proporciona valores de parámetros del proyecto. Comprueba el estado de ejecución del proyecto para asegurarse de que el flujo de trabajo y sus component es se generaron en forma correcta. • Ejecuta y soluciona los problemas del flujo de trabajo. Antes de ejecutar el flujo de trabajo, puede verificarlo al acceder al gráfico de diseño del flujo de trabajo en la consola de AWS Glue.

Véase también

- Desarrollo de esquemas en AWS Glue
- Creación de un flujo de trabajo a partir de un esquema en AWS Glue
- Permisos de personas y roles para esquemas de AWS Glue

Desarrollo de esquemas en AWS Glue

Como desarrollador de AWS Glue, puede crear y publicar esquemas que los analistas de datos pueden utilizar para generar flujos de trabajo.

Temas

- Información general sobre el desarrollo de esquemas
- Requisitos previos para desarrollar esquemas

- Escritura del código del esquema
- Proyecto de esquema de ejemplo
- Pruebas a un esquema
- Publicación de un esquema
- Referencia de clases de esquemas de AWS Glue
- Esquemas de ejemplo

> Véase también
>
> - Información general de los esquemas en AWS Glue

Información general sobre el desarrollo de esquemas

El primer paso en su proceso de desarrollo es identificar un caso de uso común que se beneficiaría de un proyecto. Un caso de uso típico implica un problema de ETL recurrente que cree que debe resolverse de manera general. Diseñe un proyecto que implemente el caso de uso generalizado y defina los parámetros de entrada del proyecto que, en conjunto, pueden definir un caso de uso específico a partir del caso de uso generalizado.

Un proyecto contiene un archivo de configuración de parámetros del proyecto y un script que define el diseño del flujo de trabajo que se va a generar. El diseño define los trabajos y los rastreadores (o entidades en la terminología del script del proyecto) que se crearán.

No se especifica directamente ningún desencadenador en el script de diseño. En su lugar, se escribe el código para especificar las dependencias entre los trabajos y los rastreadores que crea el script. AWS Glue genera los desencadenadores en función de las especificaciones de dependencia. El resultado del script de diseño es un objeto de flujo de trabajo, que contiene especificaciones para todas las entidades del flujo de trabajo.

Cree el objeto de flujo de trabajo con las siguientes bibliotecas de esquema de AWS Glue:

- `awsglue.blueprint.base_resource`: una biblioteca de recursos básicos utilizados por las bibliotecas.
- `awsglue.blueprint.workflow`: una biblioteca para definir una clase de `Workflow`.
- `awsglue.blueprint.job`: una biblioteca para definir una clase de `Job`.

- `awsglue.blueprint.crawler`: una biblioteca para definir una clase de `Crawler`.

Las únicas otras bibliotecas que se soportan para la generación de diseños son aquellas bibliotecas que están disponibles para el shell de Python.

Antes de publicar el proyecto, puede utilizar los métodos definidos en las bibliotecas del proyecto para probarlo a nivel local.

Cuando esté listo para poner el proyecto a disposición de los analistas de datos, empaquete el script, el archivo de configuración de parámetros y cualquier archivo auxiliar, como scripts y bibliotecas adicionales, en un único activo de implementación. A continuación, cargue el recurso en Amazon S3 y pida a un administrador que lo registre con AWS Glue.

Para obtener más información sobre proyectos de ejemplo, consulte Proyecto de esquema de ejemplo y Esquemas de ejemplo.

Requisitos previos para desarrollar esquemas

Para desarrollar esquemas, debe conocer el uso de AWS Glue y la escritura de scripts para trabajos de ETL de Apache Spark o trabajos de shell de Python. Además, debe completar las siguientes tareas de configuración.

- Descargue cuatro bibliotecas de AWS Python para usar en sus scripts de diseño de proyecto.
- Configure los SDK de AWS.
- Configure AWS CLI.

Descargar las bibliotecas de Python

Descargue las siguientes bibliotecas de GitHub e instálelas en su proyecto:

- https://github.com/awslabs/aws-glue-blueprint-libs/tree/master/awsglue/blueprint/base_resource.py
- https://github.com/awslabs/aws-glue-blueprint-libs/tree/master/awsglue/blueprint/workflow.py
- https://github.com/awslabs/aws-glue-blueprint-libs/tree/master/awsglue/blueprint/crawler.py
- https://github.com/awslabs/aws-glue-blueprint-libs/tree/master/awsglue/blueprint/job.py

Configure el AWS Java SDK

Para el SDK de AWS Java , debe agregar un archivo `jar` que incluya la API para proyectos.

1. Si aún no lo ha hecho, configure el SDK de AWS para Java.

   - Para Java 1.x, siga las instrucciones en Configurar AWS SDK para Java en la Guía para desarrolladores de AWS SDK para Java.
   - Para Java 2.x, siga las instrucciones en Configurar AWS SDK for Java 2.x en la Guía para desarrolladores de AWS SDK for Java 2.x.

2. Descargue el archivo `jar` del cliente que tiene acceso a las API para proyectos.

   - Para Java 1.x: s3: //awsglue-custom-blueprints-preview-artifacts/awsglue-java-sdk-preview/awsglueJavaclient-1.11.x.jar
   - Para Java 2.x: s3: //awsglue-custom-blueprints-preview-artifacts/awsglue-java-sdk-v2-preview/awsjavasdk-glue-2.0.jar

3. Agregue el `jar` del cliente al frente de la ruta de clases de Java para anular el cliente de AWS Glue proporcionado por el SDK de AWS Java.

   ```
   export CLASSPATH=<path-to-preview-client-jar>:$CLASSPATH
   ```

4. (Opcional) pruebe el SDK con la siguiente aplicación Java. La aplicación debe generar una lista vacía.

   Reemplace `accessKey` y `secretKey` con sus credenciales y reemplace `us-east-1` con su región.

   ```
   import com.amazonaws.auth.AWSCredentials;
   import com.amazonaws.auth.AWSCredentialsProvider;
   import com.amazonaws.auth.AWSStaticCredentialsProvider;
   import com.amazonaws.auth.BasicAWSCredentials;
   import com.amazonaws.services.glue.AWSGlue;
   import com.amazonaws.services.glue.AWSGlueClientBuilder;
   import com.amazonaws.services.glue.model.ListBlueprintsRequest;

   public class App{
       public static void main(String[] args) {
           AWSCredentials credentials = new BasicAWSCredentials("accessKey",
    "secretKey");
           AWSCredentialsProvider provider = new
    AWSStaticCredentialsProvider(credentials);
           AWSGlue glue = AWSGlueClientBuilder.standard().withCredentials(provider)
                   .withRegion("us-east-1").build();
   ```

```
        ListBlueprintsRequest request = new
 ListBlueprintsRequest().withMaxResults(2);
        System.out.println(glue.listBlueprints(request));
    }
}
```

Configuración de AWS Python SDK

En los siguientes pasos se supone que tiene la versión 2.7 o posterior de Python, o la versión 3.9 o una posterior instalada en el equipo.

1. Descargue el siguiente archivo wheel boto3. Si se le solicita abrir o guardar, guarde el archivo. s3: //awsglue-custom-blueprints-preview-artifacts/aws-python-sdk-preview/boto3-1.17.31-py2.py3-none-any.whl
2. Descargue el siguiente archivo wheel de botocore: s3: //awsglue-custom-blueprints-preview-artifacts/aws-python-sdk-preview/botocore-1.20.31-py2.py3-none-any.whl
3. Compruebe su versión de Python.

   ```
   python --version
   ```

4. En función de su versión de Python, ingrese los siguientes comandos (para Linux):

   - Para Python 2.7 o posterior.

     ```
     python3 -m pip install --user virtualenv
     source env/bin/activate
     ```

   - Para Python 3.9 o posterior.

     ```
     python3 -m venv python-sdk-test
     source python-sdk-test/bin/activate
     ```

5. Instale el archivo wheel de botocore.

   ```
   python3 -m pip install <download-directory>/botocore-1.20.31-py2.py3-none-any.whl
   ```

6. Instale el archivo wheel boto3.

   ```
   python3 -m pip install <download-directory>/boto3-1.17.31-py2.py3-none-any.whl
   ```

7. Configure las credenciales y la región predeterminada en los archivos `~/.aws/credentials` y `~/.aws/config`. Para obtener más información, consulte Configuración de la AWS CLI en la Guía del usuario de AWS Command Line Interface.
8. (Opcional) pruebe su configuración. Los siguientes comandos deben devolver una lista vacía.

   Reemplace la `us-east-1` por su región.

   ```
   $ python
   >>> import boto3
   >>> glue = boto3.client('glue', 'us-east-1')
   >>> glue.list_blueprints()
   ```

Configuración de la previsualización de AWS CLI

1. Si aún no lo ha hecho, instale o actualice la AWS Command Line Interface (AWS CLI) en su equipo. La manera más sencilla de hacerlo es con `pip`, la utilidad del instalador de Python:

   ```
   pip install awscli --upgrade --user
   ```

   Puede encontrar instrucciones de instalación completas para AWS CLI aquí: Instalación de AWS Command Line Interface.
2. Descargue el archivo wheel AWS CLI desde: s3: //awsglue-custom-blueprints-preview-artifacts/awscli-preview-build/awscli-1.19.31-py2.py3-none-any.whl
3. Instale el archivo wheel de la AWS CLI.

   ```
   python3 -m pip install awscli-1.19.31-py2.py3-none-any.whl
   ```
4. Ejecute el comando `aws configure`. Configure sus credenciales de AWS (incluida la clave de acceso y la clave secreta) y la región de AWS. Puede encontrar información acerca de cómo configurar la AWS CLI aquí: Configuración de AWS CLI.
5. Pruebe la AWS CLI. El siguiente comando debe devolver una lista vacía.

   Reemplace la `us-east-1` por su región.

   ```
   aws glue list-blueprints --region us-east-1
   ```

Escritura del código del esquema

Cada proyecto que cree debe contener como mínimo los siguientes archivos:

- Un script de diseño de Python que define el flujo de trabajo. El script contiene una función que define las entidades (trabajos y rastreadores) en un flujo de trabajo y las dependencias entre ellos.
- Un archivo de configuración, `blueprint.cfg`, que define:
  - La ruta completa de la función de definición de diseño del flujo de trabajo.
  - Los parámetros que acepta el proyecto.

Temas

- Creación del script de diseño del esquema
- Creación del archivo de configuración
- Especificación de parámetros del esquema

Creación del script de diseño del esquema

El script de diseño del proyecto debe incluir una función que genere las entidades en el flujo de trabajo. Puede nombrar esta función como quiera. AWS Glue utiliza el archivo de configuración para determinar el nombre completo de la función.

La función de diseño hace lo siguiente:

- (Opcional) genera instancias de clase `Job` para crear objetos `Job`, y transfiere argumentos como `Command` y `Role`. Estas son propiedades de trabajo que especificaría al crear el trabajo mediante la consola de AWS Glue o la API.
- (Opcional) genera instancias de clase `Crawler` para crear objetos `Crawler`, y transfiere nombre, rol y argumentos de destino.
- Para indicar dependencias entre los objetos (entidades de flujo de trabajo), transfiere los argumentos adicionales `DependsOn` y `WaitForDependencies` a `Job()` y `Crawler()`. Estos argumentos se explican más adelante en esta sección.
- Inicia la clase `Workflow` para crear el objeto de flujo de trabajo que se devuelve a AWS Glue, al transferir un argumento `Name`, un argumento `Entities` y un argumento opcional `OnSchedule`. El argumento `Entities` especifica todos los trabajos y rastreadores que se incluirán en el flujo de trabajo. Para ver cómo construir un objeto `Entities`, consulte el proyecto de ejemplo más adelante en esta sección.

- Devuelve un objeto `Workflow`.

Para conocer las definiciones de las clases `Job`, `Crawler` y `Workflow`, consulte Referencia de clases de esquemas de AWS Glue.

La función de diseño debe aceptar los siguientes argumentos de entrada.

Argumento	Descripción
`user_params`	Diccionario de Python de nombres y valores de parámetros del proyecto. Para obtener más información, consulte Especificación de parámetros del esquema.
`system_params`	Diccionario de Python que contiene dos propiedades: `region` y `accountId` .

Aquí hay un script de generador de diseño de ejemplo en un archivo denominado `Layout.py`:

```
import argparse
import sys
import os
import json
from awsglue.blueprint.workflow import *
from awsglue.blueprint.job import *
from awsglue.blueprint.crawler import *


def generate_layout(user_params, system_params):

    etl_job = Job(Name="{}_etl_job".format(user_params['WorkflowName']),
                  Command={
                      "Name": "glueetl",
                      "ScriptLocation": user_params['ScriptLocation'],
                      "PythonVersion": "2"
                  },
                  Role=user_params['PassRole'])
    post_process_job = Job(Name="{}_post_process".format(user_params['WorkflowName']),
                           Command={
                               "Name": "pythonshell",
                               "ScriptLocation": user_params['ScriptLocation'],
```

```
                            "PythonVersion": "2"
                        },
                        Role=user_params['PassRole'],
                        DependsOn={
                            etl_job: "SUCCEEDED"
                        },
                        WaitForDependencies="AND")
    sample_workflow = Workflow(Name=user_params['WorkflowName'],
                        Entities=Entities(Jobs=[etl_job, post_process_job]))
    return sample_workflow
```

El script de ejemplo importa las bibliotecas del proyecto requeridas e incluye una función `generate_layout` que genera un flujo de trabajo con dos trabajos. Este es un script muy sencillo. Un script más complejo podría emplear lógica y parámetros adicionales para generar un flujo de trabajo con muchos trabajos y rastreadores, o incluso un número variable de trabajos y rastreadores.

Uso del argumento DependsOn (Depende de)

El argumento `DependsOn` es una representación de diccionario de una dependencia que esta entidad tiene en otras entidades dentro del flujo de trabajo. Tiene el formato siguiente.

```
DependsOn = {dependency1 : state, dependency2 : state, ...}
```

Las claves de este diccionario representan la referencia del objeto, no el nombre de la entidad, mientras que los valores son cadenas que corresponden al estado que se debe controlar. AWS Glue infiere los desencadenantes adecuados. Para conocer los estados válidos, consulte Estructura de condiciones.

Por ejemplo, un trabajo puede depender de la finalización correcta de un rastreador. Si define un objeto de rastreador llamado `crawler2` de la siguiente manera:

```
crawler2 = Crawler(Name="my_crawler", ...)
```

Un objeto que dependa de `crawler2` incluiría un argumento constructor como:

```
DependsOn = {crawler2 : "SUCCEEDED"}
```

Por ejemplo:

```
job1 = Job(Name="Job1", ..., DependsOn = {crawler2 : "SUCCEEDED", ...})
```

Si se omite `DependsOn` para una entidad, esa entidad depende del desencadenador de inicio del flujo de trabajo.

Uso del argumento WaitForDependencies (Esperar a las dependencias)

El argumento `WaitForDependencies` define si una entidad de trabajo o rastreador debe esperar hasta que todas las entidades de las que depende se completen o hasta que alguna se complete.

Los valores permitidos son “AND” o “ANY”.

Uso del argumento OnSchedule (Programado)

El argumento `OnSchedule` para el constructor de clase `Workflow` es una expresión `cron` que establece la definición del desencadenador inicial para un flujo de trabajo.

Si se especifica este argumento, AWS Glue crea un desencadenador de programación con la programación correspondiente. Si no se especifica, el desencadenador de inicio del flujo de trabajo es un desencadenador bajo demanda.

Creación del archivo de configuración

El archivo de configuración del proyecto es un archivo necesario que define el punto de entrada del script para generar el flujo de trabajo, y los parámetros que acepta el proyecto. El archivo debe denominarse `blueprint.cfg`.

A continuación se ofrece un archivo de configuración de ejemplo.

```
{
    "layoutGenerator": "DemoBlueprintProject.Layout.generate_layout",
    "parameterSpec" : {
           "WorkflowName" : {
                "type": "String",
                "collection": false
           },
           "WorkerType" : {
                "type": "String",
                "collection": false,
                "allowedValues": ["G1.X", "G2.X"],
                "defaultValue": "G1.X"
           },
           "Dpu" : {
                "type" : "Integer",
```

```
                "allowedValues" : [2, 4, 6],
                "defaultValue" : 2
            },
            "DynamoDBTableName": {
                "type": "String",
                "collection" : false
            },
            "ScriptLocation" : {
                "type": "String",
                "collection": false
     }
    }
}
```

La propiedad `layoutGenerator` especifica el nombre completo de la función en el script que genera el diseño.

La propiedad `parameterSpec` especifica los parámetros que acepta este proyecto. Para obtener más información, consulte Especificación de parámetros del esquema.

> **Important**
>
> El archivo de configuración debe incluir el nombre del flujo de trabajo como parámetro del proyecto, o debe generar un nombre de flujo de trabajo único en el script de diseño.

Especificación de parámetros del esquema

El archivo de configuración contiene especificaciones de parámetros del proyecto en un objeto JSON `parameterSpec`. `parameterSpec` contiene uno o varios objetos de parámetro.

```
"parameterSpec": {
    "<parameter_name>": {
      "type": "<parameter-type>",
      "collection": true|false,
      "description": "<parameter-description>",
      "defaultValue": "<default value for the parameter if value not specified>"
      "allowedValues": "<list of allowed values>"
    },
    "<parameter_name>": {
       ...
```

```
    }
  }
```

Las siguientes son las reglas para codificar cada objeto de parámetro:

- El nombre y `type` de parámetro son obligatorios. Todas las demás propiedades son opcionales.
- Si especifica la propiedad `defaultValue`, el parámetro es opcional. De lo contrario, el parámetro es obligatorio y el analista de datos que está creando un flujo de trabajo a partir del proyecto debe proporcionar un valor para él.
- Si establece la propiedad `collection` a `true`, el parámetro puede tomar una recopilación de valores. Las recopilaciones pueden ser de cualquier tipo de datos.
- Si especifica `allowedValues`, la consola de AWS Glue muestra una lista desplegable de valores para que el analista de datos elija al crear un flujo de trabajo a partir del esquema.

Se permiten los siguientes valores para `type`:

Tipos de datos de los parámetros	Notas
`String`	-
`Integer`	-
`Double`	-
`Boolean`	Los posibles valores son `true` y `false`. Genera una casilla de verificación en la página Create a workflow from <blueprint> (Crear un flujo de trabajo a partir de <esquema>) en la consola de AWS Glue.
`S3Uri`	Complete la ruta de Amazon S3. Comience con `s3://`. Genera un campo de texto y el botón Browse (Examinar) en la página Create a workflow from <blueprint> (Crear un flujo de trabajo a partir de <proyecto>).
`S3Bucket`	Solo el nombre del bucket de Amazon S3. Genera un selector de buckets en la página Create a workflow from <blueprint> (Crear un flujo de trabajo a partir de <proyecto>).

Tipos de datos de los parámetros	Notas
`IAMRoleArn`	El nombre de recurso de Amazon (ARN) del rol de AWS Identity and Access Management (IAM). Genera un selector de roles en la página Create a workflow from <blueprint> (Crear un flujo de trabajo a partir de <proyecto>).
`IAMRoleName`	El nombre de un rol de IAM. Genera un selector de roles en la página Create a workflow from <blueprint> (Crear un flujo de trabajo a partir de <proyecto>).

Proyecto de esquema de ejemplo

La conversión de formato de datos es un caso de uso frecuente de extracción, transformación y carga (ETL). En cargas de trabajo analíticas típicas, se prefieren los formatos de archivo basados en columnas como Parquet u ORC sobre los formatos de texto como CSV o JSON. Este proyecto de ejemplo le permite convertir datos de CSV/JSON/etc. a Parquet para archivos en Amazon S3.

Este proyecto toma una lista de rutas S3 definidas por un parámetro del proyecto, convierte los datos al formato Parquet y los escribe en la ubicación S3 especificada por otro parámetro del proyecto. El script de diseño crea un rastreador y un trabajo para cada ruta. El script de diseño también carga el script de ETL en `Conversion.py` a un bucket S3 especificado por otro parámetro del proyecto. Luego, el script de diseño especifica el script cargado como el script de ETL para cada trabajo. El archivo ZIP del proyecto contiene el script de diseño, el script de ETL y el archivo de configuración del proyecto.

Para obtener más información sobre más proyectos de ejemplo, consulte Esquemas de ejemplo.

El siguiente es el script de diseño en el archivo `Layout.py`.

```
from awsglue.blueprint.workflow import *
from awsglue.blueprint.job import *
from awsglue.blueprint.crawler import *
import boto3

s3_client = boto3.client('s3')

# Ingesting all the S3 paths as Glue table in parquet format
```

```
def generate_layout(user_params, system_params):
    #Always give the full path for the file
    with open("ConversionBlueprint/Conversion.py", "rb") as f:
        s3_client.upload_fileobj(f, user_params['ScriptsBucket'], "Conversion.py")
    etlScriptLocation = "s3://{}/Conversion.py".format(user_params['ScriptsBucket'])

    crawlers = []
    jobs = []
    workflowName = user_params['WorkflowName']
    for path in user_params['S3Paths']:
      tablePrefix = "source_"
      crawler = Crawler(Name="{}_crawler".format(workflowName),
                        Role=user_params['PassRole'],
                        DatabaseName=user_params['TargetDatabase'],
                        TablePrefix=tablePrefix,
                        Targets= {"S3Targets": [{"Path": path}]})
      crawlers.append(crawler)
      transform_job = Job(Name="{}_transform_job".format(workflowName),
                          Command={"Name": "glueetl",
                                   "ScriptLocation": etlScriptLocation,
                                   "PythonVersion": "3"},
                          Role=user_params['PassRole'],
                          DefaultArguments={"--database_name":
 user_params['TargetDatabase'],
                                            "--table_prefix": tablePrefix,
                                            "--region_name": system_params['region'],
                                            "--output_path":
 user_params['TargetS3Location']},
                          DependsOn={crawler: "SUCCEEDED"},
                          WaitForDependencies="AND")
      jobs.append(transform_job)
    conversion_workflow = Workflow(Name=workflowName, Entities=Entities(Jobs=jobs,
 Crawlers=crawlers))
    return conversion_workflow
```

El siguiente es el archivo de configuración del proyecto correspondiente, `blueprint.cfg`.

```
{
    "layoutGenerator": "ConversionBlueprint.Layout.generate_layout",
    "parameterSpec" : {
        "WorkflowName" : {
            "type": "String",
            "collection": false,
```

```
            "description": "Name for the workflow."
        },
        "S3Paths" : {
            "type": "S3Uri",
            "collection": true,
            "description": "List of Amazon S3 paths for data ingestion."
        },
        "PassRole" : {
            "type": "IAMRoleName",
            "collection": false,
            "description": "Choose an IAM role to be used in running the job/crawler"
        },
        "TargetDatabase": {
            "type": "String",
            "collection" : false,
            "description": "Choose a database in the Data Catalog."
        },
        "TargetS3Location": {
            "type": "S3Uri",
            "collection" : false,
            "description": "Choose an Amazon S3 output path: ex:s3://<target_path>/."
        },
        "ScriptsBucket": {
            "type": "S3Bucket",
            "collection": false,
            "description": "Provide an S3 bucket name(in the same AWS Region) to store
 the scripts."
        }
    }
}
```

El siguiente script en el archivo `Conversion.py` es el script de ETL cargado. Tenga en cuenta que el esquema de partición se conserva durante la conversión.

```
import sys
from pyspark.sql.functions import *
from pyspark.context import SparkContext
from awsglue.transforms import *
from awsglue.context import GlueContext
from awsglue.job import Job
from awsglue.utils import getResolvedOptions
import boto3
```

```
args = getResolvedOptions(sys.argv, [
    'JOB_NAME',
    'region_name',
    'database_name',
    'table_prefix',
    'output_path'])
databaseName = args['database_name']
tablePrefix = args['table_prefix']
outputPath = args['output_path']

glue = boto3.client('glue', region_name=args['region_name'])

glue_context = GlueContext(SparkContext.getOrCreate())
spark = glue_context.spark_session
job = Job(glue_context)
job.init(args['JOB_NAME'], args)

def get_tables(database_name, table_prefix):
    tables = []
    paginator = glue.get_paginator('get_tables')
    for page in paginator.paginate(DatabaseName=database_name, Expression=table_prefix
+"*"):
        tables.extend(page['TableList'])
    return tables

for table in get_tables(databaseName, tablePrefix):
    tableName = table['Name']
    partitionList = table['PartitionKeys']
    partitionKeys = []
    for partition in partitionList:
        partitionKeys.append(partition['Name'])

    # Create DynamicFrame from Catalog
    dyf = glue_context.create_dynamic_frame.from_catalog(
        name_space=databaseName,
        table_name=tableName,
        additional_options={
            'useS3ListImplementation': True
        },
        transformation_ctx='dyf'
    )

    # Resolve choice type with make_struct
    dyf = ResolveChoice.apply(
```

```
        frame=dyf,
        choice='make_struct',
        transformation_ctx='resolvechoice_' + tableName
    )

    # Drop null fields
    dyf = DropNullFields.apply(
        frame=dyf,
        transformation_ctx="dropnullfields_" + tableName
    )

    # Write DynamicFrame to S3 in glueparquet
    sink = glue_context.getSink(
        connection_type="s3",
        path=outputPath,
        enableUpdateCatalog=True,
        partitionKeys=partitionKeys
    )
    sink.setFormat("glueparquet")

    sink.setCatalogInfo(
        catalogDatabase=databaseName,
        catalogTableName=tableName[len(tablePrefix):]
    )
    sink.writeFrame(dyf)

job.commit()
```

> **Note**
>
> Sólo se pueden suministrar dos rutas de Amazon S3 como entrada al proyecto de ejemplo. Esto se debe a que los desencadenadores de AWS Glue se limitan a invocar solo dos acciones de rastreador.

Pruebas a un esquema

Mientras desarrolla el código, debe realizar pruebas locales para verificar que el diseño del flujo de trabajo es correcto.

Las pruebas locales no generan trabajos, rastreadores o desencadenadores de AWS Glue. En su lugar, ejecute el script de diseño a nivel local y utilice los métodos `to_json()` y `validate()` para

imprimir objetos y buscar errores. Estos métodos están disponibles en las tres clases definidas en las bibliotecas.

Hay dos formas de manejar los argumentos `user_params` y `system_params` que AWS Glue transfiere a la función de diseño. Su código de banco de pruebas puede crear un diccionario de valores de parámetros del proyecto de ejemplo y transferirlo a la función de diseño como el argumento `user_params`. O bien, puede eliminar las referencias a `user_params` y reemplazarlas con cadenas codificadas.

Si su código hace uso de las propiedades `region` y `accountId` en el argumento `system_params`, puede transferir su propio diccionario para `system_params`.

Para realizar pruebas a un proyecto

1. Inicie un intérprete de Python en un directorio con las bibliotecas, o cargue los archivos del proyecto y las bibliotecas suministradas en su entorno de desarrollo integrado (IDE) preferido.
2. Asegúrese de que el código importe las bibliotecas suministradas.
3. Agregue código a su función de diseño para realizar llamadas a `validate()` o `to_json()` en cualquier entidad o en el objeto de `Workflow`. Por ejemplo, si su código crea un objeto de `Crawler` denominado `mycrawler`, puede llamar a `validate()` de la siguiente manera.

   ```
   mycrawler.validate()
   ```

   Puede imprimir `mycrawler` de la siguiente manera:

   ```
   print(mycrawler.to_json())
   ```

   Si llama a `to_json` en un objeto, no hay necesidad de llamar también a `validate()`, ya que `to_json()` llama a `validate()`.

   Es muy útil llamar a estos métodos en el objeto de flujo de trabajo. Suponiendo que el script nombra el objeto de flujo de trabajo `my_workflow`, valide e imprima el objeto de flujo de trabajo de la siguiente manera.

   ```
   print(my_workflow.to_json())
   ```

   Para obtener más información sobre `to_json()` y `validate()`, consulte Métodos de clase.

También puede importar `pprint` e imprimir el objeto de flujo de trabajo, tal y como se muestra en el ejemplo que se encuentra a continuación en esta sección.

4. Ejecute el código, corrija los errores y, por último, elimine cualquier llamada a `validate()` o `to_json()`.

Example

El siguiente ejemplo muestra cómo construir un diccionario de parámetros del proyecto de ejemplo y transferirlo como el argumento `user_params` a la función de diseño `generate_compaction_workflow`. También muestra cómo imprimir el objeto de flujo de trabajo generado.

```
from pprint import pprint
from awsglue.blueprint.workflow import *
from awsglue.blueprint.job import *
from awsglue.blueprint.crawler import *

USER_PARAMS = {"WorkflowName": "compaction_workflow",
               "ScriptLocation": "s3://amzn-s3-demo-bucket/scripts/threaded-
compaction.py",
               "PassRole": "arn:aws:iam::111122223333:role/GlueRole-ETL",
               "DatabaseName": "cloudtrial",
               "TableName": "ct_cloudtrail",
               "CoalesceFactor": 4,
               "MaxThreadWorkers": 200}


def generate_compaction_workflow(user_params: dict, system_params: dict) -> Workflow:
    compaction_job = Job(Name=f"{user_params['WorkflowName']}_etl_job",
                         Command={"Name": "glueetl",
                                  "ScriptLocation": user_params['ScriptLocation'],
                                  "PythonVersion": "3"},
                         Role="arn:aws:iam::111122223333:role/
AWSGlueServiceRoleDefault",
                         DefaultArguments={"DatabaseName": user_params['DatabaseName'],
                                           "TableName": user_params['TableName'],
                                           "CoalesceFactor":
 user_params['CoalesceFactor'],
                                           "max_thread_workers":
 user_params['MaxThreadWorkers']})
```

```
    catalog_target = {"CatalogTargets": [{"DatabaseName": user_params['DatabaseName'],
 "Tables": [user_params['TableName']]}]}

    compacted_files_crawler = Crawler(Name=f"{user_params['WorkflowName']}_post_crawl",
                                      Targets = catalog_target,
                                      Role=user_params['PassRole'],
                                      DependsOn={compaction_job: "SUCCEEDED"},
                                      WaitForDependencies="AND",
                                      SchemaChangePolicy={"DeleteBehavior": "LOG"})

    compaction_workflow = Workflow(Name=user_params['WorkflowName'],
                                   Entities=Entities(Jobs=[compaction_job],

 Crawlers=[compacted_files_crawler]))
    return compaction_workflow

generated = generate_compaction_workflow(user_params=USER_PARAMS, system_params={})
gen_dict = generated.to_json()

pprint(gen_dict)
```

Publicación de un esquema

Después de crear un proyecto, debe cargarlo en Amazon S3. Debe disponer de permisos de escritura en el bucket de Amazon S3 que utilice para publicar el proyecto. También debe asegurarse de que el administrador de AWS Glue, que registrará el esquema, dispone de acceso de lectura al bucket de Amazon S3. Para las políticas de permiso de AWS Identity and Access Management (IAM) sugeridas para personas y roles para esquemas de AWS Glue, consulte Permisos de personas y roles para esquemas de AWS Glue.

Para publicar un proyecto

1. Cree los scripts, recursos y archivo de configuración del proyecto necesarios.
2. Agregue todos los archivos a un archivo ZIP y cargue el archivo ZIP a Amazon S3. Utilice un bucket de S3 que se encuentre en la misma región que la región en la que los usuarios se registrarán y ejecutarán el proyecto.

   Puede crear un archivo ZIP desde la línea de comandos con el siguiente comando.

   ```
   zip -r folder.zip folder
   ```

3. Agregue una política de bucket que otorgue permisos de lectura a la cuenta deseada de AWS. La siguiente es una política de ejemplo.

   JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Principal": {
        "AWS": "arn:aws:iam::111122223333:root"
      },
      "Action": "s3:GetObject",
      "Resource": "arn:aws:s3:::my-blueprints/*"
    }
  ]
}
```

4. Conceda el permiso `s3:GetObject` de IAM en el bucket de Amazon S3 al administrador de AWS Glue o a quien registrará los esquemas. Para obtener una política de ejemplo para conceder a los administradores, consulte Permisos de administrador de AWS Glue para esquemas.

Después de haber completado las pruebas locales del esquema, es posible que también desee realizar pruebas a un esquema en AWS Glue. Para realizar pruebas a un esquema en AWS Glue, este debe estar registrado. Puede restringir quién verá el proyecto registrado mediante la autorización de IAM o mediante cuentas de prueba independientes.

Véase también:

- Registrar un esquema en AWS Glue

Referencia de clases de esquemas de AWS Glue

Las bibliotecas para los esquemas de AWS Glue definen tres clases que se utilizan en el script de diseño del flujo de trabajo: `Job`, `Crawler` y `Workflow`.

Temas

- Clase de trabajo
- Clase de rastreador
- Clase de flujo de trabajo
- Métodos de clase

Clase de trabajo

La clase de `Job` representa un trabajo de ETL de AWS Glue.

Argumentos obligatorios del constructor

A continuación, se indican los argumentos obligatorios del constructor para la clase de `Job`.

Nombre del argumento	Tipo	Descripción
`Name`	`str`	Nombre a asignar al trabajo. AWS Glue agrega un sufijo generado en forma aleatoria al nombre para distinguir el trabajo de los creados por otras ejecuciones del esquema.
`Role`	`str`	El nombre de recurso de Amazon (ARN) del rol que el trabajo debe asumir mientras se ejecuta.
`Command`	`dict`	Comando de trabajo, tal como se especifica en Estructura JobCommand en la documentación de la API.

Argumentos opcionales del constructor

A continuación, se indican los argumentos opcionales del constructor para la clase de `Job`.

Nombre del argumento	Tipo	Descripción
`DependsOn`	`dict`	Lista de entidades de flujo de trabajo de las que depende el trabajo. Para obtener más informaci

Nombre del argumento	Tipo	Descripción
		ón, consulte Uso del argumento DependsOn (Depende de).
`WaitForDependencies`	`str`	Indica si el trabajo debe esperar hasta que todas las entidades de las que depende se completen antes de ejecutarse o hasta que alguna se complete. Para obtener más informaci ón, consulte Uso del argumento WaitForDependencies (Esperar a las dependencias). Omitir si el trabajo depende de una sola entidad.
(Propiedades del trabajo)	-	Cualquiera de las propiedades del trabajo enumeradas en Estructura de trabajo en la documentación de la API de AWS Glue (excepto `CreatedOn` y `LastModifiedOn`).

Clase de rastreador

La clase de `Crawler` representa un rastreador de AWS Glue.

Argumentos obligatorios del constructor

A continuación, se indican los argumentos obligatorios del constructor para la clase de `Crawler`.

Nombre del argumento	Tipo	Descripción
`Name`	`str`	Nombre a asignar al rastreador. AWS Glue agrega un sufijo generado en forma aleatoria al nombre para distinguir el rastreador de los creados por otras ejecuciones del esquema.
`Role`	`str`	ARN del rol que el rastreador debe asumir durante la ejecución.
`Targets`	`dict`	Recopilación de destinos que se rastrearán. Los argumentos del constructor de clase de `Targets` se definen en Estructura CrawlerTa

Nombre del argumento	Tipo	Descripción
		rgets en la documentación de la API. Todos los argumentos del constructor de `Targets` son opcionales, pero debe transferir al menos uno.

Argumentos opcionales del constructor

A continuación, se indican los argumentos opcionales del constructor para la clase de `Crawler`.

Nombre del argumento	Tipo	Descripción
`DependsOn`	`dict`	Lista de entidades del flujo de trabajo de las que depende el rastreador. Para obtener más información, consulte Uso del argumento DependsOn (Depende de).
`WaitForDependencies`	`str`	Indica si el rastreador debe esperar hasta que todas las entidades de las que depende se completen antes de ejecutarse o hasta que alguna se complete. Para obtener más información, consulte Uso del argumento WaitForDependencies (Esperar a las dependencias). Omitir si el rastreador depende de una sola entidad.
(Propiedades del rastreador)	-	Cualquiera de las propiedades del rastreador enumeradas en Estructura de rastreador en la documentación de la API de AWS Glue, con las siguientes excepciones: • `State` • `CrawlElapsedTime` • `CreationTime` • `LastUpdated` • `LastCrawl` • `Version`

Clase de flujo de trabajo

La clase de `Workflow` representa un flujo de trabajo de AWS Glue. El script de diseño del flujo de trabajo devuelve un objeto `Workflow`. AWS Gluecrea un flujo de trabajo basado en este objeto.

Argumentos obligatorios del constructor

A continuación, se indican los argumentos obligatorios del constructor para la clase de `Workflow`.

Nombre del argumento	Tipo	Descripción
`Name`	`str`	El nombre que se asignará al flujo de trabajo.
`Entities`	`Entities`	Conjunto de entidades (trabajos y rastreadores) que se incluirán en el flujo de trabajo. El constructor de clase de `Entities` acepta un argumento de `Jobs`, que es una lista de objetos de `Job`, y un argumento de `Crawlers`, que es una lista de objetos de `Crawler`.

Argumentos opcionales del constructor

A continuación, se indican los argumentos opcionales del constructor para la clase de `Workflow`.

Nombre del argumento	Tipo	Descripción
`Description`	`str`	Consulte Estructura de flujo de trabajo.
`DefaultRunProperties`	`dict`	Consulte Estructura de flujo de trabajo.
`OnSchedule`	`str`	Una expresión `cron`.

Métodos de clase

Las tres clases incluyen los métodos siguientes.

validate() [validar()]

Valida las propiedades del objeto y, si se encuentran errores, genera un mensaje y sale. No genera resultados si no hay errores. Para la clase de `Workflow`, se llama a sí mismo en cada entidad en el flujo de trabajo.

to_json() [a_json()]

Serializa el objeto a JSON. También llama a `validate()`. Para la clase de `Workflow`, el objeto JSON incluye listas de trabajos y rastreadores, y una lista de desencadenadores generados por las especificaciones de dependencia del trabajo y del rastreador.

Esquemas de ejemplo

Hay una serie de esquemas de ejemplo disponibles en el repositorio de Github de esquemas de AWS Glue. Estas muestras son solo de referencia y no están destinadas a su uso en producción.

Los títulos de los proyectos de ejemplo son:

- Compaction (Compactación): este proyecto crea un trabajo que compacta los archivos de entrada en segmentos más grandes en función del tamaño de archivo deseado.
- Conversion (Conversión): este proyecto convierte archivos de entrada en varios formatos de archivo estándar en formato Apache Parquet, que está optimizado para cargas de trabajo analíticas.
- Crawling Amazon S3 locations (Rastreo de ubicaciones de Amazon S3): este proyecto rastrea varias ubicaciones de Amazon S3 para agregar tablas de metadatos al Data Catalog.
- Custom connection to Data Catalog (Conexión personalizada a Data Catalog): este esquema accede a los almacenes de datos mediante conectores personalizados de AWS Glue, lee los registros y completa las definiciones de tabla en el catálogo de datos de AWS Glue en función del esquema de registros.
- Encoding (Codificación): este proyecto convierte sus archivos no UTF en archivos codificados UTF.
- Partitioning (Particionamiento): este proyecto crea un trabajo de partición que coloca los archivos de salida en particiones en función de claves de partición específicas.
- Importing Amazon S3 data into a DynamoDB table (Importación de datos de Amazon S3 en una tabla de DynamoDB): este proyecto importa datos de Amazon S3 en una tabla de DynamoDB.
- Standard table to governed (Tabla estándar que regirá): este esquema importa una tabla de Data Catalog de AWS Glue a una tabla de Lake Formation.

Registrar un esquema en AWS Glue

Después de que el desarrollador de AWS Glue ha codificado el esquema y ha cargado un archivo ZIP a Amazon Simple Storage Service (Amazon S3), un administrador de AWS Glue debe registrar el esquema. Registrar el proyecto hace que esté disponible para su uso.

Cuando registra un esquema, AWS Glue copia el archivo de esquemas en una ubicación reservada de Amazon S3. Podrá eliminar el archivo de la ubicación de carga.

Para registrar un proyecto, necesita permisos de lectura en la ubicación de Amazon S3 que contiene el archivo cargado. También necesita el permiso de AWS Identity and Access Management (IAM), `glue:CreateBlueprint`. Para obtener los permisos sugeridos para un administrador de AWS Glue que debe registrar, ver y mantener los esquemas, consulte Permisos de administrador de AWS Glue para esquemas.

Puede registrar un esquema con la consola de AWS Glue, la API de AWS Glue o AWS Command Line Interface (AWS CLI).

Para registrar un proyecto (consola)

1. Asegúrese de que dispone de permisos de lectura (`s3:GetObject`) en el archivo ZIP del proyecto en Amazon S3.
2. Abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.

   Inicie sesión como usuario con permisos para registrar un proyecto. Cambie a la misma región de AWS que el bucket de Amazon S3 que contiene el archivo ZIP del proyecto.
3. En el panel de navegación, elija Blueprints (Esquemas). Luego, en la página Blueprints (Esquemas), elija Add blueprint (Agregar esquema).
4. Escriba un nombre de proyecto y una descripción opcional.
5. Para ZIP archive location (S3) [Ubicación del archivo ZIP (S3)], ingrese la ruta de Amazon S3 del archivo ZIP del proyecto que se subió. Incluya el nombre del archivo en la ruta y comience la ruta con `s3://`.
6. (Opcional) agregue una o más etiquetas.
7. Elija Add blueprint (Agregar proyecto).

   La página Blueprints (Esquemas) vuelve a aparecer y muestra que el estado del proyecto es `CREATING`. Elija el botón de actualización hasta que el estado cambie a `ACTIVE` o `FAILED`.

8. Si el estado es `FAILED`, seleccione el proyecto y, en el menú Actions (Acciones), elija View (Visualizar).

   En la página de detalles se muestra el motivo del error. Si el mensaje de error es “Unable to access object at location... (No se puede acceder al objeto en la ubicación...)” o “Access denied on object at location... (Acceso denegado al objeto en la ubicación...)”, revise los siguientes requisitos:

   - El usuario con el que ha iniciado sesión debe tener permiso de lectura en el archivo ZIP del proyecto en Amazon S3.
   - El bucket de Amazon S3 que contiene el archivo ZIP debe tener una política de bucket que otorgue permiso de lectura sobre el objeto a su ID de cuenta de AWS. Para obtener más información, consulte Desarrollo de esquemas en AWS Glue.
   - El bucket de Amazon S3 que está utilizando debe estar en la misma región que la región en la que ha iniciado sesión en la consola.

9. Asegúrese de que los analistas de datos tengan permisos sobre el proyecto.

   La política de IAM sugerida para analistas de datos se muestra en Permisos de analista de datos para esquemas. Esta política concede `glue:GetBlueprint` sobre cualquier recurso. Si su política está más detallada al nivel de recursos, otorgue permisos a los analistas de datos sobre este recurso recién creado.

Para registrar un proyecto (AWS CLI)

1. Escriba el siguiente comando.

   ```
   aws glue create-blueprint --name <blueprint-name> [--description <description>] --
   blueprint-location s3://<s3-path>/<archive-filename>
   ```

2. Ingrese el siguiente comando para comprobar el estado del proyecto. Repita el comando hasta que el estado cambie a `ACTIVE` o `FAILED`.

   ```
   aws glue get-blueprint --name <blueprint-name>
   ```

   Si el estado es `FAILED` y el mensaje de error es “Unable to access object at location... (No se puede acceder al objeto en la ubicación...)” o “Access denied on object at location... (Acceso denegado al objeto en la ubicación...)”, revise los siguientes requisitos:

- El usuario con el que ha iniciado sesión debe tener permiso de lectura en el archivo ZIP del proyecto en Amazon S3.
- El bucket de Amazon S3 que contiene el archivo ZIP debe tener una política de bucket que otorgue permiso de lectura sobre el objeto a su ID de cuenta de AWS. Para obtener más información, consulte Publicación de un esquema.
- El bucket de Amazon S3 que está utilizando debe estar en la misma región que la región en la que ha iniciado sesión en la consola.

Véase también:

- Información general de los esquemas en AWS Glue

Visualización de esquemas en AWS Glue

Visualice un proyecto para revisar la descripción, el estado y las especificaciones de parámetros del proyecto, y para descargar el archivo ZIP del proyecto.

Puede visualizar un esquema con la consola de AWS Glue, la API de AWS Glue o AWS Command Line Interface (AWS CLI).

Para visualizar un proyecto (consola)

1. Abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. En el panel de navegación, elija Blueprints (Esquemas).
3. En la página Blueprints (Esquemas), seleccione un esquema. Luego, en el menú Actions (Acciones), seleccione View (Visualización).

Para visualizar un proyecto (AWS CLI)

- Ingrese el siguiente comando para ver sólo el nombre, la descripción y el estado del proyecto. Reemplace *<blueprint-name>* con el nombre del proyecto que se va a visualizar.

```
aws glue get-blueprint --name <blueprint-name>
```

El resultado del comando es similar al siguiente.

```
{
    "Blueprint": {
        "Name": "myDemoBP",
        "CreatedOn": 1587414516.92,
        "LastModifiedOn": 1587428838.671,
        "BlueprintLocation": "s3://amzn-s3-demo-bucket1/demo/
DemoBlueprintProject.zip",
        "Status": "ACTIVE"
    }
}
```

Ingrese el siguiente comando para ver también las especificaciones del parámetro.

```
aws glue get-blueprint --name <blueprint-name>  --include-parameter-spec
```

El resultado del comando es similar al siguiente.

```
{
    "Blueprint": {
        "Name": "myDemoBP",
        "CreatedOn": 1587414516.92,
        "LastModifiedOn": 1587428838.671,
        "ParameterSpec": "{\"WorkflowName\":{\"type\":\"String\",\"collection
\":false,\"description\":null,\"defaultValue\":null,\"allowedValues\":null},
\"PassRole\":{\"type\":\"String\",\"collection\":false,\"description\":null,
\"defaultValue\":null,\"allowedValues\":null},\"DynamoDBTableName\":{\"type
\":\"String\",\"collection\":false,\"description\":null,\"defaultValue\":null,
\"allowedValues\":null},\"ScriptLocation\":{\"type\":\"String\",\"collection
\":false,\"description\":null,\"defaultValue\":null,\"allowedValues\":null}}",
        "BlueprintLocation": "s3://awsexamplebucket1/demo/
DemoBlueprintProject.zip",
        "Status": "ACTIVE"
    }
}
```

Agregue el argumento `--include-blueprint` a fin de incluir una URL en el resultado que puede pegar en el navegador para descargar el archivo ZIP del esquema que AWS Glue almacenó.

Véase también:

- Información general de los esquemas en AWS Glue

Actualizar un esquema en AWS Glue

Puede actualizar un proyecto si tiene un script de diseño revisado, un conjunto revisado de parámetros del proyecto o archivos de soporte revisados. Al actualizar un proyecto, se crea una versión nueva.

La actualización de un proyecto no afecta los flujos de trabajo existentes creados a partir del proyecto.

Puede actualizar un esquema con la consola de AWS Glue, la API de AWS Glue o AWS Command Line Interface (AWS CLI).

En el siguiente procedimiento se supone que el desarrollador de AWS Glue ha creado y cargado un archivo ZIP del esquema actualizado en Amazon S3.

Para actualizar un proyecto (consola)

1. Asegúrese de que dispone de permisos de lectura (`s3:GetObject`) en el archivo ZIP del proyecto en Amazon S3.
2. Abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.

   Inicie sesión como usuario con permisos para actualizar un proyecto. Cambie a la misma región de AWS que el bucket de Amazon S3 que contiene el archivo ZIP del proyecto.
3. En el panel de navegación, elija Blueprints (Esquemas).
4. En la página Blueprints (Esquemas), seleccione un proyecto y, en el menú Actions (Acciones), elija Edit (Editar).
5. En la página Edit a blueprint (Editar un proyecto), actualice la Description (Descripción) o ZIP archive location (S3) [Ubicación del archivo ZIP (S3)] del proyecto. Asegúrese de incluir el nombre del archivo en la ruta.
6. Elija Save (Guardar).

   La página Blueprints (Esquemas) vuelve a aparecer y muestra que el estado del proyecto es `UPDATING`. Elija el botón de actualización hasta que el estado cambie a `ACTIVE` o `FAILED`.

7. Si el estado es `FAILED`, seleccione el proyecto y, en el menú Actions (Acciones), elija View (Visualizar).

   En la página de detalles se muestra el motivo del error. Si el mensaje de error es “Unable to access object at location... (No se puede acceder al objeto en la ubicación...)” o “Access denied on object at location... (Acceso denegado al objeto en la ubicación...)”, revise los siguientes requisitos:

   - El usuario con el que ha iniciado sesión debe tener permiso de lectura en el archivo ZIP del proyecto en Amazon S3.
   - El bucket de Amazon S3 que contiene el archivo ZIP debe tener una política de bucket que otorgue permiso de lectura sobre el objeto a su ID de cuenta de AWS. Para obtener más información, consulte Publicación de un esquema.
   - El bucket de Amazon S3 que está utilizando debe estar en la misma región que la región en la que ha iniciado sesión en la consola.

   > **Note**
   >
   > Si se produce un error en la actualización, la siguiente ejecución del proyecto utiliza la versión más reciente del proyecto que se registró o actualizó correctamente.

Para actualizar un proyecto (AWS CLI)

1. Ingrese el siguiente comando.

   ```
   aws glue update-blueprint --name <blueprint-name> [--description <description>] --
   blueprint-location s3://<s3-path>/<archive-filename>
   ```

2. Ingrese el siguiente comando para comprobar el estado del proyecto. Repita el comando hasta que el estado cambie a `ACTIVE` o `FAILED`.

   ```
   aws glue get-blueprint --name <blueprint-name>
   ```

   Si el estado es `FAILED` y el mensaje de error es “Unable to access object at location... (No se puede acceder al objeto en la ubicación...)” o “Access denied on object at location... (Acceso denegado al objeto en la ubicación...)”, revise los siguientes requisitos:

- El usuario con el que ha iniciado sesión debe tener permiso de lectura en el archivo ZIP del proyecto en Amazon S3.
- El bucket de Amazon S3 que contiene el archivo ZIP debe tener una política de bucket que otorgue permiso de lectura sobre el objeto a su ID de cuenta de AWS. Para obtener más información, consulte Publicación de un esquema.
- El bucket de Amazon S3 que está utilizando debe estar en la misma región que la región en la que ha iniciado sesión en la consola.

Véase también

- Información general de los esquemas en AWS Glue

Creación de un flujo de trabajo a partir de un esquema en AWS Glue

Puede crear un flujo de trabajo de AWS Glue en forma manual al agregar un componente a la vez, o puede crear un flujo de trabajo desde un esquema de AWS Glue. AWS Glue incluye esquemas para casos de uso habituales. Los desarrolladores de AWS Glue pueden crear esquemas adicionales.

Important

Limite la cantidad total de trabajos, rastreadores y desencadenadores de un flujo de trabajo a 100 o menos. Si incluye más de 100, es posible que se produzcan errores al intentar reanudar o detener las ejecuciones del flujo de trabajo.

Cuando utiliza un esquema, puede generar rápidamente un flujo de trabajo para un caso de uso específico basado en el caso de uso generalizado definido por el esquema. Defina el caso de uso específico al proporcionar valores para los parámetros del esquema. Por ejemplo, un esquema que particiona un conjunto de datos podría tener como parámetros las rutas de origen y destino de Amazon S3.

AWS Glue crea un flujo de trabajo a partir de un esquema al ejecutar el esquema. La ejecución del esquema guarda los valores de parámetro proporcionados y se utiliza para realizar un seguimiento del progreso y el resultado de la creación del flujo de trabajo y sus componentes. Al solucionar

problemas de un flujo de trabajo, puede visualizar la ejecución del esquema a fin de determinar los valores de los parámetros del esquema que se utilizaron para crear el flujo de trabajo.

Para crear y visualizar flujos de trabajo, necesita determinados permisos de IAM. Si desea ver una política de IAM sugerida, consulte Permisos de analista de datos para esquemas.

Puede crear un flujo de trabajo a partir de un esquema mediante la consola de AWS Glue, la API de AWS Glue o la AWS Command Line Interface (AWS CLI).

Para crear un flujo de trabajo a partir de un esquema (consola)

1. Abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.

   Inicie sesión como usuario con permisos para crear un flujo de trabajo.
2. En el panel de navegación, elija Blueprints (Esquemas).
3. Seleccione un esquema y, en el menú Actions (Acciones), elija Create workflow (Crear flujo de trabajo).
4. En la página Create a workflow from <blueprint-name> (Crear un flujo de trabajo a partir de <nombre del esquema>), ingrese la siguiente información:

   Parámetros del esquema

   Estos varían en función del diseño del esquema. Si tiene preguntas sobre los parámetros, consulte al desarrollador. Los esquemas generalmente incluyen un parámetro para el nombre del flujo de trabajo.

   rol de IAM

   El rol que asume AWS Glue para crear el flujo de trabajo y sus componentes. El rol debe tener permisos para crear y eliminar flujos de trabajo, trabajos, rastreadores y desencadenadores. Para obtener una política sugerida para el rol, consulte Permisos para roles de esquema.
5. Elija Enviar.

   Aparece la página Blueprint details (Detalles del esquema), que muestra una lista de ejecuciones del esquema en la parte inferior.
6. En la lista de ejecuciones del esquema, verifique el estado de creación del flujo de trabajo en la última ejecución del esquema.

El estado inicial es.`RUNNING` Elija el botón de actualización hasta que el estado pase a `SUCCEEDED` o `FAILED`.

7. Realice alguna de las siguientes acciones:

   - Si el estado de finalización es `SUCCEEDED`, puede ir a la página Workflows (Flujos de trabajo), seleccionar el flujo de trabajo recién creado y ejecutarlo. Antes de ejecutar el flujo de trabajo, puede revisar el gráfico de diseño.
   - Si el estado de finalización es `FAILED`, seleccione la ejecución del esquema y, en el menú Actions (Acciones), elija View (Visualizar) para ver el mensaje de error.

Para obtener más información sobre flujos de trabajo y esquemas, consulte los siguientes temas.

- Información general de los flujos de trabajo en AWS Glue
- Actualizar un esquema en AWS Glue
- Creación y desarrollo manual de un flujo de trabajo en AWS Glue

Visualización de las ejecuciones de esquema en AWS Glue

Visualice una ejecución de proyecto para ver la siguiente información:

- Nombre del flujo de trabajo que se creó.
- Valores de parámetros del esquema que se utilizaron para crear el flujo de trabajo.
- El estado de la operación de creación del flujo de trabajo.

Puede visualizar la ejecución de un esquema con la consola de AWS Glue, la API de AWS Glue o AWS Command Line Interface (AWS CLI).

Para visualizar una ejecución del proyecto (consola)

1. Abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. En el panel de navegación, elija Blueprints (Esquemas).
3. En la página Blueprints (Esquemas), seleccione un esquema. Luego, en el menú Actions (Acciones), seleccione View (Visualización).
4. En la parte inferior de la página Blueprint Details (Detalles del proyecto), seleccione una ejecución de proyecto y, en el menú Actions (Acciones), elija View (Visualizaciones).

Para visualizar la ejecución de un proyecto (AWS CLI)

- Ingrese el siguiente comando. Reemplace *<blueprint-name>* con el nombre del proyecto. Reemplace *<blueprint-run-id>* con el ID de ejecución del proyecto.

```
aws glue get-blueprint-run --blueprint-name <blueprint-name> --run-id <blueprint-run-id>
```

Véase también:

- Información general de los esquemas en AWS Glue

AWS CloudFormation para AWS Glue

CloudFormation es un servicio que puede crear muchos recursos de AWS. AWS Glue proporciona operaciones de API para crear objetos en AWS Glue Data Catalog. Sin embargo, podría ser más cómodo definir y crear objetos de AWS Glue y otros objetos de recursos de AWS relacionados en un archivo de plantilla de CloudFormation. A continuación, puede automatizar el proceso de creación de objetos.

CloudFormation proporciona una sintaxis simplificada, JSON (JavaScript Object Notation) o YAML (YAML Ain't Markup Language), para expresar la creación de recursos de AWS. Puede utilizar las plantillas de CloudFormation para definir objetos del Catálogo de datos, como bases de datos, tablas, particiones, rastreadores, clasificadores y conexiones. También puede definir objetos ETL, por ejemplo, trabajos, disparadores y puntos de enlace de desarrollo. Puede crear una plantilla que describa todos los recursos de AWS que desea y CloudFormation se encargará del aprovisionamiento y la configuración de dichos recursos.

Para obtener más información, consulte ¿Qué es AWS CloudFormation? y Trabajar con plantillas AWS CloudFormation en la Guía del usuario de AWS CloudFormation.

Si tiene previsto utilizar plantillas de CloudFormation que sean compatibles con AWS Glue, como administrador, debe conceder acceso a CloudFormation y a los servicios y acciones de AWS de los que depende. Para otorgar permisos para crear recursos de CloudFormation, adjunte la siguiente política a los usuarios que trabajan con CloudFormation:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "cloudformation:*"
      ],
      "Resource": "*"
    }
  ]
}
```

La siguiente tabla contiene las acciones que puede realizar una plantilla de CloudFormation en su nombre. Incluye enlaces a información sobre los tipos de recursos de AWS y sus tipos de propiedad que puede agregar a una plantilla de CloudFormation.

Recurso de AWS Glue	CloudFormationPlantilla de	AWS GlueEjemplos de
Clasificador	AWS::Glue::Classifier	Clasificador de grok, clasificador de JSON, clasificador de XML
Connection	AWS::Glue::Connection	Conexión de MySQL
Rastreador	AWS::Glue::Crawler	Rastreador de Amazon S3, rastreador de MySQL
Database	AWS::Glue::Database	Base de datos vacía, base de datos con tablas
Punto de enlace de desarrollo	AWS::Glue::DevEndpoint	Punto de enlace de desarrollo
Integración	AWS::Glue::Integration	Integración sin ETL
Propiedad de recursos de integración	AWS::Glue::IntegrationResourceProperty	Integración sin ETL con la propiedad de recurso de integración
Trabajo	AWS::Glue::Job	Trabajo de Amazon S3, trabajo de JDBC
Transformación de machine learning	AWS::Glue::MLTransform	Transformación de machine learning
Conjunto de reglas de calidad de datos	AWS::Glue::DataQualityRuleset	Conjunto de reglas de calidad de datos, conjunto de reglas de calidad de datos con el programador de EventBridge
Partición	AWS::Glue::Partition	Particiones de una tabla
Tabla	AWS::Glue::Table	Tabla en una base de datos

Recurso de AWS Glue	CloudFormationPlantilla de	AWS GlueEjemplos de
Desencadenador	AWS::Glue::Trigger	Disparador bajo demanda, disparador programado, disparador condicional

Para comenzar, utilice las siguientes plantillas de muestra y personalícelas con sus propios metadatos. A continuación, utilice la consola de CloudFormation para crear una pila de CloudFormation con el fin de agregar objetos a AWS Glue y cualquier servicio asociado. Muchos campos de un objeto de AWS Glue son opcionales. Estas plantillas ilustran los campos que son obligatorios o necesarios para un objeto de AWS Glue operativo y funcional.

Una plantilla de CloudFormation puede tener formato JSON o YAML. En estos ejemplos, se utiliza YAML para facilitar la legibilidad. Los ejemplos contienen comentarios (#) para describir los valores que están definidos en las plantillas.

Las plantillas de CloudFormation pueden incluir una sección `Parameters`. Esta sección se puede modificar en el texto de muestra o cuando se envía el archivo YAML a la consola de CloudFormation para crear una pila. La sección `Resources` de la plantilla contiene la definición de AWS Glue y los objetos relacionados. Las definiciones de sintaxis de plantilla de CloudFormation puede contener propiedades que incluyan sintaxis de propiedad más detallada. Es posible que no todas las propiedades sean necesarias para crear un objeto de AWS Glue. Estas muestras incluyen valores de ejemplo de propiedades comunes para crear un objeto de AWS Glue.

Plantilla de CloudFormation de muestra para una base de datos de AWS Glue

Una base de datos de AWS Glue en el Catálogo de datos contiene tablas de metadatos. La base de datos se compone de muy pocas propiedades y se puede crear en el Catálogo de datos con una plantilla de CloudFormation. La siguiente plantilla de muestra se proporciona para ayudarle a comenzar y para ilustrar el uso de las pilas de CloudFormation con AWS Glue. El único recurso creado por la plantilla de muestra es una base de datos denominada `cfn-mysampledatabase`. Puede cambiarlo si edita el texto de la muestra o cambia el valor en la consola de CloudFormation al enviar el código YAML.

A continuación, se muestran valores de ejemplo de propiedades comunes para crear una base de datos de AWS Glue. Para obtener más información sobre la plantilla de base de datos de CloudFormation para AWS Glue, consulte AWS::Glue::Database.

```
---
AWSTemplateFormatVersion: '2010-09-09'
# Sample CloudFormation template in YAML to demonstrate creating a database named
 mysampledatabase
# The metadata created in the Data Catalog points to the flights public S3 bucket
#
# Parameters section contains names that are substituted in the Resources section
# These parameters are the names the resources created in the Data Catalog
Parameters:
  CFNDatabaseName:
    Type: String
    Default: cfn-mysampledatabse

# Resources section defines metadata for the Data Catalog
Resources:
# Create an AWS Glue database
  CFNDatabaseFlights:
    Type: AWS::Glue::Database
    Properties:
      # The database is created in the Data Catalog for your account
      CatalogId: !Ref AWS::AccountId
      DatabaseInput:
        # The name of the database is defined in the Parameters section above
        Name: !Ref CFNDatabaseName
        Description: Database to hold tables for flights data
        LocationUri: s3://crawler-public-us-east-1/flight/2016/csv/
        #Parameters: Leave AWS database parameters blank
```

Plantilla de CloudFormation de muestra para una base de datos, tabla y partición de AWS Glue

Una tabla de AWS Glue contiene los metadatos que definen la estructura y la ubicación de los datos que desea procesar con los scripts de ETL. En una tabla, puede definir particiones para paralelizar el procesamiento de los datos. Una partición es un fragmento de datos que define con una clave. Por ejemplo, si se usa el mes como una clave, todos los datos de enero se encuentran en la misma

partición. En AWS Glue, las bases de datos pueden contener tablas y las tablas pueden contener particiones.

En la siguiente muestra se presenta cómo rellenar una base de datos, una tabla y particiones con una plantilla de CloudFormation. El formato de los datos base es `csv` y están delimitados por una coma (,). Como debe existir una base de datos para que pueda contener una tabla, y una tabla debe existir para que se puedan crear particiones, la plantilla utiliza la instrucción `DependsOn` para definir la dependencia de estos objetos cuando se crean.

Los valores de esta muestra definen una tabla que contiene los datos de vuelos de un bucket de Amazon S3 disponible públicamente. Con fines ilustrativos, solo hay definidas algunas columnas de los datos y una clave de partición. También se definen cuatro particiones en el Catálogo de datos. En los campos `StorageDescriptor` también se muestran algunos campos para describir el almacenamiento de los datos base.

```
---
AWSTemplateFormatVersion: '2010-09-09'
# Sample CloudFormation template in YAML to demonstrate creating a database, a table,
 and partitions
# The metadata created in the Data Catalog points to the flights public S3 bucket
#
# Parameters substituted in the Resources section
# These parameters are names of the resources created in the Data Catalog
Parameters:
  CFNDatabaseName:
    Type: String
    Default: cfn-database-flights-1
  CFNTableName1:
    Type: String
    Default: cfn-manual-table-flights-1
# Resources to create metadata in the Data Catalog
Resources:
###
# Create an AWS Glue database
  CFNDatabaseFlights:
    Type: AWS::Glue::Database
    Properties:
      CatalogId: !Ref AWS::AccountId
      DatabaseInput:
        Name: !Ref CFNDatabaseName
        Description: Database to hold tables for flights data
```

```
###
# Create an AWS Glue table
  CFNTableFlights:
    # Creating the table waits for the database to be created
    DependsOn: CFNDatabaseFlights
    Type: AWS::Glue::Table
    Properties:
      CatalogId: !Ref AWS::AccountId
      DatabaseName: !Ref CFNDatabaseName
      TableInput:
        Name: !Ref CFNTableName1
        Description: Define the first few columns of the flights table
        TableType: EXTERNAL_TABLE
        Parameters: {
    "classification": "csv"
  }
#       ViewExpandedText: String
        PartitionKeys:
        # Data is partitioned by month
        - Name: mon
          Type: bigint
        StorageDescriptor:
          OutputFormat: org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat
          Columns:
          - Name: year
            Type: bigint
          - Name: quarter
            Type: bigint
          - Name: month
            Type: bigint
          - Name: day_of_month
            Type: bigint
          InputFormat: org.apache.hadoop.mapred.TextInputFormat
          Location: s3://crawler-public-us-east-1/flight/2016/csv/
          SerdeInfo:
            Parameters:
              field.delim: ","
            SerializationLibrary: org.apache.hadoop.hive.serde2.lazy.LazySimpleSerDe
# Partition 1
# Create an AWS Glue partition
  CFNPartitionMon1:
    DependsOn: CFNTableFlights
    Type: AWS::Glue::Partition
    Properties:
```

```
      CatalogId: !Ref AWS::AccountId
      DatabaseName: !Ref CFNDatabaseName
      TableName: !Ref CFNTableName1
      PartitionInput:
        Values:
        - 1
        StorageDescriptor:
          OutputFormat: org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat
          Columns:
          - Name: mon
            Type: bigint
          InputFormat: org.apache.hadoop.mapred.TextInputFormat
          Location: s3://crawler-public-us-east-1/flight/2016/csv/mon=1/
          SerdeInfo:
            Parameters:
              field.delim: ","
            SerializationLibrary: org.apache.hadoop.hive.serde2.lazy.LazySimpleSerDe
# Partition 2
# Create an AWS Glue partition
  CFNPartitionMon2:
    DependsOn: CFNTableFlights
    Type: AWS::Glue::Partition
    Properties:
      CatalogId: !Ref AWS::AccountId
      DatabaseName: !Ref CFNDatabaseName
      TableName: !Ref CFNTableName1
      PartitionInput:
        Values:
        - 2
        StorageDescriptor:
          OutputFormat: org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat
          Columns:
          - Name: mon
            Type: bigint
          InputFormat: org.apache.hadoop.mapred.TextInputFormat
          Location: s3://crawler-public-us-east-1/flight/2016/csv/mon=2/
          SerdeInfo:
            Parameters:
              field.delim: ","
            SerializationLibrary: org.apache.hadoop.hive.serde2.lazy.LazySimpleSerDe
# Partition 3
# Create an AWS Glue partition
  CFNPartitionMon3:
    DependsOn: CFNTableFlights
```

```
    Type: AWS::Glue::Partition
    Properties:
      CatalogId: !Ref AWS::AccountId
      DatabaseName: !Ref CFNDatabaseName
      TableName: !Ref CFNTableName1
      PartitionInput:
        Values:
        - 3
        StorageDescriptor:
          OutputFormat: org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat
          Columns:
          - Name: mon
            Type: bigint
          InputFormat: org.apache.hadoop.mapred.TextInputFormat
          Location: s3://crawler-public-us-east-1/flight/2016/csv/mon=3/
          SerdeInfo:
            Parameters:
              field.delim: ","
            SerializationLibrary: org.apache.hadoop.hive.serde2.lazy.LazySimpleSerDe
# Partition 4
# Create an AWS Glue partition
  CFNPartitionMon4:
    DependsOn: CFNTableFlights
    Type: AWS::Glue::Partition
    Properties:
      CatalogId: !Ref AWS::AccountId
      DatabaseName: !Ref CFNDatabaseName
      TableName: !Ref CFNTableName1
      PartitionInput:
        Values:
        - 4
        StorageDescriptor:
          OutputFormat: org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat
          Columns:
          - Name: mon
            Type: bigint
          InputFormat: org.apache.hadoop.mapred.TextInputFormat
          Location: s3://crawler-public-us-east-1/flight/2016/csv/mon=4/
          SerdeInfo:
            Parameters:
              field.delim: ","
            SerializationLibrary: org.apache.hadoop.hive.serde2.lazy.LazySimpleSerDe
```

Plantilla de CloudFormation de muestra para un clasificador de grok de AWS Glue

Un clasificador de AWS Glue determina el esquema de sus datos. Un tipo de clasificador personalizado utiliza un patrón de grok para adaptarse a sus datos. Si el patrón coincide, el clasificador personalizado se utiliza para crear el esquema de la tabla y se establece `classification` en el valor configurado en la definición de clasificador.

Esta muestra genera un clasificador que crea un esquema con una columna denominada `message` y establece la clasificación en `greedy`.

```
---
AWSTemplateFormatVersion: '2010-09-09'
# Sample CFN YAML to demonstrate creating a classifier
#
# Parameters section contains names that are substituted in the Resources section
# These parameters are the names the resources created in the Data Catalog
Parameters:

# The name of the classifier to be created
  CFNClassifierName:
    Type: String
    Default: cfn-classifier-grok-one-column-1

#
#
# Resources section defines metadata for the Data Catalog
Resources:
# Create classifier that uses grok pattern to put all data in one column and classifies
 it as "greedy".
  CFNClassifierFlights:
    Type: AWS::Glue::Classifier
    Properties:
      GrokClassifier:
        #Grok classifier that puts all data in one column
        Name: !Ref CFNClassifierName
        Classification: greedy

        GrokPattern: "%{GREEDYDATA:message}"
        #CustomPatterns: none
```

Plantilla de CloudFormation de muestra para un clasificador de JSON de AWS Glue

Un clasificador de AWS Glue determina el esquema de sus datos. Un tipo de clasificador personalizado utiliza una cadena `JsonPath` que define los datos JSON que el clasificador debe clasificar. AWS Glue es compatible con un subconjunto de los operadores de `JsonPath`, tal y como se describe en Escritura de clasificadores personalizados JSON.

Si el patrón coincide, el clasificador personalizado se utiliza para crear el esquema de la tabla.

En esta muestra se crea un clasificador que genera un esquema con cada registro de la matriz `Records3` en un objeto.

```
---
AWSTemplateFormatVersion: '2010-09-09'
# Sample CFN YAML to demonstrate creating a JSON classifier
#
# Parameters section contains names that are substituted in the Resources section
# These parameters are the names the resources created in the Data Catalog
Parameters:

# The name of the classifier to be created
  CFNClassifierName:
    Type: String
    Default: cfn-classifier-json-one-column-1

#
#
# Resources section defines metadata for the Data Catalog
Resources:
# Create classifier that uses a JSON pattern.
  CFNClassifierFlights:
    Type: AWS::Glue::Classifier
    Properties:
      JSONClassifier:
        #JSON classifier
        Name: !Ref CFNClassifierName
        JsonPath: $.Records3[*]
```

Plantilla de CloudFormation de muestra para un clasificador de XML de AWS Glue

Un clasificador de AWS Glue determina el esquema de sus datos. Un tipo de clasificador personalizado especifica una etiqueta XML para designar el elemento que contiene cada registro en un documento XML que se está analizando. Si el patrón coincide, el clasificador personalizado se utiliza para crear el esquema de la tabla y se establece `classification` en el valor configurado en la definición de clasificador.

En esta muestra se crea un clasificador que genera un esquema con cada registro de la etiqueta `Record` y establece la clasificación en `XML`.

```
---
AWSTemplateFormatVersion: '2010-09-09'
# Sample CFN YAML to demonstrate creating an XML classifier
#
# Parameters section contains names that are substituted in the Resources section
# These parameters are the names the resources created in the Data Catalog
Parameters:

# The name of the classifier to be created
  CFNClassifierName:
    Type: String
    Default: cfn-classifier-xml-one-column-1

#
#
# Resources section defines metadata for the Data Catalog
Resources:
# Create classifier that uses the XML pattern and classifies it as "XML".
  CFNClassifierFlights:
    Type: AWS::Glue::Classifier
    Properties:
      XMLClassifier:
        #XML classifier
        Name: !Ref CFNClassifierName
        Classification: XML
        RowTag: <Records>
```

Plantilla de CloudFormation de muestra para un rastreador de AWS Glue para Amazon S3

Un rastreador de AWS Glue crea tablas de metadatos en el Catálogo de datos que se corresponden con sus datos. A continuación, puede utilizar estas definiciones de tabla como orígenes y destinos en sus trabajos de ETL.

Esta muestra crea un rastreador, el rol de IAM necesario y una base de datos de AWS Glue en el Catálogo de datos. Cuando se ejecuta este rastreador, asume el rol de IAM y crea una tabla en la base de datos correspondiente a los datos de vuelos públicos. La tabla se crea con el prefijo "`cfn_sample_1_`". El rol de IAM que crea esta plantilla otorga permisos globales; es recomendable que cree un rol personalizado. No se definen clasificadores personalizados mediante este clasificador. De forma predeterminada, se usan los clasificadores integrados de AWS Glue.

Al enviar esta muestra a la consola de CloudFormation, debe confirmar que desea crear el rol de IAM.

```
---
AWSTemplateFormatVersion: '2010-09-09'
# Sample CFN YAML to demonstrate creating a crawler
#
# Parameters section contains names that are substituted in the Resources section
# These parameters are the names the resources created in the Data Catalog
Parameters:

# The name of the crawler to be created
  CFNCrawlerName:
    Type: String
    Default: cfn-crawler-flights-1
  CFNDatabaseName:
    Type: String
    Default: cfn-database-flights-1
  CFNTablePrefixName:
    Type: String
    Default: cfn_sample_1_
#
#
# Resources section defines metadata for the Data Catalog
Resources:
```

```
#Create IAM Role assumed by the crawler. For demonstration, this role is given all
 permissions.
  CFNRoleFlights:
    Type: AWS::IAM::Role
    Properties:
      AssumeRolePolicyDocument:
        Version: "2012-10-17"
        Statement:
          -
            Effect: "Allow"
            Principal:
              Service:
                - "glue.amazonaws.com"
            Action:
              - "sts:AssumeRole"
      Path: "/"
      Policies:
        -
          PolicyName: "root"
          PolicyDocument:
            Version: "2012-10-17"
            Statement:
              -
                Effect: "Allow"
                Action: "*"
                Resource: "*"
 # Create a database to contain tables created by the crawler
  CFNDatabaseFlights:
    Type: AWS::Glue::Database
    Properties:
      CatalogId: !Ref AWS::AccountId
      DatabaseInput:
        Name: !Ref CFNDatabaseName
        Description: "AWS Glue container to hold metadata tables for the flights
crawler"
 #Create a crawler to crawl the flights data on a public S3 bucket
  CFNCrawlerFlights:
    Type: AWS::Glue::Crawler
    Properties:
      Name: !Ref CFNCrawlerName
      Role: !GetAtt CFNRoleFlights.Arn
      #Classifiers: none, use the default classifier
      Description: AWS Glue crawler to crawl flights data
      #Schedule: none, use default run-on-demand
```

```
      DatabaseName: !Ref CFNDatabaseName
      Targets:
        S3Targets:
          # Public S3 bucket with the flights data
          - Path: "s3://crawler-public-us-east-1/flight/2016/csv"
      TablePrefix: !Ref CFNTablePrefixName
      SchemaChangePolicy:
        UpdateBehavior: "UPDATE_IN_DATABASE"
        DeleteBehavior: "LOG"
      Configuration: "{\"Version\":1.0,\"CrawlerOutput\":{\"Partitions\":
{\"AddOrUpdateBehavior\":\"InheritFromTable\"},\"Tables\":{\"AddOrUpdateBehavior\":
\"MergeNewColumns\"}}}"
```

Plantilla de CloudFormation de muestra para una conexión de AWS Glue

Una conexión de AWS Glue en el Catálogo de datos contiene la información de JDBC y de red que es necesaria para conectarse a una base de datos JDBC. Esta información se utiliza al conectarse a una base de datos JDBC para rastrear o ejecutar trabajos de ETL.

Esta muestra crea una conexión a una base de datos de Amazon RDS MySQL denominada `devdb`. Cuando se utiliza esta conexión, también se suministran un rol de IAM, credenciales de base de datos y valores de conexión de red. Consulte los detalles de los campos necesarios en la plantilla.

```
---
AWSTemplateFormatVersion: '2010-09-09'
# Sample CFN YAML to demonstrate creating a connection
#
# Parameters section contains names that are substituted in the Resources section
# These parameters are the names the resources created in the Data Catalog
Parameters:

# The name of the connection to be created
  CFNConnectionName:
    Type: String
    Default: cfn-connection-mysql-flights-1
  CFNJDBCString:
    Type: String
    Default: "jdbc:mysql://xxx-mysql.yyyyyyyyyyyyyy.us-east-1.rds.amazonaws.com:3306/
devdb"
```

```
  CFNJDBCUser:
    Type: String
    Default: "master"
  CFNJDBCPassword:
    Type: String
    Default: "12345678"
    NoEcho: true
#
#
# Resources section defines metadata for the Data Catalog
Resources:
  CFNConnectionMySQL:
    Type: AWS::Glue::Connection
    Properties:
      CatalogId: !Ref AWS::AccountId
      ConnectionInput:
        Description: "Connect to MySQL database."
        ConnectionType: "JDBC"
        #MatchCriteria: none
        PhysicalConnectionRequirements:
          AvailabilityZone: "us-east-1d"
          SecurityGroupIdList:
           - "sg-7d52b812"
          SubnetId: "subnet-84f326ee"
        ConnectionProperties: {
          "JDBC_CONNECTION_URL": !Ref CFNJDBCString,
          "USERNAME": !Ref CFNJDBCUser,
          "PASSWORD": !Ref CFNJDBCPassword
        }
        Name: !Ref CFNConnectionName
```

Plantilla de ejemplo de CloudFormation para una integración sin ETL de AWS Glue

AWS zero-ETL es un conjunto de integraciones totalmente administradas que minimiza la necesidad de crear canalizaciones de datos de ETL para casos de uso habituales de ingesta y replicación.

En este ejemplo, se crea una integración sin ETL de la fuente dada al destino.

```
---
AWSTemplateFormatVersion: '2010-09-09'
```

```
# Sample CFN YAML to demonstrate creating a zero-ETL integration in AWS Glue
#
# Parameters section contains names that are substituted in the Resources section
#
Parameters:

  # The name of the zero-ETL integration to be created
  IntegrationName:
    Type: String
  # The ARN for the source of the zero-ETL integration
  SourceArn:
    Type: String
  # The ARN for the target of the zero-ETL integration
  TargetArn:
    Type: String
#
#
Resources:
# Create an AWS Glue zero-ETL integration
  GlueIntegration:
    Type: AWS::Glue::Integration
    Properties:
      IntegrationName: !Ref IntegrationName
      Description: "AWS Glue zero-ETL integration"
      SourceArn: !Ref SourceArn
      TargetArn: !Ref TargetArn
      DataFilter: "include:table1"
      Tags:
        - Key: Purpose
          Value: GlueZeroETLIntegration
```

Plantilla de ejemplo de CloudFormation para una integración sin ETL de AWS Glue con propiedades de recursos de integración

Una integración sin ETL de AWS Glue requiere que se definan propiedades de recursos tanto para el origen como para el destino. Para el origen, la única propiedad que debe definirse es el rol de IAM que la integración utilizará para acceder a la conexión de AWS Glue o a la base de datos de DynamoDB. Para el destino, las propiedades que pueden configurarse incluyen el rol de IAM que se utilizará para acceder al destino, la red de VPC en la que debe crearse la integración, el bus de eventos que se usará para configurar las notificaciones de eventos de la integración y la clave de KMS que se utilizará para el cifrado de datos.

En el siguiente ejemplo, se definen las propiedades de los recursos de origen y destino y, a continuación, se crea una integración sin ETL desde el origen hasta el destino.

```
---
AWSTemplateFormatVersion: '2010-09-09'
# Sample CFN YAML to demonstrate defining the integration resource properties and then
 creating a zero-ETL integration in AWS Glue
#
# Parameters section contains names that are substituted in the Resources section
#
Parameters:
  #The name of the zero-ETL integration to be created
  IntegrationName:
    Type: String
  # The ARN for the target of the zero-ETL integration
  TargetArn:
    Type: String
  # The ARN for the IAM role that will be used to access the target
  TargetRoleArn:
    Type: String
  # The ARN for the source of the zero-ETL integration
  SourceArn:
    Type: String
  # The ARN for the IAM role that will be used to access thesource
  SourceRoleArn:
    Type: String
#
#
Resources:
  # Integration Resource Property for zero-ETL target
  TargetIntegrationResourceProperty:
    Type: AWS::Glue::IntegrationResourceProperty
    Properties:
      ResourceArn: !Ref TargetArn
      TargetProcessingProperties:
        RoleArn: !Ref TargetRoleArn
      Tags:
        - Key: Purpose
          Value: TargetIrpTag

  # Integration Resource Property for zero-ETL source
  SourceIntegrationResourceProperty:
```

```
    Type: AWS::Glue::IntegrationResourceProperty
    Properties:
      ResourceArn: !Ref SourceArn
      SourceProcessingProperties:
        RoleArn: !Ref SourceRoleArn
      Tags:
        - Key: Purpose
          Value: SourceIRPTag

  # Create an AWS Glue zero-ETL integration
  GlueIntegration:
    Type: AWS::Glue::Integration
    Properties:
      IntegrationName: !Ref IntegrationName
      Description: "AWS Glue zero-ETL integration"
      SourceArn: !Ref SourceArn
      TargetArn: !Ref TargetArn
      DataFilter: "include:table1"
      Tags:
        - Key: Purpose
          Value: GlueZeroETLIntegration
```

Plantilla de CloudFormation de muestra para un rastreador de AWS Glue para JDBC

Un rastreador de AWS Glue crea tablas de metadatos en el Catálogo de datos que se corresponden con sus datos. A continuación, puede utilizar estas definiciones de tabla como orígenes y destinos en sus trabajos de ETL.

Esta muestra crea un rastreador, el rol de IAM necesario y una base de datos de AWS Glue en el Catálogo de datos. Cuando se ejecuta este rastreador, asume el rol de IAM y crea una tabla en la base de datos correspondiente a los datos de vuelos públicos que se han almacenado en una base de datos MySQL. La tabla se crea con el prefijo "`cfn_jdbc_1_`". El rol de IAM que crea esta plantilla otorga permisos globales; es recomendable que cree un rol personalizado. No se puede definir ningún clasificador personalizado para los datos de JDBC. De forma predeterminada, se usan los clasificadores integrados de AWS Glue.

Al enviar esta muestra a la consola de CloudFormation, debe confirmar que desea crear el rol de IAM.

```
---
AWSTemplateFormatVersion: '2010-09-09'
# Sample CFN YAML to demonstrate creating a crawler
#
# Parameters section contains names that are substituted in the Resources section
# These parameters are the names the resources created in the Data Catalog
Parameters:

# The name of the crawler to be created
  CFNCrawlerName:
    Type: String
    Default: cfn-crawler-jdbc-flights-1
# The name of the database to be created to contain tables
  CFNDatabaseName:
    Type: String
    Default: cfn-database-jdbc-flights-1
# The prefix for all tables crawled and created
  CFNTablePrefixName:
    Type: String
    Default: cfn_jdbc_1_
# The name of the existing connection to the MySQL database
  CFNConnectionName:
    Type: String
    Default: cfn-connection-mysql-flights-1
# The name of the JDBC path (database/schema/table) with wildcard (%) to crawl
  CFNJDBCPath:
    Type: String
    Default: saldev/%
#
#
# Resources section defines metadata for the Data Catalog
Resources:
#Create IAM Role assumed by the crawler. For demonstration, this role is given all
 permissions.
  CFNRoleFlights:
    Type: AWS::IAM::Role
    Properties:
      AssumeRolePolicyDocument:
        Version: "2012-10-17"
        Statement:
          -
            Effect: "Allow"
```

```
            Principal:
              Service:
                - "glue.amazonaws.com"
            Action:
              - "sts:AssumeRole"
      Path: "/"
      Policies:
        -
          PolicyName: "root"
          PolicyDocument:
            Version: "2012-10-17"
            Statement:
              -
                Effect: "Allow"
                Action: "*"
                Resource: "*"
# Create a database to contain tables created by the crawler
 CFNDatabaseFlights:
   Type: AWS::Glue::Database
   Properties:
     CatalogId: !Ref AWS::AccountId
     DatabaseInput:
       Name: !Ref CFNDatabaseName
       Description: "AWS Glue container to hold metadata tables for the flights
crawler"
#Create a crawler to crawl the flights data in MySQL database
 CFNCrawlerFlights:
   Type: AWS::Glue::Crawler
   Properties:
     Name: !Ref CFNCrawlerName
     Role: !GetAtt CFNRoleFlights.Arn
     #Classifiers: none, use the default classifier
     Description: AWS Glue crawler to crawl flights data
     #Schedule: none, use default run-on-demand
     DatabaseName: !Ref CFNDatabaseName
     Targets:
       JdbcTargets:
         # JDBC MySQL database with the flights data
         - ConnectionName: !Ref CFNConnectionName
           Path: !Ref CFNJDBCPath
         #Exclusions: none
     TablePrefix: !Ref CFNTablePrefixName
     SchemaChangePolicy:
       UpdateBehavior: "UPDATE_IN_DATABASE"
```

```
        DeleteBehavior: "LOG"
   Configuration: "{\"Version\":1.0,\"CrawlerOutput\":{\"Partitions\":
{\"AddOrUpdateBehavior\":\"InheritFromTable\"},\"Tables\":{\"AddOrUpdateBehavior\":
\"MergeNewColumns\"}}}"
```

Plantilla de CloudFormation de muestra para un trabajo de AWS Glue para Amazon S3 a Amazon S3

Un trabajo de AWS Glue en el Catálogo de datos contiene los valores de parámetros que son necesarios para ejecutar un script en AWS Glue.

Esta muestra crea un trabajo que lee datos de vuelos de un bucket de Amazon S3 en formato `csv` y los escribe en un archivo Parquet de Amazon S3. El script que ejecuta este flujo de trabajo ya debe existir. Puede generar un script de ETL para su entorno con la consola de AWS Glue. Cuando este trabajo se ejecuta, también se debe proporcionar un rol de IAM con los permisos correspondientes.

Los valores de parámetro comunes se muestran en la plantilla. Por ejemplo, el valor predeterminado de `AllocatedCapacity` (DPU) es 5.

```
---
AWSTemplateFormatVersion: '2010-09-09'
# Sample CFN YAML to demonstrate creating a job using the public flights S3 table in a
 public bucket
#
# Parameters section contains names that are substituted in the Resources section
# These parameters are the names the resources created in the Data Catalog
Parameters:

# The name of the job to be created
  CFNJobName:
    Type: String
    Default: cfn-job-S3-to-S3-2
# The name of the IAM role that the job assumes. It must have access to data, script,
 temporary directory
  CFNIAMRoleName:
    Type: String
    Default: AWSGlueServiceRoleGA
# The S3 path where the script for this job is located
  CFNScriptLocation:
    Type: String
```

```
    Default: s3://aws-glue-scripts-123456789012-us-east-1/myid/sal-job-test2
#
#
# Resources section defines metadata for the Data Catalog
Resources:
# Create job to run script which accesses flightscsv table and write to S3 file as
 parquet.
# The script already exists and is called by this job
  CFNJobFlights:
    Type: AWS::Glue::Job
    Properties:
      Role: !Ref CFNIAMRoleName
      #DefaultArguments: JSON object
      # If script written in Scala, then set DefaultArguments={'--job-language';
 'scala', '--class': 'your scala class'}
      #Connections:  No connection needed for S3 to S3 job
      #  ConnectionsList
      #MaxRetries: Double
      Description: Job created with CloudFormation
      #LogUri: String
      Command:
        Name: glueetl
        ScriptLocation: !Ref CFNScriptLocation
             # for access to directories use proper IAM role with permission to buckets
 and folders that begin with "aws-glue-"
             # script uses temp directory from job definition if required (temp
 directory not used S3 to S3)
             # script defines target for output as s3://aws-glue-target/sal
      AllocatedCapacity: 5
      ExecutionProperty:
        MaxConcurrentRuns: 1
      Name: !Ref CFNJobName
```

Plantilla de CloudFormation de muestra para un trabajo de AWS Glue para JDBC a Amazon S3

Un trabajo de AWS Glue en el Catálogo de datos contiene los valores de parámetros que son necesarios para ejecutar un script en AWS Glue.

Esta muestra crea un trabajo que lee los datos de vuelos de una base de datos MySQL JDBC según lo definido por la conexión denominada `cfn-connection-mysql-flights-1` y los escribe en

un archivo Parquet de Amazon S3. El script que ejecuta este flujo de trabajo ya debe existir. Puede generar un script de ETL para su entorno con la consola de AWS Glue. Cuando este trabajo se ejecuta, también se debe proporcionar un rol de IAM con los permisos correspondientes.

Los valores de parámetro comunes se muestran en la plantilla. Por ejemplo, el valor predeterminado de `AllocatedCapacity` (DPU) es 5.

```
---
AWSTemplateFormatVersion: '2010-09-09'
# Sample CFN YAML to demonstrate creating a job using a MySQL JDBC DB with the flights
 data to an S3 file
#
# Parameters section contains names that are substituted in the Resources section
# These parameters are the names the resources created in the Data Catalog
Parameters:

# The name of the job to be created
  CFNJobName:
    Type: String
    Default: cfn-job-JDBC-to-S3-1
# The name of the IAM role that the job assumes. It must have access to data, script,
 temporary directory
  CFNIAMRoleName:
    Type: String
    Default: AWSGlueServiceRoleGA
# The S3 path where the script for this job is located
  CFNScriptLocation:
    Type: String
    Default: s3://aws-glue-scripts-123456789012-us-east-1/myid/sal-job-dec4a
# The name of the connection used for JDBC data source
  CFNConnectionName:
    Type: String
    Default: cfn-connection-mysql-flights-1
#
#
# Resources section defines metadata for the Data Catalog
Resources:
# Create job to run script which accesses JDBC flights table via a connection and write
 to S3 file as parquet.
# The script already exists and is called by this job
  CFNJobFlights:
    Type: AWS::Glue::Job
```

```
    Properties:
      Role: !Ref CFNIAMRoleName
      #DefaultArguments: JSON object
      # For example, if required by script, set temporary directory as
 DefaultArguments={'--TempDir'; 's3://aws-glue-temporary-xyc/sal'}
      Connections:
        Connections:
        - !Ref CFNConnectionName
      #MaxRetries: Double
      Description: Job created with CloudFormation using existing script
      #LogUri: String
      Command:
        Name: glueetl
        ScriptLocation: !Ref CFNScriptLocation
             # for access to directories use proper IAM role with permission to buckets
 and folders that begin with "aws-glue-"
             # if required, script defines temp directory as argument TempDir and used
 in script like redshift_tmp_dir = args["TempDir"]
             # script defines target for output as s3://aws-glue-target/sal
      AllocatedCapacity: 5
      ExecutionProperty:
        MaxConcurrentRuns: 1
      Name: !Ref CFNJobName
```

Ejemplo de plantilla de CloudFormation para un desencadenador bajo demanda de AWS Glue

Un desencadenador de AWS Glue en el Catálogo de datos contiene los valores de parámetros que son necesarios para iniciar una ejecución de flujo de trabajo cuando se activa el desencadenador. Un disparador bajo demanda se activa cuando lo habilita.

Esta muestra crea un disparador bajo demanda que comienza un flujo de trabajo llamado `cfn-job-S3-to-S3-1`.

```
---
AWSTemplateFormatVersion: '2010-09-09'
# Sample CFN YAML to demonstrate creating an on-demand trigger
#
# Parameters section contains names that are substituted in the Resources section
# These parameters are the names the resources created in the Data Catalog
```

```
Parameters:
  # The existing job to be started by this trigger
  CFNJobName:
    Type: String
    Default: cfn-job-S3-to-S3-1
  # The name of the trigger to be created
  CFNTriggerName:
    Type: String
    Default: cfn-trigger-ondemand-flights-1
#
# Resources section defines metadata for the Data Catalog
# Sample CFN YAML to demonstrate creating an on-demand trigger for a job
Resources:
# Create trigger to run an existing job (CFNJobName) on an on-demand schedule.
  CFNTriggerSample:
    Type: AWS::Glue::Trigger
    Properties:
      Name:
        Ref: CFNTriggerName
      Description: Trigger created with CloudFormation
      Type: ON_DEMAND
      Actions:
        - JobName: !Ref CFNJobName
        # Arguments: JSON object
      #Schedule:
      #Predicate:
```

Plantilla de CloudFormation de muestra para un disparador programado de AWS Glue

Un desencadenador de AWS Glue en el Catálogo de datos contiene los valores de parámetros que son necesarios para iniciar una ejecución de flujo de trabajo cuando se activa el desencadenador. Un disparador programado se activa cuando está habilitado y se activa el temporizador cron.

Esta muestra crea un disparador programado que comienza un flujo de trabajo llamado `cfn-job-S3-to-S3-1`. El temporizador es una expresión cron para ejecutar el flujo de trabajo cada 10 minutos los días entre semana.

```
---
AWSTemplateFormatVersion: '2010-09-09'
```

```
# Sample CFN YAML to demonstrate creating a scheduled trigger
#
# Parameters section contains names that are substituted in the Resources section
# These parameters are the names the resources created in the Data Catalog
Parameters:
  # The existing job to be started by this trigger
  CFNJobName:
    Type: String
    Default: cfn-job-S3-to-S3-1
  # The name of the trigger to be created
  CFNTriggerName:
    Type: String
    Default: cfn-trigger-scheduled-flights-1
#
# Resources section defines metadata for the Data Catalog
# Sample CFN YAML to demonstrate creating a scheduled trigger for a job
#
Resources:
# Create trigger to run an existing job (CFNJobName) on a cron schedule.
  TriggerSample1CFN:
    Type: AWS::Glue::Trigger
    Properties:
      Name:
        Ref: CFNTriggerName
      Description: Trigger created with CloudFormation
      Type: SCHEDULED
      Actions:
        - JobName: !Ref CFNJobName
        # Arguments: JSON object
      # # Run the trigger every 10 minutes on Monday to Friday
      Schedule: cron(0/10 * ? * MON-FRI *)
      #Predicate:
```

Plantilla de CloudFormation de muestra para un disparador condicional de AWS Glue

Un desencadenador de AWS Glue en el Catálogo de datos contiene los valores de parámetros que son necesarios para iniciar una ejecución de flujo de trabajo cuando se activa el desencadenador. Un disparador condicional se activa cuando está habilitado y se cumplen sus condiciones, por ejemplo, que un flujo de trabajo se realice correctamente.

Esta muestra crea un disparador condicional que comienza un flujo de trabajo llamado `cfn-job-S3-to-S3-1`. Este flujo de trabajo comienza cuando el flujo de trabajo llamado `cfn-job-S3-to-S3-2` se completa correctamente.

```
---
AWSTemplateFormatVersion: '2010-09-09'
# Sample CFN YAML to demonstrate creating a conditional trigger for a job, which starts
 when another job completes
#
# Parameters section contains names that are substituted in the Resources section
# These parameters are the names the resources created in the Data Catalog
Parameters:
  # The existing job to be started by this trigger
  CFNJobName:
    Type: String
    Default: cfn-job-S3-to-S3-1
  # The existing job that when it finishes causes trigger to fire
  CFNJobName2:
    Type: String
    Default: cfn-job-S3-to-S3-2
  # The name of the trigger to be created
  CFNTriggerName:
    Type: String
    Default: cfn-trigger-conditional-1
#
Resources:
# Create trigger to run an existing job (CFNJobName) when another job completes
 (CFNJobName2).
  CFNTriggerSample:
    Type: AWS::Glue::Trigger
    Properties:
      Name:
        Ref: CFNTriggerName
      Description: Trigger created with CloudFormation
      Type: CONDITIONAL
      Actions:
        - JobName: !Ref CFNJobName
        # Arguments: JSON object
      #Schedule: none
      Predicate:
        #Value for Logical is required if more than 1 job listed in Conditions
        Logical: AND
```

```
        Conditions:
          - LogicalOperator: EQUALS
            JobName: !Ref CFNJobName2
            State: SUCCEEDED
```

Plantilla de CloudFormation de muestra para un punto de conexión de desarrollo de AWS Glue

Una transformación de machine learning de AWS Glue es una transformación personalizada para limpiar los datos. En la actualidad, hay una transformación disponible denominada FindMatches. La transformación FindMatches le permite identificar registros duplicados o coincidentes en el conjunto de datos, incluso cuando los registros no tienen un identificador único común y no coinciden exactamente los campos.

Este ejemplo crea una transformación de machine learning. Para obtener más información sobre los parámetros que se necesitan para crear una transformación de machine learning, consulte Coincidencia de registros con FindMatches de AWS Lake Formation.

```
---
AWSTemplateFormatVersion: '2010-09-09'
# Sample CFN YAML to demonstrate creating a machine learning transform
#
# Resources section defines metadata for the machine learning transform
Resources:
  MyMLTransform:
    Type: "AWS::Glue::MLTransform"
    Condition: "isGlueMLGARegion"
    Properties:
      Name: !Sub "MyTransform"
      Description: "The bestest transform ever"
      Role: !ImportValue MyMLTransformUserRole
      GlueVersion: "1.0"
      WorkerType: "Standard"
      NumberOfWorkers: 5
      Timeout: 120
      MaxRetries: 1
      InputRecordTables:
        GlueTables:
          - DatabaseName: !ImportValue MyMLTransformDatabase
            TableName: !ImportValue MyMLTransformTable
```

```
      TransformParameters:
        TransformType: "FIND_MATCHES"
        FindMatchesParameters:
          PrimaryKeyColumnName: "testcolumn"
          PrecisionRecallTradeoff: 0.5
          AccuracyCostTradeoff: 0.5
          EnforceProvidedLabels: True
      Tags:
        key1: "value1"
        key2: "value2"
      TransformEncryption:
        TaskRunSecurityConfigurationName: !ImportValue
 MyMLTransformSecurityConfiguration
        MLUserDataEncryption:
          MLUserDataEncryptionMode: "SSE-KMS"
          KmsKeyId: !ImportValue MyMLTransformEncryptionKey
```

Ejemplo de plantilla de CloudFormation para un conjunto de reglas de AWS Glue Data Quality

Un conjunto de reglas de calidad de datos de AWS Glue contiene reglas que se pueden evaluar en una tabla del catálogo de datos. Una vez colocado el conjunto de reglas en la tabla de destino, puede ir al catálogo de datos y realizar una evaluación para comparar los datos con las reglas del conjunto de reglas. Estas reglas pueden variar desde la evaluación del recuento de filas hasta la evaluación de la integridad referencial de los datos.

En el siguiente ejemplo, se muestra una plantilla de CloudFormation que crea un conjunto de reglas con una variedad de reglas en la tabla de destino especificada.

```
AWSTemplateFormatVersion: '2010-09-09'
# Sample CFN YAML to demonstrate creating a DataQualityRuleset
#
# Parameters section contains names that are substituted in the Resources section
# These parameters are the names the resources created in the Data Catalog
Parameters:

  # The name of the ruleset to be created
  RulesetName:
    Type: String
    Default: "CFNRulesetName"
  RulesetDescription:
```

```
    Type: String
    Default: "CFN DataQualityRuleset"
  # Rules that will be associated with this ruleset
  Rules:
    Type: String
    Default: 'Rules = [
        RowCount > 100,
        IsUnique "id",
        IsComplete "nametype"
        ]'
  # Name of database and table within Data Catalog which the ruleset will
  # be applied too
  DatabaseName:
    Type: String
    Default: "ExampleDatabaseName"
  TableName:
    Type: String
    Default: "ExampleTableName"

# Resources section defines metadata for the Data Catalog
Resources:
  # Creates a Data Quality ruleset under specified rules
  DQRuleset:
    Type: AWS::Glue::DataQualityRuleset
    Properties:
      Name: !Ref RulesetName
      Description: !Ref RulesetDescription
      # The String within rules must be formatted in DQDL, a language
      # used specifically to make rules
      Ruleset: !Ref Rules
      # The targeted table must exist within Data Catalog alongside
      # the correct database
      TargetTable:
        DatabaseName: !Ref DatabaseName
        TableName: !Ref TableName
```

Plantilla de CloudFormation de ejemplo para un conjunto de reglas de AWS Glue Data Quality con el programador de EventBridge

Un conjunto de reglas de calidad de datos de AWS Glue contiene reglas que se pueden evaluar en una tabla del catálogo de datos. Una vez colocado el conjunto de reglas en la tabla de destino, puede ir al catálogo de datos y realizar una evaluación para comparar los datos con las reglas

del conjunto de reglas. En lugar de tener que ir manualmente al catálogo de datos para evaluar el conjunto de reglas, también puede agregar un EventBridge Scheduler a nuestra plantilla de CloudFormation para programar estas evaluaciones del conjunto de reglas en un intervalo de tiempo determinado.

El siguiente ejemplo es una plantilla de CloudFormation que crea un conjunto de reglas de calidad de datos y un programador de EventBridge para evaluar el conjunto de reglas mencionado anteriormente cada cinco minutos.

```
AWSTemplateFormatVersion: '2010-09-09'
# Sample CFN YAML to demonstrate creating a DataQualityRuleset
#
# Parameters section contains names that are substituted in the Resources section
# These parameters are the names the resources created in the Data Catalog
Parameters:

  # The name of the ruleset to be created
  RulesetName:
    Type: String
    Default: "CFNRulesetName"
  # Rules that will be associated with this Ruleset
  Rules:
    Type: String
    Default: 'Rules = [
        RowCount > 100,
        IsUnique "id",
        IsComplete "nametype"
        ]'
  # The name of the Schedule to be created
  ScheduleName:
    Type: String
    Default: "ScheduleDQRulsetEvaluation"
  # This expression determines the rate at which the Schedule will evaluate
  # your data using the above ruleset
  ScheduleRate:
    Type: String
    Default: "rate(5 minutes)"
  # The Request that being sent must match the details of the Data Quality Ruleset
  ScheduleRequest:
    Type: String
    Default: '
        { "DataSource": { "GlueTable": { "DatabaseName": "ExampleDatabaseName",
         "TableName": "ExampleTableName" } },
```

```
         "Role": "role/AWSGlueServiceRoleDefault",
          "RulesetNames": [ ""CFNRulesetName"" ] }
        '

# Resources section defines metadata for the Data Catalog
Resources:
  # Creates a Data Quality ruleset under specified rules
  DQRuleset:
    Type: AWS::Glue::DataQualityRuleset
    Properties:
      Name: !Ref RulesetName
      Description: "CFN DataQualityRuleset"
      # The String within rules must be formatted in DQDL, a language
      # used specifically to make rules
      Ruleset: !Ref Rules
      # The targeted table must exist within Data Catalog alongside
      # the correct database
      TargetTable:
        DatabaseName: "ExampleDatabaseName"
        TableName: "ExampleTableName"
  # Create a Scheduler to schedule evaluation runs on the above ruleset
  ScheduleDQEval:
    Type: AWS::Scheduler::Schedule
    Properties:
      Name: !Ref ScheduleName
      Description: "Schedule DataQualityRuleset Evaluations"
      FlexibleTimeWindow:
        Mode: "OFF"
      ScheduleExpression: !Ref ScheduleRate
      ScheduleExpressionTimezone: "America/New_York"
      State: "ENABLED"
      Target:
        # The ARN is the API that will be run, since we want to evaluate our ruleset
        # we want this specific ARN
        Arn: "arn:aws:scheduler:::aws-sdk:glue:startDataQualityRulesetEvaluationRun"
        # Your RoleArn must have approval to schedule
        RoleArn: "arn:aws:iam::123456789012:role/AWSGlueServiceRoleDefault"
        # This is the Request that is being sent to the Arn
        Input: '
        { "DataSource": { "GlueTable": { "DatabaseName": "sampledb", "TableName":
 "meteorite" } },
         "Role": "role/AWSGlueServiceRoleDefault",
          "RulesetNames": [ "TestCFN" ] }
```

```
        '
```

Plantilla de CloudFormation de muestra para un punto de conexión de desarrollo de AWS Glue

Un punto de enlace de desarrollo de AWS Glue es un entorno que puede utilizar para desarrollar y probar los scripts de AWS Glue.

Esta muestra crea un punto de enlace de desarrollo con los valores de parámetro de red mínimos necesarios para crearlo correctamente. Para obtener más información acerca de los parámetros que necesita para configurar un punto de enlace de desarrollo, consulte Configuración de redes para el desarrollo de AWS Glue.

Proporcione un ARN (nombre de recurso de Amazon) de rol de IAM existente para crear el punto de enlace de desarrollo. Proporcione una clave pública RSA válida y mantenga disponible la clave privada correspondiente si tiene previsto crear un servidor de blocs de notas en el punto de enlace de desarrollo.

> **Note**
>
> Usted administrará los servidores de blocs de notas que cree y estén asociados con un punto de enlace de desarrollo. Por tanto, si elimina el punto de enlace de desarrollo, para eliminar el bloc de notas, será preciso que elimine la pila de CloudFormation en la consola de CloudFormation.

```
---
AWSTemplateFormatVersion: '2010-09-09'
# Sample CFN YAML to demonstrate creating a development endpoint
#
# Parameters section contains names that are substituted in the Resources section
# These parameters are the names the resources created in the Data Catalog
Parameters:

# The name of the crawler to be created
  CFNEndpointName:
    Type: String
    Default: cfn-devendpoint-1
```

```
  CFNIAMRoleArn:
    Type: String
    Default: arn:aws:iam::123456789012/role/AWSGlueServiceRoleGA
#
#
# Resources section defines metadata for the Data Catalog
Resources:
  CFNDevEndpoint:
    Type: AWS::Glue::DevEndpoint
    Properties:
      EndpointName: !Ref CFNEndpointName
      #ExtraJarsS3Path: String
      #ExtraPythonLibsS3Path: String
      NumberOfNodes: 5
      PublicKey: ssh-rsa public.....key myuserid-key
      RoleArn: !Ref CFNIAMRoleArn
      SecurityGroupIds:
        - sg-64986c0b
      SubnetId: subnet-c67cccac
```

Guía de programación de AWS Glue

Los scripts contienen código que extrae datos de orígenes, los transforma y los carga en destinos. AWS Glue ejecuta un script cuando inicia un flujo de trabajo.

Los scripts de ETL de AWS Glue están codificados en Python o Scala. Si bien todos los tipos de trabajo se pueden escribir en Python, en el AWS Glue caso de Spark, los trabajos también se pueden escribir en Scala. Al generar automáticamente la lógica de código de origen para el trabajo en AWS Glue Studio, se crea un script. Puede editar este script o proporcionar su propio script para procesar el flujo de trabajo de ETL.

Suministro de sus propios scripts personalizados

Los scripts realizan el flujo de trabajo de extracción, transformación y carga (ETL) en AWS Glue. Un script se crea al generar automáticamente lógica de código fuente para un flujo de trabajo. Puede editar este script generado o proporcionar su propio script personalizado.

Para proporcionar su propio script personalizado en AWS Glue, siga estos pasos generales:

1. Inicie sesión en la Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. Seleccione la pestaña Trabajos de ETL y, luego, consulte la sección Crear trabajo. Elija una opción de editor de script.
3. En This job runs (Ejecuciones de este flujo de trabajo), elija una de las siguientes opciones:
   - Crear un script nuevo con código repetitivo
   - Cargar y editar un script existente
4. En la página Propiedades de trabajo, elija rol de IAM necesaria para la ejecución de su script personalizado. Para obtener más información, consulte Administración de identidades y accesos para AWS Glue.
5. Elija cualquier conexión a la que su script haga referencia. Estos objetos son necesarios para conectarse a los almacenes de datos de JDBC necesarios.

   Una interfaz de red elástica es una interfaz de red virtual que puede asociar a una instancia en una nube virtual privada (VPC). Elija la interfaz de red elástica necesaria para conectarse al almacén de datos que se usa en el script.

6. Proporcione una configuración adicional, incluidos los parámetros, específica para su tipo de trabajo. Para obtener más información sobre la configuración de su tipo de trabajo, consulte la sección Creación de trabajos de ETL visual.
7. En la pestaña Script, pegue o escriba su script personalizado.

Utilice el contenido de esta sección para guiar el proceso de escritura de su guion personalizado.

Para obtener más información acerca de la adición de trabajos en AWS Glue, consulte Creación de trabajos de ETL visual.

Para obtener instrucciones paso a paso, consulte el tutorial Add job (Añadir flujo de trabajo) en la consola de AWS Glue.

Programación de scripts de Spark

Con AWS Glue resulta más sencillo escribir o autogenerar scripts de extracción, transformación y carga (ETL), además de probarlos y ejecutarlos. En esta sección se describen las extensiones de Apache Spark que se han introducido con AWS Glue y se ofrecen ejemplos sobre cómo codificar y ejecutar scripts de ETL en Python y Scala.

> **Important**
>
> Las distintas versiones de AWS Glue admiten diferentes versiones de Apache Spark. Su script personalizado debe ser compatible con la versión de Apache Spark admitida. Para obtener información acerca de las versiones de AWS Glue, consulte Glue version job property.

Temas

- Tutorial: Escritura de un script de Glue for Spark AWS
- Programación de scripts de ETL de AWS Glue en PySpark
- Programación de scripts de ETL de AWS Glue en Scala
- Características y optimizaciones para programar AWS Glue para los scripts de Spark ETL

Tutorial: Escritura de un script de Glue for Spark AWS

Este tutorial ofrece una introducción al proceso de escritura de scripts de AWS Glue. Puede ejecutar scripts de manera programada con trabajos, o bien de manera interactiva con sesiones interactivas. Para obtener más información acerca de las tareas, consulta Creación de trabajos de ETL visual. Para más información sobre las sesiones interactivas, consulte the section called “Información general sobre las sesiones interactivas de AWS Glue”.

El editor visual de AWS Glue Studio ofrece una interfaz gráfica, sin código, para crear trabajos con AWS Glue. AWS Agregue los scripts de Glue otra vez en los trabajos visuales. Le dan acceso al conjunto ampliado de herramientas disponibles para trabajar con los programas de Apache Spark. Puede acceder a API nativas de Spark, así como a bibliotecas de AWS Glue que facilitan los flujos de trabajo de extracción, transformación y carga (ETL) desde un script de AWS Glue.

En este tutorial, extraerá, transformará y cargará un conjunto de datos de multas de estacionamiento. El script que realiza este trabajo es idéntico, tanto en forma como en función, al generado en Making ETL easier with AWS Glue Studio en el Blog de macrodatos de AWS, que presenta el editor visual de AWS Glue Studio. Al ejecutar este script en un trabajo, puede compararlo con trabajos visuales y obervar cómo funcionan los scripts ETL de AWS Glue. Esto le permite usar funcionalidades adicionales que aún no están disponibles en los trabajos visuales.

En este tutorial utilizará lenguaje y bibliotecas Python. Scala dispone de funcionalidad similar. Después de seguir este tutorial, debería poder generar e inspeccionar un script de Scala de ejemplo para comprender cómo llevar a cabo el proceso de escritura de scripts de ETL de AWS Glue de Scala.

Requisitos previos

Este tutorial tiene los requisitos previos siguientes:

- Los mismos requisitos previos que en la publicación del blog de AWS Glue Studio, en la que se indica cómo ejecutar una plantilla de CloudFormation.

  Esta plantilla usa el catálogo de datos de AWS Glue para administrar el conjunto de datos de multas de estacionamiento disponible en `s3://aws-bigdata-blog/artifacts/gluestudio/`. Crea los siguientes recursos a los que se hará referencia:
- AWS Glue StudioRole (Rol): rol de IAM que ejecuta trabajos de AWS Glue
- AWS Glue StudioAmazon S3 Bucket (Bucket de Amazon S3): nombre del bucket de Amazon S3 para almacenar archivos relacionados con el blog

- AWS Glue StudioTicketsYYZDB: base de datos de AWS Glue Data Catalog
- AWS Glue StudioTableTickets: tabla de Data Catalog que se usará como origen
- AWS Glue StudioTableTrials: tabla de Data Catalog que se usará como origen
- AWS Glue StudioParkingTicketCount: tabla de Data Catalog que se usará como destino
- El script generado en la publicación del blog de AWS Glue Studio. En caso de que la publicación se modifique, el script también está disponible en el siguiente texto.

Generación de un script de ejemplo

El editor visual de AWS Glue Studio es una potente herramienta de generación de código que puede usar para crear una estructura que sirva de base para el script que quiera escribir. Utilizará esta herramienta para crear un script de ejemplo.

Si quiere omitir estos pasos, se proporciona el script.

Script de ejemplo del tutorial

```
import sys
from awsglue.transforms import *
from awsglue.utils import getResolvedOptions
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job

args = getResolvedOptions(sys.argv, ["JOB_NAME"])
sc = SparkContext()
glueContext = GlueContext(sc)
spark = glueContext.spark_session
job = Job(glueContext)
job.init(args["JOB_NAME"], args)

# Script generated for node S3 bucket
S3bucket_node1 = glueContext.create_dynamic_frame.from_catalog(
    database="yyz-tickets", table_name="tickets", transformation_ctx="S3bucket_node1"
)

# Script generated for node ApplyMapping
ApplyMapping_node2 = ApplyMapping.apply(
    frame=S3bucket_node1,
    mappings=[
```

```
        ("tag_number_masked", "string", "tag_number_masked", "string"),
        ("date_of_infraction", "string", "date_of_infraction", "string"),
        ("ticket_date", "string", "ticket_date", "string"),
        ("ticket_number", "decimal", "ticket_number", "float"),
        ("officer", "decimal", "officer_name", "decimal"),
        ("infraction_code", "decimal", "infraction_code", "decimal"),
        ("infraction_description", "string", "infraction_description", "string"),
        ("set_fine_amount", "decimal", "set_fine_amount", "float"),
        ("time_of_infraction", "decimal", "time_of_infraction", "decimal"),
    ],
    transformation_ctx="ApplyMapping_node2",
)

# Script generated for node S3 bucket
S3bucket_node3 = glueContext.write_dynamic_frame.from_options(
    frame=ApplyMapping_node2,
    connection_type="s3",
    format="glueparquet",
    connection_options={"path": "s3://DOC-EXAMPLE-BUCKET", "partitionKeys": []},
    format_options={"compression": "gzip"},
    transformation_ctx="S3bucket_node3",
)

job.commit()
```

Para generar un script de ejemplo

1. Complete el tutorial de AWS Glue Studio. Para completar este tutorial, consulte Creación de un trabajo en AWS Glue Studio a partir de un ejemplo de trabajo.
2. Vaya a la pestaña Script de la página de trabajo, tal como se muestra en la siguiente captura de pantalla:

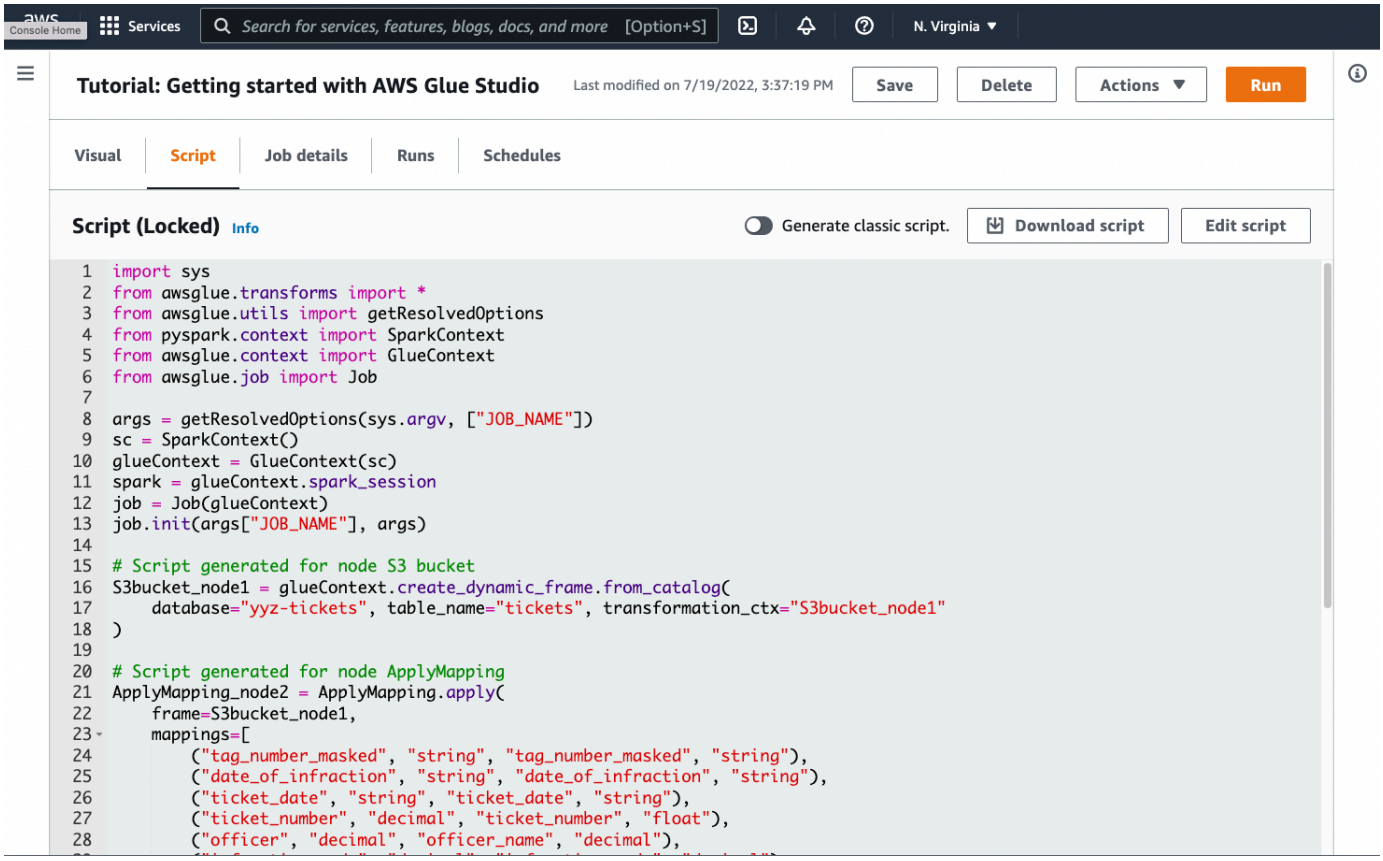

3. Copie el contenido completo de la pestaña Script. Configurando el lenguaje en Job details (Detalles del trabajo), puede cambiar y alternar entre generar código Python o Scala.

Paso 1. Crear un trabajo y pegar el script

En este paso, se crea un trabajo de AWS Glue en la Consola de administración de AWS. De esta forma, se establece una configuración que permite que AWS Glue ejecute el script. Además, crea un lugar donde almacenar y editar el script.

Para crear una tarea

1. En la Consola de administración de AWS, vaya a la página de inicio de AWS Glue.
2. En el panel de navegación lateral, seleccione Trabajos.
3. Elija Editor de scripts de Spark en Crear trabajo, a continuación, elija Crear.
4. Opcional Pegue todo el texto del script en el panel Script. Como alternativa, puede seguir el tutorial.

Paso 2. Importar bibliotecas de AWS Glue

Es necesario configurar el script para que interactúe con el código y la configuración que se definen fuera del script. Ese trabajo se realiza entre bastidores en AWS Glue Studio.

En este tutorial, se realizan las siguientes acciones.

- Importar e inicializar un objeto de `GlueContext`. Esta es la importación más importante, desde la perspectiva de la escritura de scripts. Esto expone métodos estándar para definir los conjuntos de datos de origen y de destino, que es el punto de partida de cualquier script ETL. Para obtener más información sobre la clase `GlueContext`, consulte Clase GlueContext.
- Inicializar una clase `SparkContext` y una clase `SparkSession`. Con ellas, puede configurar el motor de Spark disponible en el trabajo de AWS Glue. No necesitará utilizarlas directamente en scripts introductorios de AWS Glue.
- Llamar a `getResolvedOptions` con el fin de preparar los argumentos del trabajo para su uso en el script. Para obtener más información sobre la resolución de parámetros de trabajo, consulte the section called “getResolvedOptions”.
- Inicializar un objeto `Job`. El objeto `Job` establece la configuración y hace un seguimiento del estado de diversas características de AWS Glue. El script puede ejecutarse sin un objeto `Job`, pero lo mejor es inicializarlo para que no se produzcan confusiones si esas funciones se integran posteriormente.

  Una de esas características son los marcadores de trabajo, que puede configurar de manera opcional en este tutorial. Puede obtener información sobre los marcadores de trabajo en la siguiente sección, the section called “Opcional: habilitar marcadores de trabajo”.

En este procedimiento, escribirá el siguiente código. Este código es una parte del script de ejemplo generado.

```
from awsglue.transforms import *
from awsglue.utils import getResolvedOptions
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job

args = getResolvedOptions(sys.argv, ["JOB_NAME"])
sc = SparkContext()
glueContext = GlueContext(sc)
spark = glueContext.spark_session
```

```
job = Job(glueContext)
job.init(args["JOB_NAME"], args)
```

Para importar bibliotecas de AWS Glue

- Copie esta sección de código y péguela en el editor de Script.

> **Note**
>
> Es posible que copiar código le parezca una mala práctica de ingeniería. En este tutorial, sugerimos hacerlo para animarle a poner nombre de manera sistemática a las variables principales en todos los scripts de ETL de AWS Glue.

Paso 3. Extraer datos de un origen

En cualquier proceso de ETL, primero se debe definir el conjunto de datos de origen que quiere cambiar. En el editor visual de AWS Glue Studio, esta información se proporciona creando un nodo Source (Origen).

En este paso, se proporciona el método `create_dynamic_frame.from_catalog`, un `database` y `table_name`, para extraer datos de un origen configurado en el Catálogo de datos de AWS Glue.

En el paso anterior, se inicializó un objeto `GlueContext`. Ese objeto se emplea para buscar métodos que se utilizan para configurar orígenes, como `create_dynamic_frame.from_catalog`.

En este procedimiento, escribirá el siguiente código utilizando `create_dynamic_frame.from_catalog`. Este código es una parte del script de ejemplo generado.

```
S3bucket_node1 = glueContext.create_dynamic_frame.from_catalog(
    database="yyz-tickets", table_name="tickets", transformation_ctx="S3bucket_node1"
    )
```

Para extraer datos de un origen

1. Examine la documentación para encontrar un método en `GlueContext` para extraer datos de un origen definido en el Catálogo de datos de AWS Glue. Estos métodos están documentados

en the section called “GlueContext”. Elija el método create_dynamic_frame.from_catalog. Llame a este método en `glueContext`.

2. Examine la documentación de `create_dynamic_frame.from_catalog`. Este método necesita los parámetros `database` y `table_name`. Proporcione los parámetros necesarios a `create_dynamic_frame.from_catalog`.

   El Catálogo de datos de AWS Glue almacena información sobre la ubicación y el formato de los datos de origen, y se configuró en la sección de requisitos previos. No es necesario proporcionar directamente esa información al script.

3. Opcional: proporcione el parámetro `transformation_ctx` al método para que se admitan marcadores de trabajo. Puede obtener información sobre los marcadores de trabajo en la siguiente sección, the section called “Opcional: habilitar marcadores de trabajo”.

> **Note**
>
> Métodos habituales para extraer datos
> the section called “create_dynamic_frame_from_catalog” se utiliza para conectarse a tablas del Catálogo de datos de AWS Glue.
> Si necesita proporcionar directamente al trabajo una configuración que describa la estructura y ubicación del origen, consulte el método the section called “create_dynamic_frame_from_options”. Deberá proporcionar parámetros más detallados que describan los datos que si se utiliza `create_dynamic_frame.from_catalog`. Consulte la documentación suplementaria sobre `format_options` y `connection_parameters` para identificar los parámetros necesarios. Para ver una explicación sobre cómo proporcionar al script información sobre el formato de los datos de origen, consulte the section called “Opciones de formato de datos”. Para ver una explicación sobre cómo proporcionar al script información sobre la ubicación de los datos de origen, consulte the section called “Parámetros de conexión”.
> Si va a leer información de un origen que transmite flujos, debe proporcionar al trabajo información sobre el origen a través de los métodos the section called “create_data_frame_from_catalog” o the section called “create_data_frame_from_options”.
> Tenga en cuenta que estos métodos devuelven `DataFrames` de Apache Spark.
> Nuestro código generado llama a `create_dynamic_frame.from_catalog`, mientras que en la documentación de referencia se alude a `create_dynamic_frame_from_catalog`.
> En última instancia, estos métodos llaman al mismo código, y se incluyen para que pueda

escribir un código más limpio. Puede comprobar esto visualizando el código de origen de nuestro encapsulador de Python, disponible en aws-glue-libs.

Paso 4. Transformar los datos con AWS Glue

Después de extraer los datos de origen en un proceso de ETL, debe describir cómo desea cambiar los datos. Para proporcionar esta información, debe crear un nodo Transform (Transformación) en el editor visual de AWS Glue Studio.

En este paso, debe proporcionarle al método `ApplyMapping` un mapa de los nombres y tipos de campos actuales y deseados para transformar `DynamicFrame`.

Se deben realizar las siguientes transformaciones.

- Eliminar las cuatro claves `location` y `province`.
- Cambiar el nombre de `officer` por `officer_name`.
- Cambiar el tipo de `ticket_number` y `set_fine_amount` por `float`.

`create_dynamic_frame.from_catalog` proporciona un objeto `DynamicFrame`. `DynamicFrame` representa un conjunto de datos en AWS Glue. AWS Las transformaciones de Glue son operaciones que cambian `DynamicFrames`.

> **Note**
>
> ¿Qué es un `DynamicFrame`?
> Un `DynamicFrame` es una abstracción que permite conectar un conjunto de datos con una descripción de los nombres y tipos de entradas de los datos. En Apache Spark, existe una abstracción similar denominada DataFrame. Para ver una explicación sobre DataFrames, consulte la guía de Spark SQL.
> Con `DynamicFrames`, puede describir los esquemas de conjuntos de datos de forma dinámica. Imagine un conjunto de datos con una columna de precios, donde algunas entradas almacenan el precio como una cadena y otras lo hacen como un doble. AWS Glue calcula un esquema sobre la marcha: crea un registro autodescriptivo para cada fila.
> Los campos incoherentes (como el precio) se representan explícitamente con un tipo (`ChoiceType`) en el esquema del marco. Los campos incoherentes se pueden eliminar con `DropFields`, o bien resolverlos con `ResolveChoice`. Estas son transformaciones que

están disponibles en el DynamicFrame. Después, los datos se pueden volver a escribir en el lago de datos con writeDynamicFrame.
Puede llamar a muchas de las mismas transformaciones desde métodos de la clase DynamicFrame, lo que puede dar como resultado scripts más legibles. Para obtener más información acerca de DynamicFrame, consulte the section called “DynamicFrame”.

En este procedimiento, escribirá el siguiente código utilizando ApplyMapping. Este código es una parte del script de ejemplo generado.

```
ApplyMapping_node2 = ApplyMapping.apply(
    frame=S3bucket_node1,
    mappings=[
        ("tag_number_masked", "string", "tag_number_masked", "string"),
        ("date_of_infraction", "string", "date_of_infraction", "string"),
        ("ticket_date", "string", "ticket_date", "string"),
        ("ticket_number", "decimal", "ticket_number", "float"),
        ("officer", "decimal", "officer_name", "decimal"),
        ("infraction_code", "decimal", "infraction_code", "decimal"),
        ("infraction_description", "string", "infraction_description", "string"),
        ("set_fine_amount", "decimal", "set_fine_amount", "float"),
        ("time_of_infraction", "decimal", "time_of_infraction", "decimal"),
    ],
    transformation_ctx="ApplyMapping_node2",
)
```

Para transformar los datos con AWS Glue

1. Examine la documentación para identificar una transformación para cambiar y eliminar campos. Para obtener más información, consulte the section called “GlueTransform”. Elija la transformación ApplyMapping. Para obtener más información acerca de ApplyMapping, consulte the section called “ApplyMapping”. Llame a apply en el objeto de transformación ApplyMapping.

   > **Note**
   >
   > ¿Qué es ApplyMapping?
   > ApplyMapping toma un DynamicFrame y lo transforma. Toma una lista de tuplas que representan transformaciones en los campos, una “asignación”. Los dos primeros elementos de la tupla, un nombre y un tipo de campo, se utilizan para identificar un

campo en el marco. Los dos segundos parámetros también son un nombre y un tipo de campo.
ApplyMapping convierte el campo de origen en el nombre y tipo del destino en un nuevo `DynamicFrame`, que devuelve. Los campos que no se proporcionan se eliminan en el valor devuelto.
En lugar de llamar a `apply`, se puede llamar a la misma transformación con el método `apply_mapping` de `DynamicFrame` para crear código más fluido y legible. Para obtener más información, consulte the section called “apply_mapping”.

2. Examine la documentación de `ApplyMapping` para identificar los parámetros requeridos. Consulte the section called “ApplyMapping”. Descubrirá que este método requiere los parámetros `frame` y `mappings`. Proporcione los parámetros necesarios a `ApplyMapping`.
3. Opcional: proporcione `transformation_ctx` al método para que se admitan marcadores de trabajo. Puede obtener información sobre los marcadores de trabajo en la siguiente sección, the section called “Opcional: habilitar marcadores de trabajo”.

> **Note**
>
> Funcionalidad de Apache Spark
> Proporcionamos transformaciones para agilizar los flujos de trabajo de ETL dentro de un trabajo. Además, también puede acceder a las bibliotecas disponibles en un programa de Spark en el trabajo, creadas con fines más generales. Para utilizarlas, debe realizar conversiones entre `DynamicFrame` y `DataFrame`.
> Puede crear `DataFrame` con the section called “toDF”. A continuación, puede utilizar los métodos disponibles en el DataFrame para transformar su conjunto de datos. Para más información acerca de estos métodos, consulte DataFrame. A continuación, puede realizar la conversión inversa con the section called “fromDF” para utilizar operaciones de AWS Glue para cargar el marco a un objetivo.

Paso 5. Cargar datos en un destino

Después de transformar los datos, normalmente se almacenan los datos transformados en un lugar distinto al origen. Para realizar esta operación, cree un nodo target (destino) en el editor visual deAWS Glue Studio.

En este paso, se proporciona el método `write_dynamic_frame.from_options` los parámetros `connection_type`, `connection_options`, `format` y `format_options` para cargar datos en un bucket de destino en Amazon S3.

En el paso 1, inicializó un objeto `GlueContext`. En AWS Glue encontrará los métodos que se usan para configurar destinos y orígenes.

En este procedimiento, escribirá el siguiente código utilizando `write_dynamic_frame.from_options`. Este código es una parte del script de ejemplo generado.

```
S3bucket_node3 = glueContext.write_dynamic_frame.from_options(
    frame=ApplyMapping_node2,
    connection_type="s3",
    format="glueparquet",
    connection_options={"path": "s3://amzn-s3-demo-bucket", "partitionKeys": []},
    format_options={"compression": "gzip"},
    transformation_ctx="S3bucket_node3",
    )
```

Para cargar datos en un destino

1. Examine la documentación para buscar un método con el que cargar datos en un bucket de Amazon S3 de destino. Estos métodos están documentados en the section called “GlueContext”. Elija el método the section called “write_dynamic_frame_from_options”. Llame a este método en `glueContext`.

   > **Note**
   >
   > Métodos habituales para cargar datos
   > `write_dynamic_frame.from_options` es el método más utilizado para cargar datos. Es compatible con todos los destinos disponibles en AWS Glue.
   > Si va a escribir en un destino de JDBC definido en una conexión de AWS Glue, utilice el método the section called “write_dynamic_frame_from_jdbc_conf”. AWS Las conexiones de Glue almacenan información sobre cómo conectarse a un origen de datos. Esto elimina la necesidad de proporcionar esa información en `connection_options`. Sin embargo, aún es necesario utilizar `connection_options` para proporcionar `dbtable`.
   > `write_dynamic_frame.from_catalog` no es un método habitual para cargar datos. Este método actualiza el Catálogo de datos de AWS Glue sin actualizar el conjunto

de datos subyacente, y se utiliza en combinación con otros procesos que cambian el conjunto de datos subyacente. Para obtener más información, consulte the section called "Cómo actualizar el esquema y añadir nuevas particiones".

2. Examine la documentación de the section called "write_dynamic_frame_from_options". Este método requiere `frame`, `connection_type`, `format`, `connection_options` y `format_options`. Llame a este método en `glueContext`.

   a. Consulte la documentación suplementaria sobre `format_options` y `format` para identificar los parámetros que necesita. Para ver una explicación sobre los formatos de datos, consulte the section called "Opciones de formato de datos".

   b. Consulte la documentación suplementaria sobre `connection_type` y `connection_options` para identificar los parámetros que necesita. Para ver una explicación sobre las conexiones, consulte the section called "Parámetros de conexión".

   c. Proporcione los parámetros necesarios a `write_dynamic_frame.from_options`. Este método tiene una configuración similar a la de `create_dynamic_frame.from_options`.

3. Opcional proporcione `transformation_ctx` a `write_dynamic_frame.from_options` para que se admitan los marcadores de trabajo. Puede obtener información sobre los marcadores de trabajo en la siguiente sección, the section called "Opcional: habilitar marcadores de trabajo".

Paso 6. Confirmar el objeto **`Job`**

En el paso 1, inicializó un objeto `Job`. Es posible que necesite concluir manualmente su ciclo de vida al final del script si ciertas características opcionales lo requieren para funcionar correctamente, como cuando se utilizan marcadores de trabajos. Ese trabajo se realiza entre bastidores en AWS Glue Studio.

En este paso, llame al método `commit` del objeto `Job`.

En este procedimiento, escribirá el siguiente código. Este código es una parte del script de ejemplo generado.

```
job.commit()
```

Para confirmar el objeto **`Job`**

1. Si aún no lo ha hecho, realice los pasos opcionales indicados en las secciones anteriores para incluir `transformation_ctx`.
2. Llamar a `commit`.

Opcional: habilitar marcadores de trabajo

En todos los pasos anteriores, se le ha indicado que configure los parámetros `transformation_ctx`. Esto tiene relación con una característica denominada marcadores de trabajo.

Con los marcadores de trabajos, puede ahorrar tiempo y dinero con los trabajos que se ejecutan de forma recurrente, frente a conjuntos de datos en los que el trabajo anterior puede ser fácilmente rastreado. Los marcadores de trabajo hacen un seguimiento del progreso de una transformación de AWS Glue en un conjunto de datos a partir de ejecuciones anteriores. Al hacer un seguimiento de dónde terminaron las ejecuciones anteriores, AWS Glue puede limitar su trabajo a las filas que no haya procesado antes. Para más información acerca de los marcadores de trabajo, consulte the section called “Seguimiento de los datos procesados mediante marcadores de trabajo”.

Para habilitar los marcadores de trabajo, primero hay que agregar las instrucciones `transformation_ctx` en las funciones proporcionadas, tal como se describe en los ejemplos anteriores. El estado de los marcadores de trabajo se mantiene a través de las ejecuciones. Los parámetros `transformation_ctx` son claves que se usan para acceder a ese estado. Por sí solas, estas instrucciones no servirán de nada. También debe activar la característica en la configuración del trabajo.

En este procedimiento, habilita los marcadores de trabajo mediante Consola de administración de AWS.

Para habilitar los marcadores de trabajo

1. Vaya a la sección Job details (Detalles del trabajo) del trabajo correspondiente.
2. Establezca Job bookmark (Marcador de trabajo) como Enable (Habilitar).

Paso 7. Ejecutar el código en forma de trabajo

En este paso, ejecutará el trabajo para comprobar que ha completado correctamente este tutorial. Esto se consigue simplemente haciendo clic en un botón, como en el editor visual de AWS Glue Studio.

Para ejecutar el código en forma de trabajo

1. Elija Untitled job (Trabajo sin título) en la barra de título para editar y establecer el nombre del trabajo.
2. Vaya a la pestaña Job details (Detalles del trabajo). Asigne un Rol de IAM al trabajo. Puede utilizar el que haya creado la plantilla de CloudFormation en los requisitos previos del tutorial de AWS Glue Studio. Si ha completado ese tutorial, debería estar disponible como `AWS Glue StudioRole`.
3. Elija Save (Guardar) para guardar el script.
4. Elija Run (Ejecutar) para ejecutar el trabajo.
5. Vaya a la pestaña Ejecuciones para comprobar que el trabajo se ha completado.
6. Navegue hasta *`amzn-s3-demo-bucket`*, el destino de `write_dynamic_frame.from_options`. Compruebe que el resultado coincide con sus expectativas.

Para obtener más información sobre la configuración y administración de trabajos, consulte the section called “Suministro de sus propios scripts personalizados”.

Más información

Las bibliotecas y los métodos de Apache Spark están disponibles en los scripts de AWS Glue. Puede consultar la documentación de Spark para saber qué puede hacer con esas bibliotecas incluidas. Para obtener más información, consulte la sección de ejemplos del repositorio de origen de Spark.

AWS Glue 2.0+ incluye varias bibliotecas de Python habituales de manera predeterminada. También hay mecanismos para cargar dependencias propias en un trabajo de AWS Glue en un entorno de Scala o Python. Para más información sobre las dependencias de Python, consulte the section called “Bibliotecas Python”.

Para más ejemplos de cómo utilizar Características de AWS Glue en Python, consulte the section called “Muestras de Python”. Los trabajos de Scala y Python disponen de las mismas características,

de modo que los ejemplos para Python pueden servir de inspiración a la hora de realizar un trabajo similar en Scala.

Programación de scripts de ETL de AWS Glue en PySpark

Puede encontrar ejemplos de código de Python y utilidades para AWS Glue en el repositorio de ejemplos de AWS en el sitio web de GitHub.

Uso de Python con AWS Glue

AWS Glue soporta una extensión del dialecto PySpark Python para scripting de trabajos de extracción, transformación y carga (ETL). En esta sección se describe cómo utilizar Python en scripts de ETL con la API de AWS Glue.

- Configuración para usar Python con AWS Glue
- Llamada a las API de AWS Glue en Python
- Uso de bibliotecas de Python con AWS Glue
- Ejemplos de código Python en AWS Glue

Extensiones de PySpark de AWS Glue

AWS Glue ha creado las siguientes extensiones del dialecto PySpark Python.

- Acceso a los parámetros mediante `getResolvedOptions`
- Tipos de extensión PySpark
- Clase DynamicFrame
- Clase DynamicFrameCollection
- Clase DynamicFrameWriter
- Clase DynamicFrameReader
- Clase GlueContext

Transformaciones de PySpark de AWS Glue

AWS Glue ha creado las siguientes clases de transformación para utilizarlas en operaciones de ETL de PySpark.

- Clase de base GlueTransform
- Clase ApplyMapping
- Clase DropFields
- Clase DropNullFields
- Clase ErrorsAsDynamicFrame
- Clase FillMissingValues
- Clase de filtro
- Clase FindIncrementalMatches
- Clase FindMatches
- Clase FlatMap
- Clase Join
- Clase Map
- Clase MapToCollection
- mergeDynamicFrame
- Clase Relationalize
- Clase RenameField
- Clase ResolveChoice
- Clase SelectFields
- Clase SelectFromCollection
- Clase Spigot
- Clase SplitFields
- Clase SplitRows
- Clase Unbox
- Clase UnnestFrame

Configuración para usar Python con AWS Glue

Utilice Python para desarrollar sus scripts de ETL para trabajos de Spark. Las versiones de Python admitidas para los trabajos de ETL dependen de la versión de AWS Glue del trabajo. Para obtener más información acerca de las versiones de AWS Glue, consulte la Glue version job property.

Para configurar su sistema para usar Python con AWS Glue

Siga estos pasos para instalar Python y poder invocar las API de AWS Glue.

1. Si aún no tiene Python instalado, descárguelo e instálelo desde la página de descargas de Python.org.
2. Instale la AWS Command Line Interface (AWS CLI) tal como se detalla en la documentación de la AWS CLI.

   La AWS CLI no es directamente necesaria para usar Python. Sin embargo, su instalación y configuración es una forma cómoda de configurar AWS con sus credenciales de cuenta y comprobar que funcionan.
3. Instale el AWS SDK Python (Boto 3), como se documenta en Boto3 Quickstart.

   Las API de recurso de Boto 3 aún no están disponibles para AWS Glue. Actualmente, solo se pueden usar las API de cliente de Boto 3.

   Para obtener más información sobre Boto 3, consulte Introducción al SDK for Python (Boto3) de AWS.

Puede encontrar ejemplos de código de Python y utilidades para AWS Glue en el repositorio de ejemplos de AWS Glue en el sitio web de GitHub.

Llamada a las API de AWS Glue en Python

Tenga en cuenta que las API de recurso de Boto 3 aún no están disponibles para AWS Glue. Actualmente, solo se pueden usar las API de cliente de Boto 3.

Nombres de API de AWS Glue en Python

Los nombres de API de AWS Glue en Java y otros lenguajes de programación suelen ser CamelCased. Sin embargo, al recibir la llamada de Python, estos nombres genéricos se cambian a minúsculas, con las partes del nombre separadas por caracteres de guion bajo para que sean "más Python". En la documentación de referencia API de AWS Glue, estos nombres Python aparecen enumerados entre paréntesis después de los nombres CamelCased genéricos.

Sin embargo, aunque los propios nombres de API de AWS Glue cambian a minúsculas, los nombres de sus parámetros permanecen en mayúsculas. Es importante recordar esto, ya que los parámetros deben transferirse por nombre al llamar a las API de AWS Glue, tal como se describe en la sección siguiente.

Suministro y acceso a los parámetros de Python en AWS Glue

En las llamadas de Python a las API de AWS Glue, es mejor transferir los parámetros explícitamente por nombre. Por ejemplo:

```
job = glue.create_job(Name='sample', Role='Glue_DefaultRole',
                      Command={'Name': 'glueetl',
                               'ScriptLocation': 's3://my_script_bucket/scripts/
my_etl_script.py'})
```

Resulta útil para comprender que Python crea un diccionario de las tuplas nombre/valor que especifica como argumentos para un script de ETL en Estructura de trabajo o Estructura JobRun. Boto 3 los transfiere a continuación a AWS Glue en formato JSON a través de una llamada a la API REST. Esto significa que no puede depender del orden de los argumentos al obtener acceso a ellos en su script.

Por ejemplo, supongamos que inicia `JobRun` en una función del controlador de Lambda de Python y desea especificar varios parámetros. Su código podría tener un aspecto similar al siguiente:

```
from datetime import datetime, timedelta

client = boto3.client('glue')

def lambda_handler(event, context):
  last_hour_date_time = datetime.now() - timedelta(hours = 1)
  day_partition_value = last_hour_date_time.strftime("%Y-%m-%d")
  hour_partition_value = last_hour_date_time.strftime("%-H")

  response = client.start_job_run(
              JobName = 'my_test_Job',
              Arguments = {
                '--day_partition_key':   'partition_0',
                '--hour_partition_key':  'partition_1',
                '--day_partition_value':  day_partition_value,
                '--hour_partition_value': hour_partition_value } )
```

Para obtener acceso a estos parámetros de forma fiable en su script ETL, especifíquelos por nombre mediante la función `getResolvedOptions` de AWS Glue y, a continuación, obtenga acceso a ellos desde el diccionario resultante:

```
import sys
```

```
from awsglue.utils import getResolvedOptions

args = getResolvedOptions(sys.argv,
                          ['JOB_NAME',
                           'day_partition_key',
                           'hour_partition_key',
                           'day_partition_value',
                           'hour_partition_value'])
print "The day partition key is: ", args['day_partition_key']
print "and the day partition value is: ", args['day_partition_value']
```

Si desea transferir un argumento que es una cadena JSON anidada, para preservar el valor del parámetro a medida que se transfiere a su trabajo de ETL de AWS Glue, debe codificar la cadena de parámetros antes de iniciar la ejecución del trabajo y, a continuación, decodificar la cadena de parámetros antes de hacer referencia a su script de trabajo. Por ejemplo, tenga en cuenta las siguientes cadenas de argumentos:

```
glue_client.start_job_run(JobName = "gluejobname", Arguments={
"--my_curly_braces_string": '{"a": {"b": {"c": [{"d": {"e": 42}}]}}}'
})
```

Para transferir este parámetro correctamente, debe codificar el argumento como una cadena codificada en Base64.

```
import base64
...
sample_string='{"a": {"b": {"c": [{"d": {"e": 42}}]}}}'
sample_string_bytes = sample_string.encode("ascii")

base64_bytes = base64.b64encode(sample_string_bytes)
base64_string = base64_bytes.decode("ascii")
...
glue_client.start_job_run(JobName = "gluejobname", Arguments={
"--my_curly_braces_string": base64_bytes})
...
sample_string_bytes = base64.b64decode(base64_bytes)
sample_string = sample_string_bytes.decode("ascii")
print(f"Decoded string: {sample_string}")
...
```

Ejemplo: crear y ejecutar un trabajo

En el siguiente ejemplo se muestra cómo llamar a las API de AWS Glue con Python, para crear y ejecutar un flujo de trabajo de ETL.

Para crear y ejecutar un flujo de trabajo

1. Cree una instancia del cliente de AWS Glue:

```
import boto3
glue = boto3.client(service_name='glue', region_name='us-east-1',
              endpoint_url='https://glue.us-east-1.amazonaws.com')
```

2. Crear un flujo de trabajo. Debe utilizar `glueetl` como nombre del comando de ETL, tal como se muestra en el siguiente código:

```
myJob = glue.create_job(Name='sample', Role='Glue_DefaultRole',
                        Command={'Name': 'glueetl',
                                 'ScriptLocation': 's3://my_script_bucket/
scripts/my_etl_script.py'})
```

3. Inicie una nueva ejecución del flujo de trabajo que creó en el paso anterior:

```
myNewJobRun = glue.start_job_run(JobName=myJob['Name'])
```

4. Obtenga el estado del flujo de trabajo:

```
status = glue.get_job_run(JobName=myJob['Name'], RunId=myNewJobRun['JobRunId'])
```

5. Imprima el estado actual de la ejecución del flujo de trabajo:

```
print(status['JobRun']['JobRunState'])
```

Uso de bibliotecas de Python con AWS Glue

Puede instalar módulos y bibliotecas adicionales de Python para su uso con ETL de AWS Glue. Para AWS Glue 2.0 y versiones posteriores, AWS Glue utiliza el instalador de paquetes de Python (pip3) para instalar los módulos adicionales que utilizará ETL de AWS Glue. AWS Glue ofrece varias opciones para incorporar los módulos de Python adicionales a su entorno de trabajo de AWS Glue. Puede usar el parámetro “—additional-python-modules” para introducir módulos mediante archivos

Wheel de Python, un archivo de requisitos (requirement.txt, AWS Glue 5.0 y versiones posteriores) o una lista de módulos de Python separados por comas.

Temas

- Instalación de módulos adicionales de Python en AWS Glue 2.0 (o posterior) con pip
- Inclusión de archivos de Python con características nativas de PySpark
- Scripts de programación que utilizan transformaciones visuales
- Compresión de bibliotecas para inclusión
- Carga de bibliotecas de Python en cuadernos de AWS Glue Studio
- Carga de bibliotecas Python en un punto de conexión de desarrollo en AWS Glue 0.9/1.0
- Uso de bibliotecas Python en un trabajo o JobRun
- Analizar de forma proactiva las dependencias de Python
- Módulos de Python que ya se proporcionaron en AWS

Detalles del entorno de AWS Glue

Compatibilidad de las versiones de Glue y métodos de instalación

Versión de AWS Glue	Versión de Python	Imagen base	Versión de glibc
5.1	3.11	Amazon Linux 2023 (AL2023)	2.34
5.0	3.11	Amazon Linux 2023 (AL2023)	2.34
4.0	3.10	Amazon Linux 2 (AL2)	2.26
3.0	3.7	Amazon Linux 2 (AL2)	2.26
2.0	3.7	Amazon Linux AMI (AL1)	2.17
1.0	3.6	Amazon Linux AMI (AL1)	2.17
0.9	2.7	Amazon Linux AMI (AL1)	2.17

Según el modelo de responsabilidad compartida de AWS, usted es responsable de la administración de los módulos y las bibliotecas de Python adicionales y las dependencias que utilice con sus trabajos de ETL de AWS Glue. Esto incluye la aplicación de actualizaciones y parches de seguridad.

AWS Glue no admite la compilación de código nativo en el entorno de trabajo. No obstante, los trabajos de AWS Glue se ejecutan en un entorno de Linux administrado por Amazon. Es posible que pueda proporcionar las dependencias nativas en forma compilada a través de un archivo Wheel de Python. Consulte la tabla anterior para ver los detalles de compatibilidad de las versiones de AWS Glue.

Si las dependencias de Python están relacionadas de modo transitivo con código compilado nativo, es posible que se encuentre con la siguiente limitación: AWS Glue no admite la compilación de código nativo en el entorno de trabajo. No obstante, los trabajos de AWS Glue se ejecutan en un entorno de Linux administrado por Amazon. Es posible que pueda proporcionar las dependencias nativas en forma compilada a través de una distribución Wheel. Consulte la tabla anterior para ver los detalles de compatibilidad de las versiones de AWS Glue.

> **Important**
>
> El uso de dependencias incompatibles puede provocar problemas de tiempo de ejecución, especialmente en el caso de las bibliotecas con extensiones nativas que deben coincidir con la arquitectura y las bibliotecas del sistema del entorno de destino. Cada versión de AWS Glue se ejecuta en una versión específica de Python con bibliotecas y configuraciones de sistema preinstaladas.

Instalación de módulos adicionales de Python en AWS Glue 2.0 (o posterior) con pip

AWS Glue utiliza el instalador de paquetes de Python (pip3) para instalar los módulos adicionales que serán utilizados por AWS Glue ETL. Puede utilizar el parámetro `--additional-python-modules` con una lista de módulos de Python separados por comas para agregar un nuevo módulo o cambiar la versión de un módulo existente. Puede instalar distribuciones personalizadas de una biblioteca cargando la distribución en Amazon S3, y luego incluir la ruta al objeto de Amazon S3 en la lista de módulos.

Puede pasar opciones adicionales a pip3 con el parámetro `--python-modules-installer-option`. Por ejemplo, puede pasar `"--upgrade"` para actualizar los paquetes especificados por `"--additional-python-modules"`. Para ver más ejemplos, consulte Creación de módulos Python desde un archivo wheel para cargas de trabajo de ETL de Spark mediante AWS Glue 2.0.

Instalar bibliotecas de Python adicionales con Wheel

AWS Glue admite la instalación de paquetes de Python personalizados mediante archivos Wheel (.whl) almacenados en Amazon S3. Para incluir los archivos Wheel en sus trabajos de AWS Glue, añada al parámetro del trabajo de `--additional-python-modules` una lista separada por comas de los archivos Wheel almacenados en S3. Por ejemplo:

```
--additional-python-modules s3://amzn-s3-demo-bucket/path/to/package-1.0.0-py3-none-any.whl,s3://your-bucket/path/to/another-package-2.1.0-cp311-cp311-linux_x86_64.whl
```

Este enfoque también es válido cuando se necesitan distribuciones personalizadas o paquetes con dependencias nativas compilados previamente para el sistema operativo correcto. Para ver más ejemplos, consulte Creación de módulos Python a partir de un archivo Wheel para cargas de trabajo de ETL de Spark mediante AWS Glue 2.0.

Debe especificar `--additional-python-modules` en el campo Parámetros del trabajo de la consola de AWS Glue, o bien modificar los argumentos del trabajo en el SDK de AWS. Para obtener más información sobre la configuración de parámetros de trabajo, consulte Uso de parámetros de trabajo en los trabajos de AWS Glue.

Instalación de bibliotecas de Python adicionales en AWS Glue 5.0 o versiones posteriores mediante requirements.txt

En AWS Glue 5.0, puede proporcionar el estándar de facto `requirements.txt` para gestionar las dependencias de las bibliotecas de Python. Para ello, proporcione los dos parámetros de trabajo siguientes:

- Clave: `--python-modules-installer-option`

  Valor:: `-r`
- Clave: `--additional-python-modules`

  Valor:: `s3://path_to_requirements.txt`

Los nodos de AWS Glue 5.0 cargan inicialmente las bibliotecas de Python especificadas en `requirements.txt`.

A continuación, verá un ejemplo de requirements.txt:

```
awswrangler==3.9.1
```

```
elasticsearch==8.15.1
PyAthena==3.9.0
PyMySQL==1.1.1
PyYAML==6.0.2
pyodbc==5.2.0
pyorc==0.9.0
redshift-connector==2.1.3
scipy==1.14.1
scikit-learn==1.5.2
SQLAlchemy==2.0.36
```

> **Important**
>
> Evite las versiones de biblioteca desancladas en su archivo requirements.txt para asegurarse de que dispone de un entorno de AWS Glue fiable y determinista para los trabajos.

Cuando utiliza Wheel para las dependencias directas, puede incluir una versión incompatible de sus dependencias transitivas si no están ancladas correctamente. Como práctica recomendada, todas las versiones de la biblioteca deberían estar ancladas para mantener la coherencia en los trabajos de AWS Glue. AWS Glue recomienda comprimir el entorno de Python en un archivo Wheel para garantizar la coherencia y la fiabilidad de la carga de trabajo de producción.

Instalar bibliotecas de Python adicionales configurándolas directamente como una lista separada por comas

Para actualizar o añadir un nuevo módulo de Python, AWS Glue permite enviar el parámetro `--additional-python-modules` con una lista de módulos de Python separados por comas como valores. Por ejemplo, para actualizar o añadir un nuevo módulo scikit-learn, utilice la siguiente clave-valor: `"--additional-python-modules", "scikit-learn==0.21.3"`. Tiene dos opciones para configurar directamente los módulos de Python.

- Módulo Python anclado (recomendado)

  ```
  "--additional-python-modules", "scikit-learn==0.21.3,ephem==4.1.6"
  ```

- Módulo Python desanclado: (no se recomienda para cargas de trabajo de producción)

  ```
  "--additional-python-modules", "scikit-learn>==0.20.0,ephem>=4.0.0"
  ```

  O BIEN

```
"--additional-python-modules", "scikit-learn,ephem"
```

> **Important**
>
> Al configurar los módulos de Python directamente en `--additional-python-modules`, AWS Glue recomienda utilizar versiones de biblioteca ancladas para garantizar la coherencia en el entorno de trabajo de AWS Glue. El uso de versiones de biblioteca desancladas extrae la última versión de los módulos de Python; sin embargo, esto puede introducir cambios importantes o un módulo de Python incompatible, lo que provoca un fallo en el trabajo debido a un error de instalación de Python en el entorno de trabajo de AWS Glue. Recomendamos a los clientes que no utilicen versiones de bibliotecas desancladas para la carga de trabajo de producción. Como práctica recomendada, AWS Glue sugiere comprimir el entorno de Python en un archivo Wheel para garantizar la coherencia y la fiabilidad de la carga de trabajo de producción.

Inclusión de archivos de Python con características nativas de PySpark

AWS Glue utiliza PySpark para incluir archivos de Python en trabajos de ETL de AWS Glue. Podrá utilizar `--additional-python-modules` para administrar las dependencias cuando esté disponible. Puede utilizar el parámetro de trabajo `--extra-py-files` para incluir archivos de Python. Las dependencias deben estar alojadas en Amazon S3 y el valor del argumento debe ser una lista delimitada por comas de rutas de Amazon S3 sin espacios. Esta funcionalidad se comporta igual que la administración de dependencias de Python que se utilizaría con Spark. Para obtener más información sobre la administración de dependencias de Python en Spark, consulte la página Using PySpark Native Features (Uso de características nativas de PySpark) en la documentación de Apache Spark. `--extra-py-files` resulta útil en los casos en los que el código adicional no está empaquetado, o bien cuando se migra un programa de Spark con una cadena de herramientas existente para administrar las dependencias. Para que las herramientas para dependencias sean mantenibles, deberá agrupar las dependencias antes del envío.

Scripts de programación que utilizan transformaciones visuales

Al crear un trabajo de AWS Glue con la interfaz visual de AWS Glue Studio, puede transformar los datos con nodos administrados de transformación de datos y transformaciones visuales personalizadas. Par más información sobre los nodos administrados de transformación de datos, consulte the section called “Transformación de datos con transformaciones administradas de AWS

Glue". Para obtener más información sobre las transformaciones visuales personalizadas, consulte the section called " Transformación de datos con transformaciones visuales personalizadas ". Los scripts que utilizan transformaciones visuales solo se pueden generar cuando el Lenguaje del trabajo está establecido para que utilice Python.

Al generar un trabajo de AWS Glue con transformaciones visuales, AWS Glue Studio incluirá estas transformaciones en el entorno de tiempo de ejecución con el parámetro `--extra-py-files` en la configuración del trabajo. Para obtener más información acerca de la configuración de parámetros de trabajos, consulte the section called "Parámetros del flujo de trabajo". Cuando se realizan cambios en un script generado o un entorno de tiempo de ejecución, necesitará conservar la configuración del trabajo para que script se ejecute de manera exitosa.

Compresión de bibliotecas para inclusión

Salvo que una biblioteca se encuentre en un único archivo `.py`, deberá empaquetarse en un archivo `.zip`. El directorio del paquete debe encontrarse en la raíz del archivo y debe contener un archivo `__init__.py` para el paquete. Posteriormente, Python podrá importar el paquete de la forma habitual.

Si la biblioteca se compone solamente de un único módulo de Python en un archivo `.py`, no será necesario comprimirlo en un archivo `.zip`.

Carga de bibliotecas de Python en cuadernos de AWS Glue Studio

Para especificar las bibliotecas de Python en los cuadernos de AWS Glue Studio, consulte Installing additional Python modules.

Carga de bibliotecas Python en un punto de conexión de desarrollo en AWS Glue 0.9/1.0

Si utiliza diferentes conjuntos de bibliotecas para distintos scripts de ETL, puede configurar puntos de enlace de desarrollo independientes para cada conjunto o bien, puede sobrescribir los archivos `.zip` de la biblioteca que carga el punto de enlace de desarrollo cada vez que usted cambia de script.

Puede utilizar la consola con el fin de especificar uno o varios archivos .zip para un punto de enlace de desarrollo cuando lo cree. Después de asignar un nombre y un rol de IAM, seleccione Script Libraries and job parameters (Bibliotecas de script y parámetros de trabajo) (opcional) y escriba la ruta de Amazon S3 completa para los archivos `.zip` de la biblioteca en el cuadro Python library path (Ruta de la biblioteca Python). Por ejemplo:

```
s3://bucket/prefix/site-packages.zip
```

También puede especificar varias rutas completas a los archivos; para ello, sepárelas con comas pero sin espacios, como sigue:

```
s3://bucket/prefix/lib_A.zip,s3://bucket_B/prefix/lib_X.zip
```

Si actualiza estos archivos `.zip` más adelante, puede utilizar la consola para volver a importarlos en el punto de enlace de desarrollo. Vaya al punto de enlace del desarrollador que corresponda, marque la casilla junto al mismo y seleccione Update ETL libraries (Actualizar bibliotecas de ETL) desde el menú Action (Acción).

De forma similar, puede especificar archivos de la biblioteca mediante las API de AWS Glue. Cuando crea un punto de enlace de desarrollo al invocar Acción CreateDevEndpoint (Python: create_dev_endpoint), puede especificar una o varias rutas completas para las bibliotecas en el parámetro `ExtraPythonLibsS3Path`, en una llamada con un formato similar al siguiente:

```
dep = glue.create_dev_endpoint(
             EndpointName="testDevEndpoint",
             RoleArn="arn:aws:iam::123456789012",
             SecurityGroupIds="sg-7f5ad1ff",
             SubnetId="subnet-c12fdba4",
             PublicKey="ssh-rsa AAAAB3NzaC1yc2EAAAADAQABAAABAQCtp04H/y...",
             NumberOfNodes=3,
             ExtraPythonLibsS3Path="s3://bucket/prefix/lib_A.zip,s3://bucket_B/prefix/
lib_X.zip")
```

Cuando actualice un punto de enlace de desarrollo, también puede actualizar las bibliotecas que carga con un objeto DevEndpointCustomLibraries y si establece el parámetro `UpdateEtlLibraries` en `True` a la hora de invocar UpdateDevEndpoint (update_dev_endpoint).

Uso de bibliotecas Python en un trabajo o JobRun

Cuando crea un trabajo nuevo en la consola, puede especificar uno o más archivos .zip de la biblioteca si selecciona Script Libraries and job parameters (Bibliotecas de script y parámetros de trabajo) (opcional) y escribe las rutas completas de la biblioteca de Amazon S3, igual que cuando crea un punto de enlace de desarrollo:

```
s3://bucket/prefix/lib_A.zip,s3://bucket_B/prefix/lib_X.zip
```

Si invoca CreateJob (create_job), puede especificar una o varias rutas completas para las bibliotecas predeterminadas mediante el parámetro predeterminado `--extra-py-files` , como se indica a continuación:

```
job = glue.create_job(Name='sampleJob',
                      Role='Glue_DefaultRole',
                      Command={'Name': 'glueetl',
                               'ScriptLocation': 's3://my_script_bucket/scripts/
my_etl_script.py'},
                      DefaultArguments={'--extra-py-files': 's3://bucket/prefix/
lib_A.zip,s3://bucket_B/prefix/lib_X.zip'})
```

Posteriormente, cuando inicie un JobRun, puede anular el valor predeterminado de la biblioteca con otro distinto:

```
runId = glue.start_job_run(JobName='sampleJob',
                           Arguments={'--extra-py-files': 's3://bucket/prefix/
lib_B.zip'})
```

Analizar de forma proactiva las dependencias de Python

Para identificar de forma proactiva los posibles problemas de dependencia antes de implementarlos en AWS Glue, puede usar la herramienta de análisis de dependencias para cotejar sus paquetes de Python con el entorno de AWS Glue de destino.

AWS proporciona una herramienta de análisis de dependencias de Python de código abierto diseñada específicamente para entornos de AWS Glue. Esta herramienta está disponible en el repositorio de muestras de AWS Glue y se puede utilizar localmente para validar las dependencias antes de la implementación.

Este análisis ayuda a garantizar que sus dependencias sigan la práctica recomendada de anclar todas las versiones de la biblioteca para lograr implementaciones de producción coherentes. Para obtener más información, consulte el archivo README de la herramienta.

Uso del analizador de dependencias de AWS Glue

El analizador de dependencias Python de AWS Glue ayuda a identificar las dependencias desancladas y los conflictos de versiones al simular la instalación de pip con restricciones específicas de la plataforma que se adaptan al entorno de AWS Glue objetivo.

```
# Analyze a single Glue job
```

```
python glue_dependency_analyzer.py -j my-glue-job

# Analyze multiple jobs with specific AWS configuration
python glue_dependency_analyzer.py -j job1 -j job2 --aws-profile production --aws-
region us-west-2
```

La herramienta marcará:

- Dependencias desancladas que podrían instalar diferentes versiones en las ejecuciones de un trabajo
- Conflictos de versiones entre paquetes
- Dependencias no disponibles para su entorno de AWS Glue objetivo

Analice y corrija los errores de trabajo debido a las dependencias de Python con Amazon Q Developer

Amazon Q Developer es un asistente conversacional con tecnología de inteligencia artificial (IA) generativa que puede ayudarle a comprender, crear, extender y operar aplicaciones de AWS. Puedes descargarlo siguiendo las instrucciones de la guía de introducción de Amazon Q.

Amazon Q Developer se puede utilizar para analizar y corregir errores en los trabajos debido a la dependencia de Python. Le sugerimos que utilice la siguiente petición y sustituya el marcador de posición <Job-Name> por el nombre del trabajo de Glue.

```
I have an AWS Glue job named <Job-Name> that has failed due to Python module
 installation conflicts. Please assist in diagnosing and resolving this issue using the
 following systematic approach. Proceed once sufficient information is available.

Objective: Implement a fix that addresses the root cause module while minimizing
 disruption to the existing working environment.

Step 1: Root Cause Analysis
• Retrieve the most recent failed job run ID for the specified Glue job
• Extract error logs from CloudWatch Logs using the job run ID as a log stream prefix
• Analyze the logs to identify:
  • The recently added or modified Python module that triggered the dependency conflict
  • The specific dependency chain causing the installation failure
  • Version compatibility conflicts between required and existing modules

Step 2: Baseline Configuration Identification
```

```
• Locate the last successful job run ID prior to the dependency failure
• Document the Python module versions that were functioning correctly in that baseline
 run
• Establish the compatible version constraints for conflicting dependencies

Step 3: Targeted Resolution Implementation
• Apply pinning by updating the job's additional_python_modules parameter
• Pin only the root cause module and its directly conflicting dependencies to
 compatible versions, and do not remove python modules unless necessary
• Preserve flexibility for non-conflicting modules by avoiding unnecessary version
 constraints
• Deploy the configuration changes with minimal changes to the existing configuration
 and execute a validation test run. Do not change the Glue versions.

Implementation Example:
Scenario: Recently added pandas==2.0.0 to additional_python_modules
Error: numpy version conflict (pandas 2.0.0 requires numpy>=1.21, but existing job code
 requires numpy<1.20)
Resolution: Update additional_python_modules to "pandas==1.5.3,numpy==1.19.5"
Rationale: Use pandas 1.5.3 (compatible with numpy 1.19.5) and pin numpy to last known
 working version

Expected Outcome: Restore job functionality with minimal configuration changes while
 maintaining system stability.
```

La petición le indica a Q que:

1. Obtenga el último identificador de ejecución de un trabajo fallido
2. Busque los registros y detalles asociados
3. Busque los trabajos ejecutados correctamente para detectar cualquier paquete de Python modificado
4. Realice las correcciones de configuración necesarias y active otra ejecución de prueba

Módulos de Python que ya se proporcionaron en AWS

Para cambiar la versión de estos módulos proporcionados, indique las nuevas versiones con el parámetro de trabajo `--additional-python-modules`.

AWS Glue version 5.0

La versión 5.0 de AWS Glue incluye los siguientes módulos de Python listos para su uso:

- aiobotocore==2.13.1
- aiohappyeyeballs==2.3.5
- aiohttp==3.10.1
- aioitertools==0.11.0
- aiosignal==1.3.1
- appdirs==1.4.4
- attrs==24.2.0
- boto3==1.34.131
- botocore==1.34.131
- certifi==2024.7.4
- charset-normalizer==3.3.2
- contourpy==1.2.1
- cycler==0.12.1
- fonttools==4.53.1
- frozenlist==1.4.1
- fsspec==2024.6.1
- idna==2.10
- jmespath==0.10.0
- kaleido==0.2.1
- kiwisolver==1.4.5
- matplotlib==3.9.0
- multidict==6.0.5
- numpy==1.26.4
- packaging==24.1
- pandas==2.2.2
- pillow==10.4.0
- pip==23.0.1
- plotly==5.23.0
- pyarrow==17.0.0
- pyparsing==3.1.2

- python-dateutil==2.9.0.post0
- pytz==2024.1
- requests==2.32.2
- s3fs==2024.6.1
- s3transfer==0.10.2
- seaborn==0.13.2
- setuptools==59.6.0
- six==1.16.0
- tenacity==9.0.0
- tzdata==2024.1
- urllib3==1.25.10
- virtualenv==20.4.0
- wrapt==1.16.0
- yarl==1.9.4

AWS Glue version 4.0

La versión 4.0 de AWS Glue incluye los siguientes módulos de Python listos para su uso:

- aiobotocore==2.4.1
- aiohttp==3.8.3
- aioitertools==0.11.0
- aiosignal==1.3.1
- async-timeout==4.0.2
- asynctest==0.13.0
- attrs==22.2.0
- avro-python3==1.10.2
- boto3==1.24.70
- botocore==1.27.59
- certifi==2021.5.30
- chardet==3.0.4

- charset-normalizer==2.1.1
- click==8.1.3
- cycler==0.10.0
- Cython==0.29.32
- fsspec==2021.8.1
- idna==2.10
- importlib-metadata==5.0.0
- jmespath==0.10.0
- joblib==1.0.1
- kaleido==0.2.1
- kiwisolver==1.4.4
- matplotlib==3.4.3
- mpmath==1.2.1
- multidict==6.0.4
- nltk==3.7
- numpy==1.23.5
- packaging==23.0
- pandas==1.5.1
- patsy==0.5.1
- Pillow==9.4.0
- pip==23.0.1
- plotly==5.16.0
- pmdarima==2.0.1
- ptvsd==4.3.2
- pyarrow==10.0.0
- pydevd==2.5.0
- pyhocon==0.3.58
- PyMySQL==1.0.2
- pyparsing==2.4.7
- python-dateutil==2.8.2

- pytz==2021.1
- PyYAML==6.0.1
- regex==2022.10.31
- requests==2.23.0
- s3fs==2022.11.0
- s3transfer==0.6.0
- scikit-learn==1.1.3
- scipy==1.9.3
- setuptools==49.1.3
- six==1.16.0
- statsmodels==0.13.5
- subprocess32==3.5.4
- sympy==1.8
- tbats==1.1.0
- threadpoolctl==3.1.0
- tqdm==4.64.1
- typing_extensions==4.4.0
- urllib3==1.25.11
- wheel==0.37.0
- wrapt==1.14.1
- yarl==1.8.2
- zipp==3.10.0

AWS Glue version 3.0

La versión 3.0 de AWS Glue incluye los siguientes módulos de Python listos para su uso:

- aiobotocore==1.4.2
- aiohttp==3.8.3
- aioitertools==0.11.0
- aiosignal==1.3.1
- async-timeout==4.0.2

- asynctest==0.13.0
- attrs==22.2.0
- avro-python3==1.10.2
- boto3==1.18.50
- botocore==1.21.50
- certifi==2021.5.30
- chardet==3.0.4
- charset-normalizer==2.1.1
- click==8.1.3
- cycler==0.10.0
- Cython==0.29.4
- docutils==0.17.1
- enum34==1.1.10
- frozenlist==1.3.3
- fsspec==2021.8.1
- idna==2.10
- importlib-metadata==6.0.0
- jmespath==0.10.0
- joblib==1.0.1
- kiwisolver==1.3.2
- matplotlib==3.4.3
- mpmath==1.2.1
- multidict==6.0.4
- nltk==3.6.3
- numpy==1.19.5
- packaging==23.0
- pandas==1.3.2
- patsy==0.5.1
- Pillow==9.4.0
- pip==23.0

- pmdarima==1.8.2
- ptvsd==4.3.2
- pyarrow==5.0.0
- pydevd==2.5.0
- pyhocon==0.3.58
- PyMySQL==1.0.2
- pyparsing==2.4.7
- python-dateutil==2.8.2
- pytz==2021.1
- PyYAML==5.4.1
- regex==2022.10.31
- requests==2.23.0
- s3fs==2021.8.1
- s3transfer==0.5.0
- scikit-learn==0.24.2
- scipy==1.7.1
- six==1.16.0
- Spark==1.0
- statsmodels==0.12.2
- subprocess32==3.5.4
- sympy==1.8
- tbats==1.1.0
- threadpoolctl==3.1.0
- tqdm==4.64.1
- typing_extensions==4.4.0
- urllib3==1.25.11
- wheel==0.37.0
- wrapt==1.14.1
- yarl==1.8.2
- zipp==3.12.0

AWS Glue version 2.0

La versión 2.0 de AWS Glue incluye los siguientes módulos de Python listos para su uso:

- avro-python3==1.10.0
- awscli==1.27.60
- boto3==1.12.4
- botocore==1.15.4
- certifi==2019.11.28
- chardet==3.0.4
- click==8.1.3
- colorama==0.4.4
- cycler==0.10.0
- Cython==0.29.15
- docutils==0.15.2
- enum34==1.1.9
- fsspec==0.6.2
- idna==2.9
- importlib-metadata==6.0.0
- jmespath==0.9.4
- Joblib==0.14.1
- kiwisolver==1.1.0
- matplotlib==3.1.3
- mpmath==1.1.0
- nltk==3.5
- numpy==1.18.1
- pandas==1.0.1
- patsy==0.5.1
- pmdarima==1.5.3
- ptvsd==4.3.2
- pyarrow==0.16.0
- pyasn1==0.4.8

- pydevd==1.9.0
- pyhocon==0.3.54
- PyMySQL==0.9.3
- pyparsing==2.4.6
- python-dateutil==2.8.1
- pytz==2019.3
- PyYAML==5.3.1
- regex==2022.10.31
- requests==2.23.0
- rsa==4.7.2
- s3fs==0.4.0
- s3transfer==0.3.3
- scikit-learn==0.22.1
- scipy==1.4.1
- setuptools==45.2.0
- six==1.14.0
- Spark==1.0
- statsmodels==0.11.1
- subprocess32==3.5.4
- sympy==1.5.1
- tbats==1.0.9
- tqdm==4.64.1
- typing-extensions==4.4.0
- urllib3==1.25.8
- wheel==0.35.1
- zipp==3.12.0

Ejemplos de código Python en AWS Glue

- Código de ejemplo: unión de los datos y establecimiento de relaciones entre ellos
- Ejemplo de código: Preparación de datos con ResolveChoice, Lambda y ApplyMapping

Código de ejemplo: unión de los datos y establecimiento de relaciones entre ellos

En este ejemplo se utiliza un conjunto de datos que se ha descargado desde http://everypolitician.org/ al bucket `sample-dataset` de Amazon Simple Storage Service (Amazon S3): `s3://awsglue-datasets/examples/us-legislators/all`. El conjunto de datos contiene información en formato JSON sobre legisladores de los Estados Unidos y los escaños de los que han sido titulares en la Cámara de Representantes y el Senado. Para realizar este tutorial, este conjunto de datos se ha modificado ligeramente y está disponible en un bucket público de Amazon S3.

Puede encontrar el código fuente de este ejemplo en el archivo `join_and_relationalize.py` del repositorio de ejemplos de AWS Glue en el sitio web de GitHub.

Con estos datos, el presente tutorial le enseña a realizar las siguientes tareas:

- Utilice un rastreador de AWS Glue para clasificar los objetos que están almacenados en un bucket público de Amazon S3 y guardar sus esquemas en el Catálogo de datos de AWS Glue.
- Examinar los metadatos y los esquemas de la tabla que se obtienen a partir del rastreo.
- Escriba un script de extracción, transferencia y carga (ETL) de Python que utilice los metadatos del Catálogo de datos para hacer lo siguiente:
  - Unir los datos de los diferentes archivos de origen juntos en una única tabla de datos (es decir, desnormalizar los datos).
  - Desglosar la tabla unida en diferentes tablas según el tipo de legislador.
  - Escribir los datos resultantes en archivos Apache Parquet independientes para realizar un análisis posteriormente.

La forma preferida de depurar scripts de Python o PySpark mientras se están ejecutando en AWS es usar Notebooks en Glue Studio AWS.

Paso 1: Rastrear los datos del bucket de Amazon S3

1. Luego, inicie sesión en la Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. En función de los pasos que se indican en Configuración de rastreadores, cree un nuevo rastreador que pueda rastrear el conjunto de datos `s3://awsglue-datasets/examples/us-legislators/all` en una base de datos denominada `legislators` en el Catálogo de datos de AWS Glue. Los datos de ejemplo ya están en este bucket público de Amazon S3.
3. Ejecute el nuevo rastreador y, a continuación, compruebe la base de datos `legislators`.

El rastreador crea las siguientes tablas de metadatos:

- `persons_json`
- `memberships_json`
- `organizations_json`
- `events_json`
- `areas_json`
- `countries_r_json`

Esta es una colección seminormalizada de tablas que contienen legisladores y sus historias.

Paso 2: Añadir un script reutilizable al cuaderno del punto de conexión de desarrollo

Pegue el script reutilizable siguiente en el cuaderno del punto de enlace de desarrollo para importar las bibliotecas de AWS Glue que necesite y configurar un único `GlueContext`:

```
import sys
from awsglue.transforms import *
from awsglue.utils import getResolvedOptions
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job

glueContext = GlueContext(SparkContext.getOrCreate())
```

Paso 3: Examinar los esquemas de los datos del Catálogo de datos

A continuación, puede crear un DynamicFrame con facilidad desde el Catálogo de datos de AWS Glue y examinar los esquemas de los datos. Por ejemplo, para ver el esquema de la tabla `persons_json`, añada lo siguiente en su cuaderno:

```
persons = glueContext.create_dynamic_frame.from_catalog(
             database="legislators",
             table_name="persons_json")
print "Count: ", persons.count()
persons.printSchema()
```

Esta es la salida de las llamadas impresas:

```
Count:  1961
root
|-- family_name: string
|-- name: string
|-- links: array
|    |-- element: struct
|    |    |-- note: string
|    |    |-- url: string
|-- gender: string
|-- image: string
|-- identifiers: array
|    |-- element: struct
|    |    |-- scheme: string
|    |    |-- identifier: string
|-- other_names: array
|    |-- element: struct
|    |    |-- note: string
|    |    |-- name: string
|    |    |-- lang: string
|-- sort_name: string
|-- images: array
|    |-- element: struct
|    |    |-- url: string
|-- given_name: string
|-- birth_date: string
|-- id: string
|-- contact_details: array
|    |-- element: struct
|    |    |-- type: string
|    |    |-- value: string
|-- death_date: string
```

Cada persona de la tabla es miembro de algún órgano del congreso de los Estados Unidos.

Para ver el esquema de la tabla `memberships_json`, escriba lo siguiente:

```
memberships = glueContext.create_dynamic_frame.from_catalog(
                database="legislators",
                table_name="memberships_json")
```

```
print "Count: ", memberships.count()
memberships.printSchema()
```

La salida es la siguiente:

```
Count:  10439
root
|-- area_id: string
|-- on_behalf_of_id: string
|-- organization_id: string
|-- role: string
|-- person_id: string
|-- legislative_period_id: string
|-- start_date: string
|-- end_date: string
```

Las `organizations` son partes y las dos cámaras del Congreso, el Senado y la Cámara de Representantes. Para ver el esquema de la tabla `organizations_json`, escriba lo siguiente:

```
orgs = glueContext.create_dynamic_frame.from_catalog(
           database="legislators",
           table_name="organizations_json")
print "Count: ", orgs.count()
orgs.printSchema()
```

La salida es la siguiente:

```
Count:  13
root
|-- classification: string
|-- links: array
|    |-- element: struct
|    |    |-- note: string
|    |    |-- url: string
|-- image: string
|-- identifiers: array
|    |-- element: struct
|    |    |-- scheme: string
|    |    |-- identifier: string
```

```
|-- other_names: array
|    |-- element: struct
|    |    |-- lang: string
|    |    |-- note: string
|    |    |-- name: string
|-- id: string
|-- name: string
|-- seats: int
|-- type: string
```

Paso 4: Filtrar los datos

A continuación, mantenga solo los campos que desee y cambie el nombre `id` por `org_id`. El conjunto de datos es lo suficientemente pequeño para ver todo el conjunto.

`toDF()` convierte a `DynamicFrame` en un elemento `DataFrame` de Apache Spark, por lo que puede aplicar las transformaciones que ya existen en Apache Spark SQL:

```
orgs = orgs.drop_fields(['other_names',
                         'identifiers']).rename_field(
                             'id', 'org_id').rename_field(
                                'name', 'org_name')
orgs.toDF().show()
```

El ejemplo siguiente muestra la salida:

```
+--------------+--------------------+--------------------+--------------------+-----
+-----------+--------------------+
|classification|              org_id|            org_name|               links|seats|
     type|               image|
+--------------+--------------------+--------------------+--------------------+-----
+-----------+--------------------+
|         party|            party/al|                  AL|                null| null|
     null|                null|
|         party|      party/democrat|            Democrat|[[website,http://...| null|
     null|https://upload.wi...|
|         party|party/democrat-li...|    Democrat-Liberal|[[website,http://...| null|
     null|                null|
|   legislature|d56acebe-8fdc-47b...|House of Represen...|                null|  435|
lower house|                null|
```

```
|         party|   party/independent|         Independent|                null| null|
     null|                null|
|         party|party/new_progres...|     New Progressive|[[website,http://...| null|
     null|https://upload.wi...|
|         party|party/popular_dem...|    Popular Democrat|[[website,http://...| null|
     null|                null|
|         party|    party/republican|          Republican|[[website,http://...| null|
     null|https://upload.wi...|
|         party|party/republican-...|Republican-Conser...|[[website,http://...| null|
     null|                null|
|         party|      party/democrat|            Democrat|[[website,http://...| null|
     null|https://upload.wi...|
|         party|   party/independent|         Independent|                null| null|
     null|                null|
|         party|    party/republican|          Republican|[[website,http://...| null|
     null|https://upload.wi...|
|   legislature|8fa6c3d2-71dc-478...|              Senate|                null|  100|
upper house|                null|
+--------------+--------------------+--------------------+--------------------+-----
+-----------+--------------------+
```

Escriba lo siguiente para ver las `organizations` que aparecen en `memberships`:

```
memberships.select_fields(['organization_id']).toDF().distinct().show()
```

El ejemplo siguiente muestra la salida:

```
+--------------------+
|     organization_id|
+--------------------+
|d56acebe-8fdc-47b...|
|8fa6c3d2-71dc-478...|
+--------------------+
```

Paso 5: Reunirlo todo

Ahora utilice AWS Glue para unir estas tablas relacionales y crear una tabla del historial completo de `memberships` del legislador y sus `organizations` correspondientes.

1. En primer lugar, una `persons` y `memberships` en `id` y `person_id`.

2. A continuación, una el resultado con `orgs` en `org_id` y `organization_id`.
3. A continuación, anule los campos redundantes `person_id` y `org_id`.

Puede realizar todas estas operaciones en una línea de código (extendida):

```
l_history = Join.apply(orgs,
                       Join.apply(persons, memberships, 'id', 'person_id'),
                       'org_id', 'organization_id').drop_fields(['person_id',
 'org_id'])
print "Count: ", l_history.count()
l_history.printSchema()
```

La salida es la siguiente:

```
Count:  10439
root
|-- role: string
|-- seats: int
|-- org_name: string
|-- links: array
|    |-- element: struct
|    |    |-- note: string
|    |    |-- url: string
|-- type: string
|-- sort_name: string
|-- area_id: string
|-- images: array
|    |-- element: struct
|    |    |-- url: string
|-- on_behalf_of_id: string
|-- other_names: array
|    |-- element: struct
|    |    |-- note: string
|    |    |-- name: string
|    |    |-- lang: string
|-- contact_details: array
|    |-- element: struct
|    |    |-- type: string
|    |    |-- value: string
|-- name: string
```

```
|-- birth_date: string
|-- organization_id: string
|-- gender: string
|-- classification: string
|-- death_date: string
|-- legislative_period_id: string
|-- identifiers: array
|    |-- element: struct
|    |    |-- scheme: string
|    |    |-- identifier: string
|-- image: string
|-- given_name: string
|-- family_name: string
|-- id: string
|-- start_date: string
|-- end_date: string
```

Ahora tiene la tabla definitiva que puede utilizar para su análisis. Puede escribirla en un formato compacto y eficiente para el análisis, por ejemplo, en Parquet, en el que puede ejecutar SQL en AWS Glue, Amazon Athena o Amazon Redshift Spectrum.

La siguiente llamada escribe la tabla en varios archivos para admitir lecturas paralelas rápidas al realizar el análisis posterior:

```
glueContext.write_dynamic_frame.from_options(frame = l_history,
          connection_type = "s3",
          connection_options = {"path": "s3://glue-sample-target/output-dir/
legislator_history"},
          format = "parquet")
```

Para poner todos los datos de historial en un único archivo, debe convertirlos en una estructura de datos, crear nuevas particiones y escribirlos:

```
s_history = l_history.toDF().repartition(1)
s_history.write.parquet('s3://glue-sample-target/output-dir/legislator_single')
```

O, si desea separarlos por Senado y Cámara:

```
l_history.toDF().write.parquet('s3://glue-sample-target/output-dir/legislator_part',
```

```
                                    partitionBy=['org_name'])
```

Paso 6: Transformar los datos para bases de datos relacionales

AWS Glue facilita la tarea de escribir los datos en bases de datos relacionales como Amazon Redshift, incluso con datos semiestructurados. Ofrece una transformación `relationalize`, que aplana `DynamicFrames` sea cual sea la complejidad de los objetos de la trama.

Utilizando el elemento `l_history` `DynamicFrame` de este ejemplo, pase el nombre de una tabla (`hist_root`) y una ruta de flujo de trabajo temporal a `relationalize`. Esto devuelve un elemento `DynamicFrameCollection`. A continuación, puede enumerar los nombres de `DynamicFrames` en esa colección:

```
dfc = l_history.relationalize("hist_root", "s3://glue-sample-target/temp-dir/")
dfc.keys()
```

A continuación, se muestra la salida de la llamada `keys`:

```
[u'hist_root', u'hist_root_contact_details', u'hist_root_links',
 u'hist_root_other_names', u'hist_root_images', u'hist_root_identifiers']
```

`Relationalize` ha desglosado la tabla de historial en seis tablas nuevas: una tabla raíz que contiene un registro por cada objeto de `DynamicFrame` y tablas auxiliares para las matrices. A menudo, la gestión de matrices en las bases de datos relacionales no tiene un nivel óptimo, en particular cuando dichas matrices se hacen más grandes. Si se separan las matrices en diferentes tablas, las consultas serán mucho más rápidas.

A continuación, céntrese en la separación examinando `contact_details`:

```
l_history.select_fields('contact_details').printSchema()
dfc.select('hist_root_contact_details').toDF().where("id = 10 or id =
 75").orderBy(['id','index']).show()
```

A continuación, se muestra la salida de la llamada `show`:

```
root
```

```
|-- contact_details: array
|    |-- element: struct
|    |    |-- type: string
|    |    |-- value: string
+---+-----+-----------------------+-------------------------+
| id|index|contact_details.val.type|contact_details.val.value|
+---+-----+-----------------------+-------------------------+
| 10|    0|                    fax|                         |
| 10|    1|                       |             202-225-1314|
| 10|    2|                  phone|                         |
| 10|    3|                       |             202-225-3772|
| 10|    4|                twitter|                         |
| 10|    5|                       |          MikeRossUpdates|
| 75|    0|                    fax|                         |
| 75|    1|                       |             202-225-7856|
| 75|    2|                  phone|                         |
| 75|    3|                       |             202-225-2711|
| 75|    4|                twitter|                         |
| 75|    5|                       |                SenCapito|
+---+-----+-----------------------+-------------------------+
```

El campo `contact_details` era una matriz de estructuras en el elemento `DynamicFrame` original. Cada elemento de estas matrices es una fila independiente de la tabla auxiliar, indizada por `index`. Aquí el `id` es una clave externa en la tabla `hist_root` con la clave `contact_details`:

```
dfc.select('hist_root').toDF().where(
    "contact_details = 10 or contact_details = 75").select(
       ['id', 'given_name', 'family_name', 'contact_details']).show()
```

Se genera la salida siguiente:

```
+--------------------+----------+-----------+---------------+
|                  id|given_name|family_name|contact_details|
+--------------------+----------+-----------+---------------+
|f4fc30ee-7b42-432...|      Mike|       Ross|             10|
|e3c60f34-7d1b-4c0...|   Shelley|     Capito|             75|
+--------------------+----------+-----------+---------------+
```

Observe en estos comandos que se utiliza `toDF()` y, a continuación, una expresión `where`, para filtrar y obtener las filas que desea ver.

Por lo tanto, unir la tabla `hist_root` con las tablas auxiliares le permite hacer lo siguiente:

- Cargar datos en bases de datos sin compatibilidad de matrices.
- Consultar cada elemento individual de una matriz con SQL.

Almacene las credenciales de Amazon Redshift y acceda a ellas de forma segura con una conexión de AWS Glue. Para obtener información acerca de cómo crear su propia conexión, consulte Conexión a datos.

Ahora está preparado para escribir los datos en una conexión pasando por los elementos `DynamicFrames` de uno en uno:

```
for df_name in dfc.keys():
  m_df = dfc.select(df_name)
  print "Writing to table: ", df_name
  glueContext.write_dynamic_frame.from_jdbc_conf(frame = m_df, connection settings
 here)
```

La configuración de la conexión variará en función del tipo de base de datos relacional:

- Para obtener instrucciones sobre cómo escribir en Amazon Redshift, consulte the section called “Conexiones Redshift”.
- Para otras bases de datos, consulte Tipos de conexión y opciones para ETL en AWS Glue para Spark.

Conclusión

En general, AWS Glue es muy flexible. Le permite realizar en unas cuantas líneas de código lo que normalmente tardaría varios días en escribirse. Puede encontrar todos los scripts de ETL de origen a destino en el archivo de Python `join_and_relationalize.py`, en los ejemplos de AWS Glue en GitHub.

Ejemplo de código: Preparación de datos con ResolveChoice, Lambda y ApplyMapping

El conjunto de datos que se utiliza en este ejemplo está formado por datos de pago de Medicare Provider que se descargaron de dos sitios de Data.CMS.gov, conjuntos de datos: "Inpatient Prospective Payment System Provider Summary for the Top 100 Diagnosis-Related Groups -

FY2011" e "Inpatient Charge Data FY 2011". Después de descargar los datos, modificamos el conjunto de datos para presentar un par de registros erróneos al final del archivo. Este archivo modificado se encuentra en un bucket público de Amazon S3 en `s3://awsglue-datasets/examples/medicare/Medicare_Hospital_Provider.csv`.

Puede encontrar el código fuente de este ejemplo en el archivo `data_cleaning_and_lambda.py` del repositorio GitHub de ejemplos de AWS Glue.

La forma preferida de depurar scripts de Python o PySpark mientras se están ejecutando en AWS es usar Notebooks en Glue Studio AWS.

Paso 1: Rastrear los datos del bucket de Amazon S3

1. Inicie sesión en la Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. En función del proceso descrito en Configuración de rastreadores, cree un rastreador nuevo que pueda rastrear el archivo `s3://awsglue-datasets/examples/medicare/Medicare_Hospital_Provider.csv` y poner los metadatos resultantes en una base de datos denominada `payments` en AWS Glue Data Catalog.
3. Ejecute el nuevo rastreador y, a continuación, compruebe la base de datos `payments`. Deberá ver que el rastreador ha creado en la base de datos una tabla de metadatos denominada `medicare` después de leer el comienzo del archivo para determinar su formato y delimitador.

   El esquema de la tabla `medicare` nueva es el siguiente:

```
Column  name                              Data type
================================================
drg definition                              string
provider id                                 bigint
provider name                               string
provider street address                     string
provider city                               string
provider state                              string
provider zip code                           bigint
hospital referral region description        string
total discharges                            bigint
average covered charges                     string
average total payments                      string
average medicare payments                   string
```

Paso 2: Añadir un script reutilizable al cuaderno del punto de conexión de desarrollo

Pegue el script reutilizable siguiente en el cuaderno del punto de enlace de desarrollo para importar las bibliotecas de AWS Glue que necesite y configurar un único `GlueContext`:

```
import sys
from awsglue.transforms import *
from awsglue.utils import getResolvedOptions
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job

glueContext = GlueContext(SparkContext.getOrCreate())
```

Paso 3: Comparar diferentes análisis de esquemas

A continuación, puede ver si el esquema que un elemento `DataFrame` de Apache Spark reconoció es el mismo que su rastreador AWS Glue ha registrado. Ejecute el código siguiente:

```
medicare = spark.read.format(
   "com.databricks.spark.csv").option(
   "header", "true").option(
   "inferSchema", "true").load(
   's3://awsglue-datasets/examples/medicare/Medicare_Hospital_Provider.csv')
medicare.printSchema()
```

Esta es la salida de la llamada `printSchema`:

```
root
 |-- DRG Definition: string (nullable = true)
 |-- Provider Id: string (nullable = true)
 |-- Provider Name: string (nullable = true)
 |-- Provider Street Address: string (nullable = true)
 |-- Provider City: string (nullable = true)
 |-- Provider State: string (nullable = true)
 |-- Provider Zip Code: integer (nullable = true)
 |-- Hospital Referral Region Description: string (nullable = true)
 |--  Total Discharges : integer (nullable = true)
 |--  Average Covered Charges : string (nullable = true)
 |--  Average Total Payments : string (nullable = true)
```

```
 |-- Average Medicare Payments: string (nullable = true)
```

A continuación, examine el esquema que un `DynamicFrame` de AWS Glue genera:

```
medicare_dynamicframe = glueContext.create_dynamic_frame.from_catalog(
       database = "payments",
       table_name = "medicare")
medicare_dynamicframe.printSchema()
```

La salida de `printSchema` es la siguiente:

```
root
 |-- drg definition: string
 |-- provider id: choice
 |    |-- long
 |    |-- string
 |-- provider name: string
 |-- provider street address: string
 |-- provider city: string
 |-- provider state: string
 |-- provider zip code: long
 |-- hospital referral region description: string
 |-- total discharges: long
 |-- average covered charges: string
 |-- average total payments: string
 |-- average medicare payments: string
```

El elemento `DynamicFrame` genera un esquema donde `provider id` puede ser el tipo `long` o el tipo `string`. El esquema `DataFrame` indica que `Provider Id` es de tipo `string`, y el Data Catalog indica que `provider id` es de tipo `bigint`.

¿Cuál es el correcto? Hay dos registros al final del archivo (de 160 000 registros) con valores `string` en dicha columna. Estos son los registros erróneos que se introdujeron para ilustrar un problema.

Para abordar este tipo de problema, el `DynamicFrame` de AWS Glue introduce el concepto de tipo de choice (elección). En este caso, `DynamicFrame` muestra que los valores `long` y `string` pueden aparecer en dicha columna. El rastreador de AWS Glue no tuvo en cuenta los valores `string`, ya

que consideró solo un prefijo de 2 MB de los datos. El elemento `DataFrame` de Apache Spark tuvo en cuenta el conjunto de datos en su totalidad, pero se vio obligado a asignar el tipo más general a la columna, en este caso `string`. De hecho, Spark a menudo recurre al caso más general cuando hay tipos complejos o variaciones con las que no está familiarizado.

Para consultar la columna `provider id`, primero debe resolver el tipo de elección. Puede utilizar el método de transformación `resolveChoice` de `DynamicFrame` para convertir estos valores `string` en valores `long` con una opción `cast:long`:

```
medicare_res = medicare_dynamicframe.resolveChoice(specs = [('provider
 id','cast:long')])
medicare_res.printSchema()
```

Ahora la salida `printSchema` es:

```
root
 |-- drg definition: string
 |-- provider id: long
 |-- provider name: string
 |-- provider street address: string
 |-- provider city: string
 |-- provider state: string
 |-- provider zip code: long
 |-- hospital referral region description: string
 |-- total discharges: long
 |-- average covered charges: string
 |-- average total payments: string
 |-- average medicare payments: string
```

Cuando el valor era un elemento `string` que no se podía transformar, AWS Glue insertaba un valor `null`.

Otra opción consiste en convertir el tipo de elección en un elemento `struct`, que mantiene los valores de ambos tipos.

A continuación, examine las filas que eran anómalas:

```
medicare_res.toDF().where("'provider id' is NULL").show()
```

Verá lo siguiente:

```
+--------------------+----------+--------------+----------------------+------------
+-------------+----------------+-------------------------------------+---------------
+----------------------+---------------------+------------------------+
|      drg definition|provider id|  provider name|provider street address|provider
 city|provider state|provider zip code|hospital referral region description|total
 discharges|average covered charges|average total payments|average medicare payments|
+--------------------+----------+--------------+----------------------+------------
+-------------+----------------+-------------------------------------+---------------
+----------------------+---------------------+------------------------+
|948 - SIGNS & SYM...|       null|            INC|       1050 DIVISION ST|
 MAUSTON|            WI|            53948|                        WI - Madison|
      12|             $11961.41|             $4619.00|                $3775.33|
|948 - SIGNS & SYM...|       null| INC- ST JOSEPH|     5000 W CHAMBERS ST|
 MILWAUKEE|            WI|            53210|                        WI - Milwaukee|
        14|              $10514.28|              $5562.50|                $4522.78|
+--------------------+----------+--------------+----------------------+------------
+-------------+----------------+-------------------------------------+---------------
+----------------------+---------------------+------------------------+
```

Ahora elimine los dos registros mal formados, tal y como se indica a continuación:

```
medicare_dataframe = medicare_res.toDF()
medicare_dataframe = medicare_dataframe.where("'provider id' is NOT NULL")
```

Paso 4: Asignar los datos y utilizar las funciones Lambda de Apache Spark

AWS Glue todavía no es compatible directamente con funciones Lambda, también conocidas como funciones definidas por el usuario. Pero siempre puede convertir un elemento `DynamicFrame` en un elemento `DataFrame` de Apache Spark y viceversa, para aprovechar la funcionalidad de Spark, además de las características especiales de `DynamicFrames`.

A continuación, convierta la información de pago en números, para que los motores de análisis como Amazon Redshift o Amazon Athena puedan controlar más deprisa sus números:

```
from pyspark.sql.functions import udf
from pyspark.sql.types import StringType

chop_f = udf(lambda x: x[1:], StringType())
```

```
medicare_dataframe = medicare_dataframe.withColumn(
        "ACC", chop_f(
            medicare_dataframe["average covered charges"])).withColumn(
                "ATP", chop_f(
                    medicare_dataframe["average total payments"])).withColumn(
                        "AMP", chop_f(
                            medicare_dataframe["average medicare payments"]))
medicare_dataframe.select(['ACC', 'ATP', 'AMP']).show()
```

La salida de la llamada show es la siguiente:

```
+--------+-------+-------+
|     ACC|    ATP|    AMP|
+--------+-------+-------+
|32963.07|5777.24|4763.73|
|15131.85|5787.57|4976.71|
|37560.37|5434.95|4453.79|
|13998.28|5417.56|4129.16|
|31633.27|5658.33|4851.44|
|16920.79|6653.80|5374.14|
|11977.13|5834.74|4761.41|
|35841.09|8031.12|5858.50|
|28523.39|6113.38|5228.40|
|75233.38|5541.05|4386.94|
|67327.92|5461.57|4493.57|
|39607.28|5356.28|4408.20|
|22862.23|5374.65|4186.02|
|31110.85|5366.23|4376.23|
|25411.33|5282.93|4383.73|
| 9234.51|5676.55|4509.11|
|15895.85|5930.11|3972.85|
|19721.16|6192.54|5179.38|
|10710.88|4968.00|3898.88|
|51343.75|5996.00|4962.45|
+--------+-------+-------+
only showing top 20 rows
```

Sigue habiendo cadenas en los datos. Podemos utilizar el potente método de transformación apply_mapping para rechazar, renombrar, difundir y anidar los datos para que otros lenguajes de programación y sistemas de datos puedan obtener fácilmente acceso a ellos:

```
from awsglue.dynamicframe import DynamicFrame
```

```
medicare_tmp_dyf = DynamicFrame.fromDF(medicare_dataframe, glueContext, "nested")
medicare_nest_dyf = medicare_tmp_dyf.apply_mapping([('drg definition', 'string', 'drg',
 'string'),
                ('provider id', 'long', 'provider.id', 'long'),
                ('provider name', 'string', 'provider.name', 'string'),
                ('provider city', 'string', 'provider.city', 'string'),
                ('provider state', 'string', 'provider.state', 'string'),
                ('provider zip code', 'long', 'provider.zip', 'long'),
                ('hospital referral region description', 'string','rr', 'string'),
                ('ACC', 'string', 'charges.covered', 'double'),
                ('ATP', 'string', 'charges.total_pay', 'double'),
                ('AMP', 'string', 'charges.medicare_pay', 'double')])
medicare_nest_dyf.printSchema()
```

La salida de `printSchema` es la siguiente:

```
root
 |-- drg: string
 |-- provider: struct
 |    |-- id: long
 |    |-- name: string
 |    |-- city: string
 |    |-- state: string
 |    |-- zip: long
 |-- rr: string
 |-- charges: struct
 |    |-- covered: double
 |    |-- total_pay: double
 |    |-- medicare_pay: double
```

Si vuelve a convertir los datos en un elemento `DataFrame` de Spark, puede mostrar cómo son ahora:

```
medicare_nest_dyf.toDF().show()
```

La salida es la siguiente:

```
+--------------------+--------------------+--------------+--------------------+
|                 drg|            provider|            rr|             charges|
+--------------------+--------------------+--------------+--------------------+
|039 - EXTRACRANIA...|[10001,SOUTHEAST ...|    AL - Dothan|[32963.07,5777.24...|
|039 - EXTRACRANIA...|[10005,MARSHALL M...|AL - Birmingham|[15131.85,5787.57...|
```

```
|039 - EXTRACRANIA...|[10006,ELIZA COFF...|AL - Birmingham|[37560.37,5434.95...|
|039 - EXTRACRANIA...|[10011,ST VINCENT...|AL - Birmingham|[13998.28,5417.56...|
|039 - EXTRACRANIA...|[10016,SHELBY BAP...|AL - Birmingham|[31633.27,5658.33...|
|039 - EXTRACRANIA...|[10023,BAPTIST ME...|AL - Montgomery|[16920.79,6653.8,...|
|039 - EXTRACRANIA...|[10029,EAST ALABA...|AL - Birmingham|[11977.13,5834.74...|
|039 - EXTRACRANIA...|[10033,UNIVERSITY...|AL - Birmingham|[35841.09,8031.12...|
|039 - EXTRACRANIA...|[10039,HUNTSVILLE...|AL - Huntsville|[28523.39,6113.38...|
|039 - EXTRACRANIA...|[10040,GADSDEN RE...|AL - Birmingham|[75233.38,5541.05...|
|039 - EXTRACRANIA...|[10046,RIVERVIEW ...|AL - Birmingham|[67327.92,5461.57...|
|039 - EXTRACRANIA...|[10055,FLOWERS HO...|    AL - Dothan|[39607.28,5356.28...|
|039 - EXTRACRANIA...|[10056,ST VINCENT...|AL - Birmingham|[22862.23,5374.65...|
|039 - EXTRACRANIA...|[10078,NORTHEAST ...|AL - Birmingham|[31110.85,5366.23...|
|039 - EXTRACRANIA...|[10083,SOUTH BALD...|    AL - Mobile|[25411.33,5282.93...|
|039 - EXTRACRANIA...|[10085,DECATUR GE...|AL - Huntsville|[9234.51,5676.55,...|
|039 - EXTRACRANIA...|[10090,PROVIDENCE...|    AL - Mobile|[15895.85,5930.11...|
|039 - EXTRACRANIA...|[10092,D C H REGI...|AL - Tuscaloosa|[19721.16,6192.54...|
|039 - EXTRACRANIA...|[10100,THOMAS HOS...|    AL - Mobile|[10710.88,4968.0,...|
|039 - EXTRACRANIA...|[10103,BAPTIST ME...|AL - Birmingham|[51343.75,5996.0,...|
+--------------------+--------------------+---------------+--------------------+
only showing top 20 rows
```

Paso 5: Escribir los datos en Apache Parquet

AWS Glue le facilita la tarea de escribir los datos en un formato como Apache Parquet que las bases de datos relacionales pueden utilizar de manera eficaz:

```
glueContext.write_dynamic_frame.from_options(
       frame = medicare_nest_dyf,
       connection_type = "s3",
       connection_options = {"path": "s3://glue-sample-target/output-dir/
medicare_parquet"},
       format = "parquet")
```

Referencia de las extensiones de PySpark de AWS Glue

AWS Glue ha creado las siguientes extensiones del dialecto PySpark Python.

- Acceso a los parámetros mediante `getResolvedOptions`
- Tipos de extensión PySpark
- Clase DynamicFrame
- Clase DynamicFrameCollection

- Clase DynamicFrameWriter
- Clase DynamicFrameReader
- Clase GlueContext

Acceso a los parámetros mediante **`getResolvedOptions`**

La función de utilidad `getResolvedOptions(args, options)` de AWS Glue le da acceso a los argumentos que se pasan a su script cuando ejecuta un flujo de trabajo. Para utilizar esta función, comience importándola desde el módulo `utils` de AWS Glue junto con el módulo `sys`:

```
import sys
from awsglue.utils import getResolvedOptions
```

`getResolvedOptions(args, options)`

- `args`: lista de argumentos contenida en `sys.argv`.
- `options`: matriz de Python de los nombres de argumentos que quiere recuperar.

Example Recuperación de los argumentos que se pasan a un JobRun

Imagine que ha creado un JobRun en un script, quizás dentro de una función Lambda:

```
response = client.start_job_run(
             JobName = 'my_test_Job',
             Arguments = {
               '--day_partition_key':   'partition_0',
               '--hour_partition_key':  'partition_1',
               '--day_partition_value':  day_partition_value,
               '--hour_partition_value': hour_partition_value } )
```

Para recuperar los argumentos que se pasan, puede utilizar la función `getResolvedOptions` de la siguiente manera:

```
import sys
from awsglue.utils import getResolvedOptions

args = getResolvedOptions(sys.argv,
                          ['JOB_NAME',
```

```
                            'day_partition_key',
                            'hour_partition_key',
                            'day_partition_value',
                            'hour_partition_value'])
print "The day-partition key is: ", args['day_partition_key']
print "and the day-partition value is: ", args['day_partition_value']
```

Tenga en cuenta que al definir cada uno de los argumentos comienzan con dos guiones y después se hace referencia a ellos en el script sin los guiones. Los argumentos solo usan guiones bajos, no guiones. Sus argumentos tienen que seguir esta convención para que se puedan resolver.

Tipos de extensión PySpark

Los tipos usados por las extensiones PySpark de AWS Glue.

DataType

La clase base para los otros tipos de AWS Glue.

`__init__(properties={})`

- `properties`: propiedades del tipo de datos (opcional).

`typeName(cls)`

Devuelve el tipo de la clase de tipo de AWS Glue (es decir, el nombre de la clase con "Type" eliminado del final).

- `cls`: una instancia de clase de AWS Glue derivada de `DataType`.

`jsonValue( )`

Devuelve un objeto JSON que contiene las propiedades y los tipos de datos de la clase:

```
  {
    "dataType": typeName,
    "properties": properties
  }
```

AtomicType y derivados sencillos

Se hereda de la clase DataType y la amplía, además de servir como clase base para todos los tipos de datos atómicos de AWS Glue.

`fromJsonValue(cls, json_value)`

Inicializa una instancia de la clase con valores a partir de un objeto JSON.

- `cls`: una instancia de la clase de tipo de AWS Glue que se va a inicializar.
- `json_value`: objeto JSON desde el que se van a cargar pares clave-valor.

Los siguientes tipos son derivados sencillos de la clase AtomicType:

- `BinaryType` – Datos binarios.
- `BooleanType`: valores booleanos.
- `ByteType`: un valor de byte.
- `DateType`: un valor datetime.
- `DoubleType`: un valor doble de punto flotante.
- `IntegerType` – Un valor entero.
- `LongType`: un valor entero largo.
- `NullType`: un valor nulo.
- `ShortType`: un valor entero corto.
- `StringType`: una cadena de texto.
- `TimestampType`: un valor de marca temporal (normalmente en segundos desde el 01/01/1970).
- `UnknownType`: un valor de tipo no identificado.

DecimalType(AtomicType)

Se hereda de la clase AtomicType y la amplía para representar un número decimal (un número expresado en dígitos decimales, en contraposición a los números de base 2 binarios).

`__init__(precision=10, scale=2, properties={})`

- `precision`: el número de dígitos en el número decimal (opcional; el valor predeterminado es 10).

- `scale`: el número de dígitos situados a la derecha del punto decimal (opcional; el valor predeterminado es 2).
- `properties`: las propiedades del número decimal (opcional).

EnumType(AtomicType)

Se hereda de la clase AtomicType y la amplía para representar una enumeración de opciones válidas.

`__init__(options)`

- `options`: una lista de las opciones que se enumeran.

tipos de colección

- ArrayType(DataType)
- ChoiceType(DataType)
- MapType(DataType)
- Field(Object)
- StructType(DataType)
- (EntityType DataType)

ArrayType(DataType)

`__init__(elementType=UnknownType(), properties={})`

- `elementType`: el tipo de elementos en la matriz (opcional; el valor predeterminado es UnknownType).
- `properties`: propiedades de la matriz (opcional).

ChoiceType(DataType)

`__init__(choices=[], properties={})`

- `choices`: una lista de posibles opciones (opcional).
- `properties`: propiedades de estas opciones (opcional).

add(new_choice)

Añade una nueva opción a la lista de posibles opciones.

- `new_choice`: la opción que se va a añadir a la lista de posibles opciones.

merge(new_choices)

Combina una lista de nuevas opciones con la lista de opciones existente.

- `new_choices`: una lista de nuevas opciones que se van a combinar con las opciones existentes.

MapType(DataType)

__init__(valueType=UnknownType, properties={})

- `valueType`: el tipo de valores en el mapa (opcional; el valor predeterminado es UnknownType).
- `properties`: propiedades del mapa (opcional).

Field(Object)

Crea un objeto de campo fuera de un objeto que deriva de DataType.

__init__(name, dataType, properties={})

- `name`: el nombre que se va a asignar al campo.
- `dataType`: el objeto a partir del cual se va a crear un campo.
- `properties`: propiedades del campo (opcional).

StructType(DataType)

Define una estructura de datos (`struct`).

__init__(fields=[], properties={})

- `fields`: una lista de los campos (de tipo `Field`) que se va a incluir en la estructura (opcional).

- `properties`: propiedades de la estructura (opcional).

`add(field)`

- `field`: un objeto de tipo `Field` para añadir a la estructura.

`hasField(field)`

Devuelve `True` si esta estructura tiene un campo del mismo nombre, o `False` si no.

- `field`: un nombre de campo o un objeto de tipo `Field` cuyo nombre se usa.

`getField(field)`

- `field`: un nombre de campo o un objeto de tipo `Field` cuyo nombre se usa. Si la estructura tiene un campo del mismo nombre, se devuelve.

(EntityType DataType)

`__init__(entity, base_type, properties)`

Esta clase no se ha implementado aún.

otros tipos

- DataSource(object)
- DataSink(object)

DataSource(object)

`__init__(j_source, sql_ctx, name)`

- `j_source`: el origen de datos.
- `sql_ctx`: el contexto SQL.
- `name`: el nombre de origen de datos.

`setFormat(format, **options)`

- `format`: el formato que se va a establecer para el origen de datos.
- `options`: un conjunto de opciones que se va a establecer para el origen de datos. Para obtener más información sobre las opciones de formato, consulte the section called “Opciones de formato de datos”.

`getFrame()`

Devuelve un `DynamicFrame` para el origen de datos.

DataSink(object)

`__init__(j_sink, sql_ctx)`

- `j_sink`: el receptor que se va a crear.
- `sql_ctx`: el contexto SQL para el receptor de datos.

`setFormat(format, **options)`

- `format`: el formato que se va a establecer para el receptor de datos.
- `options`: un conjunto de opciones que se va a establecer para el receptor de datos. Para obtener más información sobre las opciones de formato, consulte the section called “Opciones de formato de datos”.

`setAccumulableSize(size)`

- `size`: el tamaño acumulable que se va a establecer, en bytes.

`writeFrame(dynamic_frame, info="")`

- `dynamic_frame`: el `DynamicFrame` que se va a escribir.
- `info`: información acerca del `DynamicFrame` (opcional).

write(dynamic_frame_or_dfc, info="")

Escribe un DynamicFrame o DynamicFrameCollection.

- dynamic_frame_or_dfc: un objeto DynamicFrame o DynamicFrameCollection que se van a escribir.
- info: información acerca de los DynamicFrame o DynamicFrames que se van a escribir (opcional).

Clase DynamicFrame

Una de las principales abstracciones de Apache Spark es el DataFrame de SparkSQL, que es similar a la construcción DataFrame que se encuentra en R y en Pandas. Un elemento DataFrame es similar a una tabla y admite operaciones de estilo funcional (map/reduce/filter/etc.) y operaciones SQL (select, project, aggregate).

DataFrames son eficaces y de uso general, pero tienen limitaciones en las operaciones de extracción, transformación y carga (ETL). Más aún, es preciso especificar un esquema antes de cargar cualquier dato. SparkSQL aborda esta cuestión al repasar dos veces los datos: la primera para deducir el esquema y la segunda para cargar los datos. Sin embargo, esta deducción es limitada y no se ocupa de la realidad de los datos confusos. Por ejemplo, el mismo campo puede ser de un tipo diferente en diferentes registros. Apache Spark a menudo renuncia e informa del tipo como si fuera una string mediante el texto del campo original. Esto podría no ser correcto y puede que desee controlar mejor cómo se resuelven las discrepancias en el esquema. Y en cuanto a grandes conjuntos de datos, un paso adicional por los datos de origen podría tener un precio prohibitivo.

Para abordar estas limitaciones, AWS Glue introduce DynamicFrame. DynamicFrame es similar a DataFrame, salvo que cada registro se describe a sí mismo, por lo que no es preciso tener un esquema inicial. En su lugar, AWS Glue procesa un esquema sobre la marcha cuando es necesario y codifica explícitamente las incoherencias de esquema mediante un tipo de elección (o unión). Puede resolver estas incoherencias para que los conjuntos de datos pasen a ser compatibles con almacenes de datos que requieren un esquema fijo.

Asimismo, un DynamicRecord representa un registro lógico dentro de un DynamicFrame. Es como una fila en un DataFrame de Spark, salvo que es autodescriptivo y se puede utilizar para datos que no se ajustan a un esquema fijo. Cuando se utiliza Glue AWS con PySpark, no suele manipular de

forma independiente DynamicRecords. Más bien, transformará el conjunto de datos en conjunto a través de DynamicFrame.

Puede convertir DynamicFrames en DataFrames y viceversa, una vez que haya resuelto las incoherencias de esquema.

— construcción —

- __init__
- fromDF
- toDF

__init__

__init__(jdf, glue_ctx, name)

- jdf: referencia a la trama de datos de la máquina virtual de Java (JVM).
- glue_ctx: objeto Clase GlueContext.
- name: cadena de nombre opcional, vacía de forma predeterminada.

fromDF

fromDF(dataframe, glue_ctx, name)

Convierte un DataFrame en un DynamicFrame al convertir campos de DataFrame en campos de DynamicRecord. Devuelve el nuevo DynamicFrame.

Un DynamicRecord representa un registro lógico en un DynamicFrame. Es similar a una fila en un DataFrame de Spark, salvo que es autodescriptivo y se puede utilizar para datos que no se ajustan a un esquema fijo.

Esta función espera que las columnas con nombres duplicados en el DataFrame ya se hayan resuelto.

- dataframe: DataFrame de Apache Spark SQL que debe convertirse (obligatorio).
- glue_ctx: objeto Clase GlueContext que especifica el contexto de esta transformación (obligatorio).

- name: el nombre de DynamicFrame que resulte (opcional desde AWS Glue 3.0).

toDF

toDF(options)

Convierte un DynamicFrame en un DataFrame de Apache Spark convirtiendo campos de DynamicRecords en campos de DataFrame. Devuelve el nuevo DataFrame.

Un DynamicRecord representa un registro lógico en un DynamicFrame. Es similar a una fila en un DataFrame de Spark, salvo que es autodescriptivo y se puede utilizar para datos que no se ajustan a un esquema fijo.

- options: lista de objetos ResolveOption que especifica cómo resolver los tipos de elección durante la conversión. Este parámetro se utiliza para gestionar las incoherencias del esquema, no para opciones de formato como el análisis de CSV.

  Para el análisis de CSV y otras opciones de formato, especifíquelas en el método from_options al crear el DynamicFrame, no en el método toDF.

  Este es un ejemplo de la forma correcta de gestionar las opciones de formato CSV:

```
from awsglue.context import GlueContext
from awsglue.dynamicframe import DynamicFrame
from pyspark.context import SparkContext

sc = SparkContext()
glueContext = GlueContext(sc)

# Correct: Specify format options in from_options
csv_dyf = glueContext.create_dynamic_frame.from_options(
    connection_type="s3",
    connection_options={"paths": ["s3://my-bucket/path/to/csv/"]},
    format="csv",
    format_options={
        "withHeader": True,
        "separator": ",",
        "inferSchema": True
    }
)

# Convert to DataFrame (no format options needed here)
```

```
csv_df = csv_dyf.toDF()
```

El parámetro `options` en `toDF` es específico para resolver tipos de opciones. Especifique el tipo de destino si ha elegido el tipo de acción `Project` y `Cast`. Algunos ejemplos son los siguientes:

```
>>>toDF([ResolveOption("a.b.c", "KeepAsStruct")])
>>>toDF([ResolveOption("a.b.c", "Project", DoubleType())])
```

— información —

- count
- esquema
- printSchema
- show
- repartition
- coalesce

count

`count( )` – Devuelve el número de filas del subyacente `DataFrame`.

esquema

`schema( )` - Muestra el esquema de este `DynamicFrame` o en caso de que no esté disponible, el esquema del elemento `DataFrame` subyacente.

Para obtener más información acerca de los tipos de `DynamicFrame` que componen este esquema, consulte the section called “Tipos”.

printSchema

`printSchema( )` – Imprime el esquema del subyacente `DataFrame`.

show

`show(num_rows)` – Imprime un número especificado de filas del subyacente `DataFrame`.

repartition

`repartition(numPartitions)`: devuelve un `DynamicFrame` nuevo con particiones `numPartitions`.

coalesce

`coalesce(numPartitions)`: devuelve un `DynamicFrame` nuevo con particiones `numPartitions`.

— transformaciones —

- apply_mapping
- drop_fields
- filtro
- unirse
- map
- mergeDynamicFrame
- relationalize
- rename_field
- resolveChoice
- select_fields
- spigot
- split_fields
- split_rows
- unbox
- the section called “unión”
- unnest
- unnest_ddb_json
- write

apply_mapping

`apply_mapping(mappings, transformation_ctx="", info="", stageThreshold=0, totalThreshold=0)`

Aplica una asignación declarativa a un `DynamicFrame` y devuelve un `DynamicFrame` nuevo con esas asignaciones aplicadas a los campos que se especifican. Los campos no especificados se omiten en el `DynamicFrame` nuevo.

- `mappings`: una lista de tuplas de asignación (obligatorio). Cada una consta de (columna de origen, tipo de origen, columna de destino, tipo de destino).

  Si la columna de origen tiene un punto "`.`" en el nombre, se deben colocar comillas simples "`` ` ``" antes y después. Por ejemplo, para asignar `this.old.name` (cadena) a `thisNewName`, debe utilizar las siguientes tuplas:

  ```
  ("`this.old.name`", "string", "thisNewName", "string")
  ```

- `transformation_ctx`: cadena única que se utiliza para identificar la información del estado (opcional).
- `info`: cadena que se asociará a la notificación de errores para esta transformación (opcional).
- `stageThreshold`: cantidad de errores detectados durante esta transformación que provocarán que el proceso falle (opcional). El valor predeterminado es cero, lo que indica que el proceso no debería fallar.
- `totalThreshold`: cantidad de errores detectados hasta esta transformación incluida que provocarán que el proceso falle (opcional). El valor predeterminado es cero, lo que indica que el proceso no debería fallar.

Ejemplo: uso de apply_mapping para cambiar el nombre de los campos y cambiar los tipos de campos

En el siguiente ejemplo de código, se muestra cómo utilizar el método `apply_mapping` para cambiar el nombre de los campos seleccionados y cambiar los tipos de campos.

> **Note**
>
> Para acceder al conjunto de datos utilizado en este ejemplo, consulte Código de ejemplo: unión de los datos y establecimiento de relaciones entre ellos y siga las instrucciones en Paso 1: Rastrear los datos del bucket de Amazon S3.

```
# Example: Use apply_mapping to reshape source data into
# the desired column names and types as a new DynamicFrame

from pyspark.context import SparkContext
from awsglue.context import GlueContext

# Create GlueContext
sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

# Create a DynamicFrame and view its schema
persons = glueContext.create_dynamic_frame.from_catalog(
    database="legislators", table_name="persons_json"
)
print("Schema for the persons DynamicFrame:")
persons.printSchema()

# Select and rename fields, change field type
print("Schema for the persons_mapped DynamicFrame, created with apply_mapping:")
persons_mapped = persons.apply_mapping(
    [
        ("family_name", "String", "last_name", "String"),
        ("name", "String", "first_name", "String"),
        ("birth_date", "String", "date_of_birth", "Date"),
    ]
)
persons_mapped.printSchema()
```

Output

```
Schema for the persons DynamicFrame:
root
|-- family_name: string
|-- name: string
```

```
|-- links: array
|    |-- element: struct
|    |    |-- note: string
|    |    |-- url: string
|-- gender: string
|-- image: string
|-- identifiers: array
|    |-- element: struct
|    |    |-- scheme: string
|    |    |-- identifier: string
|-- other_names: array
|    |-- element: struct
|    |    |-- lang: string
|    |    |-- note: string
|    |    |-- name: string
|-- sort_name: string
|-- images: array
|    |-- element: struct
|    |    |-- url: string
|-- given_name: string
|-- birth_date: string
|-- id: string
|-- contact_details: array
|    |-- element: struct
|    |    |-- type: string
|    |    |-- value: string
|-- death_date: string

Schema for the persons_mapped DynamicFrame, created with apply_mapping:
root
|-- last_name: string
|-- first_name: string
|-- date_of_birth: date
```

drop_fields

`drop_fields(paths, transformation_ctx="", info="", stageThreshold=0, totalThreshold=0)`

Llama a la transformación Clase FlatMap para eliminar campos de un elemento `DynamicFrame`. Devuelve un `DynamicFrame` nuevo con los campos especificados anulados.

- `paths`: una lista de cadenas. Cada una contiene la ruta completa a un nodo de campo que desea descartar. Puede utilizar la notación de puntos para especificar campos anidados. Por ejemplo, si el campo `first` es un elemento secundario del campo `name` en el árbol, especificará `"name.first"` para la ruta.

  Si el nombre de un nodo de campo tiene un literal `.`, debe escribir el nombre entre tildes graves (`` ` ``).
- `transformation_ctx`: cadena única que se utiliza para identificar la información del estado (opcional).
- `info`: cadena que se asociará a la notificación de errores para esta transformación (opcional).
- `stageThreshold`: cantidad de errores detectados durante esta transformación que provocarán que el proceso falle (opcional). El valor predeterminado es cero, lo que indica que el proceso no debería fallar.
- `totalThreshold`: cantidad de errores detectados hasta esta transformación incluida que provocarán que el proceso falle (opcional). El valor predeterminado es cero, lo que indica que el proceso no debería fallar.

Ejemplo: uso de drop_fields para descartar campos de un **`DynamicFrame`**

En este ejemplo de código se utiliza el método `drop_fields` para eliminar los campos anidados y de nivel superior seleccionados de un `DynamicFrame`.

Conjunto de datos de ejemplo

El ejemplo utiliza el siguiente conjunto de datos que está representado por la tabla `EXAMPLE-FRIENDS-DATA` en el código:

```
{"name": "Sally", "age": 23, "location": {"state": "WY", "county": "Fremont"},
 "friends": []}
{"name": "Varun", "age": 34, "location": {"state": "NE", "county": "Douglas"},
 "friends": [{"name": "Arjun", "age": 3}]}
{"name": "George", "age": 52, "location": {"state": "NY"}, "friends": [{"name":
 "Fred"}, {"name": "Amy", "age": 15}]}
{"name": "Haruki", "age": 21, "location": {"state": "AK", "county": "Denali"}}
{"name": "Sheila", "age": 63, "friends": [{"name": "Nancy", "age": 22}]}
```

Código de ejemplo

```
# Example: Use drop_fields to remove top-level and nested fields from a DynamicFrame.
```

```
# Replace MY-EXAMPLE-DATABASE with your Glue Data Catalog database name.
# Replace EXAMPLE-FRIENDS-DATA with your table name.

from pyspark.context import SparkContext
from awsglue.context import GlueContext

# Create GlueContext
sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

# Create a DynamicFrame from Glue Data Catalog
glue_source_database = "MY-EXAMPLE-DATABASE"
glue_source_table = "EXAMPLE-FRIENDS-DATA"

friends = glueContext.create_dynamic_frame.from_catalog(
    database=glue_source_database, table_name=glue_source_table
)
print("Schema for friends DynamicFrame before calling drop_fields:")
friends.printSchema()

# Remove location.county, remove friends.age, remove age
friends = friends.drop_fields(paths=["age", "location.county", "friends.age"])
print("Schema for friends DynamicFrame after removing age, county, and friend age:")
friends.printSchema()
```

Output

```
Schema for friends DynamicFrame before calling drop_fields:
root
|-- name: string
|-- age: int
|-- location: struct
|    |-- state: string
|    |-- county: string
|-- friends: array
|    |-- element: struct
|    |    |-- name: string
|    |    |-- age: int

Schema for friends DynamicFrame after removing age, county, and friend age:
root
|-- name: string
|-- location: struct
```

```
|    |-- state: string
|-- friends: array
|    |-- element: struct
|    |    |-- name: string
```

filtro

`filter(f, transformation_ctx="", info="", stageThreshold=0, totalThreshold=0)`

Devuelve un `DynamicFrame` nuevo que contiene todos los `DynamicRecords` dentro de la entrada `DynamicFrame` que cumplen la función `f` de predicado especificada.

- `f` – función de predicado que debe aplicarse al elemento `DynamicFrame`. La función debe tomar un `DynamicRecord` como argumento y devolver True si `DynamicRecord` cumple los requisitos de filtro o False si no los cumple (obligatorio).

  Un `DynamicRecord` representa un registro lógico en un `DynamicFrame`. Es similar a una fila en un `DataFrame` de Spark, salvo que es autodescriptivo y se puede utilizar para datos que no se ajustan a un esquema fijo.
- `transformation_ctx`: cadena única que se utiliza para identificar la información del estado (opcional).
- `info`: cadena que se asociará a la notificación de errores para esta transformación (opcional).
- `stageThreshold`: cantidad de errores detectados durante esta transformación que provocarán que el proceso falle (opcional). El valor predeterminado es cero, lo que indica que el proceso no debería fallar.
- `totalThreshold`: cantidad de errores detectados hasta esta transformación incluida que provocarán que el proceso falle (opcional). El valor predeterminado es cero, lo que indica que el proceso no debería fallar.

Ejemplo: uso de filter para obtener una selección filtrada de campos

En este ejemplo se utiliza el método `filter` para crear un `DynamicFrame` nuevo que incluye una selección filtrada de campos de otro `DynamicFrame`.

Al igual que el método `map`, `filter` toma una función como un argumento que se aplica a cada registro en el `DynamicFrame` original. La función toma un registro como una entrada y devuelve un

valor booleano. Si el valor que se devuelve es verdadero, el registro se incluye en el `DynamicFrame` resultante. Si es falso, el registro se omite.

> **Note**
>
> Para acceder al conjunto de datos utilizado en este ejemplo, consulte Ejemplo de código: Preparación de datos con ResolveChoice, Lambda y ApplyMapping y siga las instrucciones en Paso 1: Rastrear los datos del bucket de Amazon S3.

```
# Example: Use filter to create a new DynamicFrame
# with a filtered selection of records

from pyspark.context import SparkContext
from awsglue.context import GlueContext

# Create GlueContext
sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

# Create DynamicFrame from Glue Data Catalog
medicare = glueContext.create_dynamic_frame.from_options(
    "s3",
    {
        "paths": [
            "s3://awsglue-datasets/examples/medicare/Medicare_Hospital_Provider.csv"
        ]
    },
    "csv",
    {"withHeader": True},
)

# Create filtered DynamicFrame with custom lambda
# to filter records by Provider State and Provider City
sac_or_mon = medicare.filter(
    f=lambda x: x["Provider State"] in ["CA", "AL"]
    and x["Provider City"] in ["SACRAMENTO", "MONTGOMERY"]
)

# Compare record counts
print("Unfiltered record count: ", medicare.count())
```

```
print("Filtered record count:  ", sac_or_mon.count())
```

Output

```
Unfiltered record count:  163065
Filtered record count:   564
```

unirse

`join(paths1, paths2, frame2, transformation_ctx="", info="", stageThreshold=0, totalThreshold=0)`

Realiza una unión de igualdad con otro elemento `DynamicFrame` y devuelve el elemento `DynamicFrame` resultante.

- `paths1`: lista de las claves de esta trama que deben unirse.
- `paths2`: lista de las claves de la otra trama que deben unirse.
- `frame2`: el otro elemento `DynamicFrame` que debe unirse.
- `transformation_ctx`: cadena única que se utiliza para identificar la información del estado (opcional).
- `info`: cadena que se asociará a la notificación de errores para esta transformación (opcional).
- `stageThreshold`: cantidad de errores detectados durante esta transformación que provocarán que el proceso falle (opcional). El valor predeterminado es cero, lo que indica que el proceso no debería fallar.
- `totalThreshold`: cantidad de errores detectados hasta esta transformación incluida que provocarán que el proceso falle (opcional). El valor predeterminado es cero, lo que indica que el proceso no debería fallar.

Ejemplo: uso de join para combinar **`DynamicFrames`**

En este ejemplo se utiliza el método `join` para realizar una unión en tres `DynamicFrames`. AWS Glue realiza la unión en función de las claves de campos que se proporcionan. El `DynamicFrame` resultante contiene filas de los dos marcos originales donde coinciden las claves especificadas.

Tenga en cuenta que la transformación `join` mantiene todos los campos intactos. Esto significa que los campos que se especifican para que coincidan aparecen en el DynamicFrame resultante, incluso

si son redundantes y contienen las mismas claves. En este ejemplo, utilizamos `drop_fields` para eliminar estas claves redundantes después de la unión.

> **Note**
>
> Para acceder al conjunto de datos utilizado en este ejemplo, consulte Código de ejemplo: unión de los datos y establecimiento de relaciones entre ellos y siga las instrucciones en Paso 1: Rastrear los datos del bucket de Amazon S3.

```
# Example: Use join to combine data from three DynamicFrames

from pyspark.context import SparkContext
from awsglue.context import GlueContext

# Create GlueContext
sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

# Load DynamicFrames from Glue Data Catalog
persons = glueContext.create_dynamic_frame.from_catalog(
    database="legislators", table_name="persons_json"
)
memberships = glueContext.create_dynamic_frame.from_catalog(
    database="legislators", table_name="memberships_json"
)
orgs = glueContext.create_dynamic_frame.from_catalog(
    database="legislators", table_name="organizations_json"
)
print("Schema for the persons DynamicFrame:")
persons.printSchema()
print("Schema for the memberships DynamicFrame:")
memberships.printSchema()
print("Schema for the orgs DynamicFrame:")
orgs.printSchema()

# Join persons and memberships by ID
persons_memberships = persons.join(
    paths1=["id"], paths2=["person_id"], frame2=memberships
)

# Rename and drop fields from orgs
```

```
# to prevent field name collisions with persons_memberships
orgs = (
    orgs.drop_fields(["other_names", "identifiers"])
    .rename_field("id", "org_id")
    .rename_field("name", "org_name")
)

# Create final join of all three DynamicFrames
legislators_combined = orgs.join(
    paths1=["org_id"], paths2=["organization_id"], frame2=persons_memberships
).drop_fields(["person_id", "org_id"])

# Inspect the schema for the joined data
print("Schema for the new legislators_combined DynamicFrame:")
legislators_combined.printSchema()
```

Output

```
Schema for the persons DynamicFrame:
root
|-- family_name: string
|-- name: string
|-- links: array
|    |-- element: struct
|    |    |-- note: string
|    |    |-- url: string
|-- gender: string
|-- image: string
|-- identifiers: array
|    |-- element: struct
|    |    |-- scheme: string
|    |    |-- identifier: string
|-- other_names: array
|    |-- element: struct
|    |    |-- lang: string
|    |    |-- note: string
|    |    |-- name: string
|-- sort_name: string
|-- images: array
|    |-- element: struct
|    |    |-- url: string
|-- given_name: string
|-- birth_date: string
```

```
|-- id: string
|-- contact_details: array
|    |-- element: struct
|    |    |-- type: string
|    |    |-- value: string
|-- death_date: string

Schema for the memberships DynamicFrame:
root
|-- area_id: string
|-- on_behalf_of_id: string
|-- organization_id: string
|-- role: string
|-- person_id: string
|-- legislative_period_id: string
|-- start_date: string
|-- end_date: string

Schema for the orgs DynamicFrame:
root
|-- identifiers: array
|    |-- element: struct
|    |    |-- scheme: string
|    |    |-- identifier: string
|-- other_names: array
|    |-- element: struct
|    |    |-- lang: string
|    |    |-- note: string
|    |    |-- name: string
|-- id: string
|-- classification: string
|-- name: string
|-- links: array
|    |-- element: struct
|    |    |-- note: string
|    |    |-- url: string
|-- image: string
|-- seats: int
|-- type: string

Schema for the new legislators_combined DynamicFrame:
root
|-- role: string
|-- seats: int
```

```
|-- org_name: string
|-- links: array
|    |-- element: struct
|    |    |-- note: string
|    |    |-- url: string
|-- type: string
|-- sort_name: string
|-- area_id: string
|-- images: array
|    |-- element: struct
|    |    |-- url: string
|-- on_behalf_of_id: string
|-- other_names: array
|    |-- element: struct
|    |    |-- note: string
|    |    |-- name: string
|    |    |-- lang: string
|-- contact_details: array
|    |-- element: struct
|    |    |-- type: string
|    |    |-- value: string
|-- name: string
|-- birth_date: string
|-- organization_id: string
|-- gender: string
|-- classification: string
|-- legislative_period_id: string
|-- identifiers: array
|    |-- element: struct
|    |    |-- scheme: string
|    |    |-- identifier: string
|-- image: string
|-- given_name: string
|-- start_date: string
|-- family_name: string
|-- id: string
|-- death_date: string
|-- end_date: string
```

map

`map(f, transformation_ctx="", info="", stageThreshold=0, totalThreshold=0)`

Devuelve un elemento `DynamicFrame` nuevo que se obtiene al aplicar la función de mapeo especificada a todos los registros del elemento `DynamicFrame` original.

- `f` – función de asignación que debe aplicarse a todos los registros del elemento `DynamicFrame`. La función debe tomar un elemento `DynamicRecord` como argumento y devolver un `DynamicRecord` nuevo (obligatorio).

  Un `DynamicRecord` representa un registro lógico en un `DynamicFrame`. Es similar a una fila en un `DataFrame` de Apache Spark, salvo que es autodescriptivo y se puede utilizar para datos que no se ajustan a un esquema fijo.
- `transformation_ctx`: cadena única que se utiliza para identificar la información del estado (opcional).
- `info`: cadena que está asociada con errores en la transformación (opcional).
- `stageThreshold`: cantidad máxima de errores que se puede producir en la transformación antes de que se determine que es errónea (opcional). El rol predeterminado es cero.
- `totalThreshold`: cantidad máxima de errores que se pueden producir en total antes de que se determine que el proceso es erróneo (opcional). El rol predeterminado es cero.

Ejemplo: uso de map para aplicar una función a cada registro en un **`DynamicFrame`**

En este ejemplo se muestra cómo utilizar el método `map` para aplicar una función a cada registro de un `DynamicFrame`. En concreto, este ejemplo aplica una función llamada `MergeAddress` a cada registro para combinar varios campos de dirección en un solo tipo de `struct`.

> **Note**
>
> Para acceder al conjunto de datos utilizado en este ejemplo, consulte Ejemplo de código: Preparación de datos con ResolveChoice, Lambda y ApplyMapping y siga las instrucciones en Paso 1: Rastrear los datos del bucket de Amazon S3.

```
# Example: Use map to combine fields in all records
# of a DynamicFrame
```

```
from pyspark.context import SparkContext
from awsglue.context import GlueContext

# Create GlueContext
sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

# Create a DynamicFrame and view its schema
medicare = glueContext.create_dynamic_frame.from_options(
        "s3",
        {"paths": ["s3://awsglue-datasets/examples/medicare/
Medicare_Hospital_Provider.csv"]},
        "csv",
        {"withHeader": True})
print("Schema for medicare DynamicFrame:")
medicare.printSchema()

# Define a function to supply to the map transform
# that merges address fields into a single field
def MergeAddress(rec):
  rec["Address"] = {}
  rec["Address"]["Street"] = rec["Provider Street Address"]
  rec["Address"]["City"] = rec["Provider City"]
  rec["Address"]["State"] = rec["Provider State"]
  rec["Address"]["Zip.Code"] = rec["Provider Zip Code"]
  rec["Address"]["Array"] = [rec["Provider Street Address"], rec["Provider City"],
 rec["Provider State"], rec["Provider Zip Code"]]
  del rec["Provider Street Address"]
  del rec["Provider City"]
  del rec["Provider State"]
  del rec["Provider Zip Code"]
  return rec


# Use map to apply MergeAddress to every record
mapped_medicare = medicare.map(f = MergeAddress)
print("Schema for mapped_medicare DynamicFrame:")
mapped_medicare.printSchema()
```

Output

```
Schema for medicare DynamicFrame:
root
```

```
|-- DRG Definition: string
|-- Provider Id: string
|-- Provider Name: string
|-- Provider Street Address: string
|-- Provider City: string
|-- Provider State: string
|-- Provider Zip Code: string
|-- Hospital Referral Region Description: string
|-- Total Discharges: string
|-- Average Covered Charges: string
|-- Average Total Payments: string
|-- Average Medicare Payments: string

Schema for mapped_medicare DynamicFrame:
root
|-- Average Total Payments: string
|-- Average Covered Charges: string
|-- DRG Definition: string
|-- Average Medicare Payments: string
|-- Hospital Referral Region Description: string
|-- Address: struct
|    |-- Zip.Code: string
|    |-- City: string
|    |-- Array: array
|    |    |-- element: string
|    |-- State: string
|    |-- Street: string
|-- Provider Id: string
|-- Total Discharges: string
|-- Provider Name: string
```

mergeDynamicFrame

`mergeDynamicFrame(stage_dynamic_frame, primary_keys, transformation_ctx = "", options = {}, info = "", stageThreshold = 0, totalThreshold = 0)`

Combina este objeto `DynamicFrame` con una instancia provisional de `DynamicFrame` en función de las claves principales especificadas para identificar registros. Los registros duplicados (registros con las mismas claves principales) no se desduplican. Si no hay ningún registro que coincida en el marco provisional, se retienen todos los registros del origen (incluidos los duplicados). Si el marco provisional tiene registros coincidentes, estos sobrescriben a los registros del origen en AWS Glue.

- `stage_dynamic_frame`: `DynamicFrame` provisional que se fusionará.

- `primary_keys`: la lista de campos de clave principal para hacer coincidir los registros de los marcos dinámicos de origen y provisionales.
- `transformation_ctx`: cadena única que se utiliza para recuperar metadatos sobre la transformación actual (opcional).
- `options`: una cadena de pares de nombre-valor de JSON que proporcionan información adicional para esta transformación. Este argumento no se utiliza actualmente.
- `info` – un elemento `String`. Cualquier cadena que se va a asociar con los errores de esta transformación.
- `stageThreshold` – un elemento `Long`. Número de errores de la transformación especificada que provocarán que el proceso se termine.
- `totalThreshold` – un elemento `Long`. Número total de errores hasta esta transformación (incluida) que provocarán que el proceso se termine.

Este método devuelve un nuevo objeto `DynamicFrame` que se obtiene combinando esta instancia de `DynamicFrame` con la instancia de `DynamicFrame` provisional.

El objeto `DynamicFrame` devuelto contiene el registro A en estos casos:

- Si `A` existe tanto en el marco de origen como en el marco provisional, se devuelve `A` en el marco provisional.
- Si `A` está en la tabla de origen y `A.primaryKeys` no está en `stagingDynamicFrame` `A` no se actualiza en la tabla provisional.

No es necesario que el marco de origen y el marco provisional tengan el mismo esquema.

Ejemplo: utilice mergeDynamicFrame para combinar dos **`DynamicFrames`** en función de una clave principal

El siguiente ejemplo de código muestra cómo utilizar el método `mergeDynamicFrame` para combinar un `DynamicFrame` con un `DynamicFrame` de “puesta en escena”, en función del `id` de la clave principal.

Conjunto de datos de ejemplo

El ejemplo usa dos `DynamicFrames` de una `DynamicFrameCollection` llamada `split_rows_collection`. A continuación se ofrece una lista de las claves de `split_rows_collection`.

```
dict_keys(['high', 'low'])
```

Código de ejemplo

```
# Example: Use mergeDynamicFrame to merge DynamicFrames
# based on a set of specified primary keys

from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.transforms import SelectFromCollection

# Inspect the original DynamicFrames
frame_low = SelectFromCollection.apply(dfc=split_rows_collection, key="low")
print("Inspect the DynamicFrame that contains rows where ID < 10")
frame_low.toDF().show()

frame_high = SelectFromCollection.apply(dfc=split_rows_collection, key="high")
print("Inspect the DynamicFrame that contains rows where ID > 10")
frame_high.toDF().show()

# Merge the DynamicFrames based on the "id" primary key
merged_high_low = frame_high.mergeDynamicFrame(
    stage_dynamic_frame=frame_low, primary_keys=["id"]
)

# View the results where the ID is 1 or 20
print("Inspect the merged DynamicFrame that contains the combined rows")
merged_high_low.toDF().where("id = 1 or id= 20").orderBy("id").show()
```

Output

```
Inspect the DynamicFrame that contains rows where ID < 10
+---+-----+-----------------------+-----------------------+
| id|index|contact_details.val.type|contact_details.val.value|
+---+-----+-----------------------+-----------------------+
|  1|    0|                    fax|           202-225-3307|
|  1|    1|                  phone|           202-225-5731|
|  2|    0|                    fax|           202-225-3307|
|  2|    1|                  phone|           202-225-5731|
|  3|    0|                    fax|           202-225-3307|
|  3|    1|                  phone|           202-225-5731|
|  4|    0|                    fax|           202-225-3307|
```

```
|  4|    1|                  phone|            202-225-5731|
|  5|    0|                    fax|            202-225-3307|
|  5|    1|                  phone|            202-225-5731|
|  6|    0|                    fax|            202-225-3307|
|  6|    1|                  phone|            202-225-5731|
|  7|    0|                    fax|            202-225-3307|
|  7|    1|                  phone|            202-225-5731|
|  8|    0|                    fax|            202-225-3307|
|  8|    1|                  phone|            202-225-5731|
|  9|    0|                    fax|            202-225-3307|
|  9|    1|                  phone|            202-225-5731|
| 10|    0|                    fax|            202-225-6328|
| 10|    1|                  phone|            202-225-4576|
+---+-----+----------------------+------------------------+
only showing top 20 rows

Inspect the DynamicFrame that contains rows where ID > 10
+---+-----+----------------------+------------------------+
| id|index|contact_details.val.type|contact_details.val.value|
+---+-----+----------------------+------------------------+
| 11|    0|                    fax|            202-225-6328|
| 11|    1|                  phone|            202-225-4576|
| 11|    2|                twitter|          RepTrentFranks|
| 12|    0|                    fax|            202-225-6328|
| 12|    1|                  phone|            202-225-4576|
| 12|    2|                twitter|          RepTrentFranks|
| 13|    0|                    fax|            202-225-6328|
| 13|    1|                  phone|            202-225-4576|
| 13|    2|                twitter|          RepTrentFranks|
| 14|    0|                    fax|            202-225-6328|
| 14|    1|                  phone|            202-225-4576|
| 14|    2|                twitter|          RepTrentFranks|
| 15|    0|                    fax|            202-225-6328|
| 15|    1|                  phone|            202-225-4576|
| 15|    2|                twitter|          RepTrentFranks|
| 16|    0|                    fax|            202-225-6328|
| 16|    1|                  phone|            202-225-4576|
| 16|    2|                twitter|          RepTrentFranks|
| 17|    0|                    fax|            202-225-6328|
| 17|    1|                  phone|            202-225-4576|
+---+-----+----------------------+------------------------+
only showing top 20 rows

Inspect the merged DynamicFrame that contains the combined rows
```

```
+---+-----+-----------------------+-----------------------+
| id|index|contact_details.val.type|contact_details.val.value|
+---+-----+-----------------------+-----------------------+
|  1|    0|                    fax|           202-225-3307|
|  1|    1|                  phone|           202-225-5731|
| 20|    0|                    fax|           202-225-5604|
| 20|    1|                  phone|           202-225-6536|
| 20|    2|                twitter|              USRepLong|
+---+-----+-----------------------+-----------------------+
```

relationalize

`relationalize(root_table_name, staging_path, options, transformation_ctx="", info="", stageThreshold=0, totalThreshold=0)`

Convierte un `DynamicFrame` en un formulario que cabe en una base de datos relacional. Relacionalizar un `DynamicFrame` es especialmente útil cuando se desean mover datos de un entorno NoSQL como DynamoDB a una base de datos relacional como MySQL.

La transformación genera una lista de marcos al aplanar columnas anidadas y dinamizar las columnas de la matriz. Las columnas de matriz dinamizada se pueden unir a la tabla raíz con la clave de combinación generada durante la fase de desanidado.

- `root_table_name`: nombre de la tabla raíz.
- `staging_path`: ruta en la que el método puede almacenar las particiones de las tablas dinamizadas en formato CSV (opcional). Las tablas dinamizadas se leen desde esta ruta.
- `options`: diccionario de parámetros opcionales.
- `transformation_ctx`: cadena única que se utiliza para identificar la información del estado (opcional).
- `info`: cadena que se asociará a la notificación de errores para esta transformación (opcional).
- `stageThreshold`: cantidad de errores detectados durante esta transformación que provocarán que el proceso falle (opcional). El valor predeterminado es cero, lo que indica que el proceso no debería fallar.
- `totalThreshold`: cantidad de errores detectados hasta esta transformación incluida que provocarán que el proceso falle (opcional). El valor predeterminado es cero, lo que indica que el proceso no debería fallar.

Ejemplo: utilice relacionalizar para aplanar un esquema anidado en un **`DynamicFrame`**

Este ejemplo de código utiliza el método `relationalize` para aplanar un esquema anidado en un formulario que encaje en una base de datos relacional.

Conjunto de datos de ejemplo

El ejemplo usa un `DynamicFrame` llamado `legislators_combined` con el siguiente esquema. `legislators_combined` tiene varios campos anidados como `links`, `images` y `contact_details`, que se aplanarán con la transformación `relationalize`.

```
root
|-- role: string
|-- seats: int
|-- org_name: string
|-- links: array
|    |-- element: struct
|    |    |-- note: string
|    |    |-- url: string
|-- type: string
|-- sort_name: string
|-- area_id: string
|-- images: array
|    |-- element: struct
|    |    |-- url: string
|-- on_behalf_of_id: string
|-- other_names: array
|    |-- element: struct
|    |    |-- note: string
|    |    |-- name: string
|    |    |-- lang: string
|-- contact_details: array
|    |-- element: struct
|    |    |-- type: string
|    |    |-- value: string
|-- name: string
|-- birth_date: string
|-- organization_id: string
|-- gender: string
|-- classification: string
|-- legislative_period_id: string
|-- identifiers: array
|    |-- element: struct
```

```
|    |    |-- scheme: string
|    |    |-- identifier: string
|-- image: string
|-- given_name: string
|-- start_date: string
|-- family_name: string
|-- id: string
|-- death_date: string
|-- end_date: string
```

Código de ejemplo

```
# Example: Use relationalize to flatten
# a nested schema into a format that fits
# into a relational database.
# Replace DOC-EXAMPLE-S3-BUCKET/tmpDir with your own location.

from pyspark.context import SparkContext
from awsglue.context import GlueContext

# Create GlueContext
sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

# Apply relationalize and inspect new tables
legislators_relationalized = legislators_combined.relationalize(
    "l_root", "s3://DOC-EXAMPLE-BUCKET/tmpDir"
)
legislators_relationalized.keys()

# Compare the schema of the contact_details
# nested field to the new relationalized table that
# represents it
legislators_combined.select_fields("contact_details").printSchema()
legislators_relationalized.select("l_root_contact_details").toDF().where(
    "id = 10 or id = 75"
).orderBy(["id", "index"]).show()
```

Output

El siguiente resultado permite comparar el esquema del campo anidado llamado `contact_details` a la tabla que creó la transformación `relationalize`. Observe que los registros de la tabla se

vinculan a la tabla principal mediante una clave externa llamada `id` y una columna `index` que representa las posiciones de la matriz.

```
dict_keys(['l_root', 'l_root_images', 'l_root_links', 'l_root_other_names',
 'l_root_contact_details', 'l_root_identifiers'])

root
|-- contact_details: array
|    |-- element: struct
|    |    |-- type: string
|    |    |-- value: string

+---+-----+-----------------------+-----------------------+
| id|index|contact_details.val.type|contact_details.val.value|
+---+-----+-----------------------+-----------------------+
| 10|    0|                    fax|           202-225-4160|
| 10|    1|                  phone|           202-225-3436|
| 75|    0|                    fax|           202-225-6791|
| 75|    1|                  phone|           202-225-2861|
| 75|    2|                twitter|             RepSamFarr|
+---+-----+-----------------------+-----------------------+
```

rename_field

`rename_field(oldName, newName, transformation_ctx="", info="", stageThreshold=0, totalThreshold=0)`

Cambia el nombre de un campo en este `DynamicFrame` y devuelve un `DynamicFrame` nuevo con el campo con el nombre nuevo.

- `oldName`: la ruta completa al nodo cuyo nombre desea cambiar.

  Si el nombre antiguo tiene puntos, `RenameField` no funcionará a menos que lo ponga entre acentos graves (`). Por ejemplo, para reemplazar `this.old.name` por `thisNewName`, debería llamar a rename_field tal y como se indica a continuación:

  ```
  newDyF = oldDyF.rename_field("`this.old.name`", "thisNewName")
  ```

- `newName`: el nombre nuevo, indicado como una ruta completa.
- `transformation_ctx`: cadena única que se utiliza para identificar la información del estado (opcional).

- `info`: cadena que se asociará a la notificación de errores para esta transformación (opcional).
- `stageThreshold`: cantidad de errores detectados durante esta transformación que provocarán que el proceso falle (opcional). El valor predeterminado es cero, lo que indica que el proceso no debería fallar.
- `totalThreshold`: cantidad de errores detectados hasta esta transformación incluida que provocarán que el proceso falle (opcional). El valor predeterminado es cero, lo que indica que el proceso no debería fallar.

Ejemplo: utilice rename_field para cambiar el nombre de los campos de un **`DynamicFrame`**

Este ejemplo de código utiliza el método `rename_field` para cambiar el nombre de los campos de un `DynamicFrame`. Observe que en el ejemplo se utiliza el encadenamiento de métodos para renombrar varios campos al mismo tiempo.

> **Note**
>
> Para acceder al conjunto de datos utilizado en este ejemplo, consulte Código de ejemplo: unión de los datos y establecimiento de relaciones entre ellos y siga las instrucciones en Paso 1: Rastrear los datos del bucket de Amazon S3.

Código de ejemplo

```
# Example: Use rename_field to rename fields
# in a DynamicFrame

from pyspark.context import SparkContext
from awsglue.context import GlueContext

# Create GlueContext
sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

# Inspect the original orgs schema
orgs = glueContext.create_dynamic_frame.from_catalog(
    database="legislators", table_name="organizations_json"
)
print("Original orgs schema: ")
orgs.printSchema()
```

```
# Rename fields and view the new schema
orgs = orgs.rename_field("id", "org_id").rename_field("name", "org_name")
print("New orgs schema with renamed fields: ")
orgs.printSchema()
```

Output

```
Original orgs schema:
root
|-- identifiers: array
|    |-- element: struct
|    |    |-- scheme: string
|    |    |-- identifier: string
|-- other_names: array
|    |-- element: struct
|    |    |-- lang: string
|    |    |-- note: string
|    |    |-- name: string
|-- id: string
|-- classification: string
|-- name: string
|-- links: array
|    |-- element: struct
|    |    |-- note: string
|    |    |-- url: string
|-- image: string
|-- seats: int
|-- type: string

New orgs schema with renamed fields:
root
|-- identifiers: array
|    |-- element: struct
|    |    |-- scheme: string
|    |    |-- identifier: string
|-- other_names: array
|    |-- element: struct
|    |    |-- lang: string
|    |    |-- note: string
|    |    |-- name: string
|-- classification: string
|-- org_id: string
```

```
|-- org_name: string
|-- links: array
|    |-- element: struct
|    |    |-- note: string
|    |    |-- url: string
|-- image: string
|-- seats: int
|-- type: string
```

resolveChoice

`resolveChoice(specs = None, choice = "" , database = None , table_name = None , transformation_ctx="", info="", stageThreshold=0, totalThreshold=0, catalog_id = None)`

Resuelve un tipo de elección dentro de este elemento `DynamicFrame` y devuelve el `DynamicFrame` nuevo.

- `specs` – lista de ambigüedades concretas que deben resolverse, cada una en forma de tupla: `(field_path, action)`.

  Hay dos formas de usar `resolveChoice`. La primera consiste en utilizar el argumento `specs` para especificar una secuencia de campos específicos y cómo resolverlos. El otro modo de `resolveChoice` es utilizar el argumento `choice` para especificar una resolución única para todos los `ChoiceTypes`.

  Valores de `specs` se especifican como tuplas compuestas de pares `(field_path, action)`. El valor de `field_path` identifica un elemento ambiguo concreto, mientras que el valor de `action` identifica la resolución correspondiente. Los posibles valores son los siguientes:

  - `cast:`*`type`*: intenta convertir todos los valores al tipo especificado. Por ejemplo: `cast:int`.
  - `make_cols` – convierte cada tipo diferenciado en una columna con el nombre *`columnName_type`*. Resuelve una posible ambigüedad al aplanar los datos. Por ejemplo, si `columnA` puede ser tanto un `int` como una `string`, la resolución puede consistir en producir dos columnas llamadas `columnA_int` y `columnA_string` en el elemento `DynamicFrame` resultante.
  - `make_struct`: resuelve una posible ambigüedad al utilizar una `struct` para representar los datos. Por ejemplo, si los datos de una columna pueden ser tanto un `int` como una `string`,

la acción `make_struct` generará una columna de estructuras en el elemento `DynamicFrame` resultante. Cada estructura contiene tanto un `int` como una `string`.

- `project:`*`type`*: resuelve una posible ambigüedad al proyectar todos los datos a uno de los tipos de datos posibles. Por ejemplo, si los datos de una columna pueden ser tanto un `int` como una `string`, ejecutar la acción `project:string` genera una columna en el elemento `DynamicFrame` resultante, en la que todos los valores `int` se han convertido en cadenas.

Si en `field_path` se identifica una matriz, incluya corchetes vacíos después del nombre de la matriz para evitar ambigüedades. Por ejemplo, suponga que está trabajando con datos estructurados tal y como se indica a continuación:

```
"myList": [
  { "price": 100.00 },
  { "price": "$100.00" }
]
```

Puede seleccionar la versión numérica en vez de la de cadena del precio si configura `field_path` en `"myList[].price"` y `action` en `"cast:double"`.

> **Note**
>
> Solo se puede utilizar uno, el parámetro `specs` o el parámetro `choice`. Si el parámetro `specs` no es `None`, el parámetro `choice` tiene que ser una cadena vacía. Y viceversa, si el parámetro `choice` no es una cadena vacía, el parámetro `specs` tiene que ser `None`.

- `choice` – especifica una resolución única para todos los `ChoiceTypes`. Se puede utilizar en los casos en los que se desconozca la lista completa de `ChoiceTypes` antes del tiempo de ejecución. Además de las acciones enumeradas anteriormente para `specs`, este argumento también soporta la siguiente acción:
  - `match_catalog`: intenta convertir cada `ChoiceType` al tipo correspondiente en la tabla de Data Catalog especificada.
- `database`: la base de datos de Data Catalog que se usará con la acción `match_catalog`.
- `table_name`: la tabla de Data Catalog que se usará con la acción `match_catalog`.
- `transformation_ctx`: cadena única que se utiliza para identificar la información del estado (opcional).
- `info`: cadena que se asociará a la notificación de errores para esta transformación (opcional).

- `stageThreshold`: cantidad de errores detectados durante esta transformación que provocarán que el proceso falle (opcional). El valor predeterminado es cero, lo que indica que el proceso no debería fallar.
- `totalThreshold`: número de errores detectados hasta este proceso de transformación incluido que provocarán que el proceso se termine (opcional). Es cero de forma predeterminada, lo que indica que el proceso no debería terminarse por error.
- `catalog_id`: el ID de catálogo de Data Catalog al que se accede (el ID de cuenta de Data Catalog). Cuando se establece en `None` (valor predeterminado), utiliza el ID de catálogo de la cuenta que hace la llamada.

Ejemplo: utilice resolveChoice para gestionar una columna que contiene varios tipos

Este ejemplo de código utiliza el método `resolveChoice` para especificar cómo gestionar una columna `DynamicFrame` que contiene valores de varios tipos. El ejemplo muestra dos formas comunes de gestionar una columna con diferentes tipos:

- Convierta la columna en un solo tipo de datos.
- Conserve todos los tipos en columnas separadas.

Conjunto de datos de ejemplo

> **Note**
>
> Para acceder al conjunto de datos utilizado en este ejemplo, consulte Ejemplo de código: Preparación de datos con ResolveChoice, Lambda y ApplyMapping y siga las instrucciones en Paso 1: Rastrear los datos del bucket de Amazon S3.

El ejemplo usa un `DynamicFrame` llamado `medicare` con el siguiente esquema:

```
root
|-- drg definition: string
|-- provider id: choice
|    |-- long
|    |-- string
|-- provider name: string
|-- provider street address: string
|-- provider city: string
```

```
|-- provider state: string
|-- provider zip code: long
|-- hospital referral region description: string
|-- total discharges: long
|-- average covered charges: string
|-- average total payments: string
|-- average medicare payments: string
```

Código de ejemplo

```
# Example: Use resolveChoice to handle
# a column that contains multiple types

from pyspark.context import SparkContext
from awsglue.context import GlueContext

# Create GlueContext
sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

# Load the input data and inspect the "provider id" column
medicare = glueContext.create_dynamic_frame.from_catalog(
    database="payments", table_name="medicare_hospital_provider_csv"
)
print("Inspect the provider id column:")
medicare.toDF().select("provider id").show()

# Cast provider id to type long
medicare_resolved_long = medicare.resolveChoice(specs=[("provider id", "cast:long")])
print("Schema after casting provider id to type long:")
medicare_resolved_long.printSchema()
medicare_resolved_long.toDF().select("provider id").show()

# Create separate columns
# for each provider id type
medicare_resolved_cols = medicare.resolveChoice(choice="make_cols")
print("Schema after creating separate columns for each type:")
medicare_resolved_cols.printSchema()
medicare_resolved_cols.toDF().select("provider id_long", "provider id_string").show()
```

Output

```
Inspect the 'provider id' column:
```

```
+-----------+
|provider id|
+-----------+
|   [10001,]|
|   [10005,]|
|   [10006,]|
|   [10011,]|
|   [10016,]|
|   [10023,]|
|   [10029,]|
|   [10033,]|
|   [10039,]|
|   [10040,]|
|   [10046,]|
|   [10055,]|
|   [10056,]|
|   [10078,]|
|   [10083,]|
|   [10085,]|
|   [10090,]|
|   [10092,]|
|   [10100,]|
|   [10103,]|
+-----------+
only showing top 20 rows

Schema after casting 'provider id' to type long:
root
|-- drg definition: string
|-- provider id: long
|-- provider name: string
|-- provider street address: string
|-- provider city: string
|-- provider state: string
|-- provider zip code: long
|-- hospital referral region description: string
|-- total discharges: long
|-- average covered charges: string
|-- average total payments: string
|-- average medicare payments: string

+-----------+
|provider id|
+-----------+
```

```
|      10001|
|      10005|
|      10006|
|      10011|
|      10016|
|      10023|
|      10029|
|      10033|
|      10039|
|      10040|
|      10046|
|      10055|
|      10056|
|      10078|
|      10083|
|      10085|
|      10090|
|      10092|
|      10100|
|      10103|
+-----------+
only showing top 20 rows

Schema after creating separate columns for each type:
root
|-- drg definition: string
|-- provider id_string: string
|-- provider id_long: long
|-- provider name: string
|-- provider street address: string
|-- provider city: string
|-- provider state: string
|-- provider zip code: long
|-- hospital referral region description: string
|-- total discharges: long
|-- average covered charges: string
|-- average total payments: string
|-- average medicare payments: string

+----------------+------------------+
|provider id_long|provider id_string|
+----------------+------------------+
|           10001|              null|
|           10005|              null|
```

```
|           10006|              null|
|           10011|              null|
|           10016|              null|
|           10023|              null|
|           10029|              null|
|           10033|              null|
|           10039|              null|
|           10040|              null|
|           10046|              null|
|           10055|              null|
|           10056|              null|
|           10078|              null|
|           10083|              null|
|           10085|              null|
|           10090|              null|
|           10092|              null|
|           10100|              null|
|           10103|              null|
+----------------+------------------+
only showing top 20 rows
```

select_fields

`select_fields(paths, transformation_ctx="", info="", stageThreshold=0, totalThreshold=0)`

Devuelve un `DynamicFrame` nuevo que contiene los campos seleccionados.

- `paths`: una lista de cadenas. Cada cadena es una ruta a un nodo de nivel superior que desea seleccionar.
- `transformation_ctx`: cadena única que se utiliza para identificar la información del estado (opcional).
- `info`: cadena que se asociará a la notificación de errores para esta transformación (opcional).
- `stageThreshold`: cantidad de errores detectados durante esta transformación que provocarán que el proceso falle (opcional). El valor predeterminado es cero, lo que indica que el proceso no debería fallar.
- `totalThreshold`: cantidad de errores detectados hasta esta transformación incluida que provocarán que el proceso falle (opcional). El valor predeterminado es cero, lo que indica que el proceso no debería fallar.

Ejemplo: uso de select_fields para crear un **`DynamicFrame`** nuevo con los campos elegidos

En el siguiente ejemplo de código, se muestra cómo utilizar el método `select_fields` para crear un `DynamicFrame` nuevo con una lista seleccionada de campos de un `DynamicFrame` existente.

> **Note**
>
> Para acceder al conjunto de datos utilizado en este ejemplo, consulte Código de ejemplo: unión de los datos y establecimiento de relaciones entre ellos y siga las instrucciones en Paso 1: Rastrear los datos del bucket de Amazon S3.

```
# Example: Use select_fields to select specific fields from a DynamicFrame

from pyspark.context import SparkContext
from awsglue.context import GlueContext

# Create GlueContext
sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

# Create a DynamicFrame and view its schema
persons = glueContext.create_dynamic_frame.from_catalog(
    database="legislators", table_name="persons_json"
)
print("Schema for the persons DynamicFrame:")
persons.printSchema()

# Create a new DynamicFrame with chosen fields
names = persons.select_fields(paths=["family_name", "given_name"])
print("Schema for the names DynamicFrame, created with select_fields:")
names.printSchema()
names.toDF().show()
```

Output

```
Schema for the persons DynamicFrame:
root
|-- family_name: string
|-- name: string
|-- links: array
|    |-- element: struct
```

```
|    |    |-- note: string
|    |    |-- url: string
|-- gender: string
|-- image: string
|-- identifiers: array
|    |-- element: struct
|    |    |-- scheme: string
|    |    |-- identifier: string
|-- other_names: array
|    |-- element: struct
|    |    |-- lang: string
|    |    |-- note: string
|    |    |-- name: string
|-- sort_name: string
|-- images: array
|    |-- element: struct
|    |    |-- url: string
|-- given_name: string
|-- birth_date: string
|-- id: string
|-- contact_details: array
|    |-- element: struct
|    |    |-- type: string
|    |    |-- value: string
|-- death_date: string

Schema for the names DynamicFrame:
root
|-- family_name: string
|-- given_name: string

+-----------+----------+
|family_name|given_name|
+-----------+----------+
|    Collins|   Michael|
|   Huizenga|      Bill|
|    Clawson|    Curtis|
|    Solomon|    Gerald|
|     Rigell|    Edward|
|      Crapo|   Michael|
|      Hutto|      Earl|
|      Ertel|     Allen|
|     Minish|    Joseph|
|    Andrews|    Robert|
```

```
|     Walden|      Greg|
|      Kazen|   Abraham|
|     Turner|   Michael|
|      Kolbe|     James|
|  Lowenthal|      Alan|
|    Capuano|   Michael|
|   Schrader|      Kurt|
|     Nadler|   Jerrold|
|     Graves|       Tom|
|   McMillan|      John|
+-----------+----------+
only showing top 20 rows
```

simplify_ddb_json

`simplify_ddb_json(): DynamicFrame`

Simplifica las columnas anidadas en un `DynamicFrame` que se encuentran de manera específica en la estructura de JSON de DynamoDB y devuelve un nuevo `DynamicFrame` simplificado. Si hay varios tipos y tipos de mapas una lista de tipos, no se simplificarán los elementos de la lista. Tenga en cuenta que este es un tipo específico de transformación que se comporta de manera distinta a la transformación `unnest` regular y que necesita que los datos ya se encuentren en la estructura JSON de DynamoDB. Para obtener más información, consulte JSON de DynamoDB.

Por ejemplo, el esquema de una lectura de una exportación con la estructura JSON de DynamoDB puede parecerse al siguiente:

```
root
|-- Item: struct
|    |-- parentMap: struct
|    |    |-- M: struct
|    |    |    |-- childMap: struct
|    |    |    |    |-- M: struct
|    |    |    |    |    |-- appName: struct
|    |    |    |    |    |    |-- S: string
|    |    |    |    |    |-- packageName: struct
|    |    |    |    |    |    |-- S: string
|    |    |    |    |    |-- updatedAt: struct
|    |    |    |    |    |    |-- N: string
|    |-- strings: struct
|    |    |-- SS: array
```

```
|    |    |    |-- element: string
|    |-- numbers: struct
|    |    |-- NS: array
|    |    |    |-- element: string
|    |-- binaries: struct
|    |    |-- BS: array
|    |    |    |-- element: string
|    |-- isDDBJson: struct
|    |    |-- BOOL: boolean
|    |-- nullValue: struct
|    |    |-- NULL: boolean
```

La transformación `simplify_ddb_json()` convertiría esto en:

```
root
|-- parentMap: struct
|    |-- childMap: struct
|    |    |-- appName: string
|    |    |-- packageName: string
|    |    |-- updatedAt: string
|-- strings: array
|    |-- element: string
|-- numbers: array
|    |-- element: string
|-- binaries: array
|    |-- element: string
|-- isDDBJson: boolean
|-- nullValue: null
```

Por ejemplo: utilice simplify_ddb_json para invocar una simplificación JSON de DynamoDB.

Este ejemplo de código utiliza el método `simplify_ddb_json` para utilizar el conecto de exportación de DynamoDB de AWS Glue, invocar una simplificación JSON de DynamoDB e imprimir el número de pariciones.

Código de ejemplo

```
from pyspark.context import SparkContext
from awsglue.context import GlueContext

sc = SparkContext()
glueContext = GlueContext(sc)
```

```
dynamicFrame = glueContext.create_dynamic_frame.from_options(
    connection_type = "dynamodb",
    connection_options = {
        'dynamodb.export': 'ddb',
        'dynamodb.tableArn': '<table arn>',
        'dynamodb.s3.bucket': '<bucket name>',
        'dynamodb.s3.prefix': '<bucket prefix>',
        'dynamodb.s3.bucketOwner': '<account_id of bucket>'
    }
)
simplified = dynamicFrame.simplify_ddb_json()
print(simplified.getNumPartitions())
```

spigot

`spigot(path, options={})`

Escribe registros de ejemplo en un destino específico para ayudarlo a verificar las transformaciones realizadas por su trabajo.

- `path`: ruta del destino en el que se escribirá (obligatorio).
- `options`: pares valor-clave que especifican opciones (opcional). La opción `"topk"` especifica que deben escribirse los primeros registros k. La opción `"prob"` especifica la probabilidad de que se elija un registro determinado (como decimal). Puede usarlo para seleccionar registros para escribir.
- `transformation_ctx`: cadena única que se utiliza para identificar la información del estado (opcional).

Ejemplo: utilice spigot para escribir campos de ejemplo desde un **`DynamicFrame`** en Amazon S3

Este ejemplo de código utiliza el método `spigot` para escribir registros de ejemplo en un bucket de Amazon S3 después de aplicar la transformación `select_fields`.

Conjunto de datos de ejemplo

> **Note**
>
> Para acceder al conjunto de datos utilizado en este ejemplo, consulte Código de ejemplo: unión de los datos y establecimiento de relaciones entre ellos y siga las instrucciones en Paso 1: Rastrear los datos del bucket de Amazon S3.

El ejemplo usa un `DynamicFrame` llamado `persons` con el siguiente esquema:

```
root
|-- family_name: string
|-- name: string
|-- links: array
|    |-- element: struct
|    |    |-- note: string
|    |    |-- url: string
|-- gender: string
|-- image: string
|-- identifiers: array
|    |-- element: struct
|    |    |-- scheme: string
|    |    |-- identifier: string
|-- other_names: array
|    |-- element: struct
|    |    |-- lang: string
|    |    |-- note: string
|    |    |-- name: string
|-- sort_name: string
|-- images: array
|    |-- element: struct
|    |    |-- url: string
|-- given_name: string
|-- birth_date: string
|-- id: string
|-- contact_details: array
|    |-- element: struct
|    |    |-- type: string
|    |    |-- value: string
|-- death_date: string
```

Código de ejemplo

```
# Example: Use spigot to write sample records
# to a destination during a transformation
# from pyspark.context import SparkContext.
# Replace DOC-EXAMPLE-BUCKET with your own location.

from pyspark.context import SparkContext
from awsglue.context import GlueContext
```

```
# Create GlueContext
sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

# Load table data into a DynamicFrame
persons = glueContext.create_dynamic_frame.from_catalog(
    database="legislators", table_name="persons_json"
)

# Perform the select_fields on the DynamicFrame
persons = persons.select_fields(paths=["family_name", "given_name", "birth_date"])

# Use spigot to write a sample of the transformed data
# (the first 10 records)
spigot_output = persons.spigot(
    path="s3://DOC-EXAMPLE-BUCKET", options={"topk": 10}
)
# Example: Use spigot to write sample records
# to a destination during a transformation
# from pyspark.context import SparkContext.
# Replace DOC-EXAMPLE-BUCKET with your own location.

from pyspark.context import SparkContext
from awsglue.context import GlueContext

# Create GlueContext
sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

# Load table data into a DynamicFrame
persons = glueContext.create_dynamic_frame.from_catalog(
    database="legislators", table_name="persons_json"
)

# Perform the select_fields on the DynamicFrame
persons = persons.select_fields(paths=["family_name", "given_name", "birth_date"])

# Use spigot to write a sample of the transformed data
# (the first 10 records)
spigot_output = persons.spigot(
    path="s3://DOC-EXAMPLE-BUCKET", options={"topk": 10}
)
```

Output

A continuación, se muestra un ejemplo de los datos que `spigot` escribe en Amazon S3. Como se especifica el código de ejemplo `options={"topk": 10}`, los datos de la muestra contienen los 10 primeros registros.

```
{"family_name":"Collins","given_name":"Michael","birth_date":"1944-10-15"}
{"family_name":"Huizenga","given_name":"Bill","birth_date":"1969-01-31"}
{"family_name":"Clawson","given_name":"Curtis","birth_date":"1959-09-28"}
{"family_name":"Solomon","given_name":"Gerald","birth_date":"1930-08-14"}
{"family_name":"Rigell","given_name":"Edward","birth_date":"1960-05-28"}
{"family_name":"Crapo","given_name":"Michael","birth_date":"1951-05-20"}
{"family_name":"Hutto","given_name":"Earl","birth_date":"1926-05-12"}
{"family_name":"Ertel","given_name":"Allen","birth_date":"1937-11-07"}
{"family_name":"Minish","given_name":"Joseph","birth_date":"1916-09-01"}
{"family_name":"Andrews","given_name":"Robert","birth_date":"1957-08-04"}
```

split_fields

`split_fields(paths, name1, name2, transformation_ctx="", info="", stageThreshold=0, totalThreshold=0)`

Devuelve una nueva `DynamicFrameCollection` que contiene dos `DynamicFrames`. El primer `DynamicFrame` contiene todos los nodos que se han dividido y el segundo contiene los nodos que quedan.

- `paths` – Una lista de cadenas, cada una de las cuales es una ruta completa a un nodo que se desea dividir en un elemento nuevo `DynamicFrame`.
- `name1`: cadena de nombre para el `DynamicFrame` que se divide.
- `name2`: cadena de nombre para el elemento `DynamicFrame` que queda después de que se hayan dividido los nodos especificados.
- `transformation_ctx`: cadena única que se utiliza para identificar la información del estado (opcional).
- `info`: cadena que se asociará a la notificación de errores para esta transformación (opcional).
- `stageThreshold`: cantidad de errores detectados durante esta transformación que provocarán que el proceso falle (opcional). El valor predeterminado es cero, lo que indica que el proceso no debería fallar.

- `totalThreshold`: cantidad de errores detectados hasta esta transformación incluida que provocarán que el proceso falle (opcional). El valor predeterminado es cero, lo que indica que el proceso no debería fallar.

Ejemplo: utilice split_fields para dividir los campos seleccionados en un campo **`DynamicFrame`** independiente

Este ejemplo de código usa el método `split_fields` para dividir una lista de campos especificados en una lista `DynamicFrame` independiente.

Conjunto de datos de ejemplo

El ejemplo usa un `DynamicFrame` llamado `l_root_contact_details` que proviene de una colección denominada `legislators_relationalized`.

`l_root_contact_details` tiene el siguiente esquema y entradas.

```
root
|-- id: long
|-- index: int
|-- contact_details.val.type: string
|-- contact_details.val.value: string

+---+-----+------------------------+------------------------+
| id|index|contact_details.val.type|contact_details.val.value|
+---+-----+------------------------+------------------------+
|  1|    0|                   phone|              202-225-5265|
|  1|    1|                 twitter|               kathyhochul|
|  2|    0|                   phone|              202-225-3252|
|  2|    1|                 twitter|             repjackyrosen|
|  3|    0|                     fax|              202-225-1314|
|  3|    1|                   phone|              202-225-3772|
...
```

Código de ejemplo

```
# Example: Use split_fields to split selected
# fields into a separate DynamicFrame

from pyspark.context import SparkContext
from awsglue.context import GlueContext
```

```
# Create GlueContext
sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

# Load the input DynamicFrame and inspect its schema
frame_to_split = legislators_relationalized.select("l_root_contact_details")
print("Inspect the input DynamicFrame schema:")
frame_to_split.printSchema()

# Split id and index fields into a separate DynamicFrame
split_fields_collection = frame_to_split.split_fields(["id", "index"], "left", "right")

# Inspect the resulting DynamicFrames
print("Inspect the schemas of the DynamicFrames created with split_fields:")
split_fields_collection.select("left").printSchema()
split_fields_collection.select("right").printSchema()
```

Output

```
Inspect the input DynamicFrame's schema:
root
|-- id: long
|-- index: int
|-- contact_details.val.type: string
|-- contact_details.val.value: string

Inspect the schemas of the DynamicFrames created with split_fields:
root
|-- id: long
|-- index: int

root
|-- contact_details.val.type: string
|-- contact_details.val.value: string
```

split_rows

`split_rows(comparison_dict, name1, name2, transformation_ctx="", info="", stageThreshold=0, totalThreshold=0)`

Divide una o más filas de un `DynamicFrame` en un nuevo `DynamicFrame`.

El método devuelve un nuevo `DynamicFrameCollection` que contiene dos `DynamicFrames`. El primer `DynamicFrame` contiene todas las filas que se han dividido y el segundo contiene las filas que quedan.

- `comparison_dict`: diccionario donde la clave es una ruta a una columna y el valor es otro diccionario que mapea comparadores con valores con los que se compara el valor de columna. Por ejemplo, `{"age": {">": 10, "<": 20}}` divide todas las filas cuyo valor en la columna antigüedad sea superior a 10 e inferior a 20.
- `name1`: cadena de nombre para el `DynamicFrame` que se divide.
- `name2`: cadena de nombre para el elemento `DynamicFrame` que queda después de que se hayan dividido los nodos especificados.
- `transformation_ctx`: cadena única que se utiliza para identificar la información del estado (opcional).
- `info`: cadena que se asociará a la notificación de errores para esta transformación (opcional).
- `stageThreshold`: cantidad de errores detectados durante esta transformación que provocarán que el proceso falle (opcional). El valor predeterminado es cero, lo que indica que el proceso no debería fallar.
- `totalThreshold`: cantidad de errores detectados hasta esta transformación incluida que provocarán que el proceso falle (opcional). El valor predeterminado es cero, lo que indica que el proceso no debería fallar.

Ejemplo: utilice split_rows para dividir filas en un **`DynamicFrame`**

En este ejemplo de código se utiliza el método `split_rows` para dividir las filas en un `DynamicFrame` en función del valor del campo `id`.

Conjunto de datos de ejemplo

El ejemplo usa un `DynamicFrame` llamado `l_root_contact_details` que se selecciona de una colección denominada `legislators_relationalized`.

`l_root_contact_details` tiene el siguiente esquema y entradas.

```
root
|-- id: long
|-- index: int
|-- contact_details.val.type: string
|-- contact_details.val.value: string
```

```
+---+-----+-----------------------+-----------------------+
| id|index|contact_details.val.type|contact_details.val.value|
+---+-----+-----------------------+-----------------------+
|  1|    0|                  phone|             202-225-5265|
|  1|    1|                twitter|              kathyhochul|
|  2|    0|                  phone|             202-225-3252|
|  2|    1|                twitter|            repjackyrosen|
|  3|    0|                    fax|             202-225-1314|
|  3|    1|                  phone|             202-225-3772|
|  3|    2|                twitter|          MikeRossUpdates|
|  4|    0|                    fax|             202-225-1314|
|  4|    1|                  phone|             202-225-3772|
|  4|    2|                twitter|          MikeRossUpdates|
|  5|    0|                    fax|             202-225-1314|
|  5|    1|                  phone|             202-225-3772|
|  5|    2|                twitter|          MikeRossUpdates|
|  6|    0|                    fax|             202-225-1314|
|  6|    1|                  phone|             202-225-3772|
|  6|    2|                twitter|          MikeRossUpdates|
|  7|    0|                    fax|             202-225-1314|
|  7|    1|                  phone|             202-225-3772|
|  7|    2|                twitter|          MikeRossUpdates|
|  8|    0|                    fax|             202-225-1314|
+---+-----+-----------------------+-----------------------+
```

Código de ejemplo

```
# Example: Use split_rows to split up
# rows in a DynamicFrame based on value

from pyspark.context import SparkContext
from awsglue.context import GlueContext

# Create GlueContext
sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

# Retrieve the DynamicFrame to split
frame_to_split = legislators_relationalized.select("l_root_contact_details")

# Split up rows by ID
split_rows_collection = frame_to_split.split_rows({"id": {">": 10}}, "high", "low")
```

```
# Inspect the resulting DynamicFrames
print("Inspect the DynamicFrame that contains IDs < 10")
split_rows_collection.select("low").toDF().show()
print("Inspect the DynamicFrame that contains IDs > 10")
split_rows_collection.select("high").toDF().show()
```

Output

```
Inspect the DynamicFrame that contains IDs < 10
+---+-----+-----------------------+-----------------------+
| id|index|contact_details.val.type|contact_details.val.value|
+---+-----+-----------------------+-----------------------+
|  1|    0|                  phone|             202-225-5265|
|  1|    1|                twitter|              kathyhochul|
|  2|    0|                  phone|             202-225-3252|
|  2|    1|                twitter|            repjackyrosen|
|  3|    0|                    fax|             202-225-1314|
|  3|    1|                  phone|             202-225-3772|
|  3|    2|                twitter|          MikeRossUpdates|
|  4|    0|                    fax|             202-225-1314|
|  4|    1|                  phone|             202-225-3772|
|  4|    2|                twitter|          MikeRossUpdates|
|  5|    0|                    fax|             202-225-1314|
|  5|    1|                  phone|             202-225-3772|
|  5|    2|                twitter|          MikeRossUpdates|
|  6|    0|                    fax|             202-225-1314|
|  6|    1|                  phone|             202-225-3772|
|  6|    2|                twitter|          MikeRossUpdates|
|  7|    0|                    fax|             202-225-1314|
|  7|    1|                  phone|             202-225-3772|
|  7|    2|                twitter|          MikeRossUpdates|
|  8|    0|                    fax|             202-225-1314|
+---+-----+-----------------------+-----------------------+
only showing top 20 rows

Inspect the DynamicFrame that contains IDs > 10
+---+-----+-----------------------+-----------------------+
| id|index|contact_details.val.type|contact_details.val.value|
+---+-----+-----------------------+-----------------------+
| 11|    0|                  phone|             202-225-5476|
| 11|    1|                twitter|            RepDavidYoung|
| 12|    0|                  phone|             202-225-4035|
```

```
| 12|    1|                 twitter|           RepStephMurphy|
| 13|    0|                     fax|             202-226-0774|
| 13|    1|                   phone|             202-225-6335|
| 14|    0|                     fax|             202-226-0774|
| 14|    1|                   phone|             202-225-6335|
| 15|    0|                     fax|             202-226-0774|
| 15|    1|                   phone|             202-225-6335|
| 16|    0|                     fax|             202-226-0774|
| 16|    1|                   phone|             202-225-6335|
| 17|    0|                     fax|             202-226-0774|
| 17|    1|                   phone|             202-225-6335|
| 18|    0|                     fax|             202-226-0774|
| 18|    1|                   phone|             202-225-6335|
| 19|    0|                     fax|             202-226-0774|
| 19|    1|                   phone|             202-225-6335|
| 20|    0|                     fax|             202-226-0774|
| 20|    1|                   phone|             202-225-6335|
+---+-----+------------------------+-------------------------+
only showing top 20 rows
```

unbox

`unbox(path, format, transformation_ctx="", info="", stageThreshold=0, totalThreshold=0, **options)`

Realiza la conversión unboxing (vuelve a formatear) de un campo de cadena en un elemento `DynamicFrame` y devuelve un elemento `DynamicFrame` nuevo que contiene el elemento `DynamicRecords` de conversión unboxing.

Un `DynamicRecord` representa un registro lógico en un `DynamicFrame`. Es similar a una fila en un `DataFrame` de Apache Spark, salvo que es autodescriptivo y se puede utilizar para datos que no se ajustan a un esquema fijo.

- `path`: ruta completa al nodo de cadena a cuyo nombre se desea aplicar la conversión unboxing.
- `format`: una especificación de formato (opcional). La utiliza con una conexión de Amazon S3 o AWS Glue que admite diversos formatos. Consulte en Opciones de formato de datos para las entradas y las salidas en AWS Glue para Spark los formatos que se admiten.
- `transformation_ctx`: cadena única que se utiliza para identificar la información del estado (opcional).
- `info`: cadena que se asociará a la notificación de errores para esta transformación (opcional).

- `stageThreshold`: cantidad de errores detectados durante esta transformación que provocarán que el proceso falle (opcional). El valor predeterminado es cero, lo que indica que el proceso no debería fallar.
- `totalThreshold`: cantidad de errores detectados hasta esta transformación incluida que provocarán que el proceso falle (opcional). El valor predeterminado es cero, lo que indica que el proceso no debería fallar.
- `options`: una o varias de las siguientes:
  - `separator`: cadena que contiene el carácter separador.
  - `escaper`: cadena que contiene el carácter de escape.
  - `skipFirst`: valor booleano que indica si debe omitirse la primera instancia.
  - `withSchema`: una cadena que contiene una representación JSON del esquema del nodo. El formato de la representación JSON de un esquema se define mediante el resultado de `StructType.json()`.
  - `withHeader`: valor booleano que indica si se incluye un encabezado.

Ejemplo: utilice la conversión unboxing para convertir un campo de cadena en una estructura

Este ejemplo de código utiliza el método `unbox` para la conversión unboxing o volver a formatear un campo de cadena en un `DynamicFrame` en un campo de tipo estructura.

Conjunto de datos de ejemplo

El ejemplo usa un `DynamicFrame` llamado `mapped_with_string` con el siguiente esquema y entradas.

Observe el campo denominado `AddressString`. Este es el campo que el ejemplo convierte en una estructura.

```
root
|-- Average Total Payments: string
|-- AddressString: string
|-- Average Covered Charges: string
|-- DRG Definition: string
|-- Average Medicare Payments: string
|-- Hospital Referral Region Description: string
|-- Address: struct
|    |-- Zip.Code: string
|    |-- City: string
```

```
|    |-- Array: array
|    |    |-- element: string
|    |-- State: string
|    |-- Street: string
|-- Provider Id: string
|-- Total Discharges: string
|-- Provider Name: string

+----------------------+--------------------+----------------------
+--------------------+------------------------+-----------------------------------
+--------------------+----------+---------------+--------------------+
|Average Total Payments|       AddressString|Average Covered Charges|      DRG
 Definition|Average Medicare Payments|Hospital Referral Region Description|
 Address|Provider Id|Total Discharges|       Provider Name|
+----------------------+--------------------+----------------------
+--------------------+------------------------+-----------------------------------
+--------------------+----------+---------------+--------------------+
|              $5777.24|{"Street": "1108 ...|              $32963.07|039 -
 EXTRACRANIA...|                 $4763.73|                          AL - Dothan|[36301,
 DOTHAN, [...|      10001|              91|SOUTHEAST ALABAMA...|
|              $5787.57|{"Street": "2505 ...|              $15131.85|039 -
 EXTRACRANIA...|                 $4976.71|                      AL - Birmingham|[35957,
 BOAZ, [25...|      10005|              14|MARSHALL MEDICAL ...|
|              $5434.95|{"Street": "205 M...|              $37560.37|039 -
 EXTRACRANIA...|                 $4453.79|                      AL - Birmingham|[35631,
 FLORENCE,...|      10006|              24|ELIZA COFFEE MEMO...|
|              $5417.56|{"Street": "50 ME...|              $13998.28|039 -
 EXTRACRANIA...|                 $4129.16|                      AL - Birmingham|[35235,
 BIRMINGHA...|      10011|              25|   ST VINCENT'S EAST|
...
```

Código de ejemplo

```
# Example: Use unbox to unbox a string field
# into a struct in a DynamicFrame

from pyspark.context import SparkContext
from awsglue.context import GlueContext

# Create GlueContext
sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)
```

```
unboxed = mapped_with_string.unbox("AddressString", "json")
unboxed.printSchema()
unboxed.toDF().show()
```

Output

```
root
|-- Average Total Payments: string
|-- AddressString: struct
|    |-- Street: string
|    |-- City: string
|    |-- State: string
|    |-- Zip.Code: string
|    |-- Array: array
|    |    |-- element: string
|-- Average Covered Charges: string
|-- DRG Definition: string
|-- Average Medicare Payments: string
|-- Hospital Referral Region Description: string
|-- Address: struct
|    |-- Zip.Code: string
|    |-- City: string
|    |-- Array: array
|    |    |-- element: string
|    |-- State: string
|    |-- Street: string
|-- Provider Id: string
|-- Total Discharges: string
|-- Provider Name: string

+----------------------+--------------------+-----------------------
+--------------------+-------------------------+-----------------------------------
+--------------------+-----------+---------------+--------------------+
|Average Total Payments|       AddressString|Average Covered Charges|      DRG
 Definition|Average Medicare Payments|Hospital Referral Region Description|
 Address|Provider Id|Total Discharges|       Provider Name|
+----------------------+--------------------+-----------------------
+--------------------+-------------------------+-----------------------------------
+--------------------+-----------+---------------+--------------------+
|              $5777.24|[1108 ROSS CLARK ...|             $32963.07|039 -
 EXTRACRANIA...|                $4763.73|                        AL - Dothan|[36301,
 DOTHAN, [...|      10001|              91|SOUTHEAST ALABAMA...|
```

```
|              $5787.57|[2505 U S HIGHWAY...|              $15131.85|039 -
 EXTRACRANIA...|                $4976.71|                    AL - Birmingham|[35957,
 BOAZ, [25...|      10005|              14|MARSHALL MEDICAL ...|
|              $5434.95|[205 MARENGO STRE...|              $37560.37|039 -
 EXTRACRANIA...|                $4453.79|                    AL - Birmingham|[35631,
 FLORENCE,...|      10006|              24|ELIZA COFFEE MEMO...|
|              $5417.56|[50 MEDICAL PARK ...|              $13998.28|039 -
 EXTRACRANIA...|                $4129.16|                    AL - Birmingham|[35235,
 BIRMINGHA...|      10011|              25|   ST VINCENT'S EAST|
|              $5658.33|[1000 FIRST STREE...|              $31633.27|039 -
 EXTRACRANIA...|                $4851.44|                    AL - Birmingham|[35007,
 ALABASTER...|      10016|              18|SHELBY BAPTIST ME...|
|              $6653.80|[2105 EAST SOUTH ...|              $16920.79|039 -
 EXTRACRANIA...|                $5374.14|                    AL - Montgomery|[36116,
 MONTGOMER...|      10023|              67|BAPTIST MEDICAL C...|
|              $5834.74|[2000 PEPPERELL P...|              $11977.13|039 -
 EXTRACRANIA...|                $4761.41|                    AL - Birmingham|[36801,
 OPELIKA, ...|      10029|              51|EAST ALABAMA MEDI...|
|              $8031.12|[619 SOUTH 19TH S...|              $35841.09|039 -
 EXTRACRANIA...|                $5858.50|                    AL - Birmingham|[35233,
 BIRMINGHA...|      10033|              32|UNIVERSITY OF ALA...|
|              $6113.38|[101 SIVLEY RD, H...|              $28523.39|039 -
 EXTRACRANIA...|                $5228.40|                    AL - Huntsville|[35801,
 HUNTSVILL...|      10039|             135| HUNTSVILLE HOSPITAL|
|              $5541.05|[1007 GOODYEAR AV...|              $75233.38|039 -
 EXTRACRANIA...|                $4386.94|                    AL - Birmingham|[35903,
 GADSDEN, ...|      10040|              34|GADSDEN REGIONAL ...|
|              $5461.57|[600 SOUTH THIRD ...|              $67327.92|039 -
 EXTRACRANIA...|                $4493.57|                    AL - Birmingham|[35901,
 GADSDEN, ...|      10046|              14|RIVERVIEW REGIONA...|
|              $5356.28|[4370 WEST MAIN S...|              $39607.28|039 -
 EXTRACRANIA...|                $4408.20|                        AL - Dothan|[36305,
 DOTHAN, [...|      10055|              45|    FLOWERS HOSPITAL|
|              $5374.65|[810 ST VINCENT'S...|              $22862.23|039 -
 EXTRACRANIA...|                $4186.02|                    AL - Birmingham|[35205,
 BIRMINGHA...|      10056|              43|ST VINCENT'S BIRM...|
|              $5366.23|[400 EAST 10TH ST...|              $31110.85|039 -
 EXTRACRANIA...|                $4376.23|                    AL - Birmingham|[36207,
 ANNISTON,...|      10078|              21|NORTHEAST ALABAMA...|
|              $5282.93|[1613 NORTH MCKEN...|              $25411.33|039 -
 EXTRACRANIA...|                $4383.73|                        AL - Mobile|[36535,
 FOLEY, [1...|      10083|              15|SOUTH BALDWIN REG...|
```

```
|              $5676.55|[1201 7TH STREET ...|               $9234.51|039 -
 EXTRACRANIA...|                $4509.11|                   AL - Huntsville|[35609,
 DECATUR, ...|      10085|              27|DECATUR GENERAL H...|
|              $5930.11|[6801 AIRPORT BOU...|              $15895.85|039 -
 EXTRACRANIA...|                $3972.85|                       AL - Mobile|[36608,
 MOBILE, [...|      10090|              27| PROVIDENCE HOSPITAL|
|              $6192.54|[809 UNIVERSITY B...|              $19721.16|039 -
 EXTRACRANIA...|                $5179.38|                   AL - Tuscaloosa|[35401,
 TUSCALOOS...|      10092|              31|D C H REGIONAL ME...|
|              $4968.00|[750 MORPHY AVENU...|              $10710.88|039 -
 EXTRACRANIA...|                $3898.88|                       AL - Mobile|[36532,
 FAIRHOPE,...|      10100|              18|     THOMAS HOSPITAL|
|              $5996.00|[701 PRINCETON AV...|              $51343.75|039 -
 EXTRACRANIA...|                $4962.45|                   AL - Birmingham|[35211,
 BIRMINGHA...|      10103|              33|BAPTIST MEDICAL C...|
+----------------------+--------------------+----------------------
+--------------------+------------------------+-----------------------------------
+--------------------+----------+---------------+--------------------+
only showing top 20 rows
```

unión

union(frame1, frame2, transformation_ctx = "", info = "", stageThreshold = 0, totalThreshold = 0)

Unir dos DynamicFrames. Devuelve un DynamicFrame que contiene todos los registros de ambos DynamicFrames de entrada. Esta transformación puede devolver resultados diferentes de la unión de dos DataFrames con datos equivalentes. Si necesita el comportamiento de unión del DataFrame de Spark, considere usar `toDF`.

- `frame1`: primer DynamicFrame en unirse.
- `frame2`: segundo DynamicFrame en unirse.
- `transformation_ctx`: (opcional) una cadena única que se utiliza para identificar información de estadísticas/estado
- `info`: (opcional) una cadena que está asociada a errores en la transformación
- `stageThreshold`: (opcional) un número máximo de errores en la transformación hasta que se produzca un error en el procesamiento
- `totalThreshold`: (opcional) un número máximo de errores en total hasta que se produzca un error en el procesamiento.

unnest

`unnest(transformation_ctx="", info="", stageThreshold=0, totalThreshold=0)`

Desanida los objetos anidados de un elemento `DynamicFrame`, que los convierte en objetos de nivel superior y devuelve un elemento `DynamicFrame` desanidado nuevo.

- `transformation_ctx`: cadena única que se utiliza para identificar la información del estado (opcional).
- `info`: cadena que se asociará a la notificación de errores para esta transformación (opcional).
- `stageThreshold`: cantidad de errores detectados durante esta transformación que provocarán que el proceso falle (opcional). El valor predeterminado es cero, lo que indica que el proceso no debería fallar.
- `totalThreshold`: cantidad de errores detectados hasta esta transformación incluida que provocarán que el proceso falle (opcional). El valor predeterminado es cero, lo que indica que el proceso no debería fallar.

Ejemplo: utilice desanidar para convertir los campos anidados en campos de nivel superior

Este ejemplo de código utiliza el método `unnest` para desanidar todos los campos anidados en un `DynamicFrame` en campos de nivel superior.

Conjunto de datos de ejemplo

El ejemplo usa un `DynamicFrame` llamado `mapped_medicare` con el siguiente esquema. Observe que el campo `Address` es el único campo que contiene datos anidados.

```
root
|-- Average Total Payments: string
|-- Average Covered Charges: string
|-- DRG Definition: string
|-- Average Medicare Payments: string
|-- Hospital Referral Region Description: string
|-- Address: struct
|    |-- Zip.Code: string
|    |-- City: string
|    |-- Array: array
|    |    |-- element: string
|    |-- State: string
|    |-- Street: string
|-- Provider Id: string
```

```
|-- Total Discharges: string
|-- Provider Name: string
```

Código de ejemplo

```
# Example: Use unnest to unnest nested
# objects in a DynamicFrame

from pyspark.context import SparkContext
from awsglue.context import GlueContext

# Create GlueContext
sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

# Unnest all nested fields
unnested = mapped_medicare.unnest()
unnested.printSchema()
```

Output

```
root
|-- Average Total Payments: string
|-- Average Covered Charges: string
|-- DRG Definition: string
|-- Average Medicare Payments: string
|-- Hospital Referral Region Description: string
|-- Address.Zip.Code: string
|-- Address.City: string
|-- Address.Array: array
|    |-- element: string
|-- Address.State: string
|-- Address.Street: string
|-- Provider Id: string
|-- Total Discharges: string
|-- Provider Name: string
```

unnest_ddb_json

Desanida las columnas anidadas de un elemento `DynamicFrame` que se encuentren específicamente en la estructura JSON de DynamoDB y devuelve un nuevo elemento

DynamicFrame no anidado. Las columnas que sean de una matriz de tipos de estructuras no se desanidarán. Tenga en cuenta que esta transformación de desanidamiento es un tipo específico que se comporta de modo diferente a la transformación unnest normal y requiere que los datos ya estén en la estructura JSON de DynamoDB. Para obtener más información, consulte JSON de DynamoDB.

unnest_ddb_json(transformation_ctx="", info="", stageThreshold=0, totalThreshold=0)

- transformation_ctx: cadena única que se utiliza para identificar la información del estado (opcional).
- info: cadena que se asociará a la notificación de errores para esta transformación (opcional).
- stageThreshold: número de errores detectados durante este proceso de transformación que provocarán que el proceso se termine (opcional: cero de forma predeterminada, lo que indica que el proceso no debería terminarse por error).
- totalThreshold: número de errores detectados hasta este proceso de transformación incluido que provocarán que el proceso se termine (opcional: cero de forma predeterminada, lo que indica que el proceso no debería terminarse por error).

Por ejemplo, el esquema de una lectura de una exportación con la estructura JSON de DynamoDB puede parecerse al siguiente:

```
root
|-- Item: struct
|    |-- ColA: struct
|    |    |-- S: string
|    |-- ColB: struct
|    |    |-- S: string
|    |-- ColC: struct
|    |    |-- N: string
|    |-- ColD: struct
|    |    |-- L: array
|    |    |    |-- element: null
```

La transformación unnest_ddb_json( ) convertiría esto en:

```
root
|-- ColA: string
|-- ColB: string
```

```
|-- ColC: string
|-- ColD: array
|    |-- element: null
```

En el siguiente ejemplo de código, se muestra cómo utilizar el conector de exportación de DynamoDB de AWS Glue, invocar un desanidamiento JSON de DynamoDB e imprimir el número de particiones:

```
import sys
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job
from awsglue.utils import getResolvedOptions

args = getResolvedOptions(sys.argv, ["JOB_NAME"])
glue_context= GlueContext(SparkContext.getOrCreate())
job = Job(glue_context)
job.init(args["JOB_NAME"], args)

dynamicFrame = glue_context.create_dynamic_frame.from_options(
    connection_type="dynamodb",
    connection_options={
        "dynamodb.export": "ddb",
        "dynamodb.tableArn": "<test_source>",
        "dynamodb.s3.bucket": "<bucket name>",
        "dynamodb.s3.prefix": "<bucket prefix>",
        "dynamodb.s3.bucketOwner": "<account_id>",
    }
)
unnested = dynamicFrame.unnest_ddb_json()
print(unnested.getNumPartitions())

job.commit()
```

write

`write(connection_type, connection_options, format, format_options, accumulator_size)`

Obtiene un DataSink(object) del tipo de conexión especificado del Clase GlueContext de este elemento `DynamicFrame` y lo utiliza para escribir y dar formato al contenido de este `DynamicFrame`. Devuelve el nuevo `DynamicFrame` con formato y escrito tal y como se especifica.

- `connection_type`: tipo de conexión que se utilizará. Entre los valores válidos se incluyen: `s3`, `mysql`, `postgresql`, `redshift`, `sqlserver` y `oracle`.
- `connection_options`: opción de conexión que se utilizará (opcional). Para un `connection_type` de `s3`, se define una ruta de Amazon S3.

```
connection_options = {"path": "s3://aws-glue-target/temp"}
```

Para conexiones JDBC, deben definirse varias propiedades. Tenga en cuenta que el nombre de la base de datos debe ser parte de la URL. Opcionalmente, se puede incluir en las opciones de conexión.

> **Warning**
>
> No se recomienda almacenar las contraseñas en el script. Considere utilizar `boto3` para recuperarlas de AWS Secrets Manager o del catálogo de datos de Glue AWS.

```
connection_options = {"url": "jdbc-url/database", "user": "username",
 "password": passwordVariable,"dbtable": "table-name", "redshiftTmpDir": "s3-tempdir-
path"}
```

- `format`: una especificación de formato (opcional). Se utiliza para Amazon Simple Storage Service (Amazon S3) o una conexión de AWS Glue que admite diversos formatos. Consulte en Opciones de formato de datos para las entradas y las salidas en AWS Glue para Spark los formatos que se admiten.
- `format_options`: opciones del formato especificado. Consulte en Opciones de formato de datos para las entradas y las salidas en AWS Glue para Spark los formatos que se admiten.
- `accumulator_size`: el tamaño acumulable que se utilizará, en bytes (opcional).

— errores —

- assertErrorThreshold
- errorsAsDynamicFrame
- errorsCount
- stageErrorsCount

assertErrorThreshold

`assertErrorThreshold( )` – confirmación utilizada para los errores de las transformaciones que crearon este elemento `DynamicFrame`. Muestra un valor de `Exception` desde el `DataFrame` subyacente.

errorsAsDynamicFrame

`errorsAsDynamicFrame( )`: devuelve un `DynamicFrame` con registros de error anidados dentro.

Ejemplo: uso de errorsAsDynamicFrame para ver los registros de errores

En el siguiente ejemplo de código se muestra cómo utilizar el método `errorsAsDynamicFrame` para ver un registro de error de un `DynamicFrame`.

Conjunto de datos de ejemplo

El ejemplo utiliza el siguiente conjunto de datos que se puede cargar en Amazon S3 como JSON. Tenga en cuenta que el segundo registro tiene un formato incorrecto. Los datos con formato incorrecto generalmente interrumpen el análisis de archivos cuando se utiliza SparkSQL. Sin embargo, `DynamicFrame` reconoce los problemas de formato incorrecto y convierte las líneas con formato incorrecto en registros de errores que se pueden gestionar de forma individual.

```
{"id": 1, "name": "george", "surname": "washington", "height": 178}
{"id": 2, "name": "benjamin", "surname": "franklin",
{"id": 3, "name": "alexander", "surname": "hamilton", "height": 171}
{"id": 4, "name": "john", "surname": "jay", "height": 190}
```

Código de ejemplo

```
# Example: Use errorsAsDynamicFrame to view error records.
# Replace s3://DOC-EXAMPLE-S3-BUCKET/error_data.json with your location.

from pyspark.context import SparkContext
from awsglue.context import GlueContext

# Create GlueContext
sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

# Create errors DynamicFrame, view schema
errors = glueContext.create_dynamic_frame.from_options(
```

```
    "s3", {"paths": ["s3://DOC-EXAMPLE-S3-BUCKET/error_data.json"]}, "json"
)
print("Schema of errors DynamicFrame:")
errors.printSchema()

# Show that errors only contains valid entries from the dataset
print("errors contains only valid records from the input dataset (2 of 4 records)")
errors.toDF().show()

# View errors
print("Errors count:", str(errors.errorsCount()))
print("Errors:")
errors.errorsAsDynamicFrame().toDF().show()

# View error fields and error data
error_record = errors.errorsAsDynamicFrame().toDF().head()

error_fields = error_record["error"]
print("Error fields: ")
print(error_fields.asDict().keys())

print("\nError record data:")
for key in error_fields.asDict().keys():
    print("\n", key, ": ", str(error_fields[key]))
```

Output

```
Schema of errors DynamicFrame:
root
|-- id: int
|-- name: string
|-- surname: string
|-- height: int

errors contains only valid records from the input dataset (2 of 4 records)
+---+------+----------+------+
| id|  name|   surname|height|
+---+------+----------+------+
|  1|george|washington|   178|
|  4|  john|       jay|   190|
+---+------+----------+------+

Errors count: 1
```

```
Errors:
+--------------------+
|               error|
+--------------------+
|[[  File "/tmp/20...|
+--------------------+

Error fields:
dict_keys(['callsite', 'msg', 'stackTrace', 'input', 'bytesread', 'source',
 'dynamicRecord'])

Error record data:

 callsite :  Row(site='  File "/tmp/2060612586885849088", line 549, in <module>\n
 sys.exit(main())\n  File "/tmp/2060612586885849088", line 523, in main\n    response
 = handler(content)\n  File "/tmp/2060612586885849088", line 197, in execute_request
\n    result = node.execute()\n  File "/tmp/2060612586885849088", line 103, in
 execute\n    exec(code, global_dict)\n  File "<stdin>", line 10, in <module>\n
 File "/opt/amazon/lib/python3.6/site-packages/awsglue/dynamicframe.py", line 625, in
 from_options\n    format_options, transformation_ctx, push_down_predicate, **kwargs)\n
  File "/opt/amazon/lib/python3.6/site-packages/awsglue/context.py", line 233, in
 create_dynamic_frame_from_options\n    source.setFormat(format, **format_options)\n',
 info='')

 msg :  error in jackson reader

 stackTrace :  com.fasterxml.jackson.core.JsonParseException: Unexpected character
 ('{' (code 123)): was expecting either valid name character (for unquoted name) or
 double-quote (for quoted) to start field name
 at [Source: com.amazonaws.services.glue.readers.BufferedStream@73492578; line: 3,
 column: 2]
 at com.fasterxml.jackson.core.JsonParser._constructError(JsonParser.java:1581)
 at
 com.fasterxml.jackson.core.base.ParserMinimalBase._reportError(ParserMinimalBase.java:533)
 at
 com.fasterxml.jackson.core.base.ParserMinimalBase._reportUnexpectedChar(ParserMinimalBase.java
 at
 com.fasterxml.jackson.core.json.UTF8StreamJsonParser._handleOddName(UTF8StreamJsonParser.java:
 at
 com.fasterxml.jackson.core.json.UTF8StreamJsonParser._parseName(UTF8StreamJsonParser.java:1650
 at
 com.fasterxml.jackson.core.json.UTF8StreamJsonParser.nextToken(UTF8StreamJsonParser.java:740)
 at com.amazonaws.services.glue.readers.JacksonReader$$anonfun$hasNextGoodToken
$1.apply(JacksonReader.scala:57)
```

```
 at com.amazonaws.services.glue.readers.JacksonReader$$anonfun$hasNextGoodToken
$1.apply(JacksonReader.scala:57)
 at scala.collection.Iterator$$anon$9.next(Iterator.scala:162)
 at scala.collection.Iterator$$anon$16.hasNext(Iterator.scala:599)
 at scala.collection.Iterator$$anon$16.hasNext(Iterator.scala:598)
 at scala.collection.Iterator$class.foreach(Iterator.scala:891)
 at scala.collection.AbstractIterator.foreach(Iterator.scala:1334)
 at com.amazonaws.services.glue.readers.JacksonReader$$anonfun
$1.apply(JacksonReader.scala:120)
 at com.amazonaws.services.glue.readers.JacksonReader$$anonfun
$1.apply(JacksonReader.scala:116)
 at
 com.amazonaws.services.glue.DynamicRecordBuilder.handleErr(DynamicRecordBuilder.scala:209)
 at
 com.amazonaws.services.glue.DynamicRecordBuilder.handleErrorWithException(DynamicRecordBuilder
 at
 com.amazonaws.services.glue.readers.JacksonReader.nextFailSafe(JacksonReader.scala:116)
 at com.amazonaws.services.glue.readers.JacksonReader.next(JacksonReader.scala:109)
 at com.amazonaws.services.glue.readers.JSONReader.next(JSONReader.scala:247)
 at
 com.amazonaws.services.glue.hadoop.TapeHadoopRecordReaderSplittable.nextKeyValue(TapeHadoopRec
 at org.apache.spark.rdd.NewHadoopRDD$$anon$1.hasNext(NewHadoopRDD.scala:230)
 at org.apache.spark.InterruptibleIterator.hasNext(InterruptibleIterator.scala:37)
 at scala.collection.Iterator$$anon$11.hasNext(Iterator.scala:409)
 at scala.collection.Iterator$$anon$11.hasNext(Iterator.scala:409)
 at scala.collection.Iterator$$anon$13.hasNext(Iterator.scala:462)
 at scala.collection.Iterator$$anon$11.hasNext(Iterator.scala:409)
 at scala.collection.Iterator$$anon$11.hasNext(Iterator.scala:409)
 at scala.collection.Iterator$$anon$13.hasNext(Iterator.scala:462)
 at scala.collection.Iterator$$anon$11.hasNext(Iterator.scala:409)
 at scala.collection.Iterator$$anon$11.hasNext(Iterator.scala:409)
 at org.apache.spark.sql.execution.SparkPlan$$anonfun$2.apply(SparkPlan.scala:255)
 at org.apache.spark.sql.execution.SparkPlan$$anonfun$2.apply(SparkPlan.scala:247)
 at org.apache.spark.rdd.RDD$$anonfun$mapPartitionsInternal$1$$anonfun$apply
$24.apply(RDD.scala:836)
 at org.apache.spark.rdd.RDD$$anonfun$mapPartitionsInternal$1$$anonfun$apply
$24.apply(RDD.scala:836)
 at org.apache.spark.rdd.MapPartitionsRDD.compute(MapPartitionsRDD.scala:52)
 at org.apache.spark.rdd.RDD.computeOrReadCheckpoint(RDD.scala:324)
 at org.apache.spark.rdd.RDD.iterator(RDD.scala:288)
 at org.apache.spark.rdd.MapPartitionsRDD.compute(MapPartitionsRDD.scala:52)
 at org.apache.spark.rdd.RDD.computeOrReadCheckpoint(RDD.scala:324)
 at org.apache.spark.rdd.RDD.iterator(RDD.scala:288)
 at org.apache.spark.scheduler.ResultTask.runTask(ResultTask.scala:90)
```

```
 at org.apache.spark.scheduler.Task.run(Task.scala:121)
 at org.apache.spark.executor.Executor$TaskRunner$$anonfun$10.apply(Executor.scala:408)
 at org.apache.spark.util.Utils$.tryWithSafeFinally(Utils.scala:1360)
 at org.apache.spark.executor.Executor$TaskRunner.run(Executor.scala:414)
 at java.util.concurrent.ThreadPoolExecutor.runWorker(ThreadPoolExecutor.java:1149)
 at java.util.concurrent.ThreadPoolExecutor$Worker.run(ThreadPoolExecutor.java:624)
 at java.lang.Thread.run(Thread.java:750)


 input :

 bytesread :  252

 source :

 dynamicRecord :  Row(id=2, name='benjamin', surname='franklin')
```

Ejemplos de DynamicFrame completos

Los siguientes ejemplos muestran varias formas de crear y trabajar con DynamicFrames más allá de los escenarios básicos del catálogo de Glue.

Carga desde PostgreSQL con una consulta SQL SELECT

En este ejemplo, se muestra cómo cargar datos de una base de datos de PostgreSQL mediante una consulta SQL SELECT personalizada:

```
from awsglue.context import GlueContext
from pyspark.context import SparkContext

sc = SparkContext()
glueContext = GlueContext(sc)

# Load specific data from PostgreSQL with custom query
postgres_dyf = glueContext.create_dynamic_frame.from_options(
    connection_type="postgresql",
    connection_options={
        "url": "jdbc:postgresql://your-postgres-host:5432/your-database",
        "user": "your-username",
        "password": "your-password",
        "dbtable": "(SELECT customer_id, customer_name, email FROM customers WHERE
 active = true) AS filtered_customers"
```

```
    }
)
```

Carga de columnas específicas para evitar escanear tablas completas

En este ejemplo se muestra cómo cargar solo columnas específicas de una tabla de base de datos grande:

```
from awsglue.context import GlueContext
from pyspark.context import SparkContext

sc = SparkContext()
glueContext = GlueContext(sc)

# Load only specific columns from a large table
selected_columns_dyf = glueContext.create_dynamic_frame.from_options(
    connection_type="mysql",
    connection_options={
        "url": "jdbc:mysql://your-mysql-host:3306/your-database",
        "user": "your-username",
        "password": "your-password",
        "dbtable": "(SELECT order_id, customer_id FROM large_orders_table) AS
 selected_data"
    }
)

# Alternative approach using column selection in query
efficient_load_dyf = glueContext.create_dynamic_frame.from_options(
    connection_type="postgresql",
    connection_options={
        "url": "jdbc:postgresql://your-postgres-host:5432/your-database",
        "user": "your-username",
        "password": "your-password",
        "query": "SELECT product_id, product_name FROM products WHERE category =
 'electronics'"
    }
)
```

Filtrado a nivel de fila mediante conexiones JDBC

En este ejemplo se muestra cómo utilizar el filtrado a nivel de fila para cargar solo filas específicas de una tabla de base de datos:

```
from awsglue.context import GlueContext
from pyspark.context import SparkContext

sc = SparkContext()
glueContext = GlueContext(sc)

# Load filtered rows using WHERE clause
filtered_rows_dyf = glueContext.create_dynamic_frame.from_options(
    connection_type="postgresql",
    connection_options={
        "url": "jdbc:postgresql://your-postgres-host:5432/your-database",
        "user": "your-username",
        "password": "your-password",
        "dbtable": "(SELECT * FROM transactions WHERE transaction_date >= '2024-01-01'
 AND amount > 100) AS recent_large_transactions"
    }
)

# Using partitionColumn for parallel loading with filtering
partitioned_load_dyf = glueContext.create_dynamic_frame.from_options(
    connection_type="mysql",
    connection_options={
        "url": "jdbc:mysql://your-mysql-host:3306/your-database",
        "user": "your-username",
        "password": "your-password",
        "dbtable": "sales_data",
        "partitionColumn": "sale_date",
        "lowerBound": "2024-01-01",
        "upperBound": "2024-12-31",
        "numPartitions": "10"
    }
)
```

Creación de un DynamicFrame a partir de datos de Python en memoria

En este ejemplo se muestra cómo crear un DynamicFrame a partir de listas, tuplas o diccionarios de Python:

```
from awsglue.context import GlueContext
from awsglue.dynamicframe import DynamicFrame
from pyspark.context import SparkContext
from pyspark.sql import Row
```

```
sc = SparkContext()
glueContext = GlueContext(sc)

# Method 1: From list of tuples
data_tuples = [
    ("John", "Doe", 30, "Engineer"),
    ("Jane", "Smith", 25, "Designer"),
    ("Bob", "Johnson", 35, "Manager")
]

# Convert to RDD of Rows
rdd = sc.parallelize([Row(first_name=row[0], last_name=row[1], age=row[2], job=row[3])
 for row in data_tuples])
df = glueContext.spark_session.createDataFrame(rdd)
dyf_from_tuples = DynamicFrame.fromDF(df, glueContext, "employees_from_tuples")

# Method 2: From list of dictionaries
data_dicts = [
    {"product_id": 1, "product_name": "Laptop", "price": 999.99, "category":
 "Electronics"},
    {"product_id": 2, "product_name": "Book", "price": 19.99, "category": "Education"},
    {"product_id": 3, "product_name": "Chair", "price": 149.99, "category":
 "Furniture"}
]

df_from_dicts = glueContext.spark_session.createDataFrame(data_dicts)
dyf_from_dicts = DynamicFrame.fromDF(df_from_dicts, glueContext, "products_from_dicts")

# Method 3: From nested data structures
nested_data = [
    {
        "customer_id": 1,
        "customer_info": {
            "name": "Alice Brown",
            "email": "alice@example.com"
        },
        "orders": [
            {"order_id": 101, "amount": 250.00},
            {"order_id": 102, "amount": 175.50}
        ]
    }
]

df_nested = glueContext.spark_session.createDataFrame(nested_data)
```

```
dyf_nested = DynamicFrame.fromDF(df_nested, glueContext, "customers_with_orders")
```

Optimización de rendimiento para conjuntos de datos grandes

Cuando trabaje con conjuntos de datos grandes, tenga en cuenta estas técnicas de optimización del rendimiento:

```
# Use partitioning for parallel reads
large_table_dyf = glueContext.create_dynamic_frame.from_options(
    connection_type="postgresql",
    connection_options={
        "url": "jdbc:postgresql://your-postgres-host:5432/your-database",
        "user": "your-username",
        "password": "your-password",
        "dbtable": "large_table",
        "partitionColumn": "id",
        "lowerBound": "1",
        "upperBound": "1000000",
        "numPartitions": "20"
    }
)

# Use pushdown predicates to filter at source
filtered_dyf = glueContext.create_dynamic_frame.from_options(
    connection_type="mysql",
    connection_options={
        "url": "jdbc:mysql://your-mysql-host:3306/your-database",
        "user": "your-username",
        "password": "your-password",
        "dbtable": "transactions"
    },
    push_down_predicate="transaction_date >= '2024-01-01'"
)
```

errorsCount

`errorsCount( )` – Devuelve el número total de errores de un `DynamicFrame`.

stageErrorsCount

`stageErrorsCount` – Devuelve el número de errores que se produjo en el proceso de generar este `DynamicFrame`.

Clase DynamicFrameCollection

Un elemento `DynamicFrameCollection` es un diccionario de objetos Clase DynamicFrame, en el que las claves son los nombres de los elementos `DynamicFrames` y los valores son los objetos `DynamicFrame`.

__init__

`__init__(dynamic_frames, glue_ctx)`

- `dynamic_frames`: diccionario de objetos Clase DynamicFrame.
- `glue_ctx`: un objeto Clase GlueContext.

Claves

`keys( )`: devuelve una lista de las claves de esta colección, que generalmente se compone de los nombres de los valores de `DynamicFrame` correspondientes.

Valores

`values(key)`: devuelve una lista de los valores de `DynamicFrame` en esta colección.

Seleccionar

`select(key)`

Devuelve el `DynamicFrame` correspondiente a la clave especificada (que, por lo general, es el nombre del elemento `DynamicFrame`).

- `key`: clave del elemento `DynamicFrameCollection` que normalmente representa el nombre de un elemento `DynamicFrame`.

Asignación

`map(callable, transformation_ctx="")`

Utiliza una función que se le ha pasado para crear y devolver un elemento `DynamicFrameCollection` nuevo basado en el elemento `DynamicFrames` de esta colección.

- `callable`: función que toma un elemento `DynamicFrame` y el contexto de transformación especificado como parámetros y devuelve un elemento `DynamicFrame`.

- `transformation_ctx`: contexto de transformación que callable utilizará (opcional).

Flatmap

`flatmap(f, transformation_ctx="")`

Utiliza una función que se le ha pasado para crear y devolver un elemento `DynamicFrameCollection` nuevo basado en el elemento `DynamicFrames` de esta colección.

- `f`: función que toma un elemento `DynamicFrame` como parámetro y devuelve un elemento `DynamicFrame` o `DynamicFrameCollection`.
- `transformation_ctx`: contexto de transformación que la función utilizará (opcional).

Clase DynamicFrameWriter

Métodos

- __init__
- from_options
- from_catalog
- from_jdbc_conf

__init__

`__init__(glue_context)`

- `glue_context`: el Clase GlueContext que se va a utilizar.

from_options

`from_options(frame, connection_type, connection_options={}, format=None, format_options={}, transformation_ctx="")`

Escribe un `DynamicFrame` con la conexión y el formato especificados.

- `frame`: el `DynamicFrame` que se va a escribir.

- `connection_type`: el tipo de conexión. Entre los valores válidos se incluyen: `s3`, `mysql`, `postgresql`, `redshift`, `sqlserver` y `oracle`.
- `connection_options`: opciones de conexión, como la tabla de rutas y bases de datos (opcional). Para un `connection_type` de `s3`, se define una ruta de Amazon S3.

```
connection_options = {"path": "s3://aws-glue-target/temp"}
```

Para conexiones JDBC, deben definirse varias propiedades. Tenga en cuenta que el nombre de la base de datos debe ser parte de la URL. Opcionalmente, se puede incluir en las opciones de conexión.

> **Warning**
>
> No se recomienda almacenar las contraseñas en el script. Considere utilizar `boto3` para recuperarlas de AWS Secrets Manager o del catálogo de datos de Glue AWS.

```
connection_options = {"url": "jdbc-url/database", "user": "username",
 "password": passwordVariable,"dbtable": "table-name", "redshiftTmpDir": "s3-tempdir-
path"}
```

La propiedad `dbtable` es el nombre de la tabla de JDBC. Para almacenes de datos de JDBC que admiten esquemas dentro de una base de datos, especifique `schema.table-name`. Si no se ha proporcionado un esquema, se usa el esquema “public” predeterminado.

Para obtener más información, consulte Tipos de conexión y opciones para ETL en AWS Glue para Spark.

- `format`: una especificación de formato (opcional). Se utiliza para Amazon Simple Storage Service (Amazon S3) o una conexión de AWS Glue que admite diversos formatos. Consulte en Opciones de formato de datos para las entradas y las salidas en AWS Glue para Spark los formatos que se admiten.
- `format_options`: opciones del formato especificado. Consulte en Opciones de formato de datos para las entradas y las salidas en AWS Glue para Spark los formatos que se admiten.
- `transformation_ctx`: contexto de transformación que se va a utilizar (opcional).

from_catalog

`from_catalog(frame, name_space, table_name, redshift_tmp_dir="", transformation_ctx="")`

Escribe y devuelve un `DynamicFrame` con la base de datos de catálogos especificada y un nombre de tabla.

- `frame`: el `DynamicFrame` que se va a escribir.
- `name_space`: la base de datos que se va a utilizar.
- `table_name`: el `table_name` que se va a utilizar.
- `redshift_tmp_dir`: directorio provisional de Amazon Redshift que se va a utilizar (opcional).
- `transformation_ctx`: contexto de transformación que se va a utilizar (opcional).
- `additional_options`: opciones adicionales para AWS Glue.

  Para escribir en tablas que se rigen por Lake Formation, puede utilizar estas opciones adicionales:

  - `transactionId` (cadena): ID de transacción en el que se debe escribir en la tabla regida. Esta transacción no se puede confirmar ni anular, de lo contrario, se producirán errores en la escritura.
  - `callDeleteObjectsOnCancel` (booleano, opcional): si se configura en `true` (el valor predeterminado), AWS Glue llama automáticamente a la API `DeleteObjectsOnCancel` después de escribir el objeto en Amazon S3. Para obtener más información, consulte DeleteObjectsOnCancel en la Guía para desarrolladores de AWS Lake Formation.

  Example Ejemplo: Escribir en una tabla regida en Lake Formation

```
txId = glueContext.start_transaction(read_only=False)
glueContext.write_dynamic_frame.from_catalog(
    frame=dyf,
    database = db,
    table_name = tbl,
    transformation_ctx = "datasource0",
    additional_options={"transactionId":txId})
...
glueContext.commit_transaction(txId)
```

from_jdbc_conf

`from_jdbc_conf(frame, catalog_connection, connection_options={}, redshift_tmp_dir = "", transformation_ctx="")`

Escribe un `DynamicFrame` mediante la información de la conexión de JDBC especificada.

- `frame`: el `DynamicFrame` que se va a escribir.
- `catalog_connection`: conexión al catálogo que se va a utilizar.
- `connection_options`: opciones de conexión, como la tabla de rutas y bases de datos (opcional).
- `redshift_tmp_dir`: directorio provisional de Amazon Redshift que se va a utilizar (opcional).
- `transformation_ctx`: contexto de transformación que se va a utilizar (opcional).

Ejemplo de write_dynamic_frame

En este ejemplo se escribe la salida localmente mediante un `connection_type` de S3 con un argumento de ruta POSIX en `connection_options`, que permite escribir en almacenamiento local.

```
glueContext.write_dynamic_frame.from_options(\
frame = dyf_splitFields,\
connection_options = {'path': '/home/glue/GlueLocalOutput/'},\
connection_type = 's3',\
format = 'json')
```

Clase DynamicFrameReader

— métodos —

- __init__
- from_rdd
- from_options
- from_catalog

__init__

`__init__(glue_context)`

- `glue_context`: el Clase GlueContext que se va a utilizar.

from_rdd

`from_rdd(data, name, schema=None, sampleRatio=None)`

Lee un `DynamicFrame` en un conjunto de datos distribuido resistente (RDD).

- `data`: el conjunto de datos que se leerá.
- `name`: el nombre donde se efectuará la lectura.
- `schema`: el esquema que se leerá (opcional).
- `sampleRatio`: el ratio de muestra (opcional).

from_options

`from_options(connection_type, connection_options={}, format=None, format_options={}, transformation_ctx="")`

Lee un `DynamicFrame` utilizando la conexión y el formato especificados.

- `connection_type`: el tipo de conexión. Los valores válidos son `s3`, `mysql`, `postgresql`, `redshift`, `sqlserver`, `oracle`, `dynamodb` y `snowflake`.
- `connection_options`: opciones de conexión, como la tabla de rutas y bases de datos (opcional). Para obtener más información, consulte Tipos de conexiones y opciones para ETL en AWS Glue para Spark. Para un `connection_type` de `s3`, se definen las rutas de Amazon S3 en una matriz.

  ```
  connection_options = {"paths": [ "s3://amzn-s3-demo-bucket/object_a", "s3://amzn-s3-demo-bucket/object_b"]}
  ```

  Para conexiones JDBC, deben definirse varias propiedades. Tenga en cuenta que el nombre de la base de datos debe ser parte de la URL. Opcionalmente, se puede incluir en las opciones de conexión.

  > **Warning**
  >
  > No se recomienda almacenar las contraseñas en el script. Considere utilizar `boto3` para recuperarlas de AWS Secrets Manager o del catálogo de datos de Glue AWS.

```
connection_options = {"url": "jdbc-url/database", "user": "username",
 "password": passwordVariable,"dbtable": "table-name", "redshiftTmpDir": "s3-tempdir-path"}
```

Para una conexión JDBC que realiza lecturas en paralelo, puede establecer la opción hashfield. Por ejemplo:

```
connection_options = {"url": "jdbc-url/database", "user": "username",
 "password": passwordVariable,"dbtable": "table-name", "redshiftTmpDir": "s3-tempdir-path" , "hashfield": "month"}
```

Para obtener más información, consulte Lectura desde tablas de JDBC en paralelo.

- `format`: una especificación de formato (opcional). Se utiliza para Amazon Simple Storage Service (Amazon S3) o una conexión de AWS Glue que admite diversos formatos. Consulte en Opciones de formato de datos para las entradas y las salidas en AWS Glue para Spark los formatos que se admiten.
- `format_options`: opciones del formato especificado. Consulte en Opciones de formato de datos para las entradas y las salidas en AWS Glue para Spark los formatos que se admiten.
- `transformation_ctx`: contexto de transformación que se va a utilizar (opcional).
- `push_down_predicate`: filtra particiones sin tener que enumerar y leer todos los archivos del conjunto de datos. Para obtener más información, consulte Filtrado previo con predicados de inserción.

from_catalog

`from_catalog(database, table_name, redshift_tmp_dir="", transformation_ctx="", push_down_predicate="", additional_options={})`

Lee un `DynamicFrame` utilizando el espacio de nombres del catálogo y un nombre de tabla.

- `database`: la base de datos de lectura.
- `table_name`: nombre de la tabla de lectura.
- `redshift_tmp_dir`: un directorio de Amazon Redshift provisorio que se usará (opcional si no se leen datos de Redshift).
- `transformation_ctx`: contexto de transformación que se va a utilizar (opcional).

- `push_down_predicate`: filtra particiones sin tener que enumerar y leer todos los archivos del conjunto de datos. Para obtener más información, consulte Filtrado previo con predicados de inserción.
- `additional_options`: opciones adicionales para AWS Glue.
  - Para usar una conexión JDBC que realiza lecturas en paralelo, puede establecer las opciones `hashfield`, `hashexpression` o `hashpartitions`. Por ejemplo:

    ```
    additional_options = {"hashfield": "month"}
    ```

    Para obtener más información, consulte Lectura desde tablas de JDBC en paralelo.
  - Para transferir una expresión de catálogo para filtrar en función de las columnas de índice, puede ver la opción `catalogPartitionPredicate`.

    `catalogPartitionPredicate`: puede transferir una expresión de catálogo para filtrar en función de las columnas de índice. Esto inserta el filtrado hacia el lado del servidor. Para obtener más información, consulte Índices de partición de AWS Glue. Tenga en cuenta que `push_down_predicate` y `catalogPartitionPredicate` utilizan sintaxis diferentes. El primero utiliza la sintaxis estándar de Spark SQL y el segundo utiliza el analizador JSQL.

    Para obtener más información, consulte Administración de particiones para la salida de ETL en AWS Glue.

Clase GlueContext

Envuelve el objeto SparkContext de Apache SparkSQL y, por lo tanto, ofrece mecanismos para interactuar con la plataforma de Apache Spark.

__init__

`__init__(sparkContext)`

- `sparkContext`: el contexto de Apache Spark que se va a utilizar.

Creación

- __init__
- getSource

- create_dynamic_frame_from_rdd
- create_dynamic_frame_from_catalog
- create_dynamic_frame_from_options
- create_sample_dynamic_frame_from_catalog
- create_sample_dynamic_frame_from_options
- add_ingestion_time_columns
- create_data_frame_from_catalog
- create_data_frame_from_options
- forEachBatch

getSource

`getSource(connection_type, transformation_ctx = "", **options)`

Crea un objeto `DataSource` que se puede utilizar para leer `DynamicFrames` desde fuentes externas.

- `connection_type`: el tipo de conexión que se va a utilizar, como Amazon Simple Storage Service (Amazon S3), Amazon Redshift y JDBC. Los valores válidos son `s3`, `mysql`, `postgresql`, `redshift`, `sqlserver`, `oracle` y `dynamodb`.
- `transformation_ctx`: contexto de transformación que se va a utilizar (opcional).
- `options`: conjunto de pares nombre-valor opcionales. Para obtener más información, consulte Tipos de conexión y opciones para ETL en AWS Glue para Spark.

A continuación, se muestra un ejemplo de cómo se utiliza `getSource`.

```
>>> data_source = context.getSource("file", paths=["/in/path"])
>>> data_source.setFormat("json")
>>> myFrame = data_source.getFrame()
```

create_dynamic_frame_from_rdd

`create_dynamic_frame_from_rdd(data, name, schema=None, sample_ratio=None, transformation_ctx="")`

Muestra un `DynamicFrame` que se crea a partir de un conjunto de datos distribuido resistente (RDD) de Apache Spark.

- `data`: el origen de datos que se va a utilizar.
- `name`: el nombre de los datos que se van a utilizar.
- `schema`: el esquema que se va a utilizar (opcional).
- `sample_ratio`: el ratio de muestra que se va a utilizar (opcional).
- `transformation_ctx`: contexto de transformación que se va a utilizar (opcional).

create_dynamic_frame_from_catalog

`create_dynamic_frame_from_catalog(database, table_name, redshift_tmp_dir, transformation_ctx = "", push_down_predicate= "", additional_options = {}, catalog_id = None)`

Muestra un `DynamicFrame` que se crea mediante una base de datos del Catálogo de datos y un nombre de tabla. Al utilizar este método, proporciona `format_options` a través de las propiedades de la tabla en el AWS Glue Data Catalog especificada y otras opciones a través del argumento `additional_options`.

- `Database`: la base de datos de lectura.
- `table_name`: nombre de la tabla de lectura.
- `redshift_tmp_dir`: directorio provisional de Amazon Redshift que se va a utilizar (opcional).
- `transformation_ctx`: contexto de transformación que se va a utilizar (opcional).
- `push_down_predicate`: filtra particiones sin tener que enumerar y leer todos los archivos del conjunto de datos. Para conocer los orígenes compatibles y las limitaciones, consulte Optimizing reads with pushdown in AWS Glue ETL. Para obtener más información, consulte Filtrado previo con predicados de inserción.
- `additional_options`: conjunto de pares nombre-valor opcionales. Las opciones posibles incluyen las enumeradas en Tipos de conexión y opciones para ETL en AWS Glue para Spark, excepto por `endpointUrl`, `streamName`, `bootstrap.servers`, `security.protocol`, `topicName`, `classification` y `delimiter`. Otra opción soportada es `catalogPartitionPredicate`:

  `catalogPartitionPredicate`: puede transferir una expresión de catálogo para filtrar en función de las columnas de índice. Esto inserta el filtrado hacia el lado del servidor. Para obtener más información, consulte Índices de partición de AWS Glue. Tenga en cuenta que `push_down_predicate` y `catalogPartitionPredicate` utilizan sintaxis diferentes. El primero utiliza la sintaxis estándar de Spark SQL y el segundo utiliza el analizador JSQL.

- `catalog_id`: ID de catálogo (ID de cuenta) del Catálogo de datos al que se accede. Cuando el valor es Ninguno, se utiliza el ID de cuenta predeterminado del intermediario.

create_dynamic_frame_from_options

`create_dynamic_frame_from_options(connection_type, connection_options={}, format=None, format_options={}, transformation_ctx = "")`

Muestra un `DynamicFrame` que se crea con la conexión y el formato especificados.

- `connection_type`: el tipo de conexión, como Amazon S3, Amazon Redshift y JDBC. Los valores válidos son `s3`, `mysql`, `postgresql`, `redshift`, `sqlserver`, `oracle` y `dynamodb`.
- `connection_options`: las opciones de conexión, como las rutas y la tabla de bases de datos (opcional). Para un `connection_type` de `s3`, se define una lista de rutas de Amazon S3.

```
connection_options = {"paths": ["s3://aws-glue-target/temp"]}
```

Para conexiones JDBC, deben definirse varias propiedades. Tenga en cuenta que el nombre de la base de datos debe ser parte de la URL. Opcionalmente, se puede incluir en las opciones de conexión.

> **Warning**
>
> No se recomienda almacenar las contraseñas en el script. Considere utilizar `boto3` para recuperarlas de AWS Secrets Manager o del catálogo de datos de Glue AWS.

```
connection_options = {"url": "jdbc-url/database", "user": "username",
 "password": passwordVariable,"dbtable": "table-name", "redshiftTmpDir": "s3-tempdir-path"}
```

La propiedad `dbtable` es el nombre de la tabla de JDBC. Para almacenes de datos de JDBC que admiten esquemas dentro de una base de datos, especifique `schema.table-name`. Si no se ha proporcionado un esquema, se usa el esquema “public” predeterminado.

Para obtener más información, consulte Tipos de conexión y opciones para ETL en AWS Glue para Spark.

- `format`: una especificación de formato. Se utiliza con una conexión de Amazon S3 o AWS Glue que admite diversos formatos. Consulte en Opciones de formato de datos para las entradas y las salidas en AWS Glue para Spark los formatos que se admiten.
- `format_options`: opciones del formato especificado. Consulte en Opciones de formato de datos para las entradas y las salidas en AWS Glue para Spark los formatos que se admiten.
- `transformation_ctx`: contexto de transformación que se va a utilizar (opcional).
- `push_down_predicate`: filtra particiones sin tener que enumerar y leer todos los archivos del conjunto de datos. Para conocer los orígenes compatibles y las limitaciones, consulte Optimizing reads with pushdown in AWS Glue ETL. Para obtener más información, consulte Filtrado previo con predicados de inserción.

create_sample_dynamic_frame_from_catalog

`create_sample_dynamic_frame_from_catalog(database, table_name, num, redshift_tmp_dir, transformation_ctx = "", push_down_predicate= "", additional_options = {}, sample_options = {}, catalog_id = None)`

Muestra un `DynamicFrame` de ejemplo que se crea mediante una base de datos del Catálogo de datos y un nombre de tabla. La `DynamicFrame` solo contiene los primeros registros de `num` de un origen de datos.

- `database`: la base de datos de lectura.
- `table_name`: nombre de la tabla de lectura.
- `num`: número máximo de registros del marco dinámico de muestra arrojado.
- `redshift_tmp_dir`: directorio provisional de Amazon Redshift que se va a utilizar (opcional).
- `transformation_ctx`: contexto de transformación que se va a utilizar (opcional).
- `push_down_predicate`: filtra particiones sin tener que enumerar y leer todos los archivos del conjunto de datos. Para obtener más información, consulte Filtrado previo con predicados de inserción.
- `additional_options`: conjunto de pares nombre-valor opcionales. Las opciones posibles incluyen las enumeradas en Tipos de conexión y opciones para ETL en AWS Glue para Spark, excepto por `endpointUrl`, `streamName`, `bootstrap.servers`, `security.protocol`, `topicName`, `classification` y `delimiter`.
- `sample_options`: parámetros para controlar el comportamiento del muestreo (opcional). Parámetros disponibles actuales para los orígenes de Simple Storage Service (Amazon S3):

- `maxSamplePartitions`: número máximo de particiones que leerá el muestreo. El valor predeterminado es 10
- `maxSampleFilesPerPartition`: número máximo de archivos que leerá el muestreo en una partición. El valor predeterminado es 10.

  Estos parámetros ayudan a reducir el tiempo que consume el listado de archivos. Por ejemplo, supongamos que el conjunto de datos tiene 1000 particiones y cada partición tiene 10 archivos. Si se configura `maxSamplePartitions` = 10 y `maxSampleFilesPerPartition` = 10, en lugar de enumerar los 10 000 archivos, el muestreo solo mostrará y leerá las 10 primeras particiones con los 10 primeros archivos de cada uno: 10 * 10 = 100 archivos en total.

- `catalog_id`: el ID de catálogo del Catálogo de datos al que se accede (el ID de cuenta del Catálogo de datos). De forma predeterminada, se establece en `None`. `None` es el valor predeterminado para el ID de catálogo de la cuenta del servicio que hace la llamada.

create_sample_dynamic_frame_from_options

`create_sample_dynamic_frame_from_options(connection_type, connection_options={}, num, sample_options={}, format=None, format_options={}, transformation_ctx = "")`

Arroja un `DynamicFrame` de ejemplo que se crea con la conexión y el formato especificados. La `DynamicFrame` solo contiene los primeros registros de `num` de un origen de datos.

- `connection_type`: el tipo de conexión, como Amazon S3, Amazon Redshift y JDBC. Los valores válidos son `s3`, `mysql`, `postgresql`, `redshift`, `sqlserver`, `oracle` y `dynamodb`.
- `connection_options`: las opciones de conexión, como las rutas y la tabla de bases de datos (opcional). Para obtener más información, consulte Tipos de conexión y opciones para ETL en AWS Glue para Spark.
- `num`: número máximo de registros del marco dinámico de muestra arrojado.
- `sample_options`: parámetros para controlar el comportamiento del muestreo (opcional). Parámetros disponibles actuales para los orígenes de Simple Storage Service (Amazon S3):
  - `maxSamplePartitions`: número máximo de particiones que leerá el muestreo. El valor predeterminado es 10
  - `maxSampleFilesPerPartition`: número máximo de archivos que leerá el muestreo en una partición. El valor predeterminado es 10.

Estos parámetros ayudan a reducir el tiempo que consume el listado de archivos. Por ejemplo, supongamos que el conjunto de datos tiene 1000 particiones y cada partición tiene 10 archivos. Si se configura `maxSamplePartitions` = 10 y `maxSampleFilesPerPartition` = 10, en lugar de enumerar los 10 000 archivos, el muestreo solo mostrará y leerá las 10 primeras particiones con los 10 primeros archivos de cada uno: 10 * 10 = 100 archivos en total.

- `format`: una especificación de formato. Se utiliza con una conexión de Amazon S3 o AWS Glue que admite diversos formatos. Consulte en Opciones de formato de datos para las entradas y las salidas en AWS Glue para Spark los formatos que se admiten.
- `format_options`: opciones del formato especificado. Consulte en Opciones de formato de datos para las entradas y las salidas en AWS Glue para Spark los formatos que se admiten.
- `transformation_ctx`: contexto de transformación que se va a utilizar (opcional).
- `push_down_predicate`: filtra particiones sin tener que enumerar y leer todos los archivos del conjunto de datos. Para obtener más información, consulte Filtrado previo con predicados de inserción.

add_ingestion_time_columns

`add_ingestion_time_columns(dataFrame, timeGranularity = "")`

Agrega columnas de tiempo de ingesta como `ingest_year`, `ingest_month`, `ingest_day`, `ingest_hour`, `ingest_minute` al `DataFrame` de entrada. Esta función se genera en forma automática en el script generado por AWS Glue cuando especifique una tabla del Catálogo de datos con Amazon S3 como destino. Esta función actualiza en forma automática la partición con columnas de tiempo de ingesta en la tabla de salida. Esto permite que los datos de salida se dividan automáticamente en el tiempo de ingesta sin requerir columnas de tiempo de ingesta explícitas en los datos de entrada.

- `dataFrame`: el `dataFrame` al que anexar las columnas de tiempo de ingesta.
- `timeGranularity`: la granularidad de las columnas de tiempo. Los valores válidos son “`day`”, “`hour`” y “`minute`”. Por ejemplo, si “`hour`” se transfiere a la función, el `dataFrame` original tendrá las columnas de tiempo “`ingest_year`,” “`ingest_month`,” “`ingest_day`” y “`ingest_hour`” anexadas.

Devuelve el marco de datos después de anexar las columnas de granularidad de tiempo.

Ejemplo:

```
dynamic_frame = DynamicFrame.fromDF(glueContext.add_ingestion_time_columns(dataFrame,
 "hour"))
```

create_data_frame_from_catalog

`create_data_frame_from_catalog(database, table_name, transformation_ctx = "", additional_options = {})`

Devuelve un `DataFrame` que se crea con información de una tabla del Catálogo de datos.

- `database`: la base de datos del Catálogo de datos de la que se va a leer.
- `table_name`: el nombre de la tabla del Catálogo de datos de la que se va a leer.
- `transformation_ctx`: contexto de transformación que se va a utilizar (opcional).
- `additional_options`: conjunto de pares nombre-valor opcionales. Las opciones posibles incluyen las enumeradas en Tipos de conexión y opciones para ETL en AWS Glue para Spark para orígenes de streaming, como `startingPosition`, `maxFetchTimeInMs` y `startingOffsets`.
  - `useSparkDataSource`: cuando se establece en true (verdadero), obliga a AWS Glue a usar la API nativa de orígenes de datos de Spark para leer la tabla. La API de orígenes de datos de Spark admite los siguientes formatos: AVRO, binario, CSV, JSON, ORC, Parquet y texto. En una tabla del Catálogo de datos, especifique el formato mediante la propiedad `classification`. Para obtener más información sobre la API de orígenes de datos de Spark, consulte la documentación oficial de Apache Spark.

    El uso de `create_data_frame_from_catalog` con `useSparkDataSource` presenta las siguientes ventajas:

    - Devuelve directamente un `DataFrame` y ofrece una alternativa a `create_dynamic_frame.from_catalog().toDF()`.
    - Admite el control de permisos de tabla de AWS Lake Formation para formatos nativos.
    - Admite la lectura de formatos de lagos de datos sin el control de permisos de tabla de AWS Lake Formation. Para obtener más información, consulte Uso de marcos de lagos de datos con trabajos de ETL de AWS Glue.

    Cuando habilita `useSparkDataSource`, también puede agregar cualquiera de las opciones de orígenes de datos de Spark en `additional_options` según sea necesario. AWS Glue pasa estas opciones directamente al lector de Spark.

- `useCatalogSchema`: cuando se establece en true (verdadero), AWS Glue aplica el esquema del Catálogo de datos al `DataFrame` resultante. De lo contrario, el lector deduce el esquema a partir de los datos. Cuando se habilita `useCatalogSchema`, también se debe establecer `useSparkDataSource` en true (verdadero).

Limitaciones

Tenga en cuenta las siguientes limitaciones cuando utilice la opción `useSparkDataSource`:

- Cuando usa `useSparkDataSource`, AWS Glue crea un nuevo `DataFrame` en una sesión independiente de Spark que es diferente de la sesión original de Spark.
- El filtrado de particiones de DataFrame de Spark no funciona con las siguientes características de AWS Glue.
  - Marcadores de trabajo
  - Exclusión de clases de almacenamiento de Amazon S3
  - Predicados de particiones de catálogo

  Para utilizar el filtrado de particiones con estas características, puede utilizar el predicado de inserción de AWS Glue. Para obtener más información, consulte Filtrado previo con predicados de inserción. El filtrado de columnas no particionadas no se ve afectado.

  En el siguiente script de ejemplo, se muestra la forma incorrecta de filtrar particiones con la opción `excludeStorageClasses`.

```
// Incorrect partition filtering using Spark filter with excludeStorageClasses
read_df = glueContext.create_data_frame.from_catalog(
    database=database_name,
    table_name=table_name,
    additional_options = {
      "useSparkDataSource": True,
      "excludeStorageClasses" : ["GLACIER", "DEEP_ARCHIVE"]
    }
)

//  Suppose year and month are partition keys.
//  Filtering on year and month won't work, the filtered_df will still
//  contain data with other year/month values.
filtered_df = read_df.filter("year == '2017 and month == '04' and 'state == 'CA'")
```

En el siguiente script de ejemplo, se muestra la forma correcta de utilizar un predicado de inserción para filtrar particiones con la opción `excludeStorageClasses`.

```
// Correct partition filtering using the AWS Glue pushdown predicate
// with excludeStorageClasses
read_df = glueContext.create_data_frame.from_catalog(
    database=database_name,
    table_name=table_name,
    //  Use AWS Glue pushdown predicate to perform partition filtering
    push_down_predicate = "(year=='2017' and month=='04')"
    additional_options = {
      "useSparkDataSource": True,
      "excludeStorageClasses" : ["GLACIER", "DEEP_ARCHIVE"]
    }
)

//  Use Spark filter only on non-partitioned columns
filtered_df = read_df.filter("state == 'CA'")
```

Ejemplo: crear una tabla CSV con el lector de orígenes de datos de Spark

```
//  Read a CSV table with '\t' as separator
read_df = glueContext.create_data_frame.from_catalog(
    database=<database_name>,
    table_name=<table_name>,
    additional_options = {"useSparkDataSource": True,  "sep": '\t'}
)
```

create_data_frame_from_options

`create_data_frame_from_options(connection_type, connection_options={}, format=None, format_options={}, transformation_ctx = "")`

Esta API ha quedado obsoleta. En su lugar, use la API `getSource()`. Muestra un `DataFrame` que se crea con la conexión y el formato especificados. Utilice esta función solo con orígenes de streaming de AWS Glue.

- `connection_type`: el tipo de conexión de streaming. Los valores válidos son `kinesis` y `kafka`.
- `connection_options`: opciones de conexión, que son diferentes para Kinesis y Kafka. Puede encontrar la lista de todas las opciones de conexión para cada origen de datos de streaming en

Tipos de conexión y opciones para ETL en AWS Glue para Spark. Tenga en cuenta las siguientes diferencias en las opciones de conexión de streaming:

- Los orígenes de streaming de Kinesis requieren `streamARN`, `startingPosition`, `inferSchema` y `classification`.
- Los orígenes de streaming de Kafka requieren `connectionName`, `topicName`, `startingOffsets`, `inferSchema` y `classification`.

- `format`: una especificación de formato. Se utiliza con una conexión de Amazon S3 o AWS Glue que admite diversos formatos. Para obtener información acerca de los formatos soportados, consulte Opciones de formato de datos para las entradas y las salidas en AWS Glue para Spark.
- `format_options`: opciones del formato especificado. Para obtener información acerca de las opciones de formatos soportados, consulte Opciones de formato de datos para las entradas y las salidas en AWS Glue para Spark.
- `transformation_ctx`: contexto de transformación que se va a utilizar (opcional).

Ejemplo de origen de streaming de Amazon Kinesis:

```
kinesis_options =
   { "streamARN": "arn:aws:kinesis:us-east-2:777788889999:stream/fromOptionsStream",
     "startingPosition": "TRIM_HORIZON",
     "inferSchema": "true",
     "classification": "json"
   }
data_frame_datasource0 =
 glueContext.create_data_frame.from_options(connection_type="kinesis",
 connection_options=kinesis_options)
```

Ejemplo de origen de streaming de Kafka:

```
kafka_options =
    { "connectionName": "ConfluentKafka",
      "topicName": "kafka-auth-topic",
      "startingOffsets": "earliest",
      "inferSchema": "true",
      "classification": "json"
    }
data_frame_datasource0 =
 glueContext.create_data_frame.from_options(connection_type="kafka",
 connection_options=kafka_options)
```

forEachBatch

`forEachBatch(frame, batch_function, options)`

Se aplica la `batch_function` transferida a cada microlote que se lee desde el origen de streaming.

- `frame`: el DataFrame que contiene el microlote actual.
- `batch_function`: una función que se aplicará para cada microlote.
- `options`: una recopilación de pares clave-valor que contiene información sobre cómo procesar microlotes. Se requieren las siguientes opciones:
  - `windowSize`: cantidad de tiempo que se debe dedicar al procesamiento de cada lote.
  - `checkpointLocation`: la ubicación donde se almacenan los puntos de verificación para el trabajo de ETL de streaming.
  - `batchMaxRetries`: número máximo de reintentos permitidos para este lote si se genera un error. El valor predeterminado es 3. Esta opción sólo se puede configurar para Glue versión 2.0 y superior.

Ejemplo:

```
glueContext.forEachBatch(
    frame = data_frame_datasource0,
    batch_function = processBatch,
    options = {
        "windowSize": "100 seconds",
        "checkpointLocation": "s3://kafka-auth-dataplane/confluent-test/output/
checkpoint/"
    }
)

def processBatch(data_frame, batchId):
    if (data_frame.count() > 0):
        datasource0 = DynamicFrame.fromDF(
          glueContext.add_ingestion_time_columns(data_frame, "hour"),
          glueContext, "from_data_frame"
        )
        additionalOptions_datasink1 = {"enableUpdateCatalog": True}
        additionalOptions_datasink1["partitionKeys"] = ["ingest_yr", "ingest_mo",
 "ingest_day"]
        datasink1 = glueContext.write_dynamic_frame.from_catalog(
          frame = datasource0,
```

```
          database = "tempdb",
          table_name = "kafka-auth-table-output",
          transformation_ctx = "datasink1",
          additional_options = additionalOptions_datasink1
        )
```

Trabajar con conjuntos de datos en Amazon S3

- purge_table
- purge_s3_path
- transition_table
- transition_s3_path

purge_table

`purge_table(catalog_id=None, database="", table_name="", options={}, transformation_ctx="")`

Elimina archivos de Amazon S3 correspondientes a la base de datos y la tabla del catálogo especificado. Si se eliminan todos los archivos de una partición, esa partición también se eliminará del catálogo. No se admite la acción purge_table en las tablas registradas con Lake Formation.

Si desea poder recuperar los objetos eliminados, puede habilitar control de versiones de objetos en el bucket de Amazon S3. Cuando se elimina un objeto de un bucket que no tiene habilitado el control de versiones de objetos, el objeto no se puede recuperar. Para obtener más información acerca de cómo recuperar objetos eliminados en un bucket habilitado para versiones, consulte ¿Cómo puedo recuperar un objeto de Amazon S3 eliminado? en el Centro de conocimientos de AWS Support.

- `catalog_id`: el ID de catálogo del Catálogo de datos al que se accede (el ID de cuenta del Catálogo de datos). De forma predeterminada, se establece en `None`. `None` es el valor predeterminado para el ID de catálogo de la cuenta del servicio que hace la llamada.
- `database`: la base de datos que se va a utilizar.
- `table_name`: nombre de la tabla que se utilizará.
- `options`: opciones para filtrar los archivos que se van a eliminar y para la generación de archivos de manifiesto.
  - `retentionPeriod`: especifica un período para retener los archivos en cantidad de horas. Se mantienen los archivos que son posteriores al período de retención. De forma predeterminada, se establece en 168 horas (7 días).

- `partitionPredicate`: se eliminan las particiones que cumplen con este predicado. Los archivos comprendidos en el período de retención de estas particiones no se eliminan. Configurar en `""`, valor vacío de forma predeterminada.
- `excludeStorageClasses`: no se eliminan los archivos con clase de almacenamiento configurada en `excludeStorageClasses`. El valor predeterminado es `Set()`, un conjunto vacío.
- `manifestFilePath`: una ruta opcional para la generación de archivos de manifiesto. Todos los archivos que se depuraron correctamente se registran en `Success.csv`, mientras que los que no lo hicieron se registran en `Failed.csv`

- `transformation_ctx`: contexto de transformación que se va a utilizar (opcional). Se utiliza en la ruta del archivo de manifiesto.

Example

```
glueContext.purge_table("database", "table", {"partitionPredicate": "(month=='march')",
 "retentionPeriod": 1, "excludeStorageClasses": ["STANDARD_IA"], "manifestFilePath":
 "s3://bucketmanifest/"})
```

purge_s3_path

`purge_s3_path(s3_path, options={}, transformation_ctx="")`

Elimina archivos de la ruta de Amazon S3 especificada recursivamente.

Si desea poder recuperar los objetos eliminados, puede habilitar control de versiones de objetos en el bucket de Amazon S3. Cuando se elimina un objeto de un bucket que no tiene habilitado el control de versiones de objetos, el objeto no se puede recuperar. Para obtener más información acerca de cómo recuperar objetos eliminados en un bucket habilitado para control de versiones, consulte ¿Cómo puedo recuperar un objeto de Amazon S3 eliminado? en el Centro de conocimientos de Soporte.

- `s3_path`: la ruta de acceso en Amazon S3 de los archivos que se van a eliminar en el formato `s3://<bucket>/<prefix>/`
- `options`: opciones para filtrar los archivos que se van a eliminar y para la generación de archivos de manifiesto.

- `retentionPeriod`: especifica un período para retener los archivos en cantidad de horas. Se mantienen los archivos que son posteriores al período de retención. De forma predeterminada, se establece en 168 horas (7 días).
- `excludeStorageClasses`: no se eliminan los archivos con clase de almacenamiento configurada en `excludeStorageClasses`. El valor predeterminado es `Set()`, un conjunto vacío.
- `manifestFilePath`: una ruta opcional para la generación de archivos de manifiesto. Todos los archivos que se depuraron correctamente se registran en `Success.csv`, mientras que los que no lo hicieron se registran en `Failed.csv`

- `transformation_ctx`: contexto de transformación que se va a utilizar (opcional). Se utiliza en la ruta del archivo de manifiesto.

Example

```
glueContext.purge_s3_path("s3://bucket/path/", {"retentionPeriod": 1,
 "excludeStorageClasses": ["STANDARD_IA"], "manifestFilePath": "s3://bucketmanifest/"})
```

transition_table

`transition_table(database, table_name, transition_to, options={}, transformation_ctx="", catalog_id=None)`

Inicia la transición de la clase de almacenamiento de los archivos almacenados en Amazon S3 correspondientes a la base de datos y la tabla del catálogo especificado.

Puede realizar la transición entre dos clases de almacenamiento cualquiera. En el caso de las clases de almacenamiento `GLACIER` y `DEEP_ARCHIVE`, la transición puede hacerse a estas clases. Sin embargo, debería utilizar `S3 RESTORE` para realizar la transición de `GLACIER` y las clases de almacenamiento `DEEP_ARCHIVE`.

Si ejecuta trabajos de ETL de AWS Glue que leen archivos o particiones de Amazon S3, puede excluir algunos tipos de clases de almacenamiento de Amazon S3. Para obtener más información, consulte Exclusión de clases de almacenamiento de Amazon S3.

- `database`: la base de datos que se va a utilizar.
- `table_name`: nombre de la tabla que se utilizará.
- `transition_to`: la clase de almacenamiento de Amazon S3 hacia la que se hará la transición.

- `options`: opciones para filtrar los archivos que se van a eliminar y para la generación de archivos de manifiesto.
  - `retentionPeriod`: especifica un período para retener los archivos en cantidad de horas. Se mantienen los archivos que son posteriores al período de retención. De forma predeterminada, se establece en 168 horas (7 días).
  - `partitionPredicate`: se realiza la transición de las particiones que cumplen con este predicado. Los archivos comprendidos en el período de retención de estas particiones no realizan la transición. Configurar en `""`, valor vacío de forma predeterminada.
  - `excludeStorageClasses`: no se realiza la transición de los archivos con clase de almacenamiento en `excludeStorageClasses`. El valor predeterminado es `Set()`, un conjunto vacío.
  - `manifestFilePath`: una ruta opcional para la generación de archivos de manifiesto. Todos los archivos que realizaron la transición correctamente se registran en `Success.csv`, mientras que los que no lo hicieron se registran en `Failed.csv`
  - `accountId`: el ID de cuenta de Amazon Web Services para ejecutar la transformación de transición. Es obligatorio para esta transformación.
  - `roleArn`: el rol AWS para ejecutar la transformación de transición. Es obligatorio para esta transformación.
- `transformation_ctx`: contexto de transformación que se va a utilizar (opcional). Se utiliza en la ruta del archivo de manifiesto.
- `catalog_id`: el ID de catálogo del Catálogo de datos al que se accede (el ID de cuenta del Catálogo de datos). De forma predeterminada, se establece en `None`. `None` es el valor predeterminado para el ID de catálogo de la cuenta del servicio que hace la llamada.

Example

```
glueContext.transition_table("database", "table", "STANDARD_IA", {"retentionPeriod": 1,
 "excludeStorageClasses": ["STANDARD_IA"], "manifestFilePath": "s3://bucketmanifest/",
 "accountId": "12345678901", "roleArn": "arn:aws:iam::123456789012:user/example-
username"})
```

transition_s3_path

`transition_s3_path(s3_path, transition_to, options={}, transformation_ctx="")`

Realiza transiciones recursivas en la clase de almacenamiento de los archivos de la ruta de Amazon S3 especificada.

Puede realizar la transición entre dos clases de almacenamiento cualquiera. En el caso de las clases de almacenamiento `GLACIER` y `DEEP_ARCHIVE`, la transición puede hacerse a estas clases. Sin embargo, debería utilizar `S3 RESTORE` para realizar la transición de `GLACIER` y las clases de almacenamiento `DEEP_ARCHIVE`.

Si ejecuta trabajos de ETL de AWS Glue que leen archivos o particiones de Amazon S3, puede excluir algunos tipos de clases de almacenamiento de Amazon S3. Para obtener más información, consulte Exclusión de clases de almacenamiento de Amazon S3.

- `s3_path`: la ruta en Amazon S3 de los archivos sobre los que se realizará la transición en el formato `s3://<bucket>/<prefix>/`
- `transition_to`: la clase de almacenamiento de Amazon S3 hacia la que se hará la transición.
- `options`: opciones para filtrar los archivos que se van a eliminar y para la generación de archivos de manifiesto.
  - `retentionPeriod`: especifica un período para retener los archivos en cantidad de horas. Se mantienen los archivos que son posteriores al período de retención. De forma predeterminada, se establece en 168 horas (7 días).
  - `partitionPredicate`: se realiza la transición de las particiones que cumplen con este predicado. Los archivos comprendidos en el período de retención de estas particiones no realizan la transición. Configurar en `""`, valor vacío de forma predeterminada.
  - `excludeStorageClasses`: no se realiza la transición de los archivos con clase de almacenamiento en `excludeStorageClasses`. El valor predeterminado es `Set()`, un conjunto vacío.
  - `manifestFilePath`: una ruta opcional para la generación de archivos de manifiesto. Todos los archivos que realizaron la transición correctamente se registran en `Success.csv`, mientras que los que no lo hicieron se registran en `Failed.csv`
  - `accountId`: el ID de cuenta de Amazon Web Services para ejecutar la transformación de transición. Es obligatorio para esta transformación.

  - `roleArn`: el rol AWS para ejecutar la transformación de transición. Es obligatorio para esta transformación.
- `transformation_ctx`: contexto de transformación que se va a utilizar (opcional). Se utiliza en la ruta del archivo de manifiesto.

Example

```
glueContext.transition_s3_path("s3://bucket/prefix/", "STANDARD_IA",
 {"retentionPeriod": 1, "excludeStorageClasses": ["STANDARD_IA"],
 "manifestFilePath": "s3://bucketmanifest/", "accountId": "12345678901", "roleArn":
 "arn:aws:iam::123456789012:user/example-username"})
```

Extracción

- extract_jdbc_conf

extract_jdbc_conf

`extract_jdbc_conf(connection_name, catalog_id = None)`

Devuelve `dict` con claves con las propiedades de configuración del objeto de conexión de AWS Glue en el Catálogo de datos.

- `user`: nombre de usuario de la base de datos.
- `password`: contraseña de la base de datos.
- `vendor`: especifica un proveedor (`mysql`, `postgresql`, `oracle`, `sqlserver`, etc.).
- `enforceSSL`: una cadena booleana que indica si se requiere una conexión segura.
- `customJDBCCert`: uso de un certificado de cliente específico de la ruta de Amazon S3 indicada.
- `skipCustomJDBCCertValidation`: una cadena booleana que indica si `customJDBCCert` debe ser validado por una CA.
- `customJDBCCertString`: información adicional sobre el certificado personalizado, específico para el tipo de controlador.
- `url`: URL de JDBC (obsoleta) con solo protocolo, servidor y puerto.
- `fullUrl`: URL de JDBC introducida cuando se creó la conexión (Disponible en AWS Glue versión 3.0 o posterior).

Ejemplo de recuperación de configuraciones de JDBC:

```
jdbc_conf = glueContext.extract_jdbc_conf(connection_name="your_glue_connection_name")
print(jdbc_conf)
>>> {'enforceSSL': 'false', 'skipCustomJDBCCertValidation': 'false', 'url':
 'jdbc:mysql://myserver:3306', 'fullUrl': 'jdbc:mysql://myserver:3306/mydb',
 'customJDBCCertString': '', 'user': 'admin', 'customJDBCCert': '', 'password': '1234',
 'vendor': 'mysql'}
```

Transacciones

- start_transaction
- commit_transaction
- cancel_transaction

start_transaction

`start_transaction(read_only)`

Inicie una nueva transacción. Llama de forma interna a la API startTransaction de Lake Formation.

- `read_only`: (booleano) indica si esta transacción debe ser de solo lectura o de lectura y escritura. Se rechazarán las escrituras realizadas con un ID de transacción de solo lectura. No es necesario confirmar las transacciones de solo lectura.

Devuelve el ID de la transacción.

commit_transaction

`commit_transaction(transaction_id, wait_for_commit = True)`

Intenta confirmar la transacción especificada. Es posible que se devuelva `commit_transaction` antes de que la transacción haya terminado de confirmarse. Llama de forma interna a la API commitTransaction de Lake Formation.

- `transaction_id` : (cadena) la transacción que se confirmará.
- `wait_for_commit`: (booleano) determina si se devuelve `commit_transaction` de inmediato. El valor predeterminado es true. Si es falso, `commit_transaction` realiza un sondeo y espera

hasta que la transacción se haya confirmado. La cantidad de tiempo de espera se limita a un minuto mediante retroceso exponencial con un máximo de seis reintentos.

Devuelve un valor booleano para indicar si se realizó o no la confirmación.

cancel_transaction

`cancel_transaction(transaction_id)`

Intenta cancelar la transacción especificada. Devuelve una excepción de `TransactionCommittedException` si la transacción se había confirmado anteriormente. Llama de forma interna a la API CancelTransaction de Lake Formation.

- `transaction_id`: (cadena) la transacción que se cancelará.

Escritura

- getSink
- write_dynamic_frame_from_options
- write_from_options
- write_dynamic_frame_from_catalog
- write_data_frame_from_catalog
- write_dynamic_frame_from_jdbc_conf
- write_from_jdbc_conf

getSink

`getSink(connection_type, format = None, transformation_ctx = "", **options)`

Obtiene un objeto `DataSink` que se puede utilizar para escribir `DynamicFrames` en fuentes externas. Compruebe el valor de `format` de SparkSQL en primer lugar para asegurarse de que obtiene el receptor esperado.

- `connection_type`: tipo de conexión que se va a utilizar, como Amazon S3, Amazon Redshift y JDBC. Los valores válidos son `s3`, `mysql`, `postgresql`, `redshift`, `sqlserver`, `oracle`, `kinesis` y `kafka`.
- `format`: el formato de SparkSQL que se utilizará (opcional).

- `transformation_ctx`: contexto de transformación que se va a utilizar (opcional).
- `options`: conjunto de pares de nombre-valor que se utilizan para especificar las opciones de conexión. Algunos de valores posibles son:
  - `user` y `password`: para autorización
  - `url`: punto de conexión del almacén de datos
  - `dbtable`: nombre de la tabla de destino
  - `bulkSize`: grado de paralelismo para operaciones de inserción

Las opciones que puede especificar dependen del tipo de conexión. Consulte Tipos de conexión y opciones para ETL en AWS Glue para Spark para obtener más valores y ejemplos.

Ejemplo:

```
>>> data_sink = context.getSink("s3")
>>> data_sink.setFormat("json"),
>>> data_sink.writeFrame(myFrame)
```

write_dynamic_frame_from_options

`write_dynamic_frame_from_options(frame, connection_type, connection_options={}, format=None, format_options={}, transformation_ctx = "")`

Escribe y devuelve un `DynamicFrame` mediante la conexión y el formato especificados.

- `frame`: el `DynamicFrame` que se va a escribir.
- `connection_type`: el tipo de conexión, como Amazon S3, Amazon Redshift y JDBC. Los valores válidos son `s3`, `mysql`, `postgresql`, `redshift`, `sqlserver`, `oracle`, `kinesis` y `kafka`.
- `connection_options`: opciones de conexión, como la tabla de rutas y bases de datos (opcional). Para un `connection_type` de `s3`, se define una ruta de Amazon S3.

  ```
  connection_options = {"path": "s3://aws-glue-target/temp"}
  ```

  Para conexiones JDBC, deben definirse varias propiedades. Tenga en cuenta que el nombre de la base de datos debe ser parte de la URL. Opcionalmente, se puede incluir en las opciones de conexión.

> **Warning**
>
> No se recomienda almacenar las contraseñas en el script. Considere utilizar `boto3` para recuperarlas de AWS Secrets Manager o del catálogo de datos de Glue AWS.

```
connection_options = {"url": "jdbc-url/database", "user": "username",
 "password": passwordVariable,"dbtable": "table-name", "redshiftTmpDir": "s3-tempdir-path"}
```

La propiedad `dbtable` es el nombre de la tabla de JDBC. Para almacenes de datos de JDBC que admiten esquemas dentro de una base de datos, especifique `schema.table-name`. Si no se ha proporcionado un esquema, se usa el esquema "public" predeterminado.

Para obtener más información, consulte Tipos de conexión y opciones para ETL en AWS Glue para Spark.

- `format`: una especificación de formato. Se utiliza con una conexión de Amazon S3 o AWS Glue que admite diversos formatos. Consulte en Opciones de formato de datos para las entradas y las salidas en AWS Glue para Spark los formatos que se admiten.
- `format_options`: opciones del formato especificado. Consulte en Opciones de formato de datos para las entradas y las salidas en AWS Glue para Spark los formatos que se admiten.
- `transformation_ctx`: contexto de transformación que se va a utilizar (opcional).

write_from_options

`write_from_options(frame_or_dfc, connection_type, connection_options={}, format={}, format_options={}, transformation_ctx = "")`

Escribe y devuelve un `DynamicFrame` o `DynamicFrameCollection` que se crea con la información sobre la conexión y el formato especificada.

- `frame_or_dfc`: el `DynamicFrame` o la `DynamicFrameCollection` que se van a escribir.
- `connection_type`: el tipo de conexión, como Amazon S3, Amazon Redshift y JDBC. Entre los valores válidos se incluyen: `s3`, `mysql`, `postgresql`, `redshift`, `sqlserver` y `oracle`.
- `connection_options`: opciones de conexión, como la tabla de rutas y bases de datos (opcional). Para un `connection_type` de `s3`, se define una ruta de Amazon S3.

```
connection_options = {"path": "s3://aws-glue-target/temp"}
```

Para conexiones JDBC, deben definirse varias propiedades. Tenga en cuenta que el nombre de la base de datos debe ser parte de la URL. Opcionalmente, se puede incluir en las opciones de conexión.

> **Warning**
>
> No se recomienda almacenar las contraseñas en el script. Considere utilizar `boto3` para recuperarlas de AWS Secrets Manager o del catálogo de datos de Glue AWS.

```
connection_options = {"url": "jdbc-url/database", "user": "username",
 "password": passwordVariable,"dbtable": "table-name", "redshiftTmpDir": "s3-tempdir-
path"}
```

La propiedad `dbtable` es el nombre de la tabla de JDBC. Para almacenes de datos de JDBC que admiten esquemas dentro de una base de datos, especifique `schema.table-name`. Si no se ha proporcionado un esquema, se usa el esquema “public” predeterminado.

Para obtener más información, consulte Tipos de conexión y opciones para ETL en AWS Glue para Spark.

- `format`: una especificación de formato. Se utiliza con una conexión de Amazon S3 o AWS Glue que admite diversos formatos. Consulte en Opciones de formato de datos para las entradas y las salidas en AWS Glue para Spark los formatos que se admiten.
- `format_options`: opciones del formato especificado. Consulte en Opciones de formato de datos para las entradas y las salidas en AWS Glue para Spark los formatos que se admiten.
- `transformation_ctx`: contexto de transformación que se va a utilizar (opcional).

write_dynamic_frame_from_catalog

`write_dynamic_frame_from_catalog(frame, database, table_name, redshift_tmp_dir, transformation_ctx = "", additional_options = {}, catalog_id = None)`

Escribe y devuelve un `DynamicFrame` que se crea mediante una base de datos y una tabla del Catálogo de datos.

- `frame`: el `DynamicFrame` que se va a escribir.
- `Database`: la base de datos del Catálogo de datos que contiene la tabla.
- `table_name`: el nombre de la tabla del Catálogo de datos asociada al destino.
- `redshift_tmp_dir`: directorio provisional de Amazon Redshift que se va a utilizar (opcional).
- `transformation_ctx`: contexto de transformación que se va a utilizar (opcional).
- `additional_options`: conjunto de pares nombre-valor opcionales.
- `catalog_id`: ID de catálogo (ID de cuenta) del Catálogo de datos al que se accede. Cuando el valor es Ninguno, se utiliza el ID de cuenta predeterminado del intermediario.

write_data_frame_from_catalog

`write_data_frame_from_catalog(frame, database, table_name, redshift_tmp_dir, transformation_ctx = "", additional_options = {}, catalog_id = None)`

Escribe y devuelve un `DataFrame` que se crea mediante una base de datos y una tabla del Catálogo de datos. Este método admite la escritura en formatos de lagos de datos (Hudi, Iceberg y Delta Lake). Para obtener más información, consulte Uso de marcos de lagos de datos con trabajos de ETL de AWS Glue.

- `frame`: el `DataFrame` que se va a escribir.
- `Database`: la base de datos del Catálogo de datos que contiene la tabla.
- `table_name`: nombre de la tabla del Catálogo de datos que está asociada al destino.
- `redshift_tmp_dir`: directorio provisional de Amazon Redshift que se va a utilizar (opcional).
- `transformation_ctx`: contexto de transformación que se va a utilizar (opcional).
- `additional_options`: conjunto de pares nombre-valor opcionales.

- `useSparkDataSink`: cuando se establece en true (verdadero), obliga a AWS Glue a usar la API nativa del receptor de datos de Spark para escribir en la tabla. Cuando habilita esta opción, puede agregar cualquier opción de origen de datos de Spark a `additional_options` según sea necesario. AWS Glue pasa estas opciones directamente al escritor de Spark.
- `catalog_id`: el ID de catálogo (ID de cuenta) del Catálogo de datos al que se accede. Si no especifica un valor, se utiliza el ID de cuenta predeterminado del intermediario.

Limitaciones

Tenga en cuenta las siguientes limitaciones cuando utilice la opción `useSparkDataSink`:

- La opción `enableUpdateCatalog` no se admite cuando se utiliza la opción `useSparkDataSink`.

Ejemplo: escribir una tabla de Hudi con el escritor de orígenes de datos de Spark

```
hudi_options = {
    'useSparkDataSink': True,
    'hoodie.table.name': <table_name>,
    'hoodie.datasource.write.storage.type': 'COPY_ON_WRITE',
    'hoodie.datasource.write.recordkey.field': 'product_id',
    'hoodie.datasource.write.table.name': <table_name>,
    'hoodie.datasource.write.operation': 'upsert',
    'hoodie.datasource.write.precombine.field': 'updated_at',
    'hoodie.datasource.write.hive_style_partitioning': 'true',
    'hoodie.upsert.shuffle.parallelism': 2,
    'hoodie.insert.shuffle.parallelism': 2,
    'hoodie.datasource.hive_sync.enable': 'true',
    'hoodie.datasource.hive_sync.database': <database_name>,
    'hoodie.datasource.hive_sync.table': <table_name>,
    'hoodie.datasource.hive_sync.use_jdbc': 'false',
    'hoodie.datasource.hive_sync.mode': 'hms'}

glueContext.write_data_frame.from_catalog(
    frame = <df_product_inserts>,
    database = <database_name>,
    table_name = <table_name>,
    additional_options = hudi_options
)
```

write_dynamic_frame_from_jdbc_conf

`write_dynamic_frame_from_jdbc_conf(frame, catalog_connection, connection_options={}, redshift_tmp_dir = "", transformation_ctx = "", catalog_id = None)`

Escribe y devuelve un `DynamicFrame` mediante la información de la conexión JDBC especificada.

- `frame`: el `DynamicFrame` que se va a escribir.
- `catalog_connection`: conexión al catálogo que se va a utilizar.
- `connection_options`: opciones de conexión, como la tabla de rutas y bases de datos (opcional). Para obtener más información, consulte Tipos de conexión y opciones para ETL en AWS Glue para Spark.
- `redshift_tmp_dir`: directorio provisional de Amazon Redshift que se va a utilizar (opcional).
- `transformation_ctx`: contexto de transformación que se va a utilizar (opcional).
- `catalog_id`: ID de catálogo (ID de cuenta) del Catálogo de datos al que se accede. Cuando el valor es Ninguno, se utiliza el ID de cuenta predeterminado del intermediario.

write_from_jdbc_conf

`write_from_jdbc_conf(frame_or_dfc, catalog_connection, connection_options={}, redshift_tmp_dir = "", transformation_ctx = "", catalog_id = None)`

Escribe y devuelve un `DynamicFrame` o `DynamicFrameCollection` mediante la información de la conexión JDBC especificada.

- `frame_or_dfc`: el `DynamicFrame` o la `DynamicFrameCollection` que se van a escribir.
- `catalog_connection`: conexión al catálogo que se va a utilizar.
- `connection_options`: opciones de conexión, como la tabla de rutas y bases de datos (opcional). Para obtener más información, consulte Tipos de conexión y opciones para ETL en AWS Glue para Spark.
- `redshift_tmp_dir`: directorio provisional de Amazon Redshift que se va a utilizar (opcional).
- `transformation_ctx`: contexto de transformación que se va a utilizar (opcional).
- `catalog_id`: ID de catálogo (ID de cuenta) del Catálogo de datos al que se accede. Cuando el valor es Ninguno, se utiliza el ID de cuenta predeterminado del intermediario.

Referencia de transformaciones de PySpark de AWS Glue

AWS Glue proporciona las siguientes transformaciones integradas que puede utilizar en operaciones de ETL de PySpark. Los datos pasan de transformación en transformación en una estructura de datos denominada DynamicFrame, que es una extensión de `DataFrame` de Apache Spark SQL. `DynamicFrame` contiene sus datos y usted hace referencia a su esquema para procesar los datos.

La mayoría de estas transformaciones también existen como métodos de la clase `DynamicFrame`. Para obtener más información, consulte Transformación de DynamicFrame.

- Clase de base GlueTransform
- Clase ApplyMapping
- Clase DropFields
- Clase DropNullFields
- Clase ErrorsAsDynamicFrame
- Clase de EvaluateDataQuality
- Clase FillMissingValues
- Clase de filtro
- Clase FindIncrementalMatches
- Clase FindMatches
- Clase FlatMap
- Clase Join
- Clase Map
- Clase MapToCollection
- mergeDynamicFrame
- Clase Relationalize
- Clase RenameField
- Clase ResolveChoice
- Clase SelectFields
- Clase SelectFromCollection
- Clase simplify_ddb_json
- Clase Spigot
- Clase SplitFields

- Clase SplitRows
- Clase Unbox
- Clase UnnestFrame

Clase de base GlueTransform

La clase de base de la que heredan todas las clases de `awsglue.transforms`.

Todas las clases definen un método `__call__`. Pueden anular los métodos de la clase `GlueTransform` identificados en las siguientes secciones o bien, se invocan de forma predeterminada mediante el nombre de la clase.

Métodos

- apply(cls, *args, **kwargs)
- name(cls)
- describeArgs(cls)
- describeReturn(cls)
- describeTransform(cls)
- describeErrors(cls)
- describe(cls)

apply(cls, *args, **kwargs)

Aplica la transformación y, para ello, invoca a la clase de transformación y devuelve el resultado.

- `cls`: el objeto de la clase `self`.

name(cls)

Devuelve el nombre de la clase de transformación derivada.

- `cls`: el objeto de la clase `self`.

describeArgs(cls)

- `cls`: el objeto de la clase `self`.

Devuelve una lista de diccionarios, cada uno de los cuales se corresponde con un argumento designado, con el siguiente formato:

```
[
  {
    "name": "(name of argument)",
    "type": "(type of argument)",
    "description": "(description of argument)",
    "optional": "(Boolean, True if the argument is optional)",
    "defaultValue": "(Default value string, or None)(String; the default value, or
 None)"
  },
...
]
```

Genera una excepción `NotImplementedError` cuando se invoca en una transformación derivada en la que no se implementa.

describeReturn(cls)

- `cls`: el objeto de la clase `self`.

Devuelve un diccionario con información sobre el tipo de devolución, en el siguiente formato:

```
{
  "type": "(return type)",
  "description": "(description of output)"
}
```

Genera una excepción `NotImplementedError` cuando se invoca en una transformación derivada en la que no se implementa.

describeTransform(cls)

Devuelve una cadena que describe la transformación.

- `cls`: el objeto de la clase `self`.

Genera una excepción `NotImplementedError` cuando se invoca en una transformación derivada en la que no se implementa.

describeErrors(cls)

- `cls`: el objeto de la clase `self`.

Devuelve una lista de diccionarios donde cada uno de los cuales describe una posible excepción que genera esta transformación, con el siguiente formato:

```
[
  {
    "type": "(type of error)",
    "description": "(description of error)"
  },
...
]
```

describe(cls)

- `cls`: el objeto de la clase `self`.

Devuelve un objeto con el siguiente formato:

```
{
  "transform" : {
    "name" : cls.name( ),
    "args" : cls.describeArgs( ),
    "returns" : cls.describeReturn( ),
    "raises" : cls.describeErrors( ),
    "location" : "internal"
  }
}
```

Clase ApplyMapping

Aplica un mapeo en un `DynamicFrame`.

Ejemplo

Recomendamos que se utilice el método `DynamicFrame.apply_mapping()` para aplicar una asignación en un `DynamicFrame`. Para ver un ejemplo de código, consulte Ejemplo: uso de apply_mapping para cambiar el nombre de los campos y cambiar los tipos de campos.

Métodos

- __call__
- apply
- nombre
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- Describir

__call__(frame, mappings, transformation_ctx = "", info = "", stageThreshold = 0, totalThreshold = 0)

Aplica un mapeo declarativo a un `DynamicFrame` especificado.

- `frame`: `DynamicFrame` donde se aplica la asignación (obligatorio).
- `mappings`: una lista de tuplas de asignación (obligatorio). Cada una consta de (columna de origen, tipo de origen, columna de destino, tipo de destino).

  Si la columna de origen tiene un punto "`.`" en el nombre, se debe colocar acentos graves "`` ` ``" a su alrededor. Por ejemplo, para asignar `this.old.name` (cadena) a `thisNewName`, debe utilizar las siguientes tuplas:

  ```
  ("`this.old.name`", "string", "thisNewName", "string")
  ```

- `transformation_ctx`: cadena única que se utiliza para identificar la información del estado (opcional).
- `info`: cadena que está asociada con errores en la transformación (opcional).
- `stageThreshold`: cantidad máxima de errores que se puede producir en la transformación antes de que se determine que es errónea (opcional). El rol predeterminado es cero.
- `totalThreshold`: cantidad máxima de errores que se pueden producir en total antes de que se determine que el proceso es erróneo (opcional). El rol predeterminado es cero.

Devuelve solo los campos del `DynamicFrame` especificados en las tuplas de "asignación".

apply(cls, *args, **kwargs)

Heredado de `GlueTransform` apply.

name(cls)

Heredado de `GlueTransform` nombre.

describeArgs(cls)

Heredado de `GlueTransform` describeArgs.

describeReturn(cls)

Heredado de `GlueTransform` describeReturn.

describeTransform(cls)

Heredado de `GlueTransform` describeTransform.

describeErrors(cls)

Heredado de `GlueTransform` describeErrors.

describe(cls)

Heredado de `GlueTransform` describe.

Clase DropFields

Descarta campos en un `DynamicFrame`.

Ejemplo

Recomendamos que se utilice el método `DynamicFrame.drop_fields()` para descartar campos de un `DynamicFrame`. Para ver un ejemplo de código, consulte Ejemplo: uso de drop_fields para descartar campos de un `DynamicFrame`.

Métodos

- __call__
- apply
- nombre

- describeArgs
- describeReturn
- describeTransform
- describeErrors
- Describir

__call__(frame, paths, transformation_ctx = "", info = "", stageThreshold = 0, totalThreshold = 0)

Descarta nodos en un `DynamicFrame`.

- `frame`: `DynamicFrame` donde se descartan los nodos (obligatorio).
- `paths`:lista de rutas completas a los nodos que se descartarán (obligatorio).
- `transformation_ctx`: cadena única que se utiliza para identificar la información del estado (opcional).
- `info`: cadena que está asociada a errores en la transformación (opcional).
- `stageThreshold`: cantidad máxima de errores que se puede producir en la transformación antes de que se determine que es errónea (opcional). El rol predeterminado es cero.
- `totalThreshold`: cantidad máxima de errores que se pueden producir en total antes de que se determine que el proceso es erróneo (opcional). El rol predeterminado es cero.

Devuelve un `DynamicFrame` nuevo sin los campos especificados.

apply(cls, *args, **kwargs)

Heredado de `GlueTransform` apply.

name(cls)

Heredado de `GlueTransform` nombre.

describeArgs(cls)

Heredado de `GlueTransform` describeArgs.

describeReturn(cls)

Heredado de `GlueTransform` describeReturn.

describeTransform(cls)

Heredado de `GlueTransform` describeTransform.

describeErrors(cls)

Heredado de `GlueTransform` describeErrors.

describe(cls)

Heredado de `GlueTransform` describe.

Clase DropNullFields

Descarta todos los campos con valores Null en un `DynamicFrame` cuyo tipo es `NullType`. Son campos incompletos o con valores Null en cada registro del conjunto de datos de `DynamicFrame`.

Ejemplo

En este ejemplo se utiliza `DropNullFields` para crear un `DynamicFrame` nuevo donde los campos de tipo `NullType` se han descartado. Para demostrar `DropNullFields`, agregamos una columna nueva denominada `empty_column` con tipo Null al conjunto de datos `persons` ya cargado.

> **Note**
>
> Para acceder al conjunto de datos utilizado en este ejemplo, consulte Código de ejemplo: unión de los datos y establecimiento de relaciones entre ellos y siga las instrucciones en Paso 1: Rastrear los datos del bucket de Amazon S3.

```
# Example: Use DropNullFields to create a new DynamicFrame without NullType fields

from pyspark.context import SparkContext
from awsglue.context import GlueContext
from pyspark.sql.functions import lit
from pyspark.sql.types import NullType
from awsglue.dynamicframe import DynamicFrame
from awsglue.transforms import DropNullFields

# Create GlueContext
sc = SparkContext.getOrCreate()
```

```
glueContext = GlueContext(sc)

# Create DynamicFrame
persons = glueContext.create_dynamic_frame.from_catalog(
    database="legislators", table_name="persons_json"
)
print("Schema for the persons DynamicFrame:")
persons.printSchema()

# Add new column "empty_column" with NullType
persons_with_nulls = persons.toDF().withColumn("empty_column",
 lit(None).cast(NullType()))
persons_with_nulls_dyf = DynamicFrame.fromDF(persons_with_nulls, glueContext,
 "persons_with_nulls")
print("Schema for the persons_with_nulls_dyf DynamicFrame:")
persons_with_nulls_dyf.printSchema()

# Remove the NullType field
persons_no_nulls = DropNullFields.apply(persons_with_nulls_dyf)
print("Schema for the persons_no_nulls DynamicFrame:")
persons_no_nulls.printSchema()
```

Output

```
Schema for the persons DynamicFrame:
root
|-- family_name: string
|-- name: string
|-- links: array
|    |-- element: struct
|    |    |-- note: string
|    |    |-- url: string
|-- gender: string
|-- image: string
|-- identifiers: array
|    |-- element: struct
|    |    |-- scheme: string
|    |    |-- identifier: string
|-- other_names: array
|    |-- element: struct
|    |    |-- lang: string
|    |    |-- note: string
|    |    |-- name: string
```

```
|-- sort_name: string
|-- images: array
|    |-- element: struct
|    |    |-- url: string
|-- given_name: string
|-- birth_date: string
|-- id: string
|-- contact_details: array
|    |-- element: struct
|    |    |-- type: string
|    |    |-- value: string
|-- death_date: string

Schema for the persons_with_nulls_dyf DynamicFrame:
root
|-- family_name: string
|-- name: string
|-- links: array
|    |-- element: struct
|    |    |-- note: string
|    |    |-- url: string
|-- gender: string
|-- image: string
|-- identifiers: array
|    |-- element: struct
|    |    |-- scheme: string
|    |    |-- identifier: string
|-- other_names: array
|    |-- element: struct
|    |    |-- lang: string
|    |    |-- note: string
|    |    |-- name: string
|-- sort_name: string
|-- images: array
|    |-- element: struct
|    |    |-- url: string
|-- given_name: string
|-- birth_date: string
|-- id: string
|-- contact_details: array
|    |-- element: struct
|    |    |-- type: string
|    |    |-- value: string
|-- death_date: string
```

```
|-- empty_column: null

null_fields ['empty_column']
Schema for the persons_no_nulls DynamicFrame:
root
|-- family_name: string
|-- name: string
|-- links: array
|    |-- element: struct
|    |    |-- note: string
|    |    |-- url: string
|-- gender: string
|-- image: string
|-- identifiers: array
|    |-- element: struct
|    |    |-- scheme: string
|    |    |-- identifier: string
|-- other_names: array
|    |-- element: struct
|    |    |-- lang: string
|    |    |-- note: string
|    |    |-- name: string
|-- sort_name: string
|-- images: array
|    |-- element: struct
|    |    |-- url: string
|-- given_name: string
|-- birth_date: string
|-- id: string
|-- contact_details: array
|    |-- element: struct
|    |    |-- type: string
|    |    |-- value: string
|-- death_date: string
```

Métodos

- __call__
- apply
- nombre
- describeArgs

- describeReturn
- describeTransform
- describeErrors
- Describir

__call__(frame, transformation_ctx = "", info = "", stageThreshold = 0, totalThreshold = 0)

Descarta todos los campos con valores Null en un `DynamicFrame` cuyo tipo es `NullType`. Son campos incompletos o con valores Null en cada registro del conjunto de datos de `DynamicFrame`.

- `frame`: `DynamicFrame` donde se descartan los campos con valores Null (obligatorio).
- `transformation_ctx`: cadena única que se utiliza para identificar la información del estado (opcional).
- `info`: cadena que está asociada a errores en la transformación (opcional).
- `stageThreshold`: cantidad máxima de errores que se puede producir en la transformación antes de que se determine que es errónea (opcional). El rol predeterminado es cero.
- `totalThreshold`: cantidad máxima de errores que se pueden producir en total antes de que se determine que el proceso es erróneo (opcional). El rol predeterminado es cero.

Devuelve un `DynamicFrame` nuevo sin campos con valores Null.

apply(cls, *args, **kwargs)

- `cls`: cls

name(cls)

- `cls`: cls

describeArgs(cls)

- `cls`: cls

describeReturn(cls)

- `cls`: cls

describeTransform(cls)

- `cls`: cls

describeErrors(cls)

- `cls`: cls

describe(cls)

- `cls`: cls

Clase ErrorsAsDynamicFrame

Devuelve un `DynamicFrame` que contiene registros anidados de errores que ocurrieron mientras se creaba el `DynamicFrame` de origen.

Ejemplo

Le recomendamos que utilice el método `DynamicFrame.errorsAsDynamicFrame()` para recuperar y ver los registros de errores. Para ver un ejemplo de código, consulte Ejemplo: uso de errorsAsDynamicFrame para ver los registros de errores.

Métodos

- __call__
- apply
- nombre
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- Describir

__call__(frame)

Devuelve un `DynamicFrame` que contiene registros de errores anidados relacionados con el `DynamicFrame` de origen.

- `frame`: `DynamicFrame` de origen (obligatorio).

apply(cls, *args, **kwargs)

- `cls`: cls

name(cls)

- `cls`: cls

describeArgs(cls)

- `cls`: cls

describeReturn(cls)

- `cls`: cls

describeTransform(cls)

- `cls`: cls

describeErrors(cls)

- `cls`: cls

describe(cls)

- `cls`: cls

Clase de EvaluateDataQuality

Evalúa un conjunto de reglas de calidad de datos comparándolo con un `DynamicFrame` y devuelve un `DynamicFrame` nuevo con los resultados de la evaluación.

Ejemplo

En el siguiente código de ejemplo, se muestra cómo evaluar la calidad de los datos de un `DynamicFrame` y, a continuación, ver los resultados de la calidad de los datos.

```
from awsglue.transforms import *
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsgluedq.transforms import EvaluateDataQuality

#Create Glue context
sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

# Define DynamicFrame
legislatorsAreas = glueContext.create_dynamic_frame.from_catalog(
    database="legislators", table_name="areas_json")

# Create data quality ruleset
ruleset = """Rules = [ColumnExists "id", IsComplete "id"]"""

# Evaluate data quality
dqResults = EvaluateDataQuality.apply(
    frame=legislatorsAreas,
    ruleset=ruleset,
    publishing_options={
        "dataQualityEvaluationContext": "legislatorsAreas",
        "enableDataQualityCloudWatchMetrics": True,
        "enableDataQualityResultsPublishing": True,
        "resultsS3Prefix": "amzn-s3-demo-bucket1",
    },
)


# Inspect data quality results
dqResults.printSchema()
dqResults.toDF().show()
```

Output

```
root
|-- Rule: string
|-- Outcome: string
|-- FailureReason: string
|-- EvaluatedMetrics: map
|    |-- keyType: string
|    |-- valueType: double


+----------------------+-------+-------------+--------------------------------------+
|Rule                  |Outcome|FailureReason|EvaluatedMetrics                      |
+----------------------+-------+-------------+--------------------------------------+
|ColumnExists "id"     |Passed |null         |{}                                    |
|IsComplete "id"       |Passed |null         |{Column.first_name.Completeness -> 1.0}|
+----------------------+-------+-------------+--------------------------------------+
```

Métodos

- __call__
- apply
- nombre
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- describe

__call__(frame, ruleset, publishing_options = {})

- `frame`: el `DynamicFrame` del que desea evaluar la calidad de los datos.
- `ruleset`: un conjunto de reglas de lenguaje de definición de calidad de datos (DQDL) en formato de cadena. Para obtener más información sobre DQDL, consulte la guía de Referencia del lenguaje de definición de calidad de datos (DQDL).
- `publishing_options`: un diccionario que especifica las siguientes opciones para publicar los resultados y las métricas de la evaluación:

- `dataQualityEvaluationContext`: una cadena que especifica el espacio de nombres en el que AWS Glue debe publicar las métricas de Amazon CloudWatch y los resultados de calidad de los datos. Las métricas agregadas aparecen en CloudWatch, mientras que los resultados completos aparecen en la interfaz de AWS Glue Studio.
  - Obligatorio: no
  - Valor predeterminado: `default_context`
- `enableDataQualityCloudWatchMetrics`: especifica si los resultados de la evaluación de la calidad de los datos deben publicarse en CloudWatch. Especifique un espacio de nombres para las métricas mediante la opción `dataQualityEvaluationContext`.
  - Obligatorio: no
  - Valor predeterminado: False
- `enableDataQualityResultsPublishing`: especifica si los resultados de calidad de los datos deben estar visibles en la pestaña Data Quality (Calidad de datos) de la interfaz de AWS Glue Studio.
  - Obligatorio: no
  - Valor predeterminado: true
- `resultsS3Prefix`: especifica la ubicación de Amazon S3 en la que AWS Glue puede escribir los resultados de la evaluación de la calidad de los datos.
  - Obligatorio: no
  - Valor predeterminado: "" (cadena vacía)

apply(cls, *args, **kwargs)

Heredado de `GlueTransform` apply.

name(cls)

Heredado de `GlueTransform` nombre.

describeArgs(cls)

Heredado de `GlueTransform` describeArgs.

describeReturn(cls)

Heredado de `GlueTransform` describeReturn.

describeTransform(cls)

Heredado de `GlueTransform` describeTransform.

describeErrors(cls)

Heredado de `GlueTransform` describeErrors.

describe(cls)

Heredado de `GlueTransform` describe.

Clase FillMissingValues

La clase `FillMissingValues` localiza valores nulos y cadenas vacías en un `DynamicFrame` especificado y utiliza métodos de machine learning, como regresión lineal y bosque aleatorio (random forest), para predecir los valores faltantes. El trabajo de ETL utiliza los valores del conjunto de datos de entrada para formar al modelo de machine learning, que luego predice cuáles deben ser los valores que faltan.

> **Tip**
>
> Si utiliza conjuntos de datos progresivos, cada conjunto progresivo se utiliza como datos de formación para el modelo de machine learning, por lo que es posible que los resultados no sean tan precisos.

Para importar:

```
from awsglueml.transforms import FillMissingValues
```

Métodos

- Aplicar

aplicar (frame, missing_values_column, output_column ="", transformation_ctx ="", info ="", stageThreshold = 0, totalThreshold = 0)

Rellena los valores que faltan de un marco dinámico en una columna especificada y devuelve un nuevo marco con estimaciones en una nueva columna. Para filas sin valores faltantes, el valor de la columna especificada se duplica en la nueva columna.

- `frame`: el `DynamicFrame` en el que rellenar los valores que faltan. Obligatorio.
- `missing_values_column`: la columna que contiene valores faltantes (valores `null` y cadenas vacías). Obligatorio.
- `output_column`: el nombre de la nueva columna que contendrá valores estimados para todas las filas cuyo valor faltaba. Opcional; el valor predeterminado es el nombre de `missing_values_column` con el sufijo `"_filled"`.
- `transformation_ctx`: cadena única que se utiliza para identificar la información del estado (opcional).
- `info`: cadena que está asociada a errores en la transformación (opcional).
- `stageThreshold`: número máximo de errores que se pueden producir en la transformación antes de que se determine que es errónea (opcional, el valor predeterminado es cero).
- `totalThreshold`: número máximo de errores que se pueden producir en total antes de que se determine que el proceso es erróneo (opcional, el valor predeterminado es cero).

Devuelve un nuevo `DynamicFrame` con una columna adicional que contiene estimaciones para filas con valores faltantes y el valor actual para otras filas.

Clase de filtro

Crea un `DynamicFrame` nuevo que contiene registros de la entrada `DynamicFrame` que cumplen una función de predicado especificada.

Ejemplo

Recomendamos que se utilice el método `DynamicFrame.filter()` para filtrar registros en un `DynamicFrame`. Para ver un ejemplo de código, consulte Ejemplo: uso de filter para obtener una selección filtrada de campos.

Métodos

- __call__
- apply
- nombre
- describeArgs
- describeReturn

- describeTransform
- describeErrors
- describe

__call__(frame, f, transformation_ctx="", info="", stageThreshold=0, totalThreshold=0))

Devuelve un `DynamicFrame` nuevo que se crea mediante la selección de registros de la entrada `DynamicFrame` que cumplen una función de predicado especificada.

- `frame`: el `DynamicFrame` de origen al que se va a aplicar la función de filtro especificada (obligatorio).
- `f`: la función de predicado que se aplicará a cada `DynamicRecord` en el `DynamicFrame`. La función debe tomar un `DynamicRecord` como argumento y devolver True (Verdadero) si el `DynamicRecord` cumple los requisitos del filtro o False (Falso) si no los cumple (obligatorio).

  Un `DynamicRecord` representa un registro lógico en un `DynamicFrame`. Es similar a una fila en un `DataFrame` de Spark, salvo que es autodescriptivo y se puede utilizar para datos que no se ajustan a un esquema fijo.
- `transformation_ctx`: cadena única que se utiliza para identificar la información del estado (opcional).
- `info`: cadena que está asociada con errores en la transformación (opcional).
- `stageThreshold`: cantidad máxima de errores que se puede producir en la transformación antes de que se determine que es errónea (opcional). El rol predeterminado es cero.
- `totalThreshold`: cantidad máxima de errores que se pueden producir en total antes de que se determine que el proceso es erróneo (opcional). El rol predeterminado es cero.

apply(cls, *args, **kwargs)

Heredado de `GlueTransform` apply.

name(cls)

Heredado de `GlueTransform` nombre.

describeArgs(cls)

Heredado de `GlueTransform` describeArgs.

describeReturn(cls)

Heredado de `GlueTransform` describeReturn.

describeTransform(cls)

Heredado de `GlueTransform` describeTransform.

describeErrors(cls)

Heredado de `GlueTransform` describeErrors.

describe(cls)

Heredado de `GlueTransform` describe.

Clase FindIncrementalMatches

Identifica registros coincidentes en el `DynamicFrame` existente y progresivo, y crea un nuevo `DynamicFrame` con un identificador exclusivo asignado a cada grupo de registros coincidentes.

Para importar:

```
from awsglueml.transforms import FindIncrementalMatches
```

Métodos

- Aplicar

apply(existingFrame, incrementalFrame, transformId, transformation_ctx = "", info = "", stageThreshold = 0, totalThreshold = 0, enforcedMatches = none, computeMatchConfidenceScores = 0)

Identifica registros coincidentes en el `DynamicFrame` de entrada y crea un nuevo `DynamicFrame` con un identificador exclusivo asignado a cada grupo de registros coincidentes.

- `existingFrame`: el `DynamicFrame` existente y precoincidente para aplicar la transformación FindIncrementalMatches. Obligatorio.
- `incrementalFrame`: el `DynamicFrame` progresivo para aplicar la transformación FindIncrementalMatches para que coincida con el `existingFrame`. Obligatorio.
- `transformId`: el ID único asociado a la transformación FindIncrementalMatches para aplicarlo a los registros del `DynamicFrames`. Obligatorio.

- `transformation_ctx`: cadena única que se utiliza para identificar la información del estadísticas/estado. Opcional.
- `info`: cadena que está asociada a errores en la transformación. Opcional.
- `stageThreshold`: número máximo de errores que se pueden producir en la transformación antes de que se determine que es errónea. Opcional. El rol predeterminado es cero.
- `totalThreshold`: número máximo de errores que se pueden producir en total antes de que se determine que el proceso es erróneo. Opcional. El rol predeterminado es cero.
- `enforcedMatches`: el `DynamicFrame` utilizado para imponer coincidencias. Opcional. El valor predeterminado es Ninguno.
- `computeMatchConfidenceScores`: valor booleano que indica si debe calcularse una puntuación de confianza para cada grupo de registros coincidentes. Opcional. El valor predeterminado es false.

Devuelve un nuevo `DynamicFrame` con un identificador exclusivo asignado a cada grupo de registros coincidentes.

Clase FindMatches

Identifica registros coincidentes en el `DynamicFrame` de entrada y crea un nuevo `DynamicFrame` con un identificador exclusivo asignado a cada grupo de registros coincidentes.

Para importar:

```
from awsglueml.transforms import FindMatches
```

Métodos

- Aplicar

apply(frame, transformId, transformation_ctx = "", info = "", stageThreshold = 0, totalThreshold = 0, enforcedMatches = none, computeMatchConfidenceScores = 0)

Identifica registros coincidentes en el `DynamicFrame` de entrada y crea un nuevo `DynamicFrame` con un identificador exclusivo asignado a cada grupo de registros coincidentes.

- `frame`: el `DynamicFrame` para aplicar la transformación FindMatches. Obligatorio.

- `transformId`: el ID único asociado a la transformación FindMatches para aplicarlo a los registros del `DynamicFrame`. Obligatorio.
- `transformation_ctx`: cadena única que se utiliza para identificar la información del estadísticas/estado. Opcional.
- `info`: cadena que está asociada a errores en la transformación. Opcional.
- `stageThreshold`: número máximo de errores que se pueden producir en la transformación antes de que se determine que es errónea. Opcional. El rol predeterminado es cero.
- `totalThreshold`: número máximo de errores que se pueden producir en total antes de que se determine que el proceso es erróneo. Opcional. El rol predeterminado es cero.
- `enforcedMatches`: el `DynamicFrame` utilizado para imponer coincidencias. Opcional. El valor predeterminado es Ninguno.
- `computeMatchConfidenceScores`: valor booleano que indica si debe calcularse una puntuación de confianza para cada grupo de registros coincidentes. Opcional. El valor predeterminado es false.

Devuelve un nuevo `DynamicFrame` con un identificador exclusivo asignado a cada grupo de registros coincidentes.

Clase FlatMap

Aplica una transformación a cada `DynamicFrame` en una colección. Los resultados no se agrupan en un solo `DynamicFrame`, sino que se conservan como una colección.

Ejemplos de FlatMap

El siguiente fragmento de ejemplo muestra cómo utilizar la transformación `ResolveChoice` en un conjunto de marcos dinámicos cuando se aplica a un `FlatMap`. Los datos utilizados para la entrada se encuentran en el JSON ubicado en el marcador de posición de la dirección Amazon S3 `s3://bucket/path-for-data/sample.json` y contienen los siguientes datos.

Ejemplo de datos JSON

```
[{
    "firstname": "Arnav",
    "lastname": "Desai",
    "address": {
        "street": "6 Anyroad Avenue",
        "city": "London",
```

```
        "state": "England",
        "country": "UK"
    },
    "phone": 17235550101,
    "affiliations": [
        "General Anonymous Example Products",
        "Example Independent Research",
        "Government Department of Examples"
    ]
},
{
    "firstname": "Mary",
    "lastname": "Major",
    "address": {
        "street": "7821 Spot Place",
        "city": "Centerville",
        "state": "OK",
        "country": "US"
    },
    "phone": 19185550023,
    "affiliations": [
        "Example Dot Com",
        "Example Independent Research",
        "Example.io"
    ]
},
{
    "firstname": "Paulo",
    "lastname": "Santos",
    "address": {
        "street": "123 Maple Street",
        "city": "London",
        "state": "Ontario",
        "country": "CA"
    },
    "phone": 12175550181,
    "affiliations": [
        "General Anonymous Example Products",
        "Example Dot Com"
    ]
}]
```

Example Aplique ResolveChoice a una DynamicFrameCollection y muestre el resultado.

```
#Read DynamicFrame
datasource = glueContext.create_dynamic_frame_from_options("s3", connection_options =
 {"paths":["s3://bucket/path/to/file/mysamplejson.json"]}, format="json")
datasource.printSchema()
datasource.show()

## Split to create a DynamicFrameCollection
split_frame=datasource.split_fields(["firstname","lastname","address"],"personal_info","busines
split_frame.keys()
print("---")

## Use FlatMap to run ResolveChoice
kwargs = {"choice": "cast:string"}
flat = FlatMap.apply(split_frame, ResolveChoice, frame_name="frame",
 transformation_ctx='tcx', **kwargs)
flat.keys()

##Select one of the DynamicFrames
personal_info = flat.select("personal_info")
personal_info.printSchema()
personal_info.show()
print("---")

business_info = flat.select("business_info")
business_info.printSchema()
business_info.show()
```

> **Important**
>
> Al llamar a `FlatMap.apply`, el parámetro `frame_name` debe ser `"frame"`. Actualmente no se acepta ningún otro valor.

Ejemplo de resultado

```
root
|-- firstname: string
|-- lastname: string
|-- address: struct
|    |-- street: string
```

```
|    |-- city: string
|    |-- state: string
|    |-- country: string
|-- phone: long
|-- affiliations: array
|    |-- element: string
---
{
    "firstname": "Mary",
    "lastname": "Major",
    "address": {
        "street": "7821 Spot Place",
        "city": "Centerville",
        "state": "OK",
        "country": "US"
    },
    "phone": 19185550023,
    "affiliations": [
        "Example Dot Com",
        "Example Independent Research",
        "Example.io"
    ]
}

{
    "firstname": "Paulo",
    "lastname": "Santos",
    "address": {
        "street": "123 Maple Street",
        "city": "London",
        "state": "Ontario",
        "country": "CA"
    },
    "phone": 12175550181,
    "affiliations": [
        "General Anonymous Example Products",
        "Example Dot Com"
    ]
}
---
root
|-- firstname: string
|-- lastname: string
|-- address: struct
```

```
|    |-- street: string
|    |-- city: string
|    |-- state: string
|    |-- country: string

{
    "firstname": "Mary",
    "lastname": "Major",
    "address": {
        "street": "7821 Spot Place",
        "city": "Centerville",
        "state": "OK",
        "country": "US"
    }
}

{
    "firstname": "Paulo",
    "lastname": "Santos",
    "address": {
        "street": "123 Maple Street",
        "city": "London",
        "state": "Ontario",
        "country": "CA"
    }
}
---
root
|-- phone: long
|-- affiliations: array
|    |-- element: string

{
    "phone": 19185550023,
    "affiliations": [
        "Example Dot Com",
        "Example Independent Research",
        "Example.io"
    ]
}

{
    "phone": 12175550181,
    "affiliations": [
```

```
        "General Anonymous Example Products",
        "Example Dot Com"
    ]
}
```

Métodos

- __call__
- Aplicar
- Nombre
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- Describir

__call__(dfc, BaseTransform, frame_name, transformation_ctx = "", **base_kwargs)

Aplica una transformación a cada `DynamicFrame` en una colección y aplana los resultados.

- `dfc`: el `DynamicFrameCollection` para aplanar (obligatorio).
- `BaseTransform`: una transformación derivada de `GlueTransform` que se aplica a cada miembro de la colección (obligatorio).
- `frame_name`: el nombre del argumento al que se pasan los elementos de la colección (obligatorio).
- `transformation_ctx`: cadena única que se utiliza para identificar la información del estado (opcional).
- `base_kwargs`: argumentos que se pasan a la transformación de base (obligatorio).

Devuelve un nuevo `DynamicFrameCollection` que se crea al aplicar la transformación a cada `DynamicFrame` en la `DynamicFrameCollection` de origen.

apply(cls, *args, **kwargs)

Heredado de `GlueTransform` apply.

name(cls)

Heredado de `GlueTransform` nombre.

describeArgs(cls)

Heredado de `GlueTransform` describeArgs.

describeReturn(cls)

Heredado de `GlueTransform` describeReturn.

describeTransform(cls)

Heredado de `GlueTransform` describeTransform.

describeErrors(cls)

Heredado de `GlueTransform` describeErrors.

describe(cls)

Heredado de `GlueTransform` describe.

Clase Join

Realiza una unión de igualdad en dos `DynamicFrames`.

Ejemplo

Le recomendamos que utilice el método `DynamicFrame.join()` para unir a `DynamicFrames`. Para ver un ejemplo de código, consulte Ejemplo: uso de join para combinar `DynamicFrames`.

Métodos

- __call__
- apply
- nombre
- describeArgs
- describeReturn
- describeTransform
- describeErrors

- Describir

__call__(frame1, frame2, keys1, keys2, transformation_ctx = "")

Realiza una unión de igualdad en dos `DynamicFrames`.

- `frame1`: primer `DynamicFrame` que debe unirse (obligatorio).
- `frame2`: segundo `DynamicFrame` que debe unirse (obligatorio).
- `keys1`: claves que deben unirse en la primera trama (obligatorio).
- `keys2`: claves que deben unirse en la segunda trama (obligatorio).
- `transformation_ctx`: cadena única que se utiliza para identificar la información del estado (opcional).

Devuelve un `DynamicFrame` nuevo que se crea cuando se unen los dos `DynamicFrames`.

apply(cls, *args, **kwargs)

Heredado de `GlueTransform` apply.

name(cls)

Heredado de `GlueTransform` nombre.

describeArgs(cls)

Heredado de `GlueTransform` describeArgs.

describeReturn(cls)

Heredado de `GlueTransform` describeReturn.

describeTransform(cls)

Heredado de `GlueTransform` describeTransform.

describeErrors(cls)

Heredado de `GlueTransform` describeErrors.

describe(cls)

Heredado de `GlueTransform` describe.

Clase Map

Genera un nuevo `DynamicFrame` al aplicar una función a todos los registros de la entrada `DynamicFrame`.

Ejemplo

Recomendamos que se utilice el método `DynamicFrame.map()` para aplicar una función a todos los registros de un `DynamicFrame`. Para ver un ejemplo de código, consulte Ejemplo: uso de map para aplicar una función a cada registro en un `DynamicFrame`.

Métodos

- __call__
- apply
- nombre
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- Describir

__call__(frame, f, transformation_ctx="", info="", stageThreshold=0, totalThreshold=0)

Muestra un nuevo `DynamicFrame` que se obtiene al aplicar la función especificada a todos los `DynamicRecords` en el `DynamicFrame` original.

- `frame`: el `DynamicFrame` original al que se aplica la función de asignación (obligatorio).
- `f`: la función que se aplica a todos los `DynamicRecords` en el `DynamicFrame`. La función debe utilizar un `DynamicRecord` como argumento y devolver un `DynamicRecord` nuevo que se genera por la asignación (obligatorio).

  Un `DynamicRecord` representa un registro lógico en un `DynamicFrame`. Es similar a una fila en un `DataFrame` de Apache Spark, salvo que es autodescriptivo y se puede utilizar para datos que no se ajustan a un esquema fijo.
- `transformation_ctx`: cadena única que se utiliza para identificar la información del estado (opcional).

- `info`: cadena que está asociada a errores en la transformación (opcional).
- `stageThreshold`: cantidad máxima de errores que se puede producir en la transformación antes de que se determine que es errónea (opcional). El rol predeterminado es cero.
- `totalThreshold`: cantidad máxima de errores que se pueden producir en total antes de que se determine que el proceso es erróneo (opcional). El rol predeterminado es cero.

Muestra un nuevo `DynamicFrame` que se obtiene al aplicar la función especificada a todos los `DynamicRecords` en el `DynamicFrame` original.

apply(cls, *args, **kwargs)

Heredado de `GlueTransform` apply.

name(cls)

Heredado de `GlueTransform` nombre.

describeArgs(cls)

Heredado de `GlueTransform` describeArgs.

describeReturn(cls)

Heredado de `GlueTransform` describeReturn.

describeTransform(cls)

Heredado de `GlueTransform` describeTransform.

describeErrors(cls)

Heredado de `GlueTransform` describeErrors.

describe(cls)

Heredado de `GlueTransform` describe.

Clase MapToCollection

Aplica una transformación a cada `DynamicFrame` en la `DynamicFrameCollection` especificada.

Métodos

- __call__

- Aplicar
- Nombre
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- Describir

__call__(dfc, BaseTransform, frame_name, transformation_ctx = "", **base_kwargs)

Aplica una función de transformación a cada `DynamicFrame` en la `DynamicFrameCollection` especificada.

- `dfc`: la `DynamicFrameCollection` sobre la que se aplica la función de transformación (obligatorio).
- `callable`: función de transformación que se puede invocar y que se aplica a cada miembro de la colección (obligatorio).
- `transformation_ctx`: cadena única que se utiliza para identificar la información del estado (opcional).

Devuelve un nuevo `DynamicFrameCollection` que se crea al aplicar la transformación a cada `DynamicFrame` en la `DynamicFrameCollection` de origen.

apply(cls, *args, **kwargs)

Heredado de `GlueTransform` apply

name(cls)

Heredado de `GlueTransform` nombre.

describeArgs(cls)

Heredado de `GlueTransform` describeArgs.

describeReturn(cls)

Heredado de `GlueTransform` describeReturn.

describeTransform(cls)

Heredado de `GlueTransform` describeTransform.

describeErrors(cls)

Heredado de `GlueTransform` describeErrors.

describe(cls)

Heredado de `GlueTransform` describe.

Clase Relationalize

Aplana un esquema anidado en un `DynamicFrame` y dinamiza columnas de matriz a partir del fotograma aplanado.

Ejemplo

Le recomendamos que utilice el método `DynamicFrame.relationalize()` para relacionalizar un `DynamicFrame`. Para ver un ejemplo de código, consulte Ejemplo: utilice relacionalizar para aplanar un esquema anidado en un `DynamicFrame`.

Métodos

- __call__
- apply
- nombre
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- describe

__call__(frame, staging_path=None, name='roottable', options=None, transformation_ctx = "", info = "", stageThreshold = 0, totalThreshold = 0)

Establece relaciones en un `DynamicFrame` y produce una lista de fotogramas que se genera al aplanar las columnas anidadas y dinamizar las columnas de matriz. La columna de matriz

dinamizada puede unirse a la tabla raíz con la clave de combinación generada durante la fase de desanidado.

- `frame`: el `DynamicFrame` donde establecer relaciones (obligatorio).
- `staging_path`: ruta en la que el método puede almacenar las particiones de las tablas dinamizadas en formato CSV (opcional). Las tablas dinamizadas se leen desde esta ruta.
- `name`: el nombre de la tabla de raíz (opcional).
- `options`: diccionario de parámetros opcionales. En la actualidad no se utiliza.
- `transformation_ctx`: cadena única que se utiliza para identificar la información del estado (opcional).
- `info`: cadena que está asociada a errores en la transformación (opcional).
- `stageThreshold`: cantidad máxima de errores que se puede producir en la transformación antes de que se determine que es errónea (opcional). El rol predeterminado es cero.
- `totalThreshold`: cantidad máxima de errores que se pueden producir en total antes de que se determine que el proceso es erróneo (opcional). El rol predeterminado es cero.

apply(cls, *args, **kwargs)

Heredado de `GlueTransform` apply.

name(cls)

Heredado de `GlueTransform` nombre.

describeArgs(cls)

Heredado de `GlueTransform` describeArgs.

describeReturn(cls)

Heredado de `GlueTransform` describeReturn.

describeTransform(cls)

Heredado de `GlueTransform` describeTransform.

describeErrors(cls)

Heredado de `GlueTransform` describeErrors.

describe(cls)

Heredado de `GlueTransform` describe.

Clase RenameField

Cambia el nombre de un nodo dentro de un `DynamicFrame`.

Ejemplo

Recomendamos que se utilice el método `DynamicFrame.rename_field()` para renombrar registros en un `DynamicFrame`. Para ver un ejemplo de código, consulte Ejemplo: utilice rename_field para cambiar el nombre de los campos de un `DynamicFrame`.

Métodos

- __call__
- apply
- nombre
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- describe

__call__(frame, old_name, new_name, transformation_ctx = "", info = "", stageThreshold = 0, totalThreshold = 0)

Cambia el nombre de un nodo dentro de un `DynamicFrame`.

- `frame`: `DynamicFrame` donde se cambia el nombre de un nodo (obligatorio).
- `old_name`: ruta completa al nodo cuyo nombre se quiere cambiar (obligatorio).

  Si el nombre anterior contiene puntos, RenameField no funcionará a menos que lo ponga entre acentos graves (``). Por ejemplo, para reemplazar `this.old.name` por `thisNewName`, llame a RenameField como se indica a continuación:

```
newDyF = RenameField(oldDyF, "`this.old.name`", "thisNewName")
```

- `new_name`: nuevo nombre, incluida la ruta completa (obligatorio).
- `transformation_ctx`: cadena única que se utiliza para identificar la información del estado (opcional).
- `info`: cadena que está asociada a errores en la transformación (opcional).
- `stageThreshold`: cantidad máxima de errores que se puede producir en la transformación antes de que se determine que es errónea (opcional). El rol predeterminado es cero.
- `totalThreshold`: cantidad máxima de errores que se pueden producir en total antes de que se determine que el proceso es erróneo (opcional). El rol predeterminado es cero.

apply(cls, *args, **kwargs)

Heredado de `GlueTransform` apply.

name(cls)

Heredado de `GlueTransform` nombre.

describeArgs(cls)

Heredado de `GlueTransform` describeArgs.

describeReturn(cls)

Heredado de `GlueTransform` describeReturn.

describeTransform(cls)

Heredado de `GlueTransform` describeTransform.

describeErrors(cls)

Heredado de `GlueTransform` describeErrors.

describe(cls)

Heredado de `GlueTransform` describe.

Clase ResolveChoice

Resuelve un tipo de elección dentro de un elemento `DynamicFrame`.

Ejemplo

Se recomienda utilizar el método `DynamicFrame.resolveChoice()` para gestionar los campos que contienen varios tipos en un `DynamicFrame`. Para ver un ejemplo de código, consulte Ejemplo: utilice resolveChoice para gestionar una columna que contiene varios tipos.

Métodos

- __call__
- apply
- nombre
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- describe

__call__(frame, specs = none, choice = "", transformation_ctx = "", info = "", stageThreshold = 0, totalThreshold = 0)

Proporciona información para resolver tipos ambiguos dentro de un elemento `DynamicFrame`. Devuelve el elemento `DynamicFrame` resultante.

- `frame`: el elemento `DynamicFrame` en el que debe resolverse el tipo de elección (obligatorio).
- `specs`: lista de ambigüedades concretas que deben resolverse; cada una en forma de tupla: `(path, action)`. El valor de `path` identifica un elemento ambiguo concreto, mientras que el valor de `action` identifica la resolución correspondiente.

  Solo se puede utilizar el parámetro `spec` y el parámetro `choice`. Si el parámetro `spec` no es `None`, el parámetro `choice` tiene que ser una cadena vacía. Y viceversa, si el parámetro `choice` no es una cadena vacía, el parámetro `spec` tiene que ser `None`. Si no se proporciona ninguno de estos parámetros, AWS Glue intenta analizar el esquema y utilizarlo para resolver ambigüedades.

  Puede especificar una de las cuatro estrategias de resolución en la parte `action` de una tupla `specs`:

  - `cast`: le permite especificar el tipo al que se realizará una conversión (por ejemplo, `cast:int`).

- `make_cols`: resuelve una posible ambigüedad al aplanar los datos. Por ejemplo, si `columnA` puede ser tanto un `int` como una `string`, la resolución consiste en producir dos columnas llamadas `columnA_int` y `columnA_string` en el elemento `DynamicFrame` resultante.
- `make_struct`: resuelve una posible ambigüedad con una estructura para representar los datos. Por ejemplo, si los datos de una columna pueden ser tanto un `int` como una `string`, si usa la acción `make_struct` generará una columna de estructuras en el elemento `DynamicFrame` resultante, en la que cada estructura contendrá un `int` y una `string`.
- `project`: resuelve una posible ambigüedad conservando solo los valores de un tipo especificado en el `DynamicFrame` resultante. Por ejemplo, si los datos de una columna `ChoiceType` pueden ser un `int` o una `string`, al especificar una acción `project:string` se descartan los valores del `DynamicFrame` que no son del tipo `string`.

Si en `path` se identifica una matriz, incluya corchetes vacíos después del nombre de la matriz para evitar ambigüedades. Por ejemplo, suponga que está trabajando con datos estructurados tal y como se indica a continuación:

```
"myList": [
  { "price": 100.00 },
  { "price": "$100.00" }
]
```

Puede seleccionar la versión numérica en vez de la de cadena del precio si configura `path` en `"myList[].price"` y `action` en `"cast:double"`.

- `choice`: la acción de resolución predeterminada si el parámetro `specs` es `None`. Si el parámetro `specs` no es `None`, este parámetro no tiene que establecerse en nada, sino que debe dejarse como una cadena vacía.

  Además de las acciones descritas anteriormente para `specs`, este argumento también admite la siguiente acción:

  - `MATCH_CATALOG`: intenta convertir cada `ChoiceType` al tipo correspondiente en la tabla de Data Catalog especificada.
- `database`: la base de datos del catálogo de datos de AWS Glue que se utilizará con la elección `MATCH_CATALOG` (obligatoria para `MATCH_CATALOG`).
- `table_name`: el nombre de la tabla del catálogo de datos de AWS Glue que se utilizará con la elección `MATCH_CATALOG` (obligatoria para `MATCH_CATALOG`).

- `transformation_ctx`: cadena única que se utiliza para identificar la información del estado (opcional).
- `info`: cadena que está asociada a errores en la transformación (opcional).
- `stageThreshold`: cantidad máxima de errores que se puede producir en la transformación antes de que se determine que es errónea (opcional). El rol predeterminado es cero.
- `totalThreshold`: cantidad máxima de errores que se pueden producir en total antes de que se determine que el proceso es erróneo (opcional). El rol predeterminado es cero.

apply(cls, *args, **kwargs)

Heredado de `GlueTransform` apply.

name(cls)

Heredado de `GlueTransform` nombre.

describeArgs(cls)

Heredado de `GlueTransform` describeArgs.

describeReturn(cls)

Heredado de `GlueTransform` describeReturn.

describeTransform(cls)

Heredado de `GlueTransform` describeTransform.

describeErrors(cls)

Heredado de `GlueTransform` describeErrors.

describe(cls)

Heredado de `GlueTransform` describe.

Clase SelectFields

La clase `SelectFields` crea un `DynamicFrame` nuevo a partir de un `DynamicFrame` existente, y conserva solo los campos que se especifican. `SelectFields` brinda una funcionalidad similar a la de una instrucción `SELECT` en SQL.

Ejemplo

Recomendamos que se utilice el método `DynamicFrame.select_fields()` para seleccionar campos de un `DynamicFrame`. Para ver un ejemplo de código, consulte Ejemplo: uso de select_fields para crear un `DynamicFrame` nuevo con los campos elegidos.

Métodos

- __call__
- apply
- nombre
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- Describir

__call__(frame, paths, transformation_ctx = "", info = "", stageThreshold = 0, totalThreshold = 0)

Obtiene campos (nodos) en un `DynamicFrame`.

- `frame`: `DynamicFrame` donde se seleccionan los campos (obligatorio).
- `paths`: una lista de rutas completas a los campos que se van a seleccionar (obligatorio).
- `transformation_ctx`: cadena única que se utiliza para identificar la información del estado (opcional).
- `info`: cadena que está asociada con errores en la transformación (opcional).
- `stageThreshold`: cantidad máxima de errores que se puede producir en la transformación antes de que se determine que es errónea (opcional). El rol predeterminado es cero.
- `totalThreshold`: cantidad máxima de errores que se pueden producir en total antes de que se determine que el proceso es erróneo (opcional). El rol predeterminado es cero.

Devuelve un `DynamicFrame` nuevo que contiene solo los campos especificados.

apply(cls, *args, **kwargs)

Heredado de `GlueTransform` apply.

name(cls)

Heredado de `GlueTransform` nombre.

describeArgs(cls)

Heredado de `GlueTransform` describeArgs.

describeReturn(cls)

Heredado de `GlueTransform` describeReturn.

describeTransform(cls)

Heredado de `GlueTransform` describeTransform.

describeErrors(cls)

Heredado de `GlueTransform` describeErrors.

describe(cls)

Heredado de `GlueTransform` describe.

Clase SelectFromCollection

Selecciona un `DynamicFrame` en un `DynamicFrameCollection`.

Ejemplo

En este ejemplo se utiliza `SelectFromCollection` para seleccionar un `DynamicFrame` de una`DynamicFrameCollection`.

Conjunto de datos de ejemplo

En el ejemplo se seleccionan dos `DynamicFrames` de un `DynamicFrameCollection` llamado `split_rows_collection`. A continuación se ofrece una lista de las claves de `split_rows_collection`.

```
dict_keys(['high', 'low'])
```

Código de ejemplo

```
# Example: Use SelectFromCollection to select
# DynamicFrames from a DynamicFrameCollection

from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.transforms import SelectFromCollection

# Create GlueContext
sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

# Select frames and inspect entries
frame_low = SelectFromCollection.apply(dfc=split_rows_collection, key="low")
frame_low.toDF().show()

frame_high = SelectFromCollection.apply(dfc=split_rows_collection, key="high")
frame_high.toDF().show()
```

Output

```
+---+-----+-----------------------+-----------------------+
| id|index|contact_details.val.type|contact_details.val.value|
+---+-----+-----------------------+-----------------------+
|  1|    0|                    fax|           202-225-3307|
|  1|    1|                  phone|           202-225-5731|
|  2|    0|                    fax|           202-225-3307|
|  2|    1|                  phone|           202-225-5731|
|  3|    0|                    fax|           202-225-3307|
|  3|    1|                  phone|           202-225-5731|
|  4|    0|                    fax|           202-225-3307|
|  4|    1|                  phone|           202-225-5731|
|  5|    0|                    fax|           202-225-3307|
|  5|    1|                  phone|           202-225-5731|
|  6|    0|                    fax|           202-225-3307|
|  6|    1|                  phone|           202-225-5731|
|  7|    0|                    fax|           202-225-3307|
|  7|    1|                  phone|           202-225-5731|
|  8|    0|                    fax|           202-225-3307|
|  8|    1|                  phone|           202-225-5731|
|  9|    0|                    fax|           202-225-3307|
|  9|    1|                  phone|           202-225-5731|
```

```
| 10|    0|                    fax|             202-225-6328|
| 10|    1|                  phone|             202-225-4576|
+---+-----+----------------------+-------------------------+
only showing top 20 rows

+---+-----+----------------------+-------------------------+
| id|index|contact_details.val.type|contact_details.val.value|
+---+-----+----------------------+-------------------------+
| 11|    0|                    fax|             202-225-6328|
| 11|    1|                  phone|             202-225-4576|
| 11|    2|                twitter|           RepTrentFranks|
| 12|    0|                    fax|             202-225-6328|
| 12|    1|                  phone|             202-225-4576|
| 12|    2|                twitter|           RepTrentFranks|
| 13|    0|                    fax|             202-225-6328|
| 13|    1|                  phone|             202-225-4576|
| 13|    2|                twitter|           RepTrentFranks|
| 14|    0|                    fax|             202-225-6328|
| 14|    1|                  phone|             202-225-4576|
| 14|    2|                twitter|           RepTrentFranks|
| 15|    0|                    fax|             202-225-6328|
| 15|    1|                  phone|             202-225-4576|
| 15|    2|                twitter|           RepTrentFranks|
| 16|    0|                    fax|             202-225-6328|
| 16|    1|                  phone|             202-225-4576|
| 16|    2|                twitter|           RepTrentFranks|
| 17|    0|                    fax|             202-225-6328|
| 17|    1|                  phone|             202-225-4576|
+---+-----+----------------------+-------------------------+
only showing top 20 rows
```

Métodos

- __call__
- apply
- nombre
- describeArgs
- describeReturn
- describeTransform
- describeErrors

- describe

__call__(dfc, key, transformation_ctx = "")

Obtiene un `DynamicFrame` de una `DynamicFrameCollection`.

- `dfc`: la `DynamicFrameCollection` de la que el `DynamicFrame` debe seleccionarse (obligatorio).
- `key`: la clave del `DynamicFrame` que se debe seleccionar (obligatorio).
- `transformation_ctx`: cadena única que se utiliza para identificar la información del estado (opcional).

apply(cls, *args, **kwargs)

Heredado de `GlueTransform` apply.

name(cls)

Heredado de `GlueTransform` nombre.

describeArgs(cls)

Heredado de `GlueTransform` describeArgs.

describeReturn(cls)

Heredado de `GlueTransform` describeReturn.

describeTransform(cls)

Heredado de `GlueTransform` describeTransform.

describeErrors(cls)

Heredado de `GlueTransform` describeErrors.

describe(cls)

Heredado de `GlueTransform` describe.

Clase simplify_ddb_json

Simplifica las columnas anidadas en un `DynamicFrame` que se encuentran de manera específica en la estructura de JSON de DynamoDB y devuelve un nuevo `DynamicFrame` simplificado.

Ejemplo

Se recomienda utilizar el método `DynamicFrame.simplify_ddb_json()` para simplificar las columnas anidadas en un `DynamicFrame` que se encuentran de manera específica en la estructura de JSON de DynamoDB. Para ver un ejemplo de código, consulte Por ejemplo: utilice simplify_ddb_json para invocar una simplificación JSON de DynamoDB..

Clase Spigot

Escribe registros de ejemplo en un destino especificado para ayudarlo a verificar las transformaciones hechas por su trabajo de AWS Glue.

Ejemplo

Se recomienda utilizar el método `DynamicFrame.spigot()` para escribir un subconjunto de registros desde un `DynamicFrame` a un destino especificado. Para ver un ejemplo de código, consulte Ejemplo: utilice spigot para escribir campos de ejemplo desde un `DynamicFrame` en Amazon S3.

Métodos

- __call__
- apply
- nombre
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- describe

__call__(frame, path, options, transformation_ctx = "")

Escribe registros de muestra en un destino especificado durante una transformación.

- `frame`: `DynamicFrame` en el que se ejecuta spigot (obligatorio).
- `path`: ruta al destino en el que se escribirá (obligatorio).
- `options`: pares clave-valor JSON que especifican opciones (opcional). La opción `"topk"` especifica que deben escribirse los primeros registros k. La opción `"prob"` especifica la probabilidad (como decimal) de seleccionar cualquier registro. Esto se utiliza para seleccionar los registros que se desean escribir.
- `transformation_ctx`: cadena única que se utiliza para identificar la información del estado (opcional).

apply(cls, *args, **kwargs)

Heredado de `GlueTransform` apply

name(cls)

Heredado de `GlueTransform` nombre

describeArgs(cls)

Heredado de `GlueTransform` describeArgs

describeReturn(cls)

Heredado de `GlueTransform` describeReturn

describeTransform(cls)

Heredado de `GlueTransform` describeTransform

describeErrors(cls)

Heredado de `GlueTransform` describeErrors

describe(cls)

Heredado de `GlueTransform` describe

Clase SplitFields

Divide un elemento `DynamicFrame` en dos elementos nuevos según los campos especificados.

Ejemplo

Recomendamos que se utilice el método `DynamicFrame.split_fields()` para dividir campos en un `DynamicFrame`. Para ver un ejemplo de código, consulte Ejemplo: utilice split_fields para dividir los campos seleccionados en un campo `DynamicFrame` independiente.

Métodos

- __call__
- apply
- nombre
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- describe

__call__(frame, paths, name1 = none, name2 = none, transformation_ctx = "", info = "", stageThreshold = 0, totalThreshold = 0)

Divide uno o más campos de un elemento `DynamicFrame` en un elemento `DynamicFrame` nuevo y crea otro elemento `DynamicFrame` nuevo que contiene los campos restantes.

- `frame`: `DynamicFrame` de origen que se va a dividir en dos nuevos (obligatorio).
- `paths`: lista de rutas completas a los campos que se van a dividir (obligatorio).
- `name1`: nombre que se asigna al `DynamicFrame` que contendrá los campos que se van a dividir (opcional). Si no se da ningún nombre, se usa el nombre de la trama de origen con un "1" anexado.
- `name2`: nombre que se asigna al `DynamicFrame` que contendrá los campos que quedan tras haber dividido los campos que se especificaron (opcional). Si no se da ningún nombre, se usa el nombre de la trama de origen con un "2" anexado.
- `transformation_ctx`: cadena única que se utiliza para identificar la información del estado (opcional).
- `info`: cadena que está asociada a errores en la transformación (opcional).

- `stageThreshold`: cantidad máxima de errores que se puede producir en la transformación antes de que se determine que es errónea (opcional). El rol predeterminado es cero.
- `totalThreshold`: cantidad máxima de errores que se pueden producir en total antes de que se determine que el proceso es erróneo (opcional). El rol predeterminado es cero.

apply(cls, *args, **kwargs)

Heredado de `GlueTransform` apply.

name(cls)

Heredado de `GlueTransform` nombre.

describeArgs(cls)

Heredado de `GlueTransform` describeArgs.

describeReturn(cls)

Heredado de `GlueTransform` describeReturn.

describeTransform(cls)

Heredado de `GlueTransform` describeTransform.

describeErrors(cls)

Heredado de `GlueTransform` describeErrors.

describe(cls)

Heredado de `GlueTransform` describe.

Clase SplitRows

Crea una `DynamicFrameCollection` que contiene dos `DynamicFrames`. Un `DynamicFrame` contiene solo las filas especificadas para dividirlas y el otro las filas restantes.

Ejemplo

Le recomendamos que utilice el método `DynamicFrame.split_rows()` para dividir filas en un `DynamicFrame`. Para ver un ejemplo de código, consulte Ejemplo: utilice split_rows para dividir filas en un `DynamicFrame`.

Métodos

- __call__
- apply
- nombre
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- describe

__call__(frame, comparison_dict, name1="frame1", name2="frame2", transformation_ctx = "", info = none, stageThreshold = 0, totalThreshold = 0)

Divide una o más filas de un `DynamicFrame` en un nuevo `DynamicFrame`.

- `frame`: `DynamicFrame` de origen que se va a dividir en dos nuevos (obligatorio).
- `comparison_dict`: diccionario donde la clave es la ruta completa a una columna y el valor es otro diccionario que mapea comparadores con los valores con los que se comparan los valores de columna. Por ejemplo, `{"age": {">": 10, "<": 20}}` separa las filas en las que el valor "edad" se sitúa entre 10 y 20, exclusivamente, de las filas donde "edad" no se inscribe en ese intervalo (obligatorio).
- `name1`: el nombre que se asigna al `DynamicFrame` que contendrá las filas que se van a dividir (opcional).
- `name2`: el nombre que se asigna al `DynamicFrame` que contendrá las filas que quedan tras haber dividido las filas que se especificaron (opcional).
- `transformation_ctx`: cadena única que se utiliza para identificar la información del estado (opcional).
- `info`: cadena que está asociada a errores en la transformación (opcional).
- `stageThreshold`: cantidad máxima de errores que se puede producir en la transformación antes de que se determine que es errónea (opcional). El rol predeterminado es cero.
- `totalThreshold`: cantidad máxima de errores que se pueden producir en total antes de que se determine que el proceso es erróneo (opcional). El rol predeterminado es cero.

apply(cls, *args, **kwargs)

Heredado de `GlueTransform` apply.

name(cls)

Heredado de `GlueTransform` nombre.

describeArgs(cls)

Heredado de `GlueTransform` describeArgs.

describeReturn(cls)

Heredado de `GlueTransform` describeReturn.

describeTransform(cls)

Heredado de `GlueTransform` describeTransform.

describeErrors(cls)

Heredado de `GlueTransform` describeErrors.

describe(cls)

Heredado de `GlueTransform` describe.

Clase Unbox

Conversión unbox (nuevo formato) de un campo de cadena en un `DynamicFrame`.

Ejemplo

Recomendamos que se utilice el método `DynamicFrame.unbox()` para la conversión unbox en un `DynamicFrame`. Para ver un ejemplo de código, consulte Ejemplo: utilice la conversión unboxing para convertir un campo de cadena en una estructura.

Métodos

- __call__
- apply

- nombre
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- describe

__call__(frame, path, format, transformation_ctx = "", info="", stageThreshold=0, totalThreshold=0, **options)

Conversión unbox de un campo de cadena en un elemento `DynamicFrame`.

- `frame`: el `DynamicFrame` en el que se realizará la conversión unbox de un campo. (Obligatorio).
- `path`: ruta completa al elemento `StringNode` cuya conversión unbox debe realizarse (obligatorio).
- `format`: una especificación de formato (opcional). Se utiliza para una conexión de Amazon S3 o de AWS Glue que admita diversos formatos. Consulte en Opciones de formato de datos para las entradas y las salidas en AWS Glue para Spark sobre los formatos que se admiten.
- `transformation_ctx`: cadena única que se utiliza para identificar la información del estado (opcional).
- `info`: cadena que está asociada a errores en la transformación (opcional).
- `stageThreshold`: cantidad máxima de errores que se puede producir en la transformación antes de que se determine que es errónea (opcional). El rol predeterminado es cero.
- `totalThreshold`: cantidad máxima de errores que se pueden producir en total antes de que se determine que el proceso es erróneo (opcional). El rol predeterminado es cero.
- `separator`: token de separador (opcional).
- `escaper`: token de escape (opcional).
- `skipFirst`: `True` si la primera línea de datos debe omitirse o `False` si no debe omitirse (opcional).
- withSchema: cadena que contiene esquemas para los datos cuya conversión unbox debe realizarse (opcional). Debe crear siempre utilizando `StructType.json`.
- `withHeader`: `True` si los datos cuya conversión unbox se realiza contienen un encabezado o `False` en caso contrario (opcional).

apply(cls, *args, **kwargs)

Heredado de `GlueTransform` apply.

name(cls)

Heredado de `GlueTransform` nombre.

describeArgs(cls)

Heredado de `GlueTransform` describeArgs.

describeReturn(cls)

Heredado de `GlueTransform` describeReturn.

describeTransform(cls)

Heredado de `GlueTransform` describeTransform.

describeErrors(cls)

Heredado de `GlueTransform` describeErrors.

describe(cls)

Heredado de `GlueTransform` describe.

Clase UnnestFrame

Aplana `DynamicFrame` y los objetos anidados hasta convertirlos en elementos de nivel superior y genera claves de combinación para los objetos de matriz.

Ejemplo

Le recomendamos que utilice el método `DynamicFrame.unnest()` para aplanar estructuras anidadas en un `DynamicFrame`. Para ver un ejemplo de código, consulte Ejemplo: utilice desanidar para convertir los campos anidados en campos de nivel superior.

Métodos

- __call__

- apply
- nombre
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- describe

__call__(frame, transformation_ctx = "", info="", stageThreshold=0, totalThreshold=0)

Aplana `DynamicFrame` y los objetos anidados hasta convertirlos en elementos de nivel superior y genera claves de combinación para los objetos de matriz.

- `frame`: `DynamicFrame` que se va a aplanar (obligatorio).
- `transformation_ctx`: cadena única que se utiliza para identificar la información del estado (opcional).
- `info`: cadena que está asociada a errores en la transformación (opcional).
- `stageThreshold`: cantidad máxima de errores que se puede producir en la transformación antes de que se determine que es errónea (opcional). El rol predeterminado es cero.
- `totalThreshold`: cantidad máxima de errores que se pueden producir en total antes de que se determine que el proceso es erróneo (opcional). El rol predeterminado es cero.

apply(cls, *args, **kwargs)

Heredado de `GlueTransform` apply.

name(cls)

Heredado de `GlueTransform` nombre.

describeArgs(cls)

Heredado de `GlueTransform` describeArgs.

describeReturn(cls)

Heredado de `GlueTransform` describeReturn.

describeTransform(cls)

Heredado de `GlueTransform` describeTransform.

describeErrors(cls)

Heredado de `GlueTransform` describeErrors.

describe(cls)

Heredado de `GlueTransform` describe.

Clase FlagDuplicatesInColumn

La transformación `FlagDuplicatesInColumn` devuelve una nueva columna con un valor específico en cada fila que indica si el valor de la columna de origen de esa fila coincide con un valor en una fila anterior de la columna de origen. Cuando se encuentran coincidencias, se marcan como duplicadas. La aparición inicial no está marcada porque no coincide con una fila anterior.

Ejemplo

```
from pyspark.context import SparkContext
from pyspark.sql import SparkSession
from awsgluedi.transforms import *

sc = SparkContext()
spark = SparkSession(sc)

datasource1 = spark.read.json("s3://${BUCKET}/json/zips/raw/data")

try:
    df_output = column.FlagDuplicatesInColumn.apply(
        data_frame=datasource1,
        spark_context=sc,
        source_column="city",
        target_column="flag_col",
        true_string="True",
        false_string="False"
    )
except:
    print("Unexpected Error happened ")
    raise
```

Output

La transformación `FlagDuplicatesInColumn` agregará una nueva columna “flag_col” al elemento DataFrame “df_output”. Esta columna contendrá un valor de cadena que indicará si la fila correspondiente tiene un valor duplicado en la columna “city” o no. Si una fila tiene un valor “city” duplicado, “flag_col” contendrá el valor “true_string” como “True”. Si una fila tiene un único valor “city”, “flag_col” contendrá el valor “true_string” como “True”.

El elemento DataFrame “df_output” resultante contendrá todas las columnas del elemento DataFrame original “datasource1”, más la columna adicional “flag_col” que indica valores de “city” duplicados.

Métodos

- __call__
- apply
- nombre
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- describe

__call__(spark_context, data_frame, source_column, target_column, true_string=DEFAULT_TRUE_STRING, false_string=DEFAULT_FALSE_STRING)

La transformación `FlagDuplicatesInColumn` devuelve una nueva columna con un valor específico en cada fila que indica si el valor de la columna de origen de esa fila coincide con un valor en una fila anterior de la columna de origen. Cuando se encuentran coincidencias, se marcan como duplicadas. La aparición inicial no está marcada porque no coincide con una fila anterior.

- `source_column`: nombre de la columna de origen.
- `target_column`: nombre de la columna de destino.
- `true_string`: cadena que se insertará en la columna de destino cuando el valor de una columna de origen duplique un valor anterior de esa columna.
- `false_string`: cadena que se insertará en la columna de destino cuando el valor de una columna de origen sea distinto de un valor anterior de esa columna.

apply(cls, *args, **kwargs)

Heredado de `GlueTransform` apply.

name(cls)

Heredado de `GlueTransform` nombre.

describeArgs(cls)

Heredado de `GlueTransform` describeArgs.

describeReturn(cls)

Heredado de `GlueTransform` describeReturn.

describeTransform(cls)

Heredado de `GlueTransform` describeTransform.

describeErrors(cls)

Heredado de `GlueTransform` describeErrors.

describe(cls)

Heredado de `GlueTransform` describe.

Clase FormatPhoneNumber

La transformación `FormatPhoneNumber` devuelve una columna en la que la cadena de un número de teléfono se convierte en un valor formateado.

Ejemplo

```
from pyspark.context import SparkContext
from pyspark.sql import SparkSession
from awsgluedi.transforms import *

sc = SparkContext()
spark = SparkSession(sc)
```

```
input_df = spark.createDataFrame(
    [
        ("408-341-5669",),
        ("4083415669",)
    ],
    ["phone"],
)

try:
    df_output = column_formatting.FormatPhoneNumber.apply(
        data_frame=input_df,
        spark_context=sc,
        source_column="phone",
        default_region="US"
    )
    df_output.show()
except:
    print("Unexpected Error happened ")
    raise
```

Output

El resultado será:

```
```
+---------------+
| phone|
+---------------+
|(408) 341-5669|
|(408) 341-5669|
+---------------+
```
```

La transformación `FormatPhoneNumber` toma la “source_column” como “"phone"” y la “default_region” como “"US"”.

La transformación formatea correctamente ambos números de teléfono, independientemente de su formato inicial, al formato estándar estadounidense “(408) 341-5669”.

Métodos

- __call__

- apply
- nombre
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- describe

__call__(spark_context, data_frame, source_column, phone_number_format=None, default_region=None, default_region_column=None)

La transformación `FormatPhoneNumber` devuelve una columna en la que la cadena de un número de teléfono se convierte en un valor formateado.

- `source_column`: el nombre de una columna existente.
- `phone_number_format`: el formato al que se va a convertir el número de teléfono. Si no se especifica ningún formato, el formato predeterminado es `E.164`, un formato de número de teléfono estándar reconocido internacionalmente. Entre los valores válidos se incluyen los siguientes:
  - E164 (omita el punto después de E)
- `default_region`: un código de región válido compuesto por dos o tres letras mayúsculas que especifica la región del número de teléfono cuando no hay ningún código de país en el propio número. Como máximo, se puede proporcionar uno de `defaultRegion` o `defaultRegionColumn`.
- `default_region_column`: el nombre de una columna del tipo de datos avanzado `Country`. El código de región de la columna especificada se utiliza para determinar el código de país del número de teléfono cuando no hay ningún código de país en el propio número. Como máximo, se puede proporcionar uno de `defaultRegion` o `defaultRegionColumn`.

apply(cls, *args, **kwargs)

Heredado de `GlueTransform` apply.

name(cls)

Heredado de `GlueTransform` nombre.

describeArgs(cls)

Heredado de `GlueTransform` describeArgs.

describeReturn(cls)

Heredado de `GlueTransform` describeReturn.

describeTransform(cls)

Heredado de `GlueTransform` describeTransform.

describeErrors(cls)

Heredado de `GlueTransform` describeErrors.

describe(cls)

Heredado de `GlueTransform` describe.

Clase FormatCase

La transformación `FormatCase` cambia cada cadena de una columna al tipo de mayúsculas y minúsculas especificado.

Ejemplo

```
from pyspark.context import SparkContext
from pyspark.sql import SparkSession
from awsgluedi.transforms import *

sc = SparkContext()
spark = SparkSession(sc)

datasource1 = spark.read.json("s3://${BUCKET}/json/zips/raw/data")

try:
    df_output = data_cleaning.FormatCase.apply(
        data_frame=datasource1,
        spark_context=sc,
        source_column="city",
        case_type="LOWER"
    )
```

```
except:
    print("Unexpected Error happened ")
    raise
```

Output

La transformación `FormatCase` convertirá los valores de la columna “city” a minúsculas según el parámetro “case_type="LOWER"”. El elemento DataFrame “df_output” resultante contendrá todas las columnas de la “datasource1” original, pero con los valores de la columna “city” en minúsculas.

Métodos

- __call__
- apply
- nombre
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- describe

__call__(spark_context, data_frame, source_column, case_type)

La transformación `FormatCase` cambia cada cadena de una columna al tipo de mayúsculas y minúsculas especificado.

- `source_column`: el nombre de una columna existente.
- `case_type`: los tipos de mayúsculas y minúsculas admitidos son `CAPITAL`, `LOWER`, `UPPER`, `SENTENCE`.

apply(cls, *args, **kwargs)

Heredado de `GlueTransform` apply.

name(cls)

Heredado de `GlueTransform` nombre.

describeArgs(cls)

Heredado de `GlueTransform` describeArgs.

describeReturn(cls)

Heredado de `GlueTransform` describeReturn.

describeTransform(cls)

Heredado de `GlueTransform` describeTransform.

describeErrors(cls)

Heredado de `GlueTransform` describeErrors.

describe(cls)

Heredado de `GlueTransform` describe.

Clase FillWithMode

La transformación `FillWithMode` formatea una columna de acuerdo con el formato de número de teléfono que especifique. También puede especificar una lógica de desempate, en la que algunos valores son idénticos. Por ejemplo, considere los siguientes valores: `1 2 2 3 3 4`

Un ModeType `MINIMUM` hace que `FillWithMode` devuelva 2 como valor de modo. Si ModeType es `MAXIMUM`, el modo es 3. Para `AVERAGE`, el modo es 2,5.

Ejemplo

```
from awsglue.context import *
from pyspark.sql import SparkSession
from awsgluedi.transforms import *

sc = SparkContext()
spark = SparkSession(sc)

input_df = spark.createDataFrame(
    [
        (105.111, 13.12),
        (1055.123, 13.12),
        (None, 13.12),
```

```
        (13.12, 13.12),
        (None, 13.12),
    ],
    ["source_column_1", "source_column_2"],
)

try:
    df_output = data_quality.FillWithMode.apply(
        data_frame=input_df,
        spark_context=sc,
        source_column="source_column_1",
        mode_type="MAXIMUM"
    )
    df_output.show()
except:
    print("Unexpected Error happened ")
    raise
```

Output

El resultado del código dado será:

```
```
+---------------+---------------+
|source_column_1|source_column_2|
+---------------+---------------+
105.111	13.12
1055.123	13.12
1055.123	13.12
13.12	13.12
1055.123	13.12
+---------------+---------------+
```
```

La transformación `FillWithMode` del módulo “awsglue.data_quality” se aplica al elemento DataFrame “input_df”. Sustituye los valores “null” de la columna `source_column_1` por el valor máximo (“mode_type="MAXIMUM"”) de los valores no nulos de esa columna.

En este caso, el valor máximo de la columna `source_column_1` es “1055.123”. Por lo tanto, los valores “null” de `source_column_1` se sustituyen por “1055.123” en el elemento DataFrame “df_output” resultante.

Métodos

- __call__
- apply
- nombre
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- describe

__call__(spark_context, data_frame, source_column, mode_type)

La transformación `FillWithMode` formatea las cadenas de mayúsculas y minúsculas de una columna.

- `source_column`: el nombre de una columna existente.
- `mode_type`: cómo resolver los valores de empate en los datos. Este valor debe ser uno de los siguientes: `MINIMUM`, `NONE`, `AVERAGE` o `MAXIMUM`.

apply(cls, *args, **kwargs)

Heredado de `GlueTransform` apply.

name(cls)

Heredado de `GlueTransform` nombre.

describeArgs(cls)

Heredado de `GlueTransform` describeArgs.

describeReturn(cls)

Heredado de `GlueTransform` describeReturn.

describeTransform(cls)

Heredado de `GlueTransform` describeTransform.

describeErrors(cls)

Heredado de `GlueTransform` describeErrors.

describe(cls)

Heredado de `GlueTransform` describe.

Clase FlagDuplicateRows

La transformación `FlagDuplicateRows` devuelve una nueva columna con un valor específico en cada fila que indica si esa fila coincide exactamente con una fila anterior del conjunto de datos. Cuando se encuentran coincidencias, se marcan como duplicadas. La aparición inicial no está marcada porque no coincide con una fila anterior.

Ejemplo

```
from pyspark.context import SparkContext
from pyspark.sql import SparkSession
from awsgluedi.transforms import *

sc = SparkContext()
spark = SparkSession(sc)

input_df = spark.createDataFrame(
    [
        (105.111, 13.12),
        (13.12, 13.12),
        (None, 13.12),
        (13.12, 13.12),
        (None, 13.12),
    ],
    ["source_column_1", "source_column_2"],
)

try:
    df_output = data_quality.FlagDuplicateRows.apply(
        data_frame=input_df,
        spark_context=sc,
        target_column="flag_row",
        true_string="True",
        false_string="False",
        target_index=1
```

```
    )
except:
    print("Unexpected Error happened ")
    raise
```

Output

El resultado será un elemento DataFrame PySpark con una columna adicional `flag_row` que indica si una fila está duplicada o no, en función de la columna `source_column_1`. El elemento DataFrame “df_output” resultante contendrá las siguientes filas:

```
```
+---------------+---------------+--------+
|source_column_1|source_column_2|flag_row|
+---------------+---------------+--------+
105.111	13.12	False
13.12	13.12	True
null	13.12	True
13.12	13.12	True
null	13.12	True
+---------------+---------------+--------+
```
```

La columna `flag_row` indica si una fila está duplicada o no. El elemento “true_string” se establece en “True” y el elemento “false_string” se establece en “False”. El elemento “target_index” está establecido en 1, lo que significa que la columna `flag_row` se insertará en la segunda posición (índice 1) del elemento DataFrame de resultado.

Métodos

- __call__
- apply
- nombre
- describeArgs
- describeReturn
- describeTransform
- describeErrors

- describe

__call__(spark_context, data_frame, target_column, true_string=DEFAULT_TRUE_STRING, false_string=DEFAULT_FALSE_STRING, target_index=None)

La transformación `FlagDuplicateRows` devuelve una nueva columna con un valor específico en cada fila que indica si esa fila coincide exactamente con una fila anterior del conjunto de datos. Cuando se encuentran coincidencias, se marcan como duplicadas. La aparición inicial no está marcada porque no coincide con una fila anterior.

- `true_string`: valor que se insertará si la fila coincide con una fila anterior.
- `false_string`: valor que se insertará si la fila es única.
- `target_column`: nombre de la nueva columna que se inserta en el conjunto de datos.

apply(cls, *args, **kwargs)

Heredado de `GlueTransform` apply.

name(cls)

Heredado de `GlueTransform` nombre.

describeArgs(cls)

Heredado de `GlueTransform` describeArgs.

describeReturn(cls)

Heredado de `GlueTransform` describeReturn.

describeTransform(cls)

Heredado de `GlueTransform` describeTransform.

describeErrors(cls)

Heredado de `GlueTransform` describeErrors.

describe(cls)

Heredado de `GlueTransform` describe.

Clase RemoveDuplicates

La transformación `RemoveDuplicates` elimina una fila completa si se encuentra un valor duplicado en una columna de origen seleccionada.

Ejemplo

```
from pyspark.context import SparkContext
from pyspark.sql import SparkSession
from awsgluedi.transforms import *

sc = SparkContext()
spark = SparkSession(sc)

input_df = spark.createDataFrame(
    [
        (105.111, 13.12),
        (13.12, 13.12),
        (None, 13.12),
        (13.12, 13.12),
        (None, 13.12),
    ],
    ["source_column_1", "source_column_2"],
)

try:
    df_output = data_quality.RemoveDuplicates.apply(
        data_frame=input_df,
        spark_context=sc,
        source_column="source_column_1"
    )
except:
    print("Unexpected Error happened ")
    raise
```

Output

El resultado será un elemento DataFrame PySpark y se eliminarán los duplicados en función de la columna `source_column_1`. El elemento DataFrame “df_output” resultante contendrá las siguientes filas:

```
```

```
+---------------+---------------+
|source_column_1|source_column_2|
+---------------+---------------+
| 105.111| 13.12|
| 13.12| 13.12|
| null| 13.12|
+---------------+---------------+
```

Observe que las filas con los valores “13.12” y “null” de `source_column_1` aparecen solo una vez en el elemento DataFrame resultante, ya que los duplicados se han eliminado en función de la columna `source_column_1`.

Métodos

- __call__
- apply
- nombre
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- describe

__call__(spark_context, data_frame, source_column)

La transformación `RemoveDuplicates` elimina una fila completa si se encuentra un valor duplicado en una columna de origen seleccionada.

- `source_column`: el nombre de una columna existente.

apply(cls, *args, **kwargs)

Heredado de `GlueTransform` apply.

name(cls)

Heredado de `GlueTransform` nombre.

describeArgs(cls)

Heredado de `GlueTransform` describeArgs.

describeReturn(cls)

Heredado de `GlueTransform` describeReturn.

describeTransform(cls)

Heredado de `GlueTransform` describeTransform.

describeErrors(cls)

Heredado de `GlueTransform` describeErrors.

describe(cls)

Heredado de `GlueTransform` describe.

Clase MonthName

La transformación `MonthName` crea una nueva columna que contiene el nombre del mes, a partir de una cadena que representa una fecha.

Ejemplo

```
from pyspark.context import SparkContext
from pyspark.sql import SparkSession
from awsgluedi.transforms import *

sc = SparkContext()
spark = SparkSession(sc)

spark.conf.set("spark.sql.legacy.timeParserPolicy", "LEGACY")

input_df = spark.createDataFrame(
    [
        ("20-2018-12",),
        ("2018-20-12",),
        ("20182012",),
        ("12202018",),
        ("20122018",),
        ("20-12-2018",),
        ("12/20/2018",),
```

```
        ("02/02/02",),
        ("02 02 2009",),
        ("02/02/2009",),
        ("August/02/2009",),
        ("02/june/2009",),
        ("02/2020/june",),
        ("2013-02-21 06:35:45.658505",),
        ("August 02 2009",),
        ("2013/02/21",),
        (None,),
    ],
    ["column_1"],
)

try:
    df_output = datetime_functions.MonthName.apply(
        data_frame=input_df,
        spark_context=sc,
        source_column="column_1",
        target_column="target_column"
    )
    df_output.show()
except:
    print("Unexpected Error happened ")
    raise
```

Output

El resultado será:

```
```
+------------+------------+
| column_1|target_column|
+------------+------------+
20-2018-12	December
2018-20-12	null
20182012	null
12202018	null
20122018	null
20-12-2018	December
12/20/2018	December
02/02/02	February
02 02 2009	February
```
```

```
|02/02/2009 | February |
|August/02/2009| August |
|02/june/2009| null |
|02/2020/june| null |
|2013-02-21 06:35:45.658505| February |
|August 02 2009| August |
| 2013/02/21| February |
| null | null |
+------------+------------+
```

La transformación `MonthName` toma “source_column” como “"column_1"” y “target_column” como “"target_column"”. Intenta extraer el nombre del mes de las cadenas de fecha y hora de la columna “"column_1"” y lo coloca en la columna “"target_column"”. Si la cadena de fecha y hora tiene un formato desconocido o no se puede analizar, el valor de “"target_column"” se establece en “null”.

La transformación extrae correctamente el nombre del mes de varios formatos de fecha y hora, como “20-12-2018”, “20/12/2018”, “02/02/2009”, “2013-02-21 06:35:45.658505” y “2 de agosto de 2009”.

Métodos

- __call__
- apply
- nombre
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- describe

__call__(spark_context, data_frame, target_column, source_column=None, value=None)

La transformación `MonthName` crea una nueva columna que contiene el nombre del mes, a partir de una cadena que representa una fecha.

- `source_column`: el nombre de una columna existente.
- `value`: una cadena de caracteres para evaluar.
- `target_column`: un nombre para la columna recién creada.

apply(cls, *args, **kwargs)

Heredado de `GlueTransform` apply.

name(cls)

Heredado de `GlueTransform` nombre.

describeArgs(cls)

Heredado de `GlueTransform` describeArgs.

describeReturn(cls)

Heredado de `GlueTransform` describeReturn.

describeTransform(cls)

Heredado de `GlueTransform` describeTransform.

describeErrors(cls)

Heredado de `GlueTransform` describeErrors.

describe(cls)

Heredado de `GlueTransform` describe.

Clase IsEven

La transformación `IsEven` devuelve un valor booleano en una nueva columna que indica si la columna o el valor de origen son pares. Si la columna o el valor de origen es decimal, el resultado es falso.

Ejemplo

```
from pyspark.context import SparkContext
from pyspark.sql import SparkSession
from awsgluedi.transforms import *

sc = SparkContext()
spark = SparkSession(sc)

input_df = spark.createDataFrame(
    [(5,), (0,), (-1,), (2,), (None,)],
    ["source_column"],
```

```
)

try:
    df_output = math_functions.IsEven.apply(
        data_frame=input_df,
        spark_context=sc,
        source_column="source_column",
        target_column="target_column",
        value=None,
        true_string="Even",
        false_string="Not even",
    )
    df_output.show()
except:
    print("Unexpected Error happened ")
    raise
```

Output

El resultado será:

```
```
+------------+------------+
|source_column|target_column|
+------------+------------+
5	Not even
0	Even
-1	Not even
2	Even
null	null
+------------+------------+
```
```

La transformación `IsEven` toma “source_column” como “source_column” y “target_column” como “target_column”. Comprueba si el valor de “"source_column"” es par o no. Si el valor es par, establece el valor de “"target_column"” en “true_string” “Even”. Si el valor es impar, establece el valor de “"target_column"” en “false_string” “Not even”. Si el valor de “"source_column"” es “null”, el valor de “"target_column"” se establece en “null”.

La transformación identifica correctamente los números pares (0 y 2) y establece el valor de “"target_column"” en “Even”. Para los números impares (5 y -1), establece el valor

de “"target_column"” en “Not even”. Para el valor “null” de “"source_column"”, el valor de “"target_column"” se establece en “null”.

Métodos

- __call__
- apply
- nombre
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- describe

__call__(spark_context, data_frame, target_column, source_column=None, true_string=DEFAULT_TRUE_STRING, false_string=DEFAULT_FALSE_STRING, value=None)

La transformación `IsEven` devuelve un valor booleano en una nueva columna que indica si la columna o el valor de origen son pares. Si la columna o el valor de origen es decimal, el resultado es falso.

- `source_column`: el nombre de una columna existente.
- `target_column`: el nombre de la nueva columna que se va a crear.
- `true_string`: una cadena que indica si el valor es par.
- `false_string`: una cadena que indica si el valor no es par.

apply(cls, *args, **kwargs)

Heredado de `GlueTransform` apply.

name(cls)

Heredado de `GlueTransform` nombre.

describeArgs(cls)

Heredado de `GlueTransform` describeArgs.

describeReturn(cls)

Heredado de `GlueTransform` describeReturn.

describeTransform(cls)

Heredado de `GlueTransform` describeTransform.

describeErrors(cls)

Heredado de `GlueTransform` describeErrors.

describe(cls)

Heredado de `GlueTransform` describe.

Clase CryptographicHash

La transformación `CryptographicHash` aplica un algoritmo a los valores de hash de la columna.

Ejemplo

```
from pyspark.context import SparkContext
from pyspark.sql import SparkSession
from awsgluedi.transforms import *

secret = "${SECRET}"
sc = SparkContext()
spark = SparkSession(sc)

input_df = spark.createDataFrame(
    [
        (1, "1234560000"),
        (2, "1234560001"),
        (3, "1234560002"),
        (4, "1234560003"),
        (5, "1234560004"),
        (6, "1234560005"),
        (7, "1234560006"),
        (8, "1234560007"),
        (9, "1234560008"),
        (10, "1234560009"),
    ],
    ["id", "phone"],
```

```
)

try:
    df_output = pii.CryptographicHash.apply(
        data_frame=input_df,
        spark_context=sc,
        source_columns=["id", "phone"],
        secret_id=secret,
        algorithm="HMAC_SHA256",
        output_format="BASE64",
    )
    df_output.show()
except:
    print("Unexpected Error happened ")
    raise
```

Output

El resultado será:

```
```
+---+------------+------------------+------------------+
| id| phone | id_hashed | phone_hashed |
+---+------------+------------------+------------------+
1	1234560000	QUI1zXTJiXmfIb...	juDBAmiRnnO3g...
2	1234560001	ZAUWiZ3dVTzCo...	vC8lgUqBVDMNQ...
3	1234560002	ZP4VvZWkqYifu...	Kl3QAkgswYpzB...
4	1234560003	3u8vO3wQ8EQfj...	CPBzK1P8PZZkV...
5	1234560004	eWkQJk4zAOIzx...	aLf7+mHcXqbLs...
6	1234560005	xtI9fZCJZCvsa...	dy2DFgdYWmr0p...
7	1234560006	iW9hew7jnHuOf...	wwfGMCOEv6oOv...
8	1234560007	H9V1pqvgkFhfS...	g9WKhagIXy9ht...
9	1234560008	xDhEuHaxAUbU5...	b3uQLKPY+Q5vU...
10	1234560009	GRN6nFXkxk349...	VJdsKt8VbxBbt...
+---+------------+------------------+------------------+
```
```

La transformación calcula los hashes criptográficos de los valores de las columnas “id” y “phone” mediante el algoritmo y la clave secreta especificados y codifica los hashes en formato Base64. El elemento DataFrame “df_output” resultante contiene todas las columnas de la “input_df” original, además de las columnas adicionales “id_hashed” y “phone_hashed” con los valores hash calculados.

Métodos

- __call__
- apply
- nombre
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- describe

__call__(spark_context, data_frame, source_columns, secret_id, algorithm=None, secret_version=None, create_secret_if_missing=False, output_format=None, entity_type_filter=None)

La transformación `CryptographicHash` aplica un algoritmo a los valores de hash de la columna.

- `source_columns`: matriz de columnas existentes.
- `secret_id`: el ARN de la clave secreta de Secrets Manager. La clave utilizada en el algoritmo de prefijo del código de autenticación de mensajes basado en hash (HMAC) para codificar las columnas de origen.
- `secret_version`: opcional. De forma predeterminada, es la última versión secreta.
- `entity_type_filter`: matriz opcional de tipos de entidades. Se puede usar para cifrar solo la PII detectada en la columna de texto libre.
- `create_secret_if_missing`: booleano opcional. Si es verdadero, intentará crear el secreto en nombre de la persona que llama.
- `algorithm`: el algoritmo utilizado para codificar sus datos. Valores de enumeración válidos: MD5, SHA1, SHA256, SHA512, HMAC_MD5, HMAC_SHA1, HMAC_SHA256, HMAC_SHA512.

apply(cls, *args, **kwargs)

Heredado de `GlueTransform` apply.

name(cls)

Heredado de `GlueTransform` nombre.

describeArgs(cls)

Heredado de `GlueTransform` describeArgs.

describeReturn(cls)

Heredado de `GlueTransform` describeReturn.

describeTransform(cls)

Heredado de `GlueTransform` describeTransform.

describeErrors(cls)

Heredado de `GlueTransform` describeErrors.

describe(cls)

Heredado de `GlueTransform` describe.

Clase de descifrado

La transformación `Decrypt` descifra el interior de AWS Glue. Sus datos también se pueden descifrar fuera de AWS Glue con el SDK de cifrado de AWS. Si el ARN de la clave de KMS proporcionado no coincide con el que se ha utilizado para cifrar la columna, se produce un error en la operación de descifrado.

Ejemplo

```
from pyspark.context import SparkContext
from pyspark.sql import SparkSession
from awsgluedi.transforms import *

kms = "${KMS}"
sc = SparkContext()
spark = SparkSession(sc)

input_df = spark.createDataFrame(
    [
        (1, "1234560000"),
        (2, "1234560001"),
        (3, "1234560002"),
        (4, "1234560003"),
        (5, "1234560004"),
```

```
        (6, "1234560005"),
        (7, "1234560006"),
        (8, "1234560007"),
        (9, "1234560008"),
        (10, "1234560009"),
    ],
    ["id", "phone"],
)

try:
    df_encrypt = pii.Encrypt.apply(
        data_frame=input_df,
        spark_context=sc,
        source_columns=["phone"],
        kms_key_arn=kms
    )
    df_decrypt = pii.Decrypt.apply(
        data_frame=df_encrypt,
        spark_context=sc,
        source_columns=["phone"],
        kms_key_arn=kms
    )
    df_decrypt.show()
except:
    print("Unexpected Error happened ")
    raise
```

Output

El resultado será un elemento DataFrame PySpark con la columna “id” original y la columna “phone” descifrada:

```
```
+---+------------+
| id| phone|
+---+------------+
1	1234560000
2	1234560001
3	1234560002
4	1234560003
5	1234560004
6	1234560005
```
```

```
| 7| 1234560006|
| 8| 1234560007|
| 9| 1234560008|
| 10| 1234560009|
+---+------------+
```

La transformación `Encrypt` toma las “source_columns” como “[“phone”]” y “kms_key_arn” como el valor de la variable de entorno “${KMS}”. La transformación cifra los valores de la columna “phone” mediante la clave de KMS especificada. A continuación, el elemento DataFrame “df_encrypt” cifrado se pasa a la transformación `Decrypt` desde el módulo “awsglue.pii”. Toma las “source_columns” como “[“phone”]” y “kms_key_arn” como el valor de la variable de entorno “${KMS}”. La transformación descifra los valores cifrados de la columna “phone” con la misma clave de KMS. El elemento DataFrame “df_decrypt” resultante contiene la columna “id” original y la columna “phone” descifrada.

Métodos

- __call__
- apply
- nombre
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- describe

__call__(spark_context, data_frame, source_columns, kms_key_arn)

La transformación `Decrypt` descifra el interior de AWS Glue. Sus datos también se pueden descifrar fuera de AWS Glue con el SDK de cifrado de AWS. Si el ARN de la clave de KMS proporcionado no coincide con el que se ha utilizado para cifrar la columna, se produce un error en la operación de descifrado.

- `source_columns`: matriz de columnas existentes.
- `kms_key_arn`: el ARN de la clave de AWS Key Management Service que se utilizará para descifrar las columnas de origen.

apply(cls, *args, **kwargs)

Heredado de `GlueTransform` apply.

name(cls)

Heredado de `GlueTransform` nombre.

describeArgs(cls)

Heredado de `GlueTransform` describeArgs.

describeReturn(cls)

Heredado de `GlueTransform` describeReturn.

describeTransform(cls)

Heredado de `GlueTransform` describeTransform.

describeErrors(cls)

Heredado de `GlueTransform` describeErrors.

describe(cls)

Heredado de `GlueTransform` describe.

Clase de cifrado

La transformación `Encrypt` cifra las columnas de origen mediante la clave de AWS Key Management Service. La transformación `Encrypt` puede cifrar hasta 128 MiB por celda. Intentará conservar el formato al descifrarlo. Para conservar el tipo de datos, los metadatos del tipo de datos deben serializarse a menos de 1 KB. De lo contrario, debe establecer el parámetro `preserve_data_type` en “false”. Los metadatos del tipo de datos se almacenarán en texto plano en el contexto de cifrado.

Ejemplo

```
from pyspark.context import SparkContext
from pyspark.sql import SparkSession
from awsgluedi.transforms import *

kms = "${KMS}"
sc = SparkContext()
```

```
spark = SparkSession(sc)

input_df = spark.createDataFrame(
    [
        (1, "1234560000"),
        (2, "1234560001"),
        (3, "1234560002"),
        (4, "1234560003"),
        (5, "1234560004"),
        (6, "1234560005"),
        (7, "1234560006"),
        (8, "1234560007"),
        (9, "1234560008"),
        (10, "1234560009"),
    ],
    ["id", "phone"],
)

try:
    df_encrypt = pii.Encrypt.apply(
        data_frame=input_df,
        spark_context=sc,
        source_columns=["phone"],
        kms_key_arn=kms
    )
except:
    print("Unexpected Error happened ")
    raise
```

Output

El resultado será un elemento DataFrame de PySpark con la columna “id” original y una columna adicional que contendrá los valores cifrados de la columna “phone”.

```
```
+---+------------+------------------------+
| id| phone | phone_encrypted |
+---+------------+------------------------+
1	1234560000	EncryptedData1234...abc
2	1234560001	EncryptedData5678...def
3	1234560002	EncryptedData9012...ghi
4	1234560003	EncryptedData3456...jkl
```
```

```
| 5| 1234560004| EncryptedData7890...mno |
| 6| 1234560005| EncryptedData1234...pqr |
| 7| 1234560006| EncryptedData5678...stu |
| 8| 1234560007| EncryptedData9012...vwx |
| 9| 1234560008| EncryptedData3456...yz0 |
| 10| 1234560009| EncryptedData7890...123 |
+---+------------+------------------------+
```

La transformación `Encrypt` toma las “source_columns” como “[“phone”]” y “kms_key_arn” como el valor de la variable de entorno “${KMS}”. La transformación cifra los valores de la columna “phone” mediante la clave de KMS especificada. El elemento DataFrame “df_encrypt” resultante contiene la columna “id” original, la columna “phone” original y una columna adicional denominada “phone_encrypted” que contiene los valores cifrados de la columna “phone”.

Métodos

- __call__
- apply
- nombre
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- describe

__call__(spark_context, data_frame, source_columns, kms_key_arn, entity_type_filter=None, preserve_data_type=None)

La transformación `Encrypt` cifra las columnas de origen mediante la clave de AWS Key Management Service.

- `source_columns`: matriz de columnas existentes.
- `kms_key_arn`: el ARN de la clave de AWS Key Management Service que se utilizará para cifrar las columnas de origen.
- `entity_type_filter`: matriz opcional de tipos de entidades. Se puede usar para cifrar solo la PII detectada en la columna de texto libre.

- `preserve_data_type`: booleano opcional. El valor predeterminado es true (verdadero). Si es "false", el tipo de datos no se almacenará.

apply(cls, *args, **kwargs)

Heredado de `GlueTransform` apply.

name(cls)

Heredado de `GlueTransform` nombre.

describeArgs(cls)

Heredado de `GlueTransform` describeArgs.

describeReturn(cls)

Heredado de `GlueTransform` describeReturn.

describeTransform(cls)

Heredado de `GlueTransform` describeTransform.

describeErrors(cls)

Heredado de `GlueTransform` describeErrors.

describe(cls)

Heredado de `GlueTransform` describe.

Clase IntToIp

La transformación `IntToIp` convierte el valor entero de la columna de origen u otro valor en el valor IPv4 correspondiente de la columna de destino y devuelve el resultado en una nueva columna.

Ejemplo

```
from pyspark.context import SparkContext
from pyspark.sql import SparkSession
from awsgluedi.transforms import *

sc = SparkContext()
spark = SparkSession(sc)
```

```
input_df = spark.createDataFrame(
    [
        (3221225473,),
        (0,),
        (1,),
        (100,),
        (168430090,),
        (4294967295,),
        (4294967294,),
        (4294967296,),
        (-1,),
        (None,),
    ],
    ["source_column_int"],
)

try:
    df_output = web_functions.IntToIp.apply(
        data_frame=input_df,
        spark_context=sc,
        source_column="source_column_int",
        target_column="target_column",
        value=None
    )
    df_output.show()
except:
    print("Unexpected Error happened ")
    raise
```

Output

El resultado será:

```
```
+---------------+---------------+
|source_column_int|target_column|
+---------------+---------------+
3221225473	192.0.0.1
0	0.0.0.0
1	0.0.0.1
100	0.0.0.100
168430090	10.0.0.10
4294967295	255.255.255.255
```
```

```
| 4294967294| 255.255.255.254|
| 4294967296| null |
| -1| null |
| null| null |
+---------------+---------------+
```

La transformación `IntToIp.apply` toma el elemento “source_column” como “"source_column_int"” y el elemento “target_column” como “"target_column"” y convierte los valores enteros de la columna “source_column_int” en su representación de dirección IPv4 correspondiente y almacena el resultado en la columna “target_column”.

Para valores enteros válidos dentro del rango de direcciones IPv4 (0 a 4294967295), la transformación los convierte correctamente en su representación de direcciones IPv4 (por ejemplo, 192.0.0.1, 0.0.0.0, 10.0.0.10, 255.255.255.255).

Para valores enteros fuera del rango válido (por ejemplo, 4294967296, -1), el valor “target_column” se establece en “null”. Para los valores “null” de la columna “source_column_int”, el valor de “target_column” también se establece en “null”.

Métodos

- __call__
- apply
- nombre
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- describe

__call__(spark_context, data_frame, target_column, source_column=None, value=None)

La transformación `IntToIp` convierte el valor entero de la columna de origen u otro valor en el valor IPv4 correspondiente de la columna de destino y devuelve el resultado en una nueva columna.

- `sourceColumn`: el nombre de una columna existente.
- `value`: una cadena de caracteres para evaluar.

- `targetColumn`: el nombre de la nueva columna que se va a crear.

apply(cls, *args, **kwargs)

Heredado de `GlueTransform` apply.

name(cls)

Heredado de `GlueTransform` nombre.

describeArgs(cls)

Heredado de `GlueTransform` describeArgs.

describeReturn(cls)

Heredado de `GlueTransform` describeReturn.

describeTransform(cls)

Heredado de `GlueTransform` describeTransform.

describeErrors(cls)

Heredado de `GlueTransform` describeErrors.

describe(cls)

Heredado de `GlueTransform` describe.

Clase IpToInt

La transformación `IpToInt` convierte el valor del Protocolo de Internet versión 4 (IPv4) de la columna de origen u otro valor en el valor entero correspondiente de la columna de destino y devuelve el resultado en una nueva columna.

Ejemplo

Para AWS Glue 4.0 y versiones posteriores, cree o actualice argumentos de trabajo con `key: --enable-glue-di-transforms, value: true`.

```
from pyspark.context import SparkContext
from awsgluedi.transforms import *

sc = SparkContext()
```

```
input_df = spark.createDataFrame(
    [
        ("192.0.0.1",),
        ("10.10.10.10",),
        ("1.2.3.4",),
        ("1.2.3.6",),
        ("http://12.13.14.15",),
        ("https://16.17.18.19",),
        ("1.2.3.4",),
        (None,),
        ("abc",),
        ("abc.abc.abc.abc",),
        ("321.123.123.123",),
        ("244.4.4.4",),
        ("255.255.255.255",),
    ],
    ["source_column_ip"],
)

    df_output = web_functions.IpToInt.apply(
        data_frame=input_df,
        spark_context=sc,
        source_column="source_column_ip",
        target_column="target_column",
        value=None
    )
    df_output.show()
```

Output

El resultado será:

```
```
+----------------+---------------+
|source_column_ip| target_column|
+----------------+---------------+
192.0.0.1	3221225473
10.10.10.10	168427722
1.2.3.4	16909060
1.2.3.6	16909062
http://12.13.14.15	null
https://16.17.18.19	null
```
```

```
| 1.2.3.4| 16909060|
| null| null|
| abc| null|
|abc.abc.abc.abc| null|
| 321.123.123.123| null|
| 244.4.4.4| 4102444804|
| 255.255.255.255| 4294967295|
+----------------+---------------+
```

La transformación `IpToInt` toma “source_column” como “"source_column_ip"” y “target_column” como “"target_column"” y convierte las cadenas de direcciones IPv4 válidas de la columna “source_column_ip” en su correspondiente representación entera de 32 bits y almacena el resultado en la columna “target_column”.

Para cadenas de direcciones IPv4 válidas (por ejemplo, “192.0.0.1”, “10.10.10.10”, “1.2.3.4”), la transformación las convierte correctamente en su representación de números enteros (por ejemplo, 3221225473, 168427722, 16909060). Para las cadenas que no son direcciones IPv4 válidas (por ejemplo, direcciones URL, cadenas que no son IP como “abc” o formatos IP no válidos como “abc.abc.abc.abc”), el valor de “target_column” se establece en “null”. Para los valores “null” de la columna “source_column_ip”, el valor “target_column” también se establece en “null”.

Métodos

- __call__
- apply
- nombre
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- describe

__call__(spark_context, data_frame, target_column, source_column=None, value=None)

La transformación `IpToInt` convierte el valor del Protocolo de Internet versión 4 (IPv4) de la columna de origen u otro valor en el valor entero correspondiente de la columna de destino y devuelve el resultado en una nueva columna.

- `sourceColumn`: el nombre de una columna existente.
- `value`: una cadena de caracteres para evaluar.
- `targetColumn`: el nombre de la nueva columna que se va a crear.

apply(cls, *args, **kwargs)

Heredado de `GlueTransform` apply.

name(cls)

Heredado de `GlueTransform` nombre.

describeArgs(cls)

Heredado de `GlueTransform` describeArgs.

describeReturn(cls)

Heredado de `GlueTransform` describeReturn.

describeTransform(cls)

Heredado de `GlueTransform` describeTransform.

describeErrors(cls)

Heredado de `GlueTransform` describeErrors.

describe(cls)

Heredado de `GlueTransform` describe.

Transformaciones de integración de datos

Para AWS Glue 4.0 y versiones posteriores, cree o actualice argumentos de trabajo con `key: --enable-glue-di-transforms, value: true`.

Ejemplo de script de trabajo:

```
from pyspark.context import SparkContext
```

```
from awsgluedi.transforms import *
sc = SparkContext()

input_df = spark.createDataFrame(
    [(5,), (0,), (-1,), (2,), (None,)],
    ["source_column"],
)

try:
    df_output = math_functions.IsEven.apply(
        data_frame=input_df,
        spark_context=sc,
        source_column="source_column",
        target_column="target_column",
        value=None,
        true_string="Even",
        false_string="Not even",
    )
    df_output.show()
except:
    print("Unexpected Error happened ")
    raise
```

Ejemplos de sesiones con cuadernos

```
%idle_timeout 2880
%glue_version 4.0
%worker_type G.1X
%number_of_workers 5
%region eu-west-1
```

```
%%configure
{
    "--enable-glue-di-transforms": "true"
}
```

```
from pyspark.context import SparkContext
from awsgluedi.transforms import *

sc = SparkContext()

input_df = spark.createDataFrame(
```

```
    [(5,), (0,), (-1,), (2,), (None,)],
    ["source_column"],
)

try:
    df_output = math_functions.IsEven.apply(
        data_frame=input_df,
        spark_context=sc,
        source_column="source_column",
        target_column="target_column",
        value=None,
        true_string="Even",
        false_string="Not even",
    )
    df_output.show()
except:
    print("Unexpected Error happened ")
    raise
```

Ejemplos de sesiones con la AWS CLI

```
aws glue create-session --default-arguments "--enable-glue-di-transforms=true"
```

Transformaciones DI:

- Clase FlagDuplicatesInColumn
- Clase FormatPhoneNumber
- Clase FormatCase
- Clase FillWithMode
- Clase FlagDuplicateRows
- Clase RemoveDuplicates
- Clase MonthName
- Clase IsEven
- Clase CryptographicHash
- Clase de descifrado
- Clase de cifrado
- Clase IntToIp

- Clase IpToInt

Maven: agrupe el complemento con sus aplicaciones de Spark

Para agrupar la dependencia de las transformaciones con sus aplicaciones y distribuciones de Spark (versión 3.3), puede agregar la dependencia del complemento en su `pom.xml` de Maven y desarrollar sus aplicaciones de Spark de forma local.

```
<repositories>
   ...
    <repository>
        <id>aws-glue-etl-artifacts</id>
        <url>https://aws-glue-etl-artifacts.s3.amazonaws.com/release/ </url>
    </repository>
</repositories>
...
<dependency>
    <groupId>com.amazonaws</groupId>
    <artifactId>AWSGlueTransforms</artifactId>
    <version>4.0.0</version>
</dependency>
```

También puede descargar directamente los binarios de los artefactos de AWS Glue Maven e incluirlos en su aplicación de Spark de la siguiente manera.

```
#!/bin/bash
sudo wget -v https://aws-glue-etl-artifacts.s3.amazonaws.com/release/com/amazonaws/
AWSGlueTransforms/4.0.0/AWSGlueTransforms-4.0.0.jar -P /usr/lib/spark/jars/
```

Programación de scripts de ETL de AWS Glue en Scala

Puede encontrar ejemplos de código de Scala y utilidades para AWS Glue en el repositorio de ejemplos de AWS Glue en el sitio web de GitHub.

AWS Glue soporta una extensión del dialecto PySpark Scala para scripting de trabajos de extracción, transformación y carga (ETL). En las secciones siguientes se describe cómo utilizar la biblioteca de AWS Glue Scala y la API de AWS Glue en los scripts de ETL y se proporciona documentación de referencia correspondiente a la biblioteca.

Contenido

- Uso de Scala para programar scripts de ETL de AWS Glue
  - Prueba de un programa ETL de Scala en un cuaderno de Jupyter en un punto de conexión de desarrollo
  - Prueba de un programa ETL de Scala en un REPL de Scala
- Ejemplo de script de Scala - ETL de streaming
- API en la biblioteca Scala de AWS Glue
  - com.amazonaws.services.glue
  - com.amazonaws.services.glue.ml
  - com.amazonaws.services.glue.dq
  - com.amazonaws.services.glue.types
  - com.amazonaws.services.glue.util
  - API ChoiceOption Scala de AWS Glue
    - Característica ChoiceOption
    - Objeto ChoiceOption
      - Def apply
    - case class ChoiceOptionWithResolver
    - case class MatchCatalogSchemaChoiceOption
  - Abstract DataSink class
    - def writeDynamicFrame
    - def pyWriteDynamicFrame
    - Def writeDataFrame
    - Def pyWriteDataFrame
    - def setCatalogInfo
    - def supportsFormat
    - def setFormat
    - def withFormat
    - def setAccumulableSize
    - def getOutputErrorRecordsAccumulable
    - def errorsAsDynamicFrame
    - Objeto DataSink
    - def recordMetrics

- Característica DataSource Scala de AWS Glue
- API DynamicFrame Scala de AWS Glue
  - Clase DynamicFrame Scala de AWS Glue
    - Val errorsCount
    - Def applyMapping
    - Def assertErrorThreshold
    - Def count
    - Def dropField
    - Def dropFields
    - Def dropNulls
    - def errorsAsDynamicFrame
    - Def filter
    - Def getName
    - Def getNumPartitions
    - Def getSchemaIfComputed
    - Def isSchemaComputed
    - Def javaToPython
    - Def join
    - Def map
    - Def mergeDynamicFrames
    - Def printSchema
    - Def recomputeSchema
    - Def relationalize
    - Def renameField
    - Def repartition
    - Def resolveChoice
    - Def schema
    - Def selectField
    - Def selectFields
    - Def show

        - Def simplifyDDBJson
        - Def spigot
        - Def splitFields
        - Def splitRows
        - Def stageErrorsCount
        - Def toDF
        - Def unbox
        - Def unnest
        - Def unnestDDBJson
        - Def withFrameSchema
        - Def withName
        - Def withTransformationContext
    - Objeto DynamicFrame
        - Def apply
        - def emptyDynamicFrame
        - Def fromPythonRDD
        - Def ignoreErrors
        - Def inlineErrors
        - Def newFrameWithErrors
- Clase DynamicRecord Scala de AWS Glue
    - Def addField
    - Def dropField
    - Def setError
    - Def isError
    - Def getError
    - Def clearError
    - Def write
    - Def readFields
    - Def clone

    - Def schema

    - Def getRoot
    - Def toJson
    - Def getFieldNode
    - Def getField
    - Def hashCode
    - Def equals
    - Objeto DynamicRecord
        - Def apply
    - Característica RecordTraverser
- API GlueContext Scala de AWS Glue
    - def addIngestionTimeColumns
    - def createDataFrameFromOptions
    - forEachBatch
    - def getCatalogSink
    - def getCatalogSource
    - def getJDBCSink
    - def getSink
    - def getSinkWithFormat
    - def getSource
    - def getSourceWithFormat
    - def getSparkSession
    - Definición de startTransaction (iniciar transacción)
    - Definición de commitTransaction (confirmar transacción)
    - Definición de cancelTransaction (cancelar transacción)
    - def this
    - def this
    - def this
- MappingSpec
    - Case class MappingSpec
    - Objeto MappingSpec

        - Val orderingByTarget
        - Def apply
        - Def apply
        - Def apply
- API ResolveSpec Scala de AWS Glue
    - Objeto ResolveSpec
        - Def
        - Def
    - Case class ResolveSpec
        - Métodos def de ResolveSpec
- API ArrayNode Scala de AWS Glue
    - Case class ArrayNode
        - Métodos def de ArrayNode
- API BinaryNode Scala de AWS Glue
    - Case class BinaryNode
        - Campos val de BinaryNode
        - Métodos def de BinaryNode
- API BooleanNode Scala de AWS Glue
    - Case class BooleanNode
        - Campos val de BooleanNode
        - Métodos def de BooleanNode
- API ByteNode Scala de AWS Glue
    - Case class ByteNode
        - Campos val de ByteNode
        - Métodos def de ByteNode
- API DateNode Scala de AWS Glue
    - Case class DateNode
        - Campos val de DateNode
        - Métodos def de DateNode

- API DecimalNode Scala de AWS Glue

    - Case class DecimalNode
        - Campos val de DecimalNode
        - Métodos def de DecimalNode
- API DoubleNode Scala de AWS Glue
    - Case class DoubleNode
        - Campos val de DoubleNode
        - Métodos def de DoubleNode
- API DynamicNode Scala de AWS Glue
    - Clase DynamicNode
        - Métodos def de DynamicNode
    - Objeto DynamicNode
        - Métodos def de DynamicNode
- Clase de EvaluateDataQuality
    - Def apply
    - Ejemplo
- API FloatNode Scala de AWS Glue
    - Case class FloatNode
        - Campos val de FloatNode
        - Métodos def de FloatNode
- Clase FillMissingValues
    - Def apply
- Clase FindMatches
    - Def apply
- Clase FindIncrementalMatches
    - Def apply
- API IntegerNode Scala de AWS Glue
    - Case class IntegerNode
        - Campos val de IntegerNode
        - Métodos def de IntegerNode
- API LongNode Scala de AWS Glue

    - Case class LongNode
        - Campos val de LongNode
        - Métodos def de LongNode
- API MapLikeNode Scala de AWS Glue
    - Case class MapLikeNode
        - Métodos def de MapLikeNode
- API MapNode Scala de AWS Glue
    - Case class MapNode
        - Métodos def de MapNode
- API NullNode Scala de AWS Glue
    - Clase NullNode
    - Case object NullNode
- API ObjectNode Scala de AWS Glue
    - Objeto ObjectNode
        - Métodos def de ObjectNode
    - Case class ObjectNode
        - Métodos def de ObjectNode
- API ScalarNode Scala de AWS Glue
    - Clase ScalarNode
        - Métodos def de ScalarNode
    - Objeto ScalarNode
        - Métodos def de ScalarNode
- API ShortNode Scala de AWS Glue
    - Case class ShortNode
        - Campos val de ShortNode
        - Métodos def de ShortNode
- API StringNode Scala de AWS Glue
    - Case class StringNode
        - Campos val de StringNode
        - Métodos def de StringNode

- API TimestampNode Scala de AWS Glue
  - Case class TimestampNode
    - Campos val de TimestampNode
    - Métodos def de TimestampNode
- API GlueArgParser Scala de AWS Glue
  - Objeto GlueArgParser
    - Métodos def de GlueArgParser
- API Job Scala de AWS Glue
  - Objeto de trabajo
    - Métodos def de trabajo

Uso de Scala para programar scripts de ETL de AWS Glue

Puede generar automáticamente un programa de extracción, transformación y carga (ETL) Scala usando la consola de AWS Glue y modificándolo según sea necesario antes de asignarlo a un flujo de trabajo. O bien puede escribir su propio programa desde cero. Para obtener más información, consulte Configuración de las propiedades de trabajos para trabajos de Spark en AWS Glue. AWS Glue compila el programa de Scala en el servidor antes de ejecutar el flujo de trabajo asociado.

Para asegurarse de que el programa se compila sin errores y se ejecuta según lo previsto, es muy importante que lo cargue en un punto de conexión de desarrollo en REPL (Read-Eval-Print Loop) o un cuaderno de Jupyter y que lo pruebe antes de ejecutarlo en un flujo de trabajo. Debido a que el proceso de compilación se realiza en el servidor, no tendrá una visibilidad adecuada de los problemas que se produzcan en él.

Prueba de un programa ETL de Scala en un cuaderno de Jupyter en un punto de conexión de desarrollo

Para probar un programa Scala en un enlace de desarrollo de AWS Glue, configure el punto de enlace de desarrollo tal y como se describe en Añadir un punto de conexión de desarrollo..

A continuación, conéctelo a un cuaderno de Jupyter que se ejecute localmente en la máquina o de forma remota en un servidor de cuadernos de Amazon EC2. Para instalar una versión local de un cuaderno de Jupyter, siga las instrucciones de Tutorial: cuaderno de Jupyter en JupyterLab.

La única diferencia entre ejecutar código de Scala y ejecutar código de PySpark en su bloc de notas es que debe comenzar cada párrafo del bloc de notas con lo siguiente:

```
%spark
```

De este modo se impide que el servidor de bloc de notas cambie de forma predeterminada a la versión PySpark del intérprete de Spark.

Prueba de un programa ETL de Scala en un REPL de Scala

Puede probar un programa Scala en un punto de enlace de desarrollo con un REPL de Scala de AWS Glue. Siga las instrucciones de Tutorial: Uso de un cuaderno de IA de SageMaker, excepto al final del comando SSH-to-REPL, reemplace `-t gluepyspark` por `-t glue-spark-shell`. Esto invoca el REPL de Scala de AWS Glue.

Para cerrar el REPL cuando termine, escriba `sys.exit`.

Ejemplo de script de Scala - ETL de streaming

Example

El siguiente script de ejemplo se conecta a Amazon Kinesis Data Streams, utiliza un esquema del Data Catalog para analizar un flujo de datos, une el flujo a un conjunto de datos estático en Amazon S3 y envía los resultados combinados a Amazon S3 en formato parquet.

```
// This script connects to an Amazon Kinesis stream, uses a schema from the data
 catalog to parse the stream,
// joins the stream to a static dataset on Amazon S3, and outputs the joined results to
 Amazon S3 in parquet format.
import com.amazonaws.services.glue.GlueContext
import com.amazonaws.services.glue.util.GlueArgParser
import com.amazonaws.services.glue.util.Job
import java.util.Calendar
import org.apache.spark.SparkContext
import org.apache.spark.sql.Dataset
import org.apache.spark.sql.Row
import org.apache.spark.sql.SaveMode
import org.apache.spark.sql.SparkSession
import org.apache.spark.sql.functions.from_json
import org.apache.spark.sql.streaming.Trigger
import scala.collection.JavaConverters._

object streamJoiner {
  def main(sysArgs: Array[String]) {
    val spark: SparkContext = new SparkContext()
```

```
    val glueContext: GlueContext = new GlueContext(spark)
    val sparkSession: SparkSession = glueContext.getSparkSession
    import sparkSession.implicits._
    // @params: [JOB_NAME]
    val args = GlueArgParser.getResolvedOptions(sysArgs, Seq("JOB_NAME").toArray)
    Job.init(args("JOB_NAME"), glueContext, args.asJava)

    val staticData = sparkSession.read          // read() returns type DataFrameReader
      .format("csv")
      .option("header", "true")
      .load("s3://amzn-s3-demo-bucket/inputs/productsStatic.csv")  // load() returns a
DataFrame

    val datasource0 = sparkSession.readStream   // readstream() returns type
DataStreamReader
      .format("kinesis")
      .option("streamName", "stream-join-demo")
      .option("endpointUrl", "https://kinesis.us-east-1.amazonaws.com")
      .option("startingPosition", "TRIM_HORIZON")
      .load                                     // load() returns a DataFrame

    val selectfields1 = datasource0.select(from_json($"data".cast("string"),
glueContext.getCatalogSchemaAsSparkSchema("stream-demos", "stream-join-demo2")) as
"data").select("data.*")

    val datasink2 = selectfields1.writeStream.foreachBatch { (dataFrame: Dataset[Row],
batchId: Long) => {   //foreachBatch() returns type DataStreamWriter
      val joined = dataFrame.join(staticData, "product_id")
      val year: Int = Calendar.getInstance().get(Calendar.YEAR)
      val month :Int = Calendar.getInstance().get(Calendar.MONTH) + 1
      val day: Int = Calendar.getInstance().get(Calendar.DATE)
      val hour: Int = Calendar.getInstance().get(Calendar.HOUR_OF_DAY)

      if (dataFrame.count() > 0) {
        joined.write                            // joined.write returns type
DataFrameWriter
          .mode(SaveMode.Append)
          .format("parquet")
          .option("quote", " ")
          .save("s3://amzn-s3-demo-bucket/output/" + "/year=" + "%04d".format(year)
+ "/month=" + "%02d".format(month) + "/day=" + "%02d".format(day) + "/hour=" +
"%02d".format(hour) + "/")
      }
    }
```

```
    }  // end foreachBatch()
      .trigger(Trigger.ProcessingTime("100 seconds"))
      .option("checkpointLocation", "s3://amzn-s3-demo-bucket/checkpoint/")
      .start().awaitTermination()              // start() returns type StreamingQuery
    Job.commit()
  }
}
```

API en la biblioteca Scala de AWS Glue

AWS Glue es compatible con una extensión del dialecto Scala de PySpark para los trabajos de extraer, transformar y cargar (ETL) scripts. En las siguientes secciones se describen las API de la biblioteca Scala de AWS Glue.

com.amazonaws.services.glue

El paquete com.amazonaws.services.glue de la biblioteca AWS Glue Scala contiene las API siguientes:

- ChoiceOption
- DataSink
- Característica DataSource
- DynamicFrame
- DynamicRecord
- GlueContext
- MappingSpec
- ResolveSpec

com.amazonaws.services.glue.ml

El paquete com.amazonaws.services.glue.ml de la biblioteca de AWS Glue Scala contiene las siguientes API:

- FillMissingValues
- FindIncrementalMatches
- FindMatches

com.amazonaws.services.glue.dq

El paquete com.amazonaws.services.glue.dq de la biblioteca de Scala de AWS Glue contiene las siguientes API:

- EvaluateDataQuality

com.amazonaws.services.glue.types

El paquete com.amazonaws.services.glue.types de la biblioteca AWS Glue Scala contiene las API siguientes:

- ArrayNode
- BinaryNode
- BooleanNode
- ByteNode
- DateNode
- DecimalNode
- DoubleNode
- DynamicNode
- FloatNode
- IntegerNode
- LongNode
- MapLikeNode
- MapNode
- NullNode
- ObjectNode
- ScalarNode
- ShortNode
- StringNode
- TimestampNode

com.amazonaws.services.glue.util

El paquete com.amazonaws.services.util de la biblioteca AWS Glue Scala contiene las API siguientes:

- GlueArgParser
- Trabajo

API ChoiceOption Scala de AWS Glue

Temas

- Característica ChoiceOption
- Objeto ChoiceOption
- case class ChoiceOptionWithResolver
- case class MatchCatalogSchemaChoiceOption

Paquete: com.amazonaws.services.glue

Característica ChoiceOption

```
trait ChoiceOption extends Serializable
```

Objeto ChoiceOption

ChoiceOption

```
object ChoiceOption
```

Una estrategia general para resolver la selección aplicable a todos los nodos `ChoiceType` de un objeto `DynamicFrame`.

- `val CAST`
- `val MAKE_COLS`
- `val MAKE_STRUCT`
- `val MATCH_CATALOG`

- `val PROJECT`

Def apply

```
def apply(choice: String): ChoiceOption
```

case class ChoiceOptionWithResolver

```
case class ChoiceOptionWithResolver(name: String, choiceResolver: ChoiceResolver)
 extends ChoiceOption {}
```

case class MatchCatalogSchemaChoiceOption

```
case class MatchCatalogSchemaChoiceOption() extends ChoiceOption {}
```

Abstract DataSink class

Temas

- def writeDynamicFrame
- def pyWriteDynamicFrame
- Def writeDataFrame
- Def pyWriteDataFrame
- def setCatalogInfo
- def supportsFormat
- def setFormat
- def withFormat
- def setAccumulableSize
- def getOutputErrorRecordsAccumulable
- def errorsAsDynamicFrame
- Objeto DataSink

Paquete: com.amazonaws.services.glue

```
abstract class DataSink
```

El escritor análogo a un `DataSource`. `DataSink` encapsula un destino y un formato en el que se puede escribir un objeto `DynamicFrame`.

def writeDynamicFrame

```
def writeDynamicFrame( frame : DynamicFrame,
                       callSite : CallSite = CallSite("Not provided", "")
                     ) : DynamicFrame
```

def pyWriteDynamicFrame

```
def pyWriteDynamicFrame( frame : DynamicFrame,
                         site : String = "Not provided",
                         info : String = "" )
```

Def writeDataFrame

```
def writeDataFrame(frame: DataFrame,
                   glueContext: GlueContext,
                   callSite: CallSite = CallSite("Not provided", "")
                   ): DataFrame
```

Def pyWriteDataFrame

```
def pyWriteDataFrame(frame: DataFrame,
                     glueContext: GlueContext,
                     site: String = "Not provided",
                     info: String = ""
                     ): DataFrame
```

def setCatalogInfo

```
def setCatalogInfo(catalogDatabase: String,
                   catalogTableName : String,
```

```
                    catalogId : String = "")
```

def supportsFormat

```
def supportsFormat( format : String ) : Boolean
```

def setFormat

```
def setFormat( format : String,
               options : JsonOptions
             ) : Unit
```

def withFormat

```
def withFormat( format : String,
                options : JsonOptions = JsonOptions.empty
              ) : DataSink
```

def setAccumulableSize

```
def setAccumulableSize( size : Int ) : Unit
```

def getOutputErrorRecordsAccumulable

```
def getOutputErrorRecordsAccumulable : Accumulable[List[OutputError], OutputError]
```

def errorsAsDynamicFrame

```
def errorsAsDynamicFrame : DynamicFrame
```

Objeto DataSink

```
object DataSink
```

def recordMetrics

```
def recordMetrics( frame : DynamicFrame,
                   ctxt : String
                 ) : DynamicFrame
```

Característica DataSource Scala de AWS Glue

Paquete: com.amazonaws.services.glue

Una interfaz de alto nivel para producir un `DynamicFrame`.

```
trait DataSource {

  def getDynamicFrame : DynamicFrame

  def getDynamicFrame( minPartitions : Int,
                       targetPartitions : Int
                     ) : DynamicFrame
  def getDataFrame : DataFrame

  /** @param num: the number of records for sampling.
    * @param options: optional parameters to control sampling behavior. Current
 available parameter for Amazon S3 sources in options:
    *  1. maxSamplePartitions: the maximum number of partitions the sampling will
 read.
    *  2. maxSampleFilesPerPartition: the maximum number of files the sampling will
 read in one partition.
    */
  def getSampleDynamicFrame(num:Int, options: JsonOptions = JsonOptions.empty):
 DynamicFrame

  def glueContext : GlueContext

  def setFormat( format : String,
                 options : String
               ) : Unit

  def setFormat( format : String,
                 options : JsonOptions
               ) : Unit
```

```
  def supportsFormat( format : String ) : Boolean

  def withFormat( format : String,
                  options : JsonOptions = JsonOptions.empty
                ) : DataSource
}
```

API DynamicFrame Scala de AWS Glue

Paquete: com.amazonaws.services.glue

Contenido

- Clase DynamicFrame Scala de AWS Glue
  - Val errorsCount
  - Def applyMapping
  - Def assertErrorThreshold
  - Def count
  - Def dropField
  - Def dropFields
  - Def dropNulls
  - def errorsAsDynamicFrame
  - Def filter
  - Def getName
  - Def getNumPartitions
  - Def getSchemaIfComputed
  - Def isSchemaComputed
  - Def javaToPython
  - Def join
  - Def map
  - Def mergeDynamicFrames
  - Def printSchema
  - Def recomputeSchema
  - Def relationalize
  - Def renameField

- Def repartition
- Def resolveChoice
- Def schema
- Def selectField
- Def selectFields
- Def show
- Def simplifyDDBJson
- Def spigot
- Def splitFields
- Def splitRows
- Def stageErrorsCount
- Def toDF
- Def unbox
- Def unnest
- Def unnestDDBJson
- Def withFrameSchema
- Def withName
- Def withTransformationContext

- Objeto DynamicFrame
  - Def apply
  - def emptyDynamicFrame
  - Def fromPythonRDD
  - Def ignoreErrors
  - Def inlineErrors
  - Def newFrameWithErrors

Clase DynamicFrame Scala de AWS Glue

Paquete: com.amazonaws.services.glue

```
class DynamicFrame extends Serializable with Logging  (
        val glueContext : GlueContext,
```

```
            _records : RDD[DynamicRecord],
            val name : String = s"",
            val transformationContext : String = DynamicFrame.UNDEFINED,
            callSite : CallSite = CallSite("Not provided", ""),
            stageThreshold : Long = 0,
            totalThreshold : Long = 0,
            prevErrors : => Long = 0,
            errorExpr : => Unit = {} )
```

`DynamicFrame` es una colección distribuida de objetos DynamicRecord autodescriptivos.

Los elementos `DynamicFrames` se han diseñado para proporcionar un modelo de datos flexible para operaciones de ETL (extracción, transformación y carga). No necesitan un esquema para crearse y se pueden usar para leer y transformar datos que contienen valores y tipos confusos o incoherentes. Un esquema se puede calcular bajo demanda para las operaciones que necesiten uno.

Los objetos `DynamicFrame` proporcionan una serie de transformaciones para la limpieza de datos y ETL. También admiten la conversión a clases DataFrame de SparkSQL, y desde dichas clases, para integrarse con el código existente y las numerosas operaciones de análisis que proporcionan las clases DataFrame.

Los siguientes parámetros se comparten entre las numerosas transformaciones de AWS Glue que construyen objetos `DynamicFrame`:

- `transformationContext`: identificador de este `DynamicFrame`. El parámetro `transformationContext` se utiliza como clave para el estado de marcador de flujo de trabajo que se conserva de una ejecución a otra.
- `callSite`: proporciona información de contexto para los informes de error. Estos valores se establecen automáticamente cuando se realiza la llamada desde Python.
- `stageThreshold`: número máximo de registros de error permitidos en el cálculo de este objeto `DynamicFrame` antes de generar una excepción, sin incluir los registros presentes en el objeto `DynamicFrame` anterior.
- `totalThreshold`: número máximo registros de error totales antes de que se genere una excepción, incluidos los de marcos anteriores.

Val errorsCount

```
val errorsCount
```

El número de registros de error en este objeto DynamicFrame. Se incluyen errores de las operaciones anteriores.

Def applyMapping

```
def applyMapping( mappings : Seq[Product4[String, String, String, String]],
                  caseSensitive : Boolean = true,
                  transformationContext : String = "",
                  callSite : CallSite = CallSite("Not provided", ""),
                  stageThreshold : Long = 0,
                  totalThreshold : Long = 0
                ) : DynamicFrame
```

- mappings: secuencia de mapeos para construir un objeto DynamicFrame nuevo.
- caseSensitive: indica si hay que considerar que las columnas de origen distinguen entre mayúsculas y minúsculas. Configurar este valor como falso puede ser de ayuda al realizar integraciones con almacenes que no distinguen entre mayúsculas y minúsculas, como AWS Glue Data Catalog.

Selecciona, proyecta y convierte las columnas en función de una secuencia de mapeos.

Cada mapeo se compone de una columna y un tipo de origen y una columna y un tipo de destino. Los mapeos se pueden especificar como una tupla cuádruple (source_path, source_type, target_path, target_type) o un objeto MappingSpec que contiene la misma información.

Además de usar los mapeos para proyecciones y conversiones simples, también se pueden usar para anidar o aplanar campos separando los componentes de la ruta con "." (punto).

Por ejemplo, suponga que tiene una instancia de DynamicFrame con el siguiente esquema.

```
{{{
  root
  |-- name: string
  |-- age: int
  |-- address: struct
  |    |-- state: string
  |    |-- zip: int
}}}
```

Puede hacer la siguiente llamada para quitar el anidamiento en los campos state y zip:

```
{{{
  df.applyMapping(
   Seq(("name", "string", "name", "string"),
       ("age", "int", "age", "int"),
       ("address.state", "string", "state", "string"),
       ("address.zip", "int", "zip", "int")))
}}}
```

El esquema resultante es el siguiente.

```
{{{
  root
  |-- name: string
  |-- age: int
  |-- state: string
  |-- zip: int
}}}
```

También puede utilizar `applyMapping` para volver a anidar columnas. Por ejemplo, el siguiente código invierte la transformación anterior y crea una estructura denominada `address` en el destino.

```
{{{
  df.applyMapping(
   Seq(("name", "string", "name", "string"),
       ("age", "int", "age", "int"),
       ("state", "string", "address.state", "string"),
       ("zip", "int", "address.zip", "int")))
}}}
```

Los nombres de los campos que contienen caracteres `"."` (punto) se pueden citar mediante acentos graves (` `).

> **Note**
>
> Actualmente no se puede usar el método `applyMapping` para mapear columnas anidadas en matrices.

Def assertErrorThreshold

```
def assertErrorThreshold : Unit
```

Acción que fuerza el cómputo y verifica que el número de registros de error esté por debajo de `stageThreshold` y `totalThreshold`. Genera una excepción si no se cumple ninguna de las condiciones.

Def count

```
lazy
def count
```

Devuelve el número de elementos en este objeto `DynamicFrame`.

Def dropField

```
def dropField( path : String,
               transformationContext : String = "",
               callSite : CallSite = CallSite("Not provided", ""),
               stageThreshold : Long = 0,
               totalThreshold : Long = 0
             ) : DynamicFrame
```

Devuelve un objeto `DynamicFrame` nuevo sin la columna especificada.

Def dropFields

```
def dropFields( fieldNames : Seq[String],   // The column names to drop.
                transformationContext : String = "",
                callSite : CallSite = CallSite("Not provided", ""),
                stageThreshold : Long = 0,
                totalThreshold : Long = 0
              ) : DynamicFrame
```

Devuelve un objeto `DynamicFrame` nuevo sin las columnas especificadas.

Este método se puede utilizar para eliminar columnas anidadas, incluidas las que se encuentran en matrices, pero no para descartar elementos de matriz específicos.

Def dropNulls

```
def dropNulls( transformationContext : String = "",
               callSite : CallSite = CallSite("Not provided", ""),
               stageThreshold : Long = 0,
               totalThreshold : Long = 0 )
```

Devuelve un objeto `DynamicFrame` nuevo sin las columnas nulas.

> **Note**
>
> Solo se eliminan las columnas del tipo `NullType`. Los valores nulos individuales de otras columnas no se eliminan ni modifican.

def errorsAsDynamicFrame

```
def errorsAsDynamicFrame
```

Devuelve un objeto `DynamicFrame` nuevo que contiene los registros de error de este `DynamicFrame`.

Def filter

```
def filter( f : DynamicRecord => Boolean,
            errorMsg : String = "",
            transformationContext : String = "",
            callSite : CallSite = CallSite("Not provided"),
            stageThreshold : Long = 0,
            totalThreshold : Long = 0
          ) : DynamicFrame
```

Crea un objeto `DynamicFrame` nuevo que solo contiene los registros en los que la función "f" devuelve `true`. La función de filtro "f" no debe mutar el registro de entrada.

Def getName

```
def getName : String
```

Devuelve el nombre de este objeto `DynamicFrame`.

Def getNumPartitions

```
def getNumPartitions
```

Devuelve el número de particiones en este objeto `DynamicFrame`.

Def getSchemaIfComputed

```
def getSchemaIfComputed : Option[Schema]
```

Devuelve el esquema si ya se ha calculado. No analiza los datos si aún no se ha calculado el esquema.

Def isSchemaComputed

```
def isSchemaComputed : Boolean
```

Devuelve `true` si el esquema se ha calculado para este objeto `DynamicFrame`, de lo contrario devuelve `false`. Si este método devuelve false, la llamada al método `schema` necesitará otra pasada por los registros en este objeto `DynamicFrame`.

Def javaToPython

```
def javaToPython : JavaRDD[Array[Byte]]
```

Def join

```
def join( keys1 : Seq[String],
          keys2 : Seq[String],
          frame2 : DynamicFrame,
          transformationContext : String = "",
          callSite : CallSite = CallSite("Not provided", ""),
          stageThreshold : Long = 0,
          totalThreshold : Long = 0
        ) : DynamicFrame
```

- `keys1`: las columnas de este objeto `DynamicFrame` que se utilizarán para la combinación.

- `keys2`: las columnas de `frame2` que se utilizarán para la combinación. Deben tener la misma longitud que `keys1`.
- `frame2`: el elemento `DynamicFrame` con el que debe realizarse la combinación.

Devuelve el resultado de realizar una combinación equijoin con `frame2` utilizando las claves especificadas.

Def map

```
def map( f : DynamicRecord => DynamicRecord,
         errorMsg : String = "",
         transformationContext : String = "",
         callSite : CallSite = CallSite("Not provided", ""),
         stageThreshold : Long = 0,
         totalThreshold : Long = 0
       ) : DynamicFrame
```

Devuelve un objeto `DynamicFrame` nuevo creado aplicando la función "f" especificada a cada registro de este objeto `DynamicFrame`.

Este método copia cada registro antes de aplicar la función especificada, por lo que es seguro para mutar los registros. Si la función de mapeo genera una excepción en un registro determinado, dicho registro se marca como un error y la pila de seguimiento se guarda como una columna en el registro de errores.

Def mergeDynamicFrames

```
def mergeDynamicFrames( stageDynamicFrame: DynamicFrame,  primaryKeys: Seq[String],
 transformationContext: String = "",
                         options: JsonOptions = JsonOptions.empty, callSite: CallSite =
 CallSite("Not provided"),
                         stageThreshold: Long = 0, totalThreshold: Long = 0):
 DynamicFrame
```

- `stageDynamicFrame`: `DynamicFrame` provisional que se fusionará.
- `primaryKeys`: la lista de campos de clave principal para hacer coincidir los registros de los `DynamicFrame` de origen y provisionales.
- `transformationContext`: una cadena única que se utiliza para recuperar metadatos sobre la transformación actual (opcional).

- `options`: una cadena de pares de nombre-valor de JSON que proporcionan información adicional para esta transformación.
- `callSite`: se utiliza para proporcionar información de contexto para los informes de error.
- `stageThreshold`: un valor `Long`. Número de errores de la transformación especificada que provocarán que el proceso se termine.
- `totalThreshold`: un valor `Long`. Número total de errores hasta esta transformación (incluida) que provocarán que el proceso se termine.

Combina este objeto `DynamicFrame` con una instancia provisional de `DynamicFrame` en función de las claves principales especificadas para identificar registros. Los registros duplicados (registros con las mismas claves principales) no se eliminan. Si no hay ningún registro que coincida en el marco provisional, se retienen todos los registros del origen (incluidos los duplicados). Si el marco provisional tiene registros coincidentes, estos sobrescriben a los registros del origen en AWS Glue.

La instancia de `DynamicFrame` devuelta contiene el registro A en los siguientes casos:

1. Si `A` existe tanto en el marco de origen como en el marco provisional, se devuelve `A` en el marco provisional.
2. Si `A` está en la tabla de origen y `A.primaryKeys` no está en `stagingDynamicFrame` (significa que `A` no se actualiza en la tabla provisional).

No es necesario que el marco de origen y el marco provisional tengan el mismo esquema.

Example

```
val mergedFrame: DynamicFrame = srcFrame.mergeDynamicFrames(stageFrame, Seq("id1",
 "id2"))
```

Def printSchema

```
def printSchema : Unit
```

Imprime el esquema de este objeto `DynamicFrame` en `stdout` en un formato fácil de leer.

Def recomputeSchema

```
def recomputeSchema : Schema
```

Fuerza un nuevo cálculo del esquema. Es necesario realizar un análisis de los datos, lo que podría "endurecer" el esquema si hay algunos campos del esquema actual que no están en los datos.

Devuelve el esquema calculado de nuevo.

Def relationalize

```
def relationalize( rootTableName : String,
                   stagingPath : String,
                   options : JsonOptions = JsonOptions.empty,
                   transformationContext : String = "",
                   callSite : CallSite = CallSite("Not provided"),
                   stageThreshold : Long = 0,
                   totalThreshold : Long = 0
                 ) : Seq[DynamicFrame]
```

- `rootTableName`: el nombre que se va a utilizar para el `DynamicFrame` base en la salida. Los `DynamicFrame` que se crean mediante matrices dinámicas comienzan con este prefijo.
- `stagingPath`: la ruta de Amazon Simple Storage Service (Amazon S3) para escribir datos intermedios.
- `options`: opciones y configuración de Rationalize. En la actualidad no se utiliza.

Aplana todas las estructuras anidadas y convierte las matrices en tablas independientes.

Puede utilizar esta operación para preparar datos con anidamiento profundo para su incorporación a una base de datos relacional. Las estructuras anidadas se aplanan de la misma manera en que lo haría la transformación Unnest. Además, las matrices se dividen en tablas independientes en las que cada elemento de matriz se convierte en una fila. Por ejemplo, supongamos que tiene una instancia de `DynamicFrame` con los siguientes datos.

```
 {"name": "Nancy", "age": 47, "friends": ["Fred", "Lakshmi"]}
 {"name": "Stephanie", "age": 28, "friends": ["Yao", "Phil", "Alvin"]}
 {"name": "Nathan", "age": 54, "friends": ["Nicolai", "Karen"]}
```

Ejecute el siguiente código.

```
{{{
  df.relationalize("people", "s3:/my_bucket/my_path", JsonOptions.empty)
}}}
```

Se generan dos tablas. La primera tabla se denomina "people" y contiene lo siguiente.

```
{{{
  {"name": "Nancy", "age": 47, "friends": 1}
  {"name": "Stephanie", "age": 28, "friends": 2}
  {"name": "Nathan", "age": 54, "friends": 3)
}}}
```

Aquí, la matriz friends se ha reemplazado por una clave de combinación generada automáticamente. Se crea una tabla diferente llamada `people.friends` con el siguiente contenido.

```
{{{
  {"id": 1, "index": 0, "val": "Fred"}
  {"id": 1, "index": 1, "val": "Lakshmi"}
  {"id": 2, "index": 0, "val": "Yao"}
  {"id": 2, "index": 1, "val": "Phil"}
  {"id": 2, "index": 2, "val": "Alvin"}
  {"id": 3, "index": 0, "val": "Nicolai"}
  {"id": 3, "index": 1, "val": "Karen"}
}}}
```

En esta tabla, "`id`" es una clave de combinación que identifica de qué registro procede el elemento de matriz, "`index`" hace referencia a la posición en la matriz original y "`val`" es la entrada de matriz real.

El método `relationalize` devuelve la secuencia de objetos `DynamicFrame` creados aplicando este proceso de forma recursiva a todas las matrices.

> **Note**
>
> La biblioteca de AWS Glue genera automáticamente las claves de combinación de las tablas nuevas. Para garantizar que las claves de combinación sean únicas en las ejecuciones de flujo de trabajo, debe habilitar los marcadores de flujo de trabajo.

Def renameField

```
def renameField( oldName : String,
                 newName : String,
                 transformationContext : String = "",
```

```
                callSite : CallSite = CallSite("Not provided", ""),
                stageThreshold : Long = 0,
                totalThreshold : Long = 0
              ) : DynamicFrame
```

- `oldName`: el nombre original de la columna.
- `newName`: el nuevo nombre de la columna.

Devuelve un `DynamicFrame` nuevo que incluye el campo especificado con un nuevo nombre.

Puede usar este método para cambiar el nombre de los campos anidados. Por ejemplo, el siguiente código cambiaría el nombre de `state` a `state_code` en la estructura de dirección.

```
{{{
  df.renameField("address.state", "address.state_code")
}}}
```

Def repartition

```
def repartition( numPartitions : Int,
                 transformationContext : String = "",
                 callSite : CallSite = CallSite("Not provided", ""),
                 stageThreshold : Long = 0,
                 totalThreshold : Long = 0
               ) : DynamicFrame
```

Devuelve un objeto `DynamicFrame` nuevo con `numPartitions` particiones.

Def resolveChoice

```
def resolveChoice( specs : Seq[Product2[String, String]] = Seq.empty[ResolveSpec],
                   choiceOption : Option[ChoiceOption] = None,
                   database : Option[String] = None,
                   tableName : Option[String] = None,
                   transformationContext : String = "",
                   callSite : CallSite = CallSite("Not provided", ""),
                   stageThreshold : Long = 0,
                   totalThreshold : Long = 0
                 ) : DynamicFrame
```

- `choiceOption`: acción que se aplica a todas las columnas `ChoiceType` que no están indicadas en la secuencia specs.
- `database`: la base de datos de Data Catalog que se usará con la acción `match_catalog`.
- `tableName`: la tabla de Data Catalog que se usará con la acción `match_catalog`.

Devuelve un objeto `DynamicFrame` nuevo reemplazando uno o varios `ChoiceType` por un tipo más específico.

Hay dos formas de usar `resolveChoice`. La primera consiste en especificar una secuencia de columnas específicas y cómo resolverlas. Se especifican como tuplas compuestas de pares (columna, acción).

Los posibles valores son los siguientes:

- `cast:type`: intenta convertir todos los valores al tipo especificado.
- `make_cols`: convierte cada tipo diferenciado en una columna con el nombre `columnName_type`.
- `make_struct`: convierte una columna en una estructura con claves para cada tipo diferenciado.
- `project:type`: retiene solo valores del tipo especificado.

El otro modo de `resolveChoice` es especificar una resolución única para todas las columnas `ChoiceType`. Se puede utilizar en los casos en los que se desconozca la lista completa de `ChoiceType` antes de la ejecución. Además de las acciones enumeradas anteriormente, este modo también admite la siguiente acción:

- `match_catalog`: intenta convertir cada `ChoiceType` al tipo correspondiente en la tabla de catálogos especificada.

Ejemplos:

Resolver la columna `user.id` mediante la conversión a int y hacer que el campo `address` solo conserve estructuras.

```
{{{
  df.resolveChoice(specs = Seq(("user.id", "cast:int"), ("address", "project:struct")))
}}}
```

Resolver todas las columnas `ChoiceType` convirtiendo cada opción en una columna independiente.

```
{{{
  df.resolveChoice(choiceOption = Some(ChoiceOption("make_cols")))
}}}
```

Resolver todas las columnas `ChoiceType` mediante la conversión a los tipos de la tabla de catálogos especificada.

```
{{{
  df.resolveChoice(choiceOption = Some(ChoiceOption("match_catalog")),
                   database = Some("my_database"),
                   tableName = Some("my_table"))
}}}
```

Def schema

```
def schema : Schema
```

Devuelve el esquema de este objeto `DynamicFrame`.

El esquema devuelto contiene todos los campos presentes en un registro en este objeto `DynamicFrame`. Sin embargo, en un pequeño número de casos, es posible que también contenga campos adicionales. Puede usar el método Unnest para "ajustar" el esquema en función de los registros de este objeto `DynamicFrame`.

Def selectField

```
def selectField( fieldName : String,
                 transformationContext : String = "",
                 callSite : CallSite = CallSite("Not provided", ""),
                 stageThreshold : Long = 0,
                 totalThreshold : Long = 0
               ) : DynamicFrame
```

Devuelve un campo individual como un objeto `DynamicFrame`.

Def selectFields

```
def selectFields( paths : Seq[String],
                  transformationContext : String = "",
```

```
                  callSite : CallSite = CallSite("Not provided", ""),
                  stageThreshold : Long = 0,
                  totalThreshold : Long = 0
                ) : DynamicFrame
```

- `paths`: secuencia de los nombres de columna que se seleccionarán.

Devuelve un nuevo objeto `DynamicFrame` que contiene las columnas especificadas.

> **Note**
>
> Solo puede usar el método `selectFields` para seleccionar columnas de nivel superior. Puede usar el método applyMapping para seleccionar columnas anidadas.

Def show

```
def show( numRows : Int = 20 ) : Unit
```

- `numRows`: número de filas que se imprimirán.

Imprime filas de este objeto `DynamicFrame` en formato JSON.

Def simplifyDDBJson

Las exportaciones de DynamoDB con el conector de exportaciones de DynamoDB de AWS Glue generan archivos JSON con estructuras anidadas específicas. Para obtener más información, consulte Objetos de datos. `simplifyDDBJson` Simplifica las columnas anidadas en un DynamicFrame de este tipo de datos y genera un DynamicFrame nuevo y simplificado. Si hay varios tipos y un tipo de mapa contenidos en tipo de lista, los elementos en la lista no se simplificarán. Este método solo es compatible con los datos exportados de DynamoDB con el formato JSON. Considere la acción de `unnest` para realizar cambios similares en otros tipos de datos.

```
def simplifyDDBJson() : DynamicFrame
```

Este método no toma ningún parámetro.

Ejemplo de entrada

Considere el siguiente esquema generado por una exportación a DynamoDB:

```
root
|-- Item: struct
|    |-- parentMap: struct
|    |    |-- M: struct
|    |    |    |-- childMap: struct
|    |    |    |    |-- M: struct
|    |    |    |    |    |-- appName: struct
|    |    |    |    |    |    |-- S: string
|    |    |    |    |    |-- packageName: struct
|    |    |    |    |    |    |-- S: string
|    |    |    |    |    |-- updatedAt: struct
|    |    |    |    |    |    |-- N: string
|    |-- strings: struct
|    |    |-- SS: array
|    |    |    |-- element: string
|    |-- numbers: struct
|    |    |-- NS: array
|    |    |    |-- element: string
|    |-- binaries: struct
|    |    |-- BS: array
|    |    |    |-- element: string
|    |-- isDDBJson: struct
|    |    |-- BOOL: boolean
|    |-- nullValue: struct
|    |    |-- NULL: boolean
```

Código de ejemplo

```
import com.amazonaws.services.glue.GlueContext
import com.amazonaws.services.glue.util.GlueArgParser
import com.amazonaws.services.glue.util.Job
import com.amazonaws.services.glue.util.JsonOptions
import com.amazonaws.services.glue.DynamoDbDataSink
import org.apache.spark.SparkContextimport scala.collection.JavaConverters._

object GlueApp {

  def main(sysArgs: Array[String]): Unit = {
    val glueContext = new GlueContext(SparkContext.getOrCreate())
    val args = GlueArgParser.getResolvedOptions(sysArgs, Seq("JOB_NAME").toArray)
    Job.init(args("JOB_NAME"), glueContext, args.asJava)
```

```
    val dynamicFrame = glueContext.getSourceWithFormat(
      connectionType = "dynamodb",
      options = JsonOptions(Map(
        "dynamodb.export" -> "ddb",
        "dynamodb.tableArn" -> "ddbTableARN",
        "dynamodb.s3.bucket" -> "exportBucketLocation",
        "dynamodb.s3.prefix" -> "exportBucketPrefix",
        "dynamodb.s3.bucketOwner" -> "exportBucketAccountID",
      ))
    ).getDynamicFrame()

    val simplified = dynamicFrame.simplifyDDBJson()
    simplified.printSchema()

    Job.commit()
  }

}
```

Ejemplo de resultado

La transformación de `simplifyDDBJson` simplificará esto de la siguiente forma:

```
root
|-- parentMap: struct
|    |-- childMap: struct
|    |    |-- appName: string
|    |    |-- packageName: string
|    |    |-- updatedAt: string
|-- strings: array
|    |-- element: string
|-- numbers: array
|    |-- element: string
|-- binaries: array
|    |-- element: string
|-- isDDBJson: boolean
|-- nullValue: null
```

Def spigot

```
def spigot( path : String,
            options : JsonOptions = new JsonOptions("{}"),
```

```
            transformationContext : String = "",
            callSite : CallSite = CallSite("Not provided"),
            stageThreshold : Long = 0,
            totalThreshold : Long = 0
          ) : DynamicFrame
```

Transformación de paso a través que devuelve los mismos registros, pero escribe un subconjunto de registros como efecto secundario.

- `path`: ruta de Amazon S3 en la que se escribirá la salida, con el formato `s3://bucket//path`.
- `options`: mapa `JsonOptions` opcional que describe el comportamiento de muestreo.

Devuelve un objeto `DynamicFrame` que contiene los mismos registros que este.

De forma predeterminada, escribe 100 registros arbitrarios en la ubicación especificada por `path`. Puede personalizar este comportamiento mediante el mapa `options`. Entre las claves válidas se incluyen:

- `topk`: especifica el número total de registros escritos. El valor predeterminado es 100.
- `prob`: especifica la probabilidad de que se incluya un registro individual (como decimal). El valor predeterminado es 1.

Por ejemplo, la siguiente llamada realizaría un muestreo del conjunto de datos seleccionando cada registro con una probabilidad del 20 % y se detendría después de que se hubieran escrito 200 registros.

```
{{{
  df.spigot("s3://my_bucket/my_path", JsonOptions(Map("topk" -&gt; 200, "prob" -&gt;
 0.2)))
}}}
```

Def splitFields

```
def splitFields( paths : Seq[String],
                 transformationContext : String = "",
                 callSite : CallSite = CallSite("Not provided", ""),
                 stageThreshold : Long = 0,
                 totalThreshold : Long = 0
               ) : Seq[DynamicFrame]
```

- `paths`: las rutas que se incluirán en el primer objeto `DynamicFrame`.

Devuelve una secuencia de dos objetos `DynamicFrame`. El primer `DynamicFrame` contiene las rutas especificadas y el segundo contiene las demás columnas.

Ejemplo

En este ejemplo, se toma un objeto DynamicFrame creado a partir de la tabla `persons` en la base de datos `legislators` de Data Catalog de AWS Glue y divide el DynamicFrame en dos, con los campos especificados incluidos en el primer DynamicFrame y los campos restantes incluidos en un segundo DynamicFrame. Luego, el ejemplo elige el primer DynamicFrame del resultado.

```
val InputFrame = glueContext.getCatalogSource(database="legislators",
 tableName="persons",
transformationContext="InputFrame").getDynamicFrame()

val SplitField_collection = InputFrame.splitFields(paths=Seq("family_name", "name",
 "links.note",
"links.url", "gender", "image", "identifiers.scheme", "identifiers.identifier",
 "other_names.lang",
"other_names.note", "other_names.name"), transformationContext="SplitField_collection")

val ResultFrame = SplitField_collection(0)
```

Def splitRows

```
def splitRows( paths : Seq[String],
               values : Seq[Any],
               operators : Seq[String],
               transformationContext : String,
               callSite : CallSite,
               stageThreshold : Long,
               totalThreshold : Long
             ) : Seq[DynamicFrame]
```

Divide las filas en función de predicados que comparan columnas con constantes.

- `paths`: columnas que se van a utilizar para la comparación.
- `values`: valores constantes que se van a utilizar para la comparación.
- `operators`: operadores que se van a utilizar para la comparación.

Devuelve una secuencia de dos objetos DynamicFrame. El primero contiene filas en las que se aplica el predicado y el segundo contiene las que no se les aplica.

Los predicados se especifican usando tres secuencias: "paths" contiene los nombres de columna (posiblemente anidadas), "values" contiene los valores constantes con los que se realizará la comparación y "operators" contiene los operadores que se usarán para la comparación. Las tres secuencias deben tener la misma longitud: el operador que ocupa la posición n se usa para comparar la columna n con el valor n.

Cada operador debe ser uno de los siguientes: "!=", "=", "<=", "<", ">=" o ">".

A modo de ejemplo, la siguiente llamada dividiría un objeto DynamicFrame de modo que el primer marco de salida contuviera los registros de personas de más de 65 años de Estados Unidos y el segundo contuviera todos los demás registros.

```
{{{
  df.splitRows(Seq("age", "address.country"), Seq(65, "USA"), Seq("&gt;=", "="))
}}}
```

Def stageErrorsCount

```
def stageErrorsCount
```

Devuelve el número de registros de error creado al calcular este objeto DynamicFrame. Se excluyen los errores de operaciones anteriores que se pasaron a este objeto DynamicFrame como entrada.

Def toDF

```
def toDF( specs : Seq[ResolveSpec] = Seq.empty[ResolveSpec] ) : DataFrame
```

Convierte este DynamicFrame en un DataFrame Apache Spark SQL con el mismo esquema y registros.

> **Note**
>
> Dado que los objetos DataFrame no admiten ChoiceType, este método convierte automáticamente las columnas ChoiceType en StructType. Para obtener más información y opciones para la resolución de elección, consulte resolveChoice.

Def unbox

```
def unbox( path : String,
           format : String,
           optionString : String = "{}",
           transformationContext : String = "",
           callSite : CallSite = CallSite("Not provided"),
           stageThreshold : Long = 0,
           totalThreshold : Long = 0
         ) : DynamicFrame
```

- `path`: la columna que se va a analizar. Debe tener formato de cadena o binario.
- `format`: el formato que se utilizará para el análisis.
- `optionString`: opciones que se pasarán al formato, como el separador CSV.

Analiza una cadena insertada o una columna binaria de acuerdo con el formato especificado. Las columnas analizadas se anidan en una estructura con el nombre de columna original.

Por ejemplo, suponga que tiene un archivo CSV con una columna JSON insertada.

```
name, age, address
Sally, 36, {"state": "NE", "city": "Omaha"}
...
```

Después de un análisis inicial, obtendrá un objeto `DynamicFrame` con el siguiente esquema.

```
{{{
  root
  |-- name: string
  |-- age: int
  |-- address: string
}}}
```

Puede llamar a `unbox` en la columna de dirección para analizar los componentes específicos.

```
{{{
  df.unbox("address", "json")
}}}
```

Esto nos proporciona un objeto DynamicFrame con el siguiente esquema.

```
{{{
  root
  |-- name: string
  |-- age: int
  |-- address: struct
  |    |-- state: string
  |    |-- city: string
}}}
```

Def unnest

```
def unnest( transformationContext : String = "",
            callSite : CallSite = CallSite("Not Provided"),
            stageThreshold : Long = 0,
            totalThreshold : Long = 0
          ) : DynamicFrame
```

Devuelve un objeto DynamicFrame nuevo con todas las estructuras anidadas aplanadas. Los nombres se crean con el carácter "." (punto).

Por ejemplo, suponga que tiene una instancia de DynamicFrame con el siguiente esquema.

```
{{{
  root
  |-- name: string
  |-- age: int
  |-- address: struct
  |    |-- state: string
  |    |-- city: string
}}}
```

La siguiente llamada elimina el anidamiento de la estructura de dirección:

```
{{{
  df.unnest()
}}}
```

El esquema resultante es el siguiente.

```
{{{
  root
  |-- name: string
  |-- age: int
  |-- address.state: string
  |-- address.city: string
}}}
```

Este método también aplana las estructuras anidadas de dentro de las matrices. Sin embargo, por razones históricas, los nombres de dichos campos tienen anexado previamente el nombre de la matriz contenedora y "`.val`".

Def unnestDDBJson

```
unnestDDBJson(transformationContext : String = "",
            callSite : CallSite = CallSite("Not Provided"),
            stageThreshold : Long = 0,
            totalThreshold : Long = 0): DynamicFrame
```

Desanida las columnas anidadas de un elemento `DynamicFrame` que se encuentren específicamente en la estructura JSON de DynamoDB y devuelve un nuevo elemento `DynamicFrame` no anidado. Las columnas que sean de una matriz de tipos de estructuras no se desanidarán. Tenga en cuenta que esta transformación de desanidamiento es un tipo específico que se comporta de modo diferente a la transformación `unnest` normal y requiere que los datos ya estén en la estructura JSON de DynamoDB. Para obtener más información, consulte JSON de DynamoDB.

Por ejemplo, el esquema de una lectura de una exportación con la estructura JSON de DynamoDB puede parecerse al siguiente:

```
root
|-- Item: struct
|    |-- ColA: struct
|    |    |-- S: string
|    |-- ColB: struct
|    |    |-- S: string
|    |-- ColC: struct
|    |    |-- N: string
|    |-- ColD: struct
|    |    |-- L: array
|    |    |    |-- element: null
```

La transformación `unnestDDBJson()` convertiría esto en:

```
root
|-- ColA: string
|-- ColB: string
|-- ColC: string
|-- ColD: array
|    |-- element: null
```

En el siguiente ejemplo de código, se muestra cómo utilizar el conector de exportación de DynamoDB de AWS Glue, invocar un desanidamiento JSON de DynamoDB e imprimir el número de particiones:

```
import com.amazonaws.services.glue.GlueContext
import com.amazonaws.services.glue.util.GlueArgParser
import com.amazonaws.services.glue.util.Job
import com.amazonaws.services.glue.util.JsonOptions
import com.amazonaws.services.glue.DynamoDbDataSink
import org.apache.spark.SparkContext
import scala.collection.JavaConverters._


object GlueApp {

  def main(sysArgs: Array[String]): Unit = {
    val glueContext = new GlueContext(SparkContext.getOrCreate())
    val args = GlueArgParser.getResolvedOptions(sysArgs, Seq("JOB_NAME").toArray)
    Job.init(args("JOB_NAME"), glueContext, args.asJava)

    val dynamicFrame = glueContext.getSourceWithFormat(
      connectionType = "dynamodb",
      options = JsonOptions(Map(
        "dynamodb.export" -> "ddb",
        "dynamodb.tableArn" -> "<test_source>",
        "dynamodb.s3.bucket" -> "<bucket name>",
        "dynamodb.s3.prefix" -> "<bucket prefix>",
        "dynamodb.s3.bucketOwner" -> "<account_id of bucket>",
      ))
    ).getDynamicFrame()

    val unnested = dynamicFrame.unnestDDBJson()
    print(unnested.getNumPartitions())
```

```
    Job.commit()
  }

}
```

Def withFrameSchema

```
def withFrameSchema( getSchema : () => Schema ) : DynamicFrame
```

- `getSchema`: función que devuelve el esquema que se va a utilizar. Se especifica como una función sin parámetros para diferir el cómputo potencialmente costoso.

Establece el esquema de este objeto `DynamicFrame` en el valor especificado. Se utiliza principalmente de forma interna para evitar un nuevo y costoso cálculo de esquema. El esquema pasado debe contener todas las columnas presentes en los datos.

Def withName

```
def withName( name : String ) : DynamicFrame
```

- `name`: nuevo nombre que se usará.

Devuelve una copia de este objeto `DynamicFrame` con un nuevo nombre.

Def withTransformationContext

```
def withTransformationContext( ctx : String ) : DynamicFrame
```

Devuelve una copia de este objeto `DynamicFrame` con el contexto de transformación especificado.

Objeto DynamicFrame

Paquete: com.amazonaws.services.glue

```
object DynamicFrame
```

Def apply

```
def apply( df : DataFrame,
```

```
            glueContext : GlueContext
          ) : DynamicFrame
```

def emptyDynamicFrame

```
def emptyDynamicFrame( glueContext : GlueContext ) : DynamicFrame
```

Def fromPythonRDD

```
def fromPythonRDD( rdd : JavaRDD[Array[Byte]],
                   glueContext : GlueContext
                 ) : DynamicFrame
```

Def ignoreErrors

```
def ignoreErrors( fn : DynamicRecord => DynamicRecord ) : DynamicRecord
```

Def inlineErrors

```
def inlineErrors( msg : String,
                  callSite : CallSite
                ) : (DynamicRecord => DynamicRecord)
```

Def newFrameWithErrors

```
def newFrameWithErrors( prevFrame : DynamicFrame,
                        rdd : RDD[DynamicRecord],
                        name : String = "",
                        transformationContext : String = "",
                        callSite : CallSite,
                        stageThreshold : Long,
                        totalThreshold : Long
                      ) : DynamicFrame
```

Clase DynamicRecord Scala de AWS Glue

Temas

- Def addField
- Def dropField
- Def setError
- Def isError
- Def getError
- Def clearError
- Def write
- Def readFields
- Def clone
- Def schema
- Def getRoot
- Def toJson
- Def getFieldNode
- Def getField
- Def hashCode
- Def equals
- Objeto DynamicRecord
- Característica RecordTraverser

Paquete: com.amazonaws.services.glue

```
class DynamicRecord extends Serializable with Writable with Cloneable
```

Un objeto `DynamicRecord` es una estructura de datos autodescriptiva que representa una fila de datos en el conjunto de datos que se está procesando. Es autodescriptiva en el sentido de que se puede obtener el esquema de la fila representado mediante el objeto `DynamicRecord` si se inspecciona el registro. Un objeto `DynamicRecord` es similar a `Row` en Apache Spark.

Def addField

```
def addField( path : String,
              dynamicNode : DynamicNode
```

```
            ) : Unit
```

Agrega un objeto DynamicNode a la ruta especificada.

- `path`: ruta del campo que se va a agregar.
- `dynamicNode`: DynamicNode que se agregará a la ruta especificada.

Def dropField

```
def dropField(path: String, underRename: Boolean = false): Option[DynamicNode]
```

Descarta un objeto DynamicNode de la ruta especifica y devuelve el nodo descartado si no hay una matriz en la ruta especificada.

- `path`: ruta al campo que se descartará.
- `underRename`: true si se llama a `dropField` como parte de una transformación de cambio de nombre; de lo contrario, false (false de forma predeterminada).

Devuelve `scala.Option Option` (DynamicNode).

Def setError

```
def setError( error : Error )
```

Establece este registro como un registro de error, tal y como se especifica mediante el parámetro `error`.

Devuelve `DynamicRecord`.

Def isError

```
def isError
```

Comprueba si es un registro de error.

Def getError

```
def getError
```

Obtiene el `Error` si es un registro de error. Devuelve `scala.Some` Some (Error) si es un registro de error; de lo contrario, `scala.None`.

Def clearError

```
def clearError
```

Configure el `Error` en `scala.None.None`.

Def write

```
override def write( out : DataOutput ) : Unit
```

Def readFields

```
override def readFields( in : DataInput ) : Unit
```

Def clone

```
override def clone : DynamicRecord
```

Clona este registro en un nuevo objeto `DynamicRecord` y lo devuelve.

Def schema

```
def schema
```

Obtiene el objeto `Schema` mediante la inspección del registro.

Def getRoot

```
def getRoot : ObjectNode
```

Obtiene el objeto `ObjectNode` raíz del registro.

Def toJson

```
def toJson : String
```

Obtiene la cadena JSON del registro.

Def getFieldNode

```
def getFieldNode( path : String ) : Option[DynamicNode]
```

Obtiene el valor del campo en la `path` especificada como una opción de `DynamicNode`.

Devuelve `scala.Some` Some (DynamicNode) si el campo existe; de lo contrario, `scala.None.None`.

Def getField

```
def getField( path : String ) : Option[Any]
```

Obtiene el valor del campo en la `path` especificada como una opción de `DynamicNode`.

Devuelve `scala.Some` Some (valor).

Def hashCode

```
override def hashCode : Int
```

Def equals

```
override def equals( other : Any )
```

Objeto DynamicRecord

```
object DynamicRecord
```

Def apply

```
def apply( row : Row,
           schema : SparkStructType )
```

Aplique el método para convertir un objeto Row de Apache Spark SQL en un objeto DynamicRecord.

- `row`: un objeto Row de Spark SQL.
- `schema`: el objeto Schema de la fila.

Devuelve `DynamicRecord`.

Característica RecordTraverser

```
trait RecordTraverser {
  def nullValue(): Unit
  def byteValue(value: Byte): Unit
  def binaryValue(value: Array[Byte]): Unit
  def booleanValue(value: Boolean): Unit
  def shortValue(value: Short) : Unit
  def intValue(value: Int) : Unit
  def longValue(value: Long) : Unit
  def floatValue(value: Float): Unit
  def doubleValue(value: Double): Unit
  def decimalValue(value: BigDecimal): Unit
  def stringValue(value: String): Unit
  def dateValue(value: Date): Unit
  def timestampValue(value: Timestamp): Unit
  def objectStart(length: Int): Unit
  def objectKey(key: String): Unit
  def objectEnd(): Unit
  def mapStart(length: Int): Unit
  def mapKey(key: String): Unit
  def mapEnd(): Unit
  def arrayStart(length: Int): Unit
  def arrayEnd(): Unit
}
```

API GlueContext Scala de AWS Glue

Paquete: com.amazonaws.services.glue

```
class GlueContext extends SQLContext(sc) (
           @transient val sc : SparkContext,
           val defaultSourcePartitioner : PartitioningStrategy )
```

`GlueContext` es el punto de entrada para leer y escribir un DynamicFrame desde y hacia Amazon Simple Storage Service (Amazon S3), el AWS Glue Data Catalog, JDBC, etc. Esta clase ofrece

funciones de utilidades para crear objetos Característica DataSource y DataSink que, a su vez, se pueden usar para leer y escribir objetos DynamicFrame.

También se puede utilizar GlueContext para establecer un número de particiones de destino (el valor predeterminado es 20) en el objeto DynamicFrame si el número de particiones creadas desde el origen es menor que un umbral mínimo para las particiones (el valor predeterminado es 10).

def addIngestionTimeColumns

```
def addIngestionTimeColumns(
         df : DataFrame,
         timeGranularity : String = "") : dataFrame
```

Agrega columnas de tiempo de ingesta como ingest_year, ingest_month, ingest_day, ingest_hour, ingest_minute al DataFrame de entrada. Esta función se genera en forma automática en el script generado por AWS Glue cuando especifique una tabla del Catálogo de datos con Amazon S3 como destino. Esta función actualiza en forma automática la partición con columnas de tiempo de ingesta en la tabla de salida. Esto permite que los datos de salida se dividan automáticamente en el tiempo de ingesta sin requerir columnas de tiempo de ingesta explícitas en los datos de entrada.

- dataFrame: el dataFrame al que anexar las columnas de tiempo de ingesta.
- timeGranularity: la granularidad de las columnas de tiempo. Los valores válidos son “day”, “hour” y “minute”. Por ejemplo, si “hour” se transfiere a la función, el dataFrame original tendrá las columnas de tiempo “ingest_year,” “ingest_month,” “ingest_day” y “ingest_hour” anexadas.

Devuelve el marco de datos después de anexar las columnas de granularidad de tiempo.

Ejemplo:

```
glueContext.addIngestionTimeColumns(dataFrame, "hour")
```

def createDataFrameFromOptions

```
def createDataFrameFromOptions( connectionType : String,
                        connectionOptions : JsonOptions,
                        transformationContext : String = "",
```

```
                        format : String = null,
                        formatOptions : JsonOptions = JsonOptions.empty
                      ) : DataSource
```

Muestra un `DataFrame` que se crea con la conexión y el formato especificados. Utilice esta función sólo con orígenes de streaming de AWS Glue.

- `connectionType`: el tipo de conexión de streaming. Los valores válidos son `kinesis` y `kafka`.
- `connectionOptions`: opciones de conexión, que son diferentes para Kinesis y Kafka. Puede encontrar la lista de todas las opciones de conexión para cada origen de datos de streaming en Tipos de conexión y opciones para ETL en AWS Glue para Spark. Tenga en cuenta las siguientes diferencias en las opciones de conexión de streaming:
  - Los orígenes de streaming de Kinesis requieren `streamARN`, `startingPosition`, `inferSchema` y `classification`.
  - Los orígenes de streaming de Kafka requieren `connectionName`, `topicName`, `startingOffsets`, `inferSchema` y `classification`.
- `transformationContext`: el contexto de transformación que se va a utilizar (opcional).
- `format`: una especificación de formato (opcional). Se utiliza con una conexión de Amazon S3 o AWS Glue que admite diversos formatos. Para obtener información acerca de los formatos soportados, consulte Opciones de formato de datos para las entradas y las salidas en AWS Glue para Spark
- `formatOptions`: opciones de formato para el formato especificado. Para obtener información acerca de las opciones de formatos soportados, consulte Opciones de formato de datos.

Ejemplo de origen de streaming de Amazon Kinesis:

```
val data_frame_datasource0 =
glueContext.createDataFrameFromOptions(transformationContext = "datasource0",
 connectionType = "kinesis",
connectionOptions = JsonOptions("""{"streamName": "example_stream", "startingPosition":
 "TRIM_HORIZON", "inferSchema": "true", "classification": "json"}}""""))
```

Ejemplo de origen de streaming de Kafka:

```
val data_frame_datasource0 =
glueContext.createDataFrameFromOptions(transformationContext = "datasource0",
 connectionType = "kafka",
```

```
connectionOptions = JsonOptions("""{"connectionName": "example_connection",
 "topicName": "example_topic", "startingPosition": "earliest", "inferSchema": "false",
 "classification": "json", "schema":"`column1` STRING, `column2` STRING"}"""))
```

forEachBatch

`forEachBatch(frame, batch_function, options)`

Se aplica la `batch_function` transferida a cada microlote que se lee desde el origen de streaming.

- `frame`: el DataFrame que contiene el microlote actual.
- `batch_function`: una función que se aplicará para cada microlote.
- `options`: una recopilación de pares clave-valor que contiene información sobre cómo procesar microlotes. Se requieren las siguientes opciones:
  - `windowSize`: cantidad de tiempo que se debe dedicar al procesamiento de cada lote.
  - `checkpointLocation`: la ubicación donde se almacenan los puntos de verificación para el trabajo de ETL de streaming.
  - `batchMaxRetries`: número máximo de reintentos permitidos para este lote si se genera un error. El valor predeterminado es 3. Esta opción sólo se puede configurar para Glue versión 2.0 y superior.

Ejemplo:

```
glueContext.forEachBatch(data_frame_datasource0, (dataFrame: Dataset[Row], batchId:
 Long) =>
   {
      if (dataFrame.count() > 0)
        {
          val datasource0 = DynamicFrame(glueContext.addIngestionTimeColumns(dataFrame,
 "hour"), glueContext)
          // @type: DataSink
          // @args: [database = "tempdb", table_name = "fromoptionsoutput",
 stream_batch_time = "100 seconds",
          //      stream_checkpoint_location = "s3://from-options-testing-eu-central-1/
fromOptionsOutput/checkpoint/",
          //      transformation_ctx = "datasink1"]
          // @return: datasink1
          // @inputs: [frame = datasource0]
          val options_datasink1 = JsonOptions(
```

```
            Map("partitionKeys" -> Seq("ingest_year", "ingest_month","ingest_day",
 "ingest_hour"),
            "enableUpdateCatalog" -> true))
          val datasink1 = glueContext.getCatalogSink(
            database = "tempdb",
            tableName = "fromoptionsoutput",
            redshiftTmpDir = "",
            transformationContext = "datasink1",
            additionalOptions = options_datasink1).writeDynamicFrame(datasource0)
        }
   }, JsonOptions("""{"windowSize" : "100 seconds",
         "checkpointLocation" : "s3://from-options-testing-eu-central-1/
fromOptionsOutput/checkpoint/"}"""))
```

def getCatalogSink

```
def getCatalogSink( database : String,
        tableName : String,
        redshiftTmpDir : String = "",
        transformationContext : String = ""
        additionalOptions: JsonOptions = JsonOptions.empty,
        catalogId: String = null
) : DataSink
```

Crea un DataSink que escribe en una ubicación especificada en una tabla definida en el Data Catalog.

- `database`: nombre de la base de datos en el Data Catalog.
- `tableName`: nombre de la tabla en el Data Catalog.
- `redshiftTmpDir`: directorio provisional que se usará con determinados receptores de datos. Se establece en un valor vacío de forma predeterminada.
- `transformationContext`: contexto de transformación asociado con el receptor que utilizarán los marcadores de trabajo. Se establece en un valor vacío de forma predeterminada.
- `additionalOptions`: opciones adicionales para AWS Glue.
- `catalogId`: ID de catálogo (ID de cuenta) del Data Catalog al que se accede. Cuando el valor es nulo, se utiliza el ID de cuenta predeterminado del intermediario.

Devuelve el `DataSink`.

def getCatalogSource

```
def getCatalogSource( database : String,
                      tableName : String,
                      redshiftTmpDir : String = "",
                      transformationContext : String = ""
                      pushDownPredicate : String = " "
                      additionalOptions: JsonOptions = JsonOptions.empty,
                      catalogId: String = null
                    ) : DataSource
```

Crea un objeto Característica DataSource que lee datos de una definición de tabla en el Data Catalog.

- `database`: nombre de la base de datos en el Data Catalog.
- `tableName`: nombre de la tabla en el Data Catalog.
- `redshiftTmpDir`: directorio provisional que se usará con determinados receptores de datos. Se establece en un valor vacío de forma predeterminada.
- `transformationContext`: contexto de transformación asociado con el receptor que utilizarán los marcadores de trabajo. Se establece en un valor vacío de forma predeterminada.
- `pushDownPredicate`: filtra particiones sin tener que enumerar y leer todos los archivos del conjunto de datos. Para obtener más información, consulte Filtrado previo con predicados de inserción.
- `additionalOptions`: conjunto de pares nombre-valor opcionales. Las opciones posibles incluyen las enumeradas en Tipos de conexión y opciones para ETL en AWS Glue para Spark, excepto por `endpointUrl`, `streamName`, `bootstrap.servers`, `security.protocol`, `topicName`, `classification` y `delimiter`. Otra opción soportada es `catalogPartitionPredicate`:

  `catalogPartitionPredicate`: puede transferir una expresión de catálogo para filtrar en función de las columnas de índice. Esto inserta el filtrado hacia el lado del servidor. Para obtener más información, consulte Índices de partición de AWS Glue. Tenga en cuenta que `push_down_predicate` y `catalogPartitionPredicate` utilizan sintaxis diferentes. El primero utiliza la sintaxis estándar de Spark SQL y el segundo utiliza el analizador JSQL.
- `catalogId`: ID de catálogo (ID de cuenta) del Data Catalog al que se accede. Cuando el valor es nulo, se utiliza el ID de cuenta predeterminado del intermediario.

Devuelve el `DataSource`.

Ejemplo de origen de streaming

```
val data_frame_datasource0 = glueContext.getCatalogSource(
    database = "tempdb",
    tableName = "test-stream-input",
    redshiftTmpDir = "",
    transformationContext = "datasource0",
    additionalOptions = JsonOptions("""{
        "startingPosition": "TRIM_HORIZON", "inferSchema": "false"}""")
    ).getDataFrame()
```

def getJDBCSink

```
def getJDBCSink( catalogConnection : String,
                 options : JsonOptions,
                 redshiftTmpDir : String = "",
                 transformationContext : String = "",
                 catalogId: String = null
               ) : DataSink
```

Crea un DataSink que escribe en una base de datos JDBC especificada en un objeto `Connection` en el Data Catalog. El objeto `Connection` tiene información para conectarse a un receptor de JDBC, incluida la URL, el nombre de usuario, la contraseña, la VPC, la subred y los grupos de seguridad.

- `catalogConnection`: nombre de la conexión en el Data Catalog que contiene la URL de JDBC en la que se va a escribir.
- `options`: cadena de pares de nombre-valor de JSON que proporcionan información adicional que se exige para escribir en un almacén de datos JDBC. Esto incluye:
  - dbtable (obligatorio): nombre de la tabla de JDBC. Para almacenes de datos de JDBC que admiten esquemas dentro de una base de datos, especifique `schema.table-name`. Si no se ha proporcionado un esquema, se usa el esquema “public” predeterminado. El siguiente ejemplo muestra un parámetro de opciones que apunta a un esquema llamado `test` y a una tabla llamada `test_table` en la base de datos `test_db`.

    ```
    options = JsonOptions("""{"dbtable": "test.test_table", "database": "test_db"}""")
    ```

  - database (obligatorio): nombre de la base de datos de JDBC.

  - Todas las opciones adicionales transferidas directamente al escritor SparkSQL de JDBC. Para obtener más información, consulte el artículo acerca del origen de datos Redshift de Spark.
- `redshiftTmpDir`: directorio provisional que se usará con determinados receptores de datos. Se establece en un valor vacío de forma predeterminada.
- `transformationContext`: contexto de transformación asociado con el receptor que utilizarán los marcadores de trabajo. Se establece en un valor vacío de forma predeterminada.
- `catalogId`: ID de catálogo (ID de cuenta) del Data Catalog al que se accede. Cuando el valor es nulo, se utiliza el ID de cuenta predeterminado del intermediario.

Código de ejemplo:

```
getJDBCSink(catalogConnection = "my-connection-name", options =
 JsonOptions("""{"dbtable": "my-jdbc-table", "database": "my-jdbc-db"}"""),
 redshiftTmpDir = "", transformationContext = "datasink4")
```

Devuelve el `DataSink`.

def getSink

```
def getSink( connectionType : String,
             connectionOptions : JsonOptions,
             transformationContext : String = ""
           ) : DataSink
```

Crea una DataSink que escribe datos a destinos tales como Amazon Simple Storage Service (Amazon S3), JDBC, el Catálogo de datos de AWS Glue o los flujos de datos de Apache Kafka o de Amazon Kinesis.

- `connectionType` — Tipo de la conexión. Consulte the section called “Parámetros de conexión”.
- `connectionOptions`: una cadena de pares de nombre-valor de JSON que proporcionan información adicional para establecer la conexión con el receptor de datos. Consulte the section called “Parámetros de conexión”.
- `transformationContext`: contexto de transformación asociado con el receptor que utilizarán los marcadores de trabajo. Se establece en un valor vacío de forma predeterminada.

Devuelve el `DataSink`.

def getSinkWithFormat

```
def getSinkWithFormat( connectionType : String,
                       options : JsonOptions,
                       transformationContext : String = "",
                       format : String = null,
                       formatOptions : JsonOptions = JsonOptions.empty
                     ) : DataSink
```

Crea una DataSink que escribe datos a destinos tales como Amazon S3, JDBC o el Catálogo de datos o los flujos de datos de Apache Kafka o de Amazon Kinesis. También establece el formato de los datos que se escribirán en el destino.

- `connectionType` — Tipo de la conexión. Consulte the section called “Parámetros de conexión”.
- `options`: cadena de pares de nombre-valor de JSON que proporcionan información adicional para establecer una conexión con el receptor de datos. Consulte the section called “Parámetros de conexión”.
- `transformationContext`: contexto de transformación asociado con el receptor que utilizarán los marcadores de trabajo. Se establece en un valor vacío de forma predeterminada.
- `format`: formato de los datos que se escribirán en el destino.
- `formatOptions`: una cadena de pares de nombre-valor de JSON que proporcionan opciones adicionales para el formato de los datos en el destino. Consulte Opciones de formato de datos.

Devuelve el `DataSink`.

def getSource

```
def getSource( connectionType : String,
               connectionOptions : JsonOptions,
               transformationContext : String = ""
               pushDownPredicate
             ) : DataSource
```

Crea una Característica DataSource que lee datos de un origen como Amazon S3, JDBC o AWS Glue Data Catalog. También soporta orígenes de datos de streaming de Kafka y Kinesis.

- `connectionType`: tipo de origen de datos. Consulte the section called “Parámetros de conexión”.

- `connectionOptions`: una cadena de pares de nombre-valor de JSON que proporcionan información adicional para establecer una conexión con el origen de datos. Para obtener más información, consulte the section called “Parámetros de conexión”.

  Un origen de streaming de Kinesis requiere las siguientes opciones de conexión: `streamARN`, `startingPosition`, `inferSchema` y `classification`.

  Un origen de streaming de Kafka requiere las siguientes opciones de conexión: `connectionName`, `topicName`, `startingOffsets`, `inferSchema` y `classification`.
- `transformationContext`: contexto de transformación asociado con el receptor que utilizarán los marcadores de trabajo. Se establece en un valor vacío de forma predeterminada.
- `pushDownPredicate`: predicado en columnas de partición.

Devuelve el `DataSource`.

Ejemplo de origen de streaming de Amazon Kinesis:

```
val kinesisOptions = jsonOptions()
data_frame_datasource0 = glueContext.getSource("kinesis",
 kinesisOptions).getDataFrame()

private def jsonOptions(): JsonOptions = {
    new JsonOptions(
      s"""{"streamARN": "arn:aws:kinesis:eu-central-1:123456789012:stream/
fromOptionsStream",
         |"startingPosition": "TRIM_HORIZON",
         |"inferSchema": "true",
         |"classification": "json"}""".stripMargin)
}
```

Ejemplo de origen de streaming de Kafka:

```
val kafkaOptions = jsonOptions()
val data_frame_datasource0 = glueContext.getSource("kafka",
 kafkaOptions).getDataFrame()

private def jsonOptions(): JsonOptions = {
    new JsonOptions(
      s"""{"connectionName": "ConfluentKafka",
         |"topicName": "kafka-auth-topic",
```

```
        |"startingOffsets": "earliest",
        |"inferSchema": "true",
        |"classification": "json"}""".stripMargin)
 }
```

def getSourceWithFormat

```
def getSourceWithFormat( connectionType : String,
                         options : JsonOptions,
                         transformationContext : String = "",
                         format : String = null,
                         formatOptions : JsonOptions = JsonOptions.empty
                       ) : DataSource
```

Crea una Característica DataSource que lee datos de un origen como Amazon S3, JDBC o AWS Glue Data Catalog y también establece el formato de los datos almacenados en el origen.

- `connectionType`: tipo de origen de datos. Consulte the section called “Parámetros de conexión”.
- `options`: una cadena de pares de nombre-valor de JSON que proporciona información adicional para establecer una conexión con el origen de datos. Consulte the section called “Parámetros de conexión”.
- `transformationContext`: contexto de transformación asociado con el receptor que utilizarán los marcadores de flujo de trabajo. Se establece en un valor vacío de forma predeterminada.
- `format`: formato de los datos que se almacenan en el origen. Cuando el `connectionType` es "s3", también puede especificar `format`. Puede ser "avro", "csv", "grokLog", "ion", "json", "xml", "parquet" u "orco".
- `formatOptions`: una cadena de pares de nombre-valor de JSON que proporciona opciones adicionales para analizar los datos en el origen. Consulte Opciones de formato de datos.

Devuelve el `DataSource`.

Ejemplos

Cree un DynamicFrame a partir de un origen de datos que sea un archivo de valores separados por comas (CSV) en Amazon S3:

```
val datasource0 = glueContext.getSourceWithFormat(
    connectionType="s3",
```

```
    options =JsonOptions(s"""{"paths": [ "s3://csv/nycflights.csv"]}"""),
    transformationContext = "datasource0",
    format = "csv",
    formatOptions=JsonOptions(s"""{"withHeader":"true","separator": ","}""")
    ).getDynamicFrame()
```

Cree un DynamicFrame a partir de un origen de datos que es un PostgreSQL mediante una conexión JDBC:

```
val datasource0 = glueContext.getSourceWithFormat(
    connectionType="postgresql",
    options =JsonOptions(s"""{
      "url":"jdbc:postgresql://databasePostgres-1.rds.amazonaws.com:5432/testdb",
      "dbtable": "public.company",
      "redshiftTmpDir":"",
      "user":"username",
      "password":"password123"
    }"""),
    transformationContext = "datasource0").getDynamicFrame()
```

Cree un DynamicFrame a partir de un origen de datos que es un MySQL usando una conexión JDBC:

```
 val datasource0 = glueContext.getSourceWithFormat(
    connectionType="mysql",
    options =JsonOptions(s"""{
      "url":"jdbc:mysql://databaseMysql-1.rds.amazonaws.com:3306/testdb",
      "dbtable": "athenatest_nycflights13_csv",
      "redshiftTmpDir":"",
      "user":"username",
      "password":"password123"
    }"""),
    transformationContext = "datasource0").getDynamicFrame()
```

def getSparkSession

```
def getSparkSession : SparkSession
```

Obtiene el objeto `SparkSession` asociado a este GlueContext. Utilice este objeto SparkSession para registrar tablas y UDF con el fin de usarlas con el objeto `DataFrame` creado a partir de los objetos DynamicFrame.

Devuelve el objeto SparkSession.

Definición de startTransaction (iniciar transacción)

```
def startTransaction(readOnly: Boolean):String
```

Inicia una nueva transacción. Llama de forma interna a la API startTransaction de Lake Formation.

- `readOnly`: (booleano) indica si esta transacción debe ser de solo lectura o de lectura y escritura. Se rechazarán las escrituras realizadas con un ID de transacción de solo lectura. No es necesario confirmar las transacciones de solo lectura.

Devuelve el ID de la transacción.

Definición de commitTransaction (confirmar transacción)

```
def commitTransaction(transactionId: String, waitForCommit: Boolean): Boolean
```

Intenta confirmar la transacción especificada. Es posible que se devuelva `commitTransaction` antes de que la transacción haya terminado de confirmarse. Llama de forma interna a la API commitTransaction de Lake Formation.

- `transactionId`: (cadena) la transacción que se confirmará.
- `waitForCommit`: (booleano) determina si se devuelve `commitTransaction` de inmediato. El valor predeterminado es true. Si es falso, `commitTransaction` realiza un sondeo y espera hasta que la transacción se haya confirmado. La cantidad de tiempo de espera se limita a un minuto mediante retroceso exponencial con un máximo de seis reintentos.

Devuelve un valor booleano para indicar si se realizó o no la confirmación.

Definición de cancelTransaction (cancelar transacción)

```
def cancelTransaction(transactionId: String): Unit
```

Intenta cancelar la transacción especificada. Llama de forma interna a la API CancelTransaction de Lake Formation.

- `transactionId`: (cadena) la transacción que se cancelará.

Devuelve una excepción de `TransactionCommittedException` si la transacción se había confirmado con anterioridad.

def this

```
def this( sc : SparkContext,
          minPartitions : Int,
          targetPartitions : Int )
```

Crea un objeto `GlueContext` con el objeto `SparkContext` especificado, particiones mínimas y particiones de destino.

- `sc` — La `SparkContext`.
- `minPartitions`: número mínimo de particiones.
- `targetPartitions`: número de particiones de destino.

Devuelve el `GlueContext`.

def this

```
def this( sc : SparkContext )
```

Crear un objeto `GlueContext` con el `SparkContext` proporcionado. Establece las particiones mínimas en 10 y las particiones de destino en 20.

- `sc` — La `SparkContext`.

Devuelve el `GlueContext`.

def this

```
def this( sparkContext : JavaSparkContext )
```

Crear un objeto `GlueContext` con el `JavaSparkContext` proporcionado. Establece las particiones mínimas en 10 y las particiones de destino en 20.

- `sparkContext` — La `JavaSparkContext`.

Devuelve el `GlueContext`.

MappingSpec

Paquete: com.amazonaws.services.glue

Case class MappingSpec

```
case class MappingSpec( sourcePath: SchemaPath,
                        sourceType: DataType,
                        targetPath: SchemaPath,
                        targetType: DataTyp
                       ) extends Product4[String, String, String, String] {
  override def _1: String = sourcePath.toString
  override def _2: String = ExtendedTypeName.fromDataType(sourceType)
  override def _3: String = targetPath.toString
  override def _4: String = ExtendedTypeName.fromDataType(targetType)
}
```

- `sourcePath`: `SchemaPath` del campo de origen.
- `sourceType`: `DataType` del campo de origen.
- `targetPath`: `SchemaPath` del campo de destino.
- `targetType`: `DataType` del campo de destino.

Un objeto `MappingSpec` especifica un mapeo desde una ruta y un tipo de datos de origen a una ruta y un tipo de datos de destino. El valor en la ruta de origen en el marco de origen aparece en el marco de destino en la ruta de destino. El tipo de datos de origen se convierte al de destino.

Se extiende desde `Product4` para que usted pueda gestionar todos los `Product4` de su interfaz `applyMapping`.

Objeto MappingSpec

```
object MappingSpec
```

El objeto `MappingSpec` tiene los siguientes miembros:

Val orderingByTarget

```
val orderingByTarget: Ordering[MappingSpec]
```

Def apply

```
def apply( sourcePath : String,
           sourceType : DataType,
           targetPath : String,
           targetType : DataType
         ) : MappingSpec
```

Crea un `MappingSpec`.

- `sourcePath`: representación de cadena de la ruta de origen.
- `sourceType`: `DataType` de origen.
- `targetPath`: representación de cadena de la ruta de destino.
- `targetType`: el objeto `DataType` de destino.

Devuelve `MappingSpec`.

Def apply

```
def apply( sourcePath : String,
           sourceTypeString : String,
           targetPath : String,
           targetTypeString : String
         ) : MappingSpec
```

Crea un `MappingSpec`.

- `sourcePath`: representación de cadena de la ruta de origen.
- `sourceType`: representación de cadena del tipo de datos de origen.
- `targetPath`: representación de cadena de la ruta de destino.
- `targetType`: representación de cadena del tipo de datos de destino.

Devuelve un objeto MappingSpec.

Def apply

```
def apply( product : Product4[String, String, String, String] ) : MappingSpec
```

Crea un `MappingSpec`.

- `product`: el elemento `Product4` de la ruta de origen, el tipo de datos de origen, la ruta de destino y el tipo de datos de destino.

Devuelve `MappingSpec`.

API ResolveSpec Scala de AWS Glue

Temas

- Objeto ResolveSpec
- Case class ResolveSpec

Paquete: com.amazonaws.services.glue

Objeto ResolveSpec

ResolveSpec

```
object ResolveSpec
```

Def

```
def apply( path : String,
           action : String
         ) : ResolveSpec
```

Crea un `ResolveSpec`.

- `path`: representación de cadena del campo de elección que se debe resolver.
- `action`: acción de resolución. La acción puede ser una de las siguientes: `Project`, `KeepAsStruct` o `Cast`.

Devuelve el `ResolveSpec`.

Def

```
def apply( product : Product2[String, String] ) : ResolveSpec
```

Crea un `ResolveSpec`.

- `product`: `Product2` de: ruta de origen, acción de resolución.

Devuelve el `ResolveSpec`.

Case class ResolveSpec

```
case class ResolveSpec extends Product2[String, String]  (
           path : SchemaPath,
           action : String )
```

Crea un `ResolveSpec`.

- `path`: `SchemaPath` del campo de elección que se debe resolver.
- `action`: acción de resolución. La acción puede ser una de las siguientes: `Project`, `KeepAsStruct` o `Cast`.

Métodos def de ResolveSpec

```
def _1 : String
```

```
def _2 : String
```

API ArrayNode Scala de AWS Glue

Paquete: com.amazonaws.services.glue.types

Case class ArrayNode

ArrayNode

```
case class ArrayNode extends DynamicNode  (
           value : ArrayBuffer[DynamicNode] )
```

Métodos def de ArrayNode

```
def add( node : DynamicNode )
```

```
def clone
```

```
def equals( other : Any )
```

```
def get( index : Int ) : Option[DynamicNode]
```

```
def getValue
```

```
def hashCode : Int
```

```
def isEmpty : Boolean
```

```
def nodeType
```

```
def remove( index : Int )
```

```
def this
```

```
def toIterator : Iterator[DynamicNode]
```

```
def toJson : String
```

```
def update( index : Int,
            node : DynamicNode )
```

API BinaryNode Scala de AWS Glue

Paquete: com.amazonaws.services.glue.types

Case class BinaryNode

BinaryNode

```
case class BinaryNode extends ScalarNode(value, TypeCode.BINARY)  (
           value : Array[Byte] )
```

Campos val de BinaryNode

- `ordering`

Métodos def de BinaryNode

```
def clone
```

```
def equals( other : Any )
```

```
def hashCode : Int
```

API BooleanNode Scala de AWS Glue

Paquete: com.amazonaws.services.glue.types

Case class BooleanNode

BooleanNode

```
case class BooleanNode extends ScalarNode(value, TypeCode.BOOLEAN)  (
           value : Boolean )
```

Campos val de BooleanNode

- `ordering`

Métodos def de BooleanNode

```
def equals( other : Any )
```

API ByteNode Scala de AWS Glue

Paquete: com.amazonaws.services.glue.types

Case class ByteNode

ByteNode

```
case class ByteNode extends ScalarNode(value, TypeCode.BYTE)  (
```

```
            value : Byte )
```

Campos val de ByteNode

- `ordering`

Métodos def de ByteNode

```
def equals( other : Any )
```

API DateNode Scala de AWS Glue

Paquete: com.amazonaws.services.glue.types

Case class DateNode

DateNode

```
case class DateNode extends ScalarNode(value, TypeCode.DATE)  (
            value : Date )
```

Campos val de DateNode

- `ordering`

Métodos def de DateNode

```
def equals( other : Any )
```

```
def this( value : Int )
```

API DecimalNode Scala de AWS Glue

Paquete: com.amazonaws.services.glue.types

Case class DecimalNode

DecimalNode

```
case class DecimalNode extends ScalarNode(value, TypeCode.DECIMAL)  (
```

```
            value : BigDecimal )
```

Campos val de DecimalNode

- `ordering`

Métodos def de DecimalNode

```
def equals( other : Any )
```

```
def this( value : Decimal )
```

API DoubleNode Scala de AWS Glue

Paquete: com.amazonaws.services.glue.types

Case class DoubleNode

DoubleNode

```
case class DoubleNode extends ScalarNode(value, TypeCode.DOUBLE)  (
            value : Double )
```

Campos val de DoubleNode

- `ordering`

Métodos def de DoubleNode

```
def equals( other : Any )
```

API DynamicNode Scala de AWS Glue

Temas

- Clase DynamicNode
- Objeto DynamicNode

Paquete: com.amazonaws.services.glue.types

Clase DynamicNode

DynamicNode

```
class DynamicNode extends Serializable with Cloneable
```

Métodos def de DynamicNode

```
def getValue : Any
```

Obtenga el valor sin formato y vincúlelo al registro actual:

```
def nodeType : TypeCode
```

```
def toJson : String
```

Método de depuración:

```
def toRow( schema : Schema,
           options : Map[String, ResolveOption]
         ) : Row
```

```
def typeName : String
```

Objeto DynamicNode

DynamicNode

```
object DynamicNode
```

Métodos def de DynamicNode

```
def quote( field : String,
           useQuotes : Boolean
         ) : String
```

```
def quote( node : DynamicNode,
           useQuotes : Boolean
         ) : String
```

Clase de EvaluateDataQuality

Calidad de datos de AWS Glue se encuentra en versión preliminar para AWS Glue, por lo que es una característica que está sujeta a cambios.

Paquete: com.amazonaws.services.glue.dq

```
object EvaluateDataQuality
```

Def apply

```
def apply(frame: DynamicFrame,
            ruleset: String,
            publishingOptions: JsonOptions = JsonOptions.empty): DynamicFrame
```

Evalúa un conjunto de reglas de calidad de datos en relación con un `DynamicFrame` y devuelve un `DynamicFrame` nuevo con los resultados de la evaluación. Para obtener más información sobre Calidad de datos de AWS Glue, consulte Calidad de datos de AWS Glue.

- `frame`: el objeto `DynamicFrame` del que quiere evaluar la calidad de los datos.
- `ruleset`: un conjunto de reglas de lenguaje de definición de calidad de datos (DQDL) en formato de cadena. Para obtener más información sobre DQDL, consulte la guía de Referencia del lenguaje de definición de calidad de datos (DQDL).
- `publishingOptions`: un diccionario que especifica las siguientes opciones para publicar los resultados y las métricas de la evaluación:
  - `dataQualityEvaluationContext`: una cadena que especifica el espacio de nombres en el que AWS Glue debe publicar las métricas de Amazon CloudWatch y los resultados de calidad de los datos. Las métricas agregadas aparecen en CloudWatch, mientras que los resultados completos aparecen en la interfaz de AWS Glue Studio.
    - Obligatorio: no
    - Valor predeterminado: `default_context`
  - `enableDataQualityCloudWatchMetrics`: especifica si los resultados de la evaluación de la calidad de los datos deben publicarse en CloudWatch. Especifique un espacio de nombres para las métricas mediante la opción `dataQualityEvaluationContext`.
    - Obligatorio: no

  - Valor predeterminado: False
- `enableDataQualityResultsPublishing`: especifica si los resultados de calidad de los datos deben estar visibles en la pestaña Data Quality (Calidad de datos) de la interfaz de AWS Glue Studio.
  - Obligatorio: no
  - Valor predeterminado: true
- `resultsS3Prefix`: especifica la ubicación de Amazon S3 en la que AWS Glue puede escribir los resultados de la evaluación de la calidad de los datos.
  - Obligatorio: no
  - Valor predeterminado: "" (cadena vacía)

Ejemplo

El siguiente código de ejemplo muestra cómo evaluar la calidad de los datos de un `DynamicFrame` antes de hacer una transformación de `SelectFields`. El script verifica que se cumplan todas las reglas de calidad de datos antes de intentar la transformación.

```
import com.amazonaws.services.glue.GlueContext
import com.amazonaws.services.glue.MappingSpec
import com.amazonaws.services.glue.errors.CallSite
import com.amazonaws.services.glue.util.GlueArgParser
import com.amazonaws.services.glue.util.Job
import com.amazonaws.services.glue.util.JsonOptions
import org.apache.spark.SparkContext
import scala.collection.JavaConverters._
import com.amazonaws.services.glue.dq.EvaluateDataQuality

object GlueApp {
  def main(sysArgs: Array[String]) {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)
    // @params: [JOB_NAME]
    val args = GlueArgParser.getResolvedOptions(sysArgs, Seq("JOB_NAME").toArray)
    Job.init(args("JOB_NAME"), glueContext, args.asJava)

    // Create DynamicFrame with data
    val Legislators_Area = glueContext.getCatalogSource(database="legislators",
 tableName="areas_json", transformationContext="S3bucket_node1").getDynamicFrame()
```

```
    // Define data quality ruleset
    val DQ_Ruleset = """
      Rules = [ColumnExists "id"]
    """

    // Evaluate data quality
    val DQ_Results = EvaluateDataQuality.apply(frame=Legislators_Area,
 ruleset=DQ_Ruleset, publishingOptions=JsonOptions("""{"dataQualityEvaluationContext":
 "Legislators_Area", "enableDataQualityMetrics": "true",
 "enableDataQualityResultsPublishing": "true"}"""))
    assert(DQ_Results.filter(_.getField("Outcome").contains("Failed")).count == 0,
 "Failing DQ rules for Legislators_Area caused the job to fail.")

    // Script generated for node Select Fields
    val SelectFields_Results = Legislators_Area.selectFields(paths=Seq("id", "name"),
 transformationContext="Legislators_Area")

    Job.commit()
  }
}
```

API FloatNode Scala de AWS Glue

Paquete: com.amazonaws.services.glue.types

Case class FloatNode

FloatNode

```
case class FloatNode extends ScalarNode(value, TypeCode.FLOAT)  (
           value : Float )
```

Campos val de FloatNode

- `ordering`

Métodos def de FloatNode

```
def equals( other : Any )
```

Clase FillMissingValues

Paquete: com.amazonaws.services.glue.ml

```
object FillMissingValues
```

Def apply

```
def apply(frame: DynamicFrame,
          missingValuesColumn: String,
          outputColumn: String = "",
          transformationContext: String = "",
          callSite: CallSite = CallSite("Not provided", ""),
          stageThreshold: Long = 0,
          totalThreshold: Long = 0): DynamicFrame
```

Rellena los valores que faltan de un marco dinámico en una columna especificada y devuelve un nuevo marco con estimaciones en una nueva columna. Para filas sin valores faltantes, el valor de la columna especificada se duplica en la nueva columna.

- `frame`: DynamicFrame en el que rellenar los valores que faltan. Obligatorio.
- `missingValuesColumn`: la columna que contiene valores faltantes (valores `null` y cadenas vacías). Obligatorio.
- `outputColumn`: el nombre de la nueva columna que contendrá valores estimados para todas las filas cuyo valor faltaba. Opcional; el valor predeterminado es `missingValuesColumn` con el sufijo `"_filled"`.
- `transformationContext`: una cadena única que se utiliza para identificar la información de estado (opcional).
- `callSite`: se utiliza para proporcionar información de contexto para los informes de error. (Opcional).
- `stageThreshold`: el número máximo de errores que se pueden producir en la transformación antes de que se determine que es errónea (opcional, el valor predeterminado es cero).
- `totalThreshold`: el número máximo de errores que se pueden producir en total antes de que se determine que el proceso es erróneo (opcional, el valor predeterminado es cero).

Devuelve un nuevo marco dinámico con una columna adicional que contiene estimaciones para filas con valores faltantes y el valor actual para otras filas.

Clase FindMatches

Paquete: com.amazonaws.services.glue.ml

```
object FindMatches
```

Def apply

```
def apply(frame: DynamicFrame,
            transformId: String,
            transformationContext: String = "",
            callSite: CallSite = CallSite("Not provided", ""),
            stageThreshold: Long = 0,
            totalThreshold: Long = 0,
            enforcedMatches: DynamicFrame = null): DynamicFrame,
   computeMatchConfidenceScores: Boolean
```

Busque coincidencias en un marco de entrada y devuelva un nuevo marco con una nueva columna que contenga un ID único por grupo de coincidencias.

- `frame`: DynamicFrame en el que buscar coincidencias. Obligatorio.
- `transformId`: ID único asociado a la transformación FindMatches que se aplicará en el marco de entrada. Obligatorio.
- `transformationContext`: identificador de este `DynamicFrame`. Se utiliza `transformationContext` como clave para el estado de marcador de trabajo que se conserva de una ejecución a otra. Opcional.
- `callSite`: se utiliza para proporcionar información de contexto para los informes de error. Estos valores se establecen automáticamente cuando se realiza la llamada desde Python. Opcional.
- `stageThreshold`: número máximo de registros de errores permitidos en el cálculo de este `DynamicFrame` antes de generar una excepción, sin incluir los registros presentes en el `DynamicFrame` anterior. Opcional. El rol predeterminado es cero.
- `totalThreshold`: número máximo registros de errores totales antes de que se genere una excepción, incluidos los de marcos anteriores. Opcional. El rol predeterminado es cero.
- `enforcedMatches`: el marco para las coincidencias forzadas. Opcional. El valor predeterminado es `null`.
- `computeMatchConfidenceScores`: valor booleano que indica si se calcula una puntuación de confianza para cada grupo de registros coincidentes. Opcional. El valor predeterminado es false.

Devuelve un nuevo marco dinámico con un identificador único asignado a cada grupo de registros coincidentes.

Clase FindIncrementalMatches

Paquete: com.amazonaws.services.glue.ml

```
object FindIncrementalMatches
```

Def apply

```
apply(existingFrame: DynamicFrame,
            incrementalFrame: DynamicFrame,
            transformId: String,
            transformationContext: String = "",
            callSite: CallSite = CallSite("Not provided", ""),
            stageThreshold: Long = 0,
            totalThreshold: Long = 0,
            enforcedMatches: DynamicFrame = null): DynamicFrame,
   computeMatchConfidenceScores: Boolean
```

Busca coincidencias entre los marcos existentes y progresivos y devuelve un nuevo marco con una columna que contiene un ID único por grupo de coincidencias.

- `existingframe`: un marco existente al que se le ha asignado un ID coincidente para cada grupo. Obligatorio.
- `incrementalframe`: un marco progresivo utilizado para encontrar coincidencias con el marco existente. Obligatorio.
- `transformId`: un ID único asociado a la transformación FindIncrementalMatches que se aplicará a los marcos de entrada. Obligatorio.
- `transformationContext`: identificador de este `DynamicFrame`. Se utiliza `transformationContext` como clave para el estado de marcador de trabajo que se conserva de una ejecución a otra. Opcional.
- `callSite`: se utiliza para proporcionar información de contexto para los informes de error. Estos valores se establecen automáticamente cuando se realiza la llamada desde Python. Opcional.
- `stageThreshold`: número máximo de registros de errores permitidos en el cálculo de este `DynamicFrame` antes de generar una excepción, sin incluir los registros presentes en el `DynamicFrame` anterior. Opcional. El rol predeterminado es cero.

- `totalThreshold`: número máximo registros de errores totales antes de que se genere una excepción, incluidos los de marcos anteriores. Opcional. El rol predeterminado es cero.
- `enforcedMatches`: el marco para las coincidencias forzadas. Opcional. El valor predeterminado es `null`.
- `computeMatchConfidenceScores`: valor booleano que indica si se calcula una puntuación de confianza para cada grupo de registros coincidentes. Opcional. El valor predeterminado es false.

Devuelve un nuevo marco dinámico con un identificador único asignado a cada grupo de registros coincidentes.

API IntegerNode Scala de AWS Glue

Paquete: com.amazonaws.services.glue.types

Case class IntegerNode

IntegerNode

```
case class IntegerNode extends ScalarNode(value, TypeCode.INT)  (
           value : Int )
```

Campos val de IntegerNode

- `ordering`

Métodos def de IntegerNode

```
def equals( other : Any )
```

API LongNode Scala de AWS Glue

Paquete: com.amazonaws.services.glue.types

Case class LongNode

LongNode

```
case class LongNode extends ScalarNode(value, TypeCode.LONG)  (
           value : Long )
```

Campos val de LongNode

- `ordering`

Métodos def de LongNode

```
def equals( other : Any )
```

API MapLikeNode Scala de AWS Glue

Paquete: com.amazonaws.services.glue.types

Case class MapLikeNode

MapLikeNode

```
class MapLikeNode extends DynamicNode  (
           value : mutable.Map[String, DynamicNode] )
```

Métodos def de MapLikeNode

```
def clear : Unit
```

```
def get( name : String ) : Option[DynamicNode]
```

```
def getValue
```

```
def has( name : String ) : Boolean
```

```
def isEmpty : Boolean
```

```
def put( name : String,
         node : DynamicNode
       ) : Option[DynamicNode]
```

```
def remove( name : String ) : Option[DynamicNode]
```

```
def toIterator : Iterator[(String, DynamicNode)]
```

```
def toJson : String
```

```
def toJson( useQuotes : Boolean ) : String
```

Ejemplo: Teniendo en cuenta este JSON:

```
{"foo": "bar"}
```

Si `useQuotes == true`, `toJson` devuelve `{"foo": "bar"}`. Si `useQuotes == false`, `toJson` devuelve `{foo: bar}` @return.

API MapNode Scala de AWS Glue

Paquete: com.amazonaws.services.glue.types

Case class MapNode

MapNode

```
case class MapNode extends MapLikeNode(value)  (
           value : mutable.Map[String, DynamicNode] )
```

Métodos def de MapNode

```
def clone
```

```
def equals( other : Any )
```

```
def hashCode : Int
```

```
def nodeType
```

```
def this
```

API NullNode Scala de AWS Glue

Temas

- Clase NullNode
- Case object NullNode

Paquete: com.amazonaws.services.glue.types

Clase NullNode

NullNode

```
class NullNode
```

Case object NullNode

NullNode

```
case object NullNode extends NullNode
```

API ObjectNode Scala de AWS Glue

Temas

- Objeto ObjectNode
- Case class ObjectNode

Paquete: com.amazonaws.services.glue.types

Objeto ObjectNode

ObjectNode

```
object ObjectNode
```

Métodos def de ObjectNode

```
def apply( frameKeys : Set[String],
           v1 : mutable.Map[String, DynamicNode],
           v2 : mutable.Map[String, DynamicNode],
```

```
            resolveWith : String
          ) : ObjectNode
```

Case class ObjectNode

ObjectNode

```
case class ObjectNode extends MapLikeNode(value)  (
            val value : mutable.Map[String, DynamicNode] )
```

Métodos def de ObjectNode

```
def clone
```

```
def equals( other : Any )
```

```
def hashCode : Int
```

```
def nodeType
```

```
def this
```

API ScalarNode Scala de AWS Glue

Temas

- Clase ScalarNode
- Objeto ScalarNode

Paquete: com.amazonaws.services.glue.types

Clase ScalarNode

ScalarNode

```
class ScalarNode extends DynamicNode  (
            value : Any,
            scalarType : TypeCode )
```

Métodos def de ScalarNode

```
def compare( other : Any,
             operator : String
           ) : Boolean
```

```
def getValue
```

```
def hashCode : Int
```

```
def nodeType
```

```
def toJson
```

Objeto ScalarNode

ScalarNode

```
object ScalarNode
```

Métodos def de ScalarNode

```
def apply( v : Any ) : DynamicNode
```

```
def compare( tv : Ordered[T],
             other : T,
             operator : String
           ) : Boolean
```

```
def compareAny( v : Any,
                y : Any,
                o : String )
```

```
def withEscapedSpecialCharacters( jsonToEscape : String ) : String
```

API ShortNode Scala de AWS Glue

Paquete: com.amazonaws.services.glue.types

Case class ShortNode

ShortNode

```
case class ShortNode extends ScalarNode(value, TypeCode.SHORT)  (
           value : Short )
```

Campos val de ShortNode

- `ordering`

Métodos def de ShortNode

```
def equals( other : Any )
```

API StringNode Scala de AWS Glue

Paquete: com.amazonaws.services.glue.types

Case class StringNode

StringNode

```
case class StringNode extends ScalarNode(value, TypeCode.STRING)  (
           value : String )
```

Campos val de StringNode

- `ordering`

Métodos def de StringNode

```
def equals( other : Any )
```

```
def this( value : UTF8String )
```

API TimestampNode Scala de AWS Glue

Paquete: com.amazonaws.services.glue.types

Case class TimestampNode

TimestampNode

```
case class TimestampNode extends ScalarNode(value, TypeCode.TIMESTAMP)  (
           value : Timestamp )
```

Campos val de TimestampNode

- `ordering`

Métodos def de TimestampNode

```
def equals( other : Any )
```

```
def this( value : Long )
```

API GlueArgParser Scala de AWS Glue

Paquete: com.amazonaws.services.glue.util

Objeto GlueArgParser

GlueArgParser

```
object GlueArgParser
```

Esto es estrictamente coherente con la versión para Python de `utils.getResolvedOptions` del paquete `AWSGlueDataplanePython`.

Métodos def de GlueArgParser

```
def getResolvedOptions( args : Array[String],
                        options : Array[String]
                      ) : Map[String, String]
```

```
def initParser( userOptionsSet : mutable.Set[String] ) : ArgumentParser
```

Example Recuperación de los argumentos que se pasan a un trabajo

Para recuperar los argumentos del trabajo, puede usar el método `getResolvedOptions`. Considere el siguiente ejemplo, que recupera un argumento de trabajo denominado `aws_region`.

```
val args = GlueArgParser.getResolvedOptions(sysArgs,
 Seq("JOB_NAME","aws_region").toArray)
Job.init(args("JOB_NAME"), glueContext, args.asJava)
val region = args("aws_region")
println(region)
```

API Job Scala de AWS Glue

Paquete: com.amazonaws.services.glue.util

Objeto de trabajo

Trabajo

```
object Job
```

Métodos def de trabajo

```
def commit
```

```
def init( jobName : String,
          glueContext : GlueContext,
          args : java.util.Map[String, String] = Map[String, String]().asJava
        ) : this.type
```

```
def init( jobName : String,
          glueContext : GlueContext,
          endpoint : String,
          args : java.util.Map[String, String]
        ) : this.type
```

```
def isInitialized
```

```
def reset
```

```
def runId
```

Características y optimizaciones para programar AWS Glue para los scripts de Spark ETL

En las siguientes secciones se describen las técnicas y los valores que se aplican de manera general a AWS Glue para la programación de Spark ETL (extracción, transformación y carga).

Temas

- Tipos de conexión y opciones para ETL en AWS Glue para Spark
- Opciones de formato de datos para las entradas y las salidas en AWS Glue para Spark
- Soporte de AWS Glue Data Catalog para trabajos de Spark SQL
- Uso de marcadores de trabajo
- Usar la detección de datos confidenciales fuera de AWS Glue Studio
- API de Visual Job de AWS Glue

Tipos de conexión y opciones para ETL en AWS Glue para Spark

En AWS Glue para Spark, varios métodos y transformaciones de PySpark y Scala especifican el tipo de conexión mediante un parámetro `connectionType`. Especifican las opciones de conexión mediante un parámetro `connectionOptions` o `options`.

El parámetro `connectionType` puede adoptar los valores que se muestran en la tabla siguiente. Los valores del parámetro `connectionOptions` (u `options`) asociados para cada tipo se documentan en las secciones siguientes. Salvo que se indique lo contrario, los parámetros se aplican cuando la conexión se utiliza como origen o receptor.

Para obtener un código de muestra que ilustra la configuración y que utiliza las opciones de conexión, consulte la página de inicio de cada tipo de conexión.

`connectionType`	Se conecta a
dynamodb	Base de datos Amazon DynamoDB
kinesis	Amazon Kinesis Data Streams

`connectionType`	Se conecta a
s3	Amazon S3
documentdb	Base de datos de Amazon DocumentDB (con compatibilidad con MongoDB)
opensearch	Amazon OpenSearch Service.
redshift	Base de datos de Amazon Redshift
kafka	Kafka o Amazon Managed Streaming for Apache Kafka
azurecosmos	Azure Cosmos para NoSQL.
azuresql	Azure SQL.
bigquery	Google BigQuery.
mongodb	Base de datos MongoDB, incluido MongoDB Atlas.
sqlserver	Base de datos de Microsoft SQL Server (consulte Conexiones de JDBC)
mysql	Base de datos de MySQL (consulte Conexiones de JDBC)
oracle	Base de datos de Oracle (consulte Conexiones de JDBC)
postgresql	Base de datos de PostgreSQL (consulte Conexiones de JDBC)
saphana	SAP HANA.
Snowflake	Lago de datos Snowflake
teradata	Teradata Vantage.
vertica	Vertica.
custom.*	Almacenes de datos Spark, Athena o JDBC (consulte Valores de conexiones de tipo personalizada y AWS Marketplace

`connectionType`	Se conecta a
marketplace.*	Almacenes de datos Spark, Athena o JDBC (consulte Valores de conexiones de tipo personalizada y AWS Marketplace)

Conexiones de DynamoDB

Puede utilizar AWS Glue para Spark para leer y escribir en tablas de DynamoDB en AWS Glue. Para conectarse a DynamoDB, utilice los permisos de IAM adjuntos a su trabajo de AWSGlue. AWS Glue admite la escritura de datos en otra cuenta de tablas de DynamoDB de AWS. Para obtener más información, consulte the section called “Acceso entre cuentas y entre regiones a tablas de DynamoDB”.

El conector original de DynamoDB utiliza objetos DynamicFrame de Glue para trabajar con los datos extraídos de AWS DynamoDB. La versión 5.0 o posterior de Glue presenta un nuevo Conector de DynamoDB con compatibilidad con Spark DataFrame que proporciona compatibilidad nativa con Spark DataFrame.

Además del conector de ETL de DynamoDB de AWS Glue, puede leer en DynamoDB por medio del conector de exportación de DynamoDB, que invoca una solicitud `ExportTableToPointInTime` de DynamoDB y la almacena en una ubicación de Amazon S3 que se proporcione, con el formato de DynamoDB JSON. Después, AWS Glue crea un objeto DynamicFrame mediante la lectura de los datos desde la ubicación de exportación de Amazon S3.

El escritor de DynamoDB está disponible en la versión AWS Glue 1.0 o versiones posteriores. El conector de exportación de DynamoDB de AWS Glue está disponible en la versión 2.0 o versiones posteriores de AWS Glue. El nuevo conector de DynamoDB basado en DataFrame está disponible en la versión 5.0 de AWS Glue o posteriores.

Para obtener más información sobre DynamoDB, consulte la documentación de Amazon DynamoDB.

> **Note**
>
> El lector de ETL de DynamoDB no es compatible con filtros ni predicados de inserción.

Configuración de las conexiones DynamoDB

Para conectarse a DynamoDB desde AWS Glue, conceda permiso al rol de IAM asociado a su trabajo de AWS Glue para interactuar con DynamoDB. Para obtener más información sobre los permisos necesarios para leer o escribir en DynamoDB, consulte Acciones, recursos y claves de condición para DynamoDB en la documentación de IAM.

En las siguientes situaciones, es posible que necesite una configuración adicional:

- Cuando utilice el conector de exportación de DynamoDB, tendrá que configurar IAM para que su trabajo pueda solicitar exportaciones de tablas de DynamoDB. Además, tendrá que identificar un bucket de Amazon S3 para la exportación y proporcionar los permisos adecuados en IAM para que DynamoDB escriba en él y para que su trabajo de AWS Glue pueda leerlo. Para obtener más información, consulte Solicitar una exportación de tabla en DynamoDB.
- Si su trabajo de AWS Glue tiene requisitos de conectividad de Amazon VPC específicos, utilice el tipo de conexión `NETWORK` de AWS Glue para proporcionar opciones de red. Como el acceso a DynamoDB está autorizado por IAM, no es necesario utilizar un tipo de conexión de DynamoDB de AWS Glue.

Lectura y escritura en DynamoDB

En los siguientes ejemplos de código, se muestra cómo leer (con el conector de ETL) de tablas de DynamoDB y escribir en ellas. Demuestran la lectura de una tabla y la escritura en otra tabla.

Python

```
import sys
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job
from awsglue.utils import getResolvedOptions

args = getResolvedOptions(sys.argv, ["JOB_NAME"])
glue_context= GlueContext(SparkContext.getOrCreate())
job = Job(glue_context)
job.init(args["JOB_NAME"], args)

dyf = glue_context.create_dynamic_frame.from_options(
    connection_type="dynamodb",
    connection_options={"dynamodb.input.tableName": test_source,
```

```
        "dynamodb.throughput.read.percent": "1.0",
        "dynamodb.splits": "100"
    }
)
print(dyf.getNumPartitions())

glue_context.write_dynamic_frame_from_options(
    frame=dyf,
    connection_type="dynamodb",
    connection_options={"dynamodb.output.tableName": test_sink,
        "dynamodb.throughput.write.percent": "1.0"
    }
)

job.commit()
```

Scala

```
import com.amazonaws.services.glue.GlueContext
import com.amazonaws.services.glue.util.GlueArgParser
import com.amazonaws.services.glue.util.Job
import com.amazonaws.services.glue.util.JsonOptions
import com.amazonaws.services.glue.DynamoDbDataSink
import org.apache.spark.SparkContext
import scala.collection.JavaConverters._


object GlueApp {

  def main(sysArgs: Array[String]): Unit = {
    val glueContext = new GlueContext(SparkContext.getOrCreate())
    val args = GlueArgParser.getResolvedOptions(sysArgs, Seq("JOB_NAME").toArray)
    Job.init(args("JOB_NAME"), glueContext, args.asJava)

    val dynamicFrame = glueContext.getSourceWithFormat(
      connectionType = "dynamodb",
      options = JsonOptions(Map(
        "dynamodb.input.tableName" -> test_source,
        "dynamodb.throughput.read.percent" -> "1.0",
        "dynamodb.splits" -> "100"
      ))
    ).getDynamicFrame()
```

```
    print(dynamicFrame.getNumPartitions())

    val dynamoDbSink: DynamoDbDataSink =  glueContext.getSinkWithFormat(
      connectionType = "dynamodb",
      options = JsonOptions(Map(
        "dynamodb.output.tableName" -> test_sink,
        "dynamodb.throughput.write.percent" -> "1.0"
      ))
    ).asInstanceOf[DynamoDbDataSink]

    dynamoDbSink.writeDynamicFrame(dynamicFrame)

    Job.commit()
  }

}
```

Uso del conector de exportación de DynamoDB

El conector de exportación funciona mejor que el conector de ETL cuando el tamaño de la tabla de DynamoDB es superior a 80 GB. Además, dado que la solicitud de exportación se lleva a cabo fuera de los procesos de Spark en un trabajo de AWS Glue, se puede habilitar el escalado automático de los trabajos de AWS Glue para guardar el uso de DPU durante la solicitud de exportación. Con el conector de exportación, tampoco es necesario configurar el número de divisiones del paralelismo del ejecutor de Spark o el porcentaje de lectura de rendimiento de DynamoDB.

> **Note**
>
> DynamoDB tiene requisitos específicos para invocar las solicitudes `ExportTableToPointInTime`. Para obtener más información, consulte Solicitud de una exportación de tabla en DynamoDB. Por ejemplo, debe estar habilitada la restauración a un momento dado (PITR) en la tabla para utilizar este conector. El conector de DynamoDB también es compatible con el cifrado de AWS KMS para las exportaciones de DynamoDB a Amazon S3. Proporcionar la configuración de seguridad en la configuración del trabajo de AWS Glue habilita el cifrado de AWS KMS para una exportación de DynamoDB. La clave de KMS debe estar en la misma región que el bucket de Simple Storage Service (Amazon S3). Tenga en cuenta que se aplican cargos adicionales por la exportación de DynamoDB y los costos de almacenamiento de Simple Storage Service (Amazon S3). Los datos exportados en Simple Storage Service (Amazon S3) se mantienen cuando finaliza la ejecución de

un trabajo para que pueda reutilizarlos sin exportaciones adicionales de DynamoDB. Un requisito para utilizar este conector es que la recuperación en un momento dado (PITR) esté habilitada para la tabla.
El conector de ETL y el conector de exportación de DynamoDB no son compatibles con la aplicación de filtros o predicados de inserción en el origen de DynamoDB.

Los siguientes ejemplos de código muestran cómo leer desde particiones (a través del conector de exportación) e imprimir el número de estas.

Python

```
import sys
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job
from awsglue.utils import getResolvedOptions

args = getResolvedOptions(sys.argv, ["JOB_NAME"])
glue_context= GlueContext(SparkContext.getOrCreate())
job = Job(glue_context)
job.init(args["JOB_NAME"], args)

dyf = glue_context.create_dynamic_frame.from_options(
    connection_type="dynamodb",
    connection_options={
        "dynamodb.export": "ddb",
        "dynamodb.tableArn": test_source,
        "dynamodb.s3.bucket": bucket_name,
        "dynamodb.s3.prefix": bucket_prefix,
        "dynamodb.s3.bucketOwner": account_id_of_bucket,
    }
)
print(dyf.getNumPartitions())

job.commit()
```

Scala

```
import com.amazonaws.services.glue.GlueContext
import com.amazonaws.services.glue.util.GlueArgParser
import com.amazonaws.services.glue.util.Job
```

```
import com.amazonaws.services.glue.util.JsonOptions
import com.amazonaws.services.glue.DynamoDbDataSink
import org.apache.spark.SparkContext
import scala.collection.JavaConverters._


object GlueApp {

  def main(sysArgs: Array[String]): Unit = {
    val glueContext = new GlueContext(SparkContext.getOrCreate())
    val args = GlueArgParser.getResolvedOptions(sysArgs, Seq("JOB_NAME").toArray)
    Job.init(args("JOB_NAME"), glueContext, args.asJava)

    val dynamicFrame = glueContext.getSourceWithFormat(
      connectionType = "dynamodb",
      options = JsonOptions(Map(
        "dynamodb.export" -> "ddb",
        "dynamodb.tableArn" -> test_source,
        "dynamodb.s3.bucket" -> bucket_name,
        "dynamodb.s3.prefix" -> bucket_prefix,
        "dynamodb.s3.bucketOwner" -> account_id_of_bucket,
      ))
    ).getDynamicFrame()

    print(dynamicFrame.getNumPartitions())

    Job.commit()
  }

}
```

Estos ejemplos muestran cómo realizar la lectura desde particiones (a través del conector de exportación) e imprimir el número de estas desde una tabla de Data Catalog de AWS Glue que tenga una clasificación dynamodb:

Python

```
import sys
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job
from awsglue.utils import getResolvedOptions
```

```
args = getResolvedOptions(sys.argv, ["JOB_NAME"])
glue_context= GlueContext(SparkContext.getOrCreate())
job = Job(glue_context)
job.init(args["JOB_NAME"], args)

dynamicFrame = glue_context.create_dynamic_frame.from_catalog(
        database=catalog_database,
        table_name=catalog_table_name,
        additional_options={
            "dynamodb.export": "ddb",
            "dynamodb.s3.bucket": s3_bucket,
            "dynamodb.s3.prefix": s3_bucket_prefix
        }
    )
print(dynamicFrame.getNumPartitions())

job.commit()
```

Scala

```
import com.amazonaws.services.glue.GlueContext
import com.amazonaws.services.glue.util.GlueArgParser
import com.amazonaws.services.glue.util.Job
import com.amazonaws.services.glue.util.JsonOptions
import com.amazonaws.services.glue.DynamoDbDataSink
import org.apache.spark.SparkContext
import scala.collection.JavaConverters._


object GlueApp {

  def main(sysArgs: Array[String]): Unit = {
    val glueContext = new GlueContext(SparkContext.getOrCreate())
    val args = GlueArgParser.getResolvedOptions(sysArgs, Seq("JOB_NAME").toArray)
    Job.init(args("JOB_NAME"), glueContext, args.asJava)

    val dynamicFrame = glueContext.getCatalogSource(
        database = catalog_database,
        tableName = catalog_table_name,
        additionalOptions = JsonOptions(Map(
            "dynamodb.export" -> "ddb",
            "dynamodb.s3.bucket" -> s3_bucket,
```

```
            "dynamodb.s3.prefix" -> s3_bucket_prefix
        ))
    ).getDynamicFrame()
    print(dynamicFrame.getNumPartitions())
)
```

Simplificación del uso del JSON de exportación de DynamoDB

Las exportaciones de DynamoDB con el conector de exportación de DynamoDB de AWS Glue generan archivos JSON con estructuras anidadas específicas. Para obtener más información, consulte Objetos de datos. AWS Glue proporciona una transformación de DynamicFrame, que puede desanidar estas estructuras y dejarlas con una forma más fácil de usar para aplicaciones posteriores.

La transformación se puede invocar de dos formas. Puede configurar la opción de conexión de `"dynamodb.simplifyDDBJson"` con el valor `"true"` cuando se llame a un método para leer desde DynamoDB. También puede llamar a la transformación como un método disponible de forma independiente en la biblioteca de AWS Glue.

Considere el siguiente esquema generado por una exportación a DynamoDB:

```
root
|-- Item: struct
|    |-- parentMap: struct
|    |    |-- M: struct
|    |    |    |-- childMap: struct
|    |    |    |    |-- M: struct
|    |    |    |    |    |-- appName: struct
|    |    |    |    |    |    |-- S: string
|    |    |    |    |    |-- packageName: struct
|    |    |    |    |    |    |-- S: string
|    |    |    |    |    |-- updatedAt: struct
|    |    |    |    |    |    |-- N: string
|    |-- strings: struct
|    |    |-- SS: array
|    |    |    |-- element: string
|    |-- numbers: struct
|    |    |-- NS: array
|    |    |    |-- element: string
|    |-- binaries: struct
|    |    |-- BS: array
|    |    |    |-- element: string
```

```
|    |-- isDDBJson: struct
|    |    |-- BOOL: boolean
|    |-- nullValue: struct
|    |    |-- NULL: boolean
```

La transformación de `simplifyDDBJson` simplificará esto de la siguiente forma:

```
root
|-- parentMap: struct
|    |-- childMap: struct
|    |    |-- appName: string
|    |    |-- packageName: string
|    |    |-- updatedAt: string
|-- strings: array
|    |-- element: string
|-- numbers: array
|    |-- element: string
|-- binaries: array
|    |-- element: string
|-- isDDBJson: boolean
|-- nullValue: null
```

> **Note**
>
> `simplifyDDBJson` solo está disponible en AWS Glue 3.0 o versiones posteriores. La transformación `unnestDDBJson` también está disponible para simplificar la exportación de JSON a DynamoDB. Alentamos a los usuarios a realizar la transición de `unnestDDBJson` a `simplifyDDBJson`.

Configuración del paralelismo en las operaciones de DynamoDB

Para mejorar el rendimiento, puede ajustar determinados parámetros disponibles para el conector DynamoDB. Su objetivo al ajustar los parámetros de paralelismo es maximizar el uso de los trabajadores de AWS Glue aprovisionados. Por lo tanto, si necesita más rendimiento, le recomendamos que amplíe su trabajo al aumentar el número de DPU.

Puede modificar el paralelismo en una operación de lectura de DynamoDB mediante el parámetro `dynamodb.splits` cuando utilice el conector ETL. Cuando lea con el conector de exportación, no es necesario configurar el número de divisiones del paralelismo del ejecutor

de Spark. Puede modificar el paralelismo en una operación de escritura de DynamoDB con `dynamodb.output.numParallelTasks`.

Lectura con el conector ETL de DynamoDB

Le recomendamos que calcule `dynamodb.splits` en función del número máximo de trabajadores establecido en la configuración de su trabajo y del siguiente cálculo `numSlots`. Si se autoescala, la cantidad real de trabajadores disponibles puede cambiar por debajo de ese límite. Para obtener más información sobre cómo establecer el número máximo de trabajadores, consulte Número de trabajadores (`NumberOfWorkers`) en the section called “Configuración de las propiedades de trabajo de Spark”.

- `numExecutors = NumberOfWorkers - 1`

  Para contextualizar, un ejecutor está reservado para el controlador de Spark mientras que otros ejecutores procesan datos.
- `numSlotsPerExecutor =`

  AWS Glue 3.0 and later versions
  - 4 si `WorkerType` es `G.1X`
  - 8 si `WorkerType` es `G.2X`
  - 16 si `WorkerType` es `G.4X`
  - 32 si `WorkerType` es `G.8X`

  AWS Glue 2.0 and legacy versions
  - 8 si `WorkerType` es `G.1X`
  - 16 si `WorkerType` es `G.2X`
- `numSlots = numSlotsPerExecutor * numExecutors`

Le recomendamos que establezca `dynamodb.splits` al número de ranuras disponibles, `numSlots`.

Escritura en DynamoDB

El parámetro `dynamodb.output.numParallelTasks` se utiliza para determinar la WCU por tarea de Spark mediante el siguiente cálculo:

```
permittedWcuPerTask = ( TableWCU * dynamodb.throughput.write.percent ) /
dynamodb.output.numParallelTasks
```

El escritor de DynamoDB funcionará mejor si la configuración representa con precisión el número de tareas de Spark que se escriben en DynamoDB. En algunos casos, es posible que necesite anular el cálculo predeterminado para mejorar el rendimiento de la escritura. Si no especifica este parámetro, el WCU permitido por tarea de Spark se calculará automáticamente mediante la siguiente fórmula:

-
  - `numPartitions = dynamicframe.getNumPartitions()`
  - `numSlots` (tal y como se definió anteriormente en esta sección)
  - `numParallelTasks = min(numPartitions, numSlots)`
- Ejemplo 1. DPU=10, tipo de empleado=estándar. La entrada DynamicFrame tiene 100 particiones RDD.
  - `numPartitions = 100`
  - `numExecutors = (10 - 1) * 2 - 1 = 17`
  - `numSlots = 4 * 17 = 68`
  - `numParallelTasks = min(100, 68) = 68`
- Ejemplo 2. DPU=10, tipo de empleado=estándar. La entrada DynamicFrame tiene 20 particiones RDD.
  - `numPartitions = 20`
  - `numExecutors = (10 - 1) * 2 - 1 = 17`
  - `numSlots = 4 * 17 = 68`
  - `numParallelTasks = min(20, 68) = 20`

> **Note**
>
> Los trabajos heredados de las versiones de AWS Glue, y los que utilizan trabajadores estándar, requieren diferentes métodos para calcular el número de ranuras. Si necesita ajustar el rendimiento de estos trabajos, le recomendamos que haga la transición a las versiones de AWS Glue compatibles.

Referencia de opciones de conexión de DynamoDB

Designa una conexión a Amazon DynamoDB.

Las opciones de conexión son distintas entre una conexión de origen y una conexión de receptor.

"connectionType": "dynamodb" con el conector de ETL como origen

Utilice las siguientes opciones de conexión con `"connectionType": "dynamodb"` como origen cuando use el conector de ETL de DynamoDB de AWS Glue:

- `"dynamodb.input.tableName"`: (obligatorio) la tabla de DynamoDB de la que se va a leer.
- `"dynamodb.throughput.read.percent"`: (opcional) porcentaje de unidades de capacidad de lectura (RCU) que se usará. El valor predeterminado se establece en "0,5". Los valores aceptables abarcan de "0,1" a "1,5", inclusive.
  - `0.5` representa la tasa de lectura predeterminada, es decir que AWS Glue intentará consumir la mitad de la capacidad de lectura de la tabla. Si usted aumenta el valor por encima de `0.5`, AWS Glue incrementará la tasa de solicitudes; si reduce el valor por debajo de `0.5`, disminuirá la tasa de solicitudes de lectura. (La tasa de lectura real varía, según diversos factores tales como el hecho de que exista o no una distribución uniforme de claves en la tabla de DynamoDB).
  - Cuando la tabla de DynamoDB está en modo bajo demanda, AWS Glue maneja la capacidad de lectura de la tabla como 40 000. Para exportar una tabla de gran extensión, recomendamos cambiar la tabla de DynamoDB al modo bajo demanda.
- `"dynamodb.splits"`: (opcional) define la cantidad de particiones en las que dividimos esta tabla de DynamoDB al leerla. El valor predeterminado se establece en "1". Los valores aceptables abarcan de "1" a "1,000,000", inclusive.

  1 representa que no hay paralelismo. Se recomienda especialmente que especifique un valor mayor para un mejor rendimiento mediante la fórmula siguiente. Para obtener más información sobre cómo configurar un valor de forma adecuada, consulte the section called “Paralelismo de DynamoDB”.
- `"dynamodb.sts.roleArn"`: (opcional) el ARN de rol de IAM que se asumirá para el acceso entre cuentas. Este parámetro se encuentra disponible en AWS Glue 1.0 o posterior.
- `"dynamodb.sts.roleSessionName"`: (opcional) nombre de sesión STS. El valor predeterminado se establece en “glue-dynamodb-read-sts-session”. Este parámetro se encuentra disponible en AWS Glue 1.0 o posterior.

“connectionType”: “dynamodb” con el conector de exportación de DynamoDB de AWS Glue como origen

Utilice las siguientes opciones de conexión con “connectionType”: “dynamodb” como origen cuando use el conector de exportación de DynamoDB de AWS Glue, que solo está disponible a partir de AWS Glue versión 2.0:

- `"dynamodb.export"`: (obligatorio) valor de cadena:
  - Si se configura como `ddb`, habilita el conector de exportación de DynamoDB de AWS Glue cuando se invoque una nueva `ExportTableToPointInTimeRequest` durante el trabajo de AWS Glue. Se generará una nueva exportación con la ubicación pasada desde `dynamodb.s3.bucket` y `dynamodb.s3.prefix`.
  - Si se configura como `s3`, habilita el conector de exportación de DynamoDB de AWS Glue, pero omite la creación de una nueva exportación de DynamoDB y, en su lugar, utiliza `dynamodb.s3.bucket` y `dynamodb.s3.prefix` como ubicación de Simple Storage Service (Amazon S3) de una exportación anterior de esa tabla.
- `"dynamodb.tableArn"`: (obligatorio) tabla de DynamoDB desde la que se debe leer.
- `"dynamodb.unnestDDBJson"`: (Opcional) Predeterminado: falso. Valores válidos: booleano. Si se configura como true, realiza una transformación no anidada de la estructura JSON de DynamoDB que está presente en las exportaciones. Es un error si se establecen `"dynamodb.unnestDDBJson"` y `"dynamodb.simplifyDDBJson"` como verdaderos al mismo tiempo. En AWS Glue 3.0 y versiones posteriores, le recomendamos que lo utilice `"dynamodb.simplifyDDBJson"` para mejorar el comportamiento al simplificar los tipos de mapas de DynamoDB. Para obtener más información, consulte the section called “Simplificación del uso del JSON de exportación de DynamoDB”.
- `"dynamodb.simplifyDDBJson"`: (Opcional) Predeterminado: falso. Valores válidos: booleano. Si se configura como verdadero, realiza una transformación para simplificar el esquema de JSON de DynamoDB que está presente en las exportaciones. Tiene el mismo propósito que la opción `"dynamodb.unnestDDBJson"`, pero proporciona un mejor soporte para los tipos de mapas de DynamoDB o incluso con los tipos de mapas anidados en su tabla de DynamoDB. Esta característica solo está disponible en AWS Glue 3.0 o versiones posteriores. Es un error si se establecen `"dynamodb.unnestDDBJson"` y `"dynamodb.simplifyDDBJson"` como verdaderos al mismo tiempo. Para obtener más información, consulte the section called “Simplificación del uso del JSON de exportación de DynamoDB”.

- `"dynamodb.s3.bucket"`: (opcional) indica la ubicación del bucket de Simple Storage Service (Amazon S3) en el que debe llevarse a cabo el proceso `ExportTableToPointInTime` de DynamoDB. El formato de archivo para la exportación es DynamoDB JSON.
  - `"dynamodb.s3.prefix"`: (opcional) indica la ubicación del prefijo de Simple Storage Service (Amazon S3) dentro del bucket de Simple Storage Service (Amazon S3) en el que se almacenarán las cargas `ExportTableToPointInTime` de DynamoDB. Si no se especifica `dynamodb.s3.prefix` ni `dynamodb.s3.bucket`, estos valores adoptarán de manera predeterminada la ubicación del directorio temporal especificada en la configuración del trabajo de AWS Glue. Para obtener más información, consulte Parámetros especiales utilizados por AWS Glue.
  - `"dynamodb.s3.bucketOwner"`: indica el propietario del bucket que se necesita para el acceso entre cuentas de Simple Storage Service (Amazon S3).
- `"dynamodb.sts.roleArn"`: (opcional) ARN del rol de IAM que se asumirá para el acceso entre cuentas o el acceso entre regiones para la tabla de DynamoDB. Nota: El mismo ARN del rol de IAM se utilizará para acceder a la ubicación de Simple Storage Service (Amazon S3) especificada para la solicitud `ExportTableToPointInTime`.
- `"dynamodb.sts.roleSessionName"`: (opcional) nombre de sesión STS. El valor predeterminado se establece en “glue-dynamodb-read-sts-session”.
- `"dynamodb.exportTime"` (Opcional) Valores válidos: cadenas que representan instantes de la norma ISO-8601. Un punto en el tiempo en el que debe realizarse la exportación.
- `"dynamodb.sts.region"`: (Obligatorio si se realiza una llamada entre regiones mediante un punto de conexión regional) La región que aloja la tabla de DynamoDB que desea leer.

“connectionType”: “dynamodb” con el conector de ETL como receptor

Utilice las siguientes opciones de conexión con `"connectionType": "dynamodb"` como receptor:

- `"dynamodb.output.tableName"`: (obligatorio) tabla de DynamoDB en la que se va a escribir.
- `"dynamodb.throughput.write.percent"`: (opcional) porcentaje de unidades de capacidad de escritura (WCU) que se usará. El valor predeterminado se establece en "0,5". Los valores aceptables abarcan de "0,1" a "1,5", inclusive.
  - `0.5` representa la tasa de escritura predeterminada, es decir que AWS Glue intentará consumir la mitad de la capacidad de escritura de la tabla. Si usted aumenta el valor por encima de 0,5, AWS Glue incrementará la tasa de solicitudes; si reduce el valor por debajo de 0,5, disminuirá la tasa de solicitudes de escritura. (La tasa de escritura real varía en función de diversos factores,

tales como el hecho de que exista o no una distribución uniforme de claves en la tabla de DynamoDB).

- Cuando la tabla de DynamoDB está en modo bajo demanda, AWS Glue maneja la capacidad de escritura de la tabla como `40000`. Para importar una tabla grande, recomendamos cambiar la tabla de DynamoDB al modo bajo demanda.

- `"dynamodb.output.numParallelTasks"`: (opcional) define el número de tareas paralelas que escriben en DynamoDB al mismo tiempo. Se utiliza para calcular WCU permisiva por tarea de Spark. En la mayoría de los casos, AWS Glue calculará un valor predeterminado razonable para este valor. Para obtener más información, consulte the section called “Paralelismo de DynamoDB”.
- `"dynamodb.output.retry"`: (opcional) define el número de reintentos que realizamos cuando hay una `ProvisionedThroughputExceededException` de DynamoDB. El valor predeterminado se establece en “10”.
- `"dynamodb.sts.roleArn"`: (opcional) el ARN de rol de IAM que se asumirá para el acceso entre cuentas.
- `"dynamodb.sts.roleSessionName"`: (opcional) nombre de sesión STS. El valor predeterminado se establece en “glue-dynamodb-write-sts-session”.

Acceso entre cuentas y entre regiones a tablas de DynamoDB

AWS Glue Los trabajos de ETL de soportan el acceso entre cuentas y entre regiones a tablas de DynamoDB. AWS Glue Los trabajos de ETL soportan tanto la lectura de datos de una tabla de DynamoDB de otra cuenta AWS, como la escritura de datos de una tabla de DynamoDB de otra cuenta AWS. AWS Glue también soporta la lectura de una tabla de DynamoDB en otra región y la escritura en una tabla de DynamoDB en otra región. En esta sección se proporcionan instrucciones sobre cómo configurar el acceso y se proporciona un script de ejemplo.

Los procedimientos de esta sección hacen referencia a un tutorial de IAM para crear un rol de IAM y conceder acceso al rol. El tutorial también explica cómo asumir un rol, pero aquí usará un script de trabajo para asumir el rol en AWS Glue. Este tutorial también contiene información acerca de las prácticas generales entre cuentas. Para obtener más información, consulte Tutorial: delegar el acceso entre cuentas de AWS mediante roles de IAM en la Guía del usuario de IAM.

Crear un rol

Siga el paso 1 en el tutorial para crear un rol de IAM en la cuenta A. Al definir los permisos del rol, puede optar por asociar políticas existentes como `AmazonDynamoDBReadOnlyAccess` o

`AmazonDynamoDBFullAccess` para permitir que el rol lea y escriba DynamoDB. En el siguiente ejemplo, se muestra cómo crear un rol llamado `DynamoDBCrossAccessRole`, con la política de permisos `AmazonDynamoDBFullAccess`.

Conceder acceso al rol

Siga el paso 2 en el tutorial en la Guía del usuario de IAM para permitir que la cuenta B cambie al rol recién creado. En el siguiente ejemplo, se crea una nueva política con la siguiente instrucción:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": {
    "Effect": "Allow",
    "Action": "sts:AssumeRole",
    "Resource": "arn:aws:iam::111122223333:role/DynamoDBCrossAccessRole"
  }
}
```

A continuación, puede asociar esta política al grupo/rol o usuario que desea utilizar para acceder a DynamoDB.

Asumir el rol en el script de trabajo de AWS Glue

Ahora, puede iniciar sesión en la cuenta B y crear un trabajo de AWS Glue. Para crear un trabajo, consulte las instrucciones en Configuración de las propiedades de trabajos para trabajos de Spark en AWS Glue.

En el script de trabajo, debe usar el parámetro `dynamodb.sts.roleArn` para asumir el rol `DynamoDBCrossAccessRole`. Asumir este rol le permite obtener las credenciales temporales que deben utilizarse para acceder a DynamoDB en la cuenta B. Revise estos scripts de ejemplo.

Para una lectura entre cuentas entre regiones (conector ETL):

```
import sys
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job
```

```
from awsglue.utils import getResolvedOptions

args = getResolvedOptions(sys.argv, ["JOB_NAME"])
glue_context= GlueContext(SparkContext.getOrCreate())
job = Job(glue_context)
job.init(args["JOB_NAME"], args)

dyf = glue_context.create_dynamic_frame_from_options(
    connection_type="dynamodb",
    connection_options={
    "dynamodb.region": "us-east-1",
    "dynamodb.input.tableName": "test_source",
    "dynamodb.sts.roleArn": "<DynamoDBCrossAccessRole's ARN>"
    }
)
dyf.show()
job.commit()
```

Para una lectura entre cuentas entre regiones (conector ELT):

```
import sys
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job
from awsglue.utils import getResolvedOptions

args = getResolvedOptions(sys.argv, ["JOB_NAME"])
glue_context= GlueContext(SparkContext.getOrCreate())
job = Job(glue_context)
job.init(args["JOB_NAME"], args)

dyf = glue_context.create_dynamic_frame_from_options(
    connection_type="dynamodb",
    connection_options={
        "dynamodb.export": "ddb",
        "dynamodb.tableArn": "<test_source ARN>",
        "dynamodb.sts.roleArn": "<DynamoDBCrossAccessRole's ARN>"
    }
)
dyf.show()
job.commit()
```

Para una lectura y escritura entre cuentas entre regiones:

```
import sys
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job
from awsglue.utils import getResolvedOptions

args = getResolvedOptions(sys.argv, ["JOB_NAME"])
glue_context= GlueContext(SparkContext.getOrCreate())
job = Job(glue_context)
job.init(args["JOB_NAME"], args)

dyf = glue_context.create_dynamic_frame_from_options(
    connection_type="dynamodb",
    connection_options={
        "dynamodb.region": "us-east-1",
        "dynamodb.input.tableName": "test_source"
    }
)
dyf.show()

glue_context.write_dynamic_frame_from_options(
    frame=dyf,
    connection_type="dynamodb",
    connection_options={
        "dynamodb.region": "us-west-2",
        "dynamodb.output.tableName": "test_sink",
        "dynamodb.sts.roleArn": "<DynamoDBCrossAccessRole's ARN>"
    }
)

job.commit()
```

Conector de DynamoDB con compatibilidad con Spark DataFrame

El conector de DynamoDB con compatibilidad con Spark DataFrame permite leer y escribir en tablas de DynamoDB mediante las API de Spark DataFrame. Los pasos de configuración del conector son los mismos que los del conector basado en DynamicFrame y pueden consultarse aquí.

Para cargar la biblioteca del conector basado en DataFrame, asegúrese de adjuntar una conexión de DynamoDB a la tarea de Glue.

Note

La interfaz de usuario (UI) de la consola de Glue actualmente no admite la creación de una conexión de DynamoDB. Puede usar la CLI de Glue (CreateConnection) para crear una conexión de DynamoDB:

```
aws glue create-connection \
    --connection-input '{
    "Name": "my-dynamodb-connection",
    "ConnectionType": "DYNAMODB",
    "ConnectionProperties": {},
    "ValidateCredentials": false,
    "ValidateForComputeEnvironments": ["SPARK"]
    }'
```

Una vez creada la conexión de DynamoDB, puede adjuntarla a su tarea de Glue mediante la CLI (CreateJob, UpdateJob) o directamente desde la página «Job details»:

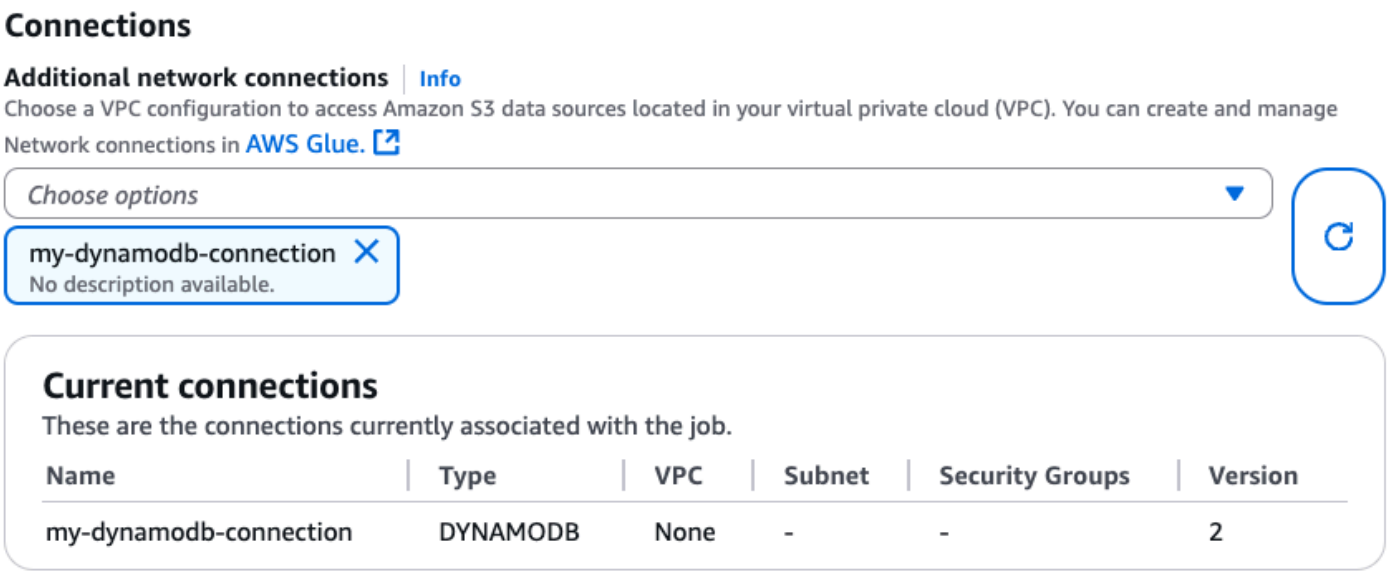

Una vez que se asegure de que una conexión de tipo DYNAMODB esté adjunta a su tarea de Glue, podrá utilizar las siguientes operaciones de lectura, escritura y exportación del conector basado en DataFrame.

Lectura y escritura en DynamoDB con el conector basado en DataFrame

En los siguientes ejemplos de código, se muestra cómo leer y escribir en tablas de DynamoDB mediante el conector basado en DataFrame. Demuestran la lectura de una tabla y la escritura en otra tabla.

Python

```
import sys
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job
from awsglue.utils import getResolvedOptions

args = getResolvedOptions(sys.argv, ["JOB_NAME"])
glue_context= GlueContext(SparkContext.getOrCreate())
spark = glueContext.spark_session
job = Job(glue_context)
job.init(args["JOB_NAME"], args)

# Read from DynamoDB
df = spark.read.format("dynamodb") \
    .option("dynamodb.input.tableName", "test-source") \
    .option("dynamodb.throughput.read.ratio", "0.5") \
    .option("dynamodb.consistentRead", "false") \
    .load()

print(df.rdd.getNumPartitions())

# Write to DynamoDB
df.write \
  .format("dynamodb") \
  .option("dynamodb.output.tableName", "test-sink") \
  .option("dynamodb.throughput.write.ratio", "0.5") \
  .option("dynamodb.item.size.check.enabled", "true") \
  .save()

job.commit()
```

Scala

```
import com.amazonaws.services.glue.GlueContext
import com.amazonaws.services.glue.util.GlueArgParser
```

```
import com.amazonaws.services.glue.util.Job
import org.apache.spark.SparkContext
import scala.collection.JavaConverters._

object GlueApp {
  def main(sysArgs: Array[String]): Unit = {

    val glueContext = new GlueContext(SparkContext.getOrCreate())
    val spark = glueContext.getSparkSession
    val args = GlueArgParser.getResolvedOptions(sysArgs, Seq("JOB_NAME").toArray)
    Job.init(args("JOB_NAME"), glueContext, args.asJava)

    val df = spark.read
      .format("dynamodb")
      .option("dynamodb.input.tableName", "test-source")
      .option("dynamodb.throughput.read.ratio", "0.5")
      .option("dynamodb.consistentRead", "false")
      .load()

    print(df.rdd.getNumPartitions)

    df.write
      .format("dynamodb")
      .option("dynamodb.output.tableName", "test-sink")
      .option("dynamodb.throughput.write.ratio", "0.5")
      .option("dynamodb.item.size.check.enabled", "true")
      .save()

    job.commit()
  }
}
```

Uso de la exportación de DynamoDB mediante el conector basado en DataFrame

Se prefiere la operación de exportación a la de lectura para tablas de DynamoDB con tamaños superiores a 80 GB. En los siguientes ejemplos de código, se muestra cómo leer desde una tabla, exportar a S3 e imprimir el número de particiones mediante el conector basado en DataFrame.

> **Note**
>
> La funcionalidad de exportación de DynamoDB está disponible a través del objeto Scala `DynamoDBExport`. Los usuarios de Python pueden acceder a esta funcionalidad mediante

la interoperabilidad con la JVM de Spark o usar el AWS SDK para Python (boto3) con la API DynamoDB `ExportTableToPointInTime`.

Scala

```
import com.amazonaws.services.glue.GlueContext
import com.amazonaws.services.glue.util.{GlueArgParser, Job}
import org.apache.spark.SparkContext
import glue.spark.dynamodb.DynamoDBExport
import scala.collection.JavaConverters._

object GlueApp {
  def main(sysArgs: Array[String]): Unit = {
    val glueContext = new GlueContext(SparkContext.getOrCreate())
    val spark = glueContext.getSparkSession
    val args = GlueArgParser.getResolvedOptions(sysArgs, Seq("JOB_NAME").toArray)
    Job.init(args("JOB_NAME"), glueContext, args.asJava)

    val options = Map(
      "dynamodb.export" -> "ddb",
      "dynamodb.tableArn" -> "arn:aws:dynamodb:us-east-1:123456789012:table/my-
table",
      "dynamodb.s3.bucket" -> "my-s3-bucket",
      "dynamodb.s3.prefix" -> "my-s3-prefix",
      "dynamodb.simplifyDDBJson" -> "true"
    )
    val df = DynamoDBExport.fullExport(spark, options)

    print(df.rdd.getNumPartitions)
    df.count()

    Job.commit()
  }
}
```

Opciones de configuración

Opciones de lectura

Opción	Descripción	Valor predeterminado
`dynamodb.input.tableName`	Nombre de la tabla de DynamoDB (obligatorio)	-
`dynamodb.throughput.read`	Las unidades de capacidad de lectura (RCU) que se van a utilizar. Si no se especifica, `dynamodb.throughput.read.ratio` se utiliza para el cálculo.	-
`dynamodb.throughput.read.ratio`	La proporción de unidades de capacidad de lectura (RCU) que se va a utilizar	0,5
`dynamodb.table.read.capacity`	La capacidad de lectura de la tabla bajo demanda que se utiliza para calcular el rendimiento Este parámetro solo es efectivo en tablas con capacidad bajo demanda. Usa de forma predeterminada unidades de rendimiento de lectura en estado semiactivo.	-
`dynamodb.splits`	Define cuántos segmentos se utilizan en operaciones de escaneo en paralelo. Si no se proporciona, el conector calculará un valor predeterminado razonable.	-
`dynamodb.consistentRead`	Uso de lecturas altamente coherentes	FALSO
`dynamodb.input.retry`	Define cuántos reintentos se realizan cuando se produce una excepción que admite reintento .	10

Opciones de escritura

Opción	Descripción	Valor predeterminado
`dynamodb.output.tableName`	Nombre de la tabla de DynamoDB (obligatorio)	-
`dynamodb.throughput.write`	Las unidades de capacidad de escritura (WCU) que se van a utilizar Si no se especifica, se utiliza `dynamodb.throughput.write.ratio` para el cálculo.	-
`dynamodb.throughput.write.ratio`	La proporción de unidades de capacidad de escritura (WCU) que se va a utilizar	0,5
`dynamodb.table.write.capacity`	La capacidad de escritura de la tabla bajo demanda que se utiliza para calcular el rendimiento. Este parámetro solo es efectivo en tablas con capacidad bajo demanda. Usa de forma predeterminada unidades de rendimiento de escritura en estado semiactivo.	-
`dynamodb.item.size.check.enabled`	Si es «true», el conector calcula el tamaño del elemento e interrumpe la operación si dicho tamaño supera el tamaño máximo, antes de escribir en la tabla de DynamoDB.	TRUE
`dynamodb.output.retry`	Define cuántos reintentos se realizan cuando se produce una excepción que admite reintento .	10

Opciones de exportación

Opción	Descripción	Valor predeterminado
`dynamodb.export`	Si se configura como ddb, se habilita el conector de exportación de DynamoDB de AWS Glue, mediante el cual se invocará una nueva `ExportTableToPointInTimeRequet` durante la tarea de AWS Glue. Se generará una nueva exportación con la ubicación pasada desde `dynamodb.s3.bucket` y `dynamodb.s3.prefix`. Si se configura como `s3`, se habilita el conector de exportación de DynamoDB de AWS Glue, pero se omite la creación de una nueva exportación de DynamoDB y, en su lugar, se usan `dynamodb.s3.bucket` y `dynamodb.s3.prefix` como la ubicación en Amazon S3 de la exportación anterior de esa tabla.	ddb
`dynamodb.tableArn`	La tabla de DynamoDB desde la que se va a leer Obligatorio si `dynamodb.export` se establece en ddb.	
`dynamodb.simplifyDDBJson`	Si se configura como `true`, realiza una transformación para simplificar el esquema de la estructura JSON de DynamoDB presente en las exportaciones.	FALSO
`dynamodb.s3.bucket`	El bucket de S3 para almacenar datos temporales durante la exportación de DynamoDB (obligatorio).	

Opción	Descripción	Valor predeterminado
`dynamodb.s3.prefix`	El prefijo de S3 para almacenar datos temporales durante la exportación de DynamoDB	
`dynamodb.s3.bucketOwner`	Indica el propietario del bucket necesario para el acceso entre cuentas a Amazon S3.	
`dynamodb.s3.sse.algorithm`	El tipo de cifrado utilizado en el bucket donde se almacenarán los datos temporales Los valores válidos son `AES256` y `KMS`.	
`dynamodb.s3.sse.kmsKeyId`	El ID de la clave administrada de AWS KMS utilizada para cifrar el bucket de S3 donde se almacenarán los datos temporales (si corresponde).	
`dynamodb.exportTime`	Un punto en el tiempo en el que debe realizarse la exportación. Valores válidos: cadenas que representan instantes ISO-8601	

Opciones generales

Opción	Descripción	Valor predeterminado
`dynamodb.sts.roleArn`	El ARN del rol de IAM que se debe asumir para el acceso entre cuentas.	-
`dynamodb.sts.roleSessionName`	Nombre de la sesión de STS	`glue-dynamodb-sts-session`

Opción	Descripción	Valor predeterminado
`dynamodb.sts.region`	Región del cliente de STS (para la asunción de roles entre regiones)	Igual que la opción `region`

Conexión de Kinesis

Puede utilizar una conexión de Kafka para leer y escribir en Amazon Kinesis Data Streams mediante información almacenada en una tabla del catálogo de datos o si proporciona información para acceder directamente al flujo de datos. Puede leer la información de Kinesis en un DataFrame de Spark y, a continuación, convertirla en un DynamicFrame de AWS Glue. Puede escribir DynamicFrames en Kinesis en formato JSON. Si accede directamente a la secuencia de datos, utilice estas opciones para proporcionar información sobre cómo acceder a la secuencia de datos.

Si utiliza `getCatalogSource` o `create_data_frame_from_catalog` para consumir registros de una fuente de streaming de Kinesis, el trabajo tiene la base de datos de Data Catalog y la información del nombre de la tabla, y puede utilizarla para obtener algunos parámetros básicos para la lectura de la fuente de streaming de Kinesis. Si utiliza `getSource`, `getSourceWithFormat`, `createDataFrameFromOptions` o `create_data_frame_from_options` debe especificar estos parámetros básicos mediante las opciones de conexión descritas aquí.

Puede especificar las opciones de conexión para Kinesis al utilizar los siguientes argumentos para los métodos especificados en la clase `GlueContext`.

- Scala
  - `connectionOptions`: se debe utilizar con `getSource`, `createDataFrameFromOptions` y `getSink`
  - `additionalOptions`: se debe utilizar con `getCatalogSource`, `getCatalogSink`
  - `options`: se debe utilizar con `getSourceWithFormat`, `getSinkWithFormat`
- Python
  - `connection_options`: se debe utilizar con `create_data_frame_from_options`, `write_dynamic_frame_from_options`

- `additional_options`: se debe utilizar con `create_data_frame_from_catalog`, `write_dynamic_frame_from_catalog`
- `options`: se debe utilizar con `getSource`, `getSink`

Para obtener notas y restricciones sobre los trabajos de ETL de Streaming, consulte the section called “Notas y restricciones de ETL de streaming”.

Configurar Kinesis

Para conectarse desde un flujo de datos de Kinesis en un trabajo de AWS Glue Spark, necesitará algunos requisitos previos:

- Si está leyendo, el trabajo de AWS Glue debe tener permisos de IAM de nivel de acceso de lectura para el flujo de datos de Kinesis.
- Si está escribiendo, el trabajo de AWS Glue debe tener permisos de IAM de nivel de acceso de escritura para el flujo de datos de Kinesis.

En algunos casos, tendrá que configurar requisitos previos adicionales:

- Si su trabajo de AWS Glue está configurado con conexiones de red adicionales (normalmente para conectarse a otros conjuntos de datos) y una de esas conexiones proporciona opciones de red de Amazon VPC, esto indicará que su trabajo se comunique a través de Amazon VPC. En este caso, también tendrá que configurar el flujo de datos de Kinesis para que se comunique a través de Amazon VPC. Puede hacerlo mediante la creación de un punto de conexión de VPC de tipo interfaz entre la Amazon VPC y el flujo de datos de Kinesis. Para obtener más información, consulte Uso de Kinesis de Amazon Kinesis Data Streams con puntos de conexión de VPC de interfaz.
- Al especificar Amazon Kinesis Data Streams en otra cuenta, debe configurar los roles y las políticas para permitir el acceso entre cuentas. Para obtener más información, consulte Ejemplo: leer desde un flujo de Kinesis en una cuenta diferente.

Para obtener más información sobre los requisitos previos del trabajo de ETL de Streaming, consulte the section called “Trabajos ETL de streaming”.

Ejemplo: lectura de transmisiones desde Kinesis

Ejemplo: lectura de transmisiones desde Kinesis

Se utiliza junto con the section called “forEachBatch”.

Ejemplo de origen de streaming de Amazon Kinesis:

```
kinesis_options =
   { "streamARN": "arn:aws:kinesis:us-east-2:777788889999:stream/fromOptionsStream",
     "startingPosition": "TRIM_HORIZON",
     "inferSchema": "true",
     "classification": "json"
   }
data_frame_datasource0 =
 glueContext.create_data_frame.from_options(connection_type="kinesis",
 connection_options=kinesis_options)
```

Ejemplo: escribir en flujos de Kinesis

Ejemplo: lectura de transmisiones desde Kinesis

Se utiliza junto con the section called “forEachBatch”.

Ejemplo de origen de streaming de Amazon Kinesis:

```
kinesis_options =
   { "streamARN": "arn:aws:kinesis:us-east-2:777788889999:stream/fromOptionsStream",
     "startingPosition": "TRIM_HORIZON",
     "inferSchema": "true",
     "classification": "json"
   }
data_frame_datasource0 =
 glueContext.create_data_frame.from_options(connection_type="kinesis",
 connection_options=kinesis_options)
```

Referencia de opciones de conexión de Kinesis

Designa opciones de conexión para Amazon Kinesis Data Streams.

Utilice las siguientes opciones de conexión para los orígenes de datos de streaming de Kinesis:

- `"streamARN"`: (Obligatorio) Se utiliza para leer/escribir. El ARN de flujo de datos de Kinesis.
- `"classification"`: (Obligatorio para lectura) Se utiliza para leer. El formato de archivo utilizado por los datos del registro. Obligatorio a menos que se proporcione a través del catálogo de datos.
- `"streamName"`: (Opcional) Se usa para leer. Nombre de un flujo de datos de Kinesis para leer. Utilizado con `endpointUrl`.
- `"endpointUrl"`: (Opcional) Se usa para leer. Predeterminado: “https://kinesis.us-east-1.amazonaws.com”. El punto de conexión de AWS del flujo de Kinesis. No es necesario cambiar esto a menos que se conecte a una región especial.
- `"partitionKey"`: (Opcional) Se usa para escribir. La clave de partición de Kinesis que se utiliza al producir registros.
- `"delimiter"`: (Opcional) Se usa para leer. El separador de valores que se utiliza cuando `classification` es CSV. El valor predeterminado es “`,`”.
- `"startingPosition"`: (Opcional) Se usa para leer. La posición inicial en el flujo de datos de Kinesis para leer los datos. Los valores posibles son `"latest"`, `"trim_horizon"`, `"earliest"` o una cadena de marca de tiempo en formato UTC en el patrón `yyyy-mm-ddTHH:MM:SSZ` (donde Z representa un desplazamiento de zona horaria UTC con un +/-. Por ejemplo, “04-04-2023 T 08:00:00-04:00”). El valor predeterminado es `"latest"`. Nota: La cadena de marca de tiempo en formato UTC para `"startingPosition"` solo es compatible con la versión 4.0 o posterior de Glue AWS.
- `"failOnDataLoss"`: (Opcional) No se realizará el trabajo si falta o ha caducado alguna partición activa. El valor predeterminado es `"false"`.
- `"awsSTSRoleARN"`: (Opcional) Se usa para escribir/leer. El nombre de recurso de Amazon (ARN) del rol de que se asumirá mediante AWS Security Token Service (AWS STS). Este rol debe tener permisos para describir o leer operaciones de registros del flujo de datos de Kinesis. Debe utilizar este parámetro para acceder a un flujo de datos de otra cuenta. Se utiliza junto con `"awsSTSSessionName"`.
- `"awsSTSSessionName"`: (Opcional) Se usa para escribir/leer. Un identificador para la sesión que asume el rol mediante AWS STS. Debe utilizar este parámetro para acceder a un flujo de datos de otra cuenta. Se utiliza junto con `"awsSTSRoleARN"`.
- `"awsSTSEndpoint"`: (Opcional) El punto de conexión de AWS STS que se utilizará al conectarse a Kinesis con un rol asumido. Esto permite usar el punto de conexión regional de AWS STS en una VPC, lo que no es posible con el punto de conexión global predeterminado.
- `"maxFetchTimeInMs"`: (Opcional) Se usa para leer. El tiempo máximo que le tomó al ejecutor del trabajo leer los registros del lote actual en el flujo de datos de Kinesis, especificado en

milisegundos (ms). Pueden realizarse varias llamadas a la API de `GetRecords` durante este tiempo. El valor predeterminado es `1000`.

- `"maxFetchRecordsPerShard"`: (Opcional) Se usa para leer. El número máximo de registros que se recuperará por partición en el flujo de datos de Kinesis por microlote. Nota: El cliente puede exceder este límite si el trabajo de streaming ya leyó registros adicionales de Kinesis (en la misma llamada de obtención de registros). Si `maxFetchRecordsPerShard` tiene que ser preciso, entonces tiene que ser un múltiplo de `maxRecordPerRead`. El valor predeterminado es `100000`.
- `"maxRecordPerRead"`: (Opcional) Se usa para leer. El número máximo de registros que se recuperará del flujo de datos de Kinesis en cada operación `getRecords`. El valor predeterminado es `10000`.
- `"addIdleTimeBetweenReads"`: (Opcional) Se usa para leer. Agrega un retardo de tiempo entre dos operaciones `getRecords` consecutivas. El valor predeterminado es `"False"`. Esta opción sólo se puede configurar para Glue versión 2.0 y superior.
- `"idleTimeBetweenReadsInMs"`: (Opcional) Se usa para leer. El tiempo mínimo de retraso entre dos operaciones `getRecords` consecutivas, especificado en ms. El valor predeterminado es `1000`. Esta opción sólo se puede configurar para Glue versión 2.0 y superior.
- `"describeShardInterval"`: (Opcional) Se usa para leer. El intervalo mínimo de tiempo entre dos llamadas a la API `ListShards` para que su script considere cambios en los fragmentos. Para obtener más información, consulte Estrategias para cambios en los fragmentos en la Guía para desarrolladores de Amazon Kinesis Data Streams. El valor predeterminado es `1s`.
- `"numRetries"`: (Opcional) Se usa para leer. El número máximo de reintentos para las solicitudes de la API de Kinesis Data Streams. El valor predeterminado es `3`.
- `"retryIntervalMs"`: (Opcional) Se usa para leer. El periodo de enfriamiento (especificado en ms) antes de volver a intentar la llamada a la API de Kinesis Data Streams. El valor predeterminado es `1000`.
- `"maxRetryIntervalMs"`: (Opcional) Se usa para leer. El periodo de enfriamiento máximo (especificado en ms) entre dos intentos de llamada a la API de Kinesis Data Streams. El valor predeterminado es `10000`.
- `"avoidEmptyBatches"`: (Opcional) Se usa para leer. Evita crear un trabajo de microlotes vacío al comprobar si hay datos no leídos en el flujo de datos de Kinesis antes de que se inicie el lote. El valor predeterminado es `"False"`.
- `"schema"`: (Obligatorio cuando inferSchema se establece en false) Se utiliza para leer. El esquema que se utilizará para procesar la carga útil. Si la clasificación es `avro`, el esquema

proporcionado debe estar en el formato de esquema Avro. Si la clasificación no es `avro`, el esquema proporcionado debe estar en el formato de esquema DDL.

A continuación, se muestran algunos ejemplos de esquemas.

Example in DDL schema format

```
`column1` INT, `column2` STRING , `column3` FLOAT
```

Example in Avro schema format

```
{
  "type":"array",
  "items":
  {
    "type":"record",
    "name":"test",
    "fields":
    [
      {
        "name":"_id",
        "type":"string"
      },
      {
        "name":"index",
        "type":
        [
          "int",
          "string",
          "float"
        ]
      }
    ]
  }
}
```

- `"inferSchema"`: (Opcional) Se usa para leer. El valor predeterminado es “false”. Si se establece en “true”, el esquema se detectará durante el tiempo de ejecución desde la carga dentro de `foreachbatch`.
- `"avroSchema"`: (Obsoleto) Se usa para leer. Parámetro utilizado para especificar un esquema de datos Avro cuando se utiliza el formato Avro. Este parámetro se ha quedado obsoleto. Utilice el parámetro `schema`.

- `"addRecordTimestamp"`: (Opcional) Se usa para leer. Cuando esta opción se establece en “true”, la salida de datos contendrá una columna adicional denominada “__src_timestamp” que indica la hora en la que el flujo recibió el registro correspondiente. El valor predeterminado es “false”. Esta opción es compatible con la versión 4.0 o posterior de AWS Glue.
- `"emitConsumerLagMetrics"`: (Opcional) Se usa para leer. Cuando la opción se establece en “verdadera”, para cada lote, emitirá las métricas correspondientes al periodo comprendido entre el registro más antiguo recibido por el flujo y el momento en que llegue a AWS Glue en CloudWatch. El nombre de la métrica es “glue.driver.streaming.maxConsumerLagInMs”. El valor predeterminado es “false”. Esta opción es compatible con la versión 4.0 o posterior de AWS Glue.
- `"fanoutConsumerARN"`: (Opcional) Se usa para leer. El ARN de un consumidor de un flujo de Kinesis para el flujo especificado en `streamARN`. Se utiliza para habilitar el modo de distribución mejorada para la conexión de Kinesis. Para obtener más información sobre cómo consumir una transmisión de Kinesis con una distribución mejorada, consulte the section called “Uso de una distribución mejorada en los trabajos de streaming de Kinesis”.
- `"recordMaxBufferedTime"`: (Opcional) Se usa para escribir. Predeterminado: 1000 (ms). Tiempo máximo que un registro permanece almacenado en búfer mientras espera a ser escrito.
- `"aggregationEnabled"`: (Opcional) Se usa para escribir. Valor predeterminado: verdadero. Especifica si los registros deben agregarse antes de enviarlos a Kinesis.
- `"aggregationMaxSize"`: (Opcional) Se usa para escribir. Predeterminado: 51 200 (bytes). Si un registro supera este límite, omitirá el agregador. Nota: Kinesis impone un límite de 50 KB en el tamaño del registro. Si lo establece por encima de 50 KB, Kinesis rechazará los registros de gran tamaño.
- `"aggregationMaxCount"`: (Opcional) Se usa para escribir. Predeterminado: 4294967295. Número máximo de elementos a empaquetar en un registro agregado.
- `"producerRateLimit"`: (Opcional) Se usa para escribir. Predeterminado: 150 (%). Limita el rendimiento por partición enviado desde un solo productor (por ejemplo, su trabajo), como porcentaje del límite de backend.
- `"collectionMaxCount"`: (Opcional) Se usa para escribir. Predeterminado: 500. Número máximo de elementos a incluir en una solicitud de PutRecords.
- `"collectionMaxSize"`: (Opcional) Se usa para escribir. Predeterminado: 5 242 880 (bytes). Cantidad máxima de datos para enviar con una solicitud de PutRecords.

Uso de una distribución mejorada en los trabajos de streaming de Kinesis

Un consumidor con una distribución mejorada puede recibir los registros de una transmisión de Kinesis con un rendimiento dedicado que puede ser superior al de los consumidores habituales. Esto se logra mediante la optimización del protocolo de transferencia utilizado para proporcionar datos a un consumidor de Kinesis, como su trabajo. Para obtener más información sobre Kinesis Enhanced Fan-Out, consulte la documentación de Kinesis.

En el modo de distribución mejorada, las opciones de conexión `maxRecordPerRead` y `idleTimeBetweenReadsInMs` ya no se aplican, ya que esos parámetros no se pueden configurar cuando se utiliza la apertura de distribución mejorada. Las opciones de configuración para los reintentos funcionan como se describe.

Utilice los siguientes procedimientos para habilitar y deshabilitar la distribución mejorada para su trabajo de streaming. Debe registrar un consumidor de transmisión para cada trabajo que vaya a consumir datos de su transmisión.

Para habilitar un consumo de distribución mejorada en su trabajo:

1. Registre un consumidor de transmisión para su trabajo mediante la API de Kinesis. Siga las instrucciones para registrar a un consumidor con una distribución mejorada mediante la API de Kinesis Data Streams de la documentación de Kinesis. Solo tendrá que seguir el primer paso: llamar a RegisterStreamConsumer. Su solicitud debe devolver un ARN, *`consumerARN`*.
2. Establezca la opción de conexión `fanoutConsumerARN` en *`consumerARN`* en los argumentos del método de conexión.
3. Reinicie el trabajo.

Para deshabilitar un consumo de distribución mejorada en su trabajo:

1. Elimine la opción de conexión `fanoutConsumerARN` de su método de llamada.
2. Reinicie el trabajo.
3. Siga las instrucciones para anular el registro de un consumidor en la documentación de Kinesis. Estas instrucciones se aplican a la consola, pero también se pueden obtener a través de la API de Kinesis. Para obtener más información sobre la cancelación del registro de consumidores de transmisión a través de la API de Kinesis, consulte DeregisterStreamConsumer en la documentación de Kinesis.

Conexiones de Amazon S3

Puede usar Glue AWS for Spark para leer y escribir archivos en Amazon S3. AWS Glue for Spark admite muchos formatos de datos habituales que se almacenan en Amazon S3 de forma inmediata, como CSV, Avro, JSON, Orc y Parquet. Para obtener más información acerca de los formatos de datos admitidos, consulte the section called “Opciones de formato de datos”. Cada formato de datos puede admitir diferentes características de Glue AWS. Consulte la página correspondiente a su formato de datos para conocer los detalles de la compatibilidad con las características. Además, puede leer y escribir archivos versionados almacenados en los marcos de lago de datos de Hudi, Iceberg y Delta Lake. Para obtener más información sobre los marcos de lago de datos, consulte the section called “Marcos de lagos de datos”.

Con Glue AWS, puede particionar sus objetos de Amazon S3 en una estructura de carpetas mientras escribe y, a continuación, recuperarlos mediante una partición para mejorar el rendimiento mediante una configuración sencilla. También puede establecer la configuración para agrupar archivos pequeños al transformar sus datos para mejorar el rendimiento. Puede leer, escribir `bzip2` y archivar `gzip` en Amazon S3.

Temas

- Configuración de las conexiones S3
- Referencia de opción de conexión de Amazon S3
- Sintaxis de conexión obsoleta para los formatos de datos
- Exclusión de clases de almacenamiento de Amazon S3
- Administración de particiones para la salida de ETL en AWS Glue
- Lectura de archivos de entrada en grupos más grandes
- Puntos de enlace de Amazon VPC para Amazon S3

Configuración de las conexiones S3

Para conectarse a Amazon S3 en un trabajo de Glue with Spark AWS, necesitará algunos requisitos previos:

- El trabajo de Glue AWS debe tener permisos de IAM para los buckets de Amazon S3 correspondientes.

En algunos casos, tendrá que configurar requisitos previos adicionales:

- Al configurar el acceso entre cuentas, los controles de acceso adecuados en el bucket de Amazon S3.
- Por motivos de seguridad, puede optar por enrutar sus solicitudes de Amazon S3 a través de una Amazon VPC. Este enfoque puede conllevar problemas de ancho de banda y disponibilidad. Para obtener más información, consulte the section called “Puntos de enlace de Amazon VPC para Amazon S3”.

Referencia de opción de conexión de Amazon S3

Designa una conexión a Amazon S3.

Dado que Amazon S3 administra archivos en lugar de tablas, además de especificar las propiedades de conexión que se proporcionan en este documento, tendrá que especificar una configuración adicional sobre su tipo de archivo. Puede especificar esta información mediante las opciones de formato de datos. Para obtener más información sobre las opciones de formato, consulte the section called “Opciones de formato de datos”. También puede especificar esta información integrándola con el catálogo de datos de Glue AWS.

Para ver un ejemplo de la distinción entre las opciones de conexión y las opciones de formato, considere la forma en que el método the section called “create_dynamic_frame_from_options” toma `connection_type`, `connection_options`, `format` y `format_options`. En esta sección se analizan específicamente los parámetros proporcionados a `connection_options`.

Utilice las siguientes opciones de conexión con `"connectionType": "s3"`:

- `"paths"`: (obligatorio) una lista de las rutas de Amazon S3 desde las que se va a leer.
- `"exclusions"`: (opcional) cadena que contiene una lista JSON de patrones glob de estilo Unix para excluir. Por ejemplo, `"[\"**.pdf\"]"` excluye todos los archivos PDF. Para obtener más información acerca de la sintaxis glob que admite AWS Glue, consulte Incluir y excluir patrones.
- `"compressionType"`: o `"compression"`: (opcional) especifica la forma en que los datos se comprimen. Use `"compressionType"` para orígenes de Amazon S3 y `"compression"` para destinos de Amazon S3. Po lo general no es necesario si los datos tienen una extensión de archivo estándar. Los posibles valores son `"gzip"` y `"bzip2"`). Es posible que se admitan formatos de compresión adicionales para formatos específicos. Consulte la página correspondiente a su formato de datos para conocer los detalles de la compatibilidad con las características.
- `"groupFiles"`: (opcional) la agrupación de archivos se habilita de forma predeterminada cuando la entrada contiene más de 50 000 archivos. Para habilitar las agrupaciones con menos de 50 000

archivos, establezca este parámetro en `"inPartition"`. Para deshabilitar las agrupaciones con más de 50 000 archivos, establezca este parámetro en `"none"`.

- `"groupSize"`: (opcional) tamaño del grupo de destino en bytes. El valor predeterminado se calcula en función del tamaño de los datos de entrada y el tamaño de su clúster. Cuando hay menos de 50 000 archivos de entrada, `"groupFiles"` debe establecerse en `"inPartition"` para que este valor surta efecto.
- `"recurse"`: (opcional) si se establece en verdadero, lee recursivamente archivos en todos los subdirectorios de las rutas especificadas.
- `"maxBand"`: (opcional, avanzada) esta opción controla la duración en milisegundos después de la que es probable que el listado de `s3` sea coherente. Se realiza un seguimiento de los archivos cuyas marcas de tiempo de modificación estén comprendidas en los últimos milisegundos de `maxBand`, en especial cuando se utilizan `JobBookmarks` para obtener coherencia eventual de Amazon S3. La mayoría de los usuarios no tienen que establecer esta opción. El valor predeterminado es 900 000 milisegundos, o 15 minutos.
- `"maxFilesInBand"`: (opcional, avanzada) esta opción especifica el número máximo de archivos que deben guardarse desde los últimos segundos de `maxBand`. Si se supera este número, los archivos adicionales se omiten y solo se procesarán en la siguiente ejecución del flujo de trabajo. La mayoría de los usuarios no tienen que establecer esta opción.
- `"isFailFast"`: (opcional) esta opción determina si un trabajo de ETL de AWS Glue arroja excepciones de análisis del lector. Si se establece en `true`, los trabajos fallan rápidamente si cuatro reintentos de la tarea Spark no pueden analizar los datos en forma correcta.
- `"catalogPartitionPredicate"`: (Opcional) Se usa para leer. El contenido de una cláusula SQL `WHERE`. Se utiliza al leer tablas del catálogo de datos con una gran cantidad de particiones. Recupera las particiones coincidentes de los índices del catálogo de datos. Se utiliza con `push_down_predicate`, una opción del método the section called “create_dynamic_frame_from_catalog” (y otros métodos similares). Para obtener más información, consulte the section called “Predicados de particiones de catálogo”.
- `"partitionKeys"`: (Opcional) Se usa para escribir. Matriz de cadenas de etiquetas de columnas. AWS Glue particionará los datos según lo especificado en esta configuración. Para obtener más información, consulte the section called “Escritura de particiones”.
- `"excludeStorageClasses"`: (Opcional) Se usa para leer. Matriz de cadenas que especifican las clases de almacenamiento de Amazon S3. AWS Glue excluirá los objetos de Amazon S3 en función de esta configuración. Para obtener más información, consulte the section called “Exclusión de clases de almacenamiento de Amazon S3”.

Sintaxis de conexión obsoleta para los formatos de datos

Se puede acceder a determinados formatos de datos mediante una sintaxis de tipo de conexión específica. Esta sintaxis está obsoleta. Recomendamos que especifique los formatos mediante la utilización del tipo de conexión `s3` y las opciones de formato que se proporcionan en the section called “Opciones de formato de datos” en su lugar.

"connectionType": "Orc"

Designa una conexión a archivos almacenados en Amazon S3 en formato de archivo Apache Hive Optimized Row Columnar (ORC).

Utilice las siguientes opciones de conexión con `"connectionType": "orc"`:

- `paths`: (obligatorio) una lista de las rutas de Amazon S3 desde las que se va a leer.
- (Otros pares de nombre/valor de la opción): cualquier opción adicional, incluidas las opciones de formato, se pasa directamente a SparkSQL `DataSource`.

"connectionType": "parquet"

Designa una conexión a archivos almacenados en Amazon S3 con el formato de archivo Apache Parquet.

Utilice las siguientes opciones de conexión con `"connectionType": "parquet"`:

- `paths`: (obligatorio) una lista de las rutas de Amazon S3 desde las que se va a leer.
- (Otros pares de nombre/valor de la opción): cualquier opción adicional, incluidas las opciones de formato, se pasa directamente a SparkSQL `DataSource`.

Exclusión de clases de almacenamiento de Amazon S3

Si ejecuta trabajos de ETL de AWS Glue que leen archivos o particiones desde Amazon Simple Storage Service (Amazon S3), puede excluir algunos tipos de clases de almacenamiento de Amazon S3.

Las siguientes clases de almacenamiento están disponibles en Amazon S3:

- `STANDARD`: para el almacenamiento de uso general de los datos a los que se accede con frecuencia.

- `INTELLIGENT_TIERING`: para datos de larga duración con patrones de acceso cambiantes o desconocidos.
- `STANDARD_IA` y `ONEZONE_IA`: para datos de larga duración, pero a los que se accede con menor frecuencia.
- `GLACIER`, `DEEP_ARCHIVE` y `REDUCED_REDUNDANCY`: para archivado a largo plazo y conservación digital.

Para obtener más información, consulte Clases de almacenamiento de Amazon S3 en la Guía para desarrolladores de Amazon S3.

Los ejemplos de esta sección muestran cómo excluir las clases de almacenamiento `DEEP_ARCHIVE` y `GLACIER`. Estas clases le permiten enumerar archivos, pero no le permiten leer los archivos a menos que se restauren. (Para obtener más información, consulte Restaurar objetos archivados en la Guía para desarrolladores de Amazon S3).

Mediante el uso de exclusiones de clase de almacenamiento, puede asegurarse de que sus trabajos de AWS Glue funcionarán en tablas que tengan particiones en estas capas de clase de almacenamiento. Sin exclusiones, los trabajos que leen datos de estas capas generan el siguiente error: AmazonS3Exception: The operation is not valid for the object's storage class (La operación no es válida para la clase de almacenamiento del objeto).

Existen diferentes formas de filtrar las clases de almacenamiento de Amazon S3 en AWS Glue.

Temas

- Exclusión de clases de almacenamiento de Amazon S3 al crear un marco dinámico
- Exclusión de clases de almacenamiento de Amazon S3 en una tabla de Data Catalog

Exclusión de clases de almacenamiento de Amazon S3 al crear un marco dinámico

Para excluir las clases de almacenamiento de Amazon S3 al crear un marco dinámico, utilice `excludeStorageClasses` en `additionalOptions`. AWS Glue utiliza automáticamente su propia implementación `Lister` de Amazon S3 para enumerar y excluir los archivos correspondientes a las clases de almacenamiento especificadas.

Los siguientes ejemplos de Python y Scala muestran cómo excluir las clases de almacenamiento `GLACIER` y `DEEP_ARCHIVE` al crear un marco dinámico.

Ejemplo de Python:

```
glueContext.create_dynamic_frame.from_catalog(
    database = "my_database",
    tableName = "my_table_name",
    redshift_tmp_dir = "",
    transformation_ctx = "my_transformation_context",
    additional_options = {
        "excludeStorageClasses" : ["GLACIER", "DEEP_ARCHIVE"]
    }
)
```

Ejemplo de Scala:

```
val* *df = glueContext.getCatalogSource(
    nameSpace, tableName, "", "my_transformation_context",
    additionalOptions = JsonOptions(
        Map("excludeStorageClasses" -> List("GLACIER", "DEEP_ARCHIVE"))
    )
).getDynamicFrame()
```

Exclusión de clases de almacenamiento de Amazon S3 en una tabla de Data Catalog

Puede especificar exclusiones de clase de almacenamiento que utilizará un trabajo de ETL de AWS Glue como parámetro de tabla en el Data Catalog de AWS Glue. Puede incluir este parámetro en la operación `CreateTable` mediante la AWS Command Line Interface (AWS CLI) o mediante programación con la API. Para obtener más información, consulte Estructura Table y CreateTable.

También puede especificar clases de almacenamiento excluidas en la consola de AWS Glue.

Para excluir clases de almacenamiento de Amazon S3 (consola)

1. Inicie sesión en la Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. En el panel de navegación de la izquierda, elija Tables (Tablas).
3. Elija el nombre de la tabla en la lista y, a continuación, elija Edit table (Editar tabla).
4. En Table properties (Propiedades de tabla), añada **`excludeStorageClasses`** como una clave y **`[\"GLACIER\",\"DEEP_ARCHIVE\"]`** como un valor.
5. Seleccione Aplicar.

Administración de particiones para la salida de ETL en AWS Glue

La creación de particiones es una importante técnica para organizar conjuntos de datos de manera que se puedan consultar de forma eficaz. Organiza los datos en una estructura de directorios jerárquica en función de los valores diferenciados de una o más columnas.

Por ejemplo, puede decidir particionar los registros de aplicación en Amazon Simple Storage Service (Amazon S3) por fecha, con desglose por año, mes y día. Los archivos que corresponden a los datos de un solo día se colocan con un prefijo como `s3://my_bucket/logs/year=2018/month=01/day=23/`. Los sistemas como Amazon Athena, Amazon Redshift Spectrum, y ahora AWS Glue, pueden utilizar estas particiones para filtrar datos por valor de partición sin tener que leer todos los datos subyacentes desde Amazon S3.

Los rastreadores no solo infieren los tipos de archivo y esquemas, sino que también identifican automáticamente la estructura de particiones del conjunto de datos cuando rellenan AWS Glue Data Catalog. Las columnas de partición resultantes están disponibles para consultarlas en trabajos de ETL de AWS Glue o motores de consulta como Amazon Athena.

Después de rastrear una tabla, puede ver las particiones que creó el rastreador. En la consola de AWS Glue, seleccione Tables (Tablas) en el panel de navegación de la izquierda. Elija la tabla creada por el rastreador y, a continuación, elija View Partitions (Ver Particiones).

En el caso de las rutas con particiones de tipo Apache Hive en el estilo `key=val`, los rastreadores rellenan automáticamente el nombre de columna con el nombre de clave. De lo contrario, utiliza nombres predeterminados como `partition_0`, `partition_1` y así sucesivamente. Puede cambiar los nombres predeterminados de la consola. Para ello, navegue hasta la tabla. Compruebe si existen índices en la pestaña Indexes (Índices). Si ese es el caso, debe eliminarlos para continuar (puede volver a crearlos con los nuevos nombres de columna más adelante). A continuación, seleccione Editar esquema y modifique allí los nombres de las columnas de partición.

En los scripts de ETL, puede filtrar por las columnas de partición. Dado que la información de partición se almacena en el Data Catalog, utilice llamadas a la API `from_catalog` para incluir las columnas de partición en el `DynamicFrame`. Por ejemplo, utilice `create_dynamic_frame.from_catalog` en lugar de `create_dynamic_frame.from_options`.

El particionamiento es una técnica de optimización que reduce el escaneo de datos. Para obtener más información sobre el proceso de identificación de cuándo esta técnica es adecuada, consulte Reducir la cantidad de datos escaneados en la guía de Prácticas recomendadas para el ajuste del rendimiento de AWS Glue para trabajos de Apache Spark en las Recomendaciones de AWS.

Filtrado previo con predicados de inserción

En muchos casos, puede utilizar un predicado de inserción para filtrar por particiones sin tener que enumerar y leer todos los archivos del conjunto de datos. En lugar de leer todo el conjunto de datos y, a continuación, realizar el filtrado en un objeto DynamicFrame, puede aplicar el filtro directamente en los metadatos de partición en el Data Catalog. A continuación, enumere y lea solo lo que necesita realmente en un objeto DynamicFrame.

Por ejemplo, en Python podría escribir lo siguiente.

```
glue_context.create_dynamic_frame.from_catalog(
    database = "my_S3_data_set",
    table_name = "catalog_data_table",
    push_down_predicate = my_partition_predicate)
```

De este modo se crea un objeto DynamicFrame que solo carga las particiones en el Data Catalog que cumplan la expresión de predicado. En función de lo pequeño que sea un subconjunto de los datos que esté cargando, se puede ahorrar mucho tiempo de procesamiento.

La expresión de predicado puede ser cualquier expresión booleana que admita Spark SQL. Funciona todo lo que podría incluir en una cláusula `WHERE` de una consulta SQL Spark. Por ejemplo, la expresión de predicado `pushDownPredicate = "(year=='2017' and month=='04')"` solo carga las particiones en el Data Catalog que tienen tanto `year` igual que 2017 como `month` igual que 04. Para obtener más información, consulte la documentación de Apache Spark SQL y, en concreto, la referencia de funciones SQL de Scala.

Filtrado del lado del servidor mediante predicados de partición de catálogo

La opción `push_down_predicate` se aplica después de crear el listado de todas las particiones del catálogo y antes de crear el listado de los archivos de Amazon S3 para esas particiones. Si tiene muchas particiones para una tabla, el listado de particiones del catálogo puede seguir incurriendo en sobrecarga de tiempo adicional. Para abordar esta sobrecarga, puede usar la poda de particiones del lado del servidor con la opción `catalogPartitionPredicate` que utiliza índices de partición en AWS Glue Data Catalog. Esto hace que el filtrado de particiones sea mucho más rápido cuando tiene millones de particiones en una tabla. Puede usar ambos `push_down_predicate` y `catalogPartitionPredicate` en `additional_options` en forma conjunta, si su `catalogPartitionPredicate` requiere sintaxis de predicado que aún no se soporta con los índices de partición del catálogo.

Python:

```
dynamic_frame = glueContext.create_dynamic_frame.from_catalog(
    database=dbname,
    table_name=tablename,
    transformation_ctx="datasource0",
    push_down_predicate="day>=10 and customer_id like '10%'",
    additional_options={"catalogPartitionPredicate":"year='2021' and month='06'"}
)
```

Scala:

```
val dynamicFrame = glueContext.getCatalogSource(
    database = dbname,
    tableName = tablename,
    transformationContext = "datasource0",
    pushDownPredicate="day>=10 and customer_id like '10%'",
    additionalOptions = JsonOptions("""{
        "catalogPartitionPredicate": "year='2021' and month='06'"}""")
    ).getDynamicFrame()
```

> **Note**
>
> `push_down_predicate` y `catalogPartitionPredicate` utilizan sintaxis diferentes. El primero utiliza la sintaxis estándar de Spark SQL y el segundo utiliza el analizador JSQL.

Escritura de particiones

De forma predeterminada, un objeto DynamicFrame no se particiona cuando se escribe. Todos los archivos de salida se escriben en el nivel superior de la ruta de salida especificada. Hasta hace poco tiempo, la única forma de escribir un objeto DynamicFrame en particiones era convertirlo en un objeto DataFrame de Spark SQL antes de la escritura.

Sin embargo, los objetos DynamicFrame ahora admiten la partición nativa mediante una secuencia de claves, utilizando la opción `partitionKeys` al crear un receptor. Por ejemplo, el siguiente código Python escribe un conjunto de datos en Amazon S3 en formato Parquet, en directorios particionados por el tipo de campo. Desde ahí puede procesar estas particiones con otros sistemas, como Amazon Athena.

```
glue_context.write_dynamic_frame.from_options(
```

```
    frame = projectedEvents,
    connection_type = "s3",
    connection_options = {"path": "$outpath", "partitionKeys": ["type"]},
    format = "parquet")
```

Lectura de archivos de entrada en grupos más grandes

Puede configurar propiedades de las tablas para habilitar que un trabajo de ETL de AWS Glue agrupe archivos cuando se leen desde un almacén de datos de Amazon S3. Estas propiedades permiten que cada tarea de ETL lea un grupo de archivos de entrada en una sola partición en memoria. Esto es especialmente útil cuando hay una gran cantidad de archivos pequeños en el almacén de datos de Amazon S3. Cuando configura determinadas propiedades, le indica a AWS Glue que agrupe los archivos en una partición de datos de Amazon S3 y configura el tamaño de los grupos que se leerán. También puede establecer estas opciones al leer desde un almacén de datos de Amazon S3 con el método `create_dynamic_frame.from_options`.

Para habilitar la agrupación de archivos para una tabla, establezca los pares clave-valor y en el campo de parámetros de la estructura de tabla. Utilice la notación JSON para establecer un valor del campo de parámetros de la tabla. Para obtener más información acerca de la edición de las propiedades de una tabla, consulte Visualización y administración de los detalles de la tabla.

Puede utilizar este método para habilitar la agrupación de tablas en Data Catalog con almacenes de datos de Amazon S3.

groupFiles

Establezca groupFiles (agrupar archivos) en `inPartition` para habilitar la agrupación de archivos en una partición de datos de Amazon S3. AWS Glue habilita automáticamente la agrupación si hay más de 50 000 archivos de entrada, como en el ejemplo siguiente.

```
'groupFiles': 'inPartition'
```

groupSize

Establezca groupSize en tamaño de destino de los grupos en bytes. La propiedad groupSize es opcional; si no se proporciona, AWS Glue calcula un tamaño para utilizar todos los núcleos de CPU del clúster a la vez que reduce el número total de tareas de ETL y particiones en memoria.

Por ejemplo, la entrada siguiente establece el tamaño del grupo en 1 MB.

```
'groupSize': '1048576'
```

Tenga en cuenta que `groupsize` se debe establecer con el resultado de un cálculo. Por ejemplo, 1024 * 1024 = 1048576.

recurse

Configure recurse en `True` para que lea de forma recursiva los archivos en todos los subdirectorios cuando especifique `paths` como una matriz de rutas. No es necesario configurar acción recursiva si `paths` es una matriz de claves de objeto en Amazon S3, o si el formato de entrada es parquet/orc, como en el siguiente ejemplo.

```
'recurse':True
```

Si va a leer de Amazon S3 directamente con el método `create_dynamic_frame.from_options`, agregue estas opciones de conexión. Por ejemplo, el siguiente código intenta agrupar los archivos en grupos de 1 MB.

```
df = glueContext.create_dynamic_frame.from_options("s3", {'paths': ["s3://s3path/"],
 'recurse':True, 'groupFiles': 'inPartition', 'groupSize': '1048576'}, format="json")
```

> **Note**
>
> `groupFiles` es compatible con los objetos DynamicFrames creados a partir de los siguientes formatos de datos: csv, ion, GrokLog, json y xml. Esta opción no es compatible con avro, parquet y orc.

Puntos de enlace de Amazon VPC para Amazon S3

Por razones de seguridad, muchos clientes de AWS ejecutan sus aplicaciones dentro de un entorno de Amazon Virtual Private Cloud (Amazon VPC). Con Amazon VPC, puede lanzar instancias de

Amazon EC2 en una nube virtual privada que está aislada de forma lógica de otras redes, incluida la red pública de Internet. Con una Amazon VPC, puede controlar el rango de direcciones IP, las subredes, las tablas de enrutamiento, las gateways de red y los ajustes de seguridad.

> **Note**
>
> Si ha creado su cuenta de AWS después del 04/12/2013, ya dispone de una VPC predeterminada en cada región de AWS. Puede comenzar a utilizar inmediatamente su VPC predeterminada sin necesidad de realizar ningún ajuste adicional.
> Para obtener más información, consulte Su VPC y subredes predeterminadas en la Guía del usuario de Amazon VPC.

A muchos clientes les preocupa con razón la privacidad y la seguridad en el envío y recepción de datos a través de la red pública de Internet. Los clientes pueden abordar estas inquietudes con el uso de una red privada virtual (VPN) para dirigir todo el tráfico de la red de Amazon S3 a través de su propia infraestructura de red corporativa. Sin embargo, este enfoque puede conllevar problemas de ancho de banda y disponibilidad.

Estos problemas se pueden solucionar con puntos de enlace de la VPC para Amazon S3. Un punto de enlace de la VPC para Amazon S3 permite a AWS Glue utilizar direcciones IP privadas para obtener acceso a Amazon S3 sin exponerse en la red pública de Internet. AWS Glue no necesita direcciones IP públicas y el usuario no necesita una gateway de Internet, un dispositivo NAT o una gateway privada virtual en su VPC. Para controlar el acceso a Amazon S3 se utilizan políticas de punto de enlace. El tráfico entre su VPC y el servicio AWS no sale de la red de Amazon.

Cuando crea un punto de enlace de la VPC para Amazon S3, todas las solicitudes a un punto de enlace de Amazon S3 dentro de la región (por ejemplo, s3.us-west-2.amazonaws.com) se dirigen a un punto de enlace de Amazon S3 privado dentro de la red de Amazon. No necesita modificar las aplicaciones que se ejecutan en instancias de Amazon EC2 de su VPC: el nombre del punto de enlace sigue siendo el mismo, pero la ruta a Amazon S3 permanece por completo dentro de la red de Amazon y no tiene acceso a la red pública de Internet.

Para obtener más información, consulte Puntos de enlace de la VPC en la Guía del usuario de Amazon VPC.

En el siguiente diagrama se muestra cómo AWS Glue utiliza un punto de enlace de la VPC para obtener acceso a Amazon S3.

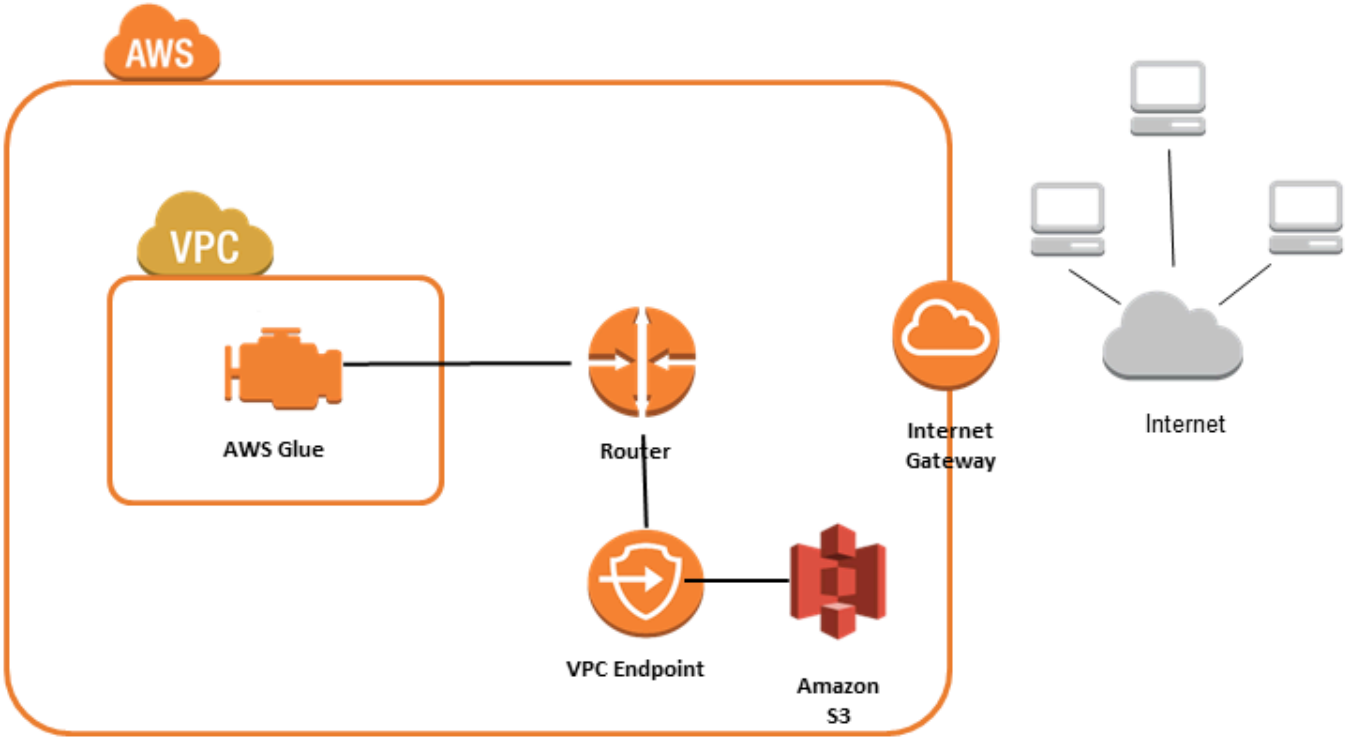

Para configurar el acceso a Amazon S3

1. Inicie sesión en la Consola de administración de AWS y abra la consola de Amazon VPC en https://console.aws.amazon.com/vpc/.
2. En el panel de navegación izquierdo, seleccione Puntos de conexión.
3. Elija Create Endpoint (Crear punto de enlace) y siga los pasos para crear un punto de enlace de Amazon S3 en la VPC de tipo gateway.

Conexiones a Amazon DocumentDB

Puede utilizar AWS Glue para Spark para leer y escribir en tablas en bases de datos de Amazon DocumentDB. Puede conectar Amazon DocumentDB con las credenciales almacenadas en AWS Secrets Manager a través de una conexión de AWS Glue.

Para obtener más información sobre Amazon DocumentDB, consulte la documentación de Amazon DocumentDB.

> **Note**
>
> Los clústeres elásticos de Amazon DocumentDB no se admiten actualmente cuando se utiliza el conector Glue AWS. Para obtener más información sobre los clústeres elásticos, consulte Uso de clústeres elásticos de Amazon DocumentDB.

Lectura y escritura en las colecciones de Amazon DocumentDB

> **Note**
>
> Cuando crea un trabajo de ETL que se conecta a Amazon DocumentDB, para la propiedad del trabajo `Connections`, debe designar un objeto de conexión que especifique la nube privada virtual (VPC) en la que se ejecuta Amazon DocumentDB. Para el objeto de conexión, el tipo de conexión debe ser `JDBC` y el `JDBC URL` debe ser `mongo://<DocumentDB_host>:27017`.

> **Note**
>
> Estos ejemplos de código fueron desarrollados para AWS Glue 3.0. Para migrar a AWS Glue 4.0, consulte the section called “MongoDB”. El parámetro `uri` ha cambiado.

> **Note**
>
> Cuando se utiliza Amazon DocumentDB, `retryWrites` debe configurarse en falso en determinadas situaciones, como cuando el documento escrito lo especifica `_id`. Para obtener más información, consulte Diferencias funcionales con MongoDB en la documentación de Amazon DocumentDB.

El siguiente script de Python muestra el uso de tipos de conexión y opciones de conexión para leer y escribir en Amazon DocumentDB.

```
import sys
from awsglue.transforms import *
from awsglue.utils import getResolvedOptions
from pyspark.context import SparkContext, SparkConf
from awsglue.context import GlueContext
from awsglue.job import Job
import time

## @params: [JOB_NAME]
args = getResolvedOptions(sys.argv, ['JOB_NAME'])

sc = SparkContext()
glueContext = GlueContext(sc)
spark = glueContext.spark_session

job = Job(glueContext)
job.init(args['JOB_NAME'], args)

output_path = "s3://some_bucket/output/" + str(time.time()) + "/"
documentdb_uri = "mongodb://<mongo-instanced-ip-address>:27017"
documentdb_write_uri = "mongodb://<mongo-instanced-ip-address>:27017"

read_docdb_options = {
    "uri": documentdb_uri,
    "database": "test",
    "collection": "coll",
    "username": "username",
    "password": "1234567890",
    "ssl": "true",
    "ssl.domain_match": "false",
    "partitioner": "MongoSamplePartitioner",
    "partitionerOptions.partitionSizeMB": "10",
    "partitionerOptions.partitionKey": "_id"
}

write_documentdb_options = {
    "retryWrites": "false",
    "uri": documentdb_write_uri,
    "database": "test",
    "collection": "coll",
    "username": "username",
    "password": "pwd"
}
```

```
# Get DynamicFrame from  DocumentDB
dynamic_frame2 =
 glueContext.create_dynamic_frame.from_options(connection_type="documentdb",

 connection_options=read_docdb_options)

# Write DynamicFrame to MongoDB and DocumentDB
glueContext.write_dynamic_frame.from_options(dynamic_frame2,
 connection_type="documentdb",

 connection_options=write_documentdb_options)

job.commit()
```

El siguiente script de Scala muestra el uso de tipos de conexión y opciones de conexión para leer y escribir en Amazon DocumentDB.

```
import com.amazonaws.services.glue.GlueContext
import com.amazonaws.services.glue.MappingSpec
import com.amazonaws.services.glue.errors.CallSite
import com.amazonaws.services.glue.util.GlueArgParser
import com.amazonaws.services.glue.util.Job
import com.amazonaws.services.glue.util.JsonOptions
import com.amazonaws.services.glue.DynamicFrame
import org.apache.spark.SparkContext
import scala.collection.JavaConverters._

object GlueApp {
  val DOC_URI: String = "mongodb://<mongo-instanced-ip-address>:27017"
  val DOC_WRITE_URI: String = "mongodb://<mongo-instanced-ip-address>:27017"
  lazy val documentDBJsonOption = jsonOptions(DOC_URI)
  lazy val writeDocumentDBJsonOption = jsonOptions(DOC_WRITE_URI)
  def main(sysArgs: Array[String]): Unit = {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)
    val args = GlueArgParser.getResolvedOptions(sysArgs, Seq("JOB_NAME").toArray)
    Job.init(args("JOB_NAME"), glueContext, args.asJava)

    // Get DynamicFrame from DocumentDB
    val resultFrame2: DynamicFrame = glueContext.getSource("documentdb",
 documentDBJsonOption).getDynamicFrame()
```

```
    // Write DynamicFrame to DocumentDB
    glueContext.getSink("documentdb", writeJsonOption).writeDynamicFrame(resultFrame2)

    Job.commit()
  }

  private def jsonOptions(uri: String): JsonOptions = {
    new JsonOptions(
      s"""{"uri": "${uri}",
         |"database":"test",
         |"collection":"coll",
         |"username": "username",
         |"password": "pwd",
         |"ssl":"true",
         |"ssl.domain_match":"false",
         |"partitioner": "MongoSamplePartitioner",
         |"partitionerOptions.partitionSizeMB": "10",
         |"partitionerOptions.partitionKey": "_id"}""".stripMargin)
  }
}
```

Referencia de opción de conexión de Amazon DocumentDB

Designa una conexión a Amazon DocumentDB (con compatibilidad con MongoDB).

Las opciones de conexión son distintas entre una conexión de origen y una conexión de receptor.

"connectionType": "Documentdb" como origen

Utilice las siguientes opciones de conexión con `"connectionType": "documentdb"` como origen:

- `"uri"`: (obligatorio) el host de Amazon DocumentDB del que se va a leer, con formato `mongodb://<host>:<port>`.
- `"database"`: (obligatorio) la base de datos de Amazon DocumentDB de la que se va a leer.
- `"collection"`: (obligatorio) la recopilación de Amazon DocumentDB de la que se va a leer.
- `"username"`: (obligatorio) nombre de usuario de Amazon DocumentDB.
- `"password"`: (obligatorio) la contraseña de Amazon DocumentDB.
- `"ssl"`: (obligatorio si usa SSL) si su conexión usa SSL, debe incluir esta opción con el valor `"true"`.

- `"ssl.domain_match"`: (obligatorio si usa SSL) si su conexión usa SSL, debe incluir esta opción con el valor `"false"`.
- `"batchSize"`: (opcional): el número de documentos que se deben devolver por lote, que se utilizan dentro del cursor de lotes internos.
- `"partitioner"`: (opcional): el nombre de la clase del particionador para leer los datos de entrada de Amazon DocumentDB. El conector proporciona los siguientes particionadores:
  - `MongoDefaultPartitioner` (predeterminado) (No compatible con AWS Glue 4.0)
  - `MongoSamplePartitioner` (No es compatible con AWS Glue 4.0)
  - `MongoShardedPartitioner`
  - `MongoSplitVectorPartitioner`
  - `MongoPaginateByCountPartitioner`
  - `MongoPaginateBySizePartitioner` (No es compatible con AWS Glue 4.0)
- `"partitionerOptions"` (opcional): opciones para el particionador designado. Se admiten las siguientes opciones para cada particionador:
  - `MongoSamplePartitioner`: `partitionKey`, `partitionSizeMB`, `samplesPerPartition`
  - `MongoShardedPartitioner`: `shardkey`
  - `MongoSplitVectorPartitioner`: `partitionKey`, partitionSizeMB
  - `MongoPaginateByCountPartitioner`: `partitionKey`, `numberOfPartitions`
  - `MongoPaginateBySizePartitioner`: `partitionKey`, partitionSizeMB

  Para obtener más información acerca de estas opciones, consulte Partitioner Configuration en la documentación de MongoDB.

"connectionType": "Documentdb" como receptor

Utilice las siguientes opciones de conexión con `"connectionType": "documentdb"` como receptor:

- `"uri"`: (obligatorio) el host de Amazon DocumentDB al que se va a escribir, con formato `mongodb://<host>:<port>`.
- `"database"`: (obligatorio) la base de datos de Amazon DocumentDB a la que se va a escribir.
- `"collection"`: (obligatorio) la recopilación de Amazon DocumentDB a la que se va a escribir.
- `"username"`: (obligatorio) nombre de usuario de Amazon DocumentDB.

- `"password"`: (obligatorio) la contraseña de Amazon DocumentDB.
- `"extendedBsonTypes"`: (opcional) si se establece en `true`, permite los tipos de BSON extendidos al escribir datos en Amazon DocumentDB. El valor predeterminado es `true`.
- `"replaceDocument"`: (opcional) si es `true`, reemplaza todo el documento al guardar conjuntos de datos que contienen un campo `_id`. Si es `false`, solo se actualizan los campos del documento que coinciden con los campos del conjunto de datos. El valor predeterminado es `true`.
- `"maxBatchSize"`: (opcional): el tamaño máximo del lote para operaciones en bloque al guardar datos. El valor predeterminado es 512.
- `"retryWrites"`: (Opcional): reintenta automáticamente determinadas operaciones de escritura una sola vez si AWS Glue detecta un error de red.

Conexiones de OpenSearch Service

Puede usar AWS Glue for Spark para leer y escribir en tablas de OpenSearch Service en AWS Glue 4.0 y versiones posteriores. Puede definir qué leer del servicio OpenSearch con una consulta de OpenSearch. Se conecta a OpenSearch Service mediante credenciales de autenticación básica HTTP almacenadas AWS Secrets Manager a través de una conexión de AWS Glue. Esta característica no es compatible con OpenSearch Service sin servidor.

Para obtener más información acerca de Amazon OpenSearch Service, consulte la documentación de Amazon OpenSearch Service.

Configurar conexiones de OpenSearch Service

Para conectarse a OpenSearch Service desde AWS Glue, deberá crear y almacenar sus credenciales de OpenSearch Service en un AWS Secrets Manager secreto y, a continuación, asociar ese secreto a una conexión OpenSearch Service AWS Glue.

Requisitos previos:

- Identifique el punto de conexión del dominio, el *`AOSEndpoint`* y el puerto, *`AOSport`* desde el que desea leer o cree el recurso siguiendo las instrucciones de la documentación de Amazon OpenSearch Service. Para obtener más información sobre la creación de un dominio, consulte Crear y administrar dominios de Amazon OpenSearch Service en la documentación de Amazon OpenSearch Service.

  Un punto de conexión de dominio de Amazon OpenSearch Service tendrá el siguiente formulario predeterminado: https://

search-*domainName*-*unstructuredIdContent*.*region*.es.amazonaws.com. Para obtener más información sobre cómo identificar su punto de conexión de dominio, consulte Crear y administrar dominios de Amazon OpenSearch Service en la documentación de Amazon OpenSearch Service.

Identifique o genere credenciales de autenticación básica HTTP, *aosUser* y *aosPassword* para su dominio.

Para configurar una conexión a OpenSearch Service:

1. En AWS Secrets Manager, cree un secreto con sus credenciales de OpenSearch Service. Para crear un secreto en Secrets Manager, siga el tutorial disponible en Crear un secreto AWS Secrets Manager en la documentación AWS Secrets Manager. Después de crear el secreto, conserve el nombre secreto, *secretName*, para el siguiente paso.
   - Al seleccionar pares clave/valor, genere un par para la clave `USERNAME` con el valor *aosUser*.
   - Al seleccionar pares clave/valor, genere un par para la clave `PASSWORD` con el valor *aosPassword*.
2. En la consola de AWS Glue, genere una conexión mediante los pasos que se indican en the section called “Adición de una conexión de AWS Glue”. Tras crear la conexión, conserve el nombre de la conexión, *connectionName*, para el uso futuro en AWS Glue.
   - Al seleccionar un tipo de conexión, seleccione OpenSearch Service.
   - Al seleccionar un punto de conexión de dominio, proporcione *aosEndpoint*.
   - Al seleccionar un puerto, proporcione *aosPort*.
   - Al seleccionar un secreto AWS, proporcione un *secretName*.

Tras crear una conexión AWS Glue OpenSearch Service, deberá realizar los siguientes pasos antes de ejecutar su trabajo de AWS Glue:

- Otorgue al rol de IAM asociado al permiso de su trabajo de AWS Glue para leer *secretName*.
- En la configuración del trabajo de Glue AWS, proporcione *connectionName* como una conexión de red adicional.

Lectura de los índices de OpenSearch Service

Requisitos previos:

- Un índice de OpenSearch Service del que quiera leer, *aosIndex*.
- Una conexión de AWS Glue OpenSearch Service configurada para proporcionar información de autenticación y ubicación de red. Para obtenerla, complete los pasos del procedimiento anterior, para configurar una conexión al servicio OpenSearch. Necesitará el nombre de la conexión de AWS Glue, *connectionName*.

En este ejemplo se lee un índice de Amazon OpenSearch Service. Deberá proporcionar el parámetro `pushdown`.

Por ejemplo:

```
opensearch_read = glueContext.create_dynamic_frame.from_options(
    connection_type="opensearch",
    connection_options={
        "connectionName": "connectionName",
        "opensearch.resource": "aosIndex",
        "pushdown": "true",
    }
)
```

También puede proporcionar una cadena de consultas para filtrar los resultados devueltos a su DynamicFrame. Deberá configurar `opensearch.query`.

`opensearch.query` puede tomar una cadena de parámetros de consulta de URL *queryString* o un objeto DSL JSON de consulta *queryObject*. Para obtener más información sobre la consulta DSL, consulte Query DSL en la documentación de OpenSearch. Para proporcionar una cadena de parámetros de consulta de URL, anteponga `?q=` a la consulta, tal y como lo haría en una URL completa. Para proporcionar un objeto DSL de consulta, coloque la cadena escape del objeto JSON antes de proporcionarlo.

Por ejemplo:

```
            queryObject = "{ "query": { "multi_match": { "query": "Sample", "fields":
[ "sample" ] } } }"
            queryString = "?q=queryString"

            opensearch_read_query = glueContext.create_dynamic_frame.from_options(
    connection_type="opensearch",
    connection_options={
```

```
        "connectionName": "connectionName",
        "opensearch.resource": "aosIndex",
        "opensearch.query": queryString,
        "pushdown": "true",
    }
)
```

Para obtener más información sobre cómo crear una consulta fuera de su sintaxis específica, consulte Sintaxis de cadenas de consulta en la documentación de OpenSearch.

Al leer colecciones de OpenSearch que contengan datos de tipo matriz, debe especificar qué campos son de tipo matriz en la llamada al método mediante el parámetro `opensearch.read.field.as.array.include`.

Por ejemplo, al leer el siguiente documento, encontrará los campos de matriz `genre` y `actor`:

```
{
    "_index": "movies",
    "_id": "2",
    "_version": 1,
    "_seq_no": 0,
    "_primary_term": 1,
    "found": true,
    "_source": {
        "director": "Frankenheimer, John",
        "genre": [
            "Drama",
            "Mystery",
            "Thriller",
            "Crime"
        ],
        "year": 1962,
        "actor": [
            "Lansbury, Angela",
            "Sinatra, Frank",
            "Leigh, Janet",
            "Harvey, Laurence",
            "Silva, Henry",
            "Frees, Paul",
            "Gregory, James",
            "Bissell, Whit",
            "McGiver, John",
            "Parrish, Leslie",
```

```
            "Edwards, James",
            "Flowers, Bess",
            "Dhiegh, Khigh",
            "Payne, Julie",
            "Kleeb, Helen",
            "Gray, Joe",
            "Nalder, Reggie",
            "Stevens, Bert",
            "Masters, Michael",
            "Lowell, Tom"
        ],
        "title": "The Manchurian Candidate"
    }
}
```

En este caso, debería incluir esos nombres de campo en su llamada al método. Por ejemplo:

```
"opensearch.read.field.as.array.include": "genre,actor"
```

Si el campo de matriz está anidado dentro de la estructura del documento, consúltelo mediante la notación de puntos: `"genre,actor,foo.bar.baz"`. Esto especificaría una matriz `baz` incluida en el documento fuente a través del documento incrustado `foo`, que contiene el documento `bar` incrustado.

Escribir en tablas de OpenSearch Service

En este ejemplo, se escribe información de un DynamicFrame existente, *`dynamicFrame`* en OpenSearch Service. Si el índice ya contiene información, AWS Glue agregará los datos de su DynamicFrame. Deberá proporcionar el parámetro `pushdown`.

Requisitos previos:

- Una tabla de OpenSearch Service a la que desearía escribir. Necesitará información de la identificación para la tabla. Llamemos a esto *`tableName`*.
- Una conexión de AWS Glue OpenSearch Service configurada para proporcionar información de autenticación y ubicación de red. Para obtenerla, complete los pasos del procedimiento anterior, para configurar una conexión al servicio OpenSearch. Necesitará el nombre de la conexión de AWS Glue, *`connectionName`*.

Por ejemplo:

```
glueContext.write_dynamic_frame.from_options(
    frame=dynamicFrame,
    connection_type="opensearch",
    connection_options={
      "connectionName": "connectionName",
      "opensearch.resource": "aosIndex",
    },
)
```

Referencia de opciones de conexión de OpenSearch Service

- `connectionName`: obligatorio. Se utiliza para lectura/escritura. El nombre de una conexión de AWS Glue OpenSearch Service configurada para proporcionar información de autenticación y ubicación de red a su método de conexión.
- `opensearch.resource`: obligatorio. Se utiliza para lectura/escritura. Valores válidos: nombres de índice de OpenSearch. El nombre del índice con el que interactuará su método de conexión.
- `opensearch.query`: se utiliza para leer. Valores válidos: cadena JSON escapada o, si esta cadena comienza con `?`, la parte de búsqueda de una URL. Una consulta de OpenSearch que filtra lo que se debe recuperar al leerlo. Para obtener más información sobre el uso de este parámetro, consulte la sección the section called “Lea de OpenSearch Service” anterior.
- `pushdown`: obligatorio si. Se usa para leer. Valores válidos: booleano. Indica a Spark que pase las consultas de lectura a OpenSearch para que la base de datos solo devuelva los documentos relevantes.
- `opensearch.read.field.as.array.include`: necesario si se leen datos de tipo matriz. Se usa para leer. Valores válidos: listas de nombres de campos separados por comas. Especifica los campos que se van a leer como matrices de los documentos de OpenSearch. Para obtener más información sobre el uso de este parámetro, consulte la sección anterior the section called “Lea de OpenSearch Service”.

Conexiones Redshift

Puede usar Glue for Spark AWS para leer y escribir en tablas en bases de datos de Amazon Redshift. Al conectarse a las bases de datos de Amazon Redshift, Glue AWS mueve los datos a través de Amazon S3 para lograr el máximo rendimiento mediante el SQL y los comandos de Amazon Redshift `COPY` y `UNLOAD`. En Glue 4.0 AWS y versiones posteriores, puede utilizar la integración de Amazon Redshift para Apache Spark para leer y escribir con optimizaciones y

funciones específicas de Amazon Redshift además de las disponibles al conectarse a través de versiones anteriores.

Descubra cómo Glue AWS facilita más que nunca a los usuarios de Amazon Redshift la migración a Glue AWS para la integración de datos sin servidor y la ETL.

Configuración de las conexiones de Redshift

Para utilizar los clústeres de Amazon Redshift en Glue AWS, necesitará algunos requisitos previos:

- Un directorio de Amazon S3 para utilizar como almacenamiento temporario al leer y escribir en la base de datos.
- Una Amazon VPC que habilita la comunicación entre su clúster de Amazon Redshift, su trabajo de AWS Glue y su directorio de Amazon S3.
- Permisos de IAM adecuados en el trabajo de Glue AWS y el clúster de Amazon Redshift.

Configuración de roles de IAM

Configurar la función para el clúster de Amazon Redshift

Su clúster de Amazon Redshift debe poder leer y escribir en Amazon S3 para poder integrarse con los trabajos de Glue AWS. Para ello, puede asociar los roles de IAM al clúster de Amazon Redshift al que desee conectarse. Su función debe tener una política que permita leer y escribir en su directorio temporario de Amazon S3. Su función debe tener una relación de confianza que permita al `redshift.amazonaws.com`servicio hacerlo`AssumeRole`.

Para asociar un rol de IAM a Amazon Redshift

1. Requisitos previos: un bucket o directorio de Amazon S3 utilizado para el almacenamiento temporario de archivos.
2. Identifique qué permisos de Amazon S3 necesitará su clúster de Amazon Redshift. Al mover datos a un clúster de Amazon Redshift y desde este, los trabajos de Glue AWS emiten instrucciones de COPIAR y DESCARGAR para Amazon Redshift. Si su trabajo modifica una tabla en Amazon Redshift, Glue AWS también emitirá instrucciones de CREAR BIBLIOTECA. Para obtener información sobre los permisos específicos de Amazon S3 necesarios para que Amazon Redshift ejecute estas instrucciones, consulte la documentación de Amazon Redshift: Amazon Redshift: permisos para acceder a otros recursos AWS.
3. En la consola de IAM, cree una política de IAM con los permisos necesarios. Para obtener más información sobre cómo crear una política de IAM, consulte Creación de políticas de IAM.

4. En la consola de IAM, cree un rol y una relación de confianza que permita a Amazon Redshift asumir el rol. Siga las instrucciones de la documentación de IAM para crear un rol para un servicio AWS (consola)

   - Cuando se pida que elija un caso de uso del servicio AWS, elija “Redshift: personalizable”.
   - Cuando se pida que adjunte una política, elija la política que definió previamente.

   > **Note**
   >
   > Para obtener más información sobre la configuración de funciones para Amazon Redshift, consulte Autorizar a Amazon Redshift para acceder a otros servicios AWS en su nombre en la documentación de Amazon Redshift.

5. En la consola de Amazon Redshift, asocie la función a su clúster de Amazon Redshift. Siga las instrucciones de la documentación de Amazon Redshift.

   Seleccione la opción resaltada en la consola de Amazon Redshift para configurar este ajuste:

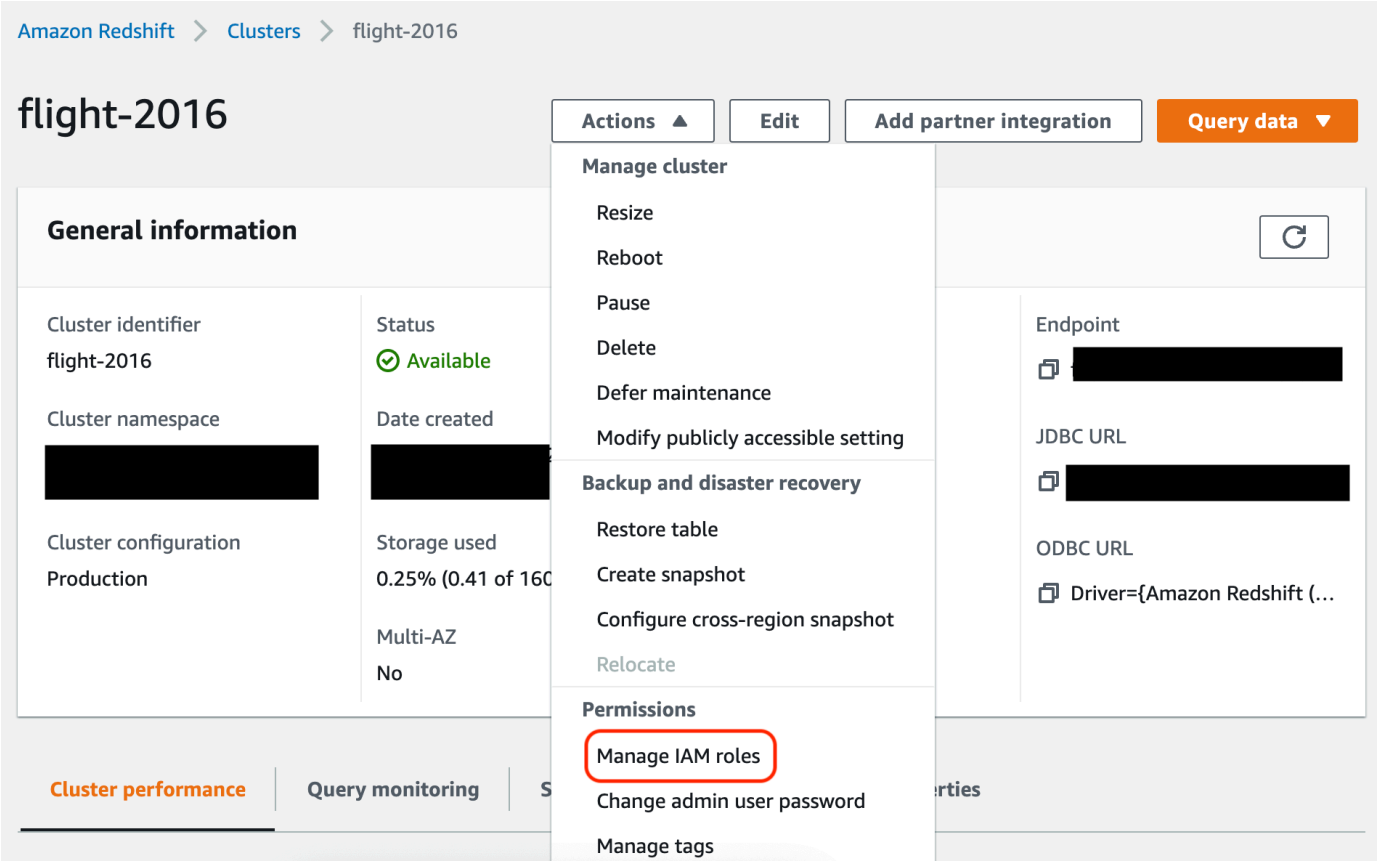

> **Note**
>
> De forma predeterminada, los trabajos de Glue AWS transfieren credenciales temporarias a Amazon Redshift creadas mediante el rol que especificó para ejecutar el trabajo. No recomendamos utilizar estas credenciales. Por motivos de seguridad, estas credenciales caducan después de 1 hora.

Configure el rol para el trabajo de Glue AWS

El trabajo de Glue AWS necesita un rol para acceder al bucket de Amazon S3. No necesita permisos de IAM para el clúster de Amazon Redshift, su acceso se controla mediante la conectividad de Amazon VPC y las credenciales de su base de datos.

Configuración de Amazon VPC

Para configurar el acceso a almacenes de datos de Amazon Redshift

1. Inicie sesión en la Consola de administración de AWS y abra la consola de Amazon Redshift en https://console.aws.amazon.com/redshiftv2/.
2. En el panel de navegación izquierdo, elija Clusters (Clústeres).
3. Seleccione el nombre de clúster al que desee obtener acceso desde AWS Glue.
4. En la sección Cluster Properties (Propiedades del clúster), elija un grupo de seguridad en VPC security groups (Grupos de seguridad de la VPC) para permitir a AWS Glue utilizarlo. Registre el nombre del grupo de seguridad que ha elegido para futuras referencias. Al elegir el grupo de seguridad se abrirá la lista de Security Groups (Grupos de seguridad) de la consola de Amazon EC2.
5. Elija el grupo de seguridad para modificar e ir a la pestaña Inbound (Entrada).
6. Añada una regla con autorreferencia para que los componentes de AWS Glue puedan comunicarse. En concreto, añada o confirme que hay una regla con Type (Tipo) `All TCP`, Protocol (Protocolo) `TCP`, Port Range (Intervalo de puertos) con todos los puertos y el Source (Origen) con el mismo nombre de grupo de seguridad que Group ID (ID de grupo).

   La regla de entrada tiene un aspecto similar al siguiente:

Tipo	Protocolo	Intervalo de puertos	Origen
Todos los TCP	TCP	0–65535	grupo_seguridad_base_de_datos

Por ejemplo:

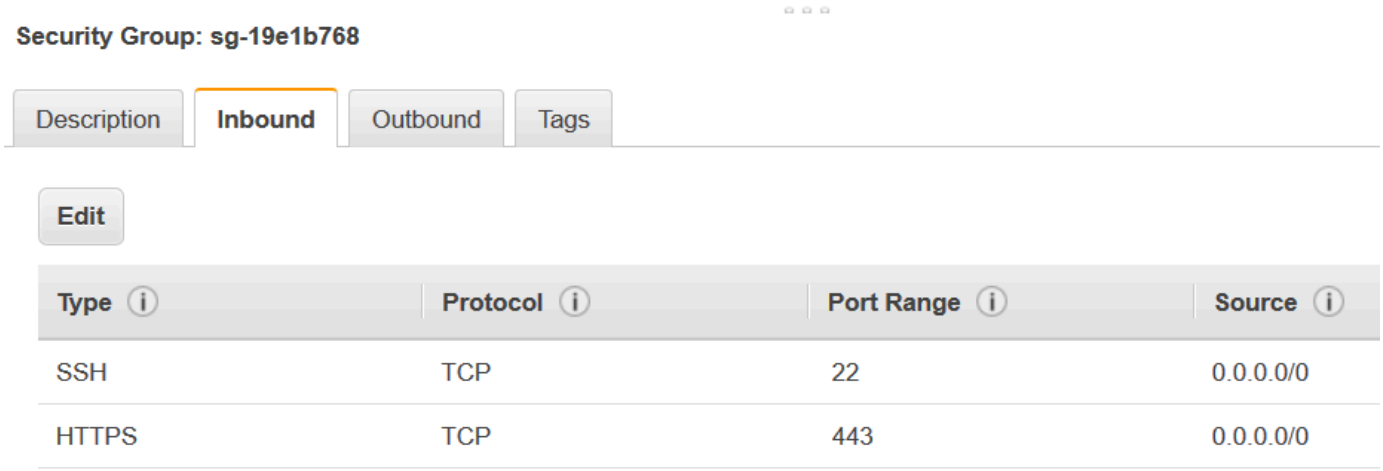

7. Añada también una regla para el tráfico saliente. Puede abrir el tráfico saliente con destino a todos los puertos, por ejemplo:

Tipo	Protocolo	Rango de puerto	Destino
All Traffic	ALL	ALL	0.0.0.0/0

O bien, crear una regla con autorreferencia en la que Type (Tipo) sea `All TCP`, Protocol (Protocolo) sea `TCP`, Port Range (Intervalo de puertos) incluya todos los puertos y Destination (Destino) sea el mismo nombre de grupo de seguridad que Group ID (ID de grupo). En caso de que se utilice un punto de conexión de VPC de Amazon S3, agregue también una regla HTTPS para el acceso de Amazon S3. Se requiere *`s3-prefix-list-id`* en la regla del grupo de seguridad para permitir el tráfico desde la VPC al punto de conexión de VPC de Amazon S3.

Por ejemplo:

Tipo	Protocolo	Rango de puerto	Destino
Todos los TCP	TCP	0–65535	*security-group*
HTTPS	TCP	443	*s3-prefix-list-id*

Configurar Glue AWS

Deberá crear una conexión al Catálogo de datos de AWS Glue que proporcione información de conexión de Amazon VPC.

Para configurar la conectividad de Amazon VPC de Amazon Redshift con AWS Glue en la consola

1. Cree una conexión al catálogo de datos mediante los pasos que se indican en: the section called "Adición de una conexión de AWS Glue". Tras crear la conexión, conserve el nombre de la conexión, *connectionName*, para el siguiente paso.

   - Al seleccionar un tipo de conexión, seleccione Amazon Redshift.
   - Al seleccionar un clúster de Redshift, seleccione el clúster por su nombre.
   - Proporcione la información de conexión predeterminada para un usuario de Amazon Redshift en su clúster.
   - La configuración de Amazon VPC se configurará automáticamente.

   > **Note**
   >
   > Deberá proporcionar manualmente `PhysicalConnectionRequirements` a su Amazon VPC al crear una conexión de Amazon Redshift a través del AWS SDK.

2. En la configuración del trabajo de Glue AWS, proporcione *connectionName* como una conexión de red adicional.

Ejemplo: lectura de tablas de Amazon Redshift

Puede leer los clústeres desde Amazon Redshift y los entornos de Amazon Redshift sin servidor.

Requisitos previos: una tabla de Amazon Redshift de la que quiera leer. Siga los pasos de la sección anterior the section called “Configurar Redshift” después de los cuales debe tener el URI de Amazon S3 para un directorio temporario, *temp-s3-dir* y un rol de IAM, *rs-role-name* (en la *cuenta role-account-id*).

Using the Data Catalog

Requisitos previos adicionales: una base de datos del catálogo de datos y una tabla para la tabla de Amazon Redshift de la que desee leer. Para obtener más información sobre las tablas de catálogo, consulte Detección y catalogación de datos. Tras crear una entrada para su tabla de Amazon Redshift, identificará su conexión con un *redshift-dc-database-name* y un *redshift-table-name*.

Configuración: en las opciones de función, identificará la tabla del catálogo de datos con los parámetros `database` y `table_name`. Identificará su directorio temporario de Amazon S3 con `redshift_tmp_dir`. También proporcionará *rs-role-name* con la clave `aws_iam_role` del parámetro `additional_options`.

```
 glueContext.create_dynamic_frame.from_catalog(
    database = "redshift-dc-database-name",
    table_name = "redshift-table-name",
    redshift_tmp_dir = args["temp-s3-dir"],
    additional_options = {"aws_iam_role": "arn:aws:iam::role-account-id:role/rs-
role-name"})
```

Connecting directly

Requisitos previos adicionales: necesitará el nombre de su tabla de Amazon Redshift *redshift-table-name*. Necesitará la información de conexión JDBC para el clúster de Amazon Redshift que almacena esa tabla. Deberá proporcionar la información de conexión con el *host*, el *puerto*, *redshift-database-name*, el *nombre de usuario* y la *contraseña*.

Puede recuperar la información de conexión de la consola de Amazon Redshift cuando trabaje con clústeres de Amazon Redshift. Si utiliza Amazon Redshift sin servidor, consulte Conexión a Amazon Redshift sin servidor en la documentación de Amazon Redshift.

Configuración: en las opciones de función, identificará los parámetros de conexión con `url`, `dbtable`, `user` y `password`. Identificará su directorio temporario de Amazon S3 con

`redshift_tmp_dir`. Puede especificar su rol de IAM mediante la utilización de `aws_iam_role` cuando utiliza `from_options`. La sintaxis es similar a la de la conexión a través del catálogo de datos, pero los parámetros se colocan en el mapa `connection_options`.

Es una mala práctica codificar las contraseñas en los scripts de Glue AWS. Considere la posibilidad de almacenar sus contraseñas en AWS Secrets Manager y recuperarlas en su script con el SDK para Python (Boto3).

```
my_conn_options = {
    "url": "jdbc:redshift://host:port/redshift-database-name",
    "dbtable": "redshift-table-name",
    "user": "username",
    "password": "password",
    "redshiftTmpDir": args["temp-s3-dir"],
    "aws_iam_role": "arn:aws:iam::account id:role/rs-role-name"
}

df = glueContext.create_dynamic_frame.from_options("redshift", my_conn_options)
```

Ejemplo: escribir en tablas de Amazon Redshift

Puede leer los clústeres desde Amazon Redshift y los entornos de Amazon Redshift sin servidor.

Requisitos previos: Un clúster de Amazon Redshift y siga los pasos de la sección anterior the section called “Configurar Redshift” después de los cuales debe tener el URI de Amazon S3 para un directorio temporario, *`temp-s3-dir`* y un rol de IAM, *`rs-role-name`*, (en la cuenta *`role-account-id`*). También necesitará un `DynamicFrame` cuyos contenido desee escribir en la base de datos.

Using the Data Catalog

Requisitos previos adicionales: una base de datos del catálogo de datos para el clúster de Amazon Redshift y una tabla a la que desee escribir. Para obtener más información sobre las tablas de catálogo, consulte Detección y catalogación de datos. Identificará su conexión con *`redshift-dc-database-name`* y la tabla de destino con *`redshift-table-name.`*

Configuración: en las opciones de función, identificará su base de datos del catálogo de datos con el parámetro `database` y, a continuación, proporcionará la tabla con `table_name`. Identificará

su directorio temporario de Amazon S3 con `redshift_tmp_dir`. También proporcionará *rs-role-name* con la clave `aws_iam_role` del parámetro `additional_options`.

```
 glueContext.write_dynamic_frame.from_catalog(
    frame = input dynamic frame,
    database = "redshift-dc-database-name",
    table_name = "redshift-table-name",
    redshift_tmp_dir = args["temp-s3-dir"],
    additional_options = {"aws_iam_role": "arn:aws:iam::account-id:role/rs-role-name"})
```

Connecting through a AWS Glue connection

Puede conectarse a Amazon Redshift directamente mediante el uso del método `write_dynamic_frame.from_options`. Sin embargo, en lugar de insertar los detalles de la conexión directamente en el script, puede hacer referencia a los detalles de la conexión almacenados en una conexión del catálogo de datos con el método `from_jdbc_conf`. Puede hacerlo sin tener que rastrear ni crear tablas del catálogo de datos para la base de datos. Para obtener más información sobre las conexiones de catálogo, consulte Conexión a datos.

Requisitos previos adicionales: una conexión del catálogo de datos para su base de datos y una tabla de Amazon Redshift de la que desee leer.

Configuración: identificará su conexión al catálogo de datos con *dc-connection-name*. Identificará la base de datos y la tabla de Amazon Redshift con *redshift-table-name* y *redshift-database-name*. Deberá proporcionar la información de conexión del catálogo de datos con `catalog_connection` y la información de Amazon Redshift junto con `dbtable` y `database`. La sintaxis es similar a la de la conexión a través del catálogo de datos, pero los parámetros se colocan en el mapa `connection_options`.

```
my_conn_options = {
    "dbtable": "redshift-table-name",
    "database": "redshift-database-name",
    "aws_iam_role": "arn:aws:iam::role-account-id:role/rs-role-name"
}

glueContext.write_dynamic_frame.from_jdbc_conf(
    frame = input dynamic frame,
```

```
    catalog_connection = "dc-connection-name",
    connection_options = my_conn_options,
    redshift_tmp_dir = args["temp-s3-dir"])
```

Referencia de opción de conexión a Amazon Redshift

Las opciones de conexión básicas que se utilizan en todas las conexiones JDBC de Glue AWS para configurar información similar a `url`, `user` y `password` son consistentes con todos los tipos de JDBC. Para obtener más información acerca de los parámetros de JDBC, consulte the section called "Parámetros de conexión de JDBC".

El tipo de conexión Amazon Redshift requiere algunas opciones de conexión adicionales:

- `"redshiftTmpDir"`: (Obligatorio) La ruta de Amazon S3 donde se pueden almacenar datos temporarios al copiar desde la base de datos.
- `"aws_iam_role"`: (Opcional) ARN para un rol de IAM. La tarea de Glue AWS transferirá esta función al clúster de Amazon Redshift para conceder al clúster los permisos necesarios para completar las instrucciones del trabajo.

Opciones de conexión adicionales disponibles en Glue 4.0+ AWS

También puede transferir opciones para el nuevo conector Amazon Redshift a través de las opciones de conexión de Glue AWS. Para obtener una lista completa de las opciones de conectores compatibles, consulte la sección Spark SQL parameters (Parámetros de Spark SQL) en Amazon Redshift integration for Apache Spark (Integración de Amazon Redshift para Apache Spark).

Para su comodidad, aquí reiteramos algunas opciones nuevas:

Nombre	Obligatorio	Predeterminado	Descripción
autopushdown	No	TRUE	Aplica la delegación de predicados y consultas mediante la captura y el análisis de los planes lógicos de Spark

Nombre	Obligatorio	Predeterminado	Descripción
			para operaciones de SQL. Las operaciones se traducen en una consulta SQL y, a continuación, se ejecutan en Amazon Redshift para mejorar el rendimiento.
autopushdown.s3_result_cache	No	FALSO	Almacena en caché la consulta SQL para descargar datos de la asignación de rutas de Amazon S3 en la memoria, de modo que no sea necesario volver a ejecutar la misma consulta en la misma sesión de Spark. Solo se admite cuando la opción `autopushdown` está habilitada.
unload_s3_format	No	PARQUET	PARQUET: descarga los resultados de la consulta en formato Parquet. TEXT: descarga los resultados de la consulta en formato de texto delimitado por barras.

Nombre	Obligatorio	Predeterminado	Descripción
sse_kms_key	No	N/A	La clave de AWS SSE-KMS que se utilizará para el cifrado durante las operaciones `UNLOAD` en lugar del cifrado predeterminado de AWS.
extracopyoptions	No	N/A	Lista de opciones adicionales que se anexarán al comando `COPY` de Amazon Redshift al cargar datos, como `TRUNCATECOLUMNS` o `MAXERROR n` (consulte otras opciones en COPY: Optional parameters [COPY: parámetros opcionales]). Tenga en cuenta que, dado que estas opciones se anexan al final del comando `COPY`, solo se pueden usar las opciones que tengan sentido al final del comando. Eso debería abarcar la mayoría de los casos de uso posibles.

Nombre	Obligatorio	Predeterminado	Descripción
csvnullstring (experimental)	No	NULL	Valor de cadena que se escribirá para los valores nulos cuando se utiliza el valor de `tempformat` CSV. Debe ser un valor que no aparezca en los datos reales.

Estos nuevos parámetros se pueden utilizar de las siguientes maneras.

Nuevas opciones para mejorar el rendimiento

El nuevo conector presenta algunas opciones nuevas de mejora del rendimiento:

- `autopushdown`: habilitada de forma predeterminada.
- `autopushdown.s3_result_cache`: deshabilitada de forma predeterminada.
- `unload_s3_format`: `PARQUET` de forma predeterminada.

Para obtener información sobre el uso de estas opciones, consulte Amazon Redshift integration for Apache Spark (Integración de Amazon Redshift para Apache Spark). Le recomendamos que no active `autopushdown.s3_result_cache` cuando tenga operaciones de lectura y escritura mixtas, ya que los resultados almacenados en caché pueden contener información obsoleta. La opción `unload_s3_format` se define como `PARQUET` de forma predeterminada para el comando `UNLOAD` a fin de mejorar el rendimiento y reducir el costo de almacenamiento. Para utilizar el comportamiento predeterminado del comando `UNLOAD`, restablezca la opción a `TEXT`.

Nueva opción de cifrado para lectura

De forma predeterminada, los datos de la carpeta temporal que AWS Glue utiliza al leer datos de la tabla de Amazon Redshift se cifran mediante el cifrado `SSE-S3`. A fin de utilizar las claves administradas por el cliente de AWS Key Management Service (AWS KMS) para cifrar los datos, puede configurar `("sse_kms_key" # kmsKey)`, donde ksmKey es el ID de clave de AWS KMS, en lugar de la opción de configuración heredada `("extraunloadoptions" # s"ENCRYPTED KMS_KEY_ID '$kmsKey'")` de la versión 3.0 de AWS Glue.

```
datasource0 = glueContext.create_dynamic_frame.from_catalog(
  database = "database-name",
  table_name = "table-name",
  redshift_tmp_dir = args["TempDir"],
  additional_options = {"sse_kms_key":"<KMS_KEY_ID>"},
  transformation_ctx = "datasource0"
)
```

Compatibilidad con URL de JDBC basadas en IAM

El nuevo conector admite una URL de JDBC basada en IAM, por lo que no es necesario pasar un usuario o contraseña ni un secreto. Con una URL de JDBC basada en IAM, el conector utiliza el rol de tiempo de ejecución del trabajo para acceder al origen de datos de Amazon Redshift.

Paso 1: adjunte la siguiente política mínima requerida a su rol de tiempo de ejecución del trabajo de AWS Glue.

JSON

```
{
    "Version":"2012-10-17",
    "Statement": [
        {
            "Sid": "VisualEditor0",
            "Effect": "Allow",
            "Action": "redshift:GetClusterCredentials",
            "Resource": [
                "arn:aws:redshift:us-east-1:111122223333:dbgroup:<cluster name>/
*",
                "arn:aws:redshift:*:111122223333:dbuser:*/*",
                "arn:aws:redshift:us-east-1:111122223333:dbname:<cluster name>/
<database name>"
            ]
        },
        {
            "Sid": "VisualEditor1",
            "Effect": "Allow",
            "Action": "redshift:DescribeClusters",
            "Resource": "*"
        }
    ]
```

```
}
```

Paso 2: utilice la URL de JDBC basada en IAM de la siguiente manera. Especifique una nueva opción `DbUser` con el nombre de usuario de Amazon Redshift con el que se está conectando.

```
conn_options = {
     // IAM-based JDBC URL
    "url": "jdbc:redshift:iam://<cluster name>:<region>/<database name>",
    "dbtable": dbtable,
    "redshiftTmpDir": redshiftTmpDir,
    "aws_iam_role": aws_iam_role,
    "DbUser": "<Redshift User name>" // required for IAM-based JDBC URL
    }

redshift_write = glueContext.write_dynamic_frame.from_options(
    frame=dyf,
    connection_type="redshift",
    connection_options=conn_options
)

redshift_read = glueContext.create_dynamic_frame.from_options(
    connection_type="redshift",
    connection_options=conn_options
)
```

> **Note**
>
> Actualmente, un `DynamicFrame` solo admite una URL de JDBC basada en IAM con un valor de `DbUser` en el flujo de trabajo de `GlueContext.create_dynamic_frame.from_options`.

Migración de la versión 3.0 de AWS Glue a la versión 4.0

En Glue 4.0 AWS, los trabajos de ETL tienen acceso a un nuevo conector de Spark para Amazon Redshift y a un nuevo controlador JDBC con diferentes opciones y configuraciones. El nuevo conector y controlador de Amazon Redshift están diseñados con el rendimiento como objetivo y mantienen la coherencia transaccional de los datos. Estos productos están registrados en la documentación de Amazon Redshift. Para obtener más información, consulte:

- Amazon Redshift integration for Apache Spark (Integración de Amazon Redshift para Apache Spark
- Amazon Redshift JDBC driver, version 2.1 (Controlador JDBC versión 2.1 de Amazon Redshift 2.1

Restricción de identificadores y nombres de tablas o columnas

El nuevo conector y el controlador de Spark para Amazon Redshift tienen un requisito más restringido para el nombre de tablas de Redshift. Si necesita más información, consulte Nombres e identificadores para definir el nombre de una tabla de Amazon Redshift. Es posible que el flujo de trabajo de marcador de trabajo no funcione con un nombre de tabla que no coincida con las reglas y con ciertos caracteres, como un espacio.

Si tiene tablas heredadas con nombres que no se ajustan a las reglas indicadas en Nombres e identificadores y tiene problemas con los marcadores (los trabajos vuelven a procesar datos antiguos de tablas de Amazon Redshift), le recomendamos que cambie el nombre de las tablas. Para obtener más información, consulte Ejemplos de ALTER TABLE.

Cambio de tempformat predeterminado en DataFrame

El conector de Spark de la versión 3.0 de AWS Glue establece de forma predeterminada el valor de `tempformat` en CSV al escribir en Amazon Redshift. Para mantener la coherencia, en la versión 3.0 de AWS Glue, el `DynamicFrame` sigue estableciendo el valor predeterminado de `tempformat` para usar `CSV`. Si ha utilizado con anterioridad las API de Dataframe de Spark directamente con el conector de Spark para Amazon Redshift, puede establecer el `tempformat` en CSV en las opciones `DataframeReader` o `Writer`. De lo contrario, `tempformat` adopta `AVRO` como valor predeterminado en el nuevo conector de Spark.

Cambio de conducta: asignación del tipo de datos REAL de Amazon Redshift al tipo de datos FLOAT de Spark en lugar de DOUBLE

En la versión 3.0 de AWS Glue, el tipo `REAL` de Amazon Redshift se convierte a un tipo `DOUBLE` de Spark. El nuevo conector de Spark para Amazon Redshift ha actualizado el comportamiento para que el tipo `REAL` de Amazon Redshift se convierta al tipo `FLOAT` de Spark y viceversa. Si tiene un caso de uso heredado en el que aún desea que el tipo `REAL` de Amazon Redshift se asigne a un tipo `DOUBLE` de Spark, puede utilizar la siguiente solución alternativa:

- En el caso de un `DynamicFrame`, asigna el tipo `Float` a un tipo `Double` con `DynamicFrame.ApplyMapping`. En el caso de un `Dataframe`, tiene que usar `cast`.

Ejemplo de código:

```
dyf_cast = dyf.apply_mapping([('a', 'long', 'a', 'long'), ('b', 'float', 'b',
 'double')])
```

Gestión del tipo de datos VARBYTE

Al trabajar con los tipos de datos de AWS Glue 3.0 y Amazon Redshift, AWS Glue 3.0 convierte Amazon Redshift `VARBYTE` al tipo Spark `STRING`. Sin embargo, el último conector de Amazon Redshift Spark no admite el tipo de datos `VARBYTE`. Para superar esta limitación, se puede crear una vista de Redshift que transforme las columnas `VARBYTE` en un tipo de datos compatible. Luego, se debe utilizar el nuevo conector para cargar los datos desde esta vista en lugar de hacerlo desde la tabla original, lo que garantiza la compatibilidad y, al mismo tiempo, mantiene el acceso a sus datos `VARBYTE`.

Ejemplo de consulta de Redshift:

```
CREATE VIEW view_name AS SELECT FROM_VARBYTE(varbyte_column, 'hex') FROM table_name
```

Conexiones de Kafka

Puede utilizar una conexión de Kafka para leer y escribir en los flujos de datos de Kafka mediante información almacenada en una tabla del catálogo de datos o si proporciona información para acceder directamente al flujo de datos. La conexión admite un clúster de Kafka o un clúster de Amazon Managed Streaming para Apache Kafka. Puede leer la información de Kafka en un DataFrame de Spark para luego convertirla en un DynamicFrame de AWS Glue. Puede escribir los DynamicFrame en Kafka en un formato JSON. Si accede directamente a la secuencia de datos, utilice estas opciones para proporcionar información sobre cómo acceder a la secuencia de datos.

Si utiliza `getCatalogSource` o `create_data_frame_from_catalog` para consumir los registros de un origen de streaming de Kafka, o `getCatalogSink` o `write_dynamic_frame_from_catalog` para escribir registros en Kafka, el trabajo cuenta con la base de datos del Catálogo de datos y la información del nombre de la tabla, lo cual se puede utilizar para obtener algunos parámetros básicos para la lectura de un origen de streaming de Kafka. Si utiliza `getSource`, `getCatalogSink`, `getSourceWithFormat`, `getSinkWithFormat`, `createDataFrameFromOptions`, `create_data_frame_from_options` o `write_dynamic_frame_from_catalog`, debe especificar estos parámetros básicos con las opciones de conexión que se describen aquí.

Puede especificar las opciones de conexión para Kafka con los argumentos que se mencionan a continuación para los métodos especificados en la clase `GlueContext`.

- Scala
  - `connectionOptions`: se debe utilizar con `getSource`, `createDataFrameFromOptions` y `getSink`
  - `additionalOptions`: se debe utilizar con `getCatalogSource`, `getCatalogSink`
  - `options`: se debe utilizar con `getSourceWithFormat`, `getSinkWithFormat`
- Python
  - `connection_options`: se debe utilizar con `create_data_frame_from_options`, `write_dynamic_frame_from_options`
  - `additional_options`: se debe utilizar con `create_data_frame_from_catalog`, `write_dynamic_frame_from_catalog`
  - `options`: se debe utilizar con `getSource`, `getSink`

Para obtener notas y conocer las restricciones sobre los trabajos de ETL de transmisión, consulte the section called “Notas y restricciones de ETL de streaming”.

Configurar Kafka

No hay requisitos previos AWS para conectarse a las transmisiones de Kafka disponibles a través de Internet.

Puede crear una conexión Glue Kafka AWS para gestionar sus credenciales de conexión. Para obtener más información, consulte the section called “Crear una conexión para un flujo de datos Kafka”. En la configuración del trabajo de Glue AWS, proporcione *`connectionName`* como conexión de red adicional y, a continuación, en la llamada al método, proporcione *`connectionName`* al parámetro `connectionName`.

En algunos casos, tendrá que configurar requisitos previos adicionales:

- Si utiliza Amazon Managed Streaming for Apache Kafka con autenticación de IAM, necesitará una configuración de IAM adecuada.
- Si utiliza Amazon Managed Streaming for Apache Kafka con una Amazon VPC, necesitará una configuración de Amazon VPC adecuada. Deberá crear una conexión a AWS Glue que proporcione información de conexión de Amazon VPC. Necesitará que la configuración de su trabajo incluya la conexión Glue AWS como conexión de red adicional.

Para obtener más información sobre los requisitos previos del trabajo de ETL de Streaming, consulte the section called “Trabajos ETL de streaming”.

Ejemplo: leer desde transmisiones de Kafka

Se utiliza junto con the section called “forEachBatch”.

Ejemplo de origen de streaming de Kafka:

```
kafka_options =
    { "connectionName": "ConfluentKafka",
      "topicName": "kafka-auth-topic",
      "startingOffsets": "earliest",
      "inferSchema": "true",
      "classification": "json"
    }
data_frame_datasource0 =
 glueContext.create_data_frame.from_options(connection_type="kafka",
 connection_options=kafka_options)
```

Ejemplo: escritura a flujos de Kafka

Ejemplos de escritura a Kafka:

Ejemplo con el método `getSink`:

```
data_frame_datasource0 =
glueContext.getSink(
 connectionType="kafka",
 connectionOptions={
  JsonOptions("""{
   "connectionName": "ConfluentKafka",
   "classification": "json",
   "topic": "kafka-auth-topic",
   "typeOfData": "kafka"}
  """)},
 transformationContext="dataframe_ApacheKafka_node1711729173428")
 .getDataFrame()
```

Ejemplo con el método `write_dynamic_frame.from_options`:

```
kafka_options =
    { "connectionName": "ConfluentKafka",
```

```
      "topicName": "kafka-auth-topic",
      "classification": "json"
    }
data_frame_datasource0 =
 glueContext.write_dynamic_frame.from_options(connection_type="kafka",
 connection_options=kafka_options)
```

Referencia de opciones de conexión de Kafka

Al leer, utilice las opciones de conexión con `"connectionType": "kafka"` a continuación:

- `"bootstrap.servers"` (obligatorio): una lista de direcciones URL Bootstrap, por ejemplo, como `b-1.vpc-test-2.o4q88o.c6.kafka.us-east-1.amazonaws.com:9094`. Esta opción debe especificarse en la llamada a la API o definirse en los metadatos de la tabla en el Data Catalog.
- `"security.protocol"` (obligatorio): el protocolo que se utiliza para la comunicación con los agentes. Los valores posibles son `"SSL"` o.`"PLAINTEXT"`
- `"topicName"` (Obligatorio) Lista separada por comas de temas a los que suscribirse. Debe especificar solo una opción de `"topicName"`, `"assign"` o `"subscribePattern"`.
- `"assign"`: (Obligatorio) Una cadena JSON que especifica el valor de `TopicPartitions` para consumir. Debe especificar solo una opción de `"topicName"`, `"assign"` o `"subscribePattern"`.

  Ejemplo: “{“temaA”:[0,1],“temaB”:[2,4]}”
- `"subscribePattern"`: (obligatorio) cadena de expresiones regulares de Java que identifica la lista de temas a la que desea suscribirse. Debe especificar solo una opción de `"topicName"`, `"assign"` o `"subscribePattern"`.

  Ejemplo: “tema.*”
- `"classification"` (Obligatorio) El formato de archivo utilizado por los datos del registro. Obligatorio a menos que se proporcione a través del catálogo de datos.
- `"delimiter"` (Opcional) El separador de valores que se utiliza cuando `classification` es CSV. El valor predeterminado es “`,`”.
- `"startingOffsets"`: (opcional) posición inicial en el tema de Kafka para leer los datos. Los valores posibles son `"earliest"` o.`"latest"` El valor predeterminado es `"latest"`.
- `"startingTimestamp"`: (Opcional, solo compatible con la versión 4.0 o posterior de Glue AWS) La marca de tiempo del registro en el tema de Kafka para leer los datos. Los valores posibles son una cadena de marca de tiempo en formato UTC en el patrón `yyyy-mm-ddTHH:MM:SSZ`

(donde Z representa un desplazamiento de zona horaria UTC con un +/-. Por ejemplo, “2023-04-04T08:00:00-04:00”).

Nota: Solo una de las opciones 'startingOffsets' o 'startingTimestamp' puede estar presente en la lista de opciones de conexión del script de streaming de AWS Glue, incluir estas dos propiedades producirá un error en el trabajo.

- `"endingOffsets"`: (opcional) el punto final cuando finaliza una consulta por lotes. Los valores posibles son `"latest"` o una cadena JSON que especifica una compensación final para cada `TopicPartition`.

  Para la cadena JSON, el formato es `{"topicA":{"0":23,"1":-1},"topicB":{"0":-1}}`. El valor `-1` como compensación representa `"latest"`.

- `"pollTimeoutMs"`: (opcional) tiempo de espera en milisegundos para sondear datos de Kafka en ejecutores de trabajos de Spark. El valor predeterminado es `600000`.

- `"numRetries"`: (opcional) el número de veces que se reintenta antes de no obtener las compensaciones de Kafka. El valor predeterminado es `3`.

- `"retryIntervalMs"`: (opcional) tiempo en milisegundos para esperar antes de volver a intentar obtener compensaciones Kafka. El valor predeterminado es `10`.

- `"maxOffsetsPerTrigger"`: (opcional) el límite de velocidad en el número máximo de compensaciones que se procesan por intervalo de desencadenador. El número total de compensaciones especificado se divide de forma proporcional entre `topicPartitions` de diferentes volúmenes. El valor predeterminado es nulo, lo que significa que el consumidor lee todos las compensaciones hasta la última compensación conocida.

- `"minPartitions"`: (opcional) el número mínimo deseado de particiones para leer desde Kafka. El valor predeterminado es nulo, lo que significa que el número de particiones de Spark es igual al número de particiones de Kafka.

- `"includeHeaders"`: (opcional) si se deben incluir los encabezados de Kafka. Cuando la opción se establece en “verdadero”, la salida de datos contendrá una columna adicional denominada “glue_streaming_kafka_headers” con el tipo `Array[Struct(key: String, value: String)]`. El valor predeterminado es “false”. Esta opción se encuentra disponible en la versión 3.0 o posterior de AWS Glue.

- `"schema"`: (Obligatorio cuando inferSchema se establece en false) Esquema que se va a utilizar para procesar la carga. Si la clasificación es `avro`, el esquema proporcionado debe estar en el formato de esquema Avro. Si la clasificación no es `avro`, el esquema proporcionado debe estar en el formato de esquema DDL.

A continuación, se muestran algunos ejemplos de esquemas.

Example in DDL schema format

```
'column1' INT, 'column2' STRING , 'column3' FLOAT
```

Example in Avro schema format

```
{
"type":"array",
"items":
{
"type":"record",
"name":"test",
"fields":
[
  {
    "name":"_id",
    "type":"string"
  },
  {
    "name":"index",
    "type":
    [
      "int",
      "string",
      "float"
    ]
  }
]
}
}
```

- `"inferSchema"`: (opcional) El valor predeterminado es “false”. Si se establece en “true”, el esquema se detectará durante el tiempo de ejecución desde la carga dentro de `foreachbatch`.
- `"avroSchema"`: (obsoleto) Parámetro utilizado para especificar un esquema de datos Avro cuando se utiliza el formato Avro. Este parámetro se ha quedado obsoleto. Utilice el parámetro `schema`.
- `"addRecordTimestamp"`: (opcional) cuando esta opción se establece en “true”, la salida de datos contendrá una columna adicional denominada “__src_timestamp” que indica la hora en la

que el tema recibió el registro correspondiente. El valor predeterminado es “false”. Esta opción es compatible con la versión 4.0 o posterior de AWS Glue.

- `"emitConsumerLagMetrics"`: (opcional) cuando esta opción se establece en “true”, para cada lote, emitirá las métricas correspondientes al período comprendido entre el registro más antiguo recibido por el tema y el momento en que llegue a AWS Glue en CloudWatch. El nombre de la métrica es “glue.driver.streaming.maxConsumerLagInMs”. El valor predeterminado es “false”. Esta opción es compatible con la versión 4.0 o posterior de AWS Glue.

Al escribir, utilice las opciones de conexión con `"connectionType": "kafka"` a continuación:

- `"connectionName"` (Obligatorio) Nombre de la conexión de AWS Glue utilizada para conectar al clúster de Kafka (similar al origen de Kafka).
- `"topic"` (Obligatorio) Si existe una columna de temas, su valor se utiliza como el tema al momento de la escritura de la fila en Kafka, a menos que esté establecida la opción de configuración de temas. Es decir, la opción de configuración de `topic` anula la columna de temas.
- `"partition"` (Opcional) Si se especifica un número válido de partición, esta `partition` se utilizará cuando se envíe el registro.

  Si no se especifica ninguna partición pero hay una `key`, se elegirá una partición con el hash de la clave.

  Si no hay ni una `key` ni una `partition`, se elegirá una partición según la partición sticky de esos cambios cuando al menos se produzcan bytes de batch.size en la partición.
- `"key"` (Opcional) Utilizado para la partición si la `partition` es nula.
- `"classification"` (Opcional) El formato de archivo utilizado por los datos en el registro. Solo se admiten los formatos JSON, CSV y Avro.

  Con el formato Avro, podemos brindar un AvroSchema personalizado para la serialización, pero tenga en cuenta que también se tiene que brindar en el origen para la deserialización. Si no, se utilizará de manera predeterminada el AvroSchema de Apache para la serialización.

Además, puede ajustar los receptores de Kafka según sea necesario al actualizar los parámetros de configuración de productor de Kafka. Tenga en cuenta que no hay una lista de permisos en las opciones de conexión; todos los pares clave-valor se conservan en el receptor como se encuentran.

Sin embargo, existe una pequeña lista de opciones de rechazos que no tendrá efecto. Para obtener más información, consulte las Configuraciones específicas de Kafka.

Conexiones de Azure Cosmos DB

Puede usar AWS Glue for Spark para leer y escribir en contenedores existentes de Azure Cosmos DB mediante la API de NoSQL en AWS Glue 4.0 y versiones posteriores. Puede definir qué leer desde Azure Cosmos DB con una consulta SQL. Se conecta a Azure Cosmos DB mediante una clave de Azure Cosmos DB almacenada en AWS Secrets Manager mediante una conexión de AWS Glue.

Para obtener más información sobre Azure Cosmos DB para NoSQL, consulte la documentación de Azure.

Configuración de las conexiones de Azure Cosmos DB

Para conectarse a Azure Cosmos DB desde AWS Glue, tendrá que crear y almacenar su clave de Azure Cosmos DB en un AWS Secrets Manager secreto y, a continuación, asociar ese secreto a una conexión AWS Glue de Azure Cosmos DB.

Requisitos previos:

- En Azure, tendrá que identificar o generar una clave de Azure Cosmos DB para que la utilice AWS Glue, `cosmosKey`. Para obtener más información, consulte Acceso seguro a los datos en Azure Cosmos DB en la documentación de Azure.

Para configurar una conexión a Azure Cosmos DB:

1. En AWS Secrets Manager, cree un secreto con su clave de datos de Azure Cosmos DB. Para crear un secreto en Secrets Manager, siga el tutorial disponible en Crear un secreto AWS Secrets Manager en la documentación AWS Secrets Manager. Después de crear el secreto, conserve el nombre secreto, *`secretName`*, para el siguiente paso.
   - Al seleccionar pares clave/valor, genere un par para la clave `spark.cosmos.accountKey` con el valor *`cosmosKey`*.
2. En la consola de AWS Glue, genere una conexión mediante los pasos que se indican en the section called “Adición de una conexión de AWS Glue”. Tras crear la conexión, conserve el nombre de la conexión, *`connectionName`*, para el uso futuro en AWS Glue.
   - Al seleccionar un tipo de conexión, seleccione Azure Cosmos DB.
   - Al seleccionar un secreto AWS, proporcione un *`secretName`*.

Tras crear una conexión a AWS Glue Azure Cosmos DB, tendrá que realizar los siguientes pasos antes de ejecutar el trabajo de AWS Glue:

- Otorgue al rol de IAM asociado al permiso de su trabajo de AWS Glue para leer *secretName*.
- En la configuración del trabajo de Glue AWS, proporcione *connectionName* como una conexión de red adicional.

Lectura de contenedores de Azure Cosmos DB para NoSQL

Requisitos previos:

- Un contenedor de Azure Cosmos DB para NoSQL del que desearía leer. Necesitará la información de identificación del contenedor.

  Un contenedor de Azure Cosmos para NoSQL se identifica por su base de datos y su contenedor. Debe proporcionar los nombres de la base de datos, *cosmosDBName*, y del contenedor, *cosmosContainerName*, al conectarse a la API de Azure Cosmos para NoSQL.
- Una conexión AWS Glue Azure Cosmos DB configurada para proporcionar información de autenticación y ubicación de red. Para obtenerla, complete los pasos del procedimiento anterior, Para configurar una conexión a Azure Cosmos DB. Necesitará el nombre de la conexión de AWS Glue, *connectionName*.

Por ejemplo:

```
azurecosmos_read = glueContext.create_dynamic_frame.from_options(
    connection_type="azurecosmos",
    connection_options={
    "connectionName": connectionName,
    "spark.cosmos.database": cosmosDBName,
    "spark.cosmos.container": cosmosContainerName,
    }
)
```

También puede proporcionar una consulta SELECT SQL para filtrar los resultados devueltos a su DynamicFrame. Deberá configurar `query`.

Por ejemplo:

```
azurecosmos_read_query = glueContext.create_dynamic_frame.from_options(
```

```
    connection_type="azurecosmos",
    connection_options={
        "connectionName": "connectionName",
        "spark.cosmos.database": cosmosDBName,
        "spark.cosmos.container": cosmosContainerName,
        "spark.cosmos.read.customQuery": "query"
    }
)
```

Escribir en un contenedor de Azure Cosmos DB para NoSQL

En este ejemplo, se escribe la información de un DynamicFrame existente, *dynamicFrame* en Azure Cosmos DB. Si el contenedor ya contiene información, AWS Glue añadirá los datos de su DynamicFrame. Si la información del contenedor tiene un esquema diferente al de la información que escribe, se producirán errores.

Requisitos previos:

- Una tabla de Azure Cosmos DB a la que desearía escribir. Necesitará la información de identificación del contenedor. Debe crear el contenedor antes de llamar al método de conexión.

  Un contenedor de Azure Cosmos para NoSQL se identifica por su base de datos y su contenedor. Debe proporcionar los nombres de la base de datos, *cosmosDBName*, y del contenedor, *cosmosContainerName*, al conectarse a la API de Azure Cosmos para NoSQL.
- Una conexión AWS Glue Azure Cosmos DB configurada para proporcionar información de autenticación y ubicación de red. Para obtenerla, complete los pasos del procedimiento anterior, Para configurar una conexión a Azure Cosmos DB. Necesitará el nombre de la conexión de AWS Glue, *connectionName*.

Por ejemplo:

```
azurecosmos_write = glueContext.write_dynamic_frame.from_options(
    frame=dynamicFrame,
    connection_type="azurecosmos",
    connection_options={
    "connectionName": connectionName,
    "spark.cosmos.database": cosmosDBName,
    "spark.cosmos.container": cosmosContainerName
)
```

Referencia de opciones de conexión de Azure Cosmos DB

- `connectionName`: obligatorio. Se utiliza para lectura/escritura. El nombre de una conexión de AWS Glue Azure Cosmos DB configurada para proporcionar información de autenticación y ubicación de red a su método de conexión.
- `spark.cosmos.database`: obligatorio. Se utiliza para lectura/escritura. Valores válidos: nombres de bases de datos. Nombre de base de datos de Azure Cosmos DB para NoSQL.
- `spark.cosmos.container`: obligatorio. Se utiliza para lectura/escritura. Valores válidos: nombres de contenedores. Nombre del contenedor de Azure Cosmos DB para NoSQL.
- `spark.cosmos.read.customQuery`: se utiliza para leer. Valores válidos: consultas SQL SELECT. Consulta personalizada para seleccionar los documentos que se van a leer.

Conexiones SQL Azure

Puede usar AWS Glue for Spark para leer y escribir en tablas en instancias administradas de Azure SQL en AWS Glue 4.0 y versiones posteriores. Puede definir qué leer de Azure SQL con una consulta SQL. Se conecta a Azure SQL con las credenciales de usuario y contraseña almacenadas en AWS Secrets Manager a través de una conexión de AWS Glue.

Para obtener más información sobre Azure SQL, consulte la documentación de Azure SQL.

Configuración de las conexiones de Azure SQL

Para conectarse a Azure SQL desde AWS Glue, tendrá que crear y almacenar las credenciales de Azure SQL en un AWS Secrets Manager secreto y, a continuación, asociar ese secreto a una conexión de AWS Glue de Azure SQL.

Para configurar una conexión a Azure SQL:

1. En AWS Secrets Manager, cree un secreto con sus credenciales de Azure SQL. Para crear un secreto en Secrets Manager, siga el tutorial disponible en Crear un secreto AWS Secrets Manager en la documentación AWS Secrets Manager. Después de crear el secreto, conserve el nombre secreto, *`secretName`*, para el siguiente paso.

   - Al seleccionar pares clave/valor, genere un par para la clave `user` con el valor *`azuresqlUsername`*.
   - Al seleccionar pares clave/valor, genere un par para la clave `password` con el valor *`azuresqlPassword`*.

2. En la consola de AWS Glue, genere una conexión mediante los pasos que se indican en the section called “Adición de una conexión de AWS Glue”. Tras crear la conexión, conserve el nombre de la conexión, *connectionName*, para el uso futuro en AWS Glue.

   - Al seleccionar un tipo de conexión, seleccione Azure SQL.
   - Al proporcionar una URL de Azure SQL, proporcione una URL de punto de conexión de JDBC.

     La lista de URL debe tener el siguiente formato: `jdbc:sqlserver://`*databaseServerName*`:`*databasePort*`;databaseName=`*azuresqlDBnam*

     AWS Glue requiere las siguientes propiedades de URL:

     - `databaseName`: una base de datos predeterminada en Azure SQL a la que conectarse.

     Para obtener más información sobre las direcciones URL de JDBC para instancias administradas de Azure SQL, consulte la documentación de Microsoft.
   - Al seleccionar un secreto AWS, proporcione un *secretName*.

Tras crear una conexión AWS Glue Azure SQL, tendrá que realizar los siguientes pasos antes de ejecutar el trabajo de AWS Glue:

- Otorgue al rol de IAM asociado al permiso de su trabajo de AWS Glue para leer *secretName*.
- En la configuración del trabajo de Glue AWS, proporcione *connectionName* como una conexión de red adicional.

Lectura de tablas de Azure SQL

Requisitos previos:

- Una tabla de Azure SQL desde la cual le gustaría leer. Necesitará información de identificación para la tabla, *databaseName* y *tableIdentifier*.

  Una tabla de Azure SQL se identifica por su base de datos, esquema y nombre de tabla. Debe proporcionar el nombre de la base de datos y el nombre de la tabla al conectarse a Azure SQL. También debe proporcionar el esquema si no es el predeterminado, "público". La base de datos se proporciona a través de una propiedad URL en *connectionName*, y el nombre de la tabla y el esquema a través de `dbtable`.
- Una conexión AWS Glue Azure SQL configurada para proporcionar información de autenticación. Complete los pasos del procedimiento anterior, Para configurar una conexión a Azure SQL para

configurar su información de autenticación. Necesitará el nombre de la conexión de AWS Glue, *connectionName*.

Por ejemplo:

```
azuresql_read_table = glueContext.create_dynamic_frame.from_options(
    connection_type="azuresql",
    connection_options={
        "connectionName": "connectionName",
        "dbtable": "tableIdentifier"
    }
)
```

También puede proporcionar una consulta SELECT SQL para filtrar los resultados devueltos a su DynamicFrame. Deberá configurar `query`.

Por ejemplo:

```
azuresql_read_query = glueContext.create_dynamic_frame.from_options(
    connection_type="azuresql",
    connection_options={
        "connectionName": "connectionName",
        "query": "query"
    }
)
```

Escribir en tablas de Azure SQL

En este ejemplo, se escribe la información de un DynamicFrame o *dynamicFrame* existente en Azure SQL. Si la tabla ya contiene información, AWS Glue añadirá los datos de su DynamicFrame.

Requisitos previos:

- Una tabla de Azure SQL en la cual le gustaría escribir. Necesitará información de identificación para la tabla, *databaseName* y *tableIdentifier*.

  Una tabla de Azure SQL se identifica por su base de datos, esquema y nombre de tabla. Debe proporcionar el nombre de la base de datos y el nombre de la tabla al conectarse a Azure SQL. También debe proporcionar el esquema si no es el predeterminado, "público". La base de datos se proporciona a través de una propiedad URL en *connectionName*, y el nombre de la tabla y el esquema a través de `dbtable`.

- Información de autenticación de Azure SQL. Complete los pasos del procedimiento anterior, Para configurar una conexión a Azure SQL para configurar su información de autenticación. Necesitará el nombre de la conexión de AWS Glue, *connectionName*.

Por ejemplo:

```
azuresql_write = glueContext.write_dynamic_frame.from_options(
    connection_type="azuresql",
    connection_options={
        "connectionName": "connectionName",
        "dbtable": "tableIdentifier"
    }
)
```

Referencia de opciones de conexión de Azure SQL

- `connectionName`: obligatorio. Se utiliza para lectura/escritura. El nombre de una conexión de AWS Glue Azure SQL configurada para proporcionar información de autenticación al método de conexión.
- `databaseName`: se utiliza para lectura/escritura. Valores válidos: nombres de bases de datos de Azure SQL. Nombre de la base de datos de Azure SQL a la que se va a conectar.
- `dbtable`: necesario para escribir, obligatorio para leer a menos que se proporcione `query`. Se utiliza para lectura/escritura. Valores válidos: nombres de tablas de Azure SQL o combinaciones de nombres de tablas y esquemas separados por puntos. Se utiliza para especificar la tabla y el esquema que identifican la tabla a la que se va a conectar. El esquema predeterminado es “público”. Si la tabla está en un esquema que no es el predeterminado, proporciona esta información en la forma *schemaName*.*tableName*.
- `query`: se utiliza para leer. Una consulta SELECT de Transact-SQL que defina lo que se debe recuperar al leer desde Azure SQL. Para obtener más información, consulte la documentación de Microsoft.

Conexiones de BigQuery

Puede usar AWS Glue para Spark para leer y escribir en tablas de Google BigQuery en AWS Glue 4.0 y versiones posteriores. Puede leer desde BigQuery con una consulta de SQL de Google. Se conecta BigQuery con las credenciales almacenadas en AWS Secrets Manager a través de una conexión de AWS Glue.

Para obtener más información sobre Google BigQuery, consulte el sitio web de Google Cloud BigQuery.

Configuración de conexiones con BigQuery

Para conectarse a Google BigQuery desde AWS Glue, tendrá que crear y almacenar las credenciales de Google Cloud Platform en un secreto de AWS Secrets Manager y, a continuación, asociar ese secreto a una conexión de Google BigQuery para AWS Glue.

Para configurar una conexión a BigQuery, siga estos pasos:

1. En Google Cloud Platform, genere e identifique los recursos pertinentes:

   - Genere e identifique un proyecto de GCP que contenga tablas de BigQuery a las que desea conectarse.
   - Habilite la API de BigQuery. Para obtener más información, consulte Cómo usar la API de lectura de almacenamiento de BigQuery para leer datos de tablas.
2. En Google Cloud Platform, genere y exporte las credenciales de la cuenta de servicio:

   Puede usar el asistente de credenciales de BigQuery para simplificar este paso: Crear credenciales.

   Para crear una cuenta de servicio en GCP, siga el tutorial disponible en Crear cuentas de servicio.

   - Al elegir un proyecto, seleccione el proyecto que contiene su tabla de BigQuery.
   - Cuando elija los roles de IAM de GCP para la cuenta de servicio, agregue o genere una función que conceda los permisos apropiados para ejecutar los trabajos en BigQuery, como la lectura, escritura o creación de tablas de BigQuery.

   Para crear credenciales para la cuenta de servicio, siga el tutorial disponible en Crear una clave de cuenta de servicio.

   - Al seleccionar el tipo de clave, seleccione JSON.

   Ahora debería haber descargado un archivo JSON que contiene las credenciales de la cuenta de servicio. Debería parecerse a lo que sigue:

```
{
```

```
  "type": "service_account",
  "project_id": "*****",
  "private_key_id": "*****",
  "private_key": "*****",
  "client_email": "*****",
  "client_id": "*****",
  "auth_uri": "https://accounts.google.com/o/oauth2/auth",
  "token_uri": "https://oauth2.googleapis.com/token",
  "auth_provider_x509_cert_url": "https://www.googleapis.com/oauth2/v1/certs",
  "client_x509_cert_url": "*****",
  "universe_domain": "googleapis.com"
}
```

3. Cargue el archivo JSON de sus credenciales a una ubicación de Amazon S3 con la seguridad adecuada. Conserve la ruta del archivo, *s3secretpath*, para pasos futuros.
4. En AWS Secrets Manager, genere un secreto mediante las credenciales de la plataforma de Google Cloud. Para crear un secreto en Secrets Manager, siga el tutorial disponible en Crear un secreto AWS Secrets Manager en la documentación AWS Secrets Manager. Después de crear el secreto, conserve el nombre secreto, *secretName*, para el siguiente paso.

   Al crear pares clave/valor, especifique las claves y los valores de la siguiente manera:

   - Para las claves `token_uri`, `client_x509_cert_url`, `private_key_id`, `project_id`, `universe_domain`, `auth_provider_x509_cert_url`, `auth_uri`, `client_email`, `private_key`, `type`, `client_id`, especifique los valores correspondientes en el archivo JSON descargado.
   - Para la clave `spark.hadoop.google.cloud.auth.service.account.json.keyfile`, especifique *s3secretpath*.
5. En el catálogo de datos de Glue AWS, cree una conexión mediante los pasos que se indican en the section called “Adición de una conexión de AWS Glue”. Tras crear la conexión, conserve el nombre de la conexión, *connectionName*, para el siguiente paso.

   - Cuando elija un Tipo de conexión, seleccione Google BigQuery.
   - Al seleccionar un secreto AWS, proporcione un *secretName*.
6. Otorgue al rol de IAM asociado al trabajo de AWS Glue el permiso para leer *secretName*.
7. En la configuración del trabajo de Glue AWS, proporcione *connectionName* como una conexión de red adicional.

Lectura de tablas de BigQuery

Requisitos previos:

- Una tabla de BigQuery desde la cual le gustaría leer. Necesitará los nombres de la tabla y el conjunto de datos de BigQuery, en el formulario `[dataset].[table]`. Llamemos a esto *`tableName`*.
- El proyecto de facturación para la tabla de BigQuery. Necesitará el nombre del proyecto, *`parentProject`*. Si no hay ningún proyecto principal de facturación, utilice el proyecto que contiene la tabla.
- Información de autenticación de BigQuery. Complete los pasos para administrar sus credenciales de conexión con AWS Glue para configurar su información de autenticación. Necesitará el nombre de la conexión de AWS Glue, *`connectionName`*.

Por ejemplo:

```
bigquery_read = glueContext.create_dynamic_frame.from_options(
    connection_type="bigquery",
    connection_options={
        "connectionName": "connectionName",
        "parentProject": "parentProject",
        "sourceType": "table",
        "table": "tableName",
    }
```

También puede proporcionar una consulta para filtrar los resultados devueltos a su DynamicFrame. Tendrá que configurar `query`, `sourceType`, `viewsEnabled` y `materializationDataset`.

Por ejemplo:

Requisitos previos adicionales:

Deberá crear o identificar un conjunto de datos de BigQuery, *`materializationDataset`*, en el que BigQuery pueda escribir vistas materializadas para las consultas.

Deberá otorgar los permisos de IAM GCP adecuados a la cuenta de servicio para crear tablas en *`materializationDataset`*.

```
glueContext.create_dynamic_frame.from_options(
```

```
            connection_type="bigquery",
            connection_options={
                "connectionName": "connectionName",
                "materializationDataset": materializationDataset,
                "parentProject": "parentProject",
                "viewsEnabled": "true",
                "sourceType": "query",
                "query": "select * from bqtest.test"
            }
        )
```

Escribir en tablas de BigQuery

En este ejemplo escribe directamente en el servicio de BigQuery. BigQuery también admite el método de escritura “indirecta”. Para obtener más información sobre la configuración de escritura indirecta, consulte the section called “Uso de escritura indirecta con Google BigQuery”.

Requisitos previos:

- Una tabla de BigQuery en la cual le gustaría escribir. Necesitará los nombres de la tabla y el conjunto de datos de BigQuery, en el formulario `[dataset].[table]`. También puede proporcionar un nombre de tabla nuevo que se creará automáticamente. Llamemos a esto *`tableName`*.
- El proyecto de facturación para la tabla de BigQuery. Necesitará el nombre del proyecto, *`parentProject`*. Si no hay ningún proyecto principal de facturación, utilice el proyecto que contiene la tabla.
- Información de autenticación de BigQuery. Complete los pasos para administrar sus credenciales de conexión con AWS Glue para configurar su información de autenticación. Necesitará el nombre de la conexión de AWS Glue, *`connectionName`*.

Por ejemplo:

```
bigquery_write = glueContext.write_dynamic_frame.from_options(
    frame=frameToWrite,
    connection_type="bigquery",
    connection_options={
        "connectionName": "connectionName",
        "parentProject": "parentProject",
        "writeMethod": "direct",
        "table": "tableName",
```

```
    }
)
```

Referencia de opciones de conexión de BigQuery

- `project`: (Predeterminado): cuenta de servicio de Google Cloud predeterminada. Se utiliza para lectura/escritura. El nombre de un proyecto de Google Cloud asociado a la tabla.
- `table` — (Obligatorio) Se utiliza para lectura/escritura. El nombre de la tabla de BigQuery en el formato `[[project:]dataset.]`.
- `dataset` (Obligatorio): cuando no se ha definido mediante la opción `table`. Se utiliza para lectura/escritura. El nombre del conjunto de datos que contiene la tabla de BigQuery.
- `parentProject`: (Predeterminado): cuenta de servicio de Google Cloud predeterminada. Se utiliza para lectura/escritura. El nombre de un proyecto de Google Cloud asociado a `project` que se utiliza para la facturación.
- `sourceType`: se utiliza para leer. Obligatorio al leer. Valores válidos: `table`, `query` informa a AWS Glue si leerá por tabla o por consulta.
- `materializationDataset`: se utiliza para leer. Valores válidos: cadenas. El nombre de un conjunto de datos de BigQuery que se utiliza para almacenar las materializaciones de las vistas.
- `viewsEnabled`: se utiliza para leer. Valor predeterminado: falso. Valores válidos: true y false. Configura si BigQuery utilizará las vistas.
- `query`: se utiliza para leer. Se utiliza cuando `viewsEnabled` es verdadero. Una consulta DQL de GoogleSQL.
- `temporaryGcsBucket`: se utiliza para escribir. Obligatorio cuando `writeMethod` se establece en el valor predeterminado (`indirect`). Nombre de un bucket de Google Cloud Storage que se utiliza para almacenar una forma intermedia de los datos mientras escribe en BigQuery.
- `writeMethod` — Predeterminado: `indirect`. Valores válidos: `direct`, `indirect`. Se utiliza para escribir. Especifica el método utilizado para escribir los datos.
  - Si se establece en `direct`, el conector escribirá con la API de escritura de BigQuery Storage.
  - Si se establece en `indirect`, el conector escribirá en Google Cloud Storage y, a continuación, lo transferirá a BigQuery mediante una operación de carga. Su cuenta de servicio de Google Cloud necesitará los permisos de GCS adecuados.

Uso de escritura indirecta con Google BigQuery

En este ejemplo, se usa la escritura indirecta, que escribe los datos en Google Cloud Storage y los copia en Google BigQuery.

Requisitos previos:

Necesitará un bucket temporal de Google Cloud Storage, llamado *temporaryBucket*.

El rol de IAM de GCP de la cuenta de servicio de GCP de AWS Glue necesitará los permisos de GCS adecuados para acceder a *temporaryBucket*.

Configuración adicional:

Para configurar la escritura indirecta con BigQuery, siga estos pasos:

1. Evalúe the section called “Cómo configurar BigQuery” y localice o vuelva a descargar el archivo JSON de credenciales de GCP. Identifique *secretName*, el secreto de AWS Secrets Manager de la conexión Google BigQuery para AWS Glue que se utiliza en el trabajo.
2. Cargue el archivo JSON de sus credenciales a una ubicación de Amazon S3 con la seguridad adecuada. Conserve la ruta del archivo, *s3secretpath*, para pasos futuros.
3. Edite el *secretName* y agregue la clave `spark.hadoop.google.cloud.auth.service.account.json.keyfile`. Establezca el valor en *s3secretpath*.
4. Otorgue permisos de IAM para AWS Glue en Amazon S3 para acceder a *s3secretpath*.

Ahora puede proporcionar la ubicación temporal de su bucket de GCS a su método de escritura. No es necesario proporcionar `writeMethod`, ya que `indirect` históricamente es el valor predeterminado.

```
bigquery_write = glueContext.write_dynamic_frame.from_options(
    frame=frameToWrite,
    connection_type="bigquery",
    connection_options={
        "connectionName": "connectionName",
        "parentProject": "parentProject",
        "temporaryGcsBucket": "temporaryBucket",
        "table": "tableName",
    }
```

```
)
```

Conexiones de JDBC

Algunos tipos de bases de datos, normalmente relacionales, admiten la conexión a través del estándar JDBC. Para obtener más información sobre JDBC, consulte la Java JDBC API documentation. AWS Glue admite de forma nativa la conexión a determinadas bases de datos a través de sus conectores JDBC; las bibliotecas JDBC se proporcionan en los trabajos de Glue Spark AWS. Al conectarse a estos tipos de bases de datos mediante las bibliotecas de GlueAWS , tiene acceso a un conjunto estándar de opciones.

Entre los valores de ConnectionType de JDBC, se incluyen los siguientes:

- `"connectionType": "sqlserver"`: designa una conexión a una base de datos Microsoft SQL Server.
- `"connectionType": "mysql"`: designa una conexión a una base de datos MySQL.
- `"connectionType": "oracle"`: designa una conexión a una base de datos Oracle.
- `"connectionType": "postgresql"`: designa una conexión a una base de datos PostgreSQL.
- `"connectionType": "redshift"`: designa una conexión a una base de datos de Amazon Redshift. Para obtener más información, consulte the section called “Conexiones Redshift”.

En la siguiente tabla, se muestran las versiones del controlador JDBC que AWS Glue soporta.

Producto	Versiones del controlador JDBC para Glue 5.0	Versiones del controlador JDBC para Glue 4.0	Versiones del controlador JDBC para Glue 3.0	Versiones del controlador JDBC para Glue 0.9, 1.0, 2.0
Microsoft SQL Server	10.2.0	9.4.0	7.x	6.x
MySQL	8.0.33	8.0.23	8.0.23	5.1
Oracle Database	23.3.0.23.09	21.7	21.1	11.2
PostgreSQL	42.7.3	42.3.6	42.2.18	42.1.x

Producto	Versiones del controlador JDBC para Glue 5.0	Versiones del controlador JDBC para Glue 4.0	Versiones del controlador JDBC para Glue 3.0	Versiones del controlador JDBC para Glue 0.9, 1.0, 2.0
Amazon Redshift *	redshift-jdbc42-2.1.0.29	redshift-jdbc42-2.1.0.16	redshift-jdbc41-1.2.12.1017	redshift-jdbc41-1.2.12.1017

* En el caso del tipo de conexión de Amazon Redshift, todos los demás pares nombre/valor que estén presentes en las opciones de una conexión JDBC, incluidas las opciones de formato, se pasan directamente al DataSource SparkSQL subyacente. En los trabajos de Glue with Spark AWS en Glue 4.0 AWS y versiones posteriores, el conector nativo de Glue AWS para Amazon Redshift utiliza la integración de Amazon Redshift para Apache Spark. Para obtener más información, consulte Integración de Amazon Redshift para Apache Spark. En versiones anteriores, consulte el origen de datos de Amazon Redshift para Spark.

Para configurar Amazon VPC para que se conecte a los almacenes de datos de Amazon RDS mediante JDBC, consulte the section called “Configuración de Amazon VPC para conectarse a los almacenes de datos de Amazon RDS”.

> **Note**
>
> Los trabajos de AWS Glue solo se asocian a una subred durante una ejecución. Esto puede afectar a su capacidad de conectarse a diversos orígenes de datos a través del mismo trabajo. Este comportamiento no se limita a los orígenes de JDBC.

Temas

- Referencia de opciones de conexión de JDBC
- Utilice sampleQuery
- Utilice un controlador JDBC personalizado
- Lectura desde tablas de JDBC en paralelo
- Configuración de Amazon VPC para conexiones JDBC a los almacenes de datos de Amazon RDS de AWS Glue

Referencia de opciones de conexión de JDBC

Si ya tiene definida una conexión JDBC de Glue AWS, puede reutilizar las propiedades de configuración definidas en ella, como url, usuario y contraseña; de este modo, no tendrá que especificarlas en el código como opciones de conexión. Esta característica solo está disponible en Glue 3.0 AWS o versiones posteriores. Para ello, utilice las siguientes propiedades de conexión:

- `"useConnectionProperties"`: configúrelo en “true” para indicar que desea utilizar la configuración desde una conexión.
- `"connectionName"`: ingrese el nombre de la conexión desde la que recuperará la configuración. La conexión debe definirse en la misma región que el trabajo.

Utilice estas opciones con las conexiones JDBC:

- `"url"`: (obligatorio) la URL de JDBC de la base de datos.
- `"dbtable"`: (Obligatorio) la tabla de la base de datos de la que se va a leer. Para almacenes de datos de JDBC que admiten esquemas dentro de una base de datos, especifique `schema.table-name`. Si no se ha proporcionado un esquema, se usa el esquema “public” predeterminado.
- `"user"`: (obligatorio) nombre de usuario que se va a utilizar para establecer la conexión.
- `"password"`: (obligatorio) contraseña que se utilizará para establecer la conexión.
- (Opcional) las siguientes opciones le permiten proporcionar un controlador JDBC personalizado. Utilice estas opciones si debe utilizar un controlador que AWS Glue no soporte de forma nativa.

  Los trabajos de ETL pueden utilizar diferentes versiones de controladores JDBC para el origen y el destino de los datos, incluso aunque el origen y el destino sean el mismo producto de base de datos. Esto le permite migrar datos entre bases de datos de origen y destino con diferentes versiones. Para usar estas opciones, primero debe subir el archivo JAR del controlador JDBC a Amazon S3.

  - `"customJdbcDriverS3Path"`: ruta de Amazon S3 del controlador JDBC personalizado.
  - `"customJdbcDriverClassName"`: nombre de clase del controlador JDBC.
- `"bulkSize"`: (opcional) se utiliza para configurar inserciones paralelas para acelerar las cargas masivas en los objetivos de JDBC. Especifique un valor entero para el grado de paralelismo que se utilizará al escribir o insertar datos. Esta opción resulta útil para mejorar el rendimiento de las escrituras en bases de datos como el repositorio de usuarios de Arch (AUR).

- `"hashfield"` (Opcional) Una cadena, utilizada para especificar el nombre de una columna de la tabla JDBC que se utilizará para dividir los datos en particiones al leer tablas JDBC en paralelo. Proporcione “hashfield” O “hashexpression”. Para obtener más información, consulte the section called “Lectura desde JDBC en paralelo”.
- `"hashexpression"` (Opcional) Una cláusula de selección de SQL que devuelve un número entero. Se utiliza para dividir los datos de una tabla JDBC en particiones al leer tablas JDBC en paralelo. Proporcione “hashfield” O “hashexpression”. Para obtener más información, consulte the section called “Lectura desde JDBC en paralelo”.
- `"hashpartitions"` (Opcional) Un entero positivo. Se utiliza para especificar el número de lecturas paralelas de la tabla JDBC al leer tablas JDBC en paralelo. Valor predeterminado: 7. Para obtener más información, consulte the section called “Lectura desde JDBC en paralelo”.
- `"sampleQuery"`: (Opcional) Una instrucción de consulta SQL personalizada. Se utiliza para especificar un subconjunto de información en una tabla para recuperar una muestra del contenido de la tabla. Cuando se configura sin tener en cuenta los datos, puede ser menos eficiente que los métodos DynamicFrame y provocar tiempos de espera o errores de falta de memoria. Para obtener más información, consulte the section called “Utilice sampleQuery”.
- `"enablePartitioningForSampleQuery"`: (Opcional) Un booleano. Valor predeterminado: falso. Se utiliza para permitir la lectura de tablas JDBC en paralelo al especificar `sampleQuery`. Si se establece en true, **`sampleQuery`** debe terminar con “where” (dónde) o “and” (y) para que Glue AWS agregue condiciones de partición. Para obtener más información, consulte the section called “Utilice sampleQuery”.
- `"sampleSize"`: (Opcional) Un entero positivo. Limita el número de filas que devuelve la consulta de ejemplo. Funciona solo cuando `enablePartitioningForSampleQuery` es true. Si la partición no está habilitada, en su lugar debe agregar `"limit x"` en el `sampleQuery` para limitar el tamaño. Para obtener más información, consulte the section called “Utilice sampleQuery”.

Utilice sampleQuery

En esta sección, se explica cómo utilizar `sampleQuery`, `sampleSize` y `enablePartitioningForSampleQuery`.

`sampleQuery` puede ser una forma eficaz de muestrear algunas filas de su conjunto de datos. De forma predeterminada, la consulta la ejecuta un ejecutor único. Cuando se configura sin tener en cuenta los datos, puede ser menos eficiente que los métodos DynamicFrame y provocar tiempos de espera o errores de falta de memoria. Por lo general, solo es necesario ejecutar SQL en la base de datos subyacente como parte de la canalización de ETL por motivos de rendimiento. Si intenta

obtener una vista previa de algunas filas de su conjunto de datos, considere utilizar the section called “show”. Si intenta transformar su conjunto de datos mediante SQL, considere utilizar the section called “toDF” para definir una transformación de SparkSQL contra sus datos en forma de DataFrame.

Si bien su consulta puede manipular una variedad de tablas, `dbtable` sigue siendo obligatoria.

Uso de sampleQuery para recuperar una muestra de la tabla

Cuando se utiliza el comportamiento predeterminado de sampleQuery para recuperar una muestra de los datos, Glue AWS no espera un rendimiento sustancial, por lo que ejecuta la consulta en un único ejecutor. Para limitar los datos que proporciona y no causar problemas de rendimiento, sugerimos que proporcione una cláusula `LIMIT` a SQL.

Example Uso de sampleQuery sin particionar

En el siguiente ejemplo de código, se muestra cómo utilizar `sampleQuery` sin particionar.

```
//A full sql query statement.
val query = "select name from $tableName where age > 0 limit 1"
val connectionOptions = JsonOptions(Map(
    "url" -> url,
    "dbtable" -> tableName,
    "user" -> user,
    "password" -> password,
    "sampleQuery" -> query ))
val dyf = glueContext.getSource("mysql", connectionOptions)
          .getDynamicFrame()
```

Uso de sampleQuery contra conjuntos de datos más grandes

Si está leyendo un conjunto de datos grande, es posible que tenga que habilitar las particiones de JDBC para consultar una tabla en paralelo. Para obtener más información, consulte the section called “Lectura desde JDBC en paralelo”. Para utilizar `sampleQuery` con la partición JDBC,configure `enablePartitioningForSampleQuery` como true. La activación de esta característica requiere que realice algunos cambios en su `sampleQuery`.

Cuando utilice la partición JDBC con `sampleQuery`, la consulta debe terminar con “where” (dónde) o “and” (y) para que Glue AWS agregue condiciones de partición.

Si desea limitar los resultados de su sampleQuery al leer tablas JDBC en paralelo, defina el parámetro `"sampleSize"` en lugar de especificar una cláusula `LIMIT`.

Example Uso de sampleQuery con particiones JDBC

En el siguiente ejemplo de código, se muestra cómo utilizar `sampleQuery` con partición JDBC.

```
//note that the query should end with "where" or "and" if use with JDBC partitioning.
val query = "select name from $tableName where age > 0 and"

//Enable JDBC partitioning by setting hashfield.
//to use sampleQuery with partitioning, set enablePartitioningForSampleQuery.
//use sampleSize to limit the size of returned data.
val connectionOptions = JsonOptions(Map(
    "url" -> url,
    "dbtable" -> tableName,
    "user" -> user,
    "password" -> password,
    "hashfield" -> primaryKey,
    "sampleQuery" -> query,
    "enablePartitioningForSampleQuery" -> true,
    "sampleSize" -> "1" ))
val dyf = glueContext.getSource("mysql", connectionOptions)
          .getDynamicFrame()
```

Notas y restricciones:

Las consultas de muestra no se pueden utilizar junto con los marcadores de trabajo. Se ignorará el estado del marcador cuando se brinden configuraciones para ambos.

Utilice un controlador JDBC personalizado

En los ejemplos de código siguientes, se muestra cómo se utilizan controladores JDBC personalizados para leer bases de datos JDBC y escribir en ellas. En ellos, se muestra cómo se lee una versión de un producto de base de datos y se escribe en una versión posterior del mismo producto.

Python

```
import sys
from awsglue.transforms import *
from awsglue.utils import getResolvedOptions
from pyspark.context import SparkContext, SparkConf
from awsglue.context import GlueContext
from awsglue.job import Job
import time
```

```
from pyspark.sql.types import StructType, StructField, IntegerType, StringType

sc = SparkContext()
glueContext = GlueContext(sc)
spark = glueContext.spark_session

# Construct JDBC connection options
connection_mysql5_options = {
    "url": "jdbc:mysql://<jdbc-host-name>:3306/db",
    "dbtable": "test",
    "user": "admin",
    "password": "pwd"}

connection_mysql8_options = {
    "url": "jdbc:mysql://<jdbc-host-name>:3306/db",
    "dbtable": "test",
    "user": "admin",
    "password": "pwd",
    "customJdbcDriverS3Path": "s3://amzn-s3-demo-bucket/mysql-connector-
java-8.0.17.jar",
    "customJdbcDriverClassName": "com.mysql.cj.jdbc.Driver"}

connection_oracle11_options = {
    "url": "jdbc:oracle:thin:@//<jdbc-host-name>:1521/ORCL",
    "dbtable": "test",
    "user": "admin",
    "password": "pwd"}

connection_oracle18_options = {
    "url": "jdbc:oracle:thin:@//<jdbc-host-name>:1521/ORCL",
    "dbtable": "test",
    "user": "admin",
    "password": "pwd",
    "customJdbcDriverS3Path": "s3://amzn-s3-demo-bucket/ojdbc10.jar",
    "customJdbcDriverClassName": "oracle.jdbc.OracleDriver"}

# Read from JDBC databases with custom driver
df_mysql8 = glueContext.create_dynamic_frame.from_options(connection_type="mysql",

 connection_options=connection_mysql8_options)

# Read DynamicFrame from MySQL 5 and write to MySQL 8
df_mysql5 = glueContext.create_dynamic_frame.from_options(connection_type="mysql",
```

```
 connection_options=connection_mysql5_options)
glueContext.write_from_options(frame_or_dfc=df_mysql5, connection_type="mysql",
                               connection_options=connection_mysql8_options)

# Read DynamicFrame from Oracle 11 and write to Oracle 18
df_oracle11 =
 glueContext.create_dynamic_frame.from_options(connection_type="oracle",

 connection_options=connection_oracle11_options)
glueContext.write_from_options(frame_or_dfc=df_oracle11, connection_type="oracle",
                               connection_options=connection_oracle18_options)
```

Scala

```
import com.amazonaws.services.glue.GlueContext
import com.amazonaws.services.glue.MappingSpec
import com.amazonaws.services.glue.errors.CallSite
import com.amazonaws.services.glue.util.GlueArgParser
import com.amazonaws.services.glue.util.Job
import com.amazonaws.services.glue.util.JsonOptions
import com.amazonaws.services.glue.DynamicFrame
import org.apache.spark.SparkContext
import scala.collection.JavaConverters._


object GlueApp {
  val MYSQL_5_URI: String = "jdbc:mysql://<jdbc-host-name>:3306/db"
  val MYSQL_8_URI: String = "jdbc:mysql://<jdbc-host-name>:3306/db"
  val ORACLE_11_URI: String = "jdbc:oracle:thin:@//<jdbc-host-name>:1521/ORCL"
  val ORACLE_18_URI: String = "jdbc:oracle:thin:@//<jdbc-host-name>:1521/ORCL"

  // Construct JDBC connection options
  lazy val mysql5JsonOption = jsonOptions(MYSQL_5_URI)
  lazy val mysql8JsonOption = customJDBCDriverJsonOptions(MYSQL_8_URI, "s3://amzn-
s3-demo-bucket/mysql-connector-java-8.0.17.jar", "com.mysql.cj.jdbc.Driver")
  lazy val oracle11JsonOption = jsonOptions(ORACLE_11_URI)
  lazy val oracle18JsonOption = customJDBCDriverJsonOptions(ORACLE_18_URI, "s3://
amzn-s3-demo-bucket/ojdbc10.jar", "oracle.jdbc.OracleDriver")

  def main(sysArgs: Array[String]): Unit = {
    val spark: SparkContext = new SparkContext()
```

```
    val glueContext: GlueContext = new GlueContext(spark)
    val args = GlueArgParser.getResolvedOptions(sysArgs, Seq("JOB_NAME").toArray)
    Job.init(args("JOB_NAME"), glueContext, args.asJava)

    // Read from JDBC database with custom driver
    val df_mysql8: DynamicFrame = glueContext.getSource("mysql",
 mysql8JsonOption).getDynamicFrame()

    // Read DynamicFrame from MySQL 5 and write to MySQL 8
    val df_mysql5: DynamicFrame = glueContext.getSource("mysql",
 mysql5JsonOption).getDynamicFrame()
    glueContext.getSink("mysql", mysql8JsonOption).writeDynamicFrame(df_mysql5)

    // Read DynamicFrame from Oracle 11 and write to Oracle 18
    val df_oracle11: DynamicFrame = glueContext.getSource("oracle",
 oracle11JsonOption).getDynamicFrame()
    glueContext.getSink("oracle", oracle18JsonOption).writeDynamicFrame(df_oracle11)

    Job.commit()
  }

  private def jsonOptions(url: String): JsonOptions = {
    new JsonOptions(
      s"""{"url": "${url}",
         |"dbtable":"test",
         |"user": "admin",
         |"password": "pwd"}""".stripMargin)
  }

  private def customJDBCDriverJsonOptions(url: String, customJdbcDriverS3Path:
 String, customJdbcDriverClassName: String): JsonOptions = {
    new JsonOptions(
      s"""{"url": "${url}",
         |"dbtable":"test",
         |"user": "admin",
         |"password": "pwd",
         |"customJdbcDriverS3Path": "${customJdbcDriverS3Path}",
         |"customJdbcDriverClassName" :
 "${customJdbcDriverClassName}"}""".stripMargin)
  }
}
```

Lectura desde tablas de JDBC en paralelo

Puede establecer las propiedades de su tabla de JDBC para permitir a AWS Glue leer datos en paralelo. Cuando establece determinadas propiedades, le indica a AWS Glue que ejecute consultas SQL en paralelo en particiones lógicas de sus datos. Puede controlar la partición mediante el establecimiento de un campo hash o una expresión hash. También puede controlar el número de lecturas en paralelo que se utilizan para obtener acceso a los datos.

La lectura paralela de tablas JDBC es una técnica de optimización que puede mejorar el rendimiento. Para obtener más información sobre el proceso de identificación de cuándo esta técnica es adecuada, consulte Reducir la cantidad de datos escaneados en la guía de Prácticas recomendadas para el ajuste del rendimiento de AWS Glue para trabajos de Apache Spark en las Recomendaciones de AWS.

Para habilitar las lecturas en paralelo, puede establecer pares clave-valor en el campo de parámetros de la estructura de tabla. Utilice la notación JSON para establecer un valor del campo de parámetros de la tabla. Para obtener más información acerca de la edición de las propiedades de una tabla, consulte Visualización y administración de los detalles de la tabla. También puede habilitar lecturas en paralelo cuando llama a los métodos de ETL (extraer, transformar y cargar) `create_dynamic_frame_from_options` y `create_dynamic_frame_from_catalog`. Para obtener más información sobre cómo especificar opciones en estos métodos, consulte from_options y from_catalog.

Puede utilizar este método para tablas de JDBC, es decir, la mayoría de tablas de datos cuya datos base es un almacén de datos de JDBC. Estas propiedades se ignoran cuando se leen las tablas de Amazon Redshift y Amazon S3.

hashfield

Establezca `hashfield` como el nombre de una columna de la tabla de JDBC que se va a utilizar para dividir los datos en particiones. Para obtener los mejores resultados, esta columna debe tener una distribución uniforme de valores para distribuir los datos entre particiones. Esta columna pueden ser de cualquier tipo de datos. AWS Glue genera consultas no solapadas que se ejecutan en paralelo para leer los datos particionados por esta columna. Por ejemplo, si los datos están distribuidos de manera uniforme por mes, puede utilizar la columna `month` para leer cada mes de datos en paralelo.

```
'hashfield': 'month'
```

AWS Glue crea una consulta para aplicar la función hash en el valor del campo y convertirlo en un número de partición, y ejecuta la consulta para todas las particiones en paralelo. Para utilizar su propia consulta para dividir la lectura de una tabla, proporcione `hashexpression` en lugar de `hashfield`.

hashexpression

Establezca `hashexpression` como una expresión SQL (que cumpla la gramática del motor de base de datos JDBC) que devuelve un número entero. Una expresión simple es el nombre de cualquier columna numérica en la tabla. AWS Glue genera consultas SQL para leer los datos de JDBC en paralelo mediante `hashexpression` en la cláusula `WHERE` para dividir los datos.

Por ejemplo, utilice la columna numérica `customerID` para leer los datos particionados por un número de cliente.

```
'hashexpression': 'customerID'
```

Para que AWS Glue controle la partición, proporcione `hashfield` en lugar de `hashexpression`.

hashpartitions

Establezca `hashpartitions` como el número de lecturas en paralelo de la tabla de JDBC. Si no se define esta propiedad, el valor predeterminado es 7.

Por ejemplo, establezca el número de lecturas en paralelo en `5`, de modo que AWS Glue lea los datos con cinco consultas (o menos).

```
'hashpartitions': '5'
```

Configuración de Amazon VPC para conexiones JDBC a los almacenes de datos de Amazon RDS de AWS Glue

Al utilizar JDBC para conectar las bases de datos en Amazon RDS, se necesitará realizar una configuración adicional. Para habilitar la comunicación entre los componentes de AWS Glue y

Amazon RDS, debe configurar el acceso a los almacenes de datos de Amazon RDS en Amazon VPC. Para que AWS Glue pueda comunicarse entre sus componentes, especifique un grupo de seguridad con una regla de entrada con autorreferencia para todos los puertos TCP. Al crear una regla con autorreferencia, se puede restringir el origen al mismo grupo de seguridad en la VPC. Una regla con autorreferencia no abrirá la VPC en todas las redes. Puede que el grupo de seguridad predeterminado de la VPC ya tenga una regla de entrada con autorreferencia para ALL Traffic.

Configuración del acceso entre AWS Glue y los almacenes de datos de Amazon RDS

1. Inicie sesión en la Consola de administración de AWS y abra la consola de Amazon RDS en https://console.aws.amazon.com/rds/.
2. En la consola de Amazon RDS, identifique los grupos de seguridad que se utilizan para controlar el acceso a la base de datos de Amazon RDS.

   En el panel de navegación a la izquierda, seleccione Bases de datos y, a continuación, seleccione la instancia a la que desea conectarse de la lista del panel principal.

   En la página de detalles de la base de datos, busque Grupos de seguridad de VPC dentro de la pestaña Conectividad y seguridad.
3. Según la arquitectura de la red, identifique qué grupo de seguridad asociado es mejor modificar para permitir el acceso al servicio de AWS Glue. Guarde el nombre *database-security-group* para consultarlo en el futuro. Si no hay un grupo de seguridad adecuado, siga las instrucciones para brindar acceso a la instancia de base de datos en la VPC con la creación de un grupo de seguridad en la documentación de Amazon RDS.
4. Inicie sesión en la Consola de administración de AWS y abra la consola de Amazon VPC en https://console.aws.amazon.com/vpc/.
5. En la consola de Amazon VPC, identifique cómo actualizar el *grupo de seguridad de la base de datos*.

   En el panel de navegación a la izquierda, seleccione Grupos de seguridad y, a continuación, seleccione *database-security-group* de la lista del panel principal.
6. Identifique el ID del grupo de seguridad para *database-security-group*, *database-sg-id*. Guárdelo para consultarlo en el futuro.

   En la página de detalles del grupo de seguridad, busque ID del grupo de seguridad.
7. Modifique las reglas de entrada del *database-security-group* y agregue una regla con autorreferencia para permitir que los componentes de AWS Glue se comuniquen. En concreto,

agregue o confirme que haya una regla en la que Tipo sea `All TCP`, Protocolo sea `TCP`, Intervalo de puertos incluya todos los puertos y Origen sea *`database-sg-id`*. Compruebe que el grupo de seguridad que introduzca en Origen sea el mismo que el grupo de seguridad que está editando.

En la página de detalles del grupo de seguridad, seleccione Editar reglas de entrada.

La regla de entrada tiene un aspecto similar al siguiente:

Tipo	Protocolo	Intervalo de puertos	Origen
Todos los TCP	TCP	0–65535	*`database-sg-id`*

8. Agregue reglas para el tráfico saliente.

   En la página de detalles del grupo de seguridad, seleccione Editar reglas de salida.

   En caso de que el grupo de seguridad permita todo el tráfico de salida, no se necesitan reglas independientes. Por ejemplo:

Tipo	Protocolo	Rango de puerto	Destino
All Traffic	ALL	ALL	0.0.0.0/0

   Si la arquitectura de red está diseñada para restringir el tráfico de salida, cree las siguientes reglas salientes:

   Cree una regla con autorreferencia en la que Tipo sea `All TCP`, Protocolo sea `TCP`, Intervalo de puertos incluya todos los puertos y Destino sea *`database-sg-id`*. Compruebe que el grupo de seguridad que introduzca en Destino sea el mismo que el grupo de seguridad que está editando.

   En caso de que se utilice un punto de conexión de VPC de Amazon S3, agregue una regla HTTPS para permitir el tráfico desde la VPC a Amazon S3. Cree una regla en la que Tipo sea `HTTPS`, Protocolo sea`TCP`, Intervalo de puertos sea `443` y Destino sea el ID de la lista de prefijos administrados para el punto de conexión de la puerta de enlace de Amazon S3, *`s3-prefix-list-id`*. Para obtener más información sobre las listas de prefijos y los puntos de conexión de la puerta de enlace de Amazon S3, consulte Gateway endpoints for Amazon S3 en la documentación de Amazon VPC.

Por ejemplo:

Tipo	Protocolo	Rango de puerto	Destino
Todos los TCP	TCP	0–65535	*database-sg-id*
HTTPS	TCP	443	*s3-prefix-list-id*

Conexiones a MongoDB

Puede usar AWS Glue for Spark para leer y escribir en tablas de MongoDB y MongoDB Atlas en AWS Glue 4.0 y versiones posteriores. Puede conectarse a MongoDB con las credenciales de nombre de usuario y contraseña almacenadas en AWS Secrets Manager a través de una conexión de AWS Glue.

Para obtener más información sobre MongoDB, consulte la documentación de MongoDB.

Configuración de las conexiones MongoDB

Para conectarte a MongoDB desde AWS Glue, necesitará sus credenciales de MongoDB, *mongodbUser* y *mongodbPass*.

Para conectarse a MongoDB desde AWS Glue, es posible que necesite algunos requisitos previos:

- Si su instancia de MongoDB está en una Amazon VPC, configure Amazon VPC para permitir que su trabajo de AWS Glue se comunique con la instancia de MongoDB sin que el tráfico atraviese la Internet pública.

  En Amazon VPC, identifique o cree una VPC, una subred y un grupo de seguridad que AWS Glue utilizará al ejecutar el trabajo. Además, debe asegurarse de que Amazon VPC esté configurada para permitir el tráfico de red entre su instancia de MongoDB y esta ubicación. Según el diseño de la red, esto puede requerir cambios en las reglas de los grupos de seguridad, las ACL de red, las puertas de enlace de NAT y las conexiones entre pares.

A continuación, puede proceder a configurar AWS Glue para su uso con MongoDB.

Para configurar una conexión a MongoDB:

1. Si lo desea, en AWS Secrets Manager, cree un secreto con sus credenciales de MongoDB. Para crear un secreto en Secrets Manager, siga el tutorial disponible en Crear un secreto AWS Secrets Manager en la documentación AWS Secrets Manager. Después de crear el secreto, conserve el nombre secreto, *secretName*, para el siguiente paso.

   - Al seleccionar pares clave/valor, genere un par para la clave `username` con el valor *mongodbUser*.

     Al seleccionar pares clave/valor, genere un par para la clave `password` con el valor *mongodbPass*.

2. En la consola de AWS Glue, genere una conexión mediante los pasos que se indican en the section called “Adición de una conexión de AWS Glue”. Tras crear la conexión, conserve el nombre de la conexión, *connectionName*, para el uso futuro en AWS Glue.

   - Al seleccionar un tipo de conexión, seleccione MongoDB o MongoDB Atlas.
   - Al seleccionar la URL de MongoDB o la URL de MongoDB Atlas, proporciona el nombre de host de la instancia de MongoDB.

     Se proporciona una URL de MongoDB en este formato `mongodb://`*mongoHost*`:`*mongoPort*`/`*mongoDBname*.

     Se proporciona una URL de MongoDB Atlas en este formato `mongodb+srv://`*mongoHost*`:`*mongoPort*`/`*mongoDBname*.

     Proporcionar la base de datos predeterminada para la conexión, *mongoDBname* es opcional.
   - Si eligió crear un secreto de Secrets Manager, elija el tipo de credencial AWS Secrets Manager.

     Luego, en AWS Secret, ingrese *secretName*.
   - Si decide proporcionar el nombre de usuario y la contraseña, proporcione *mongoDBuser* y *mongodbPass*.

3. En las siguientes situaciones, es posible que necesite una configuración adicional:

   - Para instancias de MongoDB alojadas AWS en una Amazon VPC

- Deberá proporcionar la información de conexión de Amazon VPC a la conexión AWS Glue que define sus credenciales de seguridad de MongoDB. Al crear o actualizar la conexión, configure los VPC, Subred y los grupos de seguridad en Opciones de red.

Tras crear una conexión AWS Glue MongoDB, tendrá que realizar las siguientes acciones antes de llamar a su método de conexión:

- Si ha decidido crear un secreto de Secrets Manager, conceda permiso al rol de IAM asociado a su trabajo de AWS Glue para leer *secretName*.
- En la configuración del trabajo de Glue AWS, proporcione *connectionName* como una conexión de red adicional.

Para usar su conexión AWS Glue MongoDB en AWS Glue for Spark, proporcione la opción `connectionName` en su llamada al método de conexión. Como alternativa, puede seguir los pasos que se describen en the section called “Integración con MongoDB” para utilizar la conexión junto con el catálogo de datos de AWS Glue.

Lectura de MongoDB mediante una conexión a AWS Glue

Requisitos previos:

- Una colección de MongoDB de la que quiera leer. Necesitará información de identificación para la colección.

  Una colección MongoDB se identifica mediante un nombre de base de datos y un nombre de colección, *mongodbName*, *mongodbCollection*.
- Una conexión AWS Glue MongoDB configurada para proporcionar información de autenticación. Complete los pasos del procedimiento anterior, Para configurar una conexión a MongoDB para configurar su información de autenticación. Necesitará el nombre de la conexión de AWS Glue, *connectionName*.

Por ejemplo:

```
mongodb_read = glueContext.create_dynamic_frame.from_options(
    connection_type="mongodb",
    connection_options={
        "connectionName": "connectionName",
        "database": "mongodbName",
```

```
        "collection": "mongodbCollection",
        "partitioner":
 "com.mongodb.spark.sql.connector.read.partitioner.SinglePartitionPartitioner",
        "partitionerOptions.partitionSizeMB": "10",
        "partitionerOptions.partitionKey": "_id",
        "disableUpdateUri": "false",
    }
)
```

Escribir en tablas de MongoDB

En este ejemplo se escribe información de un DynamicFrame existente, *dynamicFrame* en MongoDB.

Requisitos previos:

- Una colección de MongoDB a la que desearía escribir. Necesitará información de identificación para la colección.

  Una colección MongoDB se identifica mediante un nombre de base de datos y un nombre de colección, *mongodbName*, *mongodbCollection*.
- Una conexión AWS Glue MongoDB configurada para proporcionar información de autenticación. Complete los pasos del procedimiento anterior, Para configurar una conexión a MongoDB para configurar su información de autenticación. Necesitará el nombre de la conexión de AWS Glue, *connectionName*.

Por ejemplo:

```
glueContext.write_dynamic_frame.from_options(
    frame=dynamicFrame,
    connection_type="mongodb",
    connection_options={
        "connectionName": "connectionName",
        "database": "mongodbName",
        "collection": "mongodbCollection",
        "disableUpdateUri": "false",
        "retryWrites": "false",
    },
)
```

Leer y escribir en tablas de MongoDB

En este ejemplo se escribe información de un DynamicFrame existente, *dynamicFrame* en MongoDB.

Requisitos previos:

- Una colección de MongoDB de la que quiera leer. Necesitará información de identificación para la colección.

  Una colección de MongoDB a la que desearía escribir. Necesitará información de identificación para la colección.

  Una colección MongoDB se identifica mediante un nombre de base de datos y un nombre de colección, *mongodbName*, *mongodbCollection*.
- Información de autenticación de MongoDB, *mongodbUser* y *mongodbPassword*.

Por ejemplo:

Python

```
import sys
from awsglue.transforms import *
from awsglue.utils import getResolvedOptions
from pyspark.context import SparkContext, SparkConf
from awsglue.context import GlueContext
from awsglue.job import Job
import time

## @params: [JOB_NAME]
args = getResolvedOptions(sys.argv, ['JOB_NAME'])

sc = SparkContext()
glueContext = GlueContext(sc)
spark = glueContext.spark_session

job = Job(glueContext)
job.init(args['JOB_NAME'], args)

output_path = "s3://some_bucket/output/" + str(time.time()) + "/"
mongo_uri = "mongodb://<mongo-instanced-ip-address>:27017"
mongo_ssl_uri = "mongodb://<mongo-instanced-ip-address>:27017"
```

```
write_uri = "mongodb://<mongo-instanced-ip-address>:27017"

read_mongo_options = {
    "uri": mongo_uri,
    "database": "mongodbName",
    "collection": "mongodbCollection",
    "username": "mongodbUsername",
    "password": "mongodbPassword",
    "partitioner": "MongoSamplePartitioner",
    "partitionerOptions.partitionSizeMB": "10",
    "partitionerOptions.partitionKey": "_id"}

ssl_mongo_options = {
    "uri": mongo_ssl_uri,
    "database": "mongodbName",
    "collection": "mongodbCollection",
    "ssl": "true",
    "ssl.domain_match": "false"
}

write_mongo_options = {
    "uri": write_uri,
    "database": "mongodbName",
    "collection": "mongodbCollection",
    "username": "mongodbUsername",
    "password": "mongodbPassword",
}

# Get DynamicFrame from MongoDB
dynamic_frame =
 glueContext.create_dynamic_frame.from_options(connection_type="mongodb",

 connection_options=read_mongo_options)

# Write DynamicFrame to MongoDB
glueContext.write_dynamic_frame.from_options(dynamicFrame,
 connection_type="mongodb", connection_options=write_mongo_options)

job.commit()
```

Scala

```
import com.amazonaws.services.glue.GlueContext
```

```
import com.amazonaws.services.glue.MappingSpec
import com.amazonaws.services.glue.errors.CallSite
import com.amazonaws.services.glue.util.GlueArgParser
import com.amazonaws.services.glue.util.Job
import com.amazonaws.services.glue.util.JsonOptions
import com.amazonaws.services.glue.DynamicFrame
import org.apache.spark.SparkContext
import scala.collection.JavaConverters._

object GlueApp {
  val DEFAULT_URI: String = "mongodb://<mongo-instanced-ip-address>:27017"
  val WRITE_URI: String = "mongodb://<mongo-instanced-ip-address>:27017"
  lazy val defaultJsonOption = jsonOptions(DEFAULT_URI)
  lazy val writeJsonOption = jsonOptions(WRITE_URI)
  def main(sysArgs: Array[String]): Unit = {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)
    val args = GlueArgParser.getResolvedOptions(sysArgs, Seq("JOB_NAME").toArray)
    Job.init(args("JOB_NAME"), glueContext, args.asJava)

    // Get DynamicFrame from MongoDB
    val dynamicFrame: DynamicFrame = glueContext.getSource("mongodb",
 defaultJsonOption).getDynamicFrame()

    // Write DynamicFrame to MongoDB
    glueContext.getSink("mongodb", writeJsonOption).writeDynamicFrame(dynamicFrame)

    Job.commit()
  }

  private def jsonOptions(uri: String): JsonOptions = {
    new JsonOptions(
      s"""{"uri": "${uri}",
         |"database":"mongodbName",
         |"collection":"mongodbCollection",
         |"username": "mongodbUsername",
         |"password": "mongodbPassword",
         |"ssl":"true",
         |"ssl.domain_match":"false",
         |"partitioner": "MongoSamplePartitioner",
         |"partitionerOptions.partitionSizeMB": "10",
         |"partitionerOptions.partitionKey": "_id"}""".stripMargin)
  }
```

```
}
```

Referencia de opciones de conexión de MongoDB

Designa una conexión a MongoDB. Las opciones de conexión son distintas entre una conexión de origen y una conexión de receptor.

Estas propiedades de conexión se comparten entre las conexiones de origen y de receptor:

- `connectionName`: se utiliza para lectura/escritura. El nombre de una conexión AWS Glue MongoDB configurada para proporcionar información de autenticación y red a su método de conexión. Cuando se configura una conexión AWS Glue como se describe en la sección anterior, the section called “Configuración de MongoDB”, el suministro `connectionName` sustituirá la necesidad de proporcionar las opciones de conexión `"uri"`, `"username"` y `"password"`.
- `"uri"`: (obligatorio) el host de MongoDB del que se va a leer, con formato `mongodb://<host>:<port>`. Se utiliza en las versiones de AWS Glue anteriores a AWS Glue 4.0.
- `"connection.uri"`: (obligatorio) el host de MongoDB del que se va a leer, con formato `mongodb://<host>:<port>`. Es compatible con la versión AWS Glue 4.0 y posteriores.
- `"username"`: (obligatorio) el nombre de usuario de MongoDB.
- `"password"`: (obligatorio) la contraseña de MongoDB.
- `"database"`: (obligatorio) la base de datos de MongoDB de la que se va a leer. Esta opción también se puede transferir a `additional_options` al llamar a `glue_context.create_dynamic_frame_from_catalog` en su script de trabajo.
- `"collection"`: (obligatorio) la colección de MongoDB de la que se va a leer. Esta opción también se puede transferir a `additional_options` al llamar a `glue_context.create_dynamic_frame_from_catalog` en su script de trabajo.

"connectionType": "mongodb" como origen

Utilice las siguientes opciones de conexión con `"connectionType": "mongodb"` como origen:

- `"ssl"`: (opcional) si es `true`, inicia una conexión SSL. El valor predeterminado es `false`.
- `"ssl.domain_match"`: (opcional) si es `true` y `ssl` es `true`, se realiza la comprobación de coincidencia de dominio. El valor predeterminado es `true`.
- `"batchSize"`: (opcional): el número de documentos que se deben devolver por lote, que se utilizan dentro del cursor de lotes internos.

- `"partitioner"`: (opcional): el nombre de la clase del particionador para leer los datos de entrada de MongoDB. El conector proporciona los siguientes particionadores:
  - `MongoDefaultPartitioner` (predeterminado) (No compatible con AWS Glue 4.0)
  - `MongoSamplePartitioner` (Requiere MongoDB 3.2 o posterior) (No es compatible con AWS Glue 4.0)
  - `MongoShardedPartitioner` (No es compatible con AWS Glue 4.0)
  - `MongoSplitVectorPartitioner` (No es compatible con AWS Glue 4.0)
  - `MongoPaginateByCountPartitioner` (No es compatible con AWS Glue 4.0)
  - `MongoPaginateBySizePartitioner` (No es compatible con AWS Glue 4.0)
  - `com.mongodb.spark.sql.connector.read.partitioner.SinglePartitionPartitioner`
  - `com.mongodb.spark.sql.connector.read.partitioner.ShardedPartitioner`
  - `com.mongodb.spark.sql.connector.read.partitioner.PaginateIntoPartitionsPartit`
- `"partitionerOptions"` (opcional): opciones para el particionador designado. Se admiten las siguientes opciones para cada particionador:
  - `MongoSamplePartitioner`: `partitionKey`, `partitionSizeMB`, `samplesPerPartition`
  - `MongoShardedPartitioner`: `shardkey`
  - `MongoSplitVectorPartitioner`: `partitionKey`, `partitionSizeMB`
  - `MongoPaginateByCountPartitioner`: `partitionKey`, `numberOfPartitions`
  - `MongoPaginateBySizePartitioner`: `partitionKey`, `partitionSizeMB`

  Para obtener más información acerca de estas opciones, consulte Partitioner Configuration en la documentación de MongoDB.

"connectionType": "mongodb" como receptor

Utilice las siguientes opciones de conexión con `"connectionType": "mongodb"` como receptor:

- `"ssl"`: (opcional) si es `true`, inicia una conexión SSL. El valor predeterminado es `false`.
- `"ssl.domain_match"`: (opcional) si es `true` y `ssl` es `true`, se realiza la comprobación de coincidencia de dominio. El valor predeterminado es `true`.
- `"extendedBsonTypes"`: (opcional) si es `true`, habilitan los tipos de BSON ampliados al escribir datos en MongoDB. El valor predeterminado es `true`.

- `"replaceDocument"`: (opcional) si es `true`, reemplaza todo el documento al guardar conjuntos de datos que contienen un campo `_id`. Si es `false`, solo se actualizan los campos del documento que coinciden con los campos del conjunto de datos. El valor predeterminado es `true`.
- `"maxBatchSize"`: (opcional): el tamaño máximo del lote para operaciones en bloque al guardar datos. El valor predeterminado es 512.
- `"retryWrites"`: (Opcional): reintenta automáticamente determinadas operaciones de escritura una sola vez si AWS Glue detecta un error de red.

Conexiones SAP HANA

Puede usar AWS Glue for Spark para leer y escribir en tablas de SAP HANA en AWS Glue 4.0 y versiones posteriores. Puede definir qué leer desde SAP HANA con una consulta SQL. Se conecta a SAP HANA con las credenciales JDBC almacenadas en AWS Secrets Manager a través de una conexión de AWS Glue SAP HANA.

Para obtener más información sobre SAP HANA JDBC, consulte la documentación de SAP HANA.

Configuración de conexiones SAP HANA

Para conectarse a SAP HANA desde AWS Glue, tendrá que crear y almacenar las credenciales de SAP HANA en un AWS Secrets Manager secreto y, a continuación, asociar ese secreto a una conexión de SAP HANA AWS Glue. Deberá configurar la conectividad de red entre su servicio SAP HANA y AWS Glue.

Para conectarse a SAP HANA, es posible que necesite algunos requisitos previos:

- Si su servicio SAP HANA está en una Amazon VPC, configure Amazon VPC para permitir que su trabajo de AWS Glue comunique con el servicio SAP HANA sin que el tráfico atraviese la Internet pública.

  En Amazon VPC, identifique o cree una VPC, una subred y un grupo de seguridad que AWS Glue utilizará al ejecutar el trabajo. Además, debe asegurarse de que Amazon VPC esté configurada para permitir el tráfico de red entre su punto de conexión SAP HANA y esta ubicación. Su trabajo deberá establecer una conexión TCP con su puerto JDBC de SAP HANA. Para obtener más información sobre los puertos de SAP HANA, consulte la documentación de SAP HANA. Según el diseño de la red, esto puede requerir cambios en las reglas de los grupos de seguridad, las ACL de red, las puertas de enlace de NAT y las conexiones entre pares.

- No hay requisitos previos adicionales si se puede acceder a su punto de conexión de SAP HANA a través de Internet.

Para configurar una conexión a SAP HANA:

1. En AWS Secrets Manager, cree un secreto con sus credenciales de SAP HANA. Para crear un secreto en Secrets Manager, siga el tutorial disponible en Crear un secreto AWS Secrets Manager en la documentación AWS Secrets Manager. Después de crear el secreto, conserve el nombre secreto, *secretName*, para el siguiente paso.

   - Al seleccionar pares clave/valor, genere un par para la clave `username/USERNAME` con el valor *saphanaUsername*.
   - Al seleccionar pares clave/valor, genere un par para la clave `password/PASSWORD` con el valor *saphanaPassword*.

2. En la consola de AWS Glue, genere una conexión mediante los pasos que se indican en the section called “Adición de una conexión de AWS Glue”. Tras crear la conexión, conserve el nombre de la conexión, *connectionName*, para el uso futuro en AWS Glue.

   - Al seleccionar un tipo de conexión, seleccione SAP HANA.
   - Al proporcionar la URL de SAP HANA, proporcione la URL de su instancia.

     Las URL de JDBC de SAP HANA tienen el formato `jdbc:sap://`*saphanaHostname*`:`*saphanaPort*`/?`*databaseName*`=`*saphanaDBname*`,`*Paramete*

     AWS Glue requiere los siguientes parámetros de URL de JDBC:

     - `databaseName` — Una base de datos predeterminada en SAP HANA a la que conectarse.
   - Al seleccionar un secreto AWS, proporcione un *secretName*.

Tras crear una conexión con AWS Glue SAP HANA, deberá realizar los siguientes pasos antes de ejecutar su trabajo de AWS Glue:

- Otorgue al rol de IAM asociado al trabajo de AWS Glue el permiso para leer *secretName*.
- En la configuración del trabajo de Glue AWS, proporcione *connectionName* como una conexión de red adicional.

Lectura de tablas de SAP HANA

Requisitos previos:

- Una tabla de SAP HANA desde la cual le gustaría leer. Necesitará información de la identificación para la tabla.

  Se puede especificar una tabla con un nombre de tabla y un nombre de esquema de SAP HANA, en la forma *schemaName*.*tableName*. El nombre del esquema y el separador "." no son necesarios si la tabla está en el esquema predeterminado, "public". Esto se llama *tableIdentifier*. Tenga en cuenta que la base de datos se proporciona como un parámetro de URL de JDBC en `connectionName`.
- Una conexión AWS Glue SAP HANA configurada para proporcionar información de autenticación. Complete los pasos del procedimiento anterior, Para configurar una conexión a SAP HANA y configurar su información de autenticación. Necesitará el nombre de la conexión de AWS Glue, *connectionName*.

Por ejemplo:

```
saphana_read_table = glueContext.create_dynamic_frame.from_options(
    connection_type="saphana",
    connection_options={
        "connectionName": "connectionName",
        "dbtable": "tableIdentifier",
    }
)
```

También puede proporcionar una consulta SELECT SQL para filtrar los resultados devueltos a su DynamicFrame. Deberá configurar `query`.

Por ejemplo:

```
saphana_read_query = glueContext.create_dynamic_frame.from_options(
    connection_type="saphana",
    connection_options={
        "connectionName": "connectionName",
        "query": "query"
    }
)
```

Escribir en tablas de SAP HANA

Este ejemplo escribe información de un DynamicFrame existente, *dynamicFrame* en SAP HANA. Si la tabla ya contiene información, AWS Glue generará un error.

Requisitos previos:

- Una tabla de SAP HANA en la cual le gustaría escribir.

  Se puede especificar una tabla con un nombre de tabla y un nombre de esquema de SAP HANA, en la forma *schemaName*.*tableName*. El nombre del esquema y el separador "." no son necesarios si la tabla está en el esquema predeterminado, "public". Esto se llama *tableIdentifier*. Tenga en cuenta que la base de datos se proporciona como un parámetro de URL de JDBC en `connectionName`.
- Información de autenticación de SAP HANA. Complete los pasos del procedimiento anterior, Para configurar una conexión a SAP HANA y configurar su información de autenticación. Necesitará el nombre de la conexión de AWS Glue, *connectionName*.

Por ejemplo:

```
options = {
    "connectionName": "connectionName",
    "dbtable": 'tableIdentifier'
}

    saphana_write = glueContext.write_dynamic_frame.from_options(
        frame=dynamicFrame,
        connection_type="saphana",
        connection_options=options
)
```

Referencia de opciones de conexión de SAP HANA

- `connectionName`: obligatorio. Se utiliza para lectura/escritura. El nombre de una conexión de AWS Glue SAP HANA configurada para proporcionar información de autenticación y red a su método de conexión.
- `databaseName`: se utiliza para lectura/escritura. Valores válidos: nombres de las bases de datos en SAP HANA. Nombre de la base de datos a la que se va a conectar.

- `dbtable` — Necesario para escribir, obligatorio para leer a menos que se proporcione `query`. Se utiliza para lectura/escritura. Valores válidos: contenido de una cláusula SQL FROM de SAP HANA. Identifica una tabla en SAP HANA a la que conectarse. También puede proporcionar un SQL distinto del nombre de una tabla, como una subconsulta. Para obtener más información, consulte la cláusula From en la documentación de SAP HANA.
- `query`: se utiliza para leer. Una consulta de SAP HANA SQL SELECT que define lo que se debe recuperar al leer información de SAP HANA.

Conexiones Snowflake

Puede usar Glue for Spark AWS para leer y escribir en tablas de Snowflake en Glue 4.0 AWS y versiones posteriores. Puede leer desde Snowflake con una consulta SQL. Puede conectarse a Snowflake mediante un usuario y una contraseña. Puede consultar las credenciales de Snowflake almacenadas en AWS Secrets Manager a través del catálogo de datos de Glue AWS. Las credenciales de Snowflake del catálogo de datos para Glue for Spark AWS se almacenan por separado de las credenciales de Snowflake del catálogo de datos para los rastreadores. Debe elegir un tipo de conexión `SNOWFLAKE` y no un tipo de conexión `JDBC` configurado para conectarse a Snowflake.

Para obtener más información acerca de Snowflake, consulte el sitio web de Snowflake. Para obtener más información sobre Snowflake en AWS, consulte Snowflake Data Warehouse en Amazon Web Services.

Configuración de las conexiones de Snowflake

No hay requisitos previos AWS para conectarse a las bases de datos de Snowflake disponibles a través de Internet.

Si lo desea, puede realizar la siguiente configuración para gestionar las credenciales de conexión con Glue AWS.

Para gestionar sus credenciales de conexión con Glue AWS

1. En Snowflake, genere un usuario *`snowflakeUser`* y una contraseña *`snowflakePassword`*.
2. En AWS Secrets Manager, cree un secreto con sus credenciales de Snowflake. Para crear un secreto en Secrets Manager, siga el tutorial disponible en Crear un secreto AWS Secrets Manager en la documentación AWS Secrets Manager. Después de crear el secreto, conserve el nombre secreto, *`secretName`*, para el siguiente paso.

- Al seleccionar pares clave/valor, cree un par para *snowflakeUser* con la clave USERNAME.
- Al seleccionar pares clave/valor, cree un par para *snowflakePassword* con la clave PASSWORD.
- Al seleccionar los pares clave/valor, puede proporcionar su almacén de Snowflake con la clave sfWarehouse.
- Cuando selecciona pares clave/valor, puede proporcionar propiedades de conexión adicionales de Snowflake utilizando sus nombres de propiedad de Spark correspondientes como claves. Entre las propiedades compatibles se incluyen las siguientes:
  - sfDatabase: nombre de base de datos de Snowflake
  - sfSchema: nombre del esquema de Snowflake
  - sfRole: nombre de rol de Snowflake
  - pem_private_key: clave privada para la autenticación por par de claves

3. En el catálogo de datos de AWS Glue, seleccione Conexiones y, a continuación, Crear conexión para crear una conexión. Siga los pasos del asistente de conexión para completar el proceso:
   - Al seleccionar un origen de datos, seleccione Snowflake y, a continuación, elija Siguiente.
   - Introduzca los detalles de la conexión, como el host y el puerto. Al introducir el host URL de Snowflake, proporcione la URL de la instancia de Snowflake. La URL generalmente utilizará un nombre de host en el formulario *account_identifier*.snowflakecomputing.com. Sin embargo, el formato de la URL puede variar en función del tipo de cuenta de Snowflake (por ejemplo, AWS, alojada en Azure o en Snowflake).
   - Al seleccionar el rol de servicio de IAM, elija desde el menú desplegable. Este es el rol de IAM de su cuenta que se utilizará para acceder a AWS Secrets Manager y asignar la IP si se especifica la VPC.
   - Al seleccionar un secreto AWS, proporcione un *secretName*.
4. En el siguiente paso del asistente, defina las propiedades de la conexión a Snowflake.
5. En el último paso del asistente, revise la configuración y luego complete el proceso para crear la conexión.

En las siguientes situaciones, es posible que necesite lo siguiente:

- Para Snowflake alojado en AWS en una Amazon VPC

- Necesitará la configuración de Amazon VPC adecuada para Snowflake. Para obtener más información sobre cómo configurar su Amazon VPC, consulte AWS PrivateLink & Snowflake en la documentación de Snowflake.
- Necesitará la configuración de Amazon VPC adecuada para AWS Glue. the section called "Configuración de puntos de conexión de la VPC de tipo interfaz (AWS PrivateLink) para AWS Glue ".
- Deberá crear una conexión al Catálogo de datos de AWS Glue que proporcione la información de conexión de Amazon VPC (además del identificador de un secreto de AWS Secrets Manager que defina sus credenciales de seguridad de Snowflake). Su URL cambiará cuando utilice AWS PrivateLink, tal y como se describe en la documentación de Snowflake vinculada en un artículo anterior.
- Necesitará que la configuración de su trabajo incluya la conexión de catálogo de datos como una conexión de red adicional.

Lectura de tablas de Snowflake

Requisitos previos: una tabla de Snowflake de la que quiera leer. Necesitará el nombre de la tabla Snowflake, *tableName.* Necesitará la URL de Snowflake*snowflakeUrl*, el nombre de usuario *snowflakeUser* y la contraseña *snowflakePassword*. Si su usuario de Snowflake no tiene establecido un espacio de nombres predeterminado, necesitará el nombre de la base de datos de Snowflake *databaseName* y el nombre del esquema *schemaName.* Además, si su usuario de Snowflake no tiene un conjunto de almacenes predeterminado, necesitará un nombre de almacén *warehouseName.*

Por ejemplo:

Requisitos previos adicionales: complete los pasos para gestionar credenciales de conexión con Glue AWS para configurar *snowflakeUrl*, *snowflakeUsername* y *snowflakePassword*. Para revisar estos pasos, consulte la sección anterior the section called "Configuración de Snowflake". Para seleccionar con qué conexión de red adicional nos vamos a conectar, utilizaremos el parámetro `connectionName`.

```
snowflake_read = glueContext.create_dynamic_frame.from_options(
  connection_type="snowflake",
  connection_options={
        "connectionName": "connectionName",
        "dbtable": "tableName",
        "sfDatabase": "databaseName",
```

```
        "sfSchema": "schemaName",
        "sfWarehouse": "warehouseName",
    }
)
```

Además, puede usar los parámetros `autopushdown` y `query` para leer una parte de una tabla de Snowflake. Esto puede ser considerablemente más eficiente que filtrar los resultados después de haberlos cargado en Spark. Considere un ejemplo en el que todas las ventas se almacenan en la misma tabla, pero solo necesita analizar las ventas de una tienda determinada los días festivos. Si esa información está almacenada en la tabla, podría utilizar la función de inserción de predicados para recuperar los resultados de la siguiente manera:

```
snowflake_node = glueContext.create_dynamic_frame.from_options(
    connection_type="snowflake",
    connection_options={
        "autopushdown": "on",
        "query": "select * from sales where store='1' and IsHoliday='TRUE'",
        "connectionName": "snowflake-glue-conn",
        "sfDatabase": "databaseName",
        "sfSchema": "schemaName",
        "sfWarehouse": "warehouseName",
    }
)
```

Escribir en tablas de Snowflake

Requisitos previos: una base de datos de Snowflake a la que desearía escribir. Necesitará un nombre de tabla actual o deseado, *`tableName`*. Necesitará la URL de Snowflake*`snowflakeUrl`*, el nombre de usuario *`snowflakeUser`* y la contraseña *`snowflakePassword`*. Si su usuario de Snowflake no tiene establecido un espacio de nombres predeterminado, necesitará el nombre de la base de datos de Snowflake *`databaseName`* y el nombre del esquema *`schemaName.`* Además, si su usuario de Snowflake no tiene un conjunto de almacenes predeterminado, necesitará un nombre de almacén *`warehouseName.`*

Por ejemplo:

Requisitos previos adicionales: complete los pasos para gestionar credenciales de conexión con Glue AWS para configurar *`snowflakeUrl`*, *`snowflakeUsername`* y *`snowflakePassword`*. Para revisar estos pasos, consulte la sección anterior the section called “Configuración de Snowflake”.

Para seleccionar con qué conexión de red adicional nos vamos a conectar, utilizaremos el parámetro `connectionName`.

```
glueContext.write_dynamic_frame.from_options(
    connection_type="snowflake",
    connection_options={
        "connectionName": "connectionName",
        "dbtable": "tableName",
        "sfDatabase": "databaseName",
        "sfSchema": "schemaName",
        "sfWarehouse": "warehouseName",
    },
)
```

Referencia de la opción de conexión Snowflake

El tipo de conexión Snowflake tiene las siguientes opciones de conexión:

Puede recuperar algunos de los parámetros de esta sección desde una conexión de catálogo de datos (`sfUrl`, `sfUser`, `sfPassword`), en cuyo caso no tendrá que proporcionarlos. Puede hacerlo al proporcionar el parámetro `connectionName`.

Puede recuperar los parámetros de conexión de los secretos de AWS Secrets Manager con el parámetro `secretId`. Al usar Secrets Manager, las siguientes propiedades de Spark se pueden recuperar automáticamente si están presentes en el secreto:

- `sfUser` (con la clave `USERNAME` o `sfUser`)
- `sfPassword` (con la clave `PASSWORD` o `sfPassword`)
- `sfWarehouse` (con la clave `sfWarehouse`)
- `sfDatabase` (con la clave `sfDatabase`)
- `sfSchema` (con la clave `sfSchema`)
- `sfRole` (con la clave `sfRole`)
- `pem_private_key` (con la clave `pem_private_key`)

Orden de prioridad de las propiedades: cuando se especifica la misma propiedad en varias ubicaciones, AWS Glue utiliza el siguiente orden de prioridad (de mayor a menor):

1. Opciones de conexión proporcionadas explícitamente en el código de trabajo

2. Propiedades de la conexión del catálogo de datos
3. Valores secretos de AWS Secrets Manager (cuando se especifica `secretId`)
4. Valores predeterminados de Snowflake

Los siguientes parámetros se utilizan generalmente cuando se conecta a Snowflake.

- `sfDatabase` — Obligatorio si el usuario predeterminado no está configurado en Snowflake. Se utiliza para lectura/escritura. La base de datos que se utilizará en la sesión después de conectarse.
- `sfSchema` — Obligatorio si el usuario predeterminado no está configurado en Snowflake. Se utiliza para lectura/escritura. El esquema que se utilizará en la sesión después de conectarse.
- `sfWarehouse` — Obligatorio si el usuario predeterminado no está configurado en Snowflake. Se utiliza para lectura/escritura. El almacén virtual predeterminado que se utilizará en la sesión después de la conexión.
- `sfRole` — Obligatorio si el usuario predeterminado no está configurado en Snowflake. Se utiliza para lectura/escritura. Rol de seguridad predeterminado que se utilizará en la sesión después de conectarse.
- `sfUrl` — (Obligatorio) Se utiliza para lectura/escritura. Especifica el nombre de host para su cuenta en el siguiente formato: *`account_identifier`*`.snowflakecomputing.com`. Para obtener más información sobre los identificadores de cuenta, consulte los identificadores de cuenta en la documentación de Snowflake.
- `sfUser` — (Obligatorio) Se utiliza para lectura/escritura. Nombre de inicio de sesión del usuario de Snowflake.
- `sfPassword`: (Obligatorio a menos que `pem_private_key` se proporcione) Se utiliza para lectura/escritura. Contraseña del usuario de Snowflake.
- `dbtable` — Obligatorio cuando se trabaja con tablas completas. Se utiliza para lectura/escritura. Nombre de la tabla que se va a leer o de la tabla en la que se escriben los datos. Al leer, se recuperan todas las columnas y registros.
- `pem_private_key`: se utiliza para lectura/escritura. Cadena de clave privada codificada en b64 sin cifrar. La clave privada para el usuario de Snowflake. Es habitual copiarla de un archivo PEM. Para obtener más información, consulte Key-pair authentication and key-pair rotation en la documentación de Snowflake.
- `query` — Obligatorio cuando se lee con una consulta. Se usa para leer. La consulta exacta (instrucción `SELECT`) que se va a ejecutar

Las siguientes opciones se utilizan para configurar comportamientos específicos durante el proceso de conexión a Snowflake.

- `preactions`: se utiliza para lectura/escritura. Valores válidos: lista de declaraciones SQL separadas por punto y coma como cadena. Las declaraciones SQL se ejecutan antes de que los datos se transfieran entre Glue AWS y Snowflake. Si una instrucción contiene `%s`, el `%s` se sustituye por el nombre de la tabla a la que se hace referencia para la operación.
- `postactions`: se utiliza para lectura/escritura. Las declaraciones SQL se ejecutan después de transferir los datos entre Glue AWS y Snowflake. Si una instrucción contiene `%s`, el `%s` se sustituye por el nombre de la tabla a la que se hace referencia para la operación.
- `autopushdown` — Predeterminado: `"on"`. Valores válidos: `"on"`, `"off"`. Este parámetro controla si la inserción de visualización automática de consultas está habilitada. Si la función pushdown está habilitada, cuando se ejecuta una consulta en Spark, si parte de la consulta se puede "enviar" al servidor de Snowflake, se empuja hacia abajo. Esto mejora el rendimiento de algunas consultas. Para obtener información sobre si la consulta se puede enviar hacia abajo, consulte Pushdown en la documentación de Snowflake.

Además, algunas de las opciones disponibles en el conector Snowflake Spark pueden ser compatibles con Glue AWS. Para obtener más información sobre las opciones disponibles en el conector Snowflake Spark, consulte Configuración de las opciones de configuración del conector en la documentación de Snowflake.

Métodos de autenticación de Snowflake

AWS Glue admite los siguientes métodos de autenticación para conectarse a Snowflake:

- Autenticación de nombre de usuario y contraseña: proporcione los parámetros `sfUser` y `sfPassword`.
- Autenticación por par de claves: proporcione los parámetros `sfUser` y `pem_private_key`. Cuando se utiliza la autenticación por par de claves, el parámetro `sfPassword` no es necesario.

Ambos métodos de autenticación son totalmente compatibles y se pueden configurar mediante cualquier combinación de opciones de conexión, conexiones al catálogo de datos o secretos de AWS Secrets Manager.

Limitaciones del conector Snowflake

La conexión a Snowflake con Glue for Spark AWS está sujeta a las siguientes limitaciones.

- Este conector no admite marcadores de trabajo. Para más información acerca de los marcadores de trabajo, consulte the section called “Seguimiento de los datos procesados mediante marcadores de trabajo”.
- Este conector no admite las lecturas y escrituras de Snowflake en las tablas del catálogo de datos de Glue AWS mediante los métodos `create_dynamic_frame.from_catalog` y `write_dynamic_frame.from_catalog`.
- Este conector admite la autenticación de nombre de usuario y contraseña y la autenticación de par de claves. Actualmente, no se admiten otros métodos de autenticación (como OAuth o SAML).
- Este conector no es compatible con los trabajos de streaming.
- Este conector admite consultas basadas en declaraciones `SELECT` al recuperar información (por ejemplo, con el parámetro `query`). No se admiten otros tipos de consultas (como `SHOW`, `DESC` o declaraciones DML).
- Snowflake limita el tamaño del texto de consulta (es decir, las instrucciones SQL) enviada a través de los clientes de Snowflake a 1 MB por instrucción. Para obtener más información, consulte Límites del tamaño del texto de la consulta.

Conexiones Teradata Vantage

Puede usar AWS Glue for Spark para leer y escribir en tablas de Taradata Vantage en AWS Glue 4.0 y versiones posteriores. Puede definir qué leer de Teradata con una consulta SQL. Puede conectarse a Teradata con las credenciales de nombre de usuario y contraseña almacenadas AWS Secrets Manager a través de una conexión AWS Glue.

Para obtener más información general sobre Teradata, consulte la documentación de Teradata

Configurar las conexiones de Teradata

Para conectarse a Teradata desde AWS Glue, deberá crear y almacenar las credenciales de Teradata en un AWS Secrets Manager secreto y, a continuación, asociar ese secreto a una conexión de AWS Glue Teradata. Si su instancia de Teradata está en una Amazon VPC, también deberá proporcionar opciones de red a su conexión de AWS Glue Teradata.

Para conectarse a Teradata desde AWS Glue, es posible que necesite algunos requisitos previos:

- Si accede a su entorno de Teradata a través de Amazon VPC, configure Amazon VPC para permitir que su trabajo de AWS Glue se comunique con el entorno de Teradata. No recomendamos acceder al entorno de Teradata a través de la Internet pública.

En Amazon VPC, identifique o cree una VPC, una subred y un grupo de seguridad que AWS Glue utilizará al ejecutar el trabajo. Además, debe asegurarse de que Amazon VPC esté configurada para permitir el tráfico de red entre su instancia de Teradata y esta ubicación. Su trabajo deberá establecer una conexión TCP con su puerto de cliente de Teradata. Para obtener más información sobre los puertos de Teradata, consulte la documentación de Teradata.

Según el diseño de la red, la conectividad segura de la VPC puede requerir cambios en Amazon VPC y otros servicios de red. Para obtener más información sobre la conectividad de AWS, consulte las Opciones de conectividad de AWS en la documentación de Teradata.

Para configurar una conexión de AWS Glue Teradata:

1. En la configuración de Teradata, identifique o cree un usuario y una contraseña con los que se conectará AWS Glue, *teradataUser* y *teradataPassword*. Para obtener más información, consulte la Información general de seguridad de Vantage en la documentación de Teradata.
2. En AWS Secrets Manager, cree un secreto con sus credenciales de Teradata. Para crear un secreto en Secrets Manager, siga el tutorial disponible en Crear un secreto AWS Secrets Manager en la documentación AWS Secrets Manager. Después de crear el secreto, conserve el nombre secreto, *secretName*, para el siguiente paso.
   - Al seleccionar pares clave/valor, genere un par para la clave `user` con el valor *teradataUsername*.
   - Al seleccionar pares clave/valor, genere un par para la clave `password` con el valor *teradataPassword*.
3. En la consola de AWS Glue, genere una conexión mediante los pasos que se indican en the section called “Adición de una conexión de AWS Glue”. Tras crear la conexión, conserve el nombre de la conexión, *connectionName*, para el siguiente paso.
   - Al seleccionar un tipo de conexión, seleccione Teradata.
   - Al proporcionar la URL de JDBC, proporcione la URL de su instancia. También puede codificar determinados parámetros de conexión separados por comas en la URL de JDBC. La URL debe tener el siguiente formato: `jdbc:teradata://`*teradataHostname*`/`*ParameterName*`=`*ParameterValue*`,`*ParameterName*

     Los parámetros de URL admitidos incluyen:

    - DATABASE— nombre de la base de datos del host a la que se accede de forma predeterminada.
    - DBS_PORT— el puerto de la base de datos, que se utiliza cuando se ejecuta en un puerto no estándar.
  - Al seleccionar un Tipo de credencial, seleccione AWS Secrets Manager y, a continuación, establezca AWS Secret en *secretName*.
4. En las siguientes situaciones, es posible que necesite una configuración adicional:
  - Para las instancias de Teradata alojadas en AWS en una Amazon VPC
    - Deberá proporcionar la información de conexión de Amazon VPC a la conexión AWS Glue que define sus credenciales de seguridad de Teradata. Al crear o actualizar la conexión, configure los VPC, Subred y los grupos de seguridad en Opciones de red.

Tras crear una conexión con AWS Glue Teradata, deberá realizar los siguientes pasos antes de llamar a su método de conexión.

- Otorgue al rol de IAM asociado al permiso de su trabajo de AWS Glue para leer *secretName*.
- En la configuración del trabajo de Glue AWS, proporcione *connectionName* como una conexión de red adicional.

Leer desde Teradata

Requisitos previos:

- Una tabla de Teradata desde la cual le gustaría leer. Necesitará el nombre de la tabla, *tableName.*
- Una conexión AWS Glue Teradata configurada para proporcionar información de autenticación. Complete los pasos de Para configurar una conexión a Teradata para y configure su información de autenticación. Necesitará el nombre de la conexión de AWS Glue, *connectionName*.

Por ejemplo:

```
teradata_read_table = glueContext.create_dynamic_frame.from_options(
    connection_type="teradata",
    connection_options={
        "connectionName": "connectionName",
```

```
        "dbtable": "tableName"
    }
)
```

También puede proporcionar una consulta SELECT SQL para filtrar los resultados devueltos a su DynamicFrame. Deberá configurar `query`.

Por ejemplo:

```
teradata_read_query = glueContext.create_dynamic_frame.from_options(
    connection_type="teradata",
    connection_options={
        "connectionName": "connectionName",
        "query": "query"
    }
)
```

Escribir en tablas de Teradata

Requisitos previos: una tabla de Teradata en la que le gustaría escribir, *`tableName`*. Debe crear la tabla antes de llamar al método de conexión.

Por ejemplo:

```
teradata_write = glueContext.write_dynamic_frame.from_options(
    connection_type="teradata",
    connection_options={
        "connectionName": "connectionName",
        "dbtable": "tableName"
    }
)
```

Referencia de opciones de conexión de Teradata

- `connectionName`: obligatorio. Se utiliza para lectura/escritura. El nombre de una conexión de AWS Glue Teradata configurada para proporcionar información de autenticación y red a su método de conexión.
- `dbtable` — Necesario para escribir, obligatorio para leer a menos que se proporcione `query`. Se utiliza para lectura/escritura. El nombre de una tabla con la que interactuará su método de conexión.

- `query`: se utiliza para leer. Una consulta SELECT SQL que define lo que se debe recuperar al leer desde Teradata.

Conexiones NOS de Teradata Vantage

La conexión Native Object Store (NOS) de Teradata es una nueva conexión para Teradata Vantage que aprovecha la consulta WRITE_NOS de Teradata para leer las tablas existentes y la consulta READ_NOS para escribir en las tablas. Estas consultas utilizan Amazon S3 como directorio provisional y, por lo tanto, el conector NOS de Teradata es más rápido que el conector de Teradata existente (basado en JDBC), especialmente cuando se trata de gestionar grandes cantidades de datos.

Puede usar la conexión NOS de Teradata en AWS Glue para Spark para leer y escribir en tablas de Taradata Vantage en AWS Glue 5.0 y versiones posteriores. Puede definir qué leer de Teradata con una consulta SQL. Puede conectarse a Teradata con las credenciales de nombre de usuario y contraseña almacenadas en AWS Secrets Manager a través de una conexión de AWS Glue.

Para obtener más información general sobre Teradata, consulte la documentación de Teradata

Temas

- Creación de una conexión NOS de Teradata
- Lectura de tablas de Teradata
- Escribir en tablas de Teradata
- Referencia de opciones de conexión de Teradata
- Proporcionar opciones en la interfaz de usuario de AWS Glue Visual ETL

Creación de una conexión NOS de Teradata

Para conectarse a NOS de Teradata desde AWS Glue, tendrá que crear y almacenar sus credenciales de Teradata en un secreto de AWS Secrets Manager y, a continuación, asociar ese secreto a una conexión NOS de Teradata de AWS Glue. Si su instancia de Teradata está en una instancia de Amazon VPC, también deberá proporcionar opciones de red a su conexión NOS de Teradata de AWS Glue.

Requisitos previos:

- Si accede a su entorno de Teradata a través de Amazon VPC, configure Amazon VPC para permitir que su trabajo de AWS Glue se comunique con el entorno de Teradata. No recomendamos acceder al entorno de Teradata a través de la Internet pública.
- En Amazon VPC, identifique o cree una VPC, una subred y un grupo de seguridad que AWS Glue utilizará al poner en marcha el trabajo. Además, debe asegurarse de que Amazon VPC esté configurada para permitir el tráfico de red entre su instancia de Teradata y esta ubicación. Su trabajo deberá establecer una conexión TCP con su puerto de cliente de Teradata. Para obtener más información sobre los puertos de Teradata, consulte Security Groups for Teradata Vantage.
- Según el diseño de la red, la conectividad segura de la VPC puede requerir cambios en Amazon VPC y otros servicios de red. Para obtener más información sobre la conectividad de AWS, consulte AWS Connectivity Options en la documentación de Teradata.

Para configurar una conexión NOS de Teradata de AWS Glue, haga lo siguiente:

1. En la configuración de Teradata, identifique o cree las credenciales (*teradataUsername* y *teradataPassword*) con las que se conectará AWS Glue. Para obtener más información, consulte Vantage Security Overview en la documentación de Teradata.
2. En AWS Secrets Manager, cree un secreto con sus credenciales de Teradata. Para crear un secreto en AWS Secrets Manager, siga el tutorial disponible en Create an AWS Secrets Manager secret en la documentación de AWS Secrets Manager. Después de crear el secreto, conserve el nombre secreto, *secretName*, para el siguiente paso.
   - Al seleccionar pares clave/valor, genere un par para USERNAME de la clave con el valor *teradataUsername*.
   - Al seleccionar pares clave/valor, genere un par para PASSWORD de la clave con el valor *teradataPassword*.
3. En la consola de AWS Glue, genere una conexión mediante los pasos que se indican en Adición de una conexión de AWS Glue. Tras crear la conexión, conserve el nombre de la conexión, *connectionName*, para el siguiente paso.
   - Al seleccionar un Tipo de conexión, seleccione Teradata Vantage NOS.
   - Al proporcionar la URL de JDBC, proporcione la URL de su instancia. También puede codificar determinados parámetros de conexión separados por comas en la URL de JDBC. La URL debe tener el siguiente formato: `jdbc:teradata://teradataHostname/ParameterName=ParameterValue,ParameterName=ParameterValue`
   - Los parámetros de URL admitidos incluyen:

- `DATABASE`— nombre de la base de datos del host a la que se accede de forma predeterminada.
- `DBS_PORT`— el puerto de la base de datos, que se utiliza cuando se ejecuta en un puerto no estándar.

- Al seleccionar un Tipo de credencial, seleccione AWS Secrets Manager y, a continuación, establezca Secreto de AWS en *`secretName`*.

4. En las siguientes situaciones, es posible que necesite una configuración adicional:

   - En el caso de las instancias de Teradata alojadas en AWS en una instancia de Amazon VPC, Deberá proporcionar la información de conexión de Amazon VPC a la conexión de AWS Glue que define sus credenciales de seguridad de Teradata. Al crear o actualizar la conexión, configure VPC, Subred y Grupos de seguridad en Opciones de red.

Tras crear una conexión NOS de Teradata Vantage de AWS Glue, deberá realizar los siguientes pasos antes de llamar a su método de conexión.

1. Otorga permiso al rol de IAM asociado al trabajo de AWS Glue para leer el *`secretName`*.
2. En la configuración del trabajo de AWS Glue, proporcione un *`connectionName`* como una Conexión de red adicional en Conexiones.

Lectura de tablas de Teradata

Requisitos previos:

- Una tabla de Teradata desde la cual le gustaría leer. Necesitará el nombre de la tabla, *`tableName.`*
- El entorno de Teradata tiene acceso de escritura a la ruta de Amazon S3 especificada por la opción `staging_fs_url`, *`stagingFsUrl`*.
- El rol de IAM asociado al trabajo de AWS Glue tiene acceso de escritura a la ubicación de Amazon S3 especificada por la opción `staging_fs_url`.
- Una conexión NOS de Teradata de AWS Glue configurada para proporcionar información de autenticación. Complete los pasos de Para configurar una conexión NOS de Teradata de AWS Glue, haga lo siguiente: para configurar su información de autenticación. Necesitará el nombre de la conexión de AWS Glue, *`connectionName`*.

Ejemplo:

```
teradata_read_table = glueContext.create_dynamic_frame.from_options(
    connection_type= "teradatanos",
    connection_options={
        "connectionName": "connectionName",
        "dbtable": "tableName",
        "staging_fs_url": "stagingFsUrl"
    }
)
```

También puede proporcionar una consulta SELECT SQL para filtrar los resultados devueltos a su DynamicFrame. Tendrá que configurar query. Si configura dbTable y query, el conector no podrá leer los datos. Por ejemplo:

```
teradata_read_query = glueContext.create_dynamic_frame.from_options(
    connection_type="teradatanos",
    connection_options={
        "connectionName": "connectionName",
        "query": "query",
        "staging_fs_url": "stagingFsUrl"
    }
)
```

Además, puede usar la API DataFrame de Spark para leer tablas de Teradata. Por ejemplo:

```
options = {
    "url": "JDBC_URL",
    "dbtable": "tableName",
    "user": "teradataUsername", # or use "username" as key here
    "password": "teradataPassword",
    "staging_fs_url": "stagingFsUrl"
}
teradata_read_table = spark.read.format("teradatanos").option(**options).load()
```

Escribir en tablas de Teradata

Requisitos previos

- Una tabla de Teradata a la que desearía escribir: *tableName*.

- El entorno de Teradata tiene acceso de lectura a la ubicación de Amazon S3 especificada por la opción `staging_fs_url`, *`stagingFsUrl`*.
- El rol de IAM asociado al trabajo de AWS Glue tiene acceso de escritura a la ubicación de Amazon S3 especificada por la opción `staging_fs_url`.
- Una conexión de Teradata de AWS Glue configurada para proporcionar información de autenticación. Complete los pasos de Para configurar una conexión NOS de Teradata de AWS Glue, haga lo siguiente: para configurar su información de autenticación. Necesitará el nombre de la conexión de AWS Glue, *`connectionName`*.

  Por ejemplo:

```
teradata_write = glueContext.write_dynamic_frame.from_options(
    frame=dynamicFrame,
    connection_type= "teradatanos",
    connection_options={
        "connectionName": "connectionName",
        "dbtable": "tableName",
        "staging_fs_url": "stagingFsUrl"
    }
)
```

Referencia de opciones de conexión de Teradata

Opciones Conexión y Operación:

- `connectionName`: obligatorio. Se utiliza para lectura/escritura. El nombre de una conexión de Teradata de AWS Glue configurada para proporcionar información de autenticación y red a su método de conexión.
- `staging_fs_url`: obligatorio. Se utiliza para lectura/escritura. Una ubicación en la que se pueda escribir de Amazon S3, que se utilizará para los datos descargados al leer desde Teradata y para que los datos de Parquet se carguen en Redshift al escribir en Teradata. El bucket de S3 debe estar en la misma región que sus trabajos de AWS Glue.
- `dbtable` — Necesario para escribir, obligatorio para leer a menos que se proporcione `query`. Se utiliza para lectura/escritura. El nombre de una tabla con la que interactuará su método de conexión.
- `query`: se utiliza para leer. Una consulta SELECT SQL que define lo que se debe recuperar al leer desde Teradata. No puede pasar si se ofrece la opción `dbtable`.

- `clean_staging_s3_dir`: opcional. Se utiliza para lectura/escritura. Si es true, elimine los objetos de Amazon S3 provisionales después de una lectura o escritura. El valor predeterminado es true.
- `pre_actions`: opcional. Se utiliza para escribir. Lista de comandos de SQL separados por punto y coma que se ponen en marcha antes de transferir los datos entre Spark y Teradata Vantage.
- `post_actions`: opcional. Se utiliza para escribir. Lista de comandos de SQL separados por punto y coma que se ponen en marcha después de transferir los datos entre Spark y Teradata Vantage.
- `truncate`: opcional. Se utiliza para escribir. Si es true, el conector trunca la tabla al escribir en modo de sobrescritura. Si es false, el conector elimina la tabla al escribir en modo de sobrescritura. El valor predeterminado es false.
- `create_table_script`: opcional. Se utiliza para escribir. Una sentencia de SQL para crear una tabla al escribir en Teradata Vantage. Es útil cuando se quiere crear una tabla con metadatos personalizados (por ejemplo, CREATE MULTISET o SET table o cambiar el índice principal). Tenga en cuenta que el nombre de la tabla utilizado en el script de creación de tablas debe coincidir con el nombre de la tabla especificado en la opción `dbtable`.
- `partition_size_in_mb`: opcional. Se usa para leer. Tamaño máximo de una partición de Spark en megabytes mientras se leen objetos de Amazon S3 provisionales. El valor predeterminado es 128.

Puede brindar opciones avanzadas al crear un nodo de Teradata. Estas opciones son las mismas que las disponibles cuando se programa AWS Glue para scripts de Spark.

Consulte the section called “Conexiones Teradata Vantage”.

Opciones de autorización:

A continuación, se muestran las opciones que se utilizan para proporcionar las credenciales de la cuenta de AWS que el conector utiliza para acceder al bucket de almacenamiento provisional de Amazon S3. Puede optar por (1) no proporcionar ninguna opción de autorización y utilizar las credenciales temporales generadas a partir de su rol de ejecución de AWS Glue; (2) proporcionar un objeto de autorización `auth_object` que haya creado; (3) proporcionar `aws_access_key_id and aws_secret_access_key` si utiliza credenciales de larga duración, o bien proporcionar `aws_access_key`, `aws_secret_access_key` y `aws_session_token` si utiliza credenciales temporales.

- `auth_object`: opcional. Se usa para acceder al bucket de almacenamiento provisional de Amazon S3. Una cadena de objeto de autorización creada en una instancia de Teradata. Si

se proporciona, el conector utilizará este objeto de autorización para acceder al bucket de almacenamiento provisional de Amazon S3. Si no se proporciona, y tampoco se proporcionan `aws_access_key_id` y `aws_secret_access_key`, se recuperará una credencial temporal del rol de ejecución de AWS Glue y será utilizada por el conector. La cuenta de AWS asociada a este objeto de autorización debe estar en la misma región que sus trabajos de AWS Glue y su bucket de almacenamiento provisional de Amazon S3 o estar configurada con confianza entre cuentas.

- `aws_access_key_id`: opcional. Se usa para acceder al bucket de almacenamiento provisional de Amazon S3. Forma parte de la credencial de seguridad de una cuenta de AWS. Si no se proporciona `auth_object`, y se proporcionan `aws_access_key_id` y `aws_secret_access_key`, el conector los utilizará para acceder al bucket de almacenamiento provisional de Amazon S3. La cuenta AWS asociada a esta clave de acceso debe estar en la misma región que sus trabajos AWS Glue y su bucket de almacenamiento provisional de Amazon S3 o estar configurada con confianza entre cuentas.
- `aws_secret_access_key`: opcional. Se usa para acceder al bucket de almacenamiento provisional de Amazon S3. Forma parte de la credencial de seguridad de una cuenta de AWS. Si no se proporciona `auth_object`, y `aws_secret_access_key` se proporciona con `aws_access_key_id`, el conector los utilizará para acceder al bucket de almacenamiento provisional de Amazon S3. La cuenta AWS asociada a esta clave secreta debe estar en la misma región que sus trabajos AWS Glue y su bucket de almacenamiento provisional de Amazon S3 o estar configurada con confianza entre cuentas.
- `aws_session_token`: opcional. Se usa para acceder al bucket de almacenamiento provisional de Amazon S3. Forma parte de la credencial de seguridad temporal de una cuenta de AWS. Debe proporcionarse junto con `aws_access_key_id` y `aws_secret_access_key`.

Proporcionar opciones en la interfaz de usuario de AWS Glue Visual ETL

Puede proporcionar todas las opciones anteriores en la interfaz de su trabajo de Visual ETL. Para la opción connectionName, debe elegirla de la lista desplegable de conexiones de Teradata Vantage NOS. Para todas las demás opciones, debe proporcionarlas a través de las propiedades personalizadas de Teradata Vantage NOS como pares de clave-valor.

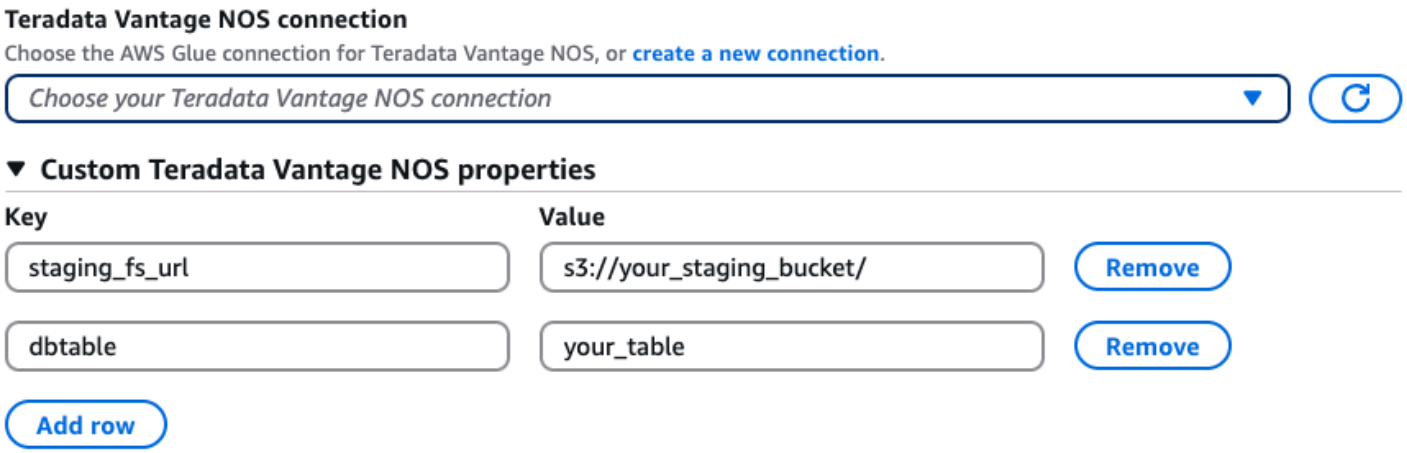

Conexiones Vertica

Puede usar AWS Glue for Spark para leer y escribir en tablas de Vertica en AWS Glue 4.0 y versiones posteriores. Puede definir qué leer desde Vertica con una consulta SQL. Se conecta a Vertica con las credenciales de nombre de usuario y contraseña almacenadas en una conexión de AWS Secrets Manager a AWS Glue.

Para obtener más información sobre Vertica, consulte la documentación de Vertica.

Configurar las conexiones de Vertica

Para conectarse a Vertica desde AWS Glue, tendrá que crear y almacenar las credenciales de Vertica en un AWS Secrets Manager secreto y, a continuación, asociar ese secreto a una conexión de Vertica AWS Glue. Si su instancia de Vertica está en una Amazon VPC, también deberá proporcionar opciones de red a su conexión de AWS Glue Vertica. Necesitará un bucket o carpeta de Amazon S3 para utilizar como almacenamiento temporario al leer y escribir en la base de datos.

Para conectarse a Vertica desde AWS Glue, necesitará algunos requisitos previos:

- Un bucket o una carpeta de Amazon S3 para utilizar como almacenamiento temporario al leer y escribir en la base de datos, al que hace referencia *tempS3Path*.

> **Note**
>
> Al utilizar Vertica en las vistas previas de los datos de los trabajos de AWS Glue, puede que los archivos temporales no se eliminen automáticamente de *tempS3Path*. Para garantizar la eliminación de los archivos temporales, finalice directamente la sesión de vista previa de datos al seleccionar Finalizar sesión en el panel Vista previa de datos.

Si no puede garantizar que la sesión de vista previa de datos finalice directamente, considere configurar Amazon S3 Lifecycle para eliminar los datos antiguos. Recomendamos eliminar los datos de más de 49 horas, en función del tiempo máximo de ejecución del trabajo más un margen. Para obtener más información sobre la configuración de Amazon S3 Lifecycle, consulte Administración del ciclo de vida del almacenamiento en la documentación de Amazon S3.

- Una política de IAM con los permisos adecuados para su ruta de Amazon S3 que puede asociar a su puesto de trabajo de AWS Glue.
- Si su instancia de Vertica está en una Amazon VPC, configure Amazon VPC para permitir que su trabajo de AWS Glue se comunique con la instancia de Vertica sin que el tráfico atraviese la Internet pública.

  En Amazon VPC, identifique o cree una VPC, una subred y un grupo de seguridad que AWS Glue utilizará al ejecutar la tarea. Además, debe asegurarse de que Amazon VPC esté configurada para permitir el tráfico de red entre su instancia de Vertica y esta ubicación. Su trabajo tendrá que establecer una conexión TCP con el puerto de cliente de Vertica (el valor predeterminado es 5433). Según el diseño de la red, esto puede requerir cambios en las reglas de los grupos de seguridad, las ACL de red, las puertas de enlace de NAT y las conexiones entre pares.

A continuación, puede proceder a configurar AWS Glue para su uso con Vertica.

Para configurar una conexión a Vertica:

1. En AWS Secrets Manager, cree un secreto con sus credenciales de Vertica, *verticaUsername* y *verticaPassword*. Para crear un secreto en Secrets Manager, siga el tutorial disponible en Crear un secreto AWS Secrets Manager en la documentación AWS Secrets Manager. Después de crear el secreto, conserve el nombre secreto, *secretName*, para el siguiente paso.

   - Al seleccionar pares clave/valor, genere un par para la clave `user` con el valor *verticaUsername*.
   - Al seleccionar pares clave/valor, genere un par para la clave `password` con el valor *verticaPassword*.
2. En la consola de AWS Glue, genere una conexión mediante los pasos que se indican en the section called “Adición de una conexión de AWS Glue”. Tras crear la conexión, conserve el nombre de la conexión, *connectionName*, para el siguiente paso.

- Al seleccionar un tipo de conexión, seleccione Vertica.
- Al seleccionar Vertica Host, proporcione el nombre de host de la instalación de Vertica.
- Al seleccionar Vertica Port, proporcione el portal a través del cual está disponible su instalación de Vertica.
- Al seleccionar un secreto AWS, proporcione un *secretName*.

3. En las siguientes situaciones, es posible que necesite una configuración adicional:

   - Para las instancias de Vertica alojadas en AWS en una Amazon VPC
     - Proporcione la información de conexión de Amazon VPC a la conexión de AWS Glue que define sus credenciales de seguridad de Vertica. Al crear o actualizar la conexión, configure los VPC, Subred y los grupos de seguridad en Opciones de red.

Tras crear una conexión AWS Glue Vertica, deberá realizar los siguientes pasos antes de llamar a su método de conexión.

- Otorgue al rol de IAM asociado a los permisos de su trabajo de AWS Glue para *tempS3Path*.
- Otorgue al rol de IAM asociado al permiso de su trabajo de AWS Glue para leer *secretName*.
- En la configuración del trabajo de Glue AWS, proporcione *connectionName* como una conexión de red adicional.

Leer desde Vertica

Requisitos previos:

- Una tabla de Vertica desde la cual le gustaría leer. Necesitará el nombre de la base de datos Vertica, *dbName* y el nombre de la tabla, *tableName*.
- Una conexión AWS Glue Vertica configurada para proporcionar información de autenticación. Complete los pasos del procedimiento anterior, Para configurar una conexión a Vertica y configurar su información de autenticación. Necesitará el nombre de la conexión de AWS Glue, *connectionName*.
- Un bucket o una carpeta de Amazon S3 para usar como almacenamiento temporal, como se mencionó anteriormente. Necesitará el nombre *tempS3Path*. Deberá conectarse a esta ubicación mediante el protocolo `s3a`.

Por ejemplo:

```
dynamicFrame = glueContext.create_dynamic_frame.from_options(
    connection_type="vertica",
    connection_options={
        "connectionName": "connectionName",
        "staging_fs_url": "s3a://tempS3Path",
        "db": "dbName",
        "table": "tableName",
    }
)
```

También puede proporcionar una consulta de SELECT SQL para filtrar los resultados devueltos a su DynamicFrame o para acceder al conjunto de datos desde múltiples tablas.

Por ejemplo:

```
dynamicFrame = glueContext.create_dynamic_frame.from_options(
    connection_type="vertica",
    connection_options={
        "connectionName": "connectionName",
        "staging_fs_url": "s3a://tempS3Path",
        "db": "dbName",
        "query": "select * FROM tableName",
    },
)
```

Escribir en tablas de Vertica

En este ejemplo, se escribe información de un DynamicFrame existente, *dynamicFrame* en Vertica. Si la tabla ya contiene información, AWS Glue agregará los datos de su DynamicFrame.

Requisitos previos:

- El nombre de tabla actual o deseado, *tableName*, al que desearía escribir. También necesitará el nombre de la base de datos de Vertica correspondiente, *dbName.*
- Una conexión AWS Glue Vertica configurada para proporcionar información de autenticación. Complete los pasos del procedimiento anterior, Para configurar una conexión a Vertica y configurar su información de autenticación. Necesitará el nombre de la conexión de AWS Glue, *connectionName*.

- Un bucket o una carpeta de Amazon S3 para usar como almacenamiento temporal, como se mencionó anteriormente. Necesitará el nombre *tempS3Path*. Deberá conectarse a esta ubicación mediante el protocolo `s3a`.

Por ejemplo:

```
glueContext.write_dynamic_frame.from_options(
    frame=dynamicFrame,
    connection_type="vertica",
    connection_options={
        "connectionName": "connectionName",
        "staging_fs_url": "s3a://tempS3Path",
        "db": "dbName",
        "table": "tableName",
    }
)
```

Referencia de opciones de conexión de Vertica

- `connectionName`: obligatorio. Se utiliza para lectura/escritura. El nombre de una conexión de AWS Glue Vertica configurada para proporcionar información de autenticación y red a su método de conexión.
- `db`: obligatorio. Se utiliza para lectura/escritura. El nombre de una base de datos de Vertica con la que interactuará su método de conexión.
- `dbSchema`— Obligatorio si es necesario para identificar la tabla. Se utiliza para lectura/escritura. Valor predeterminado: `public`. El nombre del esquema con el que interactuará su método de conexión.
- `table` — Necesario para escribir, obligatorio para leer a menos que se proporcione `query`. Se utiliza para lectura/escritura. El nombre de una tabla con la que interactuará su método de conexión.
- `query`: se utiliza para leer. Una consulta SELECT SQL que define lo que se debe recuperar al leer desde Teradata.
- `staging_fs_url`: obligatorio. Se utiliza para lectura/escritura. Valores válidos: direcciones URL `s3a`. La URL de un bucket o una carpeta de Amazon S3 que se va a utilizar como almacenamiento temporal.

Opciones de DataFrame para ETL en AWS Glue 5.0 para Spark

Un elemento de DataFrame ordenado en columnas con nombre es similar a una tabla y admite operaciones de estilo funcional (map/reduce/filter/etc.) y operaciones de SQL (select, project, aggregate).

Para crear un elemento de DataFrame para un origen de datos compatible con Glue, necesita lo siguiente:

- conector de origen de datos `ClassName`
- conexión de origen de datos `Options`

Del mismo modo, para escribir un elemento de DataFrame en un receptor de datos compatible con Glue, necesita lo mismo:

- conector de receptor de datos `ClassName`
- conexión de receptor de datos `Options`

Tenga en cuenta que las características de AWS Glue, como los marcadores de trabajos y las opciones de DynamicFrame como `connectionName`, no son compatibles con DataFrame. Para obtener más información sobre DataFrame y las operaciones compatibles, consulte la documentación de Spark sobre DataFrame.

Especificación del conector ClassName

Para especificar el origen o receptor de datos de `ClassName`, utilice la opción `.format` para proporcionar el conector correspondiente `ClassName` que defina el origen o receptor de datos.

Conectores de JDBC

En el caso de los conectores de JDBC, especifique `jdbc` como el valor de la opción `.format` y proporcione el controlador JDBC `ClassName` en la opción `driver`.

```
df = spark.read.format("jdbc").option("driver", "<DATA SOURCE JDBC DRIVER
 CLASSNAME>")...

df.write.format("jdbc").option("driver", "<DATA SINK JDBC DRIVER CLASSNAME>")...
```

En la siguiente tabla, se muestra el controlador JDBC `ClassName` del origen de datos compatible en AWS Glue para elementos de DataFrame.

Origen de datos	Controlador ClassName
PostgreSQL	org.postgresql.Driver
Oracle	oracle.jdbc.driver.OracleDriver
SQLServer	com.microsoft.sqlserver.jdbc.SQLServerDriver
MySQL	com.mysql.jdbc.Driver
SAPHana	com.sap.db.jdbc.Driver
Teradata	com.teradata.jdbc.TeraDriver

Conectores de Spark

Para los conectores de Spark, especifique el controlador `ClassName` del conector como valor de la opción `.format`.

```
df = spark.read.format("<DATA SOURCE CONNECTOR CLASSNAME>")...

df.write.format("<DATA SINK CONNECTOR CLASSNAME>")...
```

En la siguiente tabla, se muestra el controlador de Spark `ClassName` del origen de datos compatible en AWS Glue para elementos de DataFrame.

Origen de datos	ClassName
MongoDB/DocumentDB	glue.spark.mongodb
Redshift	io.github.spark_redshift_community.spark.redshift
AzureCosmos	cosmos.oltp
AzureSQL	com.microsoft.sqlserver.jdbc.spark
BigQuery	com.google.cloud.spark.bigquery
OpenSearch	org.opensearch.spark.sql

Snowflake	net.snowflake.spark.snowflake
Vertica	com.vertica.spark.datasource.VerticaSource

Especificación de la conexión Options

Para especificar la conexión `Options` en un origen o receptor de datos, utilice `.option(<KEY>, <VALUE>)` para proporcionar opciones individuales o `.options(<MAP>)` para proporcionar varias opciones como un mapa de valores clave.

Cada origen o receptor de datos admite su propio conjunto de conexiones `Options`. Para obtener detalles sobre la conexión `Options` disponible, consulte la documentación pública del conector de Spark del origen o receptor de datos específico que se detalla en la siguiente tabla.

- JDBC
- MongoDB/DocumentDB
- Redshift
- AzureCosmos
- AzureSQL
- BigQuery
- OpenSearch
- Snowflake
- Vertica

Ejemplos

Los siguientes ejemplos se leen desde PostgreSQL y se escriben en SnowFlake:

Python

Ejemplo:

```
from awsglue.context import GlueContext
from pyspark.sql import SparkSession

spark = SparkSession.builder.getOrCreate()

dataSourceClassName = "jdbc"
```

```
dataSourceOptions = {
  "driver": "org.postgresql.Driver",
  "url": "<url>",
  "user": "<user>",
  "password": "<password>",
  "dbtable": "<dbtable>",
}

dataframe = spark.read.format(className).options(**options).load()

dataSinkClassName = "net.snowflake.spark.snowflake"
dataSinkOptions = {
  "sfUrl": "<url>",
  "sfUsername": "<username>",
  "sfPassword": "<password>",
  "sfDatabase" -> "<database>",
  "sfSchema" -> "<schema>",
  "sfWarehouse" -> "<warehouse>"
}

dataframe.write.format(dataSinkClassName).options(**dataSinkOptions).save()
```

Scala

Ejemplo:

```
import org.apache.spark.sql.SparkSession

val spark = SparkSession.builder().getOrCreate()

val dataSourceClassName = "jdbc"
val dataSourceOptions = Map(
  "driver" -> "org.postgresql.Driver",
  "url" -> "<url>",
  "user" -> "<user>",
  "password" -> "<password>",
  "dbtable" -> "<dbtable>"
)

val dataframe =
 spark.read.format(dataSourceClassName).options(dataSourceOptions).load()

val dataSinkClassName = "net.snowflake.spark.snowflake"
val dataSinkOptions = Map(
```

```
  "sfUrl" -> "<url>",
  "sfUsername" -> "<username>",
  "sfPassword" -> "<password>",
  "sfDatabase" -> "<database>",
  "sfSchema" -> "<schema>",
  "sfWarehouse" -> "<warehouse>"
)

dataframe.write.format(dataSinkClassName).options(dataSinkOptions).save()
```

Valores de conexiones de tipo personalizada y AWS Marketplace

Estos incluyen los siguientes:

- `"connectionType": "marketplace.athena"`: designa una conexión a un almacén de datos de Amazon Athena. La conexión utiliza un conector de AWS Marketplace.
- `"connectionType": "marketplace.spark"`: designa una conexión a un almacén de datos de Apache Spark. La conexión utiliza un conector de AWS Marketplace.
- `"connectionType": "marketplace.jdbc"`: designa una conexión a un almacén de datos de JDBC. La conexión utiliza un conector de AWS Marketplace.
- `"connectionType": "custom.athena"`: designa una conexión a un almacén de datos de Amazon Athena. La conexión utiliza un conector personalizado que se carga a AWS Glue Studio.
- `"connectionType": "custom.spark"`: designa una conexión a un almacén de datos de Apache Spark. La conexión utiliza un conector personalizado que se carga a AWS Glue Studio.
- `"connectionType": "custom.jdbc"`: designa una conexión a un almacén de datos de JDBC. La conexión utiliza un conector personalizado que se carga a AWS Glue Studio.

Opciones de conexión para el tipo custom.jdbc o marketplace.jdbc

- `className`: cadena, obligatoria, nombre de clase de controlador.
- `connectionName`: cadena, obligatoria, nombre de la conexión asociada al conector.
- `url`: cadena, obligatoria, URL JDBC con marcadores de posición (`${}`) que se utilizan para construir la conexión al origen de datos. El marcador de posición `${secretKey}` se reemplaza con el secreto del mismo nombre en AWS Secrets Manager. Consulte la documentación del almacén de datos para obtener más información sobre la construcción de la URL.
- `secretId` o `user/password`: cadena, obligatoria, utilizada para recuperar credenciales de la URL.

- `dbTable` o `query`: cadena, obligatoria, la tabla o consulta SQL de la que se obtienen los datos. Puede especificar `dbTable` o `query`, pero no ambos.
- `partitionColumn`: cadena, opcional, el nombre de una columna entera que se utiliza para particionar. Esta opción solo funciona cuando está incluida con `lowerBound`, `upperBound` y `numPartitions`. Esta opción funciona de la misma manera que en el lector JDBC de Spark SQL. Para obtener más información, consulte JDBC a otras bases de datos en la Guía de Apache Spark SQL, DataFrames y conjuntos de datos.

  Los valores `lowerBound` y `upperBound` se utilizan para decidir el intervalo de partición, no para filtrar las filas de la tabla. Todas las filas de la tabla se particionan y se devuelven.

  > **Note**
  >
  > Cuando se utiliza una consulta en lugar de un nombre de tabla, debe validar que la consulta funciona con la condición de partición especificada. Por ejemplo:
  >
  > - Si el formato de consulta es `"SELECT col1 FROM table1"`, pruebe la consulta al agregar una cláusula `WHERE` al final de la consulta que utiliza la columna de partición.
  > - Si su formato de consulta es “`SELECT col1 FROM table1 WHERE col2=val`", pruebe la consulta al ampliar la cláusula `WHERE` con `AND` y una expresión que utiliza la columna de partición.

- `lowerBound`: entero, opcional, el valor mínimo de `partitionColumn` que se utiliza para decidir el intervalo de partición.
- `upperBound`: entero, opcional, el valor máximo de `partitionColumn` que se utiliza para decidir el intervalo de partición.
- `numPartitions`: entero, opcional, el número de particiones. Este valor, junto con `lowerBound` (inclusive) y `upperBound` (exclusivo), forma intervalos de partición para expresiones de la cláusula `WHERE` generadas, que se utilizan para dividir la `partitionColumn`.

  > **Important**
  >
  > Preste atención al número de particiones, ya que demasiadas particiones pueden causar problemas en los sistemas de base de datos externos.

- `filterPredicate`: cadena, opcional, condición adicional para filtrar datos desde el origen. Por ejemplo:

```
BillingCity='Mountain View'
```

Cuando se utiliza una consulta en lugar de una tabla, debe validar que la consulta funciona con el `filterPredicate` especificado. Por ejemplo:

- Si el formato de consulta es `"SELECT col1 FROM table1"`, pruebe la consulta al agregar una cláusula `WHERE` al final de la consulta que utiliza el predicado de filtrado.
- Si su formato de consulta es `"SELECT col1 FROM table1 WHERE col2=val"`, pruebe la consulta al ampliar la cláusula `WHERE` con `AND` y una expresión que utiliza el predicado de filtrado.

- `dataTypeMapping`: diccionario, opcional, mapeo de tipos de datos personalizado, que crea un mapeo a partir de un tipo de datos JDBC a un tipo de datos de Glue. Por ejemplo, la opción `"dataTypeMapping":{"FLOAT":"STRING"}` asigna campos de datos de tipo `FLOAT` de JDBC al tipo `String` de Java al invocar el método `ResultSet.getString()` del controlador y lo utiliza para crear registros de AWS Glue. Cada controlador implementa el objeto `ResultSet`, por lo que el comportamiento es específico del controlador que se utiliza. Consulte la documentación del controlador JDBC para comprender cómo el controlador realiza las conversiones.
- Los tipos de datos de AWS Glue que se admiten actualmente son:
  - DATE
  - STRING
  - TIMESTAMP
  - INT
  - FLOAT
  - LONG
  - BIGDECIMAL
  - BYTE
  - SHORT
  - DOBLE

  Los tipos de datos JDBC soportados son Java8 java.sql.types.

  Las asignaciones de tipos de datos predeterminados (de JDBC a AWS Glue) son:

  - DATE -> DATE
  - VARCHAR -> STRING

- CHAR -> STRING
- LONGNVARCHAR -> STRING
- TIMESTAMP -> TIMESTAMP
- INTEGER -> INT
- FLOAT -> FLOAT
- REAL -> FLOAT
- BIT -> BOOLEAN
- BOOLEAN -> BOOLEAN
- BIGINT -> LONG
- DECIMAL -> BIGDECIMAL
- NUMERIC -> BIGDECIMAL
- TINYINT -> SHORT
- SMALLINT -> SHORT
- DOUBLE -> DOUBLE

Si utiliza un mapeo de tipos de datos personalizada con la opción `dataTypeMapping`, puede anular el mapeo de tipos de datos predeterminado. Sólo los tipos de datos JDBC enumerados en la opción `dataTypeMapping` se ven afectados; el mapeo predeterminado se utiliza para todos los demás tipos de datos JDBC. Puede agregar mapeos para tipos de datos JDBC adicionales si es necesario. Si un tipo de datos JDBC no está incluido en la asignación predeterminada o en una asignación personalizada, el tipo de datos se convierte al tipo de datos `STRING` de AWS Glue de forma predeterminada.

En los ejemplos de código Python siguientes, se muestra cómo leer desde bases de datos JDBC con controladores JDBC AWS Marketplace. Demuestra la lectura desde una base de datos y la escritura en una ubicación S3.

```
    import sys
    from awsglue.transforms import *
    from awsglue.utils import getResolvedOptions
    from pyspark.context import SparkContext
    from awsglue.context import GlueContext
    from awsglue.job import Job

    ## @params: [JOB_NAME]
```

```
    args = getResolvedOptions(sys.argv, ['JOB_NAME'])

    sc = SparkContext()
    glueContext = GlueContext(sc)
    spark = glueContext.spark_session
    job = Job(glueContext)
    job.init(args['JOB_NAME'], args)
    ## @type: DataSource
    ## @args: [connection_type = "marketplace.jdbc", connection_options =
     {"dataTypeMapping":{"INTEGER":"STRING"},"upperBound":"200","query":"select id,
       name, department from department where id < 200","numPartitions":"4",
       "partitionColumn":"id","lowerBound":"0","connectionName":"test-connection-
jdbc"},
        transformation_ctx = "DataSource0"]
    ## @return: DataSource0
    ## @inputs: []
    DataSource0 = glueContext.create_dynamic_frame.from_options(connection_type =
      "marketplace.jdbc", connection_options = {"dataTypeMapping":{"INTEGER":"STRING"},
      "upperBound":"200","query":"select id, name, department from department where
       id < 200","numPartitions":"4","partitionColumn":"id","lowerBound":"0",
       "connectionName":"test-connection-jdbc"}, transformation_ctx = "DataSource0")
    ## @type: ApplyMapping
    ## @args: [mappings = [("department", "string", "department", "string"), ("name",
 "string",
     "name", "string"), ("id", "int", "id", "int")], transformation_ctx =
 "Transform0"]
    ## @return: Transform0
    ## @inputs: [frame = DataSource0]
    Transform0 = ApplyMapping.apply(frame = DataSource0, mappings = [("department",
 "string",
     "department", "string"), ("name", "string", "name", "string"), ("id", "int",
 "id", "int")],
      transformation_ctx = "Transform0")
    ## @type: DataSink
    ## @args: [connection_type = "s3", format = "json", connection_options = {"path":
     "s3://<S3 path>/", "partitionKeys": []}, transformation_ctx = "DataSink0"]
    ## @return: DataSink0
    ## @inputs: [frame = Transform0]
    DataSink0 = glueContext.write_dynamic_frame.from_options(frame = Transform0,
      connection_type = "s3", format = "json", connection_options = {"path":
      "s3://<S3 path>/", "partitionKeys": []}, transformation_ctx = "DataSink0")
    job.commit()
```

Opciones de conexión para el tipo custom.athena o marketplace.athena

- `className`: cadena, obligatoria, nombre de clase de controlador. Cuando se utiliza el conector Athena-CloudWatch, este valor de parámetro es el prefijo del nombre de clase (por ejemplo, `"com.amazonaws.athena.connectors"`). El conector Athena-CloudWatch se compone de dos clases: un controlador de metadatos y un controlador de registros. Si proporciona el prefijo común aquí, la API carga las clases correctas basadas en ese prefijo.
- `tableName`: cadena, obligatoria, el nombre del flujo de registro de CloudWatch que se va a leer. Este fragmento de código usa el nombre de vista especial `all_log_streams`, lo que significa que el marco de datos dinámico devuelto contendrá datos de todos los flujos de registro incluidos en el grupo de registros.
- `schemaName`: cadena, obligatoria, el nombre del grupo de registro de CloudWatch que se va a leer. Por ejemplo, `/aws-glue/jobs/output`.
- `connectionName`: cadena, obligatoria, nombre de la conexión asociada al conector.

Para obtener opciones adicionales para este conector, consulte el archivo README (LÉAME) del conector de Amazon Athena CloudWatch en GitHub.

En el siguiente ejemplo de código de Python, se muestra cómo se lee desde un almacén de datos de Athena mediante un conector AWS Marketplace. Demuestra la lectura de Athena y la escritura en una ubicación S3.

```
import sys
from awsglue.transforms import *
from awsglue.utils import getResolvedOptions
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job

## @params: [JOB_NAME]
args = getResolvedOptions(sys.argv, ['JOB_NAME'])

sc = SparkContext()
glueContext = GlueContext(sc)
spark = glueContext.spark_session
job = Job(glueContext)
job.init(args['JOB_NAME'], args)
## @type: DataSource
## @args: [connection_type = "marketplace.athena", connection_options =
```

```
     {"tableName":"all_log_streams","schemaName":"/aws-glue/jobs/output",
      "connectionName":"test-connection-athena"}, transformation_ctx = "DataSource0"]
   ## @return: DataSource0
   ## @inputs: []
   DataSource0 = glueContext.create_dynamic_frame.from_options(connection_type =
     "marketplace.athena", connection_options = {"tableName":"all_log_streams",,
     "schemaName":"/aws-glue/jobs/output","connectionName":
     "test-connection-athena"}, transformation_ctx = "DataSource0")
   ## @type: ApplyMapping
   ## @args: [mappings = [("department", "string", "department", "string"), ("name",
"string",
     "name", "string"), ("id", "int", "id", "int")], transformation_ctx =
"Transform0"]
   ## @return: Transform0
   ## @inputs: [frame = DataSource0]
   Transform0 = ApplyMapping.apply(frame = DataSource0, mappings = [("department",
"string",
     "department", "string"), ("name", "string", "name", "string"), ("id", "int",
"id", "int")],
      transformation_ctx = "Transform0")
   ## @type: DataSink
   ## @args: [connection_type = "s3", format = "json", connection_options = {"path":
    "s3://<S3 path>/", "partitionKeys": []}, transformation_ctx = "DataSink0"]
   ## @return: DataSink0
   ## @inputs: [frame = Transform0]
   DataSink0 = glueContext.write_dynamic_frame.from_options(frame = Transform0,
     connection_type = "s3", format = "json", connection_options = {"path":
     "s3://<S3 path>/", "partitionKeys": []}, transformation_ctx = "DataSink0")
   job.commit()
```

Opciones de conexión para el tipo custom.spark o marketplace.spark

- `className`: cadena, obligatoria, nombre de clase de conector.
- `secretId`: cadena, opcional, se utiliza para recuperar las credenciales de la conexión del conector.
- `connectionName`: cadena, obligatoria, nombre de la conexión asociada al conector.
- Otras opciones dependen del almacén de datos. Por ejemplo, las opciones de configuración de OpenSearch comienzan con el prefijo `es`, tal y como se describe en la documentación Elasticsearch para Apache Hadoop. Las conexiones de Spark con Snowflake utilizan opciones tales como `sfUser` y `sfPassword`, como se describe en Uso del conector de Spark en la guía Conexión a Snowflake.

En el siguiente ejemplo de código de Python, se muestra cómo se lee desde un almacén de datos de OpenSearch mediante una conexión `marketplace.spark`.

```
   import sys
   from awsglue.transforms import *
   from awsglue.utils import getResolvedOptions
   from pyspark.context import SparkContext
   from awsglue.context import GlueContext
   from awsglue.job import Job

   ## @params: [JOB_NAME]
   args = getResolvedOptions(sys.argv, ['JOB_NAME'])

   sc = SparkContext()
   glueContext = GlueContext(sc)
   spark = glueContext.spark_session
   job = Job(glueContext)
   job.init(args['JOB_NAME'], args)
   ## @type: DataSource
   ## @args: [connection_type = "marketplace.spark", connection_options =
{"path":"test",
     "es.nodes.wan.only":"true","es.nodes":"https://<AWS endpoint>",
     "connectionName":"test-spark-es","es.port":"443"}, transformation_ctx =
"DataSource0"]
   ## @return: DataSource0
   ## @inputs: []
   DataSource0 = glueContext.create_dynamic_frame.from_options(connection_type =
     "marketplace.spark", connection_options = {"path":"test","es.nodes.wan.only":
     "true","es.nodes":"https://<AWS endpoint>","connectionName":
     "test-spark-es","es.port":"443"}, transformation_ctx = "DataSource0")
   ## @type: DataSink
   ## @args: [connection_type = "s3", format = "json", connection_options = {"path":
        "s3://<S3 path>/", "partitionKeys": []}, transformation_ctx = "DataSink0"]
   ## @return: DataSink0
   ## @inputs: [frame = DataSource0]
   DataSink0 = glueContext.write_dynamic_frame.from_options(frame = DataSource0,
      connection_type = "s3", format = "json", connection_options = {"path":
      "s3://<S3 path>/", "partitionKeys": []}, transformation_ctx = "DataSink0")
   job.commit()
```

Opciones generales

Las opciones de esta sección se proporcionan como `connection_options`, pero no se aplican específicamente a un conector.

Los siguientes parámetros se utilizan generalmente al configurar los marcadores. Se pueden aplicar a los flujos de trabajo de Amazon S3 o JDBC. Para obtener más información, consulte the section called “Uso de marcadores de trabajo”.

- `jobBookmarkKeys` — Una matriz de nombres de columna.
- `jobBookmarkKeysSortOrder` — Cadena que define cómo comparar valores en función del orden de clasificación. Valores válidos: `"asc"`, `"desc"`.
- `useS3ListImplementation` — Se utiliza para administrar el rendimiento de la memoria al publicar los contenidos de los buckets de Amazon S3. Para obtener más información, consulte Cómo optimizar la gestión de la memoria en Glue AWS.

Opciones de formato de datos para las entradas y las salidas en AWS Glue para Spark

Estas páginas ofrecen información sobre la compatibilidad de características y los parámetros de configuración para los formatos de datos compatibles con Glue AWS de Spark.. Consulte a continuación una descripción del uso y la aplicabilidad de esta información.

Compatibilidad de características en todos los formatos de datos en AWS Glue

Cada formato de datos puede admitir diferentes características de AWS Glue. Las siguientes características comunes pueden o no ser compatibles en función del tipo de formato. Consulte la documentación del formato de datos para comprender cómo aprovechar nuestras características para cumplir sus requisitos.

Lectura	AWS Glue puede reconocer e interpretar este formato de datos sin recursos adicionales, como conectores.
Escritura	AWS Glue puede escribir datos en este formato sin recursos adicionales. Puede incluir bibliotecas de terceros en su trabajo y utilizar funciones estándares de Apache Spark para escribir

	datos, como lo haría en otros entornos de Spark. Para obtener más información sobre estas bibliotecas, consulte the section called “Bibliotecas Python”.
Lectura de streamin	AWS Glue puede reconocer e interpret ar este formato de datos a partir de una transmisión de mensajes de Apache Kafka, Amazon Managed Streaming para Apache Kafka o Amazon Kinesis. Esperamos que las transmisiones presenten los datos en un formato coherente, de manera que se lean en `DataFrames` .
Grupo de archivos pequeño	AWS Glue puede agrupar archivos para enviar trabajos en lotes a cada nodo cuando se realizan transformaciones de AWS Glue. Esto puede mejorar de forma significativa el rendimiento de las cargas de trabajo que implican grandes cantidades de archivos pequeños. Para obtener más información, consulte the section called “Agrupación de archivos de entrada”.
Marcado s de trabajo	AWS Glue puede realizar un seguimiento del progreso de las transformaciones que realizan el mismo trabajo en el mismo conjunto de datos en las ejecuciones de trabajos con marcadores de trabajo. Esto puede mejorar el rendimiento de las cargas de trabajo que involucran conjuntos de datos en los que solo es necesario trabajar en los datos nuevos desde la última ejecución del trabajo. Para obtener más información, consulte the section called “Seguimiento de los datos procesados mediante marcadores de trabajo”.

Parámetros utilizados para interactuar con formatos de datos en AWS Glue

Ciertos tipos de conexión de AWS Glue admiten varios tipos de `format`, por lo que se requiere que especifique información sobre el formato de datos con un objeto `format_options` cuando utiliza métodos como `GlueContext.write_dynamic_frame.from_options`.

- `s3`: para obtener más información, consulte Tipos y opciones de conexión para ETL en AWS Glue: Parámetros de conexión S3. También puede ver la documentación de los métodos que facilitan este tipo de conexión: the section called “create_dynamic_frame_from_options” y the section called “write_dynamic_frame_from_options” en Python y los métodos de Scala the section called “getSourceWithFormat” y the section called “getSinkWithFormat” correspondientes.

- `kinesis`: para obtener más información, consulte Tipos y opciones de conexión para ETL en AWS Glue: Parámetros de conexión de Kinesis. También puede ver la documentación del método que facilita este tipo de conexión: the section called “create_data_frame_from_options” y el método de Scala the section called “createDataFrameFromOptions” correspondiente.
- `kafka`: para obtener más información, consulte Tipos y opciones de conexión para ETL en AWS Glue: Parámetros de conexión de Kafka. También puede ver la documentación del método que facilita este tipo de conexión: the section called “create_data_frame_from_options” y el método de Scala the section called “createDataFrameFromOptions” correspondiente.

Algunos tipos de conexión no requieren `format_options`. Por ejemplo, en uso normal, una conexión de JDBC a una base de datos relacional recupera datos en un formato de datos tabular y consistente. Por lo tanto, la lectura desde una conexión de JDBC no requeriría `format_options`.

Algunos métodos para leer y escribir datos en Glue no requieren `format_options`. Por ejemplo, el uso de `GlueContext.create_dynamic_frame.from_catalog` con rastreadores de AWS Glue. Los rastreadores determinan la forma de los datos. Cuando se utilicen rastreadores, el clasificador de AWS Glue examinará los datos para tomar decisiones inteligentes sobre cómo representar el formato de datos. Luego, almacenará una representación de los datos en Data Catalog de AWS Glue, que se puede utilizar dentro de un script de ETL de AWS Glue para recuperar los datos con el método `GlueContext.create_dynamic_frame.from_catalog`. Los rastreadores eliminan la necesidad de especificar de forma manual la información sobre el formato de los datos.

Para trabajos que acceden a tablas que se rigen por AWS Lake Formation, AWS Glue admite la lectura y escritura de todos los formatos admitidos por las tablas que rige Lake Formation. Para obtener la lista actualizada de los formatos admitidos para tablas que se rigen por AWS Lake

Formation, consulte Notas y restricciones para las tablas regidas en la Guía para desarrolladores de AWS Lake Formation.

> **Note**
>
> Para escribir Apache Parquet, ETL de AWS Glue solo admite la escritura en una tabla regida al especificar una opción para un tipo de escritor de Parquet personalizado optimizado para marcos dinámicos. Al escribir en una tabla regida con el formato de `parquet`, debe agregar la clave `useGlueParquetWriter` con un valor de `true` en los parámetros de la tabla.

Temas

- Uso del formato CSV en AWS Glue
- Uso del formato Parquet en AWS Glue
- Uso del formato XML en AWS Glue
- Uso del formato Avro en AWS Glue
- Uso del formato grokLog en AWS Glue
- Uso del formato Ion en AWS Glue
- Uso del formato JSON en AWS Glue
- Uso del formato ORC en AWS Glue
- Uso de marcos de lagos de datos con trabajos de ETL de AWS Glue
- Referencia de configuración compartida

Uso del formato CSV en AWS Glue

AWS Glue recupera datos de fuentes y escribe datos en destinos almacenados y transportados en varios formatos de datos. Si sus datos se almacenan o transportan en formato de datos CSV, este documento presenta las funciones disponibles para usar sus datos en AWS Glue.

AWS Glue admite el formato de archivo de valores separados por comas (CSV). Este formato es un formato de datos mínimo basado en filas. Los CSV a menudo no se ajustan estrictamente a un estándar, pero puede consultar RFC 4180 y RFC 7111 para obtener más información.

Puede usar AWS Glue para leer los CSV de Amazon S3 y de orígenes de streaming, o para escribir los CSV en Amazon S3. Puede leer y escribir archivos `bzip` y `gzip` que contengan archivos CSV de

S3. Debe configurar el comportamiento de compresión en el Parámetros de conexión S3 en lugar de en la configuración que se describe en esta página.

En la siguiente tabla se muestran las características comunes de AWS Glue que admiten la opción de formato CSV.

Lectura	Escritura	Lectura de streaming	Grupo de archivos pequeños	Marcadores de trabajo
Compatible	Soportado	Soportado	Soportado	Compatible

Ejemplo: leer archivos o carpetas CSV de S3

Requisitos previos: necesitará las rutas de S3 (`s3path`) en las carpetas o archivos CSV que desee leer.

Configuración: en las opciones de la función, especifique `format="csv"`. En sus `connection_options`, utilice la clave `paths` para especificar `s3path`. Puede configurar la forma en que el lector interactúa con S3 en `connection_options`. Para obtener más información, consulte Tipos y opciones de conexión para ETL en AWS Glue: Parámetros de conexión S3. Puede configurar el modo en que el lector interpreta los archivos CSV en su `format_options`. Para obtener más información, consulte Referencia de configuración de CSV.

El siguiente script de ETL de AWS Glue muestra el proceso de lectura de archivos o carpetas CSV desde S3.

Proporcionamos un lector de CSV personalizado con optimizaciones de rendimiento para flujos de trabajo comunes a través de la clave de configuración `optimizePerformance`. Para determinar si este lector es adecuado para su carga de trabajo, consulte the section called “Uso de un lector CSV optimizado”.

Python

Para este ejemplo, use el método create_dynamic_frame.from_options.

```
# Example: Read CSV from S3
# For show, we handle a CSV with a header row.  Set the withHeader option.
```

```
# Consider whether optimizePerformance is right for your workflow.

from pyspark.context import SparkContext
from awsglue.context import GlueContext

sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)
spark = glueContext.spark_session

dynamicFrame = glueContext.create_dynamic_frame.from_options(
    connection_type="s3",
    connection_options={"paths": ["s3://s3path"]},
    format="csv",
    format_options={
        "withHeader": True,
        # "optimizePerformance": True,
    },
)
```

También puede usar DataFrames en un script (`pyspark.sql.DataFrame`).

```
dataFrame = spark.read\
    .format("csv")\
    .option("header", "true")\
    .load("s3://s3path")
```

Scala

Para este ejemplo, use la operación getSourceWithFormat.

```
// Example: Read CSV from S3
// For show, we handle a CSV with a header row.  Set the withHeader option.
// Consider whether optimizePerformance is right for your workflow.

import com.amazonaws.services.glue.util.JsonOptions
import com.amazonaws.services.glue.{DynamicFrame, GlueContext}
import org.apache.spark.SparkContext

object GlueApp {
  def main(sysArgs: Array[String]): Unit = {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)
```

```
    val dynamicFrame = glueContext.getSourceWithFormat(
      formatOptions=JsonOptions("""{"withHeader": true}"""),
      connectionType="s3",
      format="csv",
      options=JsonOptions("""{"paths": ["s3://s3path"], "recurse": true}""")
    ).getDynamicFrame()
  }
}
```

También puede usar DataFrames en un script (`org.apache.spark.sql.DataFrame`).

```
val dataFrame = spark.read
  .option("header","true")
  .format("csv")
  .load("s3://s3path“)
```

Ejemplo: escribir archivos y carpetas CSV en S3

Requisitos previos: necesitará un DataFrame inicializado (`dataFrame`) o un DynamicFrame (`dynamicFrame`). También necesitará la ruta de salida S3 prevista, `s3path`.

Configuración: en las opciones de la función, especifique `format="csv"`. En sus `connection_options`, utilice la clave `paths` para especificar `s3path`. Puede configurar la forma en que el escritor interactúa con S3 en `connection_options`. Para obtener más información, consulte Tipos y opciones de conexión para ETL en AWS Glue: Parámetros de conexión S3. Puede configurar la forma en que la operación escribe el contenido de los archivos en `format_options`. Para obtener más información, consulte Referencia de configuración de CSV. El siguiente script de ETL de AWS Glue muestra el proceso de escritura de archivos y carpetas CSV en S3.

Python

Para este ejemplo, use el método write_dynamic_frame.from_options.

```
# Example: Write CSV to S3
# For show, customize how we write string type values.  Set quoteChar to -1 so our
 values are not quoted.

from pyspark.context import SparkContext
from awsglue.context import GlueContext
```

```
sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

glueContext.write_dynamic_frame.from_options(
    frame=dynamicFrame,
    connection_type="s3",
    connection_options={"path": "s3://s3path"},
    format="csv",
    format_options={
        "quoteChar": -1,
    },
)
```

También puede usar DataFrames en un script (`pyspark.sql.DataFrame`).

```
dataFrame.write\
    .format("csv")\
    .option("quote", None)\
    .mode("append")\
    .save("s3://s3path")
```

Scala

Para este ejemplo, use el método getSinkWithFormat.

```
// Example: Write CSV to S3
// For show, customize how we write string type values. Set quoteChar to -1 so our
 values are not quoted.

import com.amazonaws.services.glue.util.JsonOptions
import com.amazonaws.services.glue.{DynamicFrame, GlueContext}
import org.apache.spark.SparkContext

object GlueApp {
  def main(sysArgs: Array[String]): Unit = {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)

    glueContext.getSinkWithFormat(
        connectionType="s3",
        options=JsonOptions("""{"path": "s3://s3path"}"""),
```

```
        format="csv"
    ).writeDynamicFrame(dynamicFrame)
  }
}
```

También puede usar DataFrames en un script (`org.apache.spark.sql.DataFrame`).

```
dataFrame.write
    .format("csv")
    .option("quote", null)
    .mode("Append")
    .save("s3://s3path")
```

Referencia de la configuración de CVS

Puede utilizar las siguientes `format_options` donde las bibliotecas de AWS Glue especifiquen `format="csv"`:

- `separator`: especifica el carácter delimitador. El valor predeterminado es una coma, pero puede especificarse cualquier otro carácter.
  - Tipo: Texto, Valor predeterminado: `","`
- `escaper`: especifica un carácter que se usa para aplicar escape. Esta opción solo se usa cuando se leen archivos CSV, no cuando se escriben. Si se habilita, el carácter que va inmediatamente después se usa tal cual, excepto un pequeño conjunto de escapes conocidos (`\n`, `\r`, `\t` y `\0`).
  - Tipo: Texto, Valor predeterminado: ninguno
- `quoteChar`: especifica el carácter que se usa para aplicar comillas. El carácter predeterminado es una comilla doble. Establezca esta opción en `-1` para desactivar las comillas por completo.
  - Tipo: Texto, Valor predeterminado: `'"'`
- `multiLine`: especifica si un solo registro puede abarcar varias líneas. Esto puede suceder cuando un campo contiene un carácter de nueva línea entre comillas. Debe configurar esta opción en `True` si un registro abarca varias líneas. Habilitar `multiLine` podría disminuir el rendimiento ya que requiere una división de archivos más cuidadosa durante el análisis.
  - Tipo: Booleano, Valor predeterminado: `false`
- `withHeader`: especifica si la primera línea se debe tratar como un encabezado. Esta opción se puede utilizar en la clase `DynamicFrameReader`.
  - Tipo: Booleano, Valor predeterminado: `false`

- `writeHeader`: especifica si se debe escribir el encabezado en la salida. Esta opción se puede utilizar en la clase `DynamicFrameWriter`.
  - Tipo: Booleano, Valor predeterminado: `true`
- `skipFirst`: especifica si se debe omitir la primera línea de datos.
  - Tipo: Booleano, Valor predeterminado: `false`
- `optimizePerformance`: especifica si se debe utilizar el lector CSV SIMD avanzado junto con los formatos de memoria columnar basados en Apache Arrow. Solo se encuentra disponible en 3.0+ AWS Glue.
  - Tipo: Booleano, Valor predeterminado: `false`
- `strictCheckForQuoting`: al escribir archivos CSV, Glue puede agregar comillas a los valores que interpreta como cadenas. Esto se hace para evitar la ambigüedad en lo que está escrito. Para ahorrar tiempo a la hora de decidir qué escribir, Glue puede citar en determinadas situaciones en las que las citas no son necesarias. Si se habilita una verificación estricta, el cálculo será más intensivo y solo cotizará cuando sea estrictamente necesario. Solo se encuentra disponible en 3.0+ AWS Glue.
  - Tipo: Booleano, Valor predeterminado: `false`

Optimice el rendimiento de lectura con el lector CSV SIMD vectorizado

AWS Glue versión 3.0 agrega un lector de CSV optimizado que puede acelerar significativamente el rendimiento general del trabajo en comparación con los lectores de CSV basados en filas.

El lector optimizado:

- Usa las instrucciones de la CPU SIMD para leer desde el disco
- Escribe inmediatamente los registros en la memoria en un formato de columnas (Apache Arrow)
- Divide los registros en lotes

Esto ahorra tiempo de procesamiento cuando los registros se agrupan en lotes o se convierten a un formato de columnas más adelante. Algunos ejemplos son cuando se cambian esquemas o se recuperan datos por columna.

Para usar el lector optimizado, configure "`optimizePerformance`" como `true` en `format_options` o propiedad de tabla.

```
glueContext.create_dynamic_frame.from_options(
```

```
    frame = datasource1,
    connection_type = "s3",
    connection_options = {"paths": ["s3://s3path"]},
    format = "csv",
    format_options={
        "optimizePerformance": True,
        "separator": ","
        },
    transformation_ctx = "datasink2")
```

Limitaciones para el lector CSV vectorizado

Tenga en cuenta las siguientes limitaciones del lector de CSV vectorizado:

- No soporta opciones de formato `multiLine` y `escaper`. Utiliza el `escaper` predeterminado del carácter de comillas dobles `'"'`. Cuando se establecen estas opciones, AWS Glue automáticamente vuelve a utilizar el lector CSV basado en filas.
- No soporta la creación de un DynamicFrame con ChoiceType.
- No soporta la creación de un DynamicFrame con registros de error.
- No soporta la lectura de archivos CSV con caracteres multibyte, como caracteres japoneses o chinos.

Uso del formato Parquet en AWS Glue

AWS Glue recupera datos de fuentes y escribe datos en destinos almacenados y transportados en varios formatos de datos. Si sus datos se almacenan o transportan en el formato de datos Parquet, este documento presenta las funciones disponibles para usar sus datos en AWS Glue

AWS Glue admite el uso del formato Parquet. Este formato es un formato de datos basado en columnas y orientado al rendimiento. Para obtener una introducción al formato por parte de la autoridad de normalización, consulte Información general de la documentación de Apache Parquet.

Puede usar AWS Glue para leer archivos Parquet de Amazon S3 y de orígenes de streaming, como también escribir archivos Parquet en Amazon S3. Puede leer y escribir archivos `bzip` y `gzip` que contengan archivos Parquet de S3. Debe configurar el comportamiento de compresión en el Parámetros de conexión S3 en lugar de en la configuración que se describe en esta página.

En la siguiente tabla se muestran las características comunes de AWS Glue que admiten la opción de formato Parquet.

Lectura	Escritura	Lectura de streaming	Grupo de archivos pequeños	Marcadores de trabajo
Compatible	Soportado	Compatible	No se admite	Compatible*

* Compatible con AWS Glue versión 1.0 y posterior

Ejemplo: leer archivos o carpetas de Parquet desde S3

Requisitos previos: necesitará las rutas de S3 (`s3path`) en las carpetas o archivos Parquet que desee leer.

Configuración: en las opciones de la función, especifique `format="parquet"`. En sus `connection_options`, utilice la clave `paths` para especificar su `s3path`.

Puede configurar la forma en que el lector interactúa con S3 en la `connection_options`. Para obtener más información, consulte Tipos y opciones de conexión para ETL en AWS Glue: Parámetros de conexión S3.

Puede configurar la forma en que el lector interpreta los archivos Parquet en sus `format_options`. Para obtener más información, consulte Referencia de configuración de Parquet.

El siguiente script de ETL de AWS Glue muestra el proceso de lectura de archivos o carpetas Parquet desde S3:

Python

Para este ejemplo, use el método create_dynamic_frame.from_options.

```
# Example: Read Parquet from S3

from pyspark.context import SparkContext
from awsglue.context import GlueContext

sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)
spark = glueContext.spark_session

dynamicFrame = glueContext.create_dynamic_frame.from_options(
```

```
    connection_type = "s3",
    connection_options = {"paths": ["s3://s3path/"]},
    format = "parquet"
)
```

También puede usar DataFrames en un script (`pyspark.sql.DataFrame`).

```
dataFrame = spark.read.parquet("s3://s3path/")
```

Scala

Para este ejemplo, use el método getSourceWithFormat.

```
// Example: Read Parquet from S3

import com.amazonaws.services.glue.util.JsonOptions
import com.amazonaws.services.glue.{DynamicFrame, GlueContext}
import org.apache.spark.SparkContext

object GlueApp {
  def main(sysArgs: Array[String]): Unit = {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)

    val dynamicFrame = glueContext.getSourceWithFormat(
      connectionType="s3",
      format="parquet",
      options=JsonOptions("""{"paths": ["s3://s3path"]}""")
    ).getDynamicFrame()
  }
}
```

También puede usar DataFrames en un script (`org.apache.spark.sql.DataFrame`).

```
spark.read.parquet("s3://s3path/")
```

Ejemplo: escribir archivos y carpetas de Parquet en S3

Requisitos previos: necesitará un DataFrame inicializado (`dataFrame`) o DynamicFrame (`dynamicFrame`). También necesitará la ruta de salida S3 prevista, `s3path`.

Configuración: en las opciones de la función, especifique `format="parquet"`. En sus `connection_options`, utilice la clave `paths` para especificar `s3path`.

Puede modificar aún más la forma en que el escritor interactúa con S3 en las `connection_options`. Para obtener más información, consulte Tipos y opciones de conexión para ETL en AWS Glue: Parámetros de conexión S3. Puede configurar la forma en que la operación escribe el contenido de los archivos en `format_options`. Para obtener más información, consulte Referencia de configuración de Parquet.

El siguiente script de ETL de AWS Glue muestra el proceso de escritura de archivos y carpetas Parquet en S3.

Proporcionamos un escritor de Parquet personalizado con optimizaciones de rendimiento para DynamicFrames, a través de la clave de la configuración `useGlueParquetWriter`. Para determinar si este escritor es adecuado para su carga de trabajo, consulte Escritor de Glue Parquet.

Python

Para este ejemplo, use el método write_dynamic_frame.from_options.

```
# Example: Write Parquet to S3
# Consider whether useGlueParquetWriter is right for your workflow.

from pyspark.context import SparkContext
from awsglue.context import GlueContext

sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

glueContext.write_dynamic_frame.from_options(
    frame=dynamicFrame,
    connection_type="s3",
    format="parquet",
    connection_options={
        "path": "s3://s3path",
    },
    format_options={
        # "useGlueParquetWriter": True,
    },
)
```

También puede usar DataFrames en un script (`pyspark.sql.DataFrame`).

```
df.write.parquet("s3://s3path/")
```

Scala

Para este ejemplo, use el método getSinkWithFormat.

```
// Example: Write Parquet to S3
// Consider whether useGlueParquetWriter is right for your workflow.

import com.amazonaws.services.glue.util.JsonOptions
import com.amazonaws.services.glue.{DynamicFrame, GlueContext}
import org.apache.spark.SparkContext

object GlueApp {
  def main(sysArgs: Array[String]): Unit = {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)

    glueContext.getSinkWithFormat(
        connectionType="s3",
        options=JsonOptions("""{"path": "s3://s3path"}"""),
        format="parquet"
    ).writeDynamicFrame(dynamicFrame)
  }
}
```

También puede usar DataFrames en un script (`org.apache.spark.sql.DataFrame`).

```
df.write.parquet("s3://s3path/")
```

Referencia de configuración de Parquet

Puede utilizar las siguientes `format_options` donde las bibliotecas de AWS Glue especifiquen `format="parquet"`:

- `useGlueParquetWriter`: especifica el uso de un escritor Parquet personalizado que tiene optimizaciones de rendimiento para flujos de trabajo de DynamicFrame. Para obtener más información sobre el uso, consulte Escritor de Glue Parquet.
  - Tipo: Booleano, Valor predeterminado:`false`

- `compression`: especifica el códec de compresión utilizado. Los valores son totalmente compatibles con `org.apache.parquet.hadoop.metadata.CompressionCodecName`.
  - Tipo: Texto enumerado, Valor predeterminado: `"snappy"`
  - Valores: `"uncompressed"`, `"snappy"`, `"gzip"` y `"lzo"`
- `blockSize`: especifica el tamaño en bytes de un grupo de filas que se están almacenando en el búfer. Se usa para ajustar el rendimiento. El tamaño debe dividirse exactamente en un número de megabytes.
  - Tipo: Numérico, Valor predeterminado:`134217728`
  - El valor predeterminado es igual a 128 MB.
- `pageSize`: especifica el tamaño en bytes de una página. Se usa para ajustar el rendimiento. Una página es la unidad más pequeña que debe leerse por completo para obtener acceso a un único registro.
  - Tipo: Numérico, Valor predeterminado:`1048576`
  - El valor predeterminado es igual a 1 MB.

> **Note**
>
> Además, se pueden transferir a este formato las opciones que acepte el código SparkSQL subyacente mediante el parámetro de mapa `connection_options`. Por ejemplo, se puede establecer una configuración de Spark como mergeSchema para que el lector de Spark de AWS Glue fusione el esquema para todos los archivos.

Optimice el rendimiento de escritura con el escritor de AWS Glue Parquet

> **Note**
>
> Históricamente, se ha accedido al escritor de AWS Glue Parquet mediante el tipo de formato `glueparquet`. Ya no se aboga por este patrón de acceso. En su lugar, utilice el tipo `parquet` con `useGlueParquetWriter` habilitado.

El escritor AWS Glue Parquet tiene mejoras de rendimiento que permiten escribir archivos Parquet más rápidamente. El escritor tradicional calcula un esquema antes de escribir. El formato Parquet no almacena el esquema de forma que se pueda recuperar rápidamente, por lo que puede llevar algún

tiempo. Con el escritor de AWS Glue Parquet, no se requiere un esquema precalculado. A medida que llegan los datos, el escritor calcula y modifica el esquema e forma dinámica.

Cuando especifique `useGlueParquetWriter`, tenga en cuenta las siguientes limitaciones:

- El escritor solo admite la evolución de los esquemas (como agregar o eliminar columnas) pero no permite cambiar los tipos de columnas, como sucede con `ResolveChoice`.
- El escritor no puede almacenar un DataFrame vacío, por ejemplo, para escribir un archivo solo de esquema. Al realizar la integración con el Catálogo de datos de AWS Glue mediante la configuración de `enableUpdateCatalog=True`, si se intenta escribir un DataFrame vacío, no se actualizará el Catálogo de datos. Esto creará una tabla sin esquema en el Catálogo de datos.

Si su transformación no requiere estas limitaciones, activar el escritor AWS Glue Parquet debería aumentar el rendimiento.

Uso del formato XML en AWS Glue

AWS Glue recupera datos de fuentes y escribe datos en destinos almacenados y transportados en varios formatos de datos. Si sus datos se almacenan o transportan en formato de datos XML, este documento presenta las funciones disponibles para usar sus datos en AWS Glue.

AWS Glue admite el uso del formato XML. Este formato representa estructuras de datos altamente configurables y rígidamente definidas que no están basadas en filas o columnas. XML es altamente estandarizado. Para obtener una introducción al formato de la autoridad de normalización, consulte Elementos esenciales de XML.

Puede usar AWS Glue para leer archivos XML desde Amazon S3, así como archivos `bzip` y `gzip` que contengan archivos XML. Debe configurar el comportamiento de compresión en el Parámetros de conexión S3 en lugar de en la configuración que se describe en esta página.

En la siguiente tabla se muestran las características comunes de AWS Glue que admiten la opción de formato XML.

Lectura	Escritura	Lectura de streaming	Grupo de archivos pequeños	Marcadores de trabajo
Compatible	No se admite	No se admite	Soportado	Compatible

Ejemplo: leer XML desde S3

El lector de XML toma un nombre de etiqueta XML. Examina los elementos con esa etiqueta dentro de su entrada para inferir un esquema y rellena un DynamicFrame con los valores correspondientes. La funcionalidad XML de AWS Glue se comporta de forma similar al Origen de datos XML para Apache Spark. Es posible que pueda obtener información sobre el comportamiento básico comparando este lector con la documentación de ese proyecto.

Requisitos previos: necesitará las rutas de S3 (`s3path`) en las carpetas o archivos XML que desee leer, y cierta información sobre su archivo XML. También necesitará la etiqueta del elemento XML que desea leer, `xmlTag`.

Configuración: en las opciones de la función, especifique `format="xml"`. En sus `connection_options`, utilice la clave `paths` para especificar `s3path`. Puede configurar aún más la forma en que el lector interactúa con S3 en la `connection_options`. Para obtener más información, consulte Tipos y opciones de conexión para ETL en AWS Glue: Parámetros de conexión S3. En sus `format_options`, utilice la clave `rowTag` para especificar `xmlTag`. Puede configurar aún más la forma en que el lector interpreta los archivos XML en sus `format_options`. Para obtener más información, consulte Referencia de configuración de XML.

El siguiente script de ETL de AWS Glue muestra el proceso de lectura de archivos o carpetas XML desde S3.

Python

Para este ejemplo, use el método create_dynamic_frame.from_options.

```
# Example: Read XML from S3
# Set the rowTag option to configure the reader.

from awsglue.context import GlueContext
from pyspark.context import SparkContext

sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

dynamicFrame = glueContext.create_dynamic_frame.from_options(
    connection_type="s3",
    connection_options={"paths": ["s3://s3path"]},
    format="xml",
    format_options={"rowTag": "xmlTag"},
```

```
)
```

También puede usar DataFrames en un script (`pyspark.sql.DataFrame`).

```
dataFrame = spark.read\
    .format("xml")\
    .option("rowTag", "xmlTag")\
    .load("s3://s3path")
```

Scala

Para este ejemplo, use la operación getSourceWithFormat.

```
// Example: Read XML from S3
// Set the rowTag option to configure the reader.

import com.amazonaws.services.glue.util.JsonOptions
import com.amazonaws.services.glue.GlueContext
import org.apache.spark.sql.SparkSession

val glueContext = new GlueContext(SparkContext.getOrCreate())
val sparkSession: SparkSession = glueContext.getSparkSession

object GlueApp {
  def main(sysArgs: Array[String]): Unit = {
    val dynamicFrame = glueContext.getSourceWithFormat(
      formatOptions=JsonOptions("""{"rowTag": "xmlTag"}"""),
      connectionType="s3",
      format="xml",
      options=JsonOptions("""{"paths": ["s3://s3path"], "recurse": true}""")
    ).getDynamicFrame()
}
```

También puede usar DataFrames en un script (`org.apache.spark.sql.DataFrame`).

```
val dataFrame = spark.read
  .option("rowTag", "xmlTag")
  .format("xml")
  .load("s3://s3path“)
```

Referencia de configuración de XML

Puede utilizar las siguientes `format_options` donde las bibliotecas de AWS Glue especifiquen `format="xml"`:

- `rowTag`: especifica la etiqueta XML en el archivo que se tratará como una fila. Las etiquetas de fila no pueden autocerrarse.
  - Tipo: Texto, Obligatorio
- `encoding`: especifica la codificación de caracteres. Puede ser el nombre o alias de un Charset compatible con nuestro entorno de tiempo de ejecución. No ofrecemos garantías específicas en cuanto a la compatibilidad con la codificación, pero las codificaciones principales deberían funcionar.
  - Tipo: Texto, Valor predeterminado: `"UTF-8"`
- `excludeAttribute`: especifica si desea excluir o no atributos en elementos.
  - Tipo: Booleano, Valor predeterminado: `false`
- `treatEmptyValuesAsNulls`: especifica si los espacios en blanco se tratan como un valor nulo.
  - Tipo: Booleano, Valor predeterminado: `false`
- `attributePrefix`: un prefijo de atributos para diferenciarlos del texto de elementos secundarios. Este prefijo se utiliza para los nombres de campo.
  - Tipo: Texto, Valor predeterminado: `"_"`
- `valueTag`: la etiqueta que se utiliza para un valor cuando hay atributos en el elemento que no tienen elementos secundarios.
  - Tipo: Texto, Valor predeterminado: `"_VALUE"`
- `ignoreSurroundingSpaces`: especifica si se deben ignorar los espacios en blanco alrededor de los valores.
  - Tipo: Booleano, Valor predeterminado: `false`
- `withSchema`: contiene el esquema esperado, en situaciones en las que se desea anular el esquema inferido. Si no utiliza esta opción, AWS Glue infiere el esquema a partir de los datos XML.
  - Tipo: Texto, Valor predeterminado: no aplicable
  - El valor debe ser un objeto JSON que represente un `StructType`.

Especifique manualmente el esquema XML

Ejemplo del esquema XML manual

Este es un ejemplo de uso de la opción del formato `withSchema` para especificar el esquema para los datos XML.

```
from awsglue.gluetypes import *

schema = StructType([
  Field("id", IntegerType()),
  Field("name", StringType()),
  Field("nested", StructType([
    Field("x", IntegerType()),
    Field("y", StringType()),
    Field("z", ChoiceType([IntegerType(), StringType()]))
  ]))
])

datasource0 = create_dynamic_frame_from_options(
    connection_type,
    connection_options={"paths": ["s3://xml_bucket/someprefix"]},
    format="xml",
    format_options={"withSchema": json.dumps(schema.jsonValue())},
    transformation_ctx = ""
)
```

Uso del formato Avro en AWS Glue

AWS Glue recupera datos de fuentes y escribe datos en destinos almacenados y transportados en varios formatos de datos. Si los datos se almacenan o se transportan en formato de datos Avro, este documento presenta las características disponibles para utilizar los datos en AWS Glue.

AWS Glue admite el uso del formato Avro. Este es un formato de datos basado en filas y orientado al rendimiento. Para obtener una introducción al formato por parte de la autoridad de normalización, consulte Documentación de Apache Avro 1.8.2.

Puede utilizar AWS Glue para leer archivos Avro de Amazon S3 y de orígenes de streaming, como también para escribir archivos Avro en Amazon S3. Puede leer y escribir archivos `bzip2` y `gzip` que contengan archivos Avro de S3. Además, puede escribir `deflate`, `snappy` y `xz` archivos que contengan archivos Avro. Debe configurar el comportamiento de compresión en el Parámetros de conexión S3 en lugar de en la configuración que se describe en esta página.

En la siguiente tabla se muestran las operaciones comunes de AWS Glue que admiten la opción de formato Avro.

Lectura	Escritura	Lectura de streaming	Grupo de archivos pequeños	Marcadores de trabajo
Compatible	Compatible	Compatible*	No se admite	Compatible

*Compatible con restricciones. Para obtener más información, consulte the section called “Notas y restricciones para orígenes de streaming de Avro”.

Ejemplo: leer archivos o carpetas Avro de S3

Requisitos previos: necesitará las rutas de S3 (`s3path`) de las carpetas o los archivos Avro que desee leer.

Configuración: en las opciones de la función, especifique `format="avro"`. En sus `connection_options`, utilice la clave `paths` para especificar `s3path`. Puede configurar la forma en que el lector interactúa con S3 en la `connection_options`. Para obtener más información, consulte Opciones de formato de datos para entradas y salidas de ETL en AWS Glue: the section called “Parámetros de conexión S3”. Puede configurar la manera en que el lector interpreta los archivos Avro en sus `format_options`. Para obtener más información, consulte Referencia de configuración de Avro.

El siguiente script de ETL de AWS Glue muestra el proceso de lectura de archivos o carpetas Avro de S3:

Python

Para este ejemplo, use el método create_dynamic_frame.from_options.

```
from pyspark.context import SparkContext
from awsglue.context import GlueContext

sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

dynamicFrame = glueContext.create_dynamic_frame.from_options(
```

```
    connection_type="s3",
    connection_options={"paths": ["s3://s3path"]},
    format="avro"
)
```

Scala

Para este ejemplo, use la operación getSourceWithFormat.

```
import com.amazonaws.services.glue.util.JsonOptions
import com.amazonaws.services.glue.GlueContext
import org.apache.spark.sql.SparkContext

object GlueApp {
  def main(sysArgs: Array[String]): Unit = {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)

    val dynamicFrame = glueContext.getSourceWithFormat(
      connectionType="s3",
      format="avro",
      options=JsonOptions("""{"paths": ["s3://s3path"]}""")
    ).getDynamicFrame()
  }
```

Ejemplo: escribir archivos y carpetas Avro en S3

Requisitos previos: necesitará un DataFrame inicializado (`dataFrame`) o DynamicFrame (`dynamicFrame`). También necesitará la ruta de salida S3 prevista, `s3path`.

Configuración: en las opciones de la función, especifique `format="avro"`. En sus `connection_options`, utilice la clave `paths` para especificar su `s3path`. Puede modificar aún más la forma en que el escritor interactúa con S3 en las `connection_options`. Para obtener más información, consulte Opciones de formato de datos para entradas y salidas de ETL en AWS Glue: the section called “Parámetros de conexión S3”. Puede alterar la manera en que el escritor interpreta los archivos Avro en sus `format_options`. Para obtener más información, consulte Referencia de configuración de Avro.

El siguiente script de ETL de AWS Glue muestra el proceso de escritura de archivos o carpetas Avro en S3.

Python

Para este ejemplo, use el método write_dynamic_frame.from_options.

```
from pyspark.context import SparkContext
from awsglue.context import GlueContext

sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

glueContext.write_dynamic_frame.from_options(
    frame=dynamicFrame,
    connection_type="s3",
    format="avro",
    connection_options={
        "path": "s3://s3path"
    }
)
```

Scala

Para este ejemplo, use el método getSinkWithFormat.

```
import com.amazonaws.services.glue.util.JsonOptions
import com.amazonaws.services.glue.{DynamicFrame, GlueContext}
import org.apache.spark.SparkContext

object GlueApp {
  def main(sysArgs: Array[String]): Unit = {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)

    glueContext.getSinkWithFormat(
      connectionType="s3",
      options=JsonOptions("""{"path": "s3://s3path"}"""),
      format="avro"
    ).writeDynamicFrame(dynamicFrame)
  }
}
```

Referencia de configuración de Avro

Puede utilizar los siguientes valores `format_options` donde las bibliotecas de AWS Glue especifiquen `format="avro"`:

- `version`: especifica la versión del formato lector/escritor Apache Avro que se va a soportar. El valor predeterminado es 1.7. Puede especificar `format_options={"version": “1.8”}` para habilitar el tipo de lectura y escritura lógico de Avro. Para obtener más información, consulte la especificación de Apache Avro 1.7.7 y la especificación de Apache Avro 1.8.2.

  El conector de Apache Avro 1.8 admite las siguientes conversiones de tipo lógico:

Para el lector: en esta tabla, se muestra la conversión entre el tipo de datos de Avro (tipo lógico y tipo primitivo de Avro) y el tipo de datos `DynamicFrame` de AWS Glue para las versiones 1.7 y 1.8 del lector de Avro.

Tipo de datos de Avro: Tipo lógico	Tipo de datos de Avro: Tipo primitivo de Avro	Tipo de datos DynamicFrame de Glue: Lector 1.7 de Avro	Tipo de datos DynamicFrame de Glue: Lector 1.8 de Avro
Decimal	bytes	BINARIO	Decimal
Decimal	fijo	BINARIO	Decimal
Date	int	INT	Date
Tiempo (milisegundos)	int	INT	INT
Tiempo (microsegundos)	long	LONG	LONG
Marca de tiempo (milisegundos)	long	LONG	Timestamp
Marca de tiempo (microsegundos)	long	LONG	LONG

Tipo de datos de Avro: Tipo lógico	Tipo de datos de Avro: Tipo primitivo de Avro	Tipo de datos DynamicFrame de Glue: Lector 1.7 de Avro	Tipo de datos DynamicFrame de Glue: Lector 1.8 de Avro
Duración (no es un tipo lógico)	fijo de 12	BINARIO	BINARIO

Para el escritor: en esta tabla, se muestra la conversión entre el tipo de datos `DynamicFrame` de AWS Glue y el tipo de datos de Avro para las versiones 1.7 y 1.8 del escritor de Avro.

Tipo de datos **`DynamicFrame`** de AWS Glue	Tipo de datos de Avro: Escritor 1.7 de Avro	Tipo de datos de Avro: Escritor 1.8 de Avro
Decimal	Cadena	decimal
Date	Cadena	date
Timestamp	Cadena	marca temporal (microsegundos)

Compatibilidad entre Avro y Spark DataFrame

Para utilizar Avro desde la API de Spark DataFrame, debe instalar el complemento Spark Avro para la versión de Spark correspondiente. La versión de Spark disponible en su trabajo está determinada por la versión de AWS Glue. Para obtener más información acerca de las versiones de Spark, consulte the section called “AWS GlueVersiones de ”. Apache mantiene este complemento; nosotros no ofrecemos garantías específicas de compatibilidad.

En AWS Glue 2.0 se utiliza la versión 2.4.3 del complemento Spark Avro. Puede encontrar este JAR en Maven Central, consulte org.apache.spark:spark-avro_2.12:2.4.3.

En AWS Glue 3.0 se utiliza la versión 3.1.1 del complemento Spark Avro. Puede encontrar este JAR en Maven Central, consulte org.apache.spark:spark-avro_2.12:3.1.1.

Para incluir archivos JAR adicionales en un trabajo de ETL de AWS Glue, utilice el parámetro de trabajo `--extra-jars`. Para obtener más información acerca de la configuración de parámetros de trabajos, consulte the section called “Parámetros del flujo de trabajo”. También puede configurar este parámetro en la Consola de administración de AWS.

Uso del formato grokLog en AWS Glue

AWS Glue recupera datos de fuentes y escribe datos en destinos almacenados y transportados en varios formatos de datos. Si los datos se almacenan o se transportan en texto sin formato y en un formato poco estructurado, este documento presenta las características disponibles para utilizar los datos en AWS Glue a través de patrones de Grok.

AWS Glue admite el uso de patrones de Grok. Los patrones de Grok son similares a los grupos de captura de expresiones regulares. Reconocen patrones de secuencias de caracteres en un archivo de texto sin formato y les dan un tipo y un propósito. En AWS Glue, su objetivo principal es leer registros. Para obtener una introducción a Grok por parte de los autores, consulte Referencia de Logstash: complemento de filtro de Grok.

Lectura	Escritura	Lectura de streaming	Grupo de archivos pequeños	Marcadores de trabajo
Compatible	No aplicable	Soportado	Compatible	No se admite

Referencia de configuración de grokLog

Puede utilizar los siguientes valores `format_options` con `format="grokLog"`:

- `logFormat`: especifica el patrón de Grok que coincide con el formato del registro.
- `customPatterns`: especifica los patrones de Grok adicionales que se utilizan aquí.
- `MISSING`: especifica la señal que se utilizará en la identificación de los valores que faltan. El valor predeterminado es `'-'`.
- `LineCount`: especifica el número de líneas en cada registro. El valor predeterminado es `'1'` y actualmente solo se admiten los registros de una sola línea.
- `StrictMode`: un valor booleano que especifica si el modo estricto está habilitado. En modo estricto, el lector no efectúa la conversión o recuperación de tipo automática. El valor predeterminado es `"false"`.

Uso del formato Ion en AWS Glue

AWS Glue recupera datos de fuentes y escribe datos en destinos almacenados y transportados en varios formatos de datos. Si los datos se almacenan o se transportan en formato de datos Ion, este documento presenta las características disponibles para utilizar los datos en AWS Glue.

AWS Glue admite el uso del formato Ion. Este formato representa estructuras de datos (que no están basadas en filas o columnas) en representaciones binarias y de texto sin formato intercambiables. Para obtener una introducción al formato por parte de los autores, consulte Amazon Ion. (Para obtener más información, consulte Especificación de Amazon Ion).

Puede utilizar AWS Glue para leer archivos Ion de Amazon S3. Puede leer y escribir archivos `bzip` y `gzip` que contengan archivos Ion de S3. Debe configurar el comportamiento de compresión en el Parámetros de conexión S3 en lugar de en la configuración que se describe en esta página.

En la siguiente tabla se muestran las operaciones comunes de AWS Glue que admiten la opción de formato Ion.

Lectura	Escritura	Lectura de streaming	Grupo de archivos pequeños	Marcadores de trabajo
Compatible	No se admite	No se admite	Compatible	No se admite

Ejemplo: leer archivos o carpetas Ion de S3

Requisitos previos: necesitará las rutas de S3 (`s3path`) de las carpetas o los archivos Ion que desee leer.

Configuración: en las opciones de la función, especifique `format="json"`. En sus `connection_options`, utilice la clave `paths` para especificar su `s3path`. Puede configurar la forma en que el lector interactúa con S3 en la `connection_options`. Para obtener más información, consulte Tipos y opciones de conexión para ETL en AWS Glue: the section called "Parámetros de conexión S3".

El siguiente script de ETL de AWS Glue muestra el proceso de lectura de archivos o carpetas Ion de S3:

Python

Para este ejemplo, use el método create_dynamic_frame.from_options.

```
# Example: Read ION from S3

from pyspark.context import SparkContext
from awsglue.context import GlueContext

sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

dynamicFrame = glueContext.create_dynamic_frame.from_options(
    connection_type="s3",
    connection_options={"paths": ["s3://s3path"]},
    format="ion"
)
```

Scala

Para este ejemplo, use la operación getSourceWithFormat.

```
// Example: Read ION from S3

import com.amazonaws.services.glue.util.JsonOptions
import com.amazonaws.services.glue.GlueContext
import org.apache.spark.SparkContext

object GlueApp {
  def main(sysArgs: Array[String]): Unit = {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)

    val dynamicFrame = glueContext.getSourceWithFormat(
      connectionType="s3",
      format="ion",
      options=JsonOptions("""{"paths": ["s3://s3path"], "recurse": true}""")
    ).getDynamicFrame()
  }
}
```

Referencia de configuración de Ion

No hay valores `format_options` para `format="ion"`.

Uso del formato JSON en AWS Glue

AWS Glue recupera datos de fuentes y escribe datos en destinos almacenados y transportados en varios formatos de datos. Si los datos se almacenan o se transportan en formato de datos JSON, este documento presenta las características disponibles para utilizar los datos en AWS Glue.

AWS Glue admite el uso del formato JSON. Este formato representa estructuras de datos con forma consistente, pero con contenido flexible, que no están basadas en filas o columnas. JSON está definido por estándares paralelos emitidos por varias autoridades, una de las cuales es ECMA-404. Para obtener una introducción al formato por parte de un origen al que normalmente se hace referencia, consulte Introducción a JSON.

Puede utilizar AWS Glue para leer archivos JSON de Amazon S3, así como archivos JSON comprimidos con `bzip` y `gzip`. Debe configurar el comportamiento de compresión en el Parámetros de conexión S3 en lugar de en la configuración que se describe en esta página.

Lectura	Escritura	Lectura de streaming	Grupo de archivos pequeños	Marcadores de trabajo	
Compatible	Soportado	Soportado	Soportado	Compatible	

Ejemplo: leer archivos o carpetas JSON de S3

Requisitos previos: necesitará las rutas de S3 (`s3path`) de las carpetas o los archivos JSON que desee leer.

Configuración: en las opciones de la función, especifique `format="json"`. En sus `connection_options`, utilice la clave `paths` para especificar su `s3path`. Puede modificar aún más la manera en que la operación de lectura atravesará S3 en las opciones de conexión; consulte the section called “Parámetros de conexión S3” para obtener más detalles. Puede configurar la manera en que el lector interpreta los archivos JSON en sus `format_options`. Para obtener más información, consulte Referencia de configuración de JSON.

El siguiente script de ETL de AWS Glue muestra el proceso de lectura de archivos o carpetas JSON de S3:

Python

Para este ejemplo, use el método create_dynamic_frame.from_options.

```
# Example: Read JSON from S3
# For show, we handle a nested JSON file that we can limit with the JsonPath
 parameter
# For show, we also handle a JSON where a single entry spans multiple lines
# Consider whether optimizePerformance is right for your workflow.

from pyspark.context import SparkContext
from awsglue.context import GlueContext

sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)
spark = glueContext.spark_session

dynamicFrame = glueContext.create_dynamic_frame.from_options(
    connection_type="s3",
    connection_options={"paths": ["s3://s3path"]},
    format="json",
    format_options={
        "jsonPath": "$.id",
        "multiline": True,
        # "optimizePerformance": True, -> not compatible with jsonPath, multiline
    }
)
```

También puede usar DataFrames en un script (`pyspark.sql.DataFrame`).

```
dataFrame = spark.read\
    .option("multiline", "true")\
    .json("s3://s3path")
```

Scala

Para este ejemplo, use la operación getSourceWithFormat.

```
// Example: Read JSON from S3
// For show, we handle a nested JSON file that we can limit with the JsonPath
 parameter
// For show, we also handle a JSON where a single entry spans multiple lines
// Consider whether optimizePerformance is right for your workflow.
```

```
import com.amazonaws.services.glue.util.JsonOptions
import com.amazonaws.services.glue.{DynamicFrame, GlueContext}
import org.apache.spark.SparkContext

object GlueApp {
  def main(sysArgs: Array[String]): Unit = {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)

    val dynamicFrame = glueContext.getSourceWithFormat(
      formatOptions=JsonOptions("""{"jsonPath": "$.id", "multiline": true,
 "optimizePerformance":false}"""),
      connectionType="s3",
      format="json",
      options=JsonOptions("""{"paths": ["s3://s3path"], "recurse": true}""")
    ).getDynamicFrame()
  }
}
```

También puede usar DataFrames en un script (`pyspark.sql.DataFrame`).

```
val dataFrame = spark.read
    .option("multiline", "true")
    .json("s3://s3path")
```

Ejemplo: escribir archivos y carpetas JSON en S3

Requisitos previos: necesitará un DataFrame inicializado (`dataFrame`) o un DynamicFrame (`dynamicFrame`). También necesitará la ruta de salida S3 prevista, `s3path`.

Configuración: en las opciones de la función, especifique `format="json"`. En sus `connection_options`, utilice la clave `paths` para especificar `s3path`. Puede modificar aún más la forma en que el escritor interactúa con S3 en las `connection_options`. Para obtener más información, consulte Opciones de formato de datos para entradas y salidas de ETL en AWS Glue: the section called “Parámetros de conexión S3”. Puede configurar la forma en que el escritor interpreta los archivos JSON en sus `format_options`. Para obtener más información, consulte Referencia de configuración de JSON.

El siguiente script de ETL de AWS Glue muestra el proceso de escritura de archivos o carpetas JSON de S3:

Python

Para este ejemplo, use el método write_dynamic_frame.from_options.

```
# Example: Write JSON to S3

from pyspark.context import SparkContext
from awsglue.context import GlueContext

sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

glueContext.write_dynamic_frame.from_options(
    frame=dynamicFrame,
    connection_type="s3",
    connection_options={"path": "s3://s3path"},
    format="json"
)
```

También puede usar DataFrames en un script (`pyspark.sql.DataFrame`).

```
df.write.json("s3://s3path/")
```

Scala

Para este ejemplo, use el método getSinkWithFormat.

```
// Example: Write JSON to S3

import com.amazonaws.services.glue.util.JsonOptions
import com.amazonaws.services.glue.{DynamicFrame, GlueContext}
import org.apache.spark.SparkContext

object GlueApp {
  def main(sysArgs: Array[String]): Unit = {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)

    glueContext.getSinkWithFormat(
        connectionType="s3",
        options=JsonOptions("""{"path": "s3://s3path"}"""),
        format="json"
    ).writeDynamicFrame(dynamicFrame)
```

```
  }
}
```

También puede usar DataFrames en un script (`pyspark.sql.DataFrame`).

```
df.write.json("s3://s3path")
```

Referencia de configuración de JSON

Puede utilizar los siguientes valores `format_options` con `format="json"`:

- `jsonPath`: una expresión JsonPath que identifica un objeto que se leerá en los registros. Esto resulta particularmente útil cuando un archivo contiene registros anidados en una matriz exterior. Por ejemplo, la siguiente expresión JsonPath se dirige al campo `id` de un objeto JSON.

```
format="json", format_options={"jsonPath": "$.id"}
```

- `multiline`: un valor booleano que especifica si un solo registro puede abarcar varias líneas. Esto puede suceder cuando un campo contiene un carácter de nueva línea entre comillas. Debe configurar esta opción en `"true"` si un registro abarca varias líneas. El valor predeterminado es `"false"`, que permite una división de archivo más dinámica durante el análisis.
- `optimizePerformance`: un valor booleano que especifica si se debe utilizar el lector SIMD JSON avanzado junto con los formatos de memoria en columnas basados en Apache Arrow. Solo se encuentra disponible en AWS Glue 3.0. No compatible con `multiline` ni `jsonPath`. Proporcionar cualquiera de esas opciones indicará a AWS Glue que regrese al lector estándar.
- `withSchema`— Un valor de cadena que especifica un esquema de tabla en el formato descrito en the section called “Especifique el esquema XML”. Solo se usa con `optimizePerformance` al leer desde conexiones que no son de catálogo.

Uso del lector SIMD JSON vectorizado con formato en columnas de Apache Arrow

AWS Glue versión 3.0 agrega un lector vectorizado para datos JSON. Funciona dos veces más rápido en ciertas condiciones, en comparación con el lector estándar. Este lector viene con ciertas limitaciones documentadas en esta sección que los usuarios deben tener en cuenta antes de usarlo.

Para usar el lector optimizado, configure `"optimizePerformance"` como True en `format_options` o propiedad de tabla. También deberá proporcionar `withSchema` a menos que

esté leyendo del catálogo. `withSchema` espera una entrada como se describe en the section called "Especifique el esquema XML"

```
// Read from S3 data source
glueContext.create_dynamic_frame.from_options(
    connection_type = "s3",
    connection_options = {"paths": ["s3://s3path"]},
    format = "json",
    format_options={
        "optimizePerformance": True,
        "withSchema": SchemaString
        })

// Read from catalog table
glueContext.create_dynamic_frame.from_catalog(
    database = database,
    table_name = table,
    additional_options = {
    // The vectorized reader for JSON can read your schema from a catalog table
 property.
        "optimizePerformance": True,
        })
```

Para obtener más información sobre la creación de un *SchemaString* en la biblioteca de AWS Glue, consulte the section called "Tipos".

Limitaciones para el lector CSV vectorizado

Presenta las siguientes limitaciones:

- No se admiten elementos JSON con objetos anidados o valores de matriz. Si se proporciona, AWS Glue volverá al lector estándar.
- Se debe proporcionar un esquema, ya sea del Catálogo o con `withSchema`.
- No compatible con `multiline` ni `jsonPath`. Proporcionar cualquiera de esas opciones indicará a AWS Glue que regrese al lector estándar.
- Proporcionar registros de entrada que no coincidan con el esquema de entrada provocará un error en el lector.
- No se crearán registros de errores.
- No se admiten archivos JSON con caracteres multibytes (como caracteres japoneses o chinos).

Uso del formato ORC en AWS Glue

AWS Glue recupera datos de fuentes y escribe datos en destinos almacenados y transportados en varios formatos de datos. Si los datos se almacenan o se transportan en formato de datos ORC, este documento presenta las características disponibles para utilizar los datos en AWS Glue.

AWS Glue admite el uso del formato ORC. Este formato es un formato de datos basado en columnas y orientado al rendimiento. Para obtener una introducción al formato por parte de la autoridad de normalización, consulte Apache Orc.

Puede utilizar AWS Glue para leer archivos ORC de Amazon S3 y de orígenes de streaming, como también para escribir archivos ORC en Amazon S3. Puede leer y escribir archivos `bzip` y `gzip` que contengan archivos ORC de S3. Debe configurar el comportamiento de compresión en el Parámetros de conexión S3 en lugar de en la configuración que se describe en esta página.

En la siguiente tabla se muestran las operaciones comunes de AWS Glue que admiten la opción de formato ORC.

Lectura	Escritura	Lectura de streaming	Grupo de archivos pequeños	Marcadores de trabajo
Compatible	Soportado	Compatible	No se admite	Compatible*

*Compatible con AWS Glue versión 1.0 y posterior

Ejemplo: leer archivos o carpetas ORC de S3

Requisitos previos: necesitará las rutas de S3 (`s3path`) de las carpetas o los archivos ORC que desee leer.

Configuración: en las opciones de la función, especifique `format="orc"`. En sus `connection_options`, utilice la clave `paths` para especificar su `s3path`. Puede configurar la forma en que el lector interactúa con S3 en la `connection_options`. Para obtener más información, consulte Tipos y opciones de conexión para ETL en AWS Glue: the section called "Parámetros de conexión S3".

El siguiente script de ETL de AWS Glue muestra el proceso de lectura de archivos o carpetas ORC de S3:

Python

Para este ejemplo, use el método create_dynamic_frame.from_options.

```
from pyspark.context import SparkContext
from awsglue.context import GlueContext

sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

dynamicFrame = glueContext.create_dynamic_frame.from_options(
    connection_type="s3",
    connection_options={"paths": ["s3://s3path"]},
    format="orc"
)
```

También puede usar DataFrames en un script (`pyspark.sql.DataFrame`).

```
dataFrame = spark.read\
    .orc("s3://s3path")
```

Scala

Para este ejemplo, use la operación getSourceWithFormat.

```
import com.amazonaws.services.glue.util.JsonOptions
import com.amazonaws.services.glue.GlueContext
import org.apache.spark.sql.SparkContext

object GlueApp {
  def main(sysArgs: Array[String]): Unit = {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)

    val dynamicFrame = glueContext.getSourceWithFormat(
      connectionType="s3",
      format="orc",
      options=JsonOptions("""{"paths": ["s3://s3path"]}""")
    ).getDynamicFrame()
  }
}
```

También puede usar DataFrames en un script (`pyspark.sql.DataFrame`).

```
val dataFrame = spark.read
    .orc("s3://s3path")
```

Ejemplo: escribir archivos y carpetas ORC en S3

Requisitos previos: necesitará un DataFrame inicializado (`dataFrame`) o DynamicFrame (`dynamicFrame`). También necesitará la ruta de salida S3 prevista, `s3path`.

Configuración: en las opciones de la función, especifique `format="orc"`. En las opciones de conexión, utilice la clave `paths` para especificar `s3path`. Puede modificar aún más la forma en que el escritor interactúa con S3 en las `connection_options`. Para obtener más información, consulte Opciones de formato de datos para entradas y salidas de ETL en AWS Glue: the section called “Parámetros de conexión S3”. El siguiente ejemplo de código muestra el proceso:

Python

Para este ejemplo, use el método write_dynamic_frame.from_options.

```
from pyspark.context import SparkContext
from awsglue.context import GlueContext

sc = SparkContext.getOrCreate()
glueContext = GlueContext(sc)

glueContext.write_dynamic_frame.from_options(
    frame=dynamicFrame,
    connection_type="s3",
    format="orc",
    connection_options={
        "path": "s3://s3path"
    }
)
```

También puede usar DataFrames en un script (`pyspark.sql.DataFrame`).

```
df.write.orc("s3://s3path/")
```

Scala

Para este ejemplo, use el método getSinkWithFormat.

```
import com.amazonaws.services.glue.util.JsonOptions
import com.amazonaws.services.glue.{DynamicFrame, GlueContext}
import org.apache.spark.SparkContext

object GlueApp {
  def main(sysArgs: Array[String]): Unit = {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)

    glueContext.getSinkWithFormat(
      connectionType="s3",
      options=JsonOptions("""{"path": "s3://s3path"}"""),
      format="orc"
    ).writeDynamicFrame(dynamicFrame)
  }
}
```

También puede usar DataFrames en un script (`pyspark.sql.DataFrame`).

```
df.write.orc("s3://s3path/")
```

Referencia de configuración de ORC

No hay valores `format_options` para `format="orc"`. No obstante, se le pueden pasar las opciones que acepte el código SparkSQL subyacente mediante el parámetro de mapa `connection_options`.

Uso de marcos de lagos de datos con trabajos de ETL de AWS Glue

Los marcos de lagos de datos de código abierto simplifican el procesamiento incremental de los datos para los archivos que se almacenan en los lagos de datos creados en Amazon S3. AWS Glue 3.0 y versiones posteriores admiten los siguientes marcos de lagos de datos de código abierto:

- Apache Hudi
- Linux Foundation Delta Lake
- Apache Iceberg

Proporcionamos compatibilidad nativa para estos marcos para que pueda leer y escribir los datos que almacena en Amazon S3 de manera coherente desde el punto de vista transaccional. No es

necesario instalar ningún conector independiente ni completar pasos de configuración adicionales para utilizar estos marcos en los trabajos de ETL de AWS Glue.

Cuando administre conjuntos de datos mediante AWS Glue Data Catalog, puede utilizar los métodos AWS Glue para leer y escribir tablas de lagos de datos con DataFrames de Spark. También puede leer y escribir datos de Amazon S3 mediante la API de DataFrame de Spark.

En este video, puede obtener información básica sobre el trabajo de Apache Hudi, Apache Iceberg y Delta Lake. Verá cómo insertar, actualizar y eliminar datos en su lago de datos y cómo funciona cada uno de estos marcos.

Temas

- Limitaciones
- Uso del marco de Hudi en AWS Glue
- Uso del marco de Delta Lake en AWS Glue
- Uso del marco de Iceberg en AWS Glue

Limitaciones

Tenga en cuenta las siguientes limitaciones antes de utilizar los marcos de lagos de datos con AWS Glue.

- Los siguientes métodos de AWS Glue `GlueContext` para DynamicFrame no admiten la lectura ni la escritura de tablas de marcos del lagos de datos. En su lugar, utilice los métodos `GlueContext` para la API de DataFrame o Spark DataFrame.
  - `create_dynamic_frame.from_catalog`
  - `write_dynamic_frame.from_catalog`
  - `getDynamicFrame`
  - `writeDynamicFrame`
- El control de permisos de Lake Formation admite los siguientes métodos de `GlueContext` para DataFrame:
  - `create_data_frame.from_catalog`
  - `write_data_frame.from_catalog`
  - `getDataFrame`
  - `writeDataFrame`

- No se admite la agrupación de archivos pequeños.
- No se admiten los marcadores de trabajo.
- Apache Hudi 0.10.1 para AWS Glue 3.0 no admite las tablas Merge on Read (MoR, fusionar al leer) de Hudi.
- `ALTER TABLE … RENAME TO` no está disponible para Apache Iceberg 0.13.1 para AWS Glue 3.0.

Limitaciones de las tablas con formato de lago de datos administradas por los permisos de Lake Formation

Los formatos de lago de datos se integran con AWS Glue ETL a través de los permisos de Lake Formation. No se admite la creación de un DynamicFrame utilizando `create_dynamic_frame`. Para obtener más información, consulte los ejemplos siguientes:

- Ejemplo: Lea y escriba una tabla de iceberg con el control de permisos de Lake Formation
- Ejemplo: Lea y escriba una tabla Hudi con el control de permisos de Lake Formation
- Ejemplo: Lea y escriba la tabla de Delta Lake con el control de permisos de Lake Formation

> **Note**
>
> La integración con AWS Glue ETL mediante los permisos de Lake Formation para Apache Hudi, Apache Iceberg y Delta Lake solo se admite en la AWS Glue versión 4.0.

Apache Iceberg tiene la mejor integración con AWS Glue ETL a través de los permisos de Lake Formation. Es compatible con casi todas las operaciones e incluye soporte para SQL.

Hudi es compatible con la mayoría de las operaciones básicas, con la excepción de las operaciones administrativas. Esto se debe a que estas opciones generalmente se realizan mediante la escritura de marcos de datos y se especifican mediante `additional_options`. Debe usar las API AWS Glue para crear DataFrames para sus operaciones, ya que SparkSQL no es compatible.

Delta Lake solo admite la lectura, la adición y la sobrescritura de datos de tablas. Delta Lake requiere el uso de sus propias bibliotecas para poder realizar diversas tareas, como las actualizaciones.

Las siguientes funciones no están disponibles para las tablas Iceberg administradas por los permisos de Lake Formation.

- Compactación mediante ETL AWS Glue
- Soporte para Spark SQL a través de AWS Glue ETL

Las siguientes son limitaciones de las tablas Hudi administradas por los permisos de Lake Formation:

- Eliminación de archivos huérfanos

Las siguientes son limitaciones de las tablas de Delta Lake administradas por los permisos de Lake Formation:

- Todas las funciones, excepto la inserción y lectura de las tablas de Delta Lake.

Uso del marco de Hudi en AWS Glue

AWS Glue 3.0 y versiones posteriores son compatibles con el marco de Apache Hudi para lagos de datos. Hudi es un marco de almacenamiento de lagos de datos de código abierto que simplifica el procesamiento progresivo de datos y el desarrollo de canalizaciones de datos. En este tema, se describen las características disponibles para usar los datos en AWS Glue al transportar o almacenar datos en una tabla de Hudi. Para más información sobre Hudi, consulte la documentación oficial de Apache Hudi.

Puede usar AWS Glue para llevar a cabo operaciones de lectura y escritura en tablas de Hudi en Amazon S3, o trabajar con tablas de Hudi mediante el Catálogo de datos de AWS Glue. También se admiten operaciones adicionales, como insertar, actualizar y todas las operaciones de Apache Spark.

> **Note**
>
> La implementación de Apache Hudi 0.15.0 en AWS Glue 5.0 revierte internamente HUDI-7001. No muestra la regresión relacionada con la generación de claves complejas cuando la clave de registro consta de un solo campo. Sin embargo, este comportamiento es diferente al de OSS Apache Hudi 0.15.0.
> Apache Hudi 0.10.1 para AWS Glue 3.0 no admite las tablas Merge on Read (MoR, fusionar al leer) de Hudi.

La siguiente tabla muestra la versión de Hudi que se incluye en cada versión de AWS Glue.

Versión de AWS Glue	Versión de Hudi compatible
5.0	0.15.0
4.0	0.12.1
3.0	0.10.1

Para más información sobre los marcos de lagos de datos compatibles con AWS Glue, consulte Uso de marcos de lagos de datos con trabajos de ETL de AWS Glue.

Activación de Hudi

Para activar Hudi para AWS Glue, haga las siguientes tareas:

- Especifique `hudi` como valor para el parámetro del trabajo `--datalake-formats`. Para obtener más información, consulte Uso de los parámetros de trabajo en los trabajos de AWS Glue.
- Cree una clave con el nombre `--conf` para el trabajo de AWS Glue y establézcala en el siguiente valor. Como alternativa, puede establecer la siguiente configuración mediante `SparkConf` en su script. Esta configuración ayuda a Apache Spark a gestionar correctamente las tablas de Hudi.

```
spark.serializer=org.apache.spark.serializer.KryoSerializer
```

- La compatibilidad con los permisos de Lake Formation para Hudi está habilitada de forma predeterminada en AWS Glue 4.0. No se necesita ninguna configuración adicional para leer o escribir en las tablas Hudi registradas en Lake Formation. Para leer una tabla Hudi registrada, el rol de IAM del trabajo de AWS Glue debe tener el permiso SELECT. Para escribir en una tabla Hudi registrada, el rol de IAM del trabajo de AWS Glue debe tener el permiso SUPER. Para obtener más información sobre la administración de los permisos de Lake Formation, consulte Otorgar y revocar permisos en los recursos del catálogo de datos.

Uso de una versión diferente de Hudi

Para usar una versión de Hudi que no sea compatible con AWS Glue, indique sus propios archivos JAR de Hudi mediante el parámetro de trabajo `--extra-jars`. No incluya `hudi` como valor para el parámetro de trabajo `--datalake-formats`. Si usa AWS Glue 5.0, debe configurar el parámetro de trabajo `--user-jars-first true`.

Ejemplo: escribir una tabla de Hudi en Amazon S3 y registrarla en el Catálogo de datos de AWS Glue

En este script de ejemplo, se muestra cómo escribir una tabla de Hudi en Amazon S3 y registrar la tabla en el Catálogo de datos de AWS Glue. En el ejemplo, se utiliza la herramienta Hive Sync de Hudi para registrar la tabla.

> **Note**
>
> En este ejemplo, se requiere que establezca el parámetro de trabajo de `--enable-glue-datacatalog` para utilizar el Catálogo de datos de AWS Glue como metaalmacén de Apache Spark Hive. Para obtener más información, consulte Uso de los parámetros de trabajo en los trabajos de AWS Glue.

Python

```
# Example: Create a Hudi table from a DataFrame
# and register the table to Glue Data Catalog

additional_options={
    "hoodie.table.name": "<your_table_name>",
    "hoodie.database.name": "<your_database_name>",
    "hoodie.datasource.write.storage.type": "COPY_ON_WRITE",
    "hoodie.datasource.write.operation": "upsert",
    "hoodie.datasource.write.recordkey.field": "<your_recordkey_field>",
    "hoodie.datasource.write.precombine.field": "<your_precombine_field>",
    "hoodie.datasource.write.partitionpath.field": "<your_partitionkey_field>",
    "hoodie.datasource.write.hive_style_partitioning": "true",
    "hoodie.datasource.hive_sync.enable": "true",
    "hoodie.datasource.hive_sync.database": "<your_database_name>",
    "hoodie.datasource.hive_sync.table": "<your_table_name>",
    "hoodie.datasource.hive_sync.partition_fields": "<your_partitionkey_field>",
    "hoodie.datasource.hive_sync.partition_extractor_class":
 "org.apache.hudi.hive.MultiPartKeysValueExtractor",
    "hoodie.datasource.hive_sync.use_jdbc": "false",
    "hoodie.datasource.hive_sync.mode": "hms",
    "path": "s3://<s3Path/>"
}

dataFrame.write.format("hudi") \
    .options(**additional_options) \
    .mode("overwrite") \
```

```
    .save()
```

Scala

```
// Example: Example: Create a Hudi table from a DataFrame
// and register the table to Glue Data Catalog

val additionalOptions = Map(
  "hoodie.table.name" -> "<your_table_name>",
  "hoodie.database.name" -> "<your_database_name>",
  "hoodie.datasource.write.storage.type" -> "COPY_ON_WRITE",
  "hoodie.datasource.write.operation" -> "upsert",
  "hoodie.datasource.write.recordkey.field" -> "<your_recordkey_field>",
  "hoodie.datasource.write.precombine.field" -> "<your_precombine_field>",
  "hoodie.datasource.write.partitionpath.field" -> "<your_partitionkey_field>",
  "hoodie.datasource.write.hive_style_partitioning" -> "true",
  "hoodie.datasource.hive_sync.enable" -> "true",
  "hoodie.datasource.hive_sync.database" -> "<your_database_name>",
  "hoodie.datasource.hive_sync.table" -> "<your_table_name>",
  "hoodie.datasource.hive_sync.partition_fields" -> "<your_partitionkey_field>",
  "hoodie.datasource.hive_sync.partition_extractor_class" ->
 "org.apache.hudi.hive.MultiPartKeysValueExtractor",
  "hoodie.datasource.hive_sync.use_jdbc" -> "false",
  "hoodie.datasource.hive_sync.mode" -> "hms",
  "path" -> "s3://<s3Path/>")

dataFrame.write.format("hudi")
  .options(additionalOptions)
  .mode("append")
  .save()
```

Ejemplo: leer una tabla de Hudi de Amazon S3 con el Catálogo de datos de AWS Glue

En este ejemplo, se lee la tabla de Hudi que creó en Ejemplo: escribir una tabla de Hudi en Amazon S3 y registrarla en el Catálogo de datos de AWS Glue de Amazon S3.

> **Note**
>
> En este ejemplo, se requiere que establezca el parámetro de trabajo de `--enable-glue-datacatalog` para utilizar el Catálogo de datos de AWS Glue como metaalmacén de

Apache Spark Hive. Para obtener más información, consulte Uso de los parámetros de trabajo en los trabajos de AWS Glue.

Python

Para este ejemplo, utilice el método `GlueContext.create_data_frame.from_catalog()`.

```
# Example: Read a Hudi table from Glue Data Catalog

from awsglue.context import GlueContext
from pyspark.context import SparkContext

sc = SparkContext()
glueContext = GlueContext(sc)

dataFrame = glueContext.create_data_frame.from_catalog(
    database = "<your_database_name>",
    table_name = "<your_table_name>"
)
```

Scala

Para este ejemplo, utilice el método getCatalogSource.

```
// Example: Read a Hudi table from Glue Data Catalog

import com.amazonaws.services.glue.GlueContext
import org.apache.spark.SparkContext

object GlueApp {
  def main(sysArgs: Array[String]): Unit = {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)

    val dataFrame = glueContext.getCatalogSource(
      database = "<your_database_name>",
      tableName = "<your_table_name>"
    ).getDataFrame()
  }
}
```

Ejemplo: actualizar e insertar un objeto **`DataFrame`** en una tabla de Hudi en Amazon S3

En este ejemplo, se utiliza el Catálogo de datos de AWS Glue para insertar un DataFrame en la tabla de Hudi que creó en Ejemplo: escribir una tabla de Hudi en Amazon S3 y registrarla en el Catálogo de datos de AWS Glue.

> **Note**
>
> En este ejemplo, se requiere que establezca el parámetro de trabajo de `--enable-glue-datacatalog` para utilizar el Catálogo de datos de AWS Glue como metaalmacén de Apache Spark Hive. Para obtener más información, consulte Uso de los parámetros de trabajo en los trabajos de AWS Glue.

Python

Para este ejemplo, utilice el método `GlueContext.write_data_frame.from_catalog()`.

```
# Example: Upsert a Hudi table from Glue Data Catalog

from awsglue.context import GlueContext
from pyspark.context import SparkContext

sc = SparkContext()
glueContext = GlueContext(sc)

glueContext.write_data_frame.from_catalog(
    frame = dataFrame,
    database = "<your_database_name>",
    table_name = "<your_table_name>",
    additional_options={
        "hoodie.table.name": "<your_table_name>",
        "hoodie.database.name": "<your_database_name>",
        "hoodie.datasource.write.storage.type": "COPY_ON_WRITE",
        "hoodie.datasource.write.operation": "upsert",
        "hoodie.datasource.write.recordkey.field": "<your_recordkey_field>",
        "hoodie.datasource.write.precombine.field": "<your_precombine_field>",
        "hoodie.datasource.write.partitionpath.field": "<your_partitionkey_field>",
        "hoodie.datasource.write.hive_style_partitioning": "true",
        "hoodie.datasource.hive_sync.enable": "true",
        "hoodie.datasource.hive_sync.database": "<your_database_name>",
        "hoodie.datasource.hive_sync.table": "<your_table_name>",
```

```
        "hoodie.datasource.hive_sync.partition_fields": "<your_partitionkey_field>",
        "hoodie.datasource.hive_sync.partition_extractor_class":
 "org.apache.hudi.hive.MultiPartKeysValueExtractor",
        "hoodie.datasource.hive_sync.use_jdbc": "false",
        "hoodie.datasource.hive_sync.mode": "hms"
    }
)
```

Scala

Para este ejemplo, utilice el método getCatalogSink.

```
// Example: Upsert a Hudi table from Glue Data Catalog

import com.amazonaws.services.glue.GlueContext
import com.amazonaws.services.glue.util.JsonOptions
import org.apacke.spark.SparkContext

object GlueApp {
  def main(sysArgs: Array[String]): Unit = {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)
    glueContext.getCatalogSink("<your_database_name>", "<your_table_name>",
      additionalOptions = JsonOptions(Map(
        "hoodie.table.name" -> "<your_table_name>",
        "hoodie.database.name" -> "<your_database_name>",
        "hoodie.datasource.write.storage.type" -> "COPY_ON_WRITE",
        "hoodie.datasource.write.operation" -> "upsert",
        "hoodie.datasource.write.recordkey.field" -> "<your_recordkey_field>",
        "hoodie.datasource.write.precombine.field" -> "<your_precombine_field>",
        "hoodie.datasource.write.partitionpath.field" ->
 "<your_partitionkey_field>",
        "hoodie.datasource.write.hive_style_partitioning" -> "true",
        "hoodie.datasource.hive_sync.enable" -> "true",
        "hoodie.datasource.hive_sync.database" -> "<your_database_name>",
        "hoodie.datasource.hive_sync.table" -> "<your_table_name>",
        "hoodie.datasource.hive_sync.partition_fields" ->
 "<your_partitionkey_field>",
        "hoodie.datasource.hive_sync.partition_extractor_class" ->
 "org.apache.hudi.hive.MultiPartKeysValueExtractor",
        "hoodie.datasource.hive_sync.use_jdbc" -> "false",
        "hoodie.datasource.hive_sync.mode" -> "hms"
      )))
      .writeDataFrame(dataFrame, glueContext)
```

```
  }
}
```

Ejemplo: leer una tabla de Hudi de Amazon S3 con Spark

En este ejemplo, se lee una tabla de Hudi de Amazon S3 con la API de DataFrame de Spark.

Python

```
# Example: Read a Hudi table from S3 using a Spark DataFrame

dataFrame = spark.read.format("hudi").load("s3://<s3path/>")
```

Scala

```
// Example: Read a Hudi table from S3 using a Spark DataFrame

val dataFrame = spark.read.format("hudi").load("s3://<s3path/>")
```

Ejemplo: escribir una tabla de Hudi en Amazon S3 con Spark

En este ejemplo, se escribe una tabla de Hudi en Amazon S3 con Spark.

Python

```
# Example: Write a Hudi table to S3 using a Spark DataFrame

dataFrame.write.format("hudi") \
    .options(**additional_options) \
    .mode("overwrite") \
    .save("s3://<s3Path/>")
```

Scala

```
// Example: Write a Hudi table to S3 using a Spark DataFrame

dataFrame.write.format("hudi")
  .options(additionalOptions)
  .mode("overwrite")
```

```
    .save("s3://<s3path/>")
```

Ejemplo: Lea y escriba una tabla Hudi con el control de permisos de Lake Formation

En este ejemplo se lee y escribe una tabla Hudi con el control de permisos de Lake Formation.

1. Cree una tabla Hudi y regístrela en Lake Formation.
   a. Para habilitar el control de permisos de Lake Formation, primero tendrá que registrar la tabla de la ruta Amazon S3 en Lake Formation. Para obtener más información, consulte Registro de una ubicación de Amazon S3. Puede registrarlo desde la consola de Lake Formation o mediante la AWS CLI:

   ```
   aws lakeformation register-resource --resource-arn arn:aws:s3:::<s3-bucket>/<s3-folder> --use-service-linked-role --region <REGION>
   ```

   Una vez que registre una ubicación de Amazon S3, cualquier tabla de AWS Glue que apunte a la ubicación (o a cualquiera de sus ubicaciones secundarias) devolverá el valor del parámetro `IsRegisteredWithLakeFormation` como verdadero en la llamada `GetTable`.

   b. Cree una tabla Hudi que apunte a la ruta de Amazon S3 registrada a través de la API de marcos de datos de Spark:

   ```
   hudi_options = {
       'hoodie.table.name': table_name,
       'hoodie.database.name': database_name,
       'hoodie.datasource.write.storage.type': 'COPY_ON_WRITE',
       'hoodie.datasource.write.recordkey.field': 'product_id',
       'hoodie.datasource.write.table.name': table_name,
       'hoodie.datasource.write.operation': 'upsert',
       'hoodie.datasource.write.precombine.field': 'updated_at',
       'hoodie.datasource.write.hive_style_partitioning': 'true',
       'hoodie.upsert.shuffle.parallelism': 2,
       'hoodie.insert.shuffle.parallelism': 2,
       'path': <S3_TABLE_LOCATION>,
       'hoodie.datasource.hive_sync.enable': 'true',
       'hoodie.datasource.hive_sync.database': database_name,
       'hoodie.datasource.hive_sync.table': table_name,
       'hoodie.datasource.hive_sync.use_jdbc': 'false',
       'hoodie.datasource.hive_sync.mode': 'hms'
   }
   ```

```
df_products.write.format("hudi")  \
    .options(**hudi_options)  \
    .mode("overwrite")  \
    .save()
```

2. Conceda permiso a Lake Formation para el rol de IAM del trabajo de AWS Glue. Puede conceder permisos desde la consola de Lake Formation o mediante la AWS CLI. Para obtener más información, consulte Concesión de permisos de tabla mediante la consola de Lake Formation y el método de recurso con nombre
3. Lea la tabla Hudi registrada en Lake Formation. El código es el mismo que leer una tabla Hudi no registrada. Tenga en cuenta que el rol de IAM del trabajo de AWS Glue debe tener el permiso SELECT para que la lectura se realice correctamente.

```
val dataFrame = glueContext.getCatalogSource(
     database = "<your_database_name>",
     tableName = "<your_table_name>"
   ).getDataFrame()
```

4. Escribe en una tabla Hudi registrada en Lake Formation. El código es el mismo que escribir en una tabla Hudi no registrada. Tenga en cuenta que el rol de IAM del trabajo de AWS Glue debe tener el permiso SUPER para que la escritura se realice correctamente.

```
glueContext.getCatalogSink("<your_database_name>", "<your_table_name>",
      additionalOptions = JsonOptions(Map(
        "hoodie.table.name" -> "<your_table_name>",
        "hoodie.database.name" -> "<your_database_name>",
        "hoodie.datasource.write.storage.type" -> "COPY_ON_WRITE",
        "hoodie.datasource.write.operation" -> "<write_operation>",
        "hoodie.datasource.write.recordkey.field" -> "<your_recordkey_field>",
        "hoodie.datasource.write.precombine.field" -> "<your_precombine_field>",
        "hoodie.datasource.write.partitionpath.field" -> "<your_partitionkey_field>",
        "hoodie.datasource.write.hive_style_partitioning" -> "true",
        "hoodie.datasource.hive_sync.enable" -> "true",
        "hoodie.datasource.hive_sync.database" -> "<your_database_name>",
        "hoodie.datasource.hive_sync.table" -> "<your_table_name>",
        "hoodie.datasource.hive_sync.partition_fields" ->
 "<your_partitionkey_field>",
        "hoodie.datasource.hive_sync.partition_extractor_class" ->
 "org.apache.hudi.hive.MultiPartKeysValueExtractor",
        "hoodie.datasource.hive_sync.use_jdbc" -> "false",
        "hoodie.datasource.hive_sync.mode" -> "hms"
      )))
```

```
        .writeDataFrame(dataFrame, glueContext)
```

Uso del marco de Delta Lake en AWS Glue

AWS Glue 3.0 y versiones posteriores son compatibles con el marco de Linux Foundation Delta Lake. Delta Lake es un marco de almacenamiento de lagos de datos de código abierto para hacer transacciones de ACID, escalar el manejo de metadatos y unificar la transmisión y el procesamiento de datos por lotes. En este tema se describen las características disponibles para usar los datos en AWS Glue al transportar o almacenar datos en una tabla de Delta Lake. Para más información acerca de Delta Lake, consulte la documentación oficial de Delta Lake.

Puede usar AWS Glue para llevar a cabo operaciones de lectura y escritura en tablas de Delta Lake en Amazon S3, o trabajar con tablas de Delta Lake mediante el Catálogo de datos de AWS Glue. También se admiten operaciones adicionales, como la inserción, la actualización y las lecturas y escrituras de tablas por lotes. Cuando usa tablas de Delta Lake, también tiene la opción de usar métodos de la biblioteca de Python de Delta Lake, como `DeltaTable.forPath`. Para obtener más información sobre la biblioteca de Python de Delta Lake, consulte la documentación de Python de Delta Lake.

En la siguiente tabla, se muestra la versión de Delta Lake que se incluye en cada versión de AWS Glue.

Versión de AWS Glue	Versión de Delta Lake compatible
5.0	3.3.0
4.0	2.1.0
3.0	1.0.0

Para más información sobre los marcos de lagos de datos compatibles con AWS Glue, consulte Uso de marcos de lagos de datos con trabajos de ETL de AWS Glue.

Habilitar Delta Lake para AWS Glue

Para activar Delta Lake para AWS Glue, haga las siguientes tareas:

- Especifique `delta` como valor para el parámetro del trabajo `--datalake-formats`. Para obtener más información, consulte Uso de los parámetros de trabajo en los trabajos de AWS Glue.

- Cree una clave con el nombre `--conf` para el trabajo de AWS Glue y establézcala en el siguiente valor. Como alternativa, puede establecer la siguiente configuración mediante `SparkConf` en su script. Esta configuración ayuda a Apache Spark a gestionar correctamente las tablas de Delta Lake.

```
spark.sql.extensions=io.delta.sql.DeltaSparkSessionExtension --conf
 spark.sql.catalog.spark_catalog=org.apache.spark.sql.delta.catalog.DeltaCatalog --
conf
 spark.delta.logStore.class=org.apache.spark.sql.delta.storage.S3SingleDriverLogStore
```

- La compatibilidad con los permisos de Lake Formation para las tablas Delta está habilitada de forma predeterminada en AWS Glue 4.0. No se necesita ninguna configuración adicional para leer o escribir en las tablas Delta registradas en Lake Formation. Para leer una tabla Delta registrada, el rol de IAM del trabajo de AWS Glue debe tener el permiso SELECT. Para escribir en una tabla Delta registrada, el rol de IAM de AWS Glue debe tener el permiso SUPER. Para obtener más información sobre la administración de los permisos de Lake Formation, consulte Otorgar y revocar permisos en los recursos del catálogo de datos.

Uso de una versión diferente de Delta Lake

Para usar una versión de Delta Lake que no sea compatible con AWS Glue, indique sus propios archivos JAR de Delta Lake mediante el parámetro de trabajo `--extra-jars`. No incluya `delta` como valor para el parámetro de trabajo `--datalake-formats`. Si usa AWS Glue 5.0, debe configurar el parámetro de trabajo `--user-jars-first true`. En este caso, para utilizar la biblioteca de Python de Delta Lake, debe especificar los archivos JAR de la biblioteca mediante el parámetro de trabajo `--extra-py-files`. La biblioteca de Python viene empaquetada en los archivos JAR de Delta Lake.

Ejemplo: escribir una tabla de Delta Lake en Amazon S3 y regístrela en el Catálogo de datos de AWS Glue

El siguiente script ETL de AWS Glue muestra cómo escribir una tabla de Delta Lake en Amazon S3 y registrar la tabla en el Catálogo de datos de AWS Glue.

Python

```
# Example: Create a Delta Lake table from a DataFrame
# and register the table to Glue Data Catalog

additional_options = {
```

```
    "path": "s3://<s3Path>"
}
dataFrame.write \
    .format("delta") \
    .options(**additional_options) \
    .mode("append") \
    .partitionBy("<your_partitionkey_field>") \
    .saveAsTable("<your_database_name>.<your_table_name>")
```

Scala

```
// Example: Example: Create a Delta Lake table from a DataFrame
// and register the table to Glue Data Catalog

val additional_options = Map(
  "path" -> "s3://<s3Path>"
)
dataFrame.write.format("delta")
  .options(additional_options)
  .mode("append")
  .partitionBy("<your_partitionkey_field>")
  .saveAsTable("<your_database_name>.<your_table_name>")
```

Ejemplo: leer una tabla de Delta Lake de Amazon S3 con el Catálogo de datos de AWS Glue

El siguiente script de ETL de AWS Glue lee la tabla de Delta Lake que creó en Ejemplo: escribir una tabla de Delta Lake en Amazon S3 y regístrela en el Catálogo de datos de AWS Glue.

Python

Para este ejemplo, utilice el método create_data_frame.from_catalog.

```
# Example: Read a Delta Lake table from Glue Data Catalog

from awsglue.context import GlueContext
from pyspark.context import SparkContext

sc = SparkContext()
glueContext = GlueContext(sc)

df = glueContext.create_data_frame.from_catalog(
    database="<your_database_name>",
```

```
    table_name="<your_table_name>",
    additional_options=additional_options
)
```

Scala

Para este ejemplo, utilice el método getCatalogSource.

```
// Example: Read a Delta Lake table from Glue Data Catalog

import com.amazonaws.services.glue.GlueContext
import org.apacke.spark.SparkContext

object GlueApp {
  def main(sysArgs: Array[String]): Unit = {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)
    val df = glueContext.getCatalogSource("<your_database_name>",
 "<your_table_name>",
      additionalOptions = additionalOptions)
      .getDataFrame()
  }
}
```

Ejemplo: insertar un elemento **`DataFrame`** en una tabla de Delta Lake de Amazon S3 con el Catálogo de datos de AWS Glue

En este ejemplo, se insertan los datos en la tabla de Delta Lake que creó en Ejemplo: escribir una tabla de Delta Lake en Amazon S3 y regístrela en el Catálogo de datos de AWS Glue.

> **Note**
>
> En este ejemplo, se requiere que establezca el parámetro de trabajo de `--enable-glue-datacatalog` para utilizar el Catálogo de datos de AWS Glue como metaalmacén de Apache Spark Hive. Para obtener más información, consulte Uso de los parámetros de trabajo en los trabajos de AWS Glue.

Python

Para este ejemplo, utilice el método write_data_frame.from_catalog.

```
# Example: Insert into a Delta Lake table in S3 using Glue Data Catalog

from awsglue.context import GlueContext
from pyspark.context import SparkContext

sc = SparkContext()
glueContext = GlueContext(sc)

glueContext.write_data_frame.from_catalog(
    frame=dataFrame,
    database="<your_database_name>",
    table_name="<your_table_name>",
    additional_options=additional_options
)
```

Scala

Para este ejemplo, utilice el método getCatalogSink.

```
// Example: Insert into a Delta Lake table in S3 using Glue Data Catalog

import com.amazonaws.services.glue.GlueContext
import org.apacke.spark.SparkContext

object GlueApp {
  def main(sysArgs: Array[String]): Unit = {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)
    glueContext.getCatalogSink("<your_database_name>", "<your_table_name>",
      additionalOptions = additionalOptions)
      .writeDataFrame(dataFrame, glueContext)
  }
}
```

Ejemplo: leer una tabla de Delta Lake de Amazon S3 con la API de Spark

En este ejemplo, se lee una tabla de Delta Lake de Amazon S3 con la API de Spark.

Python

```
# Example: Read a Delta Lake table from S3 using a Spark DataFrame
```

```
dataFrame = spark.read.format("delta").load("s3://<s3path/>")
```

Scala

```
// Example: Read a Delta Lake table from S3 using a Spark DataFrame

val dataFrame = spark.read.format("delta").load("s3://<s3path/>")
```

Ejemplo: escribir una tabla de Delta Lake en Amazon S3 con Spark

En este ejemplo, se escribe una tabla de Delta Lake en Amazon S3 con Spark.

Python

```
# Example: Write a Delta Lake table to S3 using a Spark DataFrame

dataFrame.write.format("delta") \
    .options(**additional_options) \
    .mode("overwrite") \
    .partitionBy("<your_partitionkey_field>")
    .save("s3://<s3Path>")
```

Scala

```
// Example: Write a Delta Lake table to S3 using a Spark DataFrame

dataFrame.write.format("delta")
  .options(additionalOptions)
  .mode("overwrite")
  .partitionBy("<your_partitionkey_field>")
  .save("s3://<s3path/>")
```

Ejemplo: Lea y escriba la tabla de Delta Lake con el control de permisos de Lake Formation

En este ejemplo se lee y escribe una tabla de Delta Lake con el control de permisos de Lake Formation.

1. Cree una tabla Delta y regístrela en Lake Formation
   a. Para habilitar el control de permisos de Lake Formation, primero tendrá que registrar la tabla de la ruta Amazon S3 en Lake Formation. Para obtener más información, consulte Registro de una

ubicación de Amazon S3. Puede registrarlo desde la consola de Lake Formation o mediante la AWS CLI:

```
aws lakeformation register-resource --resource-arn arn:aws:s3:::<s3-bucket>/<s3-folder> --use-service-linked-role --region <REGION>
```

Una vez que registre una ubicación de Amazon S3, cualquier tabla de AWS Glue que apunte a la ubicación (o a cualquiera de sus ubicaciones secundarias) devolverá el valor del parámetro `IsRegisteredWithLakeFormation` como verdadero en la llamada `GetTable`.

b. Cree una tabla Delta que apunte a la ruta de Amazon S3 registrada a través de Spark:

> **Note**
>
> A continuación, se muestran algunos ejemplos de Python.

```
dataFrame.write \
 .format("delta") \
 .mode("overwrite") \
 .partitionBy("<your_partitionkey_field>") \
 .save("s3://<the_s3_path>")
```

Una vez que los datos se hayan escrito en Amazon S3, utilice el rastreador AWS Glue para crear una nueva tabla de catálogo de Delta. Para obtener más información, consulte Presentación del soporte de tabla nativa de Delta Lake con rastreadores AWS Glue.

También puede crear la tabla manualmente a través de la API de AWS Glue.`CreateTable`

2. Conceda permiso a Lake Formation para el rol de IAM del trabajo de AWS Glue. Puede conceder permisos desde la consola de Lake Formation o mediante la AWS CLI. Para obtener más información, consulte Concesión de permisos de tabla mediante la consola de Lake Formation y el método de recurso con nombre
3. Lea la tabla Delta registrada en Lake Formation. El código es el mismo que leer una tabla Delta no registrada. Tenga en cuenta que el rol de IAM del trabajo de AWS Glue debe tener el permiso SELECT para que la lectura se realice correctamente.

```
# Example: Read a Delta Lake table from Glue Data Catalog
```

```
df = glueContext.create_data_frame.from_catalog(
    database="<your_database_name>",
    table_name="<your_table_name>",
    additional_options=additional_options
)
```

4. Escribe a una tabla Delta registrada en Lake Formation. El código es el mismo que escribir en una tabla Delta no registrada. Tenga en cuenta que el rol de IAM del trabajo de AWS Glue debe tener el permiso SUPER para que la escritura se realice correctamente.

   De forma predeterminada, AWS Glue usa `Append` como SaveMode. Puede cambiarlo configurando la opción SaveMode en `additional_options`. Para obtener información sobre la compatibilidad con SaveMode en las tablas Delta, consulte Escribir en una tabla.

```
glueContext.write_data_frame.from_catalog(
    frame=dataFrame,
    database="<your_database_name>",
    table_name="<your_table_name>",
    additional_options=additional_options
)
```

Uso del marco de Iceberg en AWS Glue

AWS Glue 3.0 y versiones posteriores son compatibles con el marco de Apache Iceberg para lagos de datos. Iceberg proporciona un formato de tabla de alto rendimiento que funciona igual que una tabla SQL. En este tema, se describen las características disponibles para usar los datos en AWS Glue al transportar o almacenar datos en una tabla de Iceberg. Para más información sobre Iceberg, consulte la documentación oficial de Apache Iceberg.

Puede usar AWS Glue para llevar a cabo operaciones de lectura y escritura en tablas de Iceberg en Amazon S3, o trabajar con tablas de Iceberg mediante el Catálogo de datos de AWS Glue. También se admiten operaciones adicionales, como insertar, y todas las consultas de Spark escrituras de Spark. La actualización no es compatible con las tablas de Iceberg.

> **Note**
>
> `ALTER TABLE … RENAME TO` no está disponible para Apache Iceberg 0.13.1 para AWS Glue 3.0.

La siguiente tabla muestra la versión de Iceberg que se incluye en cada versión de AWS Glue.

Versión de AWS Glue	Versión de Iceberg compatible
5.0	1.7.1
4.0	1.0.0
3.0	0.13.1

Para más información sobre los marcos de lagos de datos compatibles con AWS Glue, consulte Uso de marcos de lagos de datos con trabajos de ETL de AWS Glue.

Habilitar el marco de Iceberg

Para habilitar Iceberg para AWS Glue, haga las siguientes tareas:

- Especifique `iceberg` como valor para el parámetro del trabajo `--datalake-formats`. Para obtener más información, consulte Uso de los parámetros de trabajo en los trabajos de AWS Glue.
- Cree una clave con el nombre `--conf` para el trabajo de AWS Glue y establézcala en el siguiente valor. Como alternativa, puede establecer la siguiente configuración mediante `SparkConf` en su script. Esta configuración ayuda a Apache Spark a gestionar correctamente las tablas de Iceberg.

```
spark.sql.extensions=org.apache.iceberg.spark.extensions.IcebergSparkSessionExtensions
--conf spark.sql.catalog.glue_catalog=org.apache.iceberg.spark.SparkCatalog
--conf spark.sql.catalog.glue_catalog.warehouse=s3://<your-warehouse-dir>/
--conf spark.sql.catalog.glue_catalog.catalog-
impl=org.apache.iceberg.aws.glue.GlueCatalog
--conf spark.sql.catalog.glue_catalog.io-impl=org.apache.iceberg.aws.s3.S3FileIO
```

  Si lee o escribe en tablas de Iceberg registradas en Lake Formation, siga las indicaciones que aparecen en the section called “Lake Formation para FGAC” en AWS Glue 5.0 y versiones posteriores. En AWS Glue 4.0, agregue la siguiente configuración para habilitar la compatibilidad con Lake Formation.

```
--conf spark.sql.catalog.glue_catalog.glue.lakeformation-enabled=true
--conf spark.sql.catalog.glue_catalog.glue.id=<table-catalog-id>
```

Si utiliza AWS Glue 3.0 con Iceberg 0.13.1, debe establecer las siguientes configuraciones adicionales para utilizar el administrador de bloqueos de Amazon DynamoDB y garantizar la transacción atómica. AWS Glue 4.0 y versiones posteriores utilizan el bloqueo positivo de forma predeterminada. Para obtener más información, consulte Iceberg AWS Integrations en la documentación oficial de Apache Iceberg.

```
--conf spark.sql.catalog.glue_catalog.lock-
impl=org.apache.iceberg.aws.glue.DynamoLockManager
--conf spark.sql.catalog.glue_catalog.lock.table=<your-dynamodb-table-name>
```

Usar una versión diferente de Iceberg

Para usar una versión de Iceberg que no sea compatible con AWS Glue, indique sus propios archivos JAR de Iceberg mediante el parámetro de trabajo `--extra-jars`. No incluya `iceberg` como valor para el parámetro `--datalake-formats`. Si usa AWS Glue 5.0, debe configurar el parámetro de trabajo `--user-jars-first true`.

Habilitar el cifrado para tablas de Iceberg

> **Note**
>
> Las tablas de Iceberg tienen sus propios mecanismos para habilitar el cifrado del lado del servidor. Debe habilitar esta configuración además de la configuración de seguridad de Glue AWS.

Para habilitar el cifrado del lado del servidor en las tablas de Iceberg, consulte las instrucciones de la documentación de Iceberg.

Agregue la configuración de Spark para el acceso entre regiones de Iceberg

Para añadir una configuración adicional de Spark para el acceso a tablas entre regiones de Iceberg con el catálogo de datos de AWS Glue y AWS Lake Formation, siga los pasos que se indican a continuación:

1. Creación de un punto de acceso de varias regiones.
2. Defina las siguientes propiedades de Spark:

```
-----
    --conf spark.sql.catalog.my_catalog.s3.use-arn-region-enabled=true \
    --conf spark.sql.catalog.{CATALOG}.s3.access-points.bucket1",
 "arn:aws:s3::<account-id>:accesspoint/<mrap-id>.mrap \
    --conf spark.sql.catalog.{CATALOG}.s3.access-points.bucket2",
 "arn:aws:s3::<account-id>:accesspoint/<mrap-id>.mrap
-----
```

Ejemplo: escriba una tabla de Iceberg en Amazon S3 y regístrela en el Catálogo de datos de AWS Glue

En este script de ejemplo, se muestra cómo escribir una tabla de Iceberg en Amazon S3. En el ejemplo se usan integraciones de AWS de Iceberg para registrar la tabla en el Catálogo de datos de AWS Glue.

Python

```
# Example: Create an Iceberg table from a DataFrame
# and register the table to Glue Data Catalog

dataFrame.createOrReplaceTempView("tmp_<your_table_name>")

query = f"""
CREATE TABLE glue_catalog.<your_database_name>.<your_table_name>
USING iceberg
TBLPROPERTIES ("format-version"="2")
AS SELECT * FROM tmp_<your_table_name>
"""
spark.sql(query)
```

Scala

```
// Example: Example: Create an Iceberg table from a DataFrame
// and register the table to Glue Data Catalog

dataFrame.createOrReplaceTempView("tmp_<your_table_name>")

val query = """CREATE TABLE glue_catalog.<your_database_name>.<your_table_name>
USING iceberg
TBLPROPERTIES ("format-version"="2")
```

```
AS SELECT * FROM tmp_<your_table_name>
"""
spark.sql(query)
```

Como alternativa, puede escribir una tabla de Iceberg en Amazon S3 y en el Catálogo de datos con los métodos de Spark.

Requisitos previos: deberá disponer de un catálogo para su uso en la biblioteca Iceberg. Cuando se utiliza el AWS catálogo de datos de Glue AWS, Glue lo simplifica. El catálogo de datos de Glue AWS está preconfigurado para que lo utilicen las bibliotecas de Spark como `glue_catalog`. Las tablas del catálogo de datos se identifican mediante un *`databaseName`* y un *`tableName`*. Para obtener más información sobre el catálogo de datos de Glue AWS, consulte Detección y catalogación de datos.

Si no utiliza el catálogo de datos de Glue AWS, tendrá que aprovisionar un catálogo a través de las API de Spark. Para obtener más información, consulte Configuración de Spark en la documentación de Iceberg.

En este ejemplo, se escribe una tabla de Iceberg en Amazon S3 y el Catálogo de datos con Spark.

Python

```
# Example: Write an Iceberg table to S3 on the Glue Data Catalog

# Create (equivalent to CREATE TABLE AS SELECT)
dataFrame.writeTo("glue_catalog.databaseName.tableName") \
    .tableProperty("format-version", "2") \
    .create()

# Append (equivalent to INSERT INTO)
dataFrame.writeTo("glue_catalog.databaseName.tableName") \
    .tableProperty("format-version", "2") \
    .append()
```

Scala

```
// Example: Write an Iceberg table to S3 on the Glue Data Catalog

// Create (equivalent to CREATE TABLE AS SELECT)
dataFrame.writeTo("glue_catalog.databaseName.tableName")
```

```
    .tableProperty("format-version", "2")
    .create()

// Append (equivalent to INSERT INTO)
dataFrame.writeTo("glue_catalog.databaseName.tableName")
    .tableProperty("format-version", "2")
    .append()
```

Ejemplo: leer una tabla de Iceberg de Amazon S3 con el Catálogo de datos de AWS Glue

En este ejemplo, se lee la tabla de Iceberg que creó en Ejemplo: escriba una tabla de Iceberg en Amazon S3 y regístrela en el Catálogo de datos de AWS Glue.

Python

Para este ejemplo, utilice el método `GlueContext.create_data_frame.from_catalog()`.

```
# Example: Read an Iceberg table from Glue Data Catalog

from awsglue.context import GlueContext
from pyspark.context import SparkContext

sc = SparkContext()
glueContext = GlueContext(sc)

df = glueContext.create_data_frame.from_catalog(
    database="<your_database_name>",
    table_name="<your_table_name>",
    additional_options=additional_options
)
```

Scala

Para este ejemplo, utilice el método getCatalogSource.

```
// Example: Read an Iceberg table from Glue Data Catalog

import com.amazonaws.services.glue.GlueContext
import org.apacke.spark.SparkContext

object GlueApp {
  def main(sysArgs: Array[String]): Unit = {
```

```
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)
    val df = glueContext.getCatalogSource("<your_database_name>",
 "<your_table_name>",
      additionalOptions = additionalOptions)
      .getDataFrame()
  }
}
```

Ejemplo: insertar un **`DataFrame`** en una tabla de Iceberg de Amazon S3 con el Catálogo de datos de AWS Glue

En este ejemplo, se insertan los datos en la tabla de Iceberg que creó en Ejemplo: escriba una tabla de Iceberg en Amazon S3 y regístrela en el Catálogo de datos de AWS Glue.

> **Note**
>
> En este ejemplo, se requiere que establezca el parámetro de trabajo de `--enable-glue-datacatalog` para utilizar el Catálogo de datos de AWS Glue como metaalmacén de Apache Spark Hive. Para obtener más información, consulte Uso de los parámetros de trabajo en los trabajos de AWS Glue.

Python

Para este ejemplo, utilice el método `GlueContext.write_data_frame.from_catalog()`.

```
# Example: Insert into an Iceberg table from Glue Data Catalog

from awsglue.context import GlueContext
from pyspark.context import SparkContext

sc = SparkContext()
glueContext = GlueContext(sc)

glueContext.write_data_frame.from_catalog(
    frame=dataFrame,
    database="<your_database_name>",
    table_name="<your_table_name>",
    additional_options=additional_options
```

```
)
```

Scala

Para este ejemplo, utilice el método getCatalogSink.

```
// Example: Insert into an Iceberg table from Glue Data Catalog

import com.amazonaws.services.glue.GlueContext
import org.apacke.spark.SparkContext

object GlueApp {
  def main(sysArgs: Array[String]): Unit = {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)
    glueContext.getCatalogSink("<your_database_name>", "<your_table_name>",
      additionalOptions = additionalOptions)
      .writeDataFrame(dataFrame, glueContext)
  }
}
```

Ejemplo: leer una tabla de Iceberg de Amazon S3 con Spark

Requisitos previos: deberá disponer de un catálogo para su uso en la biblioteca Iceberg. Cuando se utiliza el AWS catálogo de datos de Glue AWS, Glue lo simplifica. El catálogo de datos de Glue AWS está preconfigurado para que lo utilicen las bibliotecas de Spark como `glue_catalog`. Las tablas del catálogo de datos se identifican mediante un *`databaseName`* y un *`tableName`*. Para obtener más información sobre el catálogo de datos de Glue AWS, consulte Detección y catalogación de datos.

Si no utiliza el catálogo de datos de Glue AWS, tendrá que aprovisionar un catálogo a través de las API de Spark. Para obtener más información, consulte Configuración de Spark en la documentación de Iceberg.

En este ejemplo, se lee una tabla de Iceberg en Amazon S3 del catálogo de datos con Spark.

Python

```
# Example: Read an Iceberg table on S3 as a DataFrame from the Glue Data Catalog

dataFrame = spark.read.format("iceberg").load("glue_catalog.databaseName.tableName")
```

Scala

```
// Example: Read an Iceberg table on S3 as a DataFrame from the Glue Data Catalog

val dataFrame =
 spark.read.format("iceberg").load("glue_catalog.databaseName.tableName")
```

Ejemplo: Lea y escriba una tabla de iceberg con el control de permisos de Lake Formation

En este ejemplo se lee y escribe una tabla de Iceberg con el control de permisos de Lake Formation.

> **Note**
>
> Este ejemplo solo funciona en AWS Glue 4.0. En AWS Glue 5.0 y versiones posteriores, siga las indicaciones que aparece en the section called “Lake Formation para FGAC”.

1. Cree una tabla de iceberg y regístrela en Lake Formation:
   a. Para habilitar el control de permisos de Lake Formation, primero tendrá que registrar la tabla de la ruta Amazon S3 en Lake Formation. Para obtener más información, consulte Registro de una ubicación de Amazon S3. Puede registrarlo desde la consola de Lake Formation o mediante la AWS CLI:

      ```
      aws lakeformation register-resource --resource-arn arn:aws:s3:::<s3-bucket>/<s3-folder> --use-service-linked-role --region <REGION>
      ```

      Una vez que registre una ubicación de Amazon S3, cualquier tabla de AWS Glue que apunte a la ubicación (o a cualquiera de sus ubicaciones secundarias) devolverá el valor del parámetro `IsRegisteredWithLakeFormation` como verdadero en la llamada `GetTable`.

   b. Cree una tabla de Iceberg que apunte a la ruta registrada mediante Spark SQL:

      > **Note**
      >
      > A continuación, se muestran algunos ejemplos de Python.

      ```
      dataFrame.createOrReplaceTempView("tmp_<your_table_name>")
      ```

```
query = f"""
CREATE TABLE glue_catalog.<your_database_name>.<your_table_name>
USING iceberg
AS SELECT * FROM tmp_<your_table_name>
"""
spark.sql(query)
```

También puede crear la tabla manualmente mediante la API de AWS Glue.`CreateTable` Para obtener más información, consulte Creación de tablas de Apache Iceberg.

> **Note**
>
> Actualmente, la API `UpdateTable` no es compatible con el formato de tabla Iceberg como entrada para la operación.

2. Conceda permiso a Lake Formation para el rol de IAM. Puede conceder permisos desde la consola de Lake Formation o mediante la AWS CLI. Para obtener más información, consulte: https://docs.aws.amazon.com/lake-formation/latest/dg/granting-table-permissions.html
3. Lea una tabla de Iceberg registrada en Lake Formation. El código es el mismo que leer una tabla de Icebergs no registrada. Tenga en cuenta que el rol de IAM de su trabajo de AWS Glue debe tener el permiso SELECT para que la lectura se realice correctamente.

```
# Example: Read an Iceberg table from the AWS Glue Data Catalog
from awsglue.context import GlueContextfrom pyspark.context import SparkContext

sc = SparkContext()
glueContext = GlueContext(sc)

df = glueContext.create_data_frame.from_catalog(
    database="<your_database_name>",
    table_name="<your_table_name>",
    additional_options=additional_options
)
```

4. Escriba en una tabla de Iceberg registrada en Lake Formation. El código es el mismo que escribir en una tabla Iceberg no registrada. Tenga en cuenta que su rol de IAM del trabajo de AWS Glue debe tener el permiso SUPER para que la escritura se realice correctamente.

```
glueContext.write_data_frame.from_catalog(
```

```
    frame=dataFrame,
    database="<your_database_name>",
    table_name="<your_table_name>",
    additional_options=additional_options
)
```

Referencia de configuración compartida

Puede utilizar los siguientes `format_options` valores con cualquier tipo de formato.

- `attachFilename` — Una cadena en el formato adecuado para utilizarla como nombre de columna. Si proporciona esta opción, el nombre del archivo de origen para el registro se adjuntará a él. El valor del parámetro se utilizará como nombre de la columna.
- `attachTimestamp` — Una cadena en el formato adecuado para utilizarla como nombre de columna. Si proporciona esta opción, la hora de modificación del archivo de origen para el registro se adjuntará a él. El valor del parámetro se utilizará como nombre de la columna.

Soporte de AWS Glue Data Catalog para trabajos de Spark SQL

AWS Glue Data Catalog es un catálogo compatible con metaalmacenes de Apache Hive. Puede configurar los trabajos y los puntos de conexión de desarrollo de AWS Glue para que utilicen el Data Catalog como un metaalmacén de Apache Hive externo. De este modo, podrá ejecutar directamente consultas de Apache Spark SQL en las tablas almacenadas en el catálogo de datos. De forma predeterminada, los marcos dinámicos de AWS Glue se integran con Data Catalog. Sin embargo, con esta característica, los trabajos de Spark SQL pueden empezar a utilizar Data Catalog como un metaalmacén de Hive externo.

Esta característica requiere el acceso de red al punto de conexión de la API de AWS Glue Para trabajos de AWS Glue con conexiones ubicadas en subredes privadas, debe configurar un punto de conexión de VPC o una puerta de enlace NAT para proporcionar el acceso a la red. Para obtener más información sobre la configuración del punto de conexión de VPC, consulte Configuración del acceso de red a los almacenes de datos. Para crear una gateway NAT, consulte Gateways NAT en la Guía del usuario de Amazon VPC.

Puede configurar los trabajos y los puntos de enlace de AWS Glue añadiendo el argumento `"--enable-glue-datacatalog": ""` a los argumentos de los trabajos y los puntos de enlace de desarrollo, respectivamente. Al transferir este argumento, se definen ciertas configuraciones en Spark que le permiten obtener acceso a Data Catalog como un metaalmacén de Hive externo.

También permite la compatibilidad de Hive en el objeto `SparkSession` creado en el trabajo o punto de enlace de desarrollo de AWS Glue.

Para permitir el acceso a Data Catalog, verifique la casilla Use AWS Glue Data Catalog as the Hive metastore (Utilizar AWS Glue Data Catalog como metastore de Hive) del grupo Catalog options (Opciones de Catalog), que encontrará en la página Add job (Agregar trabajo) o Add endpoint (Agregar punto de conexión) de la consola. Tenga en cuenta que el rol de IAM utilizado para el trabajo o el punto de enlace de desarrollo debe tener permisos `glue:CreateDatabase`. Si no existe una base de datos, se crea una denominada "`default`" en Data Catalog.

Veamos un ejemplo acerca de cómo se puede utilizar esta característica en los trabajos de Spark SQL. En el siguiente ejemplo, se presupone que se han rastreado los conjuntos de datos de legisladores de EE. UU. disponibles en `s3://awsglue-datasets/examples/us-legislators`.

Para serializar o deserializar los datos de las tablas definidas en AWS Glue Data Catalog, Spark SQL necesita la clase Hive SerDe del formato definido en AWS Glue Data Catalog, en la ruta de clase del trabajo de Spark.

AWS Glue distribuye las clases SerDe de algunos formatos comunes. A continuación, se incluyen los enlaces de Amazon S3 de dichas clases:

- JSON
- XML
- Grok

Añada la clase SerDe de JSON como un JAR adicional al punto de enlace de desarrollo. En el caso de los trabajos, puede añadir la clase SerDe utilizando el argumento `--extra-jars` en el campo "arguments". Para obtener más información, consulte Uso de los parámetros de trabajo en los trabajos de AWS Glue.

A continuación, se muestra un ejemplo de un JSON de entrada que crea un punto de enlace de desarrollo con Data Catalog habilitado para Spark SQL.

```
{
    "EndpointName": "Name",
    "RoleArn": "role_ARN",
    "PublicKey": "public_key_contents",
    "NumberOfNodes": 2,
    "Arguments": {
```

```
      "--enable-glue-datacatalog": ""
    },
    "ExtraJarsS3Path": "s3://crawler-public/json/serde/json-serde.jar"
}
```

Ahora, puede consultar las tablas creadas a partir del conjunto de datos de los legisladores de EE. UU con Spark SQL.

```
>>> spark.sql("use legislators")
DataFrame[]
>>> spark.sql("show tables").show()
+-----------+-----------------+-----------+
|   database|        tableName|isTemporary|
+-----------+-----------------+-----------+
|legislators|       areas_json|      false|
|legislators|   countries_json|      false|
|legislators|      events_json|      false|
|legislators| memberships_json|      false|
|legislators|organizations_json|      false|
|legislators|     persons_json|      false|
+-----------+-----------------+-----------+
>>> spark.sql("describe memberships_json").show()
+--------------------+---------+-----------------+
|            col_name|data_type|          comment|
+--------------------+---------+-----------------+
|             area_id|   string|from deserializer|
|     on_behalf_of_id|   string|from deserializer|
|     organization_id|   string|from deserializer|
|                role|   string|from deserializer|
|           person_id|   string|from deserializer|
|legislative_perio...|   string|from deserializer|
|          start_date|   string|from deserializer|
|            end_date|   string|from deserializer|
+--------------------+---------+-----------------+
```

Si la clase SerDe del formato no está disponible en el classpath del trabajo, aparecerá un error similar al siguiente.

```
>>> spark.sql("describe memberships_json").show()

Caused by: MetaException(message:java.lang.ClassNotFoundException Class
 org.openx.data.jsonserde.JsonSerDe not found)
```

```
    at
 org.apache.hadoop.hive.metastore.MetaStoreUtils.getDeserializer(MetaStoreUtils.java:399)
    at
 org.apache.hadoop.hive.ql.metadata.Table.getDeserializerFromMetaStore(Table.java:276)
    ... 64 more
```

Para ver únicamente los diferentes valores de `organization_id` de la tabla `memberships`, ejecute la siguiente consulta SQL.

```
>>> spark.sql("select distinct organization_id from memberships_json").show()
+--------------------+
|     organization_id|
+--------------------+
|d56acebe-8fdc-47b...|
|8fa6c3d2-71dc-478...|
+--------------------+
```

Si debe hacer lo mismo con marcos dinámicos, ejecute lo siguiente.

```
>>> memberships = glueContext.create_dynamic_frame.from_catalog(database="legislators",
 table_name="memberships_json")
>>> memberships.toDF().createOrReplaceTempView("memberships")
>>> spark.sql("select distinct organization_id from memberships").show()
+--------------------+
|     organization_id|
+--------------------+
|d56acebe-8fdc-47b...|
|8fa6c3d2-71dc-478...|
+--------------------+
```

Aunque DynamicFrames está optimizado para las operaciones de ETL, permitir que Spark SQL tenga acceso a Data Catalog es un modo sencillo de ejecutar instrucciones SQL complejas o migrar aplicaciones existentes.

Uso de marcadores de trabajo

AWS Glue para Spark usa marcadores de flujo de trabajo para realizar un seguimiento de los datos que ya se han procesado. Para obtener un resumen de la característica de marcadores de trabajo y lo que admite, consulte the section called “Seguimiento de los datos procesados mediante marcadores de trabajo”. Al programar un trabajo de AWS Glue con marcadores, tiene acceso a una flexibilidad que no está disponible en los trabajos visuales.

- Al leer desde la JDBC, puede especificar las columnas que se van a utilizar como claves de marcador en el script de AWS Glue.
- Puede elegir qué `transformation_ctx` aplicar a cada llamada de método.

Siempre, al principio de un script, haga una llamada a *`job.init`* y, al final, a *`job.commit`* con los parámetros configurados de manera apropiada. Estas dos características se utilizan para inicializar el servicio de marcadores y actualizar el servicio con el cambio de estado. Los favoritos no funcionarán sin llamarlos.

Especifique las claves de los marcadores

En el caso de los flujos de trabajo de JDBC, el marcador realiza un seguimiento de las filas que ha leído el trabajo al comparar los valores de los campos clave con un valor marcado. Esto no es necesario ni aplicable a los flujos de trabajo de Amazon S3. Al escribir un script AWS Glue sin el editor visual, puede especificar con marcadores qué columna desea rastrear. También puede especificar varias columnas. Se permiten espacios en la secuencia de valores al especificar las claves de marcadores definidas por el usuario.

> **Warning**
>
> Si se utilizan claves de marcador definidas por el usuario, deben aumentar o disminuir de forma monotónica estrictamente. Al seleccionar campos adicionales para una clave compuesta, los campos para conceptos como “versiones secundarias” o “números de revisión” no cumplen este criterio, ya que sus valores se reutilizan en todo el conjunto de datos.

Puede especificar `jobBookmarkKeys` y `jobBookmarkKeysSortOrder` de las siguientes maneras:

- `create_dynamic_frame.from_catalog`: utilice `additional_options`.
- `create_dynamic_frame.from_options`: utilice `connection_options`.

Contexto de transformación

Muchos de los métodos de marco dinámico de AWS Glue PySpark incluyen un parámetro opcional denominado `transformation_ctx`, que es un identificador único para la instancia de operador de ETL. El parámetro `transformation_ctx` se utiliza para identificar la información de estado

dentro de un marcador de trabajo para el operador determinado. En concreto, AWS Glue utiliza `transformation_ctx` para indexar la clave del estado de marcador.

> **Warning**
>
> `transformation_ctx` sirve de clave para realizar búsquedas en el estado de favorito de un origen específico del script. Para que el favorito funcione correctamente, siempre se debe conservar la coherencia entre el origen y el elemento `transformation_ctx` asociado. Modificar la propiedad de origen o cambiarle el nombre a `transformation_ctx` puede hacer que el favorito anterior deje de ser válido y que el filtrado basado en marcas temporales no produzca el resultado correcto.

Para que los marcadores de flujo de trabajo funcionen correctamente, habilite el parámetro de marcador de trabajo y establezca el parámetro `transformation_ctx`. Si no pasa el parámetro `transformation_ctx`, no se habilitan los marcadores de trabajo para un marco dinámico o una tabla que se usen en el método. Por ejemplo, si tiene un trabajo de ETL que lee y combina dos orígenes de Amazon S3, puede decidir transferir el parámetro `transformation_ctx` únicamente a los métodos para los que desea habilitar marcadores. Si restablece el marcador de trabajo de un trabajo, se restablecen todas las transformaciones que están asociadas al trabajo sea cual sea el `transformation_ctx` utilizado.

Para obtener más información acerca de la clase `DynamicFrameReader`, consulte Clase DynamicFrameReader. Para obtener más información acerca de las extensiones de PySpark, consulte Referencia de las extensiones de PySpark de AWS Glue.

Ejemplos

Example

A continuación, se muestra un ejemplo de un script generado para un origen de datos de Amazon S3. Las partes del script que son necesarias para utilizar marcadores de trabajo se muestran en cursiva. Para obtener más información sobre estos elementos, consulte Clase GlueContext API y Clase DynamicFrameWriter API.

```
# Sample Script
import sys
from awsglue.transforms import *
from awsglue.utils import getResolvedOptions
```

```
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job

args = getResolvedOptions(sys.argv, ['JOB_NAME'])
sc = SparkContext()
glueContext = GlueContext(sc)
spark = glueContext.spark_session
job = Job(glueContext)
job.init(args['JOB_NAME'], args)

datasource0 = glueContext.create_dynamic_frame.from_catalog(
    database = "database",
    table_name = "relatedqueries_csv",
    transformation_ctx = "datasource0"
)

applymapping1 = ApplyMapping.apply(
    frame = datasource0,
    mappings = [("col0", "string", "name", "string"), ("col1", "string", "number",
 "string")],
    transformation_ctx = "applymapping1"
)

datasink2 = glueContext.write_dynamic_frame.from_options(
    frame = applymapping1,
    connection_type = "s3",
    connection_options = {"path": "s3://input_path"},
    format = "json",
    transformation_ctx = "datasink2"
)


job.commit()
```

Example

A continuación se muestra un ejemplo de un script generado para un origen JDBC. La tabla de origen es una tabla de empleados con la columna empno como clave principal. Aunque el trabajo utiliza una clave principal secuencial como clave de marcador predeterminada, si no se especifica ninguna clave de marcador, porque empno no es necesariamente secuencial (podría haber brechas en los valores), esta clave no califica como clave de marcador predeterminada. Por lo tanto, el script

designa empno explícitamente como la clave de marcador. Esa parte del código se muestra en cursiva.

```
import sys
from awsglue.transforms import *
from awsglue.utils import getResolvedOptions
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job

args = getResolvedOptions(sys.argv, ['JOB_NAME'])

sc = SparkContext()
glueContext = GlueContext(sc)
spark = glueContext.spark_session
job = Job(glueContext)
job.init(args['JOB_NAME'], args)

datasource0 = glueContext.create_dynamic_frame.from_catalog(
    database = "hr",
    table_name = "emp",
    transformation_ctx = "datasource0",
    additional_options = {"jobBookmarkKeys":["empno"],"jobBookmarkKeysSortOrder":"asc"}
)

applymapping1 = ApplyMapping.apply(
    frame = datasource0,
    mappings = [("ename", "string", "ename", "string"), ("hrly_rate", "decimal(38,0)",
 "hrly_rate", "decimal(38,0)"), ("comm", "decimal(7,2)", "comm", "decimal(7,2)"),
 ("hiredate", "timestamp", "hiredate", "timestamp"), ("empno", "decimal(5,0)", "empno",
 "decimal(5,0)"), ("mgr", "decimal(5,0)", "mgr", "decimal(5,0)"), ("photo", "string",
 "photo", "string"), ("job", "string", "job", "string"), ("deptno", "decimal(3,0)",
 "deptno", "decimal(3,0)"), ("ssn", "decimal(9,0)", "ssn", "decimal(9,0)"), ("sal",
 "decimal(7,2)", "sal", "decimal(7,2)")],
    transformation_ctx = "applymapping1"
)

datasink2 = glueContext.write_dynamic_frame.from_options(
    frame = applymapping1,
    connection_type = "s3",
    connection_options = {"path": "s3://hr/employees"},
    format = "csv",
    transformation_ctx = "datasink2"
```

```
)

job.commit()
```

Usar la detección de datos confidenciales fuera de AWS Glue Studio

AWS Glue Studio le permite detectar datos confidenciales; sin embargo, también puede utilizar la función de detección de datos confidenciales fuera de AWS Glue Studio.

Para obtener una lista completa de los tipos de datos confidenciales administrados, consulte Tipos de datos administrados.

Detección de datos confidenciales mediante tipos de PII administrados por AWS

AWS Glue proporciona dos API en un trabajo de AWS Glue ETL. Son `detect()` y `classifyColumns()`:

```
 detect(frame: DynamicFrame,
     entityTypesToDetect: Seq[String],
     outputColumnName: String = "DetectedEntities",
     detectionSensitivity: String = "LOW"): DynamicFrame

detect(frame: DynamicFrame,
     detectionParameters: JsonOptions,
     outputColumnName: String = "DetectedEntities",
     detectionSensitivity: String = "LOW"): DynamicFrame

 classifyColumns(frame: DynamicFrame,
     entityTypesToDetect: Seq[String],
     sampleFraction: Double = 0.1,
     thresholdFraction: Double = 0.1,
     detectionSensitivity: String = "LOW")
```

Puede usar la API `detect()` para identificar tipos de PII administrados por AWS y los tipos de entidades personalizadas. Se crea automáticamente una nueva columna con el resultado de la detección. La API `classifyColumns()` devuelve un mapa donde las claves son los nombres de las columnas y los valores son una lista de los tipos de entidades detectadas. `SampleFraction` indica la fracción de los datos que deben cumplirse para que una columna se identifique en busca de entidades de PII, mientras que `ThresholdFraction` indica la fracción de los datos que deben cumplirse para que una columna se identifique como datos de PII.

Detección a nivel de fila

En el ejemplo, el trabajo consiste en realizar las siguientes acciones mediante las API `detect()` y `classifyColumns()`:

- leer datos de un bucket de Amazon S3 y convertirlos en un DynamicFrame
- detectar instancias “Email” (Correo electrónico) y “Credit Card” (Tarjeta de crédito) en el dynamicFrame
- devolver un dynamicFrame con los valores originales más una columna que incluye el resultado de la detección para cada fila
- escribir el DynamicFrame devuelto en otra ruta de Amazon S3

```
 import com.amazonaws.services.glue.GlueContext
 import com.amazonaws.services.glue.MappingSpec
 import com.amazonaws.services.glue.errors.CallSite
 import com.amazonaws.services.glue.util.GlueArgParser
 import com.amazonaws.services.glue.util.Job
 import com.amazonaws.services.glue.util.JsonOptions
 import org.apache.spark.SparkContext
 import scala.collection.JavaConverters._
 import com.amazonaws.services.glue.ml.EntityDetector

 object GlueApp {
   def main(sysArgs: Array[String]) {
     val spark: SparkContext = new SparkContext()
     val glueContext: GlueContext = new GlueContext(spark)
     val args = GlueArgParser.getResolvedOptions(sysArgs, Seq("JOB_NAME").toArray)
     Job.init(args("JOB_NAME"), glueContext, args.asJava)
     val frame=
glueContext.getSourceWithFormat(formatOptions=JsonOptions("""{"quoteChar": "\"",
"withHeader": true, "separator": ","}"""), connectionType="s3", format="csv",
options=JsonOptions("""{"paths": ["s3://pathToSource"], "recurse": true}"""),
transformationContext="AmazonS3_node1650160158526").getDynamicFrame()

     val frameWithDetectedPII = EntityDetector.detect(frame, Seq("EMAIL",
"CREDIT_CARD"))

     glueContext.getSinkWithFormat(connectionType="s3",
options=JsonOptions("""{"path": "s3://pathToOutput/", "partitionKeys": []}"""),
```

```
transformationContext="someCtx",
format="json").writeDynamicFrame(frameWithDetectedPII)

     Job.commit()
   }
 }
```

Detección a nivel de fila con acciones detalladas

En el ejemplo, el trabajo consiste en realizar las siguientes acciones mediante las API de `detect()`:

- leer datos de un bucket de Amazon S3 y convertirlos en un dynamicFrame
- detectar tipos de datos confidenciales para “USA_PTIN”, “BANK_ACCOUNT”, “USA_SSN”, “USA_PASSPORT_NUMBER” y “PHONE_NUMBER” en el dynamicFrame
- devolver un dynamicFrame con los valores modificados enmascarados más una columna que incluye el resultado de la detección para cada fila
- escribir el dynamicFrame devuelto en otra ruta de Amazon S3

A diferencia de la API `detect()` anterior, esta utiliza acciones detalladas para detectar los tipos de entidades. Para obtener más información, consulte Parámetros de detección para su uso de `detect()`.

```
import com.amazonaws.services.glue.GlueContext
import com.amazonaws.services.glue.MappingSpec
import com.amazonaws.services.glue.errors.CallSite
import com.amazonaws.services.glue.util.GlueArgParser
import com.amazonaws.services.glue.util.Job
import com.amazonaws.services.glue.util.JsonOptions
import org.apache.spark.SparkContext
import scala.collection.JavaConverters._
import com.amazonaws.services.glue.ml.EntityDetector

object GlueApp {
  def main(sysArgs: Array[String]) {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)
    val args = GlueArgParser.getResolvedOptions(sysArgs, Seq("JOB_NAME").toArray)
    Job.init(args("JOB_NAME"), glueContext, args.asJava)
    val frame =
 glueContext.getSourceWithFormat(formatOptions=JsonOptions("""{"quoteChar": "\"",
```

```
"withHeader": true, "separator": ","}"""), connectionType="s3", format="csv",
options=JsonOptions("""{"paths": ["s3://pathToSource"], "recurse": true}"""),
transformationContext="AmazonS3_node_source").getDynamicFrame()

   val detectionParameters = JsonOptions(
     """
       {
         "USA_DRIVING_LICENSE": [{
           "action": "PARTIAL_REDACT",
           "sourceColumns": ["Driving License"],
           "actionOptions": {
             "matchPattern": "[0-9]",
             "redactChar": "*"
           }
         }],
         "BANK_ACCOUNT": [{
           "action": "DETECT",
           "sourceColumns": ["*"]
         }],
         "USA_SSN": [{
           "action": "SHA256_HASH",
           "sourceColumns": ["SSN"]
         }],
         "IP_ADDRESS": [{
           "action": "REDACT",
           "sourceColumns": ["IP Address"],
           "actionOptions": {"redactText": "*****"}
         }],
         "PHONE_NUMBER": [{
           "action": "PARTIAL_REDACT",
           "sourceColumns": ["Phone Number"],
           "actionOptions": {
             "numLeftCharsToExclude": 1,
             "numRightCharsToExclude": 0,
             "redactChar": "*"
           }
         }]
       }
     """
   )

   val frameWithDetectedPII = EntityDetector.detect(frame, detectionParameters,
"DetectedEntities", "HIGH")
```

```
    glueContext.getSinkWithFormat(connectionType="s3", options=JsonOptions("""{"path":
 "s3://pathToOutput/", "partitionKeys": []}"""),
 transformationContext="AmazonS3_node_target",
 format="json").writeDynamicFrame(frameWithDetectedPII)

    Job.commit()
  }
}
```

Detección a nivel de columna

En el ejemplo, el trabajo consiste en realizar las siguientes acciones mediante las API de `classifyColumns()`:

- leer datos de un bucket de Amazon S3 y convertirlos en un dynamicFrame
- detectar instancias “Email” (Correo electrónico) y “Credit Card” (Tarjeta de crédito) en el dynamicFrame
- definir los parámetros para realizar una muestra del 100 % de la columna, marcar una entidad como detectada si se encuentra en el 10 % de las células y tener una sensibilidad “BAJA”
- devolver un mapa donde las claves son los nombres de las columnas y los valores son una lista de los tipos de entidades detectadas
- escribir el dynamicFrame devuelto en otra ruta de Amazon S3

```
import com.amazonaws.services.glue.GlueContext
import com.amazonaws.services.glue.MappingSpec
import com.amazonaws.services.glue.errors.CallSite
import com.amazonaws.services.glue.util.GlueArgParser
import com.amazonaws.services.glue.util.Job
import com.amazonaws.services.glue.util.JsonOptions
import org.apache.spark.SparkContext
import scala.collection.JavaConverters._
import com.amazonaws.services.glue.DynamicFrame
import com.amazonaws.services.glue.ml.EntityDetector

object GlueApp {
  def main(sysArgs: Array[String]) {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)
```

```
    val args = GlueArgParser.getResolvedOptions(sysArgs, Seq("JOB_NAME").toArray)
    Job.init(args("JOB_NAME"), glueContext, args.asJava)
    val frame =
 glueContext.getSourceWithFormat(formatOptions=JsonOptions("""{"quoteChar":
 "\"", "withHeader": true, "separator": ",", "optimizePerformance": false}"""),
 connectionType="s3", format="csv", options=JsonOptions("""{"paths": ["s3://
pathToSource"], "recurse": true}"""), transformationContext="frame").getDynamicFrame()

    import glueContext.sparkSession.implicits._

    val detectedDataFrame = EntityDetector.classifyColumns(
        frame,
        entityTypesToDetect = Seq("CREDIT_CARD", "PHONE_NUMBER"),
        sampleFraction = 1.0,
        thresholdFraction = 0.1,
        detectionSensitivity = "LOW"
    )
    val detectedDF = (detectedDataFrame).toSeq.toDF("columnName", "entityTypes")
    val DetectSensitiveData_node = DynamicFrame(detectedDF, glueContext)

    glueContext.getSinkWithFormat(connectionType="s3", options=JsonOptions("""{"path":
 "s3://pathToOutput", "partitionKeys": []}"""), transformationContext="someCtx",
 format="json").writeDynamicFrame(DetectSensitiveData_node)

    Job.commit()
  }
}
```

Detección de datos confidenciales mediante tipos de PII de CustomEntityType por AWS

Puede definir entidades personalizadas a través de AWS Studio. Sin embargo, para usar esta función fuera de AWS Studio, primero debe definir los tipos de entidad personalizados y, a continuación, agregar los tipos de entidades personalizados definidos a la lista de `entityTypesToDetect`.

Si tiene tipos de datos confidenciales específicos en sus datos (como “Employee ID” [ID de empleado]), puede crear entidades personalizadas si llama a la API `CreateCustomEntityType()`. El siguiente ejemplo define el tipo de entidad personalizado “EMPLOYEE_ID” (Id de empleado) para la API `CreateCustomEntityType()` con los parámetros de solicitud:

```
{
    "name": "EMPLOYEE_ID",
    "regexString": "\d{4}-\d{3}",
    "contextWords": ["employee"]
}
```

A continuación, modifique el trabajo para usar el nuevo tipo de datos confidenciales personalizado al agregar el tipo de entidad personalizado (EMPLOYEE_ID) a la API `EntityDetector()`:

```
import com.amazonaws.services.glue.GlueContext
import com.amazonaws.services.glue.MappingSpec
import com.amazonaws.services.glue.errors.CallSite
import com.amazonaws.services.glue.util.GlueArgParser
import com.amazonaws.services.glue.util.Job
import com.amazonaws.services.glue.util.JsonOptions
import org.apache.spark.SparkContext
import scala.collection.JavaConverters._
import com.amazonaws.services.glue.ml.EntityDetector

object GlueApp {
  def main(sysArgs: Array[String]) {
    val spark: SparkContext = new SparkContext()
    val glueContext: GlueContext = new GlueContext(spark)
    val args = GlueArgParser.getResolvedOptions(sysArgs, Seq("JOB_NAME").toArray)
    Job.init(args("JOB_NAME"), glueContext, args.asJava)
    val frame=
glueContext.getSourceWithFormat(formatOptions=JsonOptions("""{"quoteChar": "\"",
"withHeader": true, "separator": ","}"""), connectionType="s3", format="csv",
options=JsonOptions("""{"paths": ["s3://pathToSource"], "recurse": true}"""),
transformationContext="AmazonS3_node1650160158526").getDynamicFrame()

    val frameWithDetectedPII = EntityDetector.detect(frame, Seq("EMAIL",
"CREDIT_CARD", "EMPLOYEE_ID"))

    glueContext.getSinkWithFormat(connectionType="s3",
options=JsonOptions("""{"path": "s3://pathToOutput/", "partitionKeys": []}"""),
transformationContext="someCtx",
format="json").writeDynamicFrame(frameWithDetectedPII)

    Job.commit()
```

```
    }
  }
```

> **Note**
>
> Si se define un tipo de datos confidenciales personalizado con el mismo nombre que un tipo de entidad gestionada existente, el tipo de datos confidenciales personalizado tendrá prioridad y sobrescribirá la lógica del tipo de entidad gestionada.

Parámetros de detección para su uso de **`detect()`**

Este método se utiliza para detectar entidades en un DynamicFrame. Devuelve un nuevo DataFrame con los valores originales y una columna adicional outputColumnName que tiene metadatos de detección de PII. El enmascaramiento personalizado se puede realizar después de que se devuelva este DynamicFrame en el script de AWS Glue o, en su lugar, se puede usar la API detect() con acciones detalladas.

```
detect(frame: DynamicFrame,
       entityTypesToDetect: Seq[String],
       outputColumnName: String = "DetectedEntities",
       detectionSensitivity: String = "LOW"): DynamicFrame
```

Parámetros:

- frame – (tipo: `DynamicFrame`): el DynamicFrame de entrada que contiene los datos que se van a procesar.
- entityTypesToDetect – (tipo: `[Seq[String]`): lista de tipos de entidades que se van a detectar. Pueden ser tipos de entidad administrados o tipos de entidad personalizados.
- outputColumnName – (tipo: `String`, predeterminado: “DetectedEntities”): el nombre de la columna en la que se almacenarán las entidades detectadas. Si no se proporciona, el nombre de columna predeterminado es “DetectedEntities”.
- detectionSensitivity – (tipo: `String`, opciones: “LOW” o “HIGH”, predeterminado: “LOW”): especifica la sensibilidad del proceso de detección. Las opciones válidas son “BAJA” o “ALTA”. Si no se proporciona, la sensibilidad predeterminada se establece en “LOW”.

Configuración de `outputColumnName`:

El nombre de la columna en la que se van a almacenar las entidades detectadas. Si no se proporciona, el nombre de columna predeterminado es “DetectedEntities”. Para cada fila de la columna de salida, la columna complementaria incluye un mapa del nombre de la columna con los metadatos de la entidad detectada con los siguientes pares clave-valor:

- entityType: el tipo de entidad detectada.
- start: la posición inicial de la entidad detectada en los datos originales.
- final: la posición final de la entidad detectada en los datos originales.
- actionUsed: la acción realizada en la entidad detectada (por ejemplo, "DETECT", "REDACT", "PARTIAL_REDACT", "SHA256_HASH").

Ejemplo:

```
{
   "DetectedEntities":{
      "SSN Col":[
         {
            "entityType":"USA_SSN",
            "actionUsed":"DETECT",
            "start":4,
            "end":15
         }
      ],
      "Random Data col":[
         {
            "entityType":"BANK_ACCOUNT",
            "actionUsed":"PARTIAL_REDACT",
            "start":4,
            "end":13
         },
         {
            "entityType":"IP_ADDRESS",
            "actionUsed":"REDACT",
            "start":4,
            "end":13
         }
      ]
   }
}
```

Parámetros de detección para **`detect()`** con acciones detalladas

Este método se utiliza para detectar entidades en un DynamicFrame mediante parámetros específicos. Devuelve un nuevo DataFrame con los valores originales reemplazados por datos confidenciales enmascarados y un `outputColumnName` de columna adicional que tiene metadatos de detección de PII.

```
detect(frame: DynamicFrame,
       detectionParameters: JsonOptions,
       outputColumnName: String = "DetectedEntities",
       detectionSensitivity: String = "LOW"): DynamicFrame
```

Parámetros:

- frame - (tipo: `DynamicFrame`): el DynamicFrame de entrada que contiene los datos que se van a procesar.
- detectionParameters – (tipo: `JsonOptions`): opciones de JSON que especifican los parámetros del proceso de detección.
- outputColumnName – (tipo: `String`, predeterminado: “DetectedEntities”): el nombre de la columna en la que se almacenarán las entidades detectadas. Si no se proporciona, el nombre de columna predeterminado es “DetectedEntities”.
- detectionSensitivity – (tipo: `String`, opciones: "LOW" o "HIGH", predeterminado: “LOW”): especifica la sensibilidad del proceso de detección. Las opciones válidas son “BAJA” o “ALTA”. Si no se proporciona, la sensibilidad predeterminada se establece en “BAJA”.

`detectionParameters`Configuración de

Si no se incluye ninguna configuración, se utilizarán los valores predeterminados.

- action – (tipo: `String`, opciones: "DETECT", "REDACT", "PARTIAL_REDACT", "SHA256_HASH"): especifica la acción que se va a realizar en la entidad. Obligatorio. Tenga en cuenta que las acciones que enmascaran (todas excepto “DETECT”) solo pueden realizar una acción por columna. Se trata de una medida preventiva para enmascarar las entidades fusionadas.

- sourceColumns – (tipo: `List[String]`, predeterminado: [“*”]): lista de nombres de columnas de origen para realizar la detección de la entidad. El valor predeterminados es [“*”] si no está presente Eleva `IllegalArgumentException` si se utiliza un nombre de columna no válido.
- sourceColumnsToExclude – (tipo: `List[String]`): lista de nombres de columnas de origen para realizar la detección de la entidad. Utilice una de las dos opciones: `sourceColumns` o `sourceColumnsToExclude`. Eleva `IllegalArgumentException` si se utiliza un nombre de columna no válido.
- actionOptions: opciones adicionales basadas en la acción especificada:
  - Para "DETECT" y "SHA256_HASH", no se permiten opciones.
  - Para "REDACT":
    - redactText – (tipo: `String`, predeterminado: “*****”): texto que reemplaza a la entidad detectada.
  - Para “PARTIAL_REDACT”:
    - redactChar – (tipo: `String`, predeterminado: “*”): carácter que reemplaza a todos los caracteres detectados en la entidad.
    - matchPattern – (tipo: `String`): patrón de expresiones regulares para redacción parcial. No se puede combinar con numLeftCharsToExclude o `numRightCharsToExclude`.
    - numLeftCharsToExclude – (tipo: `String, integer`): número de caracteres de la izquierda que se van a excluir. No se puede combinar con matchPattern, pero se puede usar con `numRightCharsToExclude`.
    - numRightCharsToExclude – (tipo: `String, integer`): número de caracteres de la derecha que se van a excluir. No se puede combinar con matchPattern, pero se puede usar con `numRightCharsToExclude`.

`outputColumnName`Configuración de

Consulte la configuración de outputColumnName

Parámetros de detección para **`classifyColumns()`**

Este método se utiliza para detectar entidades en un DynamicFrame. Devuelve un mapa donde las claves son los nombres de las columnas y los valores son una lista de los tipos de entidades detectadas. El enmascaramiento personalizado se puede realizar una vez que se devuelva en el script de AWS Glue.

```
classifyColumns(frame: DynamicFrame,
```

```
                entityTypesToDetect: Seq[String],
                sampleFraction: Double = 0.1,
                thresholdFraction: Double = 0.1,
                detectionSensitivity: String = "LOW")
```

Parámetros:

- frame – (tipo: `DynamicFrame`): el DynamicFrame de entrada que contiene los datos que se van a procesar.
- entityTypesToDetect – (tipo: `Seq[String]`): lista de tipos de entidades que se van a detectar. Pueden ser tipos de entidad administrados o tipos de entidad personalizados.
- sampleFraction – (tipo: `Double`, predeterminado: 10 %): la fracción de los datos de los que se realizará una muestra al buscar entidades de PII.
- thresholdFraction – (tipo:`Double`, predeterminado: 10 %): la fracción de los datos que deben cumplirse para que una columna se identifique como datos de PII.
- detectionSensitivity – (tipo: `String`, opciones: “LOW” o “HIGH”, predeterminado: “LOW”): especifica la sensibilidad del proceso de detección. Las opciones válidas son “BAJA” o “ALTA”. Si no se proporciona, la sensibilidad predeterminada se establece en “BAJA”.

Tipos de datos confidenciales administrados

Entidades globales

Tipo de datos	Categoría	Descripción
PERSON_NAME	Universal	El nombre de la persona.
EMAIL	Personal	La dirección de correo electrónico.
IP_ADDRESS	Computer	La dirección IP
MAC_ADDRESS	Personal	La dirección MAC.

Tipos de datos para EE. UU

Tipo de datos	Descripción
BANK_ACCOUNT	El número de cuenta bancaria. No es específico de un país o región, sin embargo, solo se detectan los formatos de cuenta de EE. UU. y Canadá.
CREDIT_CARD	El número de tarjeta de crédito.
PHONE_NUMBER	El número de teléfono. No es específico de un país o región, sin embargo, en este momento solo se detectan números de teléfono de EE. UU. y Canadá.
USA_ATIN	El número de identificación fiscal de adopción de EE. UU. emitido por el Servicio de Impuestos Internos.
USA_CPT_CODE	El código CPT (específico para EE. UU.).
USA_DEA_NUMBER	El número DEA (específico para EE. UU.).
USA_DRIVING_LICENSE	El número de licencia de conducir (específico para EE. UU).
USA_HCPCS_CODE	El código HCPCS (específico para EE. UU.).
USA_HEALTH_INSURANCE_CLAIM_NUMBER	Número de reclamación del seguro médico (específico para EE. UU.).
USA_ITIN	El ITIN (para ciudadanos o entidades de EE. UU.).
USA_MEDICARE_BENEFICIARY_IDENTIFIER	Identificador de beneficiario de Medicare (específico para EE. UU.).
USA_NATIONAL_DRUG_CODE	El código NDC (específico para EE. UU.).

Tipo de datos	Descripción
USA_NATIONAL_PROVIDER_IDENTIFIER	El número de identificación nacional del proveedor (específico para EE. UU.).
USA_PASSPORT_NUMBER	El número de pasaporte (para ciudadanos estadounidenses).
USA_PTIN	El número de identificación fiscal del preparado r de impuestos estadounidense emitido por el Servicio de Impuestos Internos.
USA_SSN	El número de seguro social (para ciudadanos estadounidenses).

Tipos de datos de Argentina

Tipo de datos	Descripción
ARGENTINA_TAX_IDENTIFICATIO N_NUMBER	Número de identificación fiscal de Argentina. También conocido como CUIT o CUIL.

Tipos de datos australianos

Tipo de datos	Descripción
AUSTRALIA_BUSINESS_NUMBER	Número comercial de Australia (ABN). Un identificador único emitido por el Registro Comercial de Australia (ABR) para identificar a las empresas ante el Gobierno y la comunidad.
AUSTRALIA_COMPANY_NUMBER	Número de empresa de Australia (ACN). Identificador único emitido por la Comisión Australiana de Valores e Inversiones.

Tipo de datos	Descripción
AUSTRALIA_DRIVING_LICENSE	Un número de licencia para conductores de Australia.
AUSTRALIA_MEDICARE_NUMBER	Número de Medicare australiano. Identificador personal emitido por la Comisión de Seguros de Salud australiano.
AUSTRALIA_PASSPORT_NUMBER	Número de pasaporte australiano.
AUSTRALIA_TAX_FILE_NUMBER	Número de registro fiscal de Australia (TFN). Emitido por la Oficina de Impuestos de Australia (ATO) a los contribuyentes (individu os, empresas, etc.) para transacciones fiscales.

Tipos de datos de Austria

Tipo de datos	Descripción
AUSTRIA_DRIVING_LICENSE	El número de licencia de conducir (específico para Austria).
AUSTRIA_PASSPORT_NUMBER	El número de pasaporte (específico para Austria).
AUSTRIA_SSN	El número de seguro social (para ciudadanos de Austria).
AUSTRIA_TAX_IDENTIFICATION_NUMBER	Número de identificación fiscal (específico para Austria).
AUSTRIA_VALUE_ADDED_TAX	Impuesto al valor agregado (específico para Austria).

Tipos de datos de los Balcanes

Tipo de datos	Descripción
BOSNIA_UNIQUE_MASTER_CITIZEN_NUMBER	Número único de ciudadano maestro (JMBG) para los ciudadanos de Bosnia-Herzegovina.
KOSOVO_UNIQUE_MASTER_CITIZEN_NUMBER	Número único de ciudadano maestro (JMBG) de Kosovo.
MACEDONIA_UNIQUE_MASTER_CITIZEN_NUMBER	Número único de ciudadano mayor de Macedonia.
MONTENEGRO_UNIQUE_MASTER_CITIZEN_NUMBER	Número único de ciudadano maestro (JMBG) de Montenegro.
SERBIA_UNIQUE_MASTER_CITIZEN_NUMBER	Número único de ciudadano maestro (JMBG) de Serbia.
SERBIA_VALUE_ADDED_TAX	Impuesto sobre el valor agregado (específico para Serbia).
VOJVODINA_UNIQUE_MASTER_CITIZEN_NUMBER	Número único de ciudadano maestro (JMBG) para Voivodina.

Tipos de datos de Bélgica

Tipo de datos	Descripción
BELGIUM_DRIVING_LICENSE	El número de licencia de conducir (específico para Bélgica).
BELGIUM_NATIONAL_IDENTIFICATION_NUMBER	El número nacional belga (BNN).
BELGIUM_PASSPORT_NUMBER	El número de pasaporte (específico para Bélgica).
BELGIUM_TAX_IDENTIFICATION_NUMBER	Número de identificación fiscal (específico para Bélgica).

Tipo de datos	Descripción
BELGIUM_VALUE_ADDED_TAX	Impuesto sobre el valor agregado (específico para Bélgica).

Tipos de datos de Brasil

Tipo de datos	Descripción
BRAZIL_BANK_ACCOUNT	El número de cuenta bancaria (específico para Brasil).
BRAZIL_NATIONAL_IDENTIFICATION_NUMBER	El identificador nacional (específico para Brasil).
BRAZIL_NATIONAL_REGISTRY_OF_LEGAL_ENTITIES_NUMBER	El número de identificación emitido a las empresas (específico de Brasil), también conocido como CNPJ.
BRAZIL_NATURAL_PERSON_REGISTRY_NUMBER	Número de registro de persona física, también conocido como CPF.

Tipos de datos de Bulgaria

Tipo de datos	Descripción
BULGARIA_DRIVING_LICENSE	El número de licencia de conducir (específico para Bulgaria).
BULGARIA_UNIFORM_CIVIL_NUMBER	Número civil unificado (EGN) que sirve como número de identificación nacional.
BULGARIA_VALUE_ADDED_TAX	Impuesto sobre el valor agregado (específico para Bulgaria).

Tipos de datos de Canadá

Tipo de datos	Descripción
CANADA_DRIVING_LICENSE	El número de licencia de conducir (específico para Canadá).
CANADA_GOVERNMENT_IDENTIFICATION_CARD_NUMBER	El identificador nacional (específico para Canadá).
CANADA_PASSPORT_NUMBER	El número de pasaporte (específico para Canadá).
CANADA_PERMANENT_RESIDENCE_NUMBER	Número de residencia permanente (número de tarjeta PR).
CANADA_PERSONAL_HEALTH_NUMBER	El identificador único de la asistencia sanitaria (número PHN).
CANADA_SOCIAL_INSURANCE_NUMBER	El número de seguro social (SIN) en Canadá.

Tipos de datos de Chile

Tipo de datos	Descripción
CHILE_DRIVING_LICENSE	El número de licencia de conducir (específico para Chile).
CHILE_NATIONAL_IDENTIFICATION_NUMBER	El identificador nacional de Chile, también conocido como RUT o RUN.

Tipos de datos de China, Hong Kong, Macao y Taiwán

Tipo de datos	Descripción
CHINA_IDENTIFICATION	El identificador de China.
CHINA_LICENSE_PLATE_NUMBER	El número de licencia de conducir (específico para China).

Tipo de datos	Descripción
CHINA_MAINLAND_TRAVEL_PERMIT_ID_HONG_KONG_MACAU	El permiso de viaje a China continental para residentes de Hong Kong y Macao.
CHINA_MAINLAND_TRAVEL_PERMIT_ID_TAIWAN	El permiso de viaje a China continental para residentes de Taiwán emitido por el Gobierno de la República Popular China (PRC).
CHINA_PASSPORT_NUMBER	El número de pasaporte (específico para China).
CHINA_PHONE_NUMBER	El número de teléfono (específico para China)
HONG_KONG_IDENTITY_CARD	El documento de identidad oficial emitido por el Departamento de Inmigración de Hong Kong.
MACAU_RESIDENT_IDENTITY_CARD	La tarjeta de identidad de residente de Macao o BIR es una tarjeta de identidad oficial emitida por la Oficina de Servicios de Identificación de Macao.
TAIWAN_NATIONAL_IDENTIFICATION_NUMBER	El identificador nacional (específico para Taiwán).
TAIWAN_PASSPORT_NUMBER	El número de pasaporte (específico para Taiwán).

Tipos de datos de Colombia

Tipo de datos	Descripción
COLOMBIA_PERSONAL_IDENTIFICATION_NUMBER	Identificador único asignado a los colombianos al nacer.
COLOMBIA_TAX_IDENTIFICATION_NUMBER	Número de identificación fiscal (específico para Colombia).

Tipos de datos de Croacia

Tipo de datos	Descripción
CROATIA_DRIVING_LICENSE	El número de licencia de conducir (específico para Croacia).
CROATIA_IDENTITY_NUMBER	El identificador nacional (específico para Croacia).
CROATIA_PASSPORT_NUMBER	El número de pasaporte (específico para Croacia).
CROATIA_PERSONAL_IDENTIFICATION_NUMBER	El número de identificación personal (OIB).

Tipos de datos de Chipre

Tipo de datos	Descripción
CYPRUS_DRIVING_LICENSE	El número de licencia de conducir (específico para Cyprus).
CYPRUS_NATIONAL_IDENTIFICATION_NUMBER	El carné de identidad chipriota.
CYPRUS_PASSPORT_NUMBER	El número de pasaporte (específico para Chipre).
CYPRUS_TAX_IDENTIFICATION_NUMBER	Número de identificación fiscal (específico para Chipre).
CYPRUS_VALUE_ADDED_TAX	Impuesto sobre el valor agregado (específico para Chipre).

Tipos de datos de Chequia

Tipo de datos	Descripción
CZECHIA_DRIVING_LICENSE	El número de licencia de conducir (específico para Chequia).
CZECHIA_PERSONAL_IDENTIFICATION_NUMBER	El número de identificación personal (específico para Chequia).
CZECHIA_VALUE_ADDED_TAX	Impuesto sobre el valor agregado (específico para Chequia).

Tipos de datos de Dinamarca

Tipo de datos	Descripción
DENMARK_DRIVING_LICENSE	El número de licencia de conducir (específico para Dinamarca).
DENMARK_PERSONAL_IDENTIFICATION_NUMBER	El número de identificación personal (específico para Dinamarca).
DENMARK_TAX_IDENTIFICATION_NUMBER	Número de identificación fiscal (específico para Dinamarca).
DENMARK_VALUE_ADDED_TAX	Impuesto sobre el valor agregado (específico para Dinamarca).

Tipos de datos de Estonia

Tipo de datos	Descripción
ESTONIA_DRIVING_LICENSE	El número de licencia de conducir (específico para Estonia).
ESTONIA_PASSPORT_NUMBER	El número de pasaporte (específico para Estonia).

Tipo de datos	Descripción
ESTONIA_PERSONAL_IDENTIFICATION_CODE	El número de identificación personal (específico para Estonia).
ESTONIA_VALUE_ADDED_TAX	Impuesto sobre el valor agregado (específico para Estonia).

Tipos de datos de Finlandia

Tipo de datos	Descripción
FINLAND_DRIVING_LICENSE	El número de licencia de conducir (específico para Finlandia).
FINLAND_HEALTH_INSURANCE_NUMBER	El número de seguro médico (específico para Finlandia).
FINLAND_NATIONAL_IDENTIFICATION_NUMBER	El número de identificación nacional (específico para Finlandia).
FINLAND_PASSPORT_NUMBER	El número de pasaporte (específico para Finlandia).
FINLAND_VALUE_ADDED_TAX	Impuesto sobre el valor agregado (específico para Finlandia).

Tipos de datos de Francia

Tipo de datos	Descripción
FRANCE_BANK_ACCOUNT	El número de cuenta bancaria (específico para Francia).
FRANCE_DRIVING_LICENSE	El número de licencia de conducir (específico para Francia).

Tipo de datos	Descripción
FRANCE_HEALTH_INSURANCE_NUMBER	Número de seguro médico de Francia.
FRANCE_INSEE_CODE	Número de seguridad social, SSN o NIR de Francia.
FRANCE_NATIONAL_IDENTIFICATION_NUMBER	Número de identificación nacional (CNI) de Francia.
FRANCE_PASSPORT_NUMBER	El número de pasaporte (específico para Francia).
FRANCE_TAX_IDENTIFICATION_NUMBER	Número de identificación fiscal (específico para Francia).
FRANCE_VALUE_ADDED_TAX	Impuesto sobre el valor agregado (específico para Francia).

Tipos de datos de Alemania

Tipo de datos	Descripción
GERMANY_BANK_ACCOUNT	El número de cuenta bancaria (específico para Alemania)
GERMANY_DRIVING_LICENSE	El número de licencia de conducir (específico para Alemania).
GERMANY_PASSPORT_NUMBER	El número de pasaporte (específico para Alemania).
GERMANY_PERSONAL_IDENTIFICATION_NUMBER	El número de identificación personal (específico para Alemania).
GERMANY_TAX_IDENTIFICATION_NUMBER	Número de identificación fiscal (específico para Alemania).

Tipo de datos	Descripción
GERMANY_VALUE_ADDED_TAX	Impuesto sobre el valor agregado (específico para Alemania).

Tipos de datos de Grecia

Tipo de datos	Descripción
GREECE_DRIVING_LICENSE	El número de licencia de conducir (específico para Grecia).
GREECE_PASSPORT_NUMBER	El número de pasaporte (específico para Grecia).
GREECE_SSN	El número de seguro social (para ciudadanos de Grecia).
GREECE_TAX_IDENTIFICATION_NUMBER	Número de identificación fiscal (específico para Grecia).
GREECE_VALUE_ADDED_TAX	Impuesto sobre el valor agregado (específico para Grecia).

Tipos de datos de Hungría

Tipo de datos	Descripción
HUNGARY_DRIVING_LICENSE	El número de licencia de conducir (específico para Hungría).
HUNGARY_PASSPORT_NUMBER	El número de pasaporte (específico para Hungría).
HUNGARY_SSN	El número de seguro social (para ciudadanos húngaros).

Tipo de datos	Descripción
HUNGARY_TAX_IDENTIFICATION_NUMBER	Número de identificación fiscal (específico para Hungría).
HUNGARY_VALUE_ADDED_TAX	Impuesto sobre el valor agregado (específico para Hungría).

Tipos de datos de Islandia

Tipo de datos	Descripción
ICELAND_NATIONAL_IDENTIFICATION_NUMBER	El identificador nacional (específico para Islandia).
ICELAND_PASSPORT_NUMBER	El número de pasaporte (específico para Islandia).
ICELAND_VALUE_ADDED_TAX	Impuesto sobre el valor agregado (específico para Islandia).

Tipos de datos de India

Tipo de datos	Descripción
INDIA_AADHAAR_NUMBER	Número de identificación de Aadhaar emitido por la Autoridad de Identificación Única de la India.
INDIA_PERMANENT_ACCOUNT_NUMBER	Número de cuenta permanente de la India (PAN).

Tipos de datos de Indonesia

Tipo de datos	Descripción
INDONESIA_IDENTITY_CARD_NUMBER	El identificador nacional (específico para Indonesia).

Tipos de datos de Irlanda

Tipo de datos	Descripción
IRELAND_DRIVING_LICENSE	El número de licencia de conducir (específico para Irlanda).
IRELAND_PASSPORT_NUMBER	El número de pasaporte (específico para Irlanda).
IRELAND_PERSONAL_PUBLIC_SERVICE_NUMBER	Número de servicio público personal (PPS) de Irlanda.
IRELAND_TAX_IDENTIFICATION_NUMBER	Número de identificación fiscal (específico para Irlanda).
IRELAND_VALUE_ADDED_TAX	Impuesto sobre el valor agregado (específico para Irlanda).

Tipos de datos de Israel

Tipo de datos	Descripción
ISRAEL_IDENTIFICATION_NUMBER	El identificador nacional (específico para Israel).

Tipos de datos de Italia

Tipo de datos	Descripción
ITALY_BANK_ACCOUNT	El número de cuenta bancaria (específico para Italia).
ITALY_DRIVING_LICENSE	El número de licencia de conducir (específico para Italia).
ITALY_FISCAL_CODE	El número identificador, también conocido como Codice Fiscale italiano.
ITALY_PASSPORT_NUMBER	El número de pasaporte (específico para Italia).
ITALY_VALUE_ADDED_TAX	Impuesto sobre el valor agregado (específico para Italia).

Tipos de datos de Japón

Tipo de datos	Descripción
JAPAN_BANK_ACCOUNT	Cuenta bancaria en Japón.
JAPAN_DRIVING_LICENSE	Un número de licencia de conducir de Japón.
JAPAN_MY_NUMBER	El identificador único para los ciudadanos o corporaciones de Japón utilizado para la administración tributaria, la administración de la seguridad social y la respuesta ante desastres
JAPAN_PASSPORT_NUMBER	Número de pasaporte de Japón.

Tipos de datos de Corea

Tipo de datos	Descripción
KOREA_PASSPORT_NUMBER	El número de pasaporte (específico para Corea).

Tipo de datos	Descripción
KOREA_RESIDENCE_REGISTRATION_NUMBER_FOR_CITIZENS	Número de registro de residencia en Corea para residentes.
KOREA_RESIDENCE_REGISTRATION_NUMBER_FOR_FOREIGNERS	Número de registro de residencia en Corea para extranjeros.

Tipos de datos de Letonia

Tipo de datos	Descripción
LATVIA_DRIVING_LICENSE	El número de licencia de conducir (específico para Letonia).
LATVIA_PASSPORT_NUMBER	El número de pasaporte (específico para Letonia).
LATVIA_PERSONAL_IDENTIFICATION_NUMBER	El número de identificación personal (específico para Letonia).
LATVIA_VALUE_ADDED_TAX	Impuesto sobre el valor agregado (específico para Letonia).

Tipos de datos de Liechtenstein

Tipo de datos	Descripción
LIECHTENSTEIN_NATIONAL_IDENTIFICATION_NUMBER	El identificador nacional (específico para Liechtenstein).
LIECHTENSTEIN_PASSPORT_NUMBER	El número de pasaporte (específico para Liechtenstein).
LIECHTENSTEIN_TAX_IDENTIFICATION_NUMBER	Número de identificación fiscal (específico para Liechtenstein).

Tipos de datos de Lituania

Tipo de datos	Descripción
LITUANIA_DRIVING_LICENSE	El número de licencia de conducir (específico para Lituania).
LITHUANIA_PERSONAL_IDENTIFICATION_NUMBER	El número de identificación personal (específico para Lituania).
LITUANIA_TAX_IDENTIFICATION_NUMBER	Número de identificación fiscal (específico para Lituania).
LITHUANIA_VALUE_ADDED_TAX	Impuesto sobre el valor agregado (específico para Lituania).

Tipos de datos de Luxemburgo

Tipo de datos	Descripción
LUXEMBOURG_DRIVING_LICENSE	El número de licencia de conducir (específico para Luxemburgo).
LUXEMBOURG_NATIONAL_INDIVIDUAL_NUMBER	El identificador nacional (específico para Luxemburgo).
LUXEMBOURG_PASSPORT_NUMBER	El número de pasaporte (específico para Luxemburgo).
LUXEMBOURG_TAX_IDENTIFICATION_NUMBER	Número de identificación fiscal (específico para Luxemburgo).
LUXEMBOURG_VALUE_ADDED_TAX	Impuesto sobre el valor agregado (específico para Luxemburgo).

Tipos de datos de Malasia

Tipo de datos	Descripción
MALASIA_MYKAD_NUMBER	El identificador nacional (específico para Malasia).
MALAYSIA_PASSPORT_NUMBER	El número de pasaporte (específico para Malasia).

Tipos de datos de Malta

Tipo de datos	Descripción
MALTA_DRIVING_LICENSE	El número de licencia de conducir (específico para Malta).
MALTA_NATIONAL_IDENTIFICATION_NUMBER	El identificador nacional (específico para Malta).
MALTA_TAX_IDENTIFICATION_NUMBER	Número de identificación fiscal (específico para Malta).
MALTA_VALUE_ADDED_TAX	Impuesto sobre el valor agregado (específico para Malta).

Tipos de datos de México

Tipo de datos	Descripción
MEXICO_CLABE_NUMBER	Número de banco (CLABE (Clave Bancaria Estandarizada) de México).
MEXICO_DRIVING_LICENSE	El número de licencia de conducir (específico para México).
MEXICO_PASSPORT_NUMBER	El número de pasaporte (específico para México).

Tipo de datos	Descripción
MEXICO_TAX_IDENTIFICATION_NUMBER	Número de identificación fiscal (específico para México).
MEXICO_UNIQUE_POPULATION_REGISTRY_CODE	La Clave Única de Registro de Población (CURP) es el código de identidad único de México.

Tipos de datos de los Países Bajos

Tipo de datos	Descripción
NETHERLANDS_CITIZEN_SERVICE_NUMBER	Número de ciudadano neerlandés (BSN, burgerservicenummer).
NETHERLANDS_DRIVING_LICENSE	El número de licencia de conducir (específico para los Países Bajos).
NETHERLANDS_PASSPORT_NUMBER	El número de pasaporte (específico para los Países Bajos).
NETHERLANDS_TAX_IDENTIFICATION_NUMBER	Número de identificación fiscal (específico para los Países Bajos).
NETHERLANDS_VALUE_ADDED_TAX	Impuesto sobre el valor agregado (específico para los Países Bajos).
NETHERLANDS_BANK_ACCOUNT	El número de cuenta bancaria (específico para los Países Bajos)

Tipos de datos de Nueva Zelanda

Tipo de datos	Descripción
NEW_ZEALAND_DRIVING_LICENSE	El número de licencia de conducir (específico para Nueva Zelanda).

Tipo de datos	Descripción
NEW_ZEALAND_NATIONAL_HEALTH_INDEX_NUMBER	Número del índice nacional de salud de Nueva Zelanda.
NEW_ZEALAND_TAX_IDENTIFICATION_NUMBER	Número de identificación fiscal, también conocido como número de impuestos internos (específico para Nueva Zelanda).

Tipos de datos de Noruega

Tipo de datos	Descripción
NORWAY_BIRTH_NUMBER	Número de identidad nacional noruego.
NORWAY_DRIVING_LICENSE	El número de licencia de conducir (específico para Noruega).
NORWAY_HEALTH_INSURANCE_NUMBER	Número de seguro médico noruego.
NORWAY_NATIONAL_IDENTIFICATION_NUMBER	El número de identificación nacional (específico para Noruega).
NORWAY_VALUE_ADDED_TAX	Impuesto sobre el valor agregado (específico para Noruega).

Tipos de datos de Filipinas

Tipo de datos	Descripción
PHILIPPINES_DRIVING_LICENSE	El número de licencia de conducir (específico para Filipinas).
PHILIPPINES_PASSPORT_NUMBER	El número de pasaporte (específico para Filipinas).

Tipos de datos de Polonia

Tipo de datos	Descripción
POLAND_DRIVING_LICENSE	El número de licencia de conducir (específico para Polonia).
POLAND_IDENTIFICATION_NUMBER	El identificador del Polonia.
POLAND_PASSPORT_NUMBER	El número de pasaporte (específico para Polonia).
POLAND_REGON_NUMBER	El número identificador de REGON, también conocido como número de identificación estadística.
POLAND_SSN	El número de seguro social (para ciudadanos de Polonia).
POLAND_TAX_IDENTIFICATION_NUMBER	Número de identificación fiscal (específico para Polonia).
POLAND_VALUE_ADDED_TAX	Impuesto sobre el valor agregado (específico para Polonia).

Tipos de datos de Portugal

Tipo de datos	Descripción
PORTUGAL_DRIVING_LICENSE	El número de licencia de conducir (específico para Portugal).
PORTUGAL_NATIONAL_IDENTIFIC ATION_NUMBER	El número de identificación nacional del proveedor (específico para Portugal).
PORTUGAL_PASSPORT_NUMBER	El número de pasaporte (específico para Portugal).
PORTUGAL_TAX_IDENTIFICATION_NUMBER	Número de identificación fiscal (específico para Portugal).

Tipo de datos	Descripción
PORTUGAL_VALUE_ADDED_TAX	Impuesto sobre el valor agregado (específico para Portugal).

Tipos de datos de Rumanía

Tipo de datos	Descripción
ROMANIA_DRIVING_LICENSE	El número de licencia de conducir (específico para Rumanía).
ROMANIA_NUMERICAL_PERSONAL_CODE	El número de identificación personal (específi co para Rumanía).
ROMANIA_PASSPORT_NUMBER	El número de pasaporte (específico para Rumanía).
ROMANIA_VALUE_ADDED_TAX	Impuesto sobre el valor agregado (específico para Rumanía).

Tipos de datos de Singapur

Tipo de datos	Descripción
SINGAPORE_DRIVING_LICENSE	El número de licencia de conducir (específico para Singapur).
SINGAPORE_NATIONAL_REGISTRY _IDENTIFICATION_NUMBER	El carné de identidad de registro nacional de Singapur.
SINGAPORE_PASSPORT_NUMBER	El número de pasaporte (específico para Singapur).
SINGAPORE_UNIQUE_ENTITY_NUMBER	Número de entidad único (UEN) de Singapur

Tipos de datos de Eslovaquia

Tipo de datos	Descripción
SLOVAKIA_DRIVING_LICENSE	El número de licencia de conducir (específico para Eslovaquia).
SLOVAKIA_NATIONAL_IDENTIFICATION_NUMBER	El número de identificación nacional (específico para Eslovaquia).
SLOVAKIA_PASSPORT_NUMBER	El número de pasaporte (específico para Eslovaquia).
SLOVAKIA_VALUE_ADDED_TAX	Impuesto sobre el valor agregado (específico para Eslovaquia).

Tipos de datos de Eslovenia

Tipo de datos	Descripción
SLOVENIA_DRIVING_LICENSE	El número de licencia de conducir (específico para Eslovenia).
SLOVENIA_PASSPORT_NUMBER	El número de pasaporte (específico para Eslovenia).
ESLOVENIA_TAX_IDENTIFICATION_NUMBER	Número de identificación fiscal (específico para Eslovenia).
SLOVENIA_UNIQUE_MASTER_CITIZEN_NUMBER	Número de ciudadano maestro (JMBG) único para los ciudadanos de Eslovenia.
SLOVENIA_VALUE_ADDED_TAX	Impuesto sobre el valor agregado (específico para Eslovenia).

Tipos de datos de Sudáfrica

Tipo de datos	Descripción
SOUTH_AFRICA_PERSONAL_IDENTIFICATION_NUMBER	El número de identificación personal (específico para Sudáfrica).

Tipos de datos de España

Tipo de datos	Descripción
SPAIN_BANK_ACCOUNT	El número de cuenta bancaria (específico para España).
SPAIN_DNI	El documento nacional de identidad (Documento Nacional de Identidad) de España.
SPAIN_DRIVING_LICENSE	El número de licencia de conducir (específico para España).
SPAIN_NIE	El número de identidad del extranjero (específico para España), también conocido como NIE.
SPAIN_NIF	Número de identificación fiscal (específico para España), también conocido como NIF.
SPAIN_PASSPORT_NUMBER	El número de pasaporte (específico para España).
SPAIN_SSN	El número de seguro social (para ciudadanos de España).
SPAIN_VALUE_ADDED_TAX	Impuesto sobre el valor agregado (específico para España).

Tipos de datos de Sri Lanka

Tipo de datos	Descripción
SRI_LANKA_NATIONAL_IDENTIFICATION_NUMBER	El identificador nacional (específico para Sri Lanka).

Tipos de datos de Suecia

Tipo de datos	Descripción
SWEDEN_DRIVING_LICENSE	El número de licencia de conducir (específico para Suecia).
SWEDEN_PASSPORT_NUMBER	El número de pasaporte (específico para Suecia).
SWEDEN_PERSONAL_IDENTIFICATION_NUMBER	El número de identificación nacional (específico para Suecia).
SWEDEN_TAX_IDENTIFICATION_NUMBER	Número de identificación fiscal de Suecia (personnummer).
SWEDEN_VALUE_ADDED_TAX	Impuesto sobre el valor agregado (específico para Suecia).

Tipos de datos de Suiza

Tipo de datos	Descripción
SWITZERLAND_AHV	El número de seguro social para ciudadanos suizos (AHV).
SWITZERLAND_HEALTH_INSURANCE_NUMBER	Número de seguro médico suizo.
SWITZERLAND_PASSPORT_NUMBER	El número de pasaporte (específico para Suiza).

Tipo de datos	Descripción
SWITZERLAND_VALUE_ADDED_TAX	Impuesto sobre el valor agregado (específico para Suiza).

Tipos de datos de Tailandia

Tipo de datos	Descripción
THAILAND_PASSPORT_NUMBER	El número de pasaporte (específico para Tailandia).
THAILAND_PERSONAL_IDENTIFICATION_NUMBER	El número de identificación personal (específico para Tailandia).

Tipos de datos de Turquía

Tipo de datos	Descripción
TURKEY_NATIONAL_IDENTIFICATION_NUMBER	El número de identificación nacional (específico para Turquía).
TURKEY_PASSPORT_NUMBER	El número de pasaporte (específico para Turquía).
TURKEY_VALUE_ADDED_TAX	Impuesto sobre el valor agregado (específico para Turquía).

Tipos de datos de Ucrania

Tipo de datos	Descripción
UKRAINE_INDIVIDUAL_IDENTIFICATION_NUMBER	El identificador único (específico para Ucrania).

Tipo de datos	Descripción
UKRAINE_PASSPORT_NUMBER_DOMESTIC	El número de pasaporte nacional (específico para Ucrania).
UKRAINE_PASSPORT_NUMBER_INTERNATIONAL	El número de pasaporte internacional (específico para Ucrania).

Tipos de datos de los Emiratos Árabes Unidos (UAE

Tipo de datos	Descripción
UNITED_ARAB_EMIRATES_PERSONAL_NUMBER	El número de identificación personal (específico para los Emiratos Árabes Unidos).

Tipos de datos para Reino Unido

Tipo de datos	Descripción
UK_BANK_ACCOUNT	Cuenta bancaria en el Reino Unido (UK).
UK_BANK_SORT_CODE	Código de clasificación bancaria del Reino Unido (UK). Los códigos de clasificación son códigos bancarios que se utilizan para enrutar transferencias de dinero entre bancos de sus respectivos países a través de sus respectivas organizaciones de liquidación.
UK_DRIVING_LICENSE	El número de licencia de conducir del Reino Unido de Gran Bretaña e Irlanda del Norte (específico del Reino Unido)
UK_ELECTORAL_ROLL_NUMBER	El número de registro electoral (ERN) es el número de identificación que se expide a una persona para el registro electoral del Reino Unido. El formato de este número está especificado por las normas gubernamentales

Tipo de datos	Descripción
	del Reino Unido de la Oficina del Gabinete del Reino Unido.
UK_NATIONAL_HEALTH_SERVICE_NUMBER	El número del Servicio Nacional de Salud (National Health Service, NHS) es el número único asignado a un usuario registrado de los servicios de salud pública en el Reino Unido.
UK_NATIONAL_INSURANCE_NUMBER	El número de seguro nacional (National Insurance Number, NINO) es un número que se utiliza en el Reino Unido (UK) con el objetivo de identificar a una persona para el programa de seguro nacional o el sistema de seguridad social. Este número es lo que a veces se denomina NI NO o NINO.
UK_PASSPORT_NUMBER	Número de pasaporte del Reino Unido (UK).
UK_UNIQUE_TAXADOR_REFERENCE_NUMBER	El número de referencia tributaria única (UTR) del Reino Unido (Reino Unido). Un identificador utilizado por el Gobierno del Reino Unido para gestionar el sistema tributario.
UK_VALUE_ADDED_TAX	El IVA es un impuesto al consumo que corre a cargo del consumidor final. El IVA se paga por cada transacción del proceso de fabricación y distribución. Para el Reino Unido, el número de IVA lo emite la oficina de IVA de la región en la que está establecida la empresa.
UK_PHONE_NUMBER	Número de teléfono del Reino Unido (UK).

Tipos de datos de Venezuela

Tipo de datos	Descripción
VENEZUELA_DRIVING_LICENSE	El número de licencia de conducir (específico para Venezuela).
VENEZUELA_NATIONAL_IDENTIFICATION_NUMBER	El número de identificación nacional (específico para Venezuela).
VENEZUELA_VALUE_ADDED_TAX	Impuesto al valor agregado (específico para Venezuela).

Uso de una detección de datos confidenciales detallada

> **Note**
>
> Las acciones detalladas solo están disponibles en las versiones de AWS Glue 3.0 y 4.0. Esto incluye la experiencia AWS Glue Studio. Los cambios persistentes en el registro de auditoría tampoco están disponibles en la versión 2.0.
> En todos los trabajos visuales de las versiones de AWS Glue Studio 3.0 y 4.0 se creará un script que utilizará automáticamente API de acciones detalladas.

La transformación Detectar datos confidenciales proporciona la capacidad de detectar, enmascarar o eliminar entidades definidas por el usuario o predefinidas por AWS Glue. Las acciones detalladas permiten además aplicar una acción específica por entidad. Los beneficios adicionales incluyen:

- Rendimiento mejorado, ya que las acciones se aplican en cuanto se detectan los datos.
- La opción de incluir o excluir columnas específicas.
- La capacidad de utilizar un enmascaramiento parcial. Esto le permite enmascarar parcialmente las entidades de datos confidenciales detectadas, en lugar de enmascarar toda la cadena. Se admiten ambos parámetros simples con compensaciones y expresiones regulares.

A continuación, se muestran fragmentos de código de las API de detección de datos confidenciales y de las acciones detalladas que se utilizan en los trabajos de muestra a los que se hace referencia en la siguiente sección.

API de detección: las acciones detalladas utilizan el nuevo parámetro `detectionParameters`:

```
def detect(
    frame: DynamicFrame,
    detectionParameters: JsonOptions,
    outputColumnName: String = "DetectedEntities",
    detectionSensitivity: String = "LOW"
): DynamicFrame = {}
```

Uso de las API de detección de datos confidenciales con acciones detalladas

Las API de detección de datos confidenciales que utilizan detect analizan los datos proporcionados, determinan si las filas o columnas son tipos de entidades de datos confidenciales y ejecutarán las acciones especificadas por el usuario para cada tipo de entidad.

Uso de la API de detección con acciones detalladas

Use la API de detección y especifique el `outputColumnName` y los `detectionParameters`.

```
    object GlueApp {
      def main(sysArgs: Array[String]) {

        val spark: SparkContext = new SparkContext()
        val glueContext: GlueContext = new GlueContext(spark)

        // @params: [JOB_NAME]
        val args = GlueArgParser.getResolvedOptions(sysArgs, Seq("JOB_NAME").toArray)
        Job.init(args("JOB_NAME"), glueContext, args.asJava)

        // Script generated for node S3 bucket. Creates DataFrame from data stored in
 S3.
        val S3bucket_node1 =
 glueContext.getSourceWithFormat(formatOptions=JsonOptions("""{"quoteChar":
 "\"", "withHeader": true, "separator": ",", "optimizePerformance": false}"""),
 connectionType="s3", format="csv", options=JsonOptions("""{"paths":
 ["s3://189657479688-ddevansh-pii-test-bucket/tiny_pii.csv"], "recurse": true}"""),
 transformationContext="S3bucket_node1").getDynamicFrame()

        // Script generated for node Detect Sensitive Data. Will run detect API for the
 DataFrame
        // detectionParameter contains information on which EntityType are being
 detected
        // and what actions are being applied to them when detected.
```

```
        val DetectSensitiveData_node2 = EntityDetector.detect(
            frame = S3bucket_node1,
            detectionParameters = JsonOptions(
             """
                {
                    "PHONE_NUMBER": [
                        {
                            "action": "PARTIAL_REDACT",
                            "actionOptions": {
                                "numLeftCharsToExclude": "3",
                                "numRightCharsToExclude": "4",
                                "redactChar": "#"
                            },
                            "sourceColumnsToExclude": [ "Passport No", "DL NO#" ]
                        }
                    ],
                    "USA_PASSPORT_NUMBER": [
                        {
                            "action": "SHA256_HASH",
                            "sourceColumns": [ "Passport No" ]
                        }
                    ],
                    "USA_DRIVING_LICENSE": [
                        {
                            "action": "REDACT",
                            "actionOptions": {
                                "redactText": "USA_DL"
                            },
                            "sourceColumns": [ "DL NO#" ]
                        }
                    ]

                }
            """
            ),
            outputColumnName = "DetectedEntities"
        )

        // Script generated for node S3 bucket. Store Results of detect to S3 location
        val S3bucket_node3 = glueContext.getSinkWithFormat(connectionType="s3",
options=JsonOptions("""{"path": "s3://amzn-s3-demo-bucket/test-output/",
"partitionKeys": []}"""), transformationContext="S3bucket_node3",
format="json").writeDynamicFrame(DetectSensitiveData_node2)
```

```
    Job.commit()
  }
```

El script anterior creará un DataFrame desde una ubicación en Amazon S3 y, a continuación, ejecutará la API `detect`. Como la API `detect` requiere que el campo `detectionParameters` (un mapa del nombre de la entidad con una lista de todos los ajustes de acción que se van a utilizar en esa entidad) esté representado por el objeto `JsonOptions` de AWS Glue, también nos permitirá ampliar la funcionalidad de la API.

Para cada acción especificada por entidad, introduzca una lista de todos los nombres de columna a los que quiere aplicar la combinación de entidad y acción. Esto le permite personalizar las entidades para detectarlas en cada columna de su conjunto de datos y omitir las entidades que sabe que no están en una columna específica. Esto también permite que sus trabajos sean más eficaces al no realizar llamadas de detección innecesarias a esas entidades y le permite realizar acciones exclusivas para cada combinación de columnas y entidades.

Si analizamos más detenidamente el `detectionParameters`, en el trabajo de muestra hay tres tipos de entidades. Estos son `Phone Number`, `USA_PASSPORT_NUMBER` y `USA_DRIVING_LICENSE`. Para cada uno de estos tipos de entidades, AWS Glue ejecutará diferentes acciones que son `PARTIAL_REDACT`, `SHA256_HASH`, `REDACT` y `DETECT`. Cada uno de los tipos de entidad también tiene `sourceColumns` que aplicar o `sourceColumnsToExclude` si se detecta.

> **Note**
>
> Solo se puede usar una acción de edición in situ (`PARTIAL_REDACT`, `SHA256_HASH` o `REDACT`) por columna, pero la acción `DETECT` se puede usar con cualquiera de estas acciones.

El campo `detectionParameters` tiene el siguiente diseño:

```
ENTITY_NAME -> List[Actions]
{
 "ENTITY_NAME": [{
  Action, // required
```

```
      ColumnSpecs,
      ActionOptionsMap
        }],
        "ENTITY_NAME2": [{
      ...
        }]
    }
```

Los tipos de `actions` y `actionOptions` se enumeran a continuación:

```
DETECT
{
    # Required
    "action": "DETECT",
    # Optional, depending on action chosen
    "actionOptions": {
        // There are no actionOptions for DETECT
    },
    # 1 of below required, both can also used
    "sourceColumns": [
        "COL_1", "COL_2", ..., "COL_N"
    ],
    "sourceColumnsToExclude": [
        "COL_5"
    ]
}

SHA256_HASH
{
    # Required
    "action": "SHA256_HASH",
    # Required or optional, depending on action chosen
    "actionOptions": {
        // There are no actionOptions for SHA256_HASH
    },

    # 1 of below required, both can also used
    "sourceColumns": [
        "COL_1", "COL_2", ..., "COL_N"
    ],
    "sourceColumnsToExclude": [
        "COL_5"
```

```
    ]
}

REDACT
{
    # Required
    "action": "REDACT",
    # Required or optional, depending on action chosen
    "actionOptions": {
        // The text that is being replaced
        "redactText": "USA_DL"
    },

    # 1 of below required, both can also used
    "sourceColumns": [
        "COL_1", "COL_2", ..., "COL_N"
    ],
    "sourceColumnsToExclude": [
        "COL_5"
    ]
}

PARTIAL_REDACT
{
    # Required
    "action": "PARTIAL_REDACT",
    # Required or optional, depending on action chosen
    "actionOptions": {
        // number of characters to not redact from the left side
        "numLeftCharsToExclude": "3",
        // number of characters to not redact from the right side
        "numRightCharsToExclude": "4",
        // the partial redact will be made with this redacted character
        "redactChar": "#",
        // regex pattern for partial redaction
        "matchPattern": "[0-9]"
    },

    # 1 of below required, both can also used
    "sourceColumns": [
        "COL_1", "COL_2", ..., "COL_N"
    ],
    "sourceColumnsToExclude": [
        "COL_5"
```

```
    ]
}
```

Una vez que se ejecuta el script, los resultados se envían a la ubicación de Amazon S3 indicada. Puede ver sus datos en Amazon S3, pero con los tipos de entidades seleccionados sensibilizados en función de la acción seleccionada. En ese caso, tendríamos filas que tendrían el siguiente aspecto:

```
{
    "Name": "Colby Schuster",
    "Address": "39041 Antonietta Vista, South Rodgerside, Nebraska 24151",
    "Car Owned": "Fiat",
    "Email": "Kitty46@gmail.com",
    "Company": "O'Reilly Group",
    "Job Title": "Dynamic Functionality Facilitator",
    "ITIN": "991-22-2906",
    "Username": "Cassandre.Kub43",
    "SSN": "914-22-2906",
    "DOB": "2020-08-27",
    "Phone Number": "1-2#######1718",
    "Bank Account No": "69741187",
    "Credit Card Number": "6441-6289-6867-2162-2711",
    "Passport No": "94f311e93a623c72ccb6fc46cf5f5b0265ccb42c517498a0f27fd4c43b47111e",
    "DL NO#": "USA_DL"
}
```

En el guion anterior, el `Phone Number` se redactó parcialmente con #. Se cambió el `Passport No` a un hash SHA256. Se detectó el `DL NO#` como un número de licencia de conducir de EE. UU. y estaba redactado como “USA_DL” tal y como aparecía en los `detectionParameters`.

> **Note**
>
> La API classifyColumns no está disponible para su uso con acciones específicas debido a la naturaleza de la API. Esta API realiza un muestreo de columnas (ajustable por el usuario, pero tiene valores predeterminados) para realizar la detección más rápidamente. Por este motivo, las acciones detalladas requieren iterar todos los valores.

Registro de auditoría persistente

Una nueva característica que se introdujo con acciones detalladas (pero que también está disponible cuando se utilizan las API normales) es la presencia de un registro de auditoría persistente. Actualmente, al ejecutar la API de detección se añade un parámetro de columna adicional (predeterminado en `DetectedEntities` pero se puede personalizar mediante `outputColumnName`) con metadatos de detección de PII. Ahora tiene una clave de metadatos "actionUsed", que es una de las siguientes:`DETECT`, `PARTIAL_REDACT`, `SHA256_HASH`, `REDACT`.

```
"DetectedEntities": {
    "Credit Card Number": [
        {
            "entityType": "CREDIT_CARD",
            "actionUsed": "DETECT",
            "start": 0,
            "end": 19
        }
    ],
    "Phone Number": [
        {
            "entityType": "PHONE_NUMBER",
            "actionUsed": "REDACT",
            "start": 0,
            "end": 14
        }
    ]
}
```

Incluso los clientes que utilicen las API sin acciones detalladas, como por ejemplo `detect(entityTypesToDetect, outputColumnName)`, verán este registro de auditoría persistente en el marco de datos resultante.

Los clientes que utilicen API con acciones detalladas verán todas las acciones, independientemente de si están redactadas o no. Ejemplo:

```
+--------------------+---------------
+-------------------------------------------------------------------------------------------------------
+
| Credit Card Number  |  Phone Number  |
                                              DetectedEntities
                                                                    |
```

```
+--------------------+---------------
+-------------------------------------------------------------------------------------------------------
+
| 622126741306XXXX    | +12#####7890   | {"Credit Card Number":
[{"entityType":"CREDIT_CARD","actionUsed":"PARTIAL_REDACT","start":0,"end":16}],"Phone
 Number":
[{"entityType":"PHONE_NUMBER","actionUsed":"PARTIAL_REDACT","start":0,"end":12}]}} |
| 6221 2674 1306 XXXX | +12#######7890 | {"Credit Card Number":
[{"entityType":"CREDIT_CARD","actionUsed":"PARTIAL_REDACT","start":0,"end":19}],"Phone
 Number":
[{"entityType":"PHONE_NUMBER","actionUsed":"PARTIAL_REDACT","start":0,"end":14}]}} |
| 6221-2674-1306-XXXX | 22#######7890  | {"Credit Card Number":
[{"entityType":"CREDIT_CARD","actionUsed":"PARTIAL_REDACT","start":0,"end":19}],"Phone
 Number":
[{"entityType":"PHONE_NUMBER","actionUsed":"PARTIAL_REDACT","start":0,"end":14}]}} |
+--------------------+---------------
+-------------------------------------------------------------------------------------------------------
+
```

Si no desea ver la columna DetectedEntities, simplemente coloque la columna adicional en un script personalizado.

API de Visual Job de AWS Glue

AWS Glue proporciona una API que permite a los clientes crear trabajos de integración de datos mediante la API de AWS Glue a partir de un objeto JSON que representa un flujo de trabajo de pasos visuales. Los clientes pueden utilizar el editor visual de AWS Glue Studio para realizar estos trabajos.

Para obtener más información sobre los tipos de datos de la API Visual Job, consulte API Visual Job.

Temas

- Diseño de API y las API de CRUD
- Introducción
- Limitaciones de los trabajos visuales

Diseño de API y las API de CRUD

Las API CreateJob y UpdateJob ahora son compatibles con un parámetro opcional adicional: codeGenConfigurationNodes. Proporcionar una estructura JSON no vacía para este campo hará que

se registre el DAG en AWS Glue Studio para el trabajo creado y que se genere el código asociado. Se ignorará un valor nulo o una cadena vacía para este campo en la creación del trabajo.

Las actualizaciones del campo codeGenConfigurationNodes se realizarán a través de la API de AWS Glue UpdateJob de forma similar a CreateJob. En UpdateJob se debe especificar el campo completo en el que se ha modificado el DAG según lo deseado. Se ignorará todo valor nulo proporcionado y no se realizará ninguna actualización del DAG. Una estructura o cadena vacía hará que los codeGenConfigurationNodes se establezcan como vacíos y se elimine cualquier DAG anterior. La API GetJob devolverá un DAG, si lo hay. La API DeleteJob también eliminará cualquier DAG asociado.

Introducción

Para crear un trabajo, utilice la acción CreateJob. La entrada de la solicitud `CreateJob` tendrá un campo “codeGenConfigurationNodes” adicional en el que se puede especificar el objeto DAG en JSON.

Para tener en cuenta:

- El campo “codeGenConfigurationNodes” es un mapa de nodeId a nodo.
- Cada nodo comienza con una clave que identifica qué tipo de nodo es.
- Solo puede haber una clave especificada, ya que un nodo solo puede ser de un tipo.
- El campo de entrada contiene los nodos principales del nodo actual.

La siguiente es una representación JSON de una entrada de CreateJob.

```
{
  "node-1": {
    "S3CatalogSource": {
      "Table": "csvFormattedTable",
      "PartitionPredicate": "",
      "Name": "S3 bucket",
      "AdditionalOptions": {},
      "Database": "myDatabase"
    }
  },
  "node-3": {
    "S3DirectTarget": {
      "Inputs": ["node-2"],
      "PartitionKeys": [],
```

```
      "Compression": "none",
      "Format": "json",
      "SchemaChangePolicy": { "EnableUpdateCatalog": false },
      "Path": "",
      "Name": "S3 bucket"
    }
  },
  "node-2": {
    "ApplyMapping": {
      "Inputs": ["node-1"],
      "Name": "ApplyMapping",
      "Mapping": [
        {
          "FromType": "long",
          "ToType": "long",
          "Dropped": false,
          "ToKey": "myheader1",
          "FromPath": ["myheader1"]
        },
        {
          "FromType": "long",
          "ToType": "long",
          "Dropped": false,
          "ToKey": "myheader2",
          "FromPath": ["myheader2"]
        },
        {
          "FromType": "long",
          "ToType": "long",
          "Dropped": false,
          "ToKey": "myheader3",
          "FromPath": ["myheader3"]
        }
      ]
    }
  }
}
```

Actualización y obtención de trabajos

Dado que UpdateJob también tendrá un campo “codeGenConfigurationNodes”, el formato de entrada será el mismo. Consulte Acción UpdateJob.

La acción GetJob devolverá también un campo “codeGenConfigurationNodes” con el mismo formato. Consulte Acción GetJob.

Limitaciones de los trabajos visuales

Dado que el parámetro “codeGenConfigurationNodes” se ha agregado a las API existentes, se heredará cualquier limitación en esas API. Además, los codeGenConfigurationNodes y algunos nodos tendrán un tamaño limitado. Consulte Estructura de los trabajos para obtener más información.

Programación de scripts de Ray

AWS Glue facilita la escritura y ejecución de scripts de Ray. En esta sección se describen las capacidades de Ray compatibles que están disponibles en AWS Glue para Ray. Programación de scripts de Ray en Python.

El script personalizado debe ser compatible con la versión de Ray definida en el campo `Runtime` de la definición de su trabajo. Para obtener más información sobre `Runtime` en la API de los trabajos, consulte the section called “Trabajos”. Para obtener información acerca de cada entorno de tiempo de ejecución, consulte the section called “Entornos de tiempo de ejecución de Ray compatibles”.

Temas

- Tutorial: Cómo escribir un script ETL en AWS Glue para Ray
- Uso de Ray Core y Ray Data en AWS Glue para Ray
- Proporcionar archivos y bibliotecas de Python a los trabajos de Ray
- Conexión a los datos de los trabajos de Ray

Tutorial: Cómo escribir un script ETL en AWS Glue para Ray

Ray permite escribir y escalar tareas distribuidas de forma nativa en Python. AWS Glue para Ray ofrece entornos de Ray sin servidor a los que puede acceder tanto desde ambos trabajos y sesiones interactivas (las sesiones interactivas de Ray están en versión preliminar). El sistema de trabajo de AWS Glue proporciona una forma coherente de administrar y ejecutar las tareas de forma programada, mediante un disparador o desde la consola de AWS Glue.

La combinación de estas herramientas de AWS Glue crea una poderosa cadena de herramientas que puede usar para la extracción, transformación y carga (ETL) de cargas de trabajo, un caso de

uso popular para AWS Glue. En este tutorial, aprenderá los conceptos básicos de la creación de esta solución.

También admitimos el uso de AWS Glue para Spark para sus cargas de trabajo de ETL. Para obtener acceso a un tutorial acerca de la escritura de un script de AWS Glue para Spark, consulte the section called “Tutorial: Escritura de un script de Spark”. Para obtener más información sobre los motores disponibles, consulte the section called “AWS Glue para Spark y AWS Glue para Ray”. Ray es capaz de abordar muchos tipos diferentes de tareas en los ámbitos de la analítica, machine learning y el desarrollo de aplicaciones.

En este tutorial, extraerá, transformará y cargará un conjunto de datos de CSV alojado en Amazon Simple Storage Service (Amazon S3). Empezará con el conjunto de datos de registros de viajes de la Comisión de Taxis y Limusinas de Nueva York (TLC), que se almacena en un bucket público de Amazon S3. Para obtener más información sobre este conjunto de datos, consulte el Registro de datos abiertos en AWS.

Transformará sus datos con transformaciones predefinidas disponibles en la biblioteca Ray Data. Ray Data es una biblioteca de preparación de conjuntos de datos diseñada por Ray e incluida de forma predeterminada en los entornos de AWS Glue para Ray. Para obtener más información sobre las bibliotecas incluidad de forma predeterminada, consulte the section called “Módulos incluidos con los trabajos de Ray”. A continuación, escribirá los datos transformados en un bucket de Amazon S3 que usted controle.

Requisitos previos: para este tutorial, necesita una cuenta de AWS con acceso a AWS Glue y a Amazon S3.

Paso 1: crear un bucket en Amazon S3 para almacenar los datos de salida

Necesitará un bucket de Amazon S3 que pueda controlar para que sirva de depósito de los datos creados en este tutorial. Puede crear este bucket mediante el siguiente procedimiento.

> **Note**
>
> Si quiere escribir sus datos en un bucket existente que usted controla, puede omitir este paso. Tome nota de *yourBucketName*, el nombre del bucket existente, para usarlo en pasos posteriores.

Para crear un bucket para la salida del trabajo de Ray

- Para crear un bucket, siga los pasos que se indican en Crear un bucket en la Guía del usuario de Amazon S3.
  - Cuando elija el nombre de un bucket, tome nota de *yourBucketName*, que consultará en pasos posteriores.
  - Para otras configuraciones, la configuración sugerida que se proporciona en la consola de Amazon S3 debería funcionar correctamente en este tutorial.

  Por ejemplo, el cuadro de diálogo de creación del bucket podría tener este aspecto en la consola de Amazon S3.

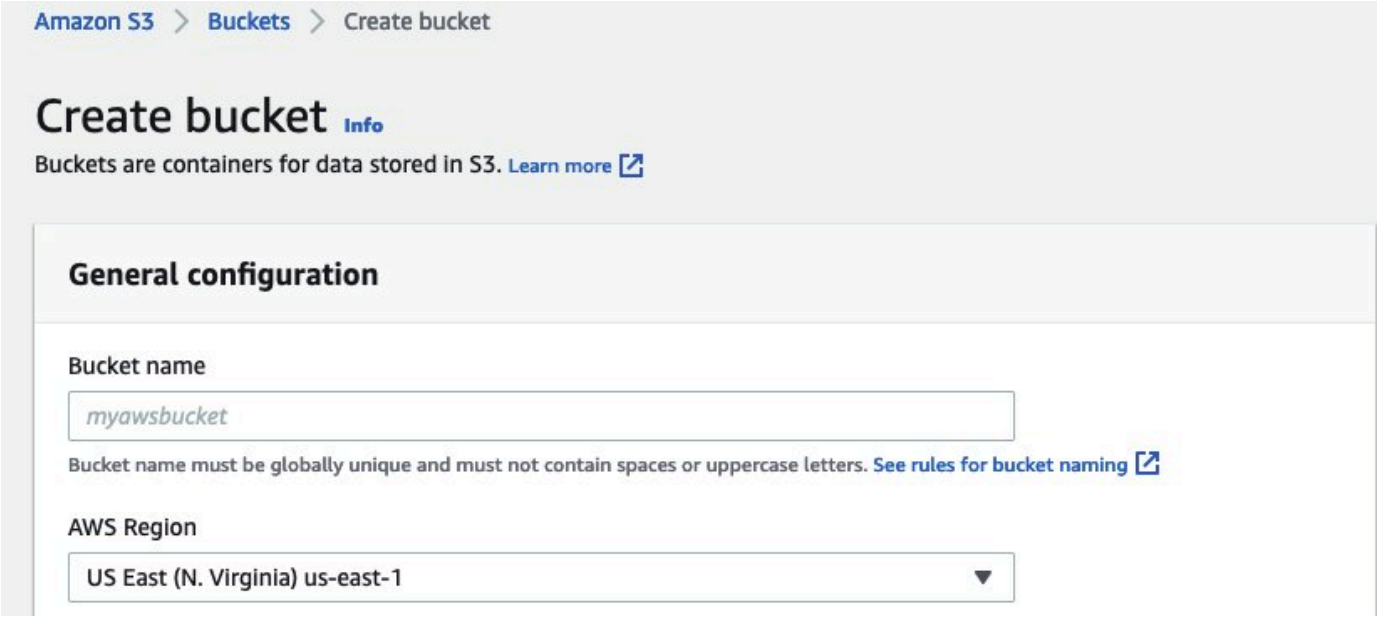

Paso 2: crear una política y rol de IAM para su trabajo de Ray

Su trabajo necesitará un rol de AWS Identity and Access Management (IAM) con lo siguiente:

- Permisos otorgados por la política administrada de `AWSGlueServiceRole`. Estos son los permisos básicos necesarios para ejecutar un trabajo de AWS Glue.
- `Read` los permisos de nivel de acceso para el recurso de Amazon S3 `nyc-tlc/*`.
- `Write` los permisos de nivel de acceso para el recurso de Amazon S3 *yourBucketName*`/*`.
- Una relación de confianza que permite a la entidad principal `glue.amazonaws.com` asumir el rol.

Puede crear este rol mediante el siguiente procedimiento.

Crear un rol de IAM para su trabajo de AWS Glue para Ray

> **Note**
>
> Puede seguir muchos procedimientos diferentes para crear un rol de IAM. Para obtener más información u opciones sobre cómo aprovisionar los recursos de IAM, consulte la documentación de AWS Identity and Access Management.

1. Cree una política que defina los permisos de Amazon S3 descritos anteriormente mediante los pasos que aparecen en Creación de políticas de IAM (consola) con el editor visual en la Guía del usuario de IAM.
   - Cuando seleccione un servicio, elija Amazon S3.
   - Cuando seleccione los permisos para su política, adjunte los siguientes conjuntos de acciones para los siguientes recursos (mencionados anteriormente):
     - Lea los permisos de nivel de acceso para el recurso de Amazon S3 `nyc-tlc/*`.
     - Escriba los permisos de nivel de acceso para el recurso de Amazon S3 *`yourBucketName`*`/*`.
   - Cuando seleccione el nombre de la política, tome nota de *`YourPolicyName`*, que consultará en un paso posterior.
2. Cree un rol para su trabajo de AWS Glue para Ray; para ello, siga los pasos que se indican en Crear un rol para un servicio de AWS (consola) en la Guía del usuario de IAM.
   - Cuando seleccione una entidad de servicio AWS de confianza, elija `Glue`. Esto completará automáticamente la relación de confianza necesaria para su trabajo.
   - Cuando seleccione políticas para la política de permisos, adjunte las siguientes políticas:
     - `AWSGlueServiceRole`
     - *`YourPolicyName`*
   - Cuando seleccione el nombre del rol, tome nota de *`YourRoleName`*, que consultará en pasos posteriores.

Paso 3: crear y ejecutar un trabajo de AWS Glue para Ray

En este paso, usted crea un trabajo de AWS Glue mediante la Consola de administración de AWS, proporciona un script de ejemplo y ejecuta el trabajo. Cuando crea un trabajo, se crea un lugar en la consola para que usted almacene, configure y edite el script de Ray. Para obtener más información acerca de la creación de trabajos, consulte the section called “Inicie sesión en la consola”.

En este tutorial, abordamos el siguiente escenario de ETL: lea los registros de enero de 2022 del conjunto de datos de Registros de viajes de TLC de New York City, agregue una nueva columna (`tip_rate`) al conjunto de datos mediante la combinación de datos en las columnas existentes; luego, elimine la cantidad de columnas que no sean relevantes para el análisis actual y, a continuación, escriba los resultados en *`yourBucketName`*. El siguiente script de Ray lleva a cabo estos pasos:

```
import ray
import pandas
from ray import data

ray.init('auto')

ds = ray.data.read_csv("s3://nyc-tlc/opendata_repo/opendata_webconvert/yellow/
yellow_tripdata_2022-01.csv")

# Add the given new column to the dataset and show the sample record after adding a new
 column
ds = ds.add_column( "tip_rate", lambda df: df["tip_amount"] / df["total_amount"])

# Dropping few columns from the underlying Dataset
ds = ds.drop_columns(["payment_type", "fare_amount", "extra", "tolls_amount",
 "improvement_surcharge"])

ds.write_parquet("s3://yourBucketName/ray/tutorial/output/")
```

Para crear y ejecutar un trabajo de AWS Glue para Ray

1. En la Consola de administración de AWS, vaya a la página de inicio de AWS Glue.
2. En el panel de navegación lateral, seleccione Trabajos de ETL.
3. En Crear trabajo, elija Editor de script de Ray y, a continuación, elija Crear, como se muestra en la siguiente ilustración.

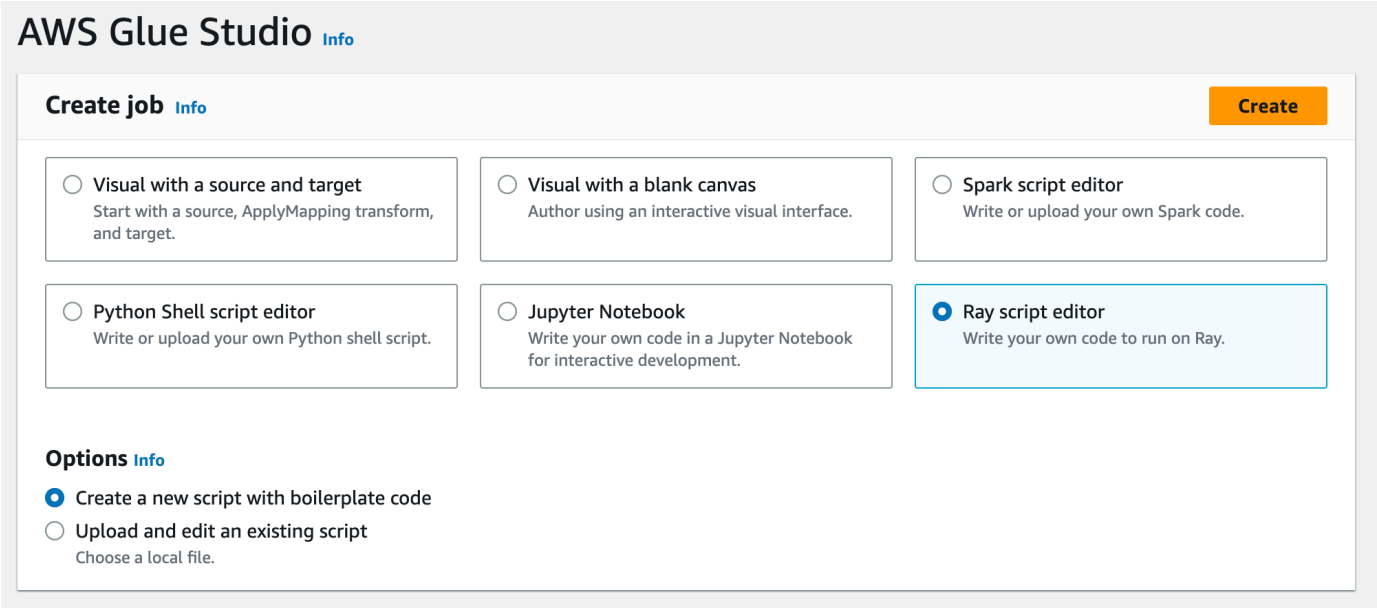

4. Pegue el texto completo del script en el panel Script y sustituya el texto existente.
5. Vaya a Detalles del trabajo y configure la propiedad de rol de IAM en *YourRoleName*.
6. Elija Guardar y, a continuación, elija Ejecutar.

Paso 4: inspeccionar la salida

Después de ejecutar su trabajo de AWS Glue, debe validar que el resultado cumpla con las expectativas de este escenario. Puede hacerlo mediante el siguiente procedimiento.

Para validar si su trabajo de Ray se ejecutó correctamente

1. En la página de detalles del trabajo, vaya a Ejecuciones.
2. Después de unos minutos, debería ver una ejecución con el Estado de ejecución como Correcto.
3. Vaya a la consola de Amazon S3 en https://console.aws.amazon.com/s3/ e inspeccione *yourBucketName*. Debería ver los archivos escritos en su bucket de salida.
4. Lea los archivos de Parquet y verifique su contenido. Puede hacerlo con las herramientas existentes. Si no dispone de un proceso para validar los archivos de Parquet, puede hacerlo en la consola de AWS Glue mediante una sesión interactiva de AWS Glue, con Spark o Ray (versión preliminar).

   En una sesión interactiva, tiene acceso a las bibliotecas Ray Data, Spark o pandas, que se proporcionan de forma predeterminada (según el motor que elija). Para verificar el contenido del archivo, puede usar los métodos de inspección habituales disponibles en esas bibliotecas,

como `count`, `schema` y `show`. Para obtener más información sobre las sesiones interactivas en la consola, consulte Uso de cuaderno con AWS Glue Studio y AWS Glue.

Como ha confirmado que los archivos se han escrito en el bucket, puede decir con relativa certeza que si el resultado tiene problemas, no están relacionados con la configuración de IAM. Configure su sesión con *`YourRoleName`* para tener acceso a los archivos pertinentes.

Si no ve los resultados esperados, examine el contenido de resolución de problemas que aparecen en esta guía para identificar y corregir el origen del error. Encontrará el contenido sobre la resolución de problemas en el capítulo Solución de problemas de AWS Glue. Para ver errores específicos relacionados con los trabajos de Ray, consulte the section called “Solución de errores de Ray” en el capítulo sobre resolución de problemas.

Pasos a seguir a continuación

Ya ha visto y realizado un proceso de ETL mediante AWS Glue para Ray de principio a fin. Puede utilizar los siguientes recursos a fin de comprender qué herramientas proporciona AWS Glue para Ray para transformar e interpretar sus datos a escala.

- Para obtener más información sobre este tema, consulte the section called “Uso de Ray Core y Ray Data en AWS Glue para Ray”. Para obtener más experiencia en el uso de las tareas de Ray, siga los ejemplos que aparecen en la documentación de Ray Core. Consulte Ray Core: Ray Tutorials and Examples (2.4.0) en la documentación de Ray.
- Para obtener información sobre las bibliotecas de administración de datos disponibles en AWS Glue para Ray, consulte the section called “Conexión a datos”. Para obtener más experiencia en el uso de Ray Data para transformar y escribir conjuntos de datos, siga los ejemplos que aparecen en la documentación de Ray Data. Consulte Ray Data: Examples (2.4.0).
- Para obtener más información sobre la configuración de trabajos de AWS Glue para Ray, consulte the section called “Trabajar con tareas de Ray”.
- Para obtener más información sobre cómo escribir scripts de AWS Glue para Ray, continúe leyendo la documentación de esta sección.

Uso de Ray Core y Ray Data en AWS Glue para Ray

Ray es un marco para escalar verticalmente los scripts de Python mediante la distribución del trabajo en un clúster. Puede usar Ray como solución a muchos tipos de problemas, por lo que Ray proporciona bibliotecas para optimizar determinadas tareas. En AWS Glue, nos centramos en usar

Ray para transformar grandes conjuntos de datos. AWS Glueofrece soporte para Ray Data y partes de Ray Core a fin de facilitar esta tarea.

¿Qué es Ray Core?

El primer paso para crear una aplicación distribuida es identificar y definir el trabajo que se puede realizar de forma simultánea. Ray Core contiene las partes de Ray que se utilizan para definir las tareas que se pueden realizar de forma simultánea. Ray proporciona información de referencia y de inicio rápido que puede utilizar para aprender las herramientas que proporcionan. Para obtener más información, consulte ¿Qué es Ray Core? y Ray Core Quick Start. Para obtener más información sobre cómo definir eficazmente las tareas simultáneas en Ray, consulte Consejos para usuarios principiantes.

> **Tareas y actores de Ray**
>
> En la documentación de AWS Glue para Ray, podríamos referirnos a las tareas y los actores, que son conceptos básicos de Ray.
> Ray usa las características y clases de Python como bloques de construcción de un sistema de computación distribuida. Al igual que cuando las características y variables de Python se convierten en “métodos” y “atributos” cuando se usan en una clase, las funciones se convierten en “tareas” y las clases se convierten en “actores” cuando se usan en Ray para enviar código a los trabajadores. Mediante la anotación de `@ray.remote`, puede identificar las características y las clases que Ray podría usar.
> Las tareas y los actores son configurables, tienen un ciclo de vida y consumen recursos informáticos a lo largo de su vida. El código que genera errores se puede rastrear hasta una tarea o actor cuando se busca la causa raíz de los problemas. Por lo tanto, estos términos pueden surgir cuando aprenda a configurar, monitorear o depurar trabajos de AWS Glue para Ray.
> Para empezar a aprender a utilizar eficazmente las tareas y los actores a fin de crear una aplicación distribuida, consulte Conceptos clave en los documentos de Ray.

Ray Core en AWS Glue para Ray

AWS Glue para los entornos de Ray administra la formación y el escalado vertical de los clústeres, así como la recopilación y visualización de registros. Como gestionamos estos problemas, limitamos el acceso y el soporte a las API de Ray Core que se utilizarían para abordar estos problemas en un clúster de código abierto.

En el entorno de tiempo de ejecución de `Ray2.4` administrado, no admitimos lo siguiente:

- CLI de Ray Core
- CLI de Ray State
- `ray.util.metrics`Métodos de utilidad métrica de Prometheus:
  - Contador
  - Calibre
  - Histograma
- Otras herramientas de depuración:
  - ray.util.pdb.set_trace
  - ray.util.inspect_serializabilidad
  - ray.timeline

¿Qué es Ray Data?

Cuando se conecta a orígenes y destinos de datos, gestiona conjuntos de datos e inicia transformaciones comunes, Ray Data es una metodología sencilla para usar Ray a fin de resolver problemas mediante la transformación de conjuntos de datos de Ray. Para obtener más información sobre el uso de Ray Data, consulte Ray Datasets: Preprocesamiento de datos distribuidos.

Puede usar Ray Data u otras herramientas para acceder a sus datos. Para obtener más información sobre cómo acceder a sus datos en Ray, consulte the section called “Conexión a datos”.

Ray Data en AWS Glue para Ray

Ray Data es compatible y se proporciona de forma predeterminada en el entorno de tiempo de ejecución de `Ray2.4` administrado. Para obtener más información sobre los módulos proporcionados, consulte the section called “Módulos incluidos con los trabajos de Ray”.

Proporcionar archivos y bibliotecas de Python a los trabajos de Ray

En esta sección, se proporciona información que se necesita para utilizar las bibliotecas de Python con los trabajos de Ray de AWS Glue. Puede utilizar determinadas bibliotecas comunes incluidas de forma predeterminada en todos los trabajos de Ray. También puede proporcionar sus propias bibliotecas de Python en su trabajo de Ray.

Módulos incluidos con los trabajos de Ray

Puede aplicar flujos de trabajo de integración de datos en un trabajo de Ray con los siguientes paquetes proporcionados. Estos paquetes están disponibles de manera predeterminada en trabajos de Ray.

AWS Glue version 4.0

En AWS Glue 4.0, el entorno de Ray (tiempo de ejecución `Ray2.4`) proporciona los siguientes paquetes:

- boto3 == 1.26.133
- ray == 2.4.0
- pyarrow == 11.0.0
- pandas == 1.5.3
- numpy == 1.24.3
- fsspec == 2023.4.0

Esta lista incluye todos los paquetes que se instalarían con `ray[data] == 2.4.0`. Ray Data se admite de fábrica.

Proporcionar archivos a su trabajo de Ray

Puede proporcionar archivos a su trabajo de Ray con el parámetro `--working-dir`. Proporcione este parámetro con una ruta a un archivo .zip alojado en Amazon S3. Dentro del archivo .zip, los archivos deben estar contenidos en un único directorio de nivel superior. No debe haber ningún otro archivo en el nivel superior.

Los archivos se distribuirán a cada nodo de Ray antes de que el script comience a ejecutarse. Considere cómo esto podría repercutir en el espacio en disco disponible para cada nodo de Ray. El espacio en disco disponible viene determinado por el WorkerType establecido en la configuración del trabajo. Si desea proporcionar los datos de su trabajo a escala, este mecanismo no es la solución adecuada. Para obtener más información sobre cómo proporcionar datos a sus trabajos, consulte the section called “Conexión a datos”.

Se podrá acceder a sus archivos como si el directorio se hubiera proporcionado a Ray a través del parámetro `working_dir`. Por ejemplo, para leer un archivo denominado `sample.txt` en el directorio de nivel superior del archivo .zip, puede llamar a:

```
@ray.remote
def do_work():
    f = open("sample.txt", "r")
    print(f.read())
```

Para obtener más información acerca de `working_dir`, consulte la documentación de Ray. Esta característica se comporta de forma similar a las capacidades nativas de Ray.

Módulos de Python adicionales para trabajos de Ray

Módulos adicionales de PyPI

Los trabajos de Ray utilizan el instalador de paquetes de Python (pip3) para instalar los módulos adicionales que utilizará un script de Ray. Puede utilizar el parámetro `--pip-install` con una lista de módulos de Python separados por comas para agregar un nuevo módulo o cambiar la versión de un módulo existente.

Por ejemplo, para actualizar o agregar un nuevo módulo `scikit-learn`, utilice el siguiente par clave-valor:

`"--pip-install", "scikit-learn==0.21.3"`

Si tiene módulos o parches personalizados, puede distribuir sus propias bibliotecas desde Amazon S3 con el parámetro `--s3-py-modules`. Es posible que sea necesario volver a empaquetar y compilar su distribución antes de cargarla. Seguir las directrices en the section called “Incluir código Python en los trabajos de Ray”.

Distribuciones personalizadas de Amazon S3

Las distribuciones personalizadas deben cumplir con las pautas de empaquetado de Ray para las dependencias. Puede encontrar información sobre la compilación de estas distribuciones en la siguiente sección. Para obtener más información sobre cómo Ray configura las dependencias, consulte Environment Dependencies (Dependencias de entorno) en la documentación de Ray.

Para incluir un distribuible personalizado después de evaluar su contenido, cárguelo en un bucket disponible para el rol de IAM del trabajo. Especifique la ruta de Amazon S3 a un archivo zip de

Python en la configuración del parámetro. Si proporciona varios distribuibles, sepárelos con comas. Por ejemplo:

```
"--s3-py-modules", "s3://s3bucket/pythonPackage.zip"
```

Limitaciones

Los trabajos de Ray no admiten la compilación de código nativo en el entorno de trabajo. Esto puede ser una limitación si las dependencias de Python dependen de forma transitiva de código nativo compilado. Los trabajos de Ray pueden ejecutar los binarios proporcionados, pero deben compilarse para Linux en ARM64. Esto significa que quizás pueda utilizar el contenido de las ruedas de `aarch64manylinux`. Para poder proporcionar las dependencias nativas en un formato compilado, vuelva a empaquetar una rueda según los estándares de Ray. Por lo general, esto significa eliminar las carpetas `dist-info` para que solo haya una carpeta en la raíz del archivo.

No puede actualizar la versión de `ray` o `ray[data]` mediante este parámetro. Para usar una nueva versión de Ray, tendrá que cambiar el campo de tiempo de ejecución de su trabajo una vez que hayamos publicado el soporte para ello. Para obtener más información acerca de las versiones de Ray admitidas, consulte the section called “AWS GlueVersiones de ”.

Incluir código Python en los trabajos de Ray

Python Software Foundation ofrece comportamientos estandarizados para empaquetar archivos de Python para su uso en diferentes entornos de ejecución. Ray introduce limitaciones en los estándares de empaquetado que debe conocer. AWS Glue no especifica estándares de empaquetado más allá de los especificados para Ray. Las siguientes instrucciones proporcionan una guía estándar sobre cómo empaquetar paquetes simples de Python.

Empaquete sus archivos en un archivo `.zip`. El directorio debe estar en la raíz del archivo. No debe haber ningún otro archivo en el nivel raíz del archivo; de lo contrario, se producirá un comportamiento inesperado. El directorio raíz es el paquete, y su nombre se utiliza para hacer referencia al código de Python al importarlo.

Si proporciona una distribución de esta forma a un trabajo de Ray con `--s3-py-modules`, podrá importar código de Python del paquete en el script de Ray.

Su paquete puede proporcionar un único módulo de Python con algunos archivos de Python o puede empaquetar varios módulos juntos. Al volver a empaquetar las dependencias, como las bibliotecas de PyPI, compruebe si hay archivos ocultos y directorios de metadatos dentro de esos paquetes.

> **Warning**
>
> Determinados comportamientos del sistema operativo dificultan el seguimiento correcto de estas instrucciones de empaquetado.
>
> - OSX puede agregar archivos ocultos, como `__MACOSX`, a su archivo zip en el nivel superior.
> - Windows puede agregar sus archivos a una carpeta dentro del zip automáticamente y crear involuntariamente una carpeta anidada.

En los siguientes procedimientos se supone que interactúa con los archivos en Amazon Linux 2 o en un sistema operativo similar que proporciona una distribución de las utilidades `zip` y `zipinfo` de Info-ZIP. Recomendamos utilizar estas herramientas para evitar comportamientos inesperados.

Para empaquetar archivos de Python para usarlos en Ray

1. Cree un directorio temporal con el nombre de su paquete; a continuación, confirme que su directorio de trabajo es el directorio principal. Puede hacer esto con los siguientes comandos:

   ```
   cd parent_directory
   mkdir temp_dir
   ```

2. Copie los archivos en el directorio temporal; a continuación, confirme la estructura del directorio. Se accederá directamente al contenido de este directorio como módulo de Python. Puede hacer esto con el siguiente comando de la :

   ```
   ls -AR temp_dir
   # my_file_1.py
   # my_file_2.py
   ```

3. Use zip para comprimir la carpeta temporal. Puede hacer esto con los siguientes comandos:

   ```
   zip -r zip_file.zip temp_dir
   ```

4. Confirme que el archivo esté correctamente empaquetado. Ahora, *`zip_file`*`.zip` debería encontrarse en su directorio de trabajo. Puede inspeccionarlo con el siguiente comando:

   ```
   zipinfo -1 zip_file.zip
   ```

```
# temp_dir/
# temp_dir/my_file_1.py
# temp_dir/my_file_2.py
```

Volver a empaquetar un paquete de Python para usarlo en Ray.

1. Cree un directorio temporal con el nombre de su paquete; a continuación, confirme que su directorio de trabajo es el directorio principal. Puede hacer esto con los siguientes comandos:

```
cd parent_directory
mkdir temp_dir
```

2. Descomprima el paquete y copie el contenido en el directorio temporal. Elimine los archivos relacionados con su estándar de empaquetado anterior y deje solo el contenido del módulo. Confirme que la estructura de archivos sea correcta con el siguiente comando:

```
ls -AR temp_dir
# my_module
# my_module/__init__.py
# my_module/my_file_1.py
# my_module/my_submodule/__init__.py
# my_module/my_submodule/my_file_2.py
# my_module/my_submodule/my_file_3.py
```

3. Use zip para comprimir la carpeta temporal. Puede hacer esto con los siguientes comandos:

```
zip -r zip_file.zip temp_dir
```

4. Confirme que el archivo esté correctamente empaquetado. Ahora, *zip_file*`.zip` debería encontrarse en su directorio de trabajo. Puede inspeccionarlo con el siguiente comando:

```
zipinfo -1 zip_file.zip
# temp_dir/my_module/
# temp_dir/my_module/__init__.py
# temp_dir/my_module/my_file_1.py
# temp_dir/my_module/my_submodule/
# temp_dir/my_module/my_submodule/__init__.py
# temp_dir/my_module/my_submodule/my_file_2.py
# temp_dir/my_module/my_submodule/my_file_3.py
```

Conexión a los datos de los trabajos de Ray

Los trabajos de Ray de AWS Glue pueden usar una amplia matriz de paquetes de Python que están diseñados para que usted pueda integrar datos rápidamente. Proporcionamos un conjunto mínimo de dependencias para no saturar su entorno. Para obtener más información acerca de lo que se incluye de forma predeterminada, consulte the section called “Módulos incluidos con los trabajos de Ray”.

> **Note**
>
> Extracción, transformación y carga (ETL) de AWS Glue proporciona la abstracción de DynamicFrame para simplificar los flujos de trabajo de ETL en los que se resuelven las diferencias de esquema entre las filas en el conjunto de datos. AWS Glue ETL ofrece características adicionales: marcadores de trabajos y agrupación de archivos entrada. Por el momento, no proporcionamos las características correspondientes en los trabajos de Ray. AWS Glue para Spark ofrece asistencia directa para conectarse a determinados formatos, orígenes y receptores de datos. En Ray, AWS SDK para pandas y bibliotecas externas actuales cubren sustancialmente esa necesidad. Deberá consultar esas bibliotecas para conocer las capacidades disponibles.

La integración de AWS Glue para Ray con Amazon VPC no está disponible actualmente. No se podrá acceder a los recursos de Amazon VPC sin una ruta pública. Para obtener más información acerca del uso de AWS Glue con Amazon VPC, consulte the section called “Configuración de puntos de conexión de la VPC de tipo interfaz (AWS PrivateLink) para AWS Glue ”.

Bibliotecas comunes para trabajar con datos en Ray

Ray Data: Ray Data proporciona métodos para gestionar formatos, orígenes y receptores de datos comunes. Para obtener más información sobre los formatos y orígenes compatibles con Ray Data, consulte Input/Output en la documentación de Ray Data. Ray Data es una biblioteca obstinada, en lugar de una biblioteca de uso general, para gestionar conjuntos de datos.

Ray proporciona cierta orientación sobre los casos de uso en los que Ray Data podría ser la mejor solución para su trabajo. Para obtener más información, consulte Casos de uso de Ray en la documentación de Ray.

AWS SDK para pandas (awswrangler): AWS SDK es un producto de AWS que ofrece soluciones limpias y probadas para leer y escribir en los servicios de AWS cuando las transformaciones

administran datos con DataFrames de pandas. Para obtener más información sobre los formatos y orígenes compatibles con AWS SDK para pandas, consulte API Reference en la documentación de AWS SDK para pandas.

Para ver ejemplos de cómo leer y escribir datos con AWS SDK para pandas, consulte Quick Start en la documentación de AWS SDK para pandas. AWS SDK para pandas no proporciona transformaciones para sus datos. Solo proporciona asistencia para leer y escribir desde las orígenes.

Modin: Modin es una biblioteca de Python que implementa operaciones comunes de pandas de forma distribuible. Para obtener más información sobre Modin, consulte la documentación de Mondin. Modin en sí no admite la lectura y la escritura a partir de orígenes. Proporciona implementaciones distribuidas de transformaciones comunes. AWS SDK para pandas admite Modin.

Cuando ejecuta Modin y AWS SDK para pandas juntos en un entorno de Ray, puede realizar tareas ETL habituales con resultados de alto rendimiento. Para obtener más información sobre el uso de Modin con AWS SDK para pandas, consulte At scale en la documentación de AWS SDK para pandas.

Otros esquemas: para obtener más información sobre los esquemas compatibles con Ray, consulte El ecosistema de Ray en la documentación de Ray. No ofrecemos soporte para otros marcos en el caso AWS Glue para Ray.

Conexión a los datos mediante el Catálogo de datos

AWS SDK para pandas admite la administración de los datos a través del Catálogo de datos junto con los trabajos de Ray. Para más información, consulte Glue Catalog (Catálogo de Glue) en el sitio web de AWS SDK para pandas.

Cómo utilizar este servicio con un AWS SDK

Los kits de desarrollo de software (SDK) de AWS se encuentran disponibles en muchos lenguajes de programación populares. Cada SDK proporciona una API, ejemplos de código y documentación que facilitan a los desarrolladores la creación de aplicaciones en su lenguaje preferido.

Documentación de SDK	Ejemplos de código
AWS SDK para C++	AWS SDK para C++ Ejemplos de código de la
AWS CLI	AWS CLI Ejemplos de código de la
AWS SDK para Go	AWS SDK para Go Ejemplos de código de la
AWS SDK para Java	AWS SDK para Java Ejemplos de código de la
AWS SDK para JavaScript	AWS SDK para JavaScript Ejemplos de código de la
AWS SDK para Kotlin	AWS SDK para Kotlin Ejemplos de código de la
AWS SDK para .NET	AWS SDK para .NET Ejemplos de código de la
AWS SDK para PHP	AWS SDK para PHP Ejemplos de código de la
Herramientas de AWS para PowerShell	Herramientas de AWS para PowerShell Ejemplos de código de la
AWS SDK para Python (Boto3)	AWS SDK para Python (Boto3) Ejemplos de código de la
AWS SDK para Ruby	AWS SDK para Ruby Ejemplos de código de la
AWS SDK para Rust	AWS SDK para Rust Ejemplos de código de la
AWS SDK para SAP ABAP	AWS SDK para SAP ABAP Ejemplos de código de la
AWS SDK para Swift	AWS SDK para Swift Ejemplos de código de la

Para obtener ejemplos específicos de este servicio, consulte Ejemplos de código de la API de AWS Glue con SDK de AWS.

> **Ejemplo de disponibilidad**
>
> ¿No encuentra lo que necesita? Solicite un ejemplo de código a través del enlace de Enviar comentarios que se encuentra al final de esta página.

API de AWS Glue

En esta sección se describen los tipos de datos y las primitivas que usan los SDK y las herramientas de AWS Glue. Existen tres formas generales de interactuar con AWS Glue por medio de un programa fuera de la Consola de administración de AWS, cada uno con su propia documentación:

- Las bibliotecas de SDK de idiomas le permiten acceder a recursos de AWS de lenguajes de programación comunes. Encuentre más información en Herramientas para crear en AWS.
- La AWS CLI le permite acceder a recursos de AWS en la línea de comandos. Encuentre más información en Referencia de comandos de la AWS CLI.
- CloudFormation le permite definir un conjunto de recursos de AWS que deben disponerse juntos de forma coherente. Encuentre más información en CloudFormation: Referencia de tipos de recursos de AWS Glue.

En esta sección se registran las primitivas compartidas independientemente de estos SDK y herramientas. Las herramientas usan la Referencia de la API web de AWS Glue para comunicarse con AWS.

Contenido

- API de seguridad en AWS Glue
  - Tipos de datos
  - DataCatalogEncryptionSettings structure
  - Estructura EncryptionAtRest
  - Estructura ConnectionPasswordEncryption
  - Estructura EncryptionConfiguration
  - Estructura S3Encryption
  - Estructura CloudWatchEncryption
  - Estructura JobBookmarksEncryption
  - Estructura SecurityConfiguration
  - Estructura GluePolicy
  - Estructura DataQualityEncryption
  - Operaciones
  - Acción GetDataCatalogEncryptionSettings (Python: get_data_catalog_encryption_settings)

- Acción PutDataCatalogEncryptionSettings (Python: put_data_catalog_encryption_settings)
- Acción PutResourcePolicy (Python: put_resource_policy)
- Acción GetResourcePolicy (Python: get_resource_policy)
- Acción DeleteResourcePolicy (Python: delete_resource_policy)
- Acción CreateSecurityConfiguration (Python: create_security_configuration)
- Acción DeleteSecurityConfiguration (Python: delete_security_configuration)
- Acción GetSecurityConfiguration (Python: get_security_configuration)
- Acción GetSecurityConfigurations (Python: get_security_configurations)
- Acción GetResourcePolicies (Python: get_resource_policies)
- API de objetos del catálogo
  - API de catálogos
    - Tipos de datos
    - Estructura del catálogo
    - Estructura CatalogInput
    - Estructura TargetRedshiftCatalog
    - Estructura CatalogoProperties
    - Estructura CatalogPropertiesOutput
    - Estructura de DataLakeAccessProperties
    - Estructura IcebergOptimizationProperties
    - Estructura de DataLakeAccessPropertiesOutput
    - Estructura IcebergOptimizationPropertiesOutput
    - Estructura FederatedCatalog
    - Operaciones
    - Acción CreateCatalog (Python: create_catalog)
    - Acción UpdateCatalog (Python: update_catalog)
    - Acción DeleteCatalog (Python: delete_catalog)
    - Acción GetCatalog (Python: get_catalog)
    - Acción GetCatalogs (Python: get_catalogs)
  - API de la base de datos
    - Tipos de datos

- Estructura de base de datos
- Estructura DatabaseInput
- Estructura PrincipalPermissions
- Estructura DataLakePrincipal
- Estructura DatabaseIdentifier
- Estructura de FederatedDatabase
- Operaciones
- Acción CreateDatabase (Python: create_database)
- Acción UpdateDatabase (Python: update_database)
- Acción DeleteDatabase (Python: delete_database)
- Acción GetDatabase (Python: get_database)
- Acción GetDatabases (Python: get_databases)

- API de tabla
  - Tipos de datos
  - Estructura de tabla
  - Estructura TableInput
  - Estructura de FederatedTable
  - Estructura de las columnas
  - Estructura StorageDescriptor
  - Estructura SchemaReference
  - Estructura SerDeInfo
  - Estructura Order
  - Estructura SkewedInfo
  - Estructura TableVersion
  - Estructura TableError
  - Estructura TableVersionError
  - Estructura SortCriterion
  - Estructura TableIdentifier
  - Estructura KeySchemaElement
  - Estructura PartitionIndex

- Estructura PartitionIndexDescriptor
- Estructura BackFillError
- Estructura de IcebergInput
- Estructura de OpenTableFormatInput
- Estructura ViewDefinition
- Estructura ViewDefinitionInput
- Estructura ViewRepresentation
- Estructura ViewRepresentationInput
- Estructura UpdateOpenTableFormatInput
- Estructura UpdateIcebergInput
- Estructura CreateIcebergTableInput
- Estructura UpdateIcebergTableInput
- Estructura IcebergSortOrder
- Estructura IcebergSortField
- Estructura IcebergPartitionSpec
- Estructura IcebergPartitionField
- Estructura IcebergSchema
- Estructura IcebergStructField
- Estructura IcebergTableUpdate
- Estructura de AuditContext
- Operaciones
- Acción CreateTable (Python: create_table)
- Acción UpdateTable (Python: update_table)
- Acción DeleteTable (Python: delete_table)
- Acción BatchDeleteTable (Python: batch_delete_table)
- Acción GetTable (Python: get_table)
- Acción GetTables (Python: get_tables)
- Acción GetTableVersion (Python: get_table_version)
- Acción GetTableVersions (Python: get_table_versions)
- Acción DeleteTableVersion (Python: delete_table_version)

- Acción BatchDeleteTableVersion (Python: batch_delete_table_version)
- Acción SearchTables (Python: search_tables)
- Acción GetPartitionIndexes (Python: get_partition_indexes)
- Acción CreatePartitionIndex (Python: create_partition_index)
- Acción DeletePartitionIndex (Python: delete_partition_index)
- Acción GetColumnStatisticsForTable (Python: get_column_statistics_for_table)
- Acción UpdateColumnStatisticsForTable (Python: update_column_statistics_for_table)
- Acción DeleteColumnStatisticsForTable (Python: delete_column_statistics_for_table)

- API de partición
  - Tipos de datos
  - Estructura Partition
  - Estructura PartitionInput
  - Estructura PartitionSpecWithSharedStorageDescriptor
  - Estructura PartitionListComposingSpec
  - Estructura PartitionSpecProxy
  - Estructura PartitionValueList
  - Estructura Segment
  - Estructura PartitionError
  - Estructura BatchUpdatePartitionFailureEntry
  - Estructura BatchUpdatePartitionRequestEntry
  - Estructura StorageDescriptor
  - Estructura SchemaReference
  - Estructura SerDeInfo
  - Estructura SkewedInfo
  - Operaciones
  - Acción CreatePartition (Python: create_partition)
  - Acción BatchCreatePartition (Python: batch_create_partition)
  - Acción UpdatePartition (Python: update_partition)
  - Acción DeletePartition (Python: delete_partition)
  - Acción BatchDeletePartition (Python: batch_delete_partition)

- Acción GetPartition (Python: get_partition)
- Acción GetPartitions (Python: get_partitions)
- Acción BatchGetPartition (Python: batch_get_partition)
- Acción BatchUpdatePartition (Python: batch_update_partition)
- Acción GetColumnStatisticsForPartition (Python: get_column_statistics_for_partition)
- Acción UpdateColumnStatisticsForPartition (Python: update_column_statistics_for_partition)
- Acción DeleteColumnStatisticsForPartition (Python: delete_column_statistics_for_partition)

- API de conexión
  - API de conexión
    - Tipos de datos
    - Estructura Connection
    - Estructura ConnectionInput
    - Estructura TestConnectionInput
    - Estructura PhysicalConnectionRequirements
    - Estructura GetConnectionsFilter
    - Estructura AuthenticationConfiguration
    - Estructura AuthenticationConfigurationInput
    - Estructura OAuth2Properties
    - Estructura OAuth2PropertiesInput
    - Estructura OAuth2ClientApplication
    - Estructura AuthorizationCodeProperties
    - Estructura BasicAuthenticationCredentials
    - Estructura OAuth2Credentials
    - Operaciones
    - Acción CreateConnection (Python: create_connection)
    - Acción DeleteConnection (Python: delete_connection)
    - Acción GetConnection (Python: get_connection)
    - Acción GetConnections (Python: get_connections)
    - Acción UpdateConnection (Python: update_connection)
    - Acción TestConnection (Python: test_connection)

        - Acción BatchDeleteConnection (Python: batch_delete_connection)
    - API de tipos de conexión
        - API de administración de conexiones
        - Acción DescribeConnectionType (Python: describe_connection_type)
        - Acción ListConnectionTypes (Python: list_connection_types)
        - Estructura ConnectionTypeBrief
        - Estructura ConnectionTypeVariant
        - datatypes
        - Estructura de Validación
        - Estructura AuthConfiguration
        - Estructura de capacidades
        - Estructura de propiedad
        - Estructura AllowedValue
        - Estructura ComputeEnvironmentConfiguration
    - API de vista previa y metadatos de conexión
        - Tipos de datos
        - Estructura de la entidad
        - Estructura de campo
        - Operaciones
        - Acción ListEntities (Python: list_entities)
        - Acción DescribeEntity (Python: describe_entity)
        - Acción GetEntityRecords (Python: get_entity_records)
- API de funciones definidas por el usuario
    - Tipos de datos
    - Estructura UserDefinedFunction
    - Estructura UserDefinedFunctionInput
    - Operaciones
    - Acción CreateUserDefinedFunction (Python: create_user_defined_function)
    - Acción UpdateUserDefinedFunction (Python: update_user_defined_function)
    - Acción DeleteUserDefinedFunction (Python: delete_user_defined_function)

        - Acción GetUserDefinedFunction (Python: get_user_defined_function)
        - Acción GetUserDefinedFunctions (Python: get_user_defined_functions)
    - Importación de un catálogo de Athena a AWS Glue
        - Tipos de datos
        - Estructura CatalogImportStatus
        - Operaciones
        - Acción ImportCatalogToGlue (Python: import_catalog_to_glue)
        - Acción GetCatalogImportStatus (Python: get_catalog_import_status)
- API del optimizador de tablas
    - Tipos de datos
    - Estructura de TableOptimizer
    - Estructura de TableOptimizerConfiguration
    - Estructura de TableOptimizerVpcConfiguration
    - Estructura CompactionConfiguration
    - Estructura IcebergCompactionConfiguration
    - Estructura de TableOptimizerRun
    - Estructura de BatchGetTableOptimizerEntry
    - Estructura de BatchTableOptimizer
    - Estructura de BatchGetTableOptimizerError
    - Estructura de RetentionConfiguration
    - Estructura de IcebergRetentionConfiguration
    - Estructura de OrphanFileDeletionConfiguration
    - Estructura de IcebergOrphanFileDeletionConfiguration
    - Estructura de CompactionMetrics
    - Estructura de RetentionMetrics
    - Estructura de OrphanFileDeletionMetrics
    - Estructura de IcebergCompactionMetrics
    - Estructura de IcebergRetentionMetrics
    - Estructura de IcebergOrphanFileDeletionMetrics
    - Estructura RunMetrics

- Operaciones
- Acción GetTableOptimizer (Python: get_table_optimizer)
- Acción BatchGetTableOptimizer (Python: batch_get_table_optimizer)
- Acción ListTableOptimizerRuns (Python: list_table_optimizer_runs)
- Cción CreateTableOptimizer (Python: create_table_optimizer)
- Acción DeleteTableOptimizer (Python: delete_table_optimizer)
- Acción UpdateTableOptimizer (Python: update_table_optimizer)

- API de rastreadores y clasificadores
  - API de clasificador
    - Tipos de datos
    - Estructura Classifier
    - Estructura GrokClassifier
    - Estructura XMLClassifier
    - Estructura JsonClassifier
    - Estructura CsvClassifier
    - Estructura CreateGrokClassifierRequest
    - Estructura UpdateGrokClassifierRequest
    - Estructura CreateXMLClassifierRequest
    - Estructura UpdateXMLClassifierRequest
    - Estructura CreateJsonClassifierRequest
    - Estructura UpdateJsonClassifierRequest
    - Estructura CreateCsvClassifierRequest
    - Estructura UpdateCsvClassifierRequest
    - Operaciones
    - Acción CreateClassifier (Python: create_classifier)
    - Acción DeleteClassifier (Python: delete_classifier)
    - Acción GetClassifier (Python: get_classifier)
    - Acción GetClassifiers (Python: get_classifiers)
    - Acción UpdateClassifier (Python: update_classifier)
  - La API del rastreador

- Tipos de datos
- Estructura de rastreador
- Estructura de programación
- Estructura CrawlerTargets
- Estructura S3Target
- Estructura de S3DeltaCatalogTarget
- Estructura de S3DeltaDirectTarget
- Estructura JdbcTarget
- Estructura MongoDBTarget
- Estructura DynamoDBTarget
- Estructura DeltaTarget
- Estructura de IcebergTarget
- Estructura de HudiTarget
- Estructura CatalogTarget
- Estructura CrawlerMetrics
- Estructura de CrawlerHistory
- Estructura de CrawlsFilter
- Estructura SchemaChangePolicy
- Estructura LastCrawlInfo
- Estructura RecrawlPolicy
- Estructura LineageConfiguration
- Estructura LakeFormationConfiguration
- Operaciones
- Acción CreateCrawler (Python: create_crawler)
- Acción DeleteCrawler (Python: delete_crawler)
- Acción GetCrawler (Python: get_crawler)
- Acción GetCrawlers (Python: get_crawlers)
- Acción GetCrawlerMetrics (Python: get_crawler_metrics)
- Acción UpdateCrawler (Python: update_crawler)
- Acción StartCrawler (Python: start_crawler)

- Acción StopCrawler (Python: stop_crawler)
- Acción BatchGetCrawlers (Python: batch_get_crawlers)
- Acción ListCrawlers (Python: list_crawlers)
- Acción ListCrawls (Python: list_crawls)

- API de estadísticas de columna
  - Tipos de datos
  - Estructura ColumnStatisticsTaskRun
  - Estructura ColumnStatisticsTaskSettings
  - Estructura ExecutionAttempt
  - Operaciones
  - StartColumnStatisticsTaskRun action (Python: start_column_statistics_task_run)
  - GetColumnStatisticsTaskRun action (Python: get_column_statistics_task_run)
  - GetColumnStatisticsTaskRuns action (Python: get_column_statistics_task_runs)
  - ListColumnStatisticsTaskRuns action (Python: list_column_statistics_task_runs)
  - StopColumnStatisticsTaskRun action (Python: stop_column_statistics_task_run)
  - Acción CreateColumnStatisticsTaskSettings (Python: create_column_statistics_task_settings)
  - Acción UpdateColumnStatisticsTaskSettings (Python: update_column_statistics_task_settings)
  - Acción GetColumnStatisticsTaskSettings (Python: get_column_statistics_task_settings)
  - Acción DeleteColumnStatisticsTaskSettings (Python: delete_column_statistics_task_settings)
  - Acción StartColumnStatisticsTaskRunSchedule (Python: start_column_statistics_task_run_schedule)
  - Acción StopColumnStatisticsTaskRunSchedule (Python: stop_column_statistics_task_run_schedule)
  - Excepciones
  - Estructura ColumnStatisticsTaskRunningException
  - Estructura ColumnStatisticsTaskNotRunningException
  - Estructura ColumnStatisticsTaskStopingException
  - Estructura ColumnStatisticsTaskAutoConcurrencyLimitException

    - Estructura InvalidCatalogSettingException
  - API del programador del rastreador
    - Tipos de datos
    - Estructura de programación
    - Operaciones
    - Acción UpdateCrawlerSchedule (Python: update_crawler_schedule)
    - Acción StartCrawlerSchedule (Python: start_crawler_schedule)
    - Acción StopCrawlerSchedule (Python: stop_crawler_schedule)
- API de generación automática de scripts de ETL
  - Tipos de datos
  - Estructura CodeGenNode
  - Estructura CodeGenNodeArg
  - Estructura CodeGenEdge
  - Estructura de ubicación
  - Estructura CatalogEntry
  - Estructura MappingEntry
  - Operaciones
  - Acción CreateScript (Python: create_script)
  - Acción GetDataflowGraph (Python: get_dataflow_graph)
  - Acción GetMapping (Python: get_mapping)
  - Acción GetPlan (Python: get_plan)
- API de Visual Job
  - Tipos de datos
  - Estructura CodeGenConfigurationNode
  - Estructura JDBCConnectorOptions
  - Estructura StreamingDataPreviewOptions
  - Estructura AthenaConnectorSource
  - Estructura JDBCConnectorSource
  - Estructura SparkConnectorSource
  - Estructura CatalogSource

- Estructura MySQLCatalogSource
- Estructura PostgreSQLCatalogSource
- Estructura OracleSQLCatalogSource
- Estructura MicrosoftSQLServerCatalog
- Estructura CatalogKinesisSource
- Estructura DirectKinesisSource
- Estructura KinesisStreamingSourceOptions
- Estructura CatalogKafkaSource
- Estructura DirectKafkaSource
- Estructura KafkaStreamingSourceOptions
- Estructura RedshiftSource
- Estructura de AmazonRedshiftSource
- Estructura de AmazonRedshiftNodeData
- Estructura de AmazonRedshiftAdvancedOption
- Estructura de opción
- Estructura S3CatalogSource
- Estructura S3SourceAdditionalOptions
- Estructura S3CsvSource
- Estructura DirectJDBCSource
- Estructura S3DirectSourceAdditionalOptions
- Estructura S3JsonSource
- Estructura S3ParquetSource
- Estructura de S3DeltaSource
- Estructura de S3CatalogDeltaSource
- Estructura de CatalogDeltaSource
- Estructura S3HudiSource
- Estructura S3CatalogHudiSource
- Estructura S3ExcelSource
- Estructura CatalogHudiSource
- Estructura DynamoDBCatalogSource

- Estructura RelationalCatalogSource
- Estructura JDBCConnectorTarget
- Estructura SparkConnectorTarget
- Estructura BasicCatalogTarget
- Estructura MySQLCatalogTarget
- Estructura PostgreSQLCatalogSourceTarget
- Estructura OracleSQLCatalogTarget
- Estructura MicrosoftSQLServerCatalogTarget
- Estructura RedshiftTarget
- Estructura de AmazonRedshiftTarget
- Estructura UpsertRedShiftTargetOptions
- Estructura S3CatalogTarget
- Estructura S3GlueParquetTarget
- Estructura CatalogSchemaChangePolicy
- Estructura S3DirectTarget
- Estructura S3HudiCatalogTarget
- Estructura S3HudiDirectTarget
- Estructura de S3DeltaCatalogTarget
- Estructura de S3DeltaDirectTarget
- Estructura S3HyperDirectTarget
- Estructura S3IcebergDirectTarget
- Estructura DirectSchemaChangePolicy
- Estructura ApplyMapping
- Estructura de asignación
- Estructura SelectFields
- Estructura DropFields
- Estructura RenameField
- Estructura Spigot
- Estructura Join
- Estructura JoinColumn

- Estructura SplitFields
- Estructura SelectFromCollection
- Estructura FillMissingValues
- Estructura Filter
- Estructura FilterExpression
- Estructura FilterValue
- Estructura CustomCode
- Estructura SparkSQL
- Estructura SQLAlias
- Estructura DropNullFields
- Estructura NullCheckBoxList
- Estructura NullValueField
- Estructura Datatype
- Estructura Merge
- Estructura Union
- Estructura PIIDetection
- Estructura Aggregate
- Estructura DropDuplicates
- Estructura GovernedCatalogTarget
- Estructura GovernedCatalogSource
- Estructura AggregateOperation
- Estructura GlueSchema
- Estructura GlueStudioSchemaColumn
- Estructura GluStudioColumn
- Estructura de DynamicTransform
- Estructura de TransformConfigParameter
- Estructura de EvaluateDataQuality
- Estructura de DQResultsPublishingOptions
- Estructura de DQStopJobOnFailureOptions
- Estructura EvaluateDataQualityMultiFrame

- Estructura de receta
- Estructura RecipeReference
- Estructura de SnowflakeNodeData
- Estructura de SnowflakeSource
- Estructura de SnowflakeTarget
- Estructura de ConnectorDataSource
- Estructura de ConnectorDataTarget
- Estructura de RecipeStep
- Estructura de RecipeAction
- Estructura de ConditionExpression
- Estructura S3CatalogIcebergSource
- Estructura CatalogIcebergSource
- Estructura S3IcebergCatalogTarget
- Estructura DynamoDBELTConnectorSource
- Estructura DDBELTConnectionOptions
- Estructura DDBELTCatalogAdditionalOptions
- Estructura de rutas
- Estructura GroupFilters
- Estructura AutoDataQuality

- API de trabajos
  - Jobs
    - Tipos de datos
    - Estructura de trabajo
    - Estructura ExecutionProperty
    - Estructura NotificationProperty
    - Estructura JobCommand
    - Estructura ConnectionsList
    - Estructura JobUpdate
    - Estructura SourceControlDetails
    - Operaciones

- Acción CreateJob (Python: create_job)
- Acción UpdateJob (Python: update_job)
- Acción GetJob (Python: get_job)
- Acción GetJobs (Python: get_jobs)
- Acción DeleteJob (Python: delete_job)
- Acción ListJobs (Python: list_jobs)
- Acción BatchGetJobs (Python: batch_get_jobs)

- Ejecuciones de trabajo
  - Tipos de datos
  - Estructura JobRun
  - Estructura Predecessor
  - Estructura JobBookmarkEntry
  - Estructura BatchStopJobRunSuccessfulSubmission
  - Estructura BatchStopJobRunError
  - Estructura NotificationProperty
  - Operaciones
  - Acción StartJobRun (Python: start_job_run)
  - Acción BatchStopJobRun (Python: batch_stop_job_run)
  - Acción GetJobRun (Python: get_job_run)
  - Acción GetJobRuns (Python: get_job_runs)
  - Acción GetJobBookmark (Python: get_job_bookmark)
  - Acción GetJobBookmarks (Python: get_job_bookmarks)
  - Acción ResetJobBookmark (Python: reset_job_bookmark)

- Desencadenadores
  - Tipos de datos
  - Estructura del desencadenador
  - Estructura de TriggerUpdate
  - Estructura de Predicate
  - Estructura de Condition
  - Estructura de acción

- Estructura EventBatchingCondition
- Operaciones
- Acción CreateTrigger (Python: create_trigger)
- Acción StartTrigger (Python: start_trigger)
- Acción GetTrigger (Python: get_trigger)
- Acción GetTriggers (Python: get_triggers)
- Acción UpdateTrigger (Python: update_trigger)
- Acción StopTrigger (Python: stop_trigger)
- Acción DeleteTrigger (Python: delete_trigger)
- Acción ListTriggers (Python: list_triggers)
- Acción BatchGetTriggers (Python: batch_get_triggers)

- API de integración en AWS Glue
  - Tipos de datos
  - Estructura de integración
  - Estructura IntegrationConfig
  - Estructura IntegrationPartition
  - Estructura IntegrationError
  - Estructura IntegrationFilter
  - Estructura InboundIntegration
  - Estructura SourceProcessingProperties
  - Estructura TargetProcessingProperties
  - Estructura SourceTableConfig
  - Estructura TargetTableConfig
  - Operaciones
  - Acción CreateIntegration (Python: create_integration)
  - Acción ModificyIntegration (Python: modify_integration)
  - Acción DescribeIntegrations (Python: describe_integrations)
  - Acción DeleteIntegration (Python: delete_integration)
  - Acción DescribeInboundIntegrations (Python: describe_inbound_integrations)
  - Acción CreateIntegrationTableProperties (Python: create_integration_table_properties)

- Acción UpdateIntegrationTableProperties (Python: update_integration_properties)
- Acción GetIntegrationTableProperties (Python: get_integration_table_properties)
- Acción DeleteIntegrationTableProperties (Python: delete_integration_table_properties)
- Acción CreateIntegrationResourceProperty (Python: create_integration_resource_property)
- Acción UpdateIntegrationResourceProperty (Python: update_integration_resource_property)
- Acción GetIntegrationResourceProperty (Python: get_integration_resource_property)
- Acción UntagResource (Python: untag_resource)
- Acción ListTagsForResource (Python: list_tags_for_resource)
- Excepciones
- Estructura ResourceNotFoundException
- Estructura InternalServerException
- Estructura IntegrationAlreadyExistsFault
- Estructura IntegrationConflictOperationFault
- Estructura IntegrationQuotaExceededFault
- Estructura KMSKeyNotAccessibleFault
- Estructura IntegrationNotFoundFault
- Estructura TargetResourceNotFound
- Estructura InvalidIntegrationStateFault
- API de sesiones interactivas
  - Tipos de datos
  - Estructura de sesión
  - Estructura SessionCommand
  - Estructura de instrucción
  - Estructura SchetumentOutput
  - Estructura StatementOutputData
  - Estructura ConnectionsList
  - Operaciones
  - Acción CreateSession (Python: create_session)
  - Acción StopSession (Python: stop_session)
  - Acción DeleteSession (Python: delete_session)

- Acción GetSession (Python: get_session)
- Acción ListSessions (Python: list_sessions)
- Acción RunStatement (Python: run_statement)
- Acción CancelStatement (Python: cancel_statement)
- Acción GetStatement (Python: get_statement)
- Acción ListStatements (Python: list_statement)
- Acción GetGlueIdentityCenterConfiguration (Python: get_glue_identity_center_configuration)
- Acción UpdateBlueIdentityCenterConfiguration (Python: update_glue_identity_center_configuration)
- Acción CreateBlueIdentityCenter_Configuration (Python: create_glue_identity_center_configuration)
- Acción DeleteGlueIdentityCenterConfiguration (Python: delete_glue_identity_center_configuration)

- API de puntos de conexión de desarrollo
  - Tipos de datos
  - Estructura DevEndpoint
  - Estructura DevEndpointCustomLibraries
  - Operaciones
  - Acción CreateDevEndpoint (Python: create_dev_endpoint)
  - Acción UpdateDevEndpoint (Python: update_dev_endpoint)
  - Acción DeleteDevEndpoint (Python: delete_dev_endpoint)
  - Acción GetDevEndpoint (Python: get_dev_endpoint)
  - Acción GetDevEndpoints (Python: get_dev_endpoints)
  - Acción BatchGetDevEndpoints (Python: batch_get_dev_endpoints)
  - Acción ListDevEndpoints (Python: list_dev_endpoints)
- Schema Registry
  - Tipos de datos
  - Estructura RegistryId
  - Estructura RegistryListItem
  - Estructura MetadataInfo
  - Estructura OtherMetadataValueListItem

- Estructura SchemaListItem
- Estructura SchemaVersionListItem
- Estructura MetadataKeyValuePair
- Estructura SchemaVersionErrorItem
- Estructura ErrorDetails
- Estructura SchemaVersionNumber
- Estructura SchemaId
- Operaciones
- Acción CreateRegistry (Python: create_registry)
- Acción CreateSchema (Python: create_schema)
- Acción GetSchema (Python: get_schema)
- Acción ListSchemaVersions (Python: list_schema_versions)
- Acción GetSchemaVersion (Python: get_schema_version)
- Acción GetSchemaVersionsDiff (Python: get_schema_versions_diff)
- Acción ListRegistries (Python: list_registries)
- Acción ListSchemas (Python: list_schemas)
- Acción RegisterSchemaVersion (Python: register_schema_version)
- Acción UpdateSchema (Python: update_schema)
- Acción CheckSchemaVersionValidity (Python: check_schema_version_validity)
- Acción UpdateRegistry (Python: update_registry)
- Acción GetSchemabyDefinition (Python: get_schema_by_definition)
- Acción GetRegistry (Python: get_registry)
- Acción PutSchemaVersionMetadata (Python: put_schema_version_metadata)
- Acción QuerySchemaVersionMetadata (Python: query_schema_version_metadata)
- Acción RemoveSchemaVersionMetadata (Python: remove_schema_version_metadata)
- Acción DeleteRegistry (Python: delete_registry)
- Acción DeleteSchema (Python: delete_schema)
- Acción DeleteSchemaVersions (Python: delete_schema_versions)

- Flujos de trabajo
  - Tipos de datos

- Estructura JobNodeDetails
- Estructura CrawlerNodeDetails
- Estructura TriggerNodeDetails
- Estructura de rastreo
- Estructura de nodos
- Estructura perimetral
- Estructura de flujo de trabajo
- Estructura WorkflowGraph
- Estructura WorkflowRun
- Estructura WorkflowRunStatistics
- Estructura StartingEventBatchCondition
- Estructura de proyecto
- Estructura BlueprintDetails
- Estructura LastActiveDefinition
- Estructura BlueprintRun
- Operaciones
- Acción CreateWorkflow (Python: create_workflow)
- Acción UpdateWorkflow (Python: update_workflow)
- DeleteWorkflow Action (Python: delete_workflow)
- Acción GetWorkFlow (Python: get_workflow)
- Acción ListWorkflows (Python: list_workflows)
- Acción BatchGetWorkflows (Python: batch_get_workflows)
- Acción GetWorkflowRun (Python: get_workflow_run)
- Acción GetWorkflowRuns (Python: get_workflow_runs)
- Acción GetWorkflowRunProperties (Python: get_workflow_run_properties)
- PutWorkflowRunProperties Action (Python: put_workflow_run_properties)
- Acción CreateBlueprint (Python: create_blueprint)
- Acción UpdateBlueprint (Python: update_blueprint)
- Acción DeleteBlueprint (Python: delete_blueprint)
- Acción ListBlueprints (Python: list_blueprints)

- Acción BatchGetBlueprints (Python: batch_get_blueprints)
- Acción StartBlueprintRun (Python: start_blueprint_run)
- Acción GetBlueprintRun (Python: get_blueprint_run)
- Acción GetBlueprintRuns (Python: get_blueprint_runs)
- Acción StartWorkflowRun (Python: start_workflow_run)
- Acción StopWorkflowRun (Python: stop_workflow_run)
- Acción ResumeWorkflowRun (Python: resume_workflow_run)

- Perfiles de uso
  - Tipos de datos
  - Estructura ProfileConfiguration
  - Estructura ConfigurationObject
  - Estructura UsageProfileDefinition
  - Operaciones
  - Acción CreateUsageProfile (Python: create_usage_profile)
  - Acción GetUsageProfile (Python: get_usage_profile)
  - Acción UpdateUsageProfile (Python: update_usage_profile)
  - Acción DeleteUsageProfile (Python: delete_usage_profile)
  - Acción ListUsageProfiles (Python: list_usage_profiles)
- API de machine learning
  - Tipos de datos
  - Estructura TransformParameters
  - Estructura EvaluationMetrics
  - Estructura MLTransform
  - Estructura FindMatchesParameters
  - Estructura FindMatchesMetrics
  - Estructura ConfusionMatrix
  - Estructura GlueTable
  - Estructura TaskRun
  - Estructura TransformFilterCriteria
  - Estructura TransformSortCriteria

- Estructura TaskRunFilterCriteria
- Estructura TaskRunSortCriteria
- Estructura TaskRunProperties
- Estructura FindMatchesTaskRunProperties
- Estructura ImportLabelsTaskRunProperties
- Estructura ExportLabelsTaskRunProperties
- Estructura LabelingSetGenerationTaskRunProperties
- Estructura SchemaColumn
- Estructura TransformEncryption
- Estructura MLUserDataEncryption
- Estructura ColumnImportance
- Operaciones
- Acción CreateMLTransform (Python: create_ml_transform)
- Acción UpdateMLTransform (Python: update_ml_transform)
- Acción DeleteMLTransform (Python: delete_ml_transform)
- Acción GetMLTransform (Python: get_ml_transform)
- Acción GetMLTransforms (Python: get_ml_transforms)
- Acción ListMLTransforms (Python: list_ml_transforms)
- Acción StartMLEvaluationTaskRun (Python: start_ml_evaluation_task_run)
- Acción StartMLLabelingSetGenerationTaskRun (Python: start_ml_labeling_set_generation_task_run)
- Acción GetMLTaskRun (Python: get_ml_task_run)
- Acción GetMLTaskRuns (Python: get_ml_task_runs)
- Acción CancelMLTaskRun (Python: cancel_ml_task_run)
- Acción StartExportLabelsTaskRun (Python: start_export_labels_task_run)
- Acción StartImportLabelsTaskRun (Python: start_import_labels_task_run)

- API de Calidad de datos
  - Tipos de datos
  - Estructura de DataSource

  - Estructura de DataQualityRulesetListDetails

- Estructura de DataQualityTargetTable
- Estructura de DataQualityRulesetEvaluationRunDescription
- Estructura de DataQualityRulesetEvaluationRunFilter
- Estructura de DataQualityEvaluationRunAdditionalRunOptions
- Estructura de DataQualityRuleRecommendationRunDescription
- Estructura de DataQualityRuleRecommendationRunFilter
- Estructura de DataQualityResult
- Estructura de DataQualityAnalyzerResult
- Estructura de DataQualityObservation
- Estructura de MetricBasedObservation
- Estructura de DataQualityMetricValues
- Estructura de DataQualityRuleResult
- Estructura de DataQualityResultDescription
- Estructura de DataQualityResultFilterCriteria
- Estructura de DataQualityRulesetFilterCriteria
- Estructura DataQualityAggregatedMetrics
- Estructura StatisticAnnotation
- Estructura TimestampedInclusionAnnotation
- Estructura AnnotationError
- Estructura DatapointInclusionAnnotation
- Lista StatisticSummaryList
- Estructura StatisticSummary
- Estructura RunIdentifier
- Estructura StatisticModelResult
- Estructura de DataQualityGlueTable
- Operaciones
- Acción StartDataQualityRulesetEvaluationRun (Python: start_data_quality_ruleset_evaluation_run)
- Acción CancelDataQualityRulesetEvaluationRun (Python: cancel_data_quality_ruleset_evaluation_run)
- Acción GetDataQualityRulesetEvaluationRun (Python: get_data_quality_ruleset_evaluation_run)

- Acción ListDataQualityRulesetEvaluationRuns (Python: list_data_quality_ruleset_evaluation_runs)
- Acción StartDataQualityRuleRecommendationRun (Python: start_data_quality_rule_recommendation_run)
- Acción CancelDataQualityRuleRecommendationRun (Python: cancel_data_quality_rule_recommendation_run)
- Acción GetDataQualityRuleRecommendationRun (Python: get_data_quality_rule_recommendation_run)
- Acción ListDataQualityRuleRecommendationRuns (Python: list_data_quality_rule_recommendation_runs)
- Acción GetDataQualityResult (Python: get_data_quality_result)
- Acción BatchGetDataQualityResult (Python: batch_get_data_quality_result)
- Acción ListDataQualityResults (Python: list_data_quality_results)
- Acción CreateDataQualityRuleset (Python: create_data_quality_ruleset)
- Acción DeleteDataQualityRuleset (Python: delete_data_quality_ruleset)
- Acción GetDataQualityRuleset (Python: get_data_quality_ruleset)
- Acción ListDataQualityRulesets (Python: list_data_quality_rulesets)
- Acción UpdateDataQualityRuleset (Python: update_data_quality_ruleset)
- Acción ListDataQualityStatistics (Python: list_data_quality_statistics)
- Estructura TimestampFilter
- Estructura CreateDataQualityRulesetRequest
- Estructura GetDataQualityRulesetResponse
- Estructura GetDataQualityResultResponse
- Estructura StartDataQualityRuleRecommendationRunRequest
- Estructura GetDataQualityRuleRecommendationRunResponse
- Acción BatchPutDataQualityStatisticAnnotation (Python: batch_put_data_quality_statistic_annotation)
- Acción GetDataQualityModel (Python: get_data_quality_model)
- Acción GetDataQualityModelResult (Python: get_data_quality_model_result)
- Acción ListDataQualityStatisticAnnotations (Python: list_data_quality_statistic_annotations)
- Acción PutDataQualityProfileAnnotation (Python: put_data_quality_profile_annotation)

- API de detección de información confidencial
  - Tipos de datos
  - Estructura CustomEntityType
  - Operaciones
  - Acción CreateCustomEntityType (Python: create_custom_entity_type)
  - Acción DeleteCustomEntityType (Python: delete_custom_entity_type)
  - Acción GetCustomEntityType (Python: get_custom_entity_type)
  - Acción BatchGetCustomEntityTypes (Python: batch_get_custom_entity_types)
  - Acción ListCustomEntityTypes (Python: list_custom_entity_types)
- API de etiquetado en AWS Glue
  - Tipos de datos
  - Estructura de etiquetas
  - Operaciones
  - Acción TagResource (Python: tag_resource)
  - Acción UntagResource (Python: untag_resource)
  - Acción GetTags (Python: get_tags)
- Tipos de datos comunes
  - Estructura de etiquetas
  - Estructura DecimalNumber
  - Estructura ErrorDetail
  - Estructura PropertyPredicate
  - Estructura ResourceUri
  - Estructura ColumnStatistics
  - Estructura ColumnStatisticsError
  - Estructura ColumnError
  - Estructura ColumnStatisticsData
  - Estructura BooleanColumnStatisticsData
  - Estructura DateColumnStatisticsData
  - Estructura DecimalColumnStatisticsData
  - Estructura DoubleColumnStatisticsData

- Estructura LongColumnStatisticsData
- Estructura StringColumnStatisticsData
- Estructura BinaryColumnStatisticsData
- Patrones de cadena

- Excepciones
  - Estructura AccessDeniedException
  - Estructura de AlreadyExistsException
  - Estructura ConcurrentModificationException
  - Estructura ConcurrentRunsExceededException
  - Estructura CrawlerNotRunningException
  - Estructura CrawlerRunningException
  - Estructura CrawlerStoppingException
  - Estructura EntityNotFoundException
  - Estructura de FederationSourceException
  - Estructura de FederationSourceRetryableException
  - Estructura GlueEncryptionException
  - Estructura IdempotentParameterMismatchException
  - Estructura IllegalWorkflowStateException
  - Estructura InternalServiceException
  - Estructura InvalidExecutionEngineException
  - Estructura InvalidInputException
  - Estructura InvalidStateException
  - Estructura InvalidTaskStatusTransitionException
  - Estructura JobDefinitionErrorException
  - Estructura JobRunInTerminalStateException
  - Estructura JobRunInvalidStateTransitionException
  - Estructura JobRunNotInTerminalStateException
  - Estructura LateRunnerException
  - Estructura NoScheduleException
  - Estructura OperationTimeoutException

- Estructura ResourceNotReadyException
- Estructura ResourceNumberLimitExceededException
- Estructura SchedulerNotRunningException
- Estructura SchedulerRunningException
- Estructura SchedulerTransitioningException
- Estructura UnrecognizedRunnerException
- Estructura ValidationException
- Estructura VersionMismatchException

API de seguridad en AWS Glue

La API de seguridad describe los tipos de datos de seguridad y la API relacionada con la seguridad en AWS Glue.

Tipos de datos

- DataCatalogEncryptionSettings structure
- Estructura EncryptionAtRest
- Estructura ConnectionPasswordEncryption
- Estructura EncryptionConfiguration
- Estructura S3Encryption
- Estructura CloudWatchEncryption
- Estructura JobBookmarksEncryption
- Estructura SecurityConfiguration
- Estructura GluePolicy
- Estructura DataQualityEncryption

DataCatalogEncryptionSettings structure

Contiene información de configuración para mantener la seguridad del catálogo de datos.

Campos

- `EncryptionAtRest`: un objeto EncryptionAtRest.

Especifica la configuración de cifrado en reposo del catálogo de datos.

- `ConnectionPasswordEncryption`: un objeto ConnectionPasswordEncryption.

  Cuando está habilitada la protección de la contraseña de conexión, el catálogo de datos utiliza una clave proporcionada por el cliente para cifrar la contraseña como parte de `CreateConnection` o `UpdateConnection`, y almacenarla en el campo `ENCRYPTED_PASSWORD` de las propiedades de conexión. Puede habilitar el cifrado de catálogo o cifrado de solo por contraseña.

Estructura EncryptionAtRest

Especifica la configuración de cifrado en reposo del catálogo de datos.

Campos

- `CatalogEncryptionMode` – Obligatorio: cadena UTF-8 (valores válidos: `DISABLED` | `SSE-KMS="SSEKMS"` | `SSE-KMS-WITH-SERVICE-ROLE="SSEKMSWITHSERVICEROLE"`).

  Modo de cifrado en reposo para cifrar los datos del catálogo de datos.

- `SseAwsKmsKeyId` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de la clave AWS KMS que se debe usar para el cifrado en reposo.

- `CatalogEncryptionServiceRole` – cadena UTF-8 que coincide con el Custom string pattern #53.

  El rol que asume AWS Glue para cifrar y descifrar los objetos del Catálogo de datos en nombre de quien realiza la llamada.

Estructura ConnectionPasswordEncryption

La estructura de datos que utiliza el catálogo de datos para cifrar la contraseña como parte de `CreateConnection` o `UpdateConnection`, y almacenarla en el campo `ENCRYPTED_PASSWORD` de las propiedades de conexión. Puede habilitar el cifrado de catálogo o cifrado de solo por contraseña.

Cuando llega una solicitud `CreationConnection` que contiene una contraseña, el Data Catalog primero cifra la contraseña usando su clave AWS KMS. A continuación, vuelve a cifrar todo el objeto de conexión si también está activada el cifrado de catálogo.

Este cifrado requiere que configure los permisos de clave AWS KMS KMS para habilitar o restringir el acceso a la clave de contraseña de acuerdo con sus requisitos de seguridad. Por ejemplo, es posible que desee que solo los administradores tengan permiso para descifrar la clave de contraseña.

Campos

- `ReturnConnectionPasswordEncrypted` – Obligatorio: Booleano.

  Cuando la marca `ReturnConnectionPasswordEncrypted` se establece en “true”, las contraseñas permanecen cifradas en las respuestas de `GetConnection` y `GetConnections`. Este cifrado tiene efecto independientemente del cifrado del catálogo.
- `AwsKmsKeyId` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Una clave AWS KMS que se utiliza para cifrar la contraseña de conexión.

  Si la protección de la contraseña de conexión está habilitada, el que realiza la llamada de `CreateConnection` y `UpdateConnection` necesita, al menos, permiso `kms:Encrypt` en la clave AWS KMS especificada para cifrar las contraseñas antes de almacenarlas en el Data Catalog.

  Puede establecer el permiso de descifrado para habilitar o restringir el acceso a la clave de contraseña de acuerdo con sus requisitos de seguridad.

Estructura EncryptionConfiguration

Especifica una configuración de cifrado.

Campos

- `S3Encryption`: matriz de objetos S3Encryption.

  La configuración de cifrado de datos de Amazon Simple Storage Service (Amazon S3).
- `CloudWatchEncryption`: un objeto CloudWatchEncryption.

  La configuración de cifrado para Amazon CloudWatch.

- `JobBookmarksEncryption`: un objeto JobBookmarksEncryption.

  La configuración de cifrado para marcadores de trabajo.

- `DataQualityEncryption`: un objeto DataQualityEncryption.

  La configuración de cifrado para los activos de AWS Glue Data Quality.

Estructura S3Encryption

Especifica cómo se deben cifrar los datos de Amazon Simple Storage Service (Amazon S3).

Campos

- `S3EncryptionMode` – Cadena UTF-8 (valores válidos: `DISABLED` | `SSE-KMS="SSEKMS"` | `SSE-S3="SSES3"`).

  El modo de cifrado que usar para datos de Amazon S3.

- `KmsKeyArn` – cadena UTF-8 que coincide con el Custom string pattern #42.

  El nombre de recurso de Amazon (ARN) de la clave de KMS que utilizar para cifrar los datos.

Estructura CloudWatchEncryption

Especifica cómo se deben cifrar los datos de Amazon CloudWatch.

Campos

- `CloudWatchEncryptionMode` – Cadena UTF-8 (valores válidos: `DISABLED` | `SSE-KMS="SSEKMS"`).

  Modo de cifrado que usar para datos de CloudWatch.

- `KmsKeyArn` – cadena UTF-8 que coincide con el Custom string pattern #42.

  El nombre de recurso de Amazon (ARN) de la clave de KMS que utilizar para cifrar los datos.

Estructura JobBookmarksEncryption

Especifica cómo se deben cifrar los datos de los marcadores de trabajo.

Campos

- `JobBookmarksEncryptionMode` – Cadena UTF-8 (valores válidos: `DISABLED` | `CSE-KMS="CSEKMS"`).

  Modo de cifrado que usar para datos de marcadores de trabajos.

- `KmsKeyArn` – cadena UTF-8 que coincide con el Custom string pattern #42.

  El nombre de recurso de Amazon (ARN) de la clave de KMS que utilizar para cifrar los datos.

Estructura SecurityConfiguration

Especifica una configuración de seguridad.

Campos

- `Name` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la configuración de seguridad.

- `CreatedTimeStamp`: marca temporal.

  El momento en que se creó esta configuración de seguridad.

- `EncryptionConfiguration`: un objeto EncryptionConfiguration.

  La configuración de cifrado asociada con esta configuración de seguridad.

Estructura GluePolicy

Estructura para devolver una política de recursos.

Campos

- `PolicyInJson`: cadena UTF-8 de 2 bytes de largo como mínimo.

  Contiene el documento de política solicitado, en formato JSON.

- `PolicyHash` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

Contiene el valor de hash asociado a esta política.

- `CreateTime`: marca temporal.

  La fecha y hora en la que se creó la política.

- `UpdateTime`: marca temporal.

  La fecha y hora en la que se actualizó la política por última vez.

Estructura DataQualityEncryption

Especifica cómo deben cifrarse los activos de Data Quality en su cuenta.

Campos

- `DataQualityEncryptionMode` – Cadena UTF-8 (valores válidos: `DISABLED` | `SSE-KMS="SSEKMS"`).

  El modo de cifrado que se utilizará para cifrar los activos de Data Quality. Estos activos incluyen conjuntos de reglas de calidad de datos, resultados, estadísticas, modelos de detección de anomalías y observaciones.

  Los valores válidos son `SSEKMS` para el cifrado mediante una clave KMS administrada por el cliente, o `DISABLED`.

- `KmsKeyArn` – cadena UTF-8 que coincide con el Custom string pattern #42.

  El nombre de recurso de Amazon (ARN) de la clave de KMS que utilizar para cifrar los datos.

Operaciones

- Acción GetDataCatalogEncryptionSettings (Python: get_data_catalog_encryption_settings)
- Acción PutDataCatalogEncryptionSettings (Python: put_data_catalog_encryption_settings)
- Acción PutResourcePolicy (Python: put_resource_policy)
- Acción GetResourcePolicy (Python: get_resource_policy)
- Acción DeleteResourcePolicy (Python: delete_resource_policy)
- Acción CreateSecurityConfiguration (Python: create_security_configuration)
- Acción DeleteSecurityConfiguration (Python: delete_security_configuration)

- Acción GetSecurityConfiguration (Python: get_security_configuration)
- Acción GetSecurityConfigurations (Python: get_security_configurations)
- Acción GetResourcePolicies (Python: get_resource_policies)

Acción GetDataCatalogEncryptionSettings (Python: get_data_catalog_encryption_settings)

Recupera la configuración de seguridad para un catálogo especificado.

Solicitud

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del catálogo de datos para el que recuperar la configuración de seguridad. Si no se proporciona ninguno, se usará de forma predeterminada el ID de cuenta de AWS.

Respuesta

- `DataCatalogEncryptionSettings`: un objeto DataCatalogEncryptionSettings.

  La configuración de seguridad solicitada.

Errores

- `InternalServiceException`
- `InvalidInputException`
- `OperationTimeoutException`

Acción PutDataCatalogEncryptionSettings (Python: put_data_catalog_encryption_settings)

Establece la configuración de seguridad para un catálogo especificado. Después de que se ha establecido la configuración, a partir de entonces, se aplicará el cifrado especificado a cada escritura de catálogos.

Solicitud

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del catálogo de datos para el que establecer la configuración de seguridad. Si no se proporciona ninguno, se usará de forma predeterminada el ID de cuenta de AWS.
- `DataCatalogEncryptionSettings`: obligatorio: objeto DataCatalogEncryptionSettings.

  La configuración de seguridad que se va a establecer.

Respuesta

- Sin parámetros de respuesta.

Errores

- `InternalServiceException`
- `InvalidInputException`
- `OperationTimeoutException`

Acción PutResourcePolicy (Python: put_resource_policy)

Establece el catálogo de datos de política de recursos para el control de acceso.

Solicitud

- `PolicyInJson`: obligatorio: cadena UTF-8 de 2 bytes de largo como mínimo.

  Contiene el documento de política para establecer, en formato JSON.
- `ResourceArn` – cadena UTF-8, con 1 byte de largo como mínimo y 10 240 bytes de largo como máximo, que coincide con el Custom string pattern #50.

  No utilizar. Para uso interno únicamente.
- `PolicyHashCondition` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

El valor hash devuelto cuando la política anterior se ha establecido mediante `PutResourcePolicy`. Su objetivo es evitar modificaciones simultáneas de una política. No utilice este parámetro si no se ha establecido ninguna política anterior.

- `PolicyExistsCondition` – Cadena UTF-8 (valores válidos: `MUST_EXIST` | `NOT_EXIST` | `NONE`).

  Un valor de `MUST_EXIST` se utiliza para actualizar una política. Un valor de `NOT_EXIST` se utiliza para crear una política nueva. Si se utiliza el valor de `NONE` o un valor nulo, la llamada no dependerá de la existencia de una política.

- `EnableHybrid` – Cadena UTF-8 (valores válidos: `TRUE` | `FALSE`).

  Si se utiliza `'TRUE'`, significa que está utilizando ambos métodos para conceder acceso entre cuentas a recursos del Data Catalog:

  - Al actualizar directamente la política de recursos con `PutResourePolicy`
  - Al utilizar el comando Grant permissions (Concesión de permisos) en la Consola de administración de AWS.

  Debe establecerse en `'TRUE'` si ya ha utilizado Management Console para conceder acceso entre cuentas; de lo contrario, se producirá un error en la llamada. La opción predeterminada es 'FALSO'.

Respuesta

- `PolicyHash` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Un hash de la política que se acaba de definir. Este debe incluirse en una llamada posterior que sobrescribe o actualiza esta política.

Errores

- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`

- `ConditionCheckFailureException`

Acción GetResourcePolicy (Python: get_resource_policy)

Recupera una política de recursos especificada.

Solicitud

- `ResourceArn` – cadena UTF-8, con 1 byte de largo como mínimo y 10 240 bytes de largo como máximo, que coincide con el Custom string pattern #50.

  El ARN del recurso de AWS Glue para el que se recuperará la política de recursos. Si no se proporciona, se devuelve la política de recursos del Data Catalog. Use `GetResourcePolicies` para ver todas las políticas de recursos existentes. Para obtener más información, consulte Especificación de ARN de recursos de AWS Glue.

Respuesta

- `PolicyInJson`: cadena UTF-8 de 2 bytes de largo como mínimo.

  Contiene el documento de política solicitado, en formato JSON.
- `PolicyHash` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Contiene el valor de hash asociado a esta política.
- `CreateTime`: marca temporal.

  La fecha y hora en la que se creó la política.
- `UpdateTime`: marca temporal.

  La fecha y hora en la que se actualizó la política por última vez.

Errores

- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`

- `InvalidInputException`

Acción DeleteResourcePolicy (Python: delete_resource_policy)

Elimina una política especificada.

Solicitud

- `PolicyHashCondition` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El valor de hash devuelto cuando esta política se definió.
- `ResourceArn` – cadena UTF-8, con 1 byte de largo como mínimo y 10 240 bytes de largo como máximo, que coincide con el Custom string pattern #50.

  El ARN del recurso de AWS Glue para la política de recursos que se eliminará.

Respuesta

- Sin parámetros de respuesta.

Errores

- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`
- `ConditionCheckFailureException`

Acción CreateSecurityConfiguration (Python: create_security_configuration)

Crea una nueva configuración de seguridad. Una configuración de seguridad es un conjunto de propiedades de seguridad que puede usar AWS Glue. Puede utilizar una configuración de seguridad para cifrar los datos en reposo. Para obtener información acerca de cómo usar configuraciones de seguridad en AWS Glue, consulte Cifrado de datos escritos por rastreadores, trabajos y puntos de enlace de desarrollo.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la nueva configuración de seguridad.
- `EncryptionConfiguration` – Obligatorio: objeto EncryptionConfiguration.

  La configuración de cifrado para la nueva configuración de seguridad.

Respuesta

- `Name` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre asignado a la nueva configuración de seguridad.
- `CreatedTimestamp`: marca temporal.

  El momento en que se creó la nueva configuración de seguridad.

Errores

- `AlreadyExistsException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`

Acción DeleteSecurityConfiguration (Python: delete_security_configuration)

Elimina una configuración de seguridad especificada.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la configuración de seguridad que se va a eliminar.

Respuesta

- Sin parámetros de respuesta.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

Acción GetSecurityConfiguration (Python: get_security_configuration)

Recupera una configuración de seguridad especificada.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la configuración de seguridad que se va a recuperar.

Respuesta

- `SecurityConfiguration`: un objeto SecurityConfiguration.

  La configuración de seguridad solicitada.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

Acción GetSecurityConfigurations (Python: get_security_configurations)

Recupera una lista de todas las configuraciones de seguridad.

Solicitud

- `MaxResults`: número (entero) que no es inferior a 1 ni es superior a 1000.

  El número máximo de resultados que devolver.
- `NextToken`: cadena UTF-8.

  Token de continuación si se trata de una llamada de continuidad.

Respuesta

- `SecurityConfigurations`: matriz de objetos SecurityConfiguration.

  Una lista de las configuraciones de seguridad.
- `NextToken`: cadena UTF-8.

  Un token de continuación, si hay más configuraciones de seguridad que devolver.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

Acción GetResourcePolicies (Python: get_resource_policies)

Recupera las políticas de recursos configuradas en recursos individuales por AWS Resource Access Manager durante la concesión de permisos entre cuentas. También recupera el la política de recursos del Data Catalog.

Si ha habilitado el cifrado de metadatos en la configuración del Data Catalog y no tiene permiso en la clave AWS KMS, la operación no puede devolver la política de recursos del Data Catalog.

Solicitud

- `NextToken`: cadena UTF-8.

  Token de continuación, si se trata de una solicitud de continuidad.
- `MaxResults`: número (entero) que no es inferior a 1 ni es superior a 1000.

  Tamaño máximo de una lista que se devolverá.

Respuesta

- `GetResourcePoliciesResponseList`: matriz de objetos Política de Glue.

  Una lista de las políticas de recursos individuales y la política de recursos a nivel de cuenta.
- `NextToken`: cadena UTF-8.

  Un token de continuación, si la lista devuelta no contiene la última política de recursos disponible.

Errores

- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`
- `GlueEncryptionException`

API de objetos del catálogo

La API de objetos del catálogo describe los tipos de datos y la API relacionada con el trabajo con catálogos en AWS Glue.

Temas

- API de catálogos
- API de la base de datos
- API de tabla
- API de partición
- API de conexión

- API de funciones definidas por el usuario
- Importación de un catálogo de Athena a AWS Glue

API de catálogos

La API de catálogos describe las API de creación, eliminación, localización, actualización y creación de listados de catálogos.

Tipos de datos

- Estructura del catálogo
- Estructura CatalogInput
- Estructura TargetRedshiftCatalog
- Estructura CatalogoProperties
- Estructura CatalogPropertiesOutput
- Estructura de DataLakeAccessProperties
- Estructura IcebergOptimizationProperties
- Estructura de DataLakeAccessPropertiesOutput
- Estructura IcebergOptimizationPropertiesOutput
- Estructura FederatedCatalog

Estructura del catálogo

El objeto de catálogo representa una agrupación lógica de bases de datos en el catálogo de datos de AWS Glue o en un origen federado. Puede crear un catálogo federado de Redshift o un catálogo que contenga enlaces de recursos a bases de datos de Redshift en otra cuenta o región.

Campos

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Es el ID del catálogo. Para permitir el acceso al catálogo predeterminado, no debe proporcionar este campo.
- `Name` (requerido): cadena UTF-8, cuya extensión tenga 1 byte como mínimo y 64 bytes como máximo y que coincide con Custom string pattern #25.

Es el nombre del catálogo. No puede ser el mismo que el ID de la cuenta.

- `ResourceArn`: cadena UTF-8.

  Es el nombre de recurso de Amazon (ARN) asignado al recurso del catálogo.

- `Description` – cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Cadena de descripción, cuya extensión no sea más de 2048 bytes y que coincida con el patrón de cadena de varias líneas de la dirección URI. Es una descripción del catálogo.

- `Parameters`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena de claves con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Cada valor es una cadena UTF-8 que no tiene más de 512000 bytes de largo.

  Matriz de mapas de pares clave-valor que define los parámetros y las propiedades del catálogo.

- `CreateTime`: marca temporal.

  Es la hora a la que se creó el catálogo.

- `UpdateTime`: marca temporal.

  Es la hora en la que se actualizó el catálogo por última vez.

- `TargetRedshiftCatalog`: un objeto TargetRedshiftCatalog.

  Objeto `TargetRedshiftCatalog` que describe un catálogo de destino para la vinculación de recursos de la base de datos.

- `FederatedCatalog`: un objeto FederatedCatalog.

  Objeto `FederatedCatalog` que apunta a una entidad externa al catálogo de datos de AWS Glue.

- `CatalogProperties`: un objeto CatalogPropertiesOutput.

  Objeto `CatalogProperties` que especifica las propiedades de acceso al lago de datos y otras propiedades personalizadas.

- `CreateTableDefaultPermissions`: matriz de objetos PrincipalPermissions.

Una matriz de objetos `PrincipalPermissions`. Permite crear un conjunto de permisos predeterminados en las tablas de las entidades principales. Lo utiliza AWS Lake Formation. No se utiliza en el transcurso normal de las operaciones de AWS Glue.

- `CreateDatabaseDefaultPermissions`: matriz de objetos PrincipalPermissions.

  Una matriz de objetos `PrincipalPermissions`. Permite crear un conjunto de permisos predeterminados en las bases de datos de las entidades principales. Lo utiliza AWS Lake Formation. No se utiliza en el transcurso normal de las operaciones de AWS Glue.

- `AllowFullTableExternalDataAccess` – Cadena UTF-8 (valores válidos: `True` | `False`).

  Permite que motores de terceros accedan a datos en ubicaciones de Amazon S3 registradas en Lake Formation.

Estructura CatalogInput

Estructura que describe las propiedades del catálogo.

Campos

- `Description` – cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Cadena de descripción, cuya extensión no sea más de 2048 bytes y que coincida con el patrón de cadena de varias líneas de la dirección URI. Es una descripción del catálogo.

- `FederatedCatalog`: un objeto FederatedCatalog.

  Un objeto `FederatedCatalog`. Estructura `FederatedCatalog` que hace referencia a una entidad externa al catálogo de datos de AWS Glue; por ejemplo, una base de datos de Redshift.

- `Parameters`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena de claves con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Cada valor es una cadena UTF-8 que no tiene más de 512000 bytes de largo.

  Matriz de mapas de pares clave-valor que define los parámetros y las propiedades del catálogo.

- `TargetRedshiftCatalog`: un objeto TargetRedshiftCatalog.

Objeto `TargetRedshiftCatalog` que describe un catálogo de destino para la vinculación de recursos.

- `CatalogProperties`: un objeto CatalogProperties.

  Objeto `CatalogProperties` que especifica las propiedades de acceso al lago de datos y otras propiedades personalizadas.

- `CreateTableDefaultPermissions`: matriz de objetos PrincipalPermissions.

  Una matriz de objetos `PrincipalPermissions`. Permite crear un conjunto de permisos predeterminados en las tablas de las entidades principales. Lo utiliza AWS Lake Formation. Por lo general, se debe establecer de forma explícita como una lista vacía.

- `CreateDatabaseDefaultPermissions`: matriz de objetos PrincipalPermissions.

  Una matriz de objetos `PrincipalPermissions`. Permite crear un conjunto de permisos predeterminados en las bases de datos de las entidades principales. Lo utiliza AWS Lake Formation. Por lo general, se debe establecer de forma explícita como una lista vacía.

- `AllowFullTableExternalDataAccess` – Cadena UTF-8 (valores válidos: `True` | `False`).

  Permite que motores de terceros accedan a datos en ubicaciones de Amazon S3 registradas en Lake Formation.

Estructura TargetRedshiftCatalog

Estructura que describe un catálogo de destino para la vinculación de recursos.

Campos

- `CatalogArn` – Obligatorio: cadena UTF-8.

  El nombre de recurso de Amazon (ARN) del recurso de catálogo.

Estructura CatalogoProperties

Estructura que especifica las propiedades de acceso al lago de datos y otras propiedades personalizadas.

Campos

- `DataLakeAccessProperties`: un objeto DataLakeAccessProperties.

  Objeto `DataLakeAccessProperties` que especifica las propiedades para configurar el acceso al lago de datos del recurso de catálogo en el catálogo de datos de AWS Glue.

- `IcebergOptimizationProperties`: un objeto IcebergOptimizationProperties.

  Estructura que especifica las propiedades de optimización de la tabla de Iceberg para el catálogo. Esto incluye la configuración para las operaciones de compactación, retención y eliminación de archivos huérfanos que se pueden aplicar a las tablas de Iceberg de este catálogo.

- `CustomProperties`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena de claves con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Cada valor es una cadena UTF-8 que no tiene más de 512000 bytes de largo.

  Propiedades de valores clave adicionales para el catálogo, como las optimizaciones de las estadísticas de columnas.

Estructura CatalogPropertiesOutput

Atributos de propiedad que incluyen las propiedades de configuración del recurso del catálogo.

Campos

- `DataLakeAccessProperties`: un objeto DataLakeAccessPropertiesOutput.

  Objeto `DataLakeAccessProperties` con propiedades de entrada para configurar el acceso al lago de datos del recurso de catálogo en el catálogo de datos de AWS Glue.

- `IcebergOptimizationProperties`: un objeto IcebergOptimizationPropertiesOutput.

  Un objeto `IcebergOptimizationPropertiesOutput` que especifica la configuración de optimización de las tablas de Iceberg para el catálogo, incluidas las configuraciones para las operaciones de compactación, retención y eliminación de archivos huérfanos.

- `CustomProperties`: matriz de mapas de pares clave-valor.

Cada clave es una cadena de claves con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

Cada valor es una cadena UTF-8 que no tiene más de 512000 bytes de largo.

Propiedades de valores clave adicionales para el catálogo, como las optimizaciones de las estadísticas de columnas.

Estructura de DataLakeAccessProperties

Propiedades de entrada para configurar el acceso al lago de datos del recurso de catálogo en el catálogo de datos de AWS Glue.

Campos

- `DataLakeAccess`: booleano.

  Permite activar o desactivar el acceso al lago de datos en las aplicaciones de Apache Spark que acceden a las bases de datos de Amazon Redshift del catálogo de datos desde cualquier motor que no sea Redshift, como Amazon Athena, Amazon EMR o ETL AWS Glue.
- `DataTransferRole` – cadena UTF-8 que coincide con el Custom string pattern #53.

  Rol que asumirá AWS Glue para realizar la transferencia de datos hacia o desde el bucket transitorio durante una consulta.
- `KmsKey`: cadena UTF-8.

  Clave de cifrado que se utilizará en el bucket transitorio y que se creará junto con el catálogo.
- `CatalogType` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Especifica un tipo de catálogo federado para el recurso de catálogo nativo. El tipo que se admite actualmente es `aws:redshift`.

Estructura IcebergOptimizationProperties

Una estructura que especifica las propiedades de optimización de las tablas de Iceberg para el catálogo, incluidas las configuraciones para las operaciones de compactación, retención y eliminación de archivos huérfanos.

Campos

- `RoleArn` – cadena UTF-8 que coincide con el Custom string pattern #53.

  El nombre de recurso de Amazon (ARN) del rol de IAM que se asumirá para llevar a cabo las operaciones de optimización de la tabla de Iceberg.

- `Compaction`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena de claves con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Cada valor es una cadena UTF-8 que no tiene más de 512000 bytes de largo.

  Un mapa de pares clave-valor que especifica los parámetros de configuración para las operaciones de compactación de tablas de Iceberg, que optimizan el diseño de los archivos de datos para mejorar el rendimiento de las consultas.

- `Retention`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena de claves con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Cada valor es una cadena UTF-8 que no tiene más de 512000 bytes de largo.

  Un mapa de pares clave-valor que especifica los parámetros de configuración para las operaciones de retención de tablas de Iceberg, que gestionan el ciclo de vida de las instantáneas de las tablas para controlar los costos de almacenamiento.

- `OrphanFileDeletion`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena de claves con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Cada valor es una cadena UTF-8 que no tiene más de 512000 bytes de largo.

  Un mapa de pares clave-valor que especifica los parámetros de configuración para las operaciones de eliminación de archivos huérfanos de Iceberg, que identifican y eliminan los archivos a los que los metadatos de la tabla ya no hacen referencia.

Estructura de DataLakeAccessPropertiesOutput

Propiedades de salida para configurar el acceso al lago de datos del recurso de catálogo en el catálogo de datos de AWS Glue.

Campos

- `DataLakeAccess`: booleano.

  Permite activar o desactivar el acceso al lago de datos en las aplicaciones de Apache Spark que acceden a las bases de datos de Amazon Redshift del catálogo de datos.
- `DataTransferRole` – cadena UTF-8 que coincide con el Custom string pattern #53.

  Rol que asumirá AWS Glue para realizar la transferencia de datos hacia o desde el bucket transitorio durante una consulta.
- `KmsKey`: cadena UTF-8.

  Clave de cifrado que se utilizará en el bucket transitorio y que se creará junto con el catálogo.
- `ManagedWorkgroupName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Es el nombre de computación administrado de Redshift sin servidor que se crea para el recurso de catálogo.
- `ManagedWorkgroupStatus` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Es el estado de computación administrado de Redshift sin servidor.
- `RedshiftDatabaseName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Es el nombre predeterminado del recurso de base de datos de Redshift en la computación administrada.
- `StatusMessage` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Mensaje que proporciona información más detallada sobre el estado del grupo de trabajo administrado.

- `CatalogType` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Especifica un tipo de catálogo federado para el recurso de catálogo nativo. El tipo que se admite actualmente es `aws:redshift`.

Estructura IcebergOptimizationPropertiesOutput

Una estructura que contiene las propiedades de salida de la configuración de la optimización de la tabla de Iceberg para el recurso de catálogo en el Catálogo de datos de AWS Glue.

Campos

- `RoleArn` – cadena UTF-8 que coincide con el Custom string pattern #53.

  El nombre de recurso de Amazon (ARN) del rol de IAM que se asume para llevar a cabo las operaciones de optimización de la tabla de Iceberg.
- `Compaction`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena de claves con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Cada valor es una cadena UTF-8 que no tiene más de 512000 bytes de largo.

  Un mapa de pares clave-valor que especifica los parámetros de configuración para las operaciones de compactación de tablas de Iceberg, que optimizan el diseño de los archivos de datos para mejorar el rendimiento de las consultas.
- `Retention`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena de claves con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Cada valor es una cadena UTF-8 que no tiene más de 512000 bytes de largo.

  Un mapa de pares clave-valor que especifica los parámetros de configuración para las operaciones de retención de tablas de Iceberg, que gestionan el ciclo de vida de las instantáneas de las tablas para controlar los costos de almacenamiento.
- `OrphanFileDeletion`: matriz de mapas de pares clave-valor.

Cada clave es una cadena de claves con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

Cada valor es una cadena UTF-8 que no tiene más de 512000 bytes de largo.

Un mapa de pares clave-valor que especifica los parámetros de configuración para las operaciones de eliminación de archivos huérfanos de Iceberg, que identifican y eliminan los archivos a los que los metadatos de la tabla ya no hacen referencia.

- `LastUpdatedTime`: marca temporal.

  La marca de tiempo de la última actualización de las propiedades de optimización de Iceberg.

Estructura FederatedCatalog

Catálogo que apunta a una entidad externa al catálogo de datos de AWS Glue.

Campos

- `Identifier` – cadena UTF-8, con 1 byte de largo como mínimo y 512 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Identificador único del catálogo federado.

- `ConnectionName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Es el nombre de la conexión a un origen de datos externo; por ejemplo, un catálogo federado de Redshift.

- `ConnectionType` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El tipo de conexión utilizado para acceder al catálogo federado, que especifica el protocolo o método de conexión con el origen de datos externo.

Operaciones

- Acción CreateCatalog (Python: create_catalog)
- Acción UpdateCatalog (Python: update_catalog)

- Acción DeleteCatalog (Python: delete_catalog)
- Acción GetCatalog (Python: get_catalog)
- Acción GetCatalogs (Python: get_catalogs)

Acción CreateCatalog (Python: create_catalog)

Permite crear un nuevo catálogo en el catálogo de datos de AWS Glue.

Solicitud

- `Name` (requerido): cadena UTF-8, cuya extensión tenga 1 byte como mínimo y 64 bytes como máximo y que coincide con Custom string pattern #25.

  Nombre del catálogo que se va a crear.
- `CatalogInput`: obligatorio: objeto CatalogInput.

  Objeto `CatalogInput` que define los metadatos del catálogo.
- `Tags`: matriz de mapas de pares de clave-valor, con 50 pares como máximo.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es una cadena UTF-8 que no tiene más de 256 bytes de largo.

  Matriz de mapas de pares clave-valor, con 50 pares como máximo. Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes. Cada valor es una cadena UTF-8 que no tiene más de 256 bytes de largo. Son las etiquetas que asigna al catálogo.

Respuesta

- Sin parámetros de respuesta.

Errores

- `InvalidInputException`
- `AlreadyExistsException`
- `ResourceNumberLimitExceededException`
- `InternalServiceException`

- `OperationTimeoutException`
- `GlueEncryptionException`
- `ConcurrentModificationException`
- `AccessDeniedException`
- `EntityNotFoundException`
- `FederatedResourceAlreadyExistsException`
- `FederationSourceException`

Acción UpdateCatalog (Python: update_catalog)

Permite actualizar las propiedades de un catálogo existente en el catálogo de datos de AWS Glue.

Solicitud

- `CatalogId`: Obligatorio: cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Es el ID del catálogo.
- `CatalogInput`: obligatorio: objeto CatalogInput.

  Objeto `CatalogInput` que especifica las propiedades nuevas de un catálogo existente.

Respuesta

- Sin parámetros de respuesta.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`
- `ConcurrentModificationException`
- `AccessDeniedException`

- `FederationSourceException`

Acción DeleteCatalog (Python: delete_catalog)

Permite eliminar el catálogo especificado del catálogo de datos de AWS Glue.

Después de completar esta operación, ya no tendrá acceso a las bases de datos, tablas (y todas las versiones y particiones de tabla que podrían pertenecer a las tablas) ni a las funciones definidas por el usuario en el catálogo eliminado. AWS Glue elimina estos recursos “huérfanos” de manera asíncrona y oportuna, según lo solicite el servicio.

Para garantizar la eliminación inmediata de todos los recursos relacionados, antes de llamar a la operación `DeleteCatalog`, use `DeleteTableVersion` (o `BatchDeleteTableVersion`), `DeletePartition` (o `BatchDeletePartition`), `DeleteTable` (o `BatchDeleteTable`), `DeleteUserDefinedFunction` y `DeleteDatabase` para eliminar todos los recursos que pertenezcan al catálogo.

Solicitud

- `CatalogId`: Obligatorio: cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Es el ID del catálogo.

Respuesta

- Sin parámetros de respuesta.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`
- `ConcurrentModificationException`
- `AccessDeniedException`

- `FederationSourceException`

Acción GetCatalog (Python: get_catalog)

Es el nombre del catálogo que se va a recuperar. Debe estar todo en minúsculas.

Solicitud

- `CatalogId`: Obligatorio: cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  ID del catálogo principal donde reside el catálogo. Si no se proporciona ninguno, se usará de forma predeterminada el número de cuenta de AWS.

Respuesta

- `Catalog`: un objeto Catálogo.

  Un objeto `Catalog`. Definición del catálogo especificado en el catálogo de datos de AWS Glue.

Errores

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`
- `AccessDeniedException`
- `EntityNotFoundException`
- `FederationSourceException`
- `FederationSourceRetryableException`

Acción GetCatalogs (Python: get_catalogs)

Permite recuperar todos los catálogos definidos en un catálogo del catálogo de datos de AWS Glue. Para un caso de uso de un catálogo federado por Redshift, esta operación devuelve la lista de

catálogos asignados a las bases de datos de Redshift en el catálogo de espacios de nombres de Redshift.

Solicitud

- `ParentCatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  ID del catálogo principal donde reside el catálogo. Si no se proporciona ninguno, se usará de forma predeterminada el número de cuenta de AWS.
- `NextToken`: cadena UTF-8.

  Token de continuación si se trata de una llamada de continuidad.
- `MaxResults`: número (entero) que no es inferior a 1 ni es superior a 1000.

  Número máximo de catálogos que se devuelven en una respuesta.
- `Recursive`: booleano.

  Indica si se deben listar todos los catálogos a lo largo de la jerarquía de catálogos, comenzando desde el `ParentCatalogId`. El valor predeterminado es `false` . Cuando `true`, todos los objetos de catálogo en la jerarquía `ParentCatalogID` se enumeran en la respuesta.
- `IncludeRoot`: booleano.

  Indica si se debe listar el catálogo predeterminado de la cuenta y la región en la respuesta. El valor predeterminado es `false`. Cuando `true` y `ParentCatalogId = NULL | AWS Account ID`, todos los catálogos y el catálogo predeterminado se enumeran en la respuesta.

  Cuando el `ParentCatalogId` no es igual a nulo y este atributo se pasa como `false` o `true`, se lanza un `InvalidInputException`.

Respuesta

- `CatalogList` (obligatorio): una matriz de objetos Catálogo.

  Una matriz de objetos `Catalog`. Lista de objetos `Catalog` del catálogo principal especificado.
- `NextToken`: cadena UTF-8.

  Token de continuación para paginar la lista de tokens obtenida; se devuelve si el segmento actual de la lista no es el último.

Errores

- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`
- `AccessDeniedException`
- `EntityNotFoundException`
- `FederationSourceException`
- `FederationSourceRetryableException`

API de la base de datos

La API de la base de datos describe los tipos de datos de la base de datos e incluye la API de creación, eliminación, ubicación, actualización y enumeración de las bases de datos.

Tipos de datos

- Estructura de base de datos
- Estructura DatabaseInput
- Estructura PrincipalPermissions
- Estructura DataLakePrincipal
- Estructura DatabaseIdentifier
- Estructura de FederatedDatabase

Estructura de base de datos

El objeto `Database` representa una agrupación lógica de tablas que puede residir en un metaalmacén de Hive o en un RDBMS.

Campos

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

El nombre de la base de datos. Para su compatibilidad con Hive, este se incorpora en minúsculas al almacenarse.

- `Description`: cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Una descripción de la base de datos.

- `LocationUri`: identificador uniforme de recursos (uri), con 1 byte de largo como mínimo y 1024 bytes de largo como máximo, que coincide con el URI address multi-line string pattern.

  La ubicación de la base de datos (por ejemplo, una ruta de HDFS).

- `Parameters`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena de claves con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Cada valor es una cadena UTF-8 que no tiene más de 512000 bytes de largo.

  Estos pares de clave-valor definen los parámetros y las propiedades de la base de datos.

- `CreateTime`: marca temporal.

  Hora de creación de la base de datos de metadatos en el catálogo.

- `CreateTableDefaultPermissions`: matriz de objetos PrincipalPermissions.

  Permite crear un conjunto de permisos predeterminados en la tabla para las entidades principales. Utilizado por AWS Lake Formation. No se utiliza en el transcurso normal de las operaciones de AWS Glue.

- `TargetDatabase`: un objeto DatabaseIdentifier.

  Estructura `DatabaseIdentifier` que describe una base de datos de destino para la vinculación de recursos.

- `CatalogId`: cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del Catálogo de datos donde reside la base de datos.

- `FederatedDatabase`: un objeto FederatedDatabase.

Una estructura `FederatedDatabase` que hace referencia a una entidad externa aAWS Glue Data Catalog.

Estructura DatabaseInput

Estructura usada para crear o actualizar una base de datos.

Campos

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos. Para su compatibilidad con Hive, este se incorpora en minúsculas al almacenarse.
- `Description`: cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Una descripción de la base de datos.
- `LocationUri`: identificador uniforme de recursos (uri), con 1 byte de largo como mínimo y 1024 bytes de largo como máximo, que coincide con el URI address multi-line string pattern.

  La ubicación de la base de datos (por ejemplo, una ruta de HDFS).
- `Parameters`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena de claves con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Cada valor es una cadena UTF-8 que no tiene más de 512000 bytes de largo.

  Estos pares de clave-valor definen los parámetros y las propiedades de la base de datos.

  Estos pares de clave-valor definen los parámetros y las propiedades de la base de datos.
- `CreateTableDefaultPermissions`: matriz de objetos PrincipalPermissions.

  Permite crear un conjunto de permisos predeterminados en la tabla para las entidades principales. Utilizado por AWS Lake Formation. No se utiliza en el transcurso normal de las operaciones de AWS Glue.
- `TargetDatabase`: un objeto DatabaseIdentifier.

Estructura `DatabaseIdentifier` que describe una base de datos de destino para la vinculación de recursos.

- `FederatedDatabase`: un objeto FederatedDatabase.

  Una estructura `FederatedDatabase` que hace referencia a una entidad externa aAWS Glue Data Catalog.

Estructura PrincipalPermissions

Permisos concedidos a una entidad principal.

Campos

- `Principal`: un objeto DataLakePrincipal.

  La entidad principal a la que se conceden los permisos.
- `Permissions`: matriz de cadenas UTF-8.

  Los permisos que se conceden al principal.

Estructura DataLakePrincipal

La AWS Lake Formation principal.

Campos

- `DataLakePrincipalIdentifier`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo.

  Un identificador para la AWS Lake Formation principal.

Estructura DatabaseIdentifier

Estructura que describe una base de datos de destino para la vinculación de recursos.

Campos

- `CatalogId`: cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

El ID del Catálogo de datos donde reside la base de datos.

- `DatabaseName`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre de la base de datos del catálogo.

- `Region`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Región de la base de datos objetivo.

Estructura de FederatedDatabase

Una base de datos que apunta a una entidad externa a AWS Glue Data Catalog.

Campos

- `Identifier`: cadena UTF-8, con 1 byte de largo como mínimo y 512 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Un identificador único para la base de datos federada.

- `ConnectionName`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la conexión al metalmacén externo.

- `ConnectionType`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El tipo de conexión utilizado para acceder a la base de datos federada, como JDBC, ODBC u otros protocolos de conexión compatibles.

Operaciones

- Acción CreateDatabase (Python: create_database)
- Acción UpdateDatabase (Python: update_database)
- Acción DeleteDatabase (Python: delete_database)
- Acción GetDatabase (Python: get_database)

- Acción GetDatabases (Python: get_databases)

Acción CreateDatabase (Python: create_database)

Crea una base de datos nueva en un Catálogo de datos.

Solicitud

- `CatalogId`: cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del Catálogo de datos donde se crea la base de datos. Si no se proporciona ninguno, se usará de forma predeterminada el ID de cuenta de AWS.
- `DatabaseInput`: obligatorio: objeto DatabaseInput.

  Los metadatos de la base de datos.
- `Tags`: matriz de mapas de pares de clave-valor, con 50 pares como máximo.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es una cadena UTF-8 que no tiene más de 256 bytes de largo.

  Las etiquetas que asigna a la base de datos.

Respuesta

- Sin parámetros de respuesta.

Errores

- `InvalidInputException`
- `AlreadyExistsException`
- `ResourceNumberLimitExceededException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`
- `ConcurrentModificationException`

- `FederatedResourceAlreadyExistsException`
- `FederationSourceException`
- `FederationSourceRetryableException`

Acción UpdateDatabase (Python: update_database)

Actualiza una definición de base de datos existente en un Catálogo de datos.

Solicitud

- `CatalogId`: cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del Catálogo de datos donde reside la base de datos de metadatos. Si no se proporciona ninguno, se usará de forma predeterminada el ID de cuenta de AWS.
- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre de la base de datos que debe actualizarse en el catálogo. Para su compatibilidad con Hive, se convierte en minúsculas.
- `DatabaseInput`: obligatorio: objeto DatabaseInput.

  Objeto `DatabaseInput` que especifica la nueva definición de la base de datos de metadatos en el catálogo.

Respuesta

- Sin parámetros de respuesta.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`

- `ConcurrentModificationException`
- `FederationSourceException`
- `FederationSourceRetryableException`
- `AlreadyExistsException`

Acción DeleteDatabase (Python: delete_database)

Elimina una base de datos especificada de un Catálogo de datos.

> **Note**
>
> Después de completar esta operación, ya no tendrá acceso a las tablas (y todas las versiones y particiones de tabla que podrían pertenecer a las tablas) ni a las funciones definidas por el usuario en la base de datos eliminada. AWS Glue elimina estos recursos "huérfanos" de manera asíncrona en forma oportuna, a discreción del servicio.
> Para asegurarse de la eliminación inmediata de todos los recursos relacionados, antes de llamar a `DeleteDatabase`, use `DeleteTableVersion` o `BatchDeleteTableVersion`, `DeletePartition` o `BatchDeletePartition`, `DeleteUserDefinedFunction` y `DeleteTable` o `BatchDeleteTable` para eliminar todos los recursos que pertenezcan a la base de datos.

Solicitud

- `CatalogId`: cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del Catálogo de datos donde reside la base de datos. Si no se proporciona ninguno, se usará de forma predeterminada el ID de cuenta de AWS.
- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos que se va a eliminar. Para su compatibilidad con Hive, este debe estar completamente en minúsculas.

Respuesta

- Sin parámetros de respuesta.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ConcurrentModificationException`
- `FederationSourceException`
- `FederationSourceRetryableException`

Acción GetDatabase (Python: get_database)

Recupera la definición de una base de datos especificada.

Solicitud

- `CatalogId`: cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del Catálogo de datos donde reside la base de datos. Si no se proporciona ninguno, se usará de forma predeterminada el ID de cuenta de AWS.
- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre de la base de datos que debe recuperarse. Para su compatibilidad con Hive, el nombre debe estar completamente en minúsculas.

Respuesta

- `Database`: un objeto Base de datos.

  La definición de la base de datos especificada en el catálogo.

Errores

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`
- `FederationSourceException`
- `FederationSourceRetryableException`

Acción GetDatabases (Python: get_databases)

Recupera todas las bases de datos definidas en un Catálogo de datos determinado.

Solicitud

- `CatalogId`: cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del Catálogo de datos donde se recuperará `Databases`. Si no se proporciona ninguno, se usará de forma predeterminada el ID de cuenta de AWS.
- `NextToken`: cadena UTF-8.

  Token de continuación si se trata de una llamada de continuidad.
- `MaxResults`: número (entero) que no es inferior a 1 ni es superior a 100.

  Número máximo de bases de datos que se devuelven en una respuesta.
- `ResourceShareType`: cadena UTF-8 (valores válidos: `FOREIGN` | `ALL` | `FEDERATED`).

  Le permite especificar que desea enumerar las bases de datos compartidas con su cuenta. Los valores permitidos son `FEDERATED`, `FOREIGN` o `ALL`.
  - Si se establece en `FEDERATED`, enumerará las bases de datos federadas (que hacen referencia a una entidad externa) compartidas con la cuenta.
  - Si se establece en `FOREIGN`, enumerará las bases de datos compartidas con su cuenta.
  - Si se establece en `ALL`, enumerará las bases de datos compartidas con su cuenta, así como las bases de datos de su cuenta local.

- `AttributesToGet`: matriz de cadenas UTF-8.

  Especifica los campos de la base de datos devueltos por la llamada `GetDatabases`. Este parámetro no acepta una lista vacía. La solicitud debe incluir `NAME`.

Respuesta

- `DatabaseList` (obligatorio): una matriz de objetos Base de datos.

  Lista de objetos `Database` del catálogo especificado.
- `NextToken`: cadena UTF-8.

  Token de continuación para paginar la lista de tokens obtenida; se devuelve si el segmento actual de la lista no es el último.

Errores

- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`
- `EntityNotFoundException`
- `FederationSourceException`
- `FederationSourceRetryableException`

API de tabla

La API de tabla describe los tipos de datos y las operaciones que se asocian a las tablas.

Tipos de datos

- Estructura de tabla
- Estructura TableInput
- Estructura de FederatedTable
- Estructura de las columnas

- Estructura StorageDescriptor
- Estructura SchemaReference
- Estructura SerDeInfo
- Estructura Order
- Estructura SkewedInfo
- Estructura TableVersion
- Estructura TableError
- Estructura TableVersionError
- Estructura SortCriterion
- Estructura TableIdentifier
- Estructura KeySchemaElement
- Estructura PartitionIndex
- Estructura PartitionIndexDescriptor
- Estructura BackFillError
- Estructura de IcebergInput
- Estructura de OpenTableFormatInput
- Estructura ViewDefinition
- Estructura ViewDefinitionInput
- Estructura ViewRepresentation
- Estructura ViewRepresentationInput
- Estructura UpdateOpenTableFormatInput
- Estructura UpdateIcebergInput
- Estructura CreateIcebergTableInput
- Estructura UpdateIcebergTableInput
- Estructura IcebergSortOrder
- Estructura IcebergSortField
- Estructura IcebergPartitionSpec
- Estructura IcebergPartitionField
- Estructura IcebergSchema

- Estructura IcebergStructField
- Estructura IcebergTableUpdate
- Estructura de AuditContext

Estructura de tabla

Representa una recopilación de datos relacionados organizados en columnas y filas.

Campos

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la tabla. Para su compatibilidad con Hive, este debe estar completamente en minúsculas.
- `DatabaseName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos de metadatos donde residen los metadatos de la tabla. Para su compatibilidad con Hive, este debe estar completamente en minúsculas.
- `Description` – cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Una descripción de la tabla.
- `Owner` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El propietario de la tabla.
- `CreateTime`: marca temporal.

  La hora de creación de la definición de la tabla en el Catálogo de datos.
- `UpdateTime`: marca temporal.

  La última vez que se actualizó la tabla.
- `LastAccessTime`: marca temporal.

  La última vez que se accedió a tabla. Esta suele tomarse de HDFS y podría no ser de confianza.
- `LastAnalyzedTime`: marca temporal.

La última vez que se calcularon las estadísticas de columna para esta tabla.

- `Retention`: número (entero), cero como máximo.

  El tiempo de retención para esta tabla.

- `StorageDescriptor`: un objeto StorageDescriptor.

  Un descriptor de almacenamiento que contiene información acerca del almacenamiento físico de esta tabla.

- `PartitionKeys`: matriz de objetos Columna.

  Una lista de columnas por las que se particiona la tabla. Solo se admiten los tipos primitivos como claves de partición.

  Cuando se crea una tabla utilizada por Amazon Athena, y no especifica ninguna `partitionKeys`, al menos debe establecer el valor de `partitionKeys` en una lista vacía. Por ejemplo:

  `"PartitionKeys": []`

- `ViewOriginalText`: cadena UTF-8 de 409600 bytes de largo como máximo.

  Se incluye para permitir la compatibilidad con Apache Hive. No se utiliza en el transcurso normal de las operaciones de AWS Glue. Si la tabla es una `VIRTUAL_VIEW`, ciertos parámetros de configuración de Athena se codifican en base64.

- `ViewExpandedText`: cadena UTF-8 de 409600 bytes de largo como máximo.

  Se incluye para permitir la compatibilidad con Apache Hive. No se utiliza en el transcurso normal de las operaciones de AWS Glue.

- `TableType`: cadena UTF-8 de 255 bytes de largo como máximo.

  El tipo de esta tabla. AWS Glue creará tablas del tipo `EXTERNAL_TABLE`. Es posible que otros servicios, como Athena, creen tablas de otros tipos.

  Tipos de tablas relacionados con AWS Glue:

  EXTERNAL_TABLE

  Atributo de compatibilidad con Hive: indica una tabla no gestionada por Hive.

  GOVERNED

  Utilizado por AWS Lake Formation. El Catálogo de datos de AWS Glue entiende `GOVERNED`.

- `Parameters`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena de claves con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Cada valor es una cadena UTF-8 que no tiene más de 512000 bytes de largo.

  Estos pares clave-valor definen las propiedades asociadas a la tabla.

- `CreatedBy` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  La persona o entidad que creó la tabla.

- `IsRegisteredWithLakeFormation`: booleano.

  Indica si la tabla se ha registrado con AWS Lake Formation.

- `TargetTable`: un objeto TableIdentifier.

  Estructura `TableIdentifier` que describe una tabla de destino para la vinculación de recursos.

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  ID del Catálogo de datos donde reside la tabla.

- `VersionId` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de la versión de la tabla.

- `FederatedTable`: un objeto FederatedTable.

  Una estructura `FederatedTable` que hace referencia a una entidad externa aAWS Glue Data Catalog.

- `ViewDefinition`: un objeto ViewDefinition.

  Estructura que contiene toda la información que define la vista, incluidos el dialecto o los dialectos de la vista, y la consulta.

- `IsMultiDialectView`: booleano.

  Especifica si la vista admite los dialectos SQL de uno o varios motores de consulta diferentes y, por lo tanto, si esos motores pueden leerla.

Estructura TableInput

Una estructura utilizada para definir una tabla.

Campos

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la tabla. Para su compatibilidad con Hive, este se incorpora en minúsculas al almacenarse.

- `Description` – cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Una descripción de la tabla.

- `Owner` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El propietario de la tabla. Se incluye para permitir la compatibilidad con Apache Hive. No se utiliza en el transcurso normal de las operaciones de AWS Glue.

- `LastAccessTime`: marca temporal.

  La última vez que se accedió a tabla.

- `LastAnalyzedTime`: marca temporal.

  La última vez que se calcularon las estadísticas de columna para esta tabla.

- `Retention`: número (entero), cero como máximo.

  El tiempo de retención para esta tabla.

- `StorageDescriptor`: un objeto StorageDescriptor.

  Un descriptor de almacenamiento que contiene información acerca del almacenamiento físico de esta tabla.

- `PartitionKeys`: matriz de objetos Columna.

  Una lista de columnas por las que se particiona la tabla. Solo se admiten los tipos primitivos como claves de partición.

Cuando se crea una tabla utilizada por Amazon Athena, y no especifica ninguna `partitionKeys`, al menos debe establecer el valor de `partitionKeys` en una lista vacía. Por ejemplo:

```
"PartitionKeys": []
```

- `ViewOriginalText`: cadena UTF-8 de 409600 bytes de largo como máximo.

  Se incluye para permitir la compatibilidad con Apache Hive. No se utiliza en el transcurso normal de las operaciones de AWS Glue. Si la tabla es una `VIRTUAL_VIEW`, ciertos parámetros de configuración de Athena se codifican en base64.

- `ViewExpandedText`: cadena UTF-8 de 409600 bytes de largo como máximo.

  Se incluye para permitir la compatibilidad con Apache Hive. No se utiliza en el transcurso normal de las operaciones de AWS Glue.

- `TableType`: cadena UTF-8 de 255 bytes de largo como máximo.

  El tipo de esta tabla. AWS Glue creará tablas del tipo `EXTERNAL_TABLE`. Es posible que otros servicios, como Athena, creen tablas de otros tipos.

  Tipos de tablas relacionados con AWS Glue:

  EXTERNAL_TABLE

  Atributo de compatibilidad con Hive: indica una tabla no gestionada por Hive.

  GOVERNED

  Utilizado por AWS Lake Formation. El Catálogo de datos de AWS Glue entiende `GOVERNED`.

- `Parameters`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena de claves con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Cada valor es una cadena UTF-8 que no tiene más de 512000 bytes de largo.

  Estos pares clave-valor definen las propiedades asociadas a la tabla.

- `TargetTable`: un objeto TableIdentifier.

  Estructura `TableIdentifier` que describe una tabla de destino para la vinculación de recursos.

- `ViewDefinition`: un objeto ViewDefinitionInput.

Estructura que contiene toda la información que define la vista, incluidos el dialecto o los dialectos de la vista, y la consulta.

Estructura de FederatedTable

Una tabla que apunta a una entidad externa a AWS Glue Data Catalog.

Campos

- `Identifier` – cadena UTF-8, con 1 byte de largo como mínimo y 512 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Un identificador único para la tabla federada.

- `DatabaseIdentifier` – cadena UTF-8, con 1 byte de largo como mínimo y 512 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Un identificador único para la base de datos federada.

- `ConnectionName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la conexión al metalmacén externo.

- `ConnectionType` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El tipo de conexión utilizado para acceder a la tabla federada, que especifica el protocolo o método de conexión con el origen de datos externo.

Estructura de las columnas

Una columna en una `Table`.

Campos

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del elemento `Column`.

- `Type` – cadena UTF-8 con un máximo de 131072 bytes de largo, que coincide con el Single-line string pattern.

  El tipo de datos de la `Column`.

- `Comment` – cadena de comentario de un máximo de 255 bytes de largo, que coincide con el Single-line string pattern.

  Un comentario de texto de formato libre.

- `Parameters`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena de claves con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Cada valor es una cadena UTF-8 que no tiene más de 512000 bytes de largo.

  Estos pares clave-valor. definen las propiedades asociadas a la columna.

Estructura StorageDescriptor

Describe el almacenamiento físico de los datos de la tabla.

Campos

- `Columns`: matriz de objetos Columna.

  Una lista de las `Columns` de la tabla.

- `Location` – cadena de ubicación de un máximo de 2056 bytes de largo, que coincide con el URI address multi-line string pattern.

  Ubicación física de la tabla. De forma predeterminada, adopta la forma de la ubicación de almacén, seguida de la ubicación de la base de datos en el almacén, seguida del nombre de tabla.

- `AdditionalLocations`: matriz de cadenas UTF-8.

  Lista de ubicaciones que apuntan a la ruta en la que se encuentra una tabla Delta.

- `InputFormat` – cadena de formato de un máximo de 128 bytes de largo, que coincide con el Single-line string pattern.

  Formato de entrada: `SequenceFileInputFormat` (binario), `TextInputFormat` o formato personalizado.

- `OutputFormat` – cadena de formato de un máximo de 128 bytes de largo, que coincide con el Single-line string pattern.

  Formato de salida: `SequenceFileOutputFormat` (binario), `IgnoreKeyTextOutputFormat` o formato personalizado.

- `Compressed`: booleano.

  `True` si los datos de la tabla están comprimidos o `False` si no.

- `NumberOfBuckets`: número (entero).

  Debe especificarse si la tabla contiene alguna columna de dimensión.

- `SerdeInfo`: un objeto SerDeInfo.

  La información de serialización y deserialización (SerDe).

- `BucketColumns`: matriz de cadenas UTF-8.

  Lista de columnas de agrupamiento del reductor, columnas de clústeres y columnas de almacenamiento en bucket de la tabla.

- `SortColumns`: matriz de objetos Order.

  Una lista donde se especifica el orden de clasificación de cada bucket en la tabla.

- `Parameters`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena de claves con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Cada valor es una cadena UTF-8 que no tiene más de 512000 bytes de largo.

  Las propiedades facilitadas por el usuario en formato clave-valor.

- `SkewedInfo`: un objeto SkewedInfo.

  La información sobre los valores que aparecen con frecuencia en una columna (valores sesgados).

- `StoredAsSubDirectories`: booleano.

  `True` si los datos de la tabla se almacenan en subdirectorios o `False` si no.

- `SchemaReference`: un objeto SchemaReference.

  Objeto que hace referencia a un esquema almacenado en AWS Glue Schema Registry.

Al crear una tabla, puede pasar una lista vacía de columnas para el esquema y, en su lugar, utilizar una referencia de esquema.

Estructura SchemaReference

Objeto que hace referencia a un esquema almacenado en AWS Glue Schema Registry.

Campos

- `SchemaId`: un objeto SchemaId.

  Estructura que contiene campos de identidad de esquema. Este o el `SchemaVersionId` tiene que ser proporcionado.
- `SchemaVersionId` – cadena UTF-8, con 36 bytes de largo como mínimo y 36 bytes de largo como máximo, que coincide con el Custom string pattern #45.

  El ID único asignado a una versión del esquema. Este o el `SchemaId` tiene que ser proporcionado.
- `SchemaVersionNumber`: número (largo) que no es inferior a 1 ni es superior a 100 000.

  El número de versión del esquema.

Estructura SerDeInfo

Información sobre un programa de serialización y deserialización (SerDe) que sirve de extractor y cargador.

Campos

- `Name` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del SerDe.
- `SerializationLibrary` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  En general, la clase que implementa el SerDe. Un ejemplo es: . `org.apache.hadoop.hive.serde2.columnar.ColumnarSerDe`.
- `Parameters`: matriz de mapas de pares clave-valor.

Cada clave es una cadena de claves con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

Cada valor es una cadena UTF-8 que no tiene más de 512000 bytes de largo.

Estos pares de clave-valor definen parámetros de inicialización para el SerDe.

Estructura Order

Especifica el orden de clasificación de una columna ordenada.

Campos

- `Column`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la columna.
- `SortOrder` – Obligatorio: número (entero), uno como máximo.

  Indica que la columna se clasifica en orden ascendente (`== 1`) o descendente (`==0`).

Estructura SkewedInfo

Especifica valores sesgados en una tabla. Los valores sesgados son los que se producen con una frecuencia muy alta.

Campos

- `SkewedColumnNames`: matriz de cadenas UTF-8.

  Una lista de nombres de columnas que contienen valores de sesgado.
- `SkewedColumnValues`: matriz de cadenas UTF-8.

  Una lista de valores que aparecen con tanta frecuencia como para considerarse de sesgado.
- `SkewedColumnValueLocationMaps`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8.

  Cada valor es una cadena UTF-8.

Un mapeo de valores de sesgado a las columnas que los contienen.

Estructura TableVersion

Especifica una versión de una tabla.

Campos

- `Table`: un objeto Tabla.

  La tabla en cuestión.

- `VersionId` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El valor de ID que identifica la versión de esta tabla. Una `VersionId` es una representación de cadena de un número entero. Cada versión se incrementa en 1.

Estructura TableError

Un registro de error para las operaciones con tablas.

Campos

- `TableName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la tabla. Para su compatibilidad con Hive, este debe estar completamente en minúsculas.

- `ErrorDetail`: un objeto ErrorDetail.

  Los detalles sobre el error.

Estructura TableVersionError

Un registro de error para las operaciones con versiones de tablas.

Campos

- `TableName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre de la tabla en cuestión.
- `VersionId` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El valor de ID de la versión en cuestión. Una `VersionID` es una representación de cadena de un número entero. Cada versión se incrementa en 1.
- `ErrorDetail`: un objeto ErrorDetail.

  Los detalles sobre el error.

Estructura SortCriterion

Especifica un campo por el que se va a ordenar y un orden de clasificación.

Campos

- `FieldName`: cadena de valor con una extensión de 1 byte como mínimo o 1024 bytes como máximo.

  El nombre del campo en el que se va a ordenar.
- `Sort` – Cadena UTF-8 (valores válidos: `ASC="ASCENDING"` | `DESC="DESCENDING"`).

  Orden ascendente o descendente.

Estructura TableIdentifier

Estructura que describe una tabla de destino para la vinculación de recursos.

Campos

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  ID del Catálogo de datos donde reside la tabla.

- `DatabaseName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre de la base de datos del catálogo que contiene la tabla de destino.
- `Name` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la tabla de destino.
- `Region` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Región de la tabla objetivo.

Estructura KeySchemaElement

Un par de claves de partición que consta de un nombre y un tipo.

Campos

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de una clave de partición.
- `Type` – Obligatorio: cadena UTF-8, de 131 072 bytes de largo como máximo, que coincide con Single-line string pattern.

  El tipo de una clave de partición.

Estructura PartitionIndex

Una estructura para un índice de partición.

Campos

- `Keys`: obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo.

  Las claves para el índice de partición.
- `IndexName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

El nombre del índice de partición.

Estructura PartitionIndexDescriptor

Un descriptor para un índice de partición en una tabla.

Campos

- `IndexName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del índice de partición.

- `Keys` – Obligatorio: una matriz de objetos KeySchemaElement, 1 estructura como mínimo.

  Una lista de una o más claves, como estructuras `KeySchemaElement`, para el índice de partición.

- `IndexStatus` – Obligatorio: cadena UTF-8 (valores válidos: `CREATING` | `ACTIVE` | `DELETING` | `FAILED`).

  El estado del índice de partición.

  Los posibles estados son:

  - CREACIÓN: el índice se está creando. Cuando el índice está en un estado CREACIÓN, el índice o su tabla no se pueden eliminar.
  - ACTIVO: la creación del índice se realiza correctamente.
  - ERROR: error en la creación del índice.
  - ELIMINACIÓN: el índice se elimina de la lista de índices.

- `BackfillErrors`: matriz de objetos BackFillError.

  Una lista de los errores que pueden producirse al registrar índices de particiones para una tabla existente.

Estructura BackFillError

Una lista de los errores que pueden producirse al registrar índices de particiones para una tabla existente.

Estos errores dan los detalles acerca de por qué un registro de índice presentó error y proporcionan un número limitado de particiones en la respuesta, de modo que pueda corregir las particiones con errores e intentar registrar el índice de nuevo. El conjunto más común de errores que pueden ocurrir se clasifican de la siguiente manera:

- EncryptedPartitionError: las particiones están cifradas.
- InvalidPartitionTypeDataError: el valor de las particiones no coincide con el tipo de datos de esa columna de partición.
- MissingPartitionValueError: las particiones están cifradas.
- UnsupportedPartitionCharacterError: no se admiten caracteres dentro del valor de partición. Por ejemplo: U+0000, U+0001, U+0002.
- InternalError: cualquier error que no pertenezca a otros códigos de error.

Campos

- `Code` – Cadena UTF-8 (valores válidos: `ENCRYPTED_PARTITION_ERROR` | `INTERNAL_ERROR` | `INVALID_PARTITION_TYPE_DATA_ERROR` | `MISSING_PARTITION_VALUE_ERROR` | `UNSUPPORTED_PARTITION_CHARACTER_ERROR`).

  Una lista de los errores que ocurrieron al registrar índices de particiones para una tabla existente.
- `Partitions`: matriz de objetos PartitionValueList.

  Una lista de un número limitado de particiones en la respuesta.

Estructura de IcebergInput

Una estructura que define una tabla de metadatos de Apache Iceberg para crearla en el catálogo.

Campos

- `MetadataOperation` – Obligatorio: cadena UTF-8 (valores válidos: `CREATE`).

  Una operación de metadatos obligatoria. Esto solo se puede configurar en `CREATE`.
- `Version` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  La versión de tabla para la tabla de Iceberg. El valor predeterminado es 2.

- `CreateIcebergTableInput`: un objeto CreateIcebergTableInput.

  Los parámetros de configuración necesarios para crear una nueva tabla de Iceberg en el Catálogo de datos de AWS Glue, incluidos las propiedades de la tabla y las especificaciones de metadatos.

Estructura de OpenTableFormatInput

Una estructura que representa una tabla de formato abierto.

Campos

- `IcebergInput`: un objeto IcebergInput.

  Especifica una estructura `IcebergInput` que define una tabla de metadatos de Apache Iceberg.

Estructura ViewDefinition

Estructura que contiene detalles para las representaciones.

Campos

- `IsProtected`: booleano.

  Puede establecer este indicador como verdadero para indicar al motor que no inserte las operaciones proporcionadas por el usuario en el plan lógico de la vista durante la planificación de las consultas. Sin embargo, establecer este indicador no garantiza que el motor cumpla con las normas. Consulte la documentación del motor para comprender las garantías que se ofrecen si las hubiera.
- `Definer` – cadena UTF-8, con 20 bytes como mínimo o más de 2048 bytes de largo, que coincide con el Single-line string pattern.

  El definidor de una vista en SQL.
- `SubObjects`: matriz de cadenas UTF-8, con 10 cadenas como máximo.

  Una lista de los nombres de recursos de Amazon (ARN) de la tabla.
- `Representations`: matriz de objetos ViewRepresentation, con una estructura como mínimo y 1000 estructuras como máximo.

  Una lista de representaciones.

Estructura ViewDefinitionInput

Estructura que contiene detalles para crear o actualizar una vista de AWS Glue.

Campos

- `IsProtected`: booleano.

  Puede establecer este indicador como verdadero para indicar al motor que no inserte las operaciones proporcionadas por el usuario en el plan lógico de la vista durante la planificación de las consultas. Sin embargo, establecer este indicador no garantiza que el motor cumpla con las normas. Consulte la documentación del motor para comprender las garantías que se ofrecen si las hubiera.
- `Definer` – cadena UTF-8, con 20 bytes como mínimo o más de 2048 bytes de largo, que coincide con el Single-line string pattern.

  El definidor de una vista en SQL.
- `Representations`: Una matriz de objetos ViewRepresentationInput, con 1 estructura como mínimo y 10 como máximo.

  Lista de estructuras que contiene el dialecto de la vista y la consulta que define la vista.
- `SubObjects`: matriz de cadenas UTF-8, con 10 cadenas como máximo.

  Una lista de los ARN de la tabla base que componen la vista.

Estructura ViewRepresentation

Estructura que contiene el dialecto de la vista y la consulta que define la vista.

Campos

- `Dialect` – Cadena UTF-8 (valores válidos: `REDSHIFT` | `ATHENA` | `SPARK`).

  El dialecto del motor de consultas.
- `DialectVersion`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo.

  La versión del dialecto del motor de consultas. Por ejemplo, 3.0.0.
- `ViewOriginalText`: cadena UTF-8 de 409600 bytes de largo como máximo.

La consulta SELECT proporcionada por el cliente durante CREATE VIEW DDL. Este SQL no se usa durante una consulta en una vista (en su lugar, se usa ViewExpandedText). ViewOriginalText se usa en casos como SHOW CREATE VIEW, en los que los usuarios desean ver el comando DDL original que creó la vista.

- ViewExpandedText: cadena UTF-8 de 409600 bytes de largo como máximo.

  El SQL expandido para la vista. Los motores utilizan este SQL para procesar una consulta en una vista. Es posible que los motores hagan operaciones durante la creación de la vista para transformar ViewOriginalText en ViewExpandedText. Por ejemplo:

  - Identificadores totalmente cualificados: SELECT * from table1 -> SELECT * from db1.table1

- ValidationConnection – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre de la conexión que se usará para validar la representación específica de la vista.

- IsStale: booleano.

  Los dialectos marcados como obsoletos ya no son válidos y deben actualizarse para poder consultarlos en sus respectivos motores de consulta.

Estructura ViewRepresentationInput

Estructura que contiene detalles de una representación para actualizar o crear una vista de Lake Formation.

Campos

- Dialect – Cadena UTF-8 (valores válidos: REDSHIFT | ATHENA | SPARK).

  Parámetro que especifica el tipo de motor de una representación específica.

- DialectVersion: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo.

  Un parámetro que especifica la versión del motor de una representación específica.

- ViewOriginalText: cadena UTF-8 de 409600 bytes de largo como máximo.

  Una cadena que representa la consulta SQL original que describe la vista.

- `ValidationConnection` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre de la conexión que se usará para validar la representación específica de la vista.

- `ViewExpandedText`: cadena UTF-8 de 409600 bytes de largo como máximo.

  Cadena que representa la consulta SQL que describe la vista con los ARN de recursos ampliados.

Estructura UpdateOpenTableFormatInput

Parámetros de entrada para actualizar tablas con formatos abiertos en el Catálogo de datos de AWS Glue, que sirven como envoltura para operaciones de actualización propias de cada formato, como Apache Iceberg.

Campos

- `UpdateIcebergInput`: un objeto UpdateIcebergInput.

  Parámetros de actualización específicos de Apache Iceberg que definen las modificaciones que se aplicarán a la tabla, incluidas los cambios de esquema, las especificaciones de partición y las propiedades de la tabla.

Estructura UpdateIcebergInput

Parámetros de entrada específicos para la actualización de tablas de Apache Iceberg en el Catálogo de datos de AWS Glue, que contienen las operaciones de actualización que se aplicarán a una tabla de Iceberg existente.

Campos

- `UpdateIcebergTableInput` – Obligatorio: objeto UpdateIcebergTableInput.

  Las operaciones de actualización específicas que se aplicarán a la tabla de Iceberg, que contienen una lista de actualizaciones que definen el nuevo estado de la tabla, incluidos el esquema, las particiones y las propiedades.

Estructura CreateIcebergTableInput

Los parámetros de configuración necesarios para crear una nueva tabla de Iceberg en el Catálogo de datos de AWS Glue, incluidos las propiedades de la tabla y las especificaciones de metadatos.

Campos

- `Location`: obligatorio: cadena de ubicación, con una longitud máxima de 2056 bytes, que coincida con URI address multi-line string pattern.

  La ubicación en S3 donde se almacenarán los datos de la tabla de Iceberg.

- `Schema` – Obligatorio: objeto IcebergSchema.

  La definición de esquema que especifica la estructura, los tipos de campos y los metadatos de la tabla de Iceberg.

- `PartitionSpec`: un objeto IcebergPartitionSpec.

  La especificación de partición que define cómo se organizarán y particionarán los datos de la tabla de Iceberg para un rendimiento óptimo en las consultas.

- `WriteOrder`: un objeto IcebergSortOrder.

  La especificación de ordenación que define cómo se deben ordenar los datos dentro de cada partición para optimizar el rendimiento de las consultas.

- `Properties` –

  Pares clave-valor de propiedades adicionales de la tabla y configuraciones para la tabla de Iceberg.

Estructura UpdateIcebergTableInput

Contiene las operaciones de actualización que se aplican a una tabla de Iceberg existente en el Catálogo de datos de AWS Glue y definen el nuevo estado de los metadatos de la tabla.

Campos

- `Updates` (obligatorio): una matriz de objetos IcebergTableUpdate.

La lista de operaciones de actualización de la tabla que especifican los cambios que se deben aplicar a la tabla de Iceberg, incluidas las modificaciones del esquema, las especificaciones de partición y las propiedades de la tabla.

Estructura IcebergSortOrder

Define la especificación de ordenación de una tabla de Iceberg y determina cómo se ordenan los datos dentro de las particiones para optimizar el rendimiento de las consultas.

Campos

- `OrderId` – Obligatorio: número (entero).

  El identificador único de esta especificación de ordenación dentro de los metadatos de la tabla de Iceberg.
- `Fields` (obligatorio): una matriz de objetos IcebergSortField.

  La lista de campos y sus direcciones de orden que establecen los criterios de ordenación de los datos de la tabla de Iceberg.

Estructura IcebergSortField

Define un solo campo dentro de una especificación de ordenación de Iceberg e incluye el campo de origen, la transformación, la dirección de orden y el orden de los valores nulos.

Campos

- `SourceId` – Obligatorio: número (entero).

  El identificador del campo de origen del esquema de la tabla en el que se basa este campo de ordenación.
- `Transform` – Obligatorio: cadena UTF-8.

  La función de transformación aplicada al campo de origen antes de la ordenación, como identidad, bucket o truncamiento.
- `Direction`: obligatorio: cadena UTF-8 (valores válidos: `asc="ASC"` | `desc="DESC"`).

  La dirección de orden de este campo, ya sea ascendente o descendente.

- `NullOrder`: obligatorio: cadena UTF-8 (valores válidos: `nulls-first="NULLS_FIRST"` | `nulls-last="NULLS_LAST"`).

  El comportamiento de ordenación de los valores nulos en este campo, que especifica si los nulos deben aparecer al principio o al final del orden.

Estructura IcebergPartitionSpec

Define la especificación de partición de una tabla de Iceberg y determina cómo se organiza y particiona la información de la tabla para lograr un rendimiento óptimo en las consultas.

Campos

- `Fields` (obligatorio): una matriz de objetos IcebergPartitionField.

  La lista de campos de partición que definen cómo se deben particionar los datos de la tabla, incluidos los campos de origen y sus transformaciones.
- `SpecId`: número (entero).

  El identificador único de esta especificación de partición dentro del historial de metadatos de la tabla de Iceberg.

Estructura IcebergPartitionField

Define un solo campo de partición dentro de una especificación de partición de Iceberg e incluye el campo de origen, la función de transformación, el nombre de la partición y el identificador único.

Campos

- `SourceId` – Obligatorio: número (entero).

  El identificador del campo de origen del esquema de la tabla en el que se basa este campo de partición.
- `Transform` – Obligatorio: cadena UTF-8.

  La función de transformación aplicada al campo de origen para crear la partición, como identidad, bucket, truncamiento, año, mes, día u hora.
- `Name` – Obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 1024 bytes de largo como máximo, que coincide con el Single-line string pattern.

El nombre del campo de partición tal como aparecerá en la estructura de la tabla particionada.

- `FieldId`: número (entero).

  El identificador único asignado a este campo de partición dentro de la especificación de partición de la tabla de Iceberg.

Estructura IcebergSchema

Define la estructura de esquema de una tabla de Iceberg e incluye las definiciones de campos, los tipos de datos y los metadatos del esquema.

Campos

- `SchemaId`: número (entero).

  El identificador único de esta versión del esquema dentro del historial de evolución del esquema de la tabla de Iceberg.
- `IdentifierFieldIds`: una matriz de enteros con signo de 32 bits.

  La lista de identificadores de campos que identifican de forma única los registros en la tabla, utilizada para operaciones a nivel de fila y eliminación de duplicados.
- `Type` – Cadena UTF-8 (valores válidos: `struct="STRUCT"`).

  El tipo raíz de la estructura del esquema, que suele ser “estructura” en los esquemas de tablas de Iceberg.
- `Fields` (obligatorio): una matriz de objetos IcebergStructField.

  La lista de definiciones de campos que conforman el esquema de la tabla, incluidos los nombres de los campos, los tipos y los metadatos.

Estructura IcebergStructField

Define un solo campo dentro del esquema de una tabla de Iceberg e incluye su identificador, nombre, tipo de dato, posibilidad de nulo y documentación.

Campos

- `Id` – Obligatorio: número (entero).

El identificador único asignado a este campo dentro del esquema de la tabla de Iceberg, utilizado para la evolución del esquema y el seguimiento de campos.

- `Name` – Obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 1024 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del campo tal como aparece en el esquema de la tabla y en las operaciones de consulta.

- `Type`: Obligatorio: una estructura vacía llamada `IcebergDocument`.

  La definición del tipo de dato de este campo, que especifica la estructura y el formato de los datos que contiene.

- `Required` – Obligatorio: Booleano.

  Indica si este campo es obligatorio (no admite valores nulos) u opcional (admite valores nulos) en el esquema de la tabla.

- `Doc` – cadena de comentario de un máximo de 255 bytes de largo, que coincide con el Single-line string pattern.

  Documentación o texto descriptivo opcional que proporciona contexto adicional sobre el propósito y el uso de este campo.

Estructura IcebergTableUpdate

Define un conjunto completo de actualizaciones que se aplican a una tabla de Iceberg, incluidos los cambios de esquema, las modificaciones de particiones, los ajustes del orden de clasificación, las actualizaciones de ubicación y los cambios de propiedades.

Campos

- `Schema` – Obligatorio: objeto IcebergSchema.

  La definición actualizada del esquema de la tabla de Iceberg, que especifica los cambios en la estructura de los campos, los tipos de datos o los metadatos del esquema.

- `PartitionSpec`: un objeto IcebergPartitionSpec.

  La especificación de partición actualizada que define cómo se deben reorganizar y particionar los datos de la tabla.

- `SortOrder`: un objeto IcebergSortOrder.

  La especificación de ordenación actualizada que define cómo se deben ordenar los datos dentro de las particiones para lograr un rendimiento óptimo en las consultas.
- `Location`: obligatorio: cadena de ubicación, con una longitud máxima de 2056 bytes, que coincida con URI address multi-line string pattern.

  La ubicación actualizada en S3 donde se almacenarán los datos de la tabla de Iceberg.
- `Properties` –

  Pares clave-valor actualizados de propiedades de la tabla y configuraciones de la tabla de Iceberg.

Estructura de AuditContext

Estructura que contiene el contexto de auditoría de Lake Formation.

Campos

- `AdditionalAuditContext`: cadena UTF-8, no más de 2048 bytes de largo.

  Una cadena que contiene la información adicional del contexto de auditoría.
- `RequestedColumns`: matriz de cadenas UTF-8.

  Las columnas solicitadas para la auditoría.
- `AllColumnsRequested`: booleano.

  Todas las columnas solicitan una auditoría.

Operaciones

- Acción CreateTable (Python: create_table)
- Acción UpdateTable (Python: update_table)
- Acción DeleteTable (Python: delete_table)
- Acción BatchDeleteTable (Python: batch_delete_table)
- Acción GetTable (Python: get_table)
- Acción GetTables (Python: get_tables)
- Acción GetTableVersion (Python: get_table_version)

- Acción GetTableVersions (Python: get_table_versions)
- Acción DeleteTableVersion (Python: delete_table_version)
- Acción BatchDeleteTableVersion (Python: batch_delete_table_version)
- Acción SearchTables (Python: search_tables)
- Acción GetPartitionIndexes (Python: get_partition_indexes)
- Acción CreatePartitionIndex (Python: create_partition_index)
- Acción DeletePartitionIndex (Python: delete_partition_index)
- Acción GetColumnStatisticsForTable (Python: get_column_statistics_for_table)
- Acción UpdateColumnStatisticsForTable (Python: update_column_statistics_for_table)
- Acción DeleteColumnStatisticsForTable (Python: delete_column_statistics_for_table)

Acción CreateTable (Python: create_table)

Crea una nueva definición de tabla en el Catálogo de datos.

Solicitud

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del Catálogo de datos donde se crea la `Table`. Si no se proporciona ninguno, el ID de cuenta de AWS se usará de forma predeterminada.
- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  La base de datos de catálogos en la que se crea la nueva tabla. Para compatibilidad con Hive, este nombre está completamente en minúsculas.
- `Name` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El identificador único de la tabla dentro de la base de datos especificada que se creará en el Catálogo de datos de AWS Glue.
- `TableInput`: un objeto TableInput.

  Objeto `TableInput` que define la tabla de metadatos que se va a crear en el catálogo.
- `PartitionIndexes`: matriz de objetos PartitionIndex, con 3 estructuras como máximo.

Una lista de índices de particiones, estructuras `PartitionIndex`, para crear en la tabla.

- `TransactionId` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #44.

  El ID de la transacción.

- `OpenTableFormatInput`: un objeto OpenTableFormatInput.

  Especifica una estructura `OpenTableFormatInput` al crear una tabla de formato abierto.

Respuesta

- Sin parámetros de respuesta.

Errores

- `AlreadyExistsException`
- `InvalidInputException`
- `EntityNotFoundException`
- `ResourceNumberLimitExceededException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`
- `ConcurrentModificationException`
- `ResourceNotReadyException`
- `FederationSourceException`
- `FederationSourceRetryableException`

Acción UpdateTable (Python: update_table)

Actualiza una tabla de metadatos en el Catálogo de datos.

Solicitud

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

El ID del Catálogo de datos donde reside la tabla. Si no se proporciona ninguno, se usará de forma predeterminada el ID de cuenta de AWS.

- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos de catálogos donde reside la tabla. Para compatibilidad con Hive, este nombre está completamente en minúsculas.
- `Name` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El identificador único de la tabla dentro de la base de datos especificada que se creará en el Catálogo de datos de AWS Glue.
- `TableInput`: un objeto TableInput.

  Objeto `TableInput` actualizado para definir la tabla de metadatos en el catálogo.
- `SkipArchive`: booleano.

  De forma predeterminada, `UpdateTable` crea siempre una versión archivada de la tabla antes de actualizarla. Si `skipArchive` se establece en true, sin embargo, `UpdateTable` no crea la versión archivada.
- `TransactionId` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #44.

  ID de transacción en el que se va a actualizar el contenido de la tabla.
- `VersionId` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de la versión a la que se actualizará el contenido de la tabla.
- `ViewUpdateAction` – Cadena UTF-8 (valores válidos: `ADD` | `REPLACE` | `ADD_OR_REPLACE` | `DROP`).

  La operación que se llevará a cabo al actualizar la vista.
- `Force`: booleano.

  Un indicador que se puede establecer como verdadero para ignorar los requisitos de coincidencia entre el descriptor de almacenamiento y el subobjeto.
- `UpdateOpenTableFormatInput`: un objeto UpdateOpenTableFormatInput.

Parámetros de entrada para actualizar tablas con formatos abiertos en el Catálogo de datos de AWS Glue, que sirven como envoltura para operaciones de actualización propias de cada formato, como Apache Iceberg.

Respuesta

- Sin parámetros de respuesta.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ConcurrentModificationException`
- `ResourceNumberLimitExceededException`
- `GlueEncryptionException`
- `ResourceNotReadyException`
- `FederationSourceException`
- `FederationSourceRetryableException`
- `AlreadyExistsException`

Acción DeleteTable (Python: delete_table)

Quita una definición de tabla del Catálogo de datos.

> **Note**
>
> Después de completar esta operación, ya no tendrá acceso a las versiones de la tabla y a las particiones que pertenecen a la tabla. AWS Glue elimina estos recursos “huérfanos” de manera asíncrona en forma oportuna, a discreción del servicio.
> Para asegurarse de la eliminación inmediata de todos los recursos relacionados, antes de llamar a `DeleteTable`, use `DeleteTableVersion` o `BatchDeleteTableVersion` y

`DeletePartition` o `BatchDeletePartition`, para eliminar todos los recursos que pertenezcan a la tabla.

Solicitud

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del Catálogo de datos donde reside la tabla. Si no se proporciona ninguno, se usará de forma predeterminada el ID de cuenta de AWS.
- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos de catálogos donde reside la tabla. Para compatibilidad con Hive, este nombre está completamente en minúsculas.
- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la tabla que se eliminará. Para compatibilidad con Hive, este nombre está completamente en minúsculas.
- `TransactionId` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #44.

  ID de transacción en el que se va a eliminar el contenido de la tabla.

Respuesta

- Sin parámetros de respuesta.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ConcurrentModificationException`

- `ResourceNotReadyException`
- `FederationSourceException`
- `FederationSourceRetryableException`

Acción BatchDeleteTable (Python: batch_delete_table)

Elimina varias tablas a la vez.

> **Note**
>
> Después de completar esta operación, ya no tendrá acceso a las versiones de la tabla y a las particiones que pertenecen a la tabla. AWS Glue elimina estos recursos "huérfanos" de manera asíncrona en forma oportuna, a discreción del servicio.
> Para asegurarse de la eliminación inmediata de todos los recursos relacionados, antes de llamar a `BatchDeleteTable`, use `DeleteTableVersion` o `BatchDeleteTableVersion` y `DeletePartition` o `BatchDeletePartition`, para eliminar todos los recursos que pertenezcan a la tabla.

Solicitud

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del Catálogo de datos donde reside la tabla. Si no se proporciona ninguno, se usará de forma predeterminada el ID de cuenta de AWS.
- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos de catálogos donde residen las tablas que se van a eliminar. Para compatibilidad con Hive, este nombre está completamente en minúsculas.
- `TablesToDelete` – Obligatorio: matriz de cadenas UTF-8, con 100 cadenas como máximo.

  Una lista de las tablas que se van a eliminar.
- `TransactionId` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #44.

  ID de transacción en el que se va a eliminar el contenido de la tabla.

Respuesta

- `Errors`: matriz de objetos TableError.

  Una lista de errores encontrados al intentar eliminar las tablas especificadas.

Errores

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`
- `ResourceNotReadyException`

Acción GetTable (Python: get_table)

Recupera la definición de `Table` en un Catálogo de datos para una tabla especificada.

Solicitud

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del Catálogo de datos donde reside la tabla. Si no se proporciona ninguno, se usará de forma predeterminada el ID de cuenta de AWS.
- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos en el catálogo donde reside la tabla. Para compatibilidad con Hive, este nombre está completamente en minúsculas.
- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la tabla para la que recuperar la definición. Para compatibilidad con Hive, este nombre está completamente en minúsculas.

- `TransactionId` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #44.

  ID de transacción en el que se va a leer el contenido de la tabla.

- `QueryAsOfTime`: marca temporal.

  El momento a partir del que se debe leer el contenido de la tabla. Si no se establece, se utilizará el tiempo de confirmación de la transacción más reciente. No se puede especificar junto con `TransactionId`.

- `AuditContext`: un objeto AuditContext.

  Estructura que contiene el contexto de auditoría de Lake Formation.

- `IncludeStatusDetails`: booleano.

  Especifica si se deben incluir los detalles de estado relacionados con una solicitud de creación o actualización de una vista del catálogo de datos AWS Glue.

Respuesta

- `Table`: un objeto Tabla.

  Objeto `Table` que define la tabla especificada.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`
- `ResourceNotReadyException`
- `FederationSourceException`
- `FederationSourceRetryableException`

Acción GetTables (Python: get_tables)

Recupera las definiciones de algunas o de todas las tablas en una determinada `Database`.

Solicitud

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del Catálogo de datos donde residen las tablas. Si no se proporciona ninguno, se usará de forma predeterminada el ID de cuenta de AWS.
- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  La base de datos del catálogo cuyas tablas se van a listar. Para compatibilidad con Hive, este nombre está completamente en minúsculas.
- `Expression` – cadena UTF-8 con un máximo de 2048 bytes de largo, que coincide con el Single-line string pattern.

  Un patrón de expresiones regulares. Si están presentes, solo se devuelven esas tablas cuyos nombres coinciden con el patrón.
- `NextToken`: cadena UTF-8.

  Token de continuación, incluido si se trata de una llamada de continuidad.
- `MaxResults`: número (entero) que no es inferior a 1 ni es superior a 100.

  El número máximo de tablas que se devuelven en una única respuesta.
- `TransactionId` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #44.

  ID de transacción en el que se va a leer el contenido de la tabla.
- `QueryAsOfTime`: marca temporal.

  El momento a partir del que se debe leer el contenido de la tabla. Si no se establece, se utilizará el tiempo de confirmación de la transacción más reciente. No se puede especificar junto con `TransactionId`.
- `AuditContext`: un objeto AuditContext.

  Estructura que contiene el contexto de auditoría de Lake Formation.

- `IncludeStatusDetails`: booleano.

  Especifica si se deben incluir los detalles de estado relacionados con una solicitud de creación o actualización de una vista del catálogo de datos AWS Glue.

- `AttributesToGet`: matriz de cadenas UTF-8.

  Especifica los campos de la tabla devueltos por la llamada `GetTables`. Este parámetro no acepta una lista vacía. La solicitud debe incluir el `NAME`.

  Las siguientes son combinaciones de valores válidas:

  - `NAME`: nombres de todas las tablas de la base de datos.
  - `NAME`, `TABLE_TYPE`: nombres de todas las tablas y tipos de tablas.

Respuesta

- `TableList`: matriz de objetos Tabla.

  Una lista de los objetos `Table` solicitados.

- `NextToken`: cadena UTF-8.

  Un token de continuación, presente si el segmento de lista actual no es el último.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`
- `GlueEncryptionException`
- `FederationSourceException`
- `FederationSourceRetryableException`

Acción GetTableVersion (Python: get_table_version)

Recupera una versión especificada de una tabla.

Solicitud

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del Catálogo de datos donde residen las tablas. Si no se proporciona ninguno, se usará de forma predeterminada el ID de cuenta de AWS.

- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  La base de datos del catálogo donde reside la tabla. Para compatibilidad con Hive, este nombre está completamente en minúsculas.

- `TableName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la tabla. Para compatibilidad con Hive, este nombre está completamente en minúsculas.

- `VersionId` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El valor de ID de la versión de la tabla que se va a recuperar. Una `VersionID` es una representación de cadena de un número entero. Cada versión se incrementa en 1.

Respuesta

- `TableVersion`: un objeto TableVersion.

  La versión de la tabla solicitada.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`

Acción GetTableVersions (Python: get_table_versions)

Recupera una lista de cadenas que identifican las versiones disponibles de una tabla especificada.

Solicitud

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del Catálogo de datos donde residen las tablas. Si no se proporciona ninguno, se usará de forma predeterminada el ID de cuenta de AWS.
- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  La base de datos del catálogo donde reside la tabla. Para compatibilidad con Hive, este nombre está completamente en minúsculas.
- `TableName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la tabla. Para compatibilidad con Hive, este nombre está completamente en minúsculas.
- `NextToken`: cadena UTF-8.

  Token de continuación si no se trata de la primera llamada.
- `MaxResults`: número (entero) que no es inferior a 1 ni es superior a 100.

  El número máximo de versiones de la tabla que se devuelven en una respuesta.

Respuesta

- `TableVersions`: matriz de objetos TableVersion.

  Una lista de cadenas que identifican las versiones disponibles de la tabla especificada.
- `NextToken`: cadena UTF-8.

  Token de continuación, si la lista de versiones disponibles no incluye la última.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`

Acción DeleteTableVersion (Python: delete_table_version)

Elimina una versión especificada de una tabla.

Solicitud

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del Catálogo de datos donde residen las tablas. Si no se proporciona ninguno, se usará de forma predeterminada el ID de cuenta de AWS.

- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  La base de datos del catálogo donde reside la tabla. Para compatibilidad con Hive, este nombre está completamente en minúsculas.

- `TableName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la tabla. Para compatibilidad con Hive, este nombre está completamente en minúsculas.

- `VersionId`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de la versión de la tabla que se va a eliminar. Una `VersionID` es una representación de cadena de un número entero. Cada versión se incrementa en 1.

Respuesta

- Sin parámetros de respuesta.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

Acción BatchDeleteTableVersion (Python: batch_delete_table_version)

Elimina un lote especificado de versiones de una tabla.

Solicitud

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del Catálogo de datos donde residen las tablas. Si no se proporciona ninguno, se usará de forma predeterminada el ID de cuenta de AWS.
- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  La base de datos del catálogo donde reside la tabla. Para compatibilidad con Hive, este nombre está completamente en minúsculas.
- `TableName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la tabla. Para compatibilidad con Hive, este nombre está completamente en minúsculas.
- `VersionIds` – Obligatorio: matriz de cadenas UTF-8, con 100 cadenas como máximo.

  Una lista de los ID de versiones que se van a eliminar. Una `VersionId` es una representación de cadena de un número entero. Cada versión se incrementa en 1.

Respuesta

- `Errors`: matriz de objetos TableVersionError.

  Una lista de errores encontrados mientras se intentan eliminar las versiones de la tabla especificadas.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

Acción SearchTables (Python: search_tables)

Busca un conjunto de tablas basado en las propiedades de los metadatos de la tabla, así como en la base de datos principal. Puede realizar búsquedas en condiciones de texto o filtro.

Solo puede obtener tablas a las que tiene acceso en función de las políticas de seguridad definidas en Lake Formation. Necesita al menos un acceso de solo lectura a la tabla para que se devuelva. Si no tiene acceso a todas las columnas de la tabla, estas columnas no se buscarán cuando le devuelva la lista de tablas. Si tiene acceso a las columnas, pero no a los datos de las columnas, esas columnas y los metadatos asociados para esas columnas se incluirán en la búsqueda.

Solicitud

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Un identificador único, que consta de *`account_id`*.
- `NextToken`: cadena UTF-8.

  Token de continuación, incluido si se trata de una llamada de continuidad.
- `Filters`: matriz de objetos PropertyPredicate.

  Una lista de pares clave-valor y un comparador utilizado para filtrar los resultados de búsqueda. Devuelve todas las entidades que coinciden con el predicado.

El miembro `Comparator` de la estructura `PropertyPredicate` se usa solo para campos de tiempo y se puede omitir para otros tipos de campos. Además, al comparar valores de cadena, como `Key=Name`, se utiliza un algoritmo de coincidencia aproximada. El campo `Key` (por ejemplo, el valor del campo `Name`) se divide en tokens con determinados caracteres de puntuación, por ejemplo, -, :, #, etc. Luego, cada token es una coincidencia exacta en comparación con el miembro `Value` de `PropertyPredicate`. Por ejemplo, para `Key=Name` y `Value=link`, se devuelven las tablas denominadas `customer-link` y `xx-link-yy`, pero no se devuelve `xxlinkyy`.

- `SearchText`: cadena de valor con una extensión de 1 byte como mínimo o 1024 bytes como máximo.

  Una cadena utilizada para una búsqueda de texto.

  Especificar un valor entre comillas filtra en base a una coincidencia exacta con el valor.

- `SortCriteria`: matriz de objetos SortCriterion, con 1 estructura como máximo.

  Una lista de criterios para ordenar los resultados por nombre de campo, en orden ascendente o descendente.

- `MaxResults`: número (entero) que no es inferior a 1 ni es superior a 1000.

  El número máximo de tablas que se devuelven en una única respuesta.

- `ResourceShareType` – Cadena UTF-8 (valores válidos: `FOREIGN` | `ALL` | `FEDERATED`).

  Le permite especificar que desea buscar en las tablas compartidas con su cuenta. Los valores permitidos son `FOREIGN` o `ALL`.

  - Si se establece en `FOREIGN`, buscará en las tablas compartidas con su cuenta.
  - Si se establece en `ALL`, buscará en las tablas compartidas con su cuenta, así como en las tablas de su cuenta local.

- `IncludeStatusDetails`: booleano.

  Especifica si se deben incluir los detalles de estado relacionados con una solicitud de creación o actualización de una vista del catálogo de datos AWS Glue.

Respuesta

- `NextToken`: cadena UTF-8.

  Un token de continuación, presente si el segmento de lista actual no es el último.

- `TableList`: matriz de objetos Tabla.

  Una lista de los objetos `Table` solicitados. La respuesta `SearchTables` devuelve solo las tablas a las que tiene acceso.

Errores

- `InternalServiceException`
- `InvalidInputException`
- `OperationTimeoutException`

Acción GetPartitionIndexes (Python: get_partition_indexes)

Recupera los índices de partición asociados a una tabla.

Solicitud

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del catálogo donde reside la tabla.
- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Especifica el nombre de una base de datos desde la que desea recuperar índices de particiones.
- `TableName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Especifica el nombre de una base de datos para la que desea recuperar índices de particiones.
- `NextToken`: cadena UTF-8.

  Token de continuación, incluido si se trata de una llamada de continuidad.

Respuesta

- `PartitionIndexDescriptorList`: matriz de objetos PartitionIndexDescriptor.

  Una lista de descriptores de índice.

- `NextToken`: cadena UTF-8.

  Un token de continuación, presente si el segmento de lista actual no es el último.

Errores

- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`
- `EntityNotFoundException`
- `ConflictException`

Acción CreatePartitionIndex (Python: create_partition_index)

Crea un índice de partición especificado en una tabla existente.

Solicitud

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del catálogo donde reside la tabla.
- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Especifica el nombre de una base de datos en la que desea crear un índice de particiones.
- `TableName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Especifica el nombre de una tabla en la que desea crear un índice de particiones.
- `PartitionIndex`: obligatorio: objeto PartitionIndex.

  Especifica una estructura de `PartitionIndex` para crear un índice de partición en una tabla existente.

Respuesta

- Sin parámetros de respuesta.

Errores

- `AlreadyExistsException`
- `InvalidInputException`
- `EntityNotFoundException`
- `ResourceNumberLimitExceededException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`

Acción DeletePartitionIndex (Python: delete_partition_index)

Elimina un índice de partición especificado de una tabla existente.

Solicitud

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del catálogo donde reside la tabla.
- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Especifica el nombre de una base de datos desde la que desea eliminar un índice de particiones.
- `TableName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Especifica el nombre de una tabla desde la que desea eliminar un índice de particiones.
- `IndexName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del índice de partición que se eliminará.

Respuesta

- Sin parámetros de respuesta.

Errores

- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`
- `EntityNotFoundException`
- `ConflictException`
- `GlueEncryptionException`

Acción GetColumnStatisticsForTable (Python: get_column_statistics_for_table)

Recupera estadísticas de las columnas de las tablas.

El permiso de Identity and Access Management (IAM) necesario para esta operación es `GetTable`.

Solicitud

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del Catálogo de datos donde residen las particiones en cuestión. Si no se proporciona ninguno, el ID de cuenta de AWS se usará de forma predeterminada.
- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos de catálogos donde residen las particiones.
- `TableName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre de la tabla de las particiones.
- `ColumnNames` – Obligatorio: matriz de cadenas UTF-8, con 100 cadenas como máximo.

  Una lista de los nombres de las columnas.

Respuesta

- `ColumnStatisticsList`: matriz de objetos ColumnStatistics.

  Lista de ColumnStatistics.

- `Errors`: matriz de objetos ColumnError.

  Lista de ColumnStatistics que no se pudieron recuperar.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`

Acción UpdateColumnStatisticsForTable (Python: update_column_statistics_for_table)

Crea o actualiza las estadísticas de las columnas de la tabla.

El permiso de Identity and Access Management (IAM) necesario para esta operación es `UpdateTable`.

Solicitud

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del Catálogo de datos donde residen las particiones en cuestión. Si no se proporciona ninguno, el ID de cuenta de AWS se usará de forma predeterminada.

- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos de catálogos donde residen las particiones.

- `TableName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

Nombre de la tabla de las particiones.

- `ColumnStatisticsList` – Obligatorio: matriz de objetos ColumnStatistics, con 25 estructuras como máximo.

  Una lista de las estadísticas de las columnas.

Respuesta

- `Errors`: matriz de objetos ColumnaStatisticsError.

  Lista de ColumnStatisticsErrors.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`

Acción DeleteColumnStatisticsForTable (Python: delete_column_statistics_for_table)

Recupera estadísticas de las columnas de las tablas.

El permiso de Identity and Access Management (IAM) necesario para esta operación es `DeleteTable`.

Solicitud

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del Catálogo de datos donde residen las particiones en cuestión. Si no se proporciona ninguno, el ID de cuenta de AWS se usará de forma predeterminada.
- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

El nombre de la base de datos de catálogos donde residen las particiones.

- `TableName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre de la tabla de las particiones.

- `ColumnName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la columna.

Respuesta

- Sin parámetros de respuesta.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`

API de partición

La API de partición describe los tipos de datos y las operaciones que se utilizan para trabajar con particiones.

Tipos de datos

- Estructura Partition
- Estructura PartitionInput
- Estructura PartitionSpecWithSharedStorageDescriptor
- Estructura PartitionListComposingSpec
- Estructura PartitionSpecProxy
- Estructura PartitionValueList

- Estructura Segment
- Estructura PartitionError
- Estructura BatchUpdatePartitionFailureEntry
- Estructura BatchUpdatePartitionRequestEntry
- Estructura StorageDescriptor
- Estructura SchemaReference
- Estructura SerDeInfo
- Estructura SkewedInfo

Estructura Partition

Representa un sector de los datos de la tabla.

Campos

- `Values`: matriz de cadenas UTF-8.

  Los valores de la partición.
- `DatabaseName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos de catálogos donde se crea la partición.
- `TableName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la tabla de base de datos en la que se desea crear la partición.
- `CreationTime`: marca temporal.

  La hora a la que se creó la partición.
- `LastAccessTime`: marca temporal.

  La última vez que se obtuvo acceso a la partición.
- `StorageDescriptor`: un objeto StorageDescriptor.

  Ofrece información sobre la ubicación física donde se almacena la partición.
- `Parameters`: matriz de mapas de pares clave-valor.

Cada clave es una cadena de claves con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

Cada valor es una cadena UTF-8 que no tiene más de 512000 bytes de largo.

Estos pares de clave-valor definen los parámetros de partición.

- `LastAnalyzedTime`: marca temporal.

  La última vez que se calcularon las estadísticas de columna para esta partición.

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  ID del Data Catalog donde reside la partición.

Estructura PartitionInput

La estructura que se utiliza para crear y actualizar una partición.

Campos

- `Values`: matriz de cadenas UTF-8.

  Los valores de la partición. Aunque este parámetro no lo requiere el SDK, debe especificarlo para una entrada válida.

  Los valores de las claves de la nueva partición deben pasarse como una matriz de objetos String que deben ordenarse en el mismo orden que las claves de partición que aparecen en el prefijo de Amazon S3. De lo contrario, AWS Glue agregará los valores a las claves erróneas.

- `LastAccessTime`: marca temporal.

  La última vez que se obtuvo acceso a la partición.

- `StorageDescriptor`: un objeto StorageDescriptor.

  Ofrece información sobre la ubicación física donde se almacena la partición.

- `Parameters`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena de claves con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

Cada valor es una cadena UTF-8 que no tiene más de 512000 bytes de largo.

Estos pares de clave-valor definen los parámetros de partición.

- `LastAnalyzedTime`: marca temporal.

  La última vez que se calcularon las estadísticas de columna para esta partición.

Estructura PartitionSpecWithSharedStorageDescriptor

Especificación de partición para las particiones que comparten una ubicación física.

Campos

- `StorageDescriptor`: un objeto StorageDescriptor.

  La información compartida sobre el almacenamiento físico.
- `Partitions`: matriz de objetos Partición.

  Lista de las particiones que comparten esta ubicación física.

Estructura PartitionListComposingSpec

Muestra las particiones relacionadas.

Campos

- `Partitions`: matriz de objetos Partición.

  Lista de las particiones en la especificación de composición.

Estructura PartitionSpecProxy

Ofrece una ruta hacia las particiones especificadas.

Campos

- `DatabaseName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

La base de datos de catálogos donde residen las particiones.

- `TableName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la tabla que contiene las particiones.

- `RootPath` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  La ruta raíz del proxy para abordar las particiones.

- `PartitionSpecWithSharedSD`: un objeto PartitionSpecWithSharedStorageDescriptor.

  Especificación de las particiones que comparten la misma ubicación de almacenamiento física.

- `PartitionListComposingSpec`: un objeto PartitionListComposingSpec.

  Especifica una lista de particiones.

Estructura PartitionValueList

Contiene una lista de valores que definen particiones.

Campos

- `Values` – Obligatorio: una matriz de cadenas UTF-8.

  La lista de valores.

Estructura Segment

Define una región de particiones de una tabla que no se solapa, lo que permite ejecutar varias solicitudes a la vez.

Campos

- `SegmentNumber` – Obligatorio: número (entero), cero como máximo.

  El número de índice de base cero del segmento. Por ejemplo, si el número total de segmentos es de 4, los valores `SegmentNumber` van de 0 a 3.

- `TotalSegments` – Obligatorio: número (entero), uno como mínimo o 10 como máximo.

El número total de segmentos.

Estructura PartitionError

Contiene información sobre un error de partición.

Campos

- `PartitionValues`: matriz de cadenas UTF-8.

  Los valores que definen la partición.
- `ErrorDetail`: un objeto ErrorDetail.

  Detalles sobre el error de la partición.

Estructura BatchUpdatePartitionFailureEntry

Contiene información sobre un error de partición de actualización por lotes.

Campos

- `PartitionValueList`: matriz de cadenas UTF-8, con 100 cadenas como máximo.

  Una lista de los valores que definen las particiones.
- `ErrorDetail`: un objeto ErrorDetail.

  Los detalles sobre el error de partición del actualización por lotes.

Estructura BatchUpdatePartitionRequestEntry

Una estructura que contiene los valores y la estructura utilizados para actualizar una partición.

Campos

- `PartitionValueList` – Obligatorio: matriz de cadenas UTF-8, con 100 cadenas como máximo.

  Una lista de los valores que definen las particiones.
- `PartitionInput`: obligatorio: objeto PartitionInput.

La estructura que se utiliza para actualizar una partición.

Estructura StorageDescriptor

Describe el almacenamiento físico de los datos de la tabla.

Campos

- `Columns`: matriz de objetos Columna.

  Una lista de las `Columns` de la tabla.
- `Location` – cadena de ubicación de un máximo de 2056 bytes de largo, que coincide con el URI address multi-line string pattern.

  Ubicación física de la tabla. De forma predeterminada, adopta la forma de la ubicación de almacén, seguida de la ubicación de la base de datos en el almacén, seguida del nombre de tabla.
- `AdditionalLocations`: matriz de cadenas UTF-8.

  Lista de ubicaciones que apuntan a la ruta en la que se encuentra una tabla Delta.
- `InputFormat` – cadena de formato de un máximo de 128 bytes de largo, que coincide con el Single-line string pattern.

  Formato de entrada: `SequenceFileInputFormat` (binario), `TextInputFormat` o formato personalizado.
- `OutputFormat` – cadena de formato de un máximo de 128 bytes de largo, que coincide con el Single-line string pattern.

  Formato de salida: `SequenceFileOutputFormat` (binario), `IgnoreKeyTextOutputFormat` o formato personalizado.
- `Compressed`: booleano.

  `True` si los datos de la tabla están comprimidos o `False` si no.
- `NumberOfBuckets`: número (entero).

  Debe especificarse si la tabla contiene alguna columna de dimensión.
- `SerdeInfo`: un objeto SerDeInfo.

  La información de serialización y deserialización (SerDe).

- `BucketColumns`: matriz de cadenas UTF-8.

  Lista de columnas de agrupamiento del reductor, columnas de clústeres y columnas de almacenamiento en bucket de la tabla.

- `SortColumns`: matriz de objetos Order.

  Una lista donde se especifica el orden de clasificación de cada bucket en la tabla.

- `Parameters`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena de claves con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Cada valor es una cadena UTF-8 que no tiene más de 512000 bytes de largo.

  Las propiedades facilitadas por el usuario en formato clave-valor.

- `SkewedInfo`: un objeto SkewedInfo.

  La información sobre los valores que aparecen con frecuencia en una columna (valores sesgados).

- `StoredAsSubDirectories`: booleano.

  `True` si los datos de la tabla se almacenan en subdirectorios o `False` si no.

- `SchemaReference`: un objeto SchemaReference.

  Objeto que hace referencia a un esquema almacenado en AWS Glue Schema Registry.

  Al crear una tabla, puede pasar una lista vacía de columnas para el esquema y, en su lugar, utilizar una referencia de esquema.

Estructura SchemaReference

Objeto que hace referencia a un esquema almacenado en AWS Glue Schema Registry.

Campos

- `SchemaId`: un objeto SchemaId.

  Estructura que contiene campos de identidad de esquema. Este o el `SchemaVersionId` tiene que ser proporcionado.

- `SchemaVersionId` – cadena UTF-8, con 36 bytes de largo como mínimo y 36 bytes de largo como máximo, que coincide con el Custom string pattern #45.

  El ID único asignado a una versión del esquema. Este o el `SchemaId` tiene que ser proporcionado.

- `SchemaVersionNumber`: número (largo) que no es inferior a 1 ni es superior a 100 000.

  El número de versión del esquema.

Estructura SerDeInfo

Información sobre un programa de serialización y deserialización (SerDe) que sirve de extractor y cargador.

Campos

- `Name` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del SerDe.

- `SerializationLibrary` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  En general, la clase que implementa el SerDe. Un ejemplo es: . `org.apache.hadoop.hive.serde2.columnar.ColumnarSerDe`.

- `Parameters`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena de claves con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Cada valor es una cadena UTF-8 que no tiene más de 512000 bytes de largo.

  Estos pares de clave-valor definen parámetros de inicialización para el SerDe.

Estructura SkewedInfo

Especifica valores sesgados en una tabla. Los valores sesgados son los que se producen con una frecuencia muy alta.

Campos

- `SkewedColumnNames`: matriz de cadenas UTF-8.

  Una lista de nombres de columnas que contienen valores de sesgado.
- `SkewedColumnValues`: matriz de cadenas UTF-8.

  Una lista de valores que aparecen con tanta frecuencia como para considerarse de sesgado.
- `SkewedColumnValueLocationMaps`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8.

  Cada valor es una cadena UTF-8.

  Un mapeo de valores de sesgado a las columnas que los contienen.

Operaciones

- Acción CreatePartition (Python: create_partition)
- Acción BatchCreatePartition (Python: batch_create_partition)
- Acción UpdatePartition (Python: update_partition)
- Acción DeletePartition (Python: delete_partition)
- Acción BatchDeletePartition (Python: batch_delete_partition)
- Acción GetPartition (Python: get_partition)
- Acción GetPartitions (Python: get_partitions)
- Acción BatchGetPartition (Python: batch_get_partition)
- Acción BatchUpdatePartition (Python: batch_update_partition)
- Acción GetColumnStatisticsForPartition (Python: get_column_statistics_for_partition)
- Acción UpdateColumnStatisticsForPartition (Python: update_column_statistics_for_partition)
- Acción DeleteColumnStatisticsForPartition (Python: delete_column_statistics_for_partition)

Acción CreatePartition (Python: create_partition)

Crea una partición nueva.

Solicitud

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de cuenta de AWS del catálogo en el que se creará la partición.

- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos de metadatos donde se va a crear la partición.

- `TableName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la tabla de datos de metadatos donde se va a crear la partición.

- `PartitionInput`: obligatorio: objeto PartitionInput.

  Estructura `PartitionInput` que define la partición que se va a crear.

Respuesta

- Sin parámetros de respuesta.

Errores

- `InvalidInputException`
- `AlreadyExistsException`
- `ResourceNumberLimitExceededException`
- `InternalServiceException`
- `EntityNotFoundException`
- `OperationTimeoutException`
- `GlueEncryptionException`

Acción BatchCreatePartition (Python: batch_create_partition)

Crea una o varias particiones en una operación por lotes.

Solicitud

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del catálogo en el que se va a crear la partición. En la actualidad, debe ser el ID de cuenta de AWS.

- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos de metadatos donde se va a crear la partición.

- `TableName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la tabla de datos de metadatos donde se va a crear la partición.

- `PartitionInputList` – Obligatorio: matriz de objetos PartitionInput, con 100 estructuras como máximo.

  Lista de estructuras `PartitionInput` que definen las particiones que se van a crear.

Respuesta

- `Errors`: matriz de objetos PartitionError.

  Los errores encontrados al intentar crear las particiones solicitadas.

Errores

- `InvalidInputException`
- `AlreadyExistsException`
- `ResourceNumberLimitExceededException`
- `InternalServiceException`
- `EntityNotFoundException`
- `OperationTimeoutException`
- `GlueEncryptionException`

Acción UpdatePartition (Python: update_partition)

Actualiza una partición.

Solicitud

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del catálogo de datos donde reside la partición que se va a actualizar. Si no se proporciona ninguno, se usará de forma predeterminada el ID de cuenta de AWS.
- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos de catálogos donde reside la tabla relevante.
- `TableName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la tabla donde se encuentra la partición que se va a actualizar.
- `PartitionValueList` – Obligatorio: matriz de cadenas UTF-8, con 100 cadenas como máximo.

  Lista de valores de clave de partición que definen la partición que se va a actualizar.
- `PartitionInput`: obligatorio: objeto PartitionInput.

  El nuevo objeto de la partición para el que se actualiza la partición.

  La propiedad `Values` no puede modificarse. Si desea modificar los valores de clave de partición de una partición, elimine y vuelva a crear la partición.

Respuesta

- Sin parámetros de respuesta.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`

- `OperationTimeoutException`
- `GlueEncryptionException`

Acción DeletePartition (Python: delete_partition)

Elimina la partición especificada.

Solicitud

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del catálogo de datos donde reside la partición que se va a eliminar. Si no se proporciona ninguno, se usará de forma predeterminada el ID de cuenta de AWS.
- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos de catálogos donde reside la tabla relevante.
- `TableName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la tabla que contiene la partición que se va a eliminar.
- `PartitionValues` – Obligatorio: una matriz de cadenas UTF-8.

  Los valores que definen la partición.

Respuesta

- Sin parámetros de respuesta.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

Acción BatchDeletePartition (Python: batch_delete_partition)

Elimina una o varias particiones en una operación por lotes.

Solicitud

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del catálogo de datos donde reside la partición que se va a eliminar. Si no se proporciona ninguno, se usará de forma predeterminada el ID de cuenta de AWS.
- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos de catálogos donde reside la tabla relevante.
- `TableName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la tabla que contiene las particiones que se van a eliminar.
- `PartitionsToDelete` – Obligatorio: matriz de objetos PartitionValueList, con 25 estructuras como máximo.

  Lista de estructuras `PartitionInput` que definen las particiones que se van a eliminar.

Respuesta

- `Errors`: matriz de objetos PartitionError.

  Los errores encontrados al intentar eliminar las particiones solicitadas.

Errores

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`

Acción GetPartition (Python: get_partition)

Recupera información sobre una partición especificada.

Solicitud

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del catálogo de datos donde reside la partición en cuestión. Si no se proporciona ninguno, se usará de forma predeterminada el ID de cuenta de AWS.
- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos de catálogos donde reside la partición.
- `TableName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre de la tabla de particiones.
- `PartitionValues` – Obligatorio: una matriz de cadenas UTF-8.

  Los valores que definen la partición.

Respuesta

- `Partition`: un objeto Partición.

  La información solicitada, con formato de objeto `Partition`.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`
- `FederationSourceException`

- `FederationSourceRetryableException`

Acción GetPartitions (Python: get_partitions)

Recupera información acerca de las particiones de una tabla.

Solicitud

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del Catálogo de datos donde residen las particiones en cuestión. Si no se proporciona ninguno, se usará de forma predeterminada el ID de cuenta de AWS.
- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos de catálogos donde residen las particiones.
- `TableName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre de la tabla de las particiones.
- `Expression` – cadena de predicado de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Una expresión que filtra las particiones que se van a devolver.

  La expresión usa una sintaxis SQL similar a la cláusula de filtro `WHERE` de SQL. El analizador de instrucciones SQL JSQLParser analiza la expresión.

  Operadores: estos son los operadores que puede usar en la llamada a la API `Expression`:

  =

  Comprueba si los valores de los dos operandos son iguales o no; en caso afirmativo, la condición será "true".

  Ejemplo: supongamos que la "variable a" tiene 10 y, la "variable b", 20.

  (a = b) no es "true".

< >

Comprueba si los valores de los dos operandos son iguales o no; en caso negativo, la condición será "true".

Ejemplo: (a < > b) es "true".

>

Comprueba si el valor del operando izquierdo es mayor que el valor del operando derecho; en caso afirmativo, la condición será "true".

Ejemplo: (a > b) no es "true".

<

Comprueba si el valor del operando izquierdo es menor que el valor del operando derecho; en caso afirmativo, la condición será "true".

Ejemplo: (a < b) es "true".

>=

Comprueba si el valor del operando izquierdo es mayor o igual que el valor del operando derecho; en caso afirmativo, la condición será "true".

Ejemplo: (a >= b) no es "true".

<=

Comprueba si el valor del operando izquierdo es menor o igual que el valor del operando derecho; en caso afirmativo, la condición será "true".

Ejemplo: (a <= b) es "true".

AND, OR, IN, BETWEEN, LIKE, NOT, IS NULL

Operadores lógicos.

Tipos de clave de partición admitidos: estas son las claves de partición admitidas.

- `string`
- `date`
- `timestamp`

- `int`
- `bigint`
- `long`
- `tinyint`
- `smallint`
- `decimal`

Si se encuentra un tipo no válido, se produce una excepción.

En la siguiente lista se muestran todos los tipos de operador válido. Al definir un rastreador, se crea el tipo `partitionKey` como `STRING`, para ser compatible con las particiones del catálogo.

Ejemplo de llamada a la API:

Example

La tabla `twitter_partition` tiene tres particiones:

```
year = 2015
        year = 2016
        year = 2017
```

Example

Get Partition `year` equivale a 2015

```
aws glue get-partitions --database-name dbname --table-name twitter_partition
        --expression "year*=*'2015'"
```

Example

Get Partition `year` entre 2016 y 2018 (exclusivo)

```
aws glue get-partitions --database-name dbname --table-name twitter_partition
        --expression "year>'2016' AND year<'2018'"
```

Example

Get Partition `year` entre 2015 y 2018 (incluido). Las siguientes llamadas a la API son equivalentes entre sí:

```
aws glue get-partitions --database-name dbname --table-name twitter_partition
        --expression "year>='2015' AND year<='2018'"

        aws glue get-partitions --database-name dbname --table-name
 twitter_partition
        --expression "year BETWEEN 2015 AND 2018"

        aws glue get-partitions --database-name dbname --table-name
 twitter_partition
        --expression "year IN (2015,2016,2017,2018)"
```

Example

Filtro comodín de partición, donde la siguiente salida de llamadas será el año de partición, 2017. No se admite una expresión regular en `LIKE`.

```
aws glue get-partitions --database-name dbname --table-name twitter_partition
        --expression "year LIKE '%7'"
```

- `NextToken`: cadena UTF-8.

  Token de continuación, si no es la primera llamada para recuperar estas particiones.

- `Segment`: un objeto Segmento.

  El segmento de las particiones de la tabla que se va a analizar en esta solicitud.

- `MaxResults`: número (entero) que no es inferior a 1 ni es superior a 1000.

  El número máximo de particiones que se devuelven en una única respuesta.

- `ExcludeColumnSchema`: booleano.

  Si es verdadero, especifica no devolver el esquema de columna de partición. Es útil cuando solo está interesado en otros atributos de partición, como valores de partición o ubicación. Este enfoque evita el problema de una respuesta grande al no devolver datos duplicados.

- `TransactionId` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #44.

  ID de transacción en el que se va a leer el contenido de la partición.

- `QueryAsOfTime`: marca temporal.

  El momento a partir del que se debe leer el contenido de la partición. Si no se establece, se utilizará el tiempo de confirmación de la transacción más reciente. No se puede especificar junto con `TransactionId`.

Respuesta

- `Partitions`: matriz de objetos Partición.

  Lista de particiones solicitadas.

- `NextToken`: cadena UTF-8.

  Un token de continuación, si la lista de particiones que se devuelve no incluye la última.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`
- `GlueEncryptionException`
- `InvalidStateException`
- `ResourceNotReadyException`
- `FederationSourceException`
- `FederationSourceRetryableException`

Acción BatchGetPartition (Python: batch_get_partition)

Recupera particiones en una solicitud por lotes.

Solicitud

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del Catálogo de datos donde residen las particiones en cuestión. Si no se proporciona ninguno, el ID de cuenta de AWS se usará de forma predeterminada.
- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos de catálogos donde residen las particiones.
- `TableName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre de la tabla de las particiones.
- `PartitionsToGet` – Obligatorio: matriz de objetos PartitionValueList, con 1000 estructuras como máximo.

  Lista de los valores de partición que identifican las particiones que se van a recuperar.

Respuesta

- `Partitions`: matriz de objetos Partición.

  Lista de las particiones solicitadas.
- `UnprocessedKeys`: matriz de objetos PartitionValueList, con 1000 estructuras como máximo.

  Una lista de los valores de partición en la solicitud para la que no se devolvieron particiones.

Errores

- `InvalidInputException`
- `EntityNotFoundException`
- `OperationTimeoutException`
- `InternalServiceException`
- `GlueEncryptionException`
- `InvalidStateException`

- `FederationSourceException`
- `FederationSourceRetryableException`

Acción BatchUpdatePartition (Python: batch_update_partition)

Actualiza una o varias particiones en una operación por lotes.

Solicitud

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del catálogo en el que se va a actualizar la partición. En la actualidad, debe ser el ID de cuenta de AWS.
- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos de metadatos donde se va a actualizar la partición.
- `TableName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la tabla de metadatos donde se va a actualizar la partición.
- `Entries` – Obligatorio: una matriz de objetos BatchUpdatePartitionRequestEntry, con 1 estructura como mínimo y 100 estructuras como máximo.

  Lista de hasta 100 objetos `BatchUpdatePartitionRequestEntry` que se van a actualizar.

Respuesta

- `Errors`: matriz de objetos BatchUpdatePartitionFailureEntry.

  Los errores encontrados al intentar actualizar las particiones solicitadas. Una lista de objetos `BatchUpdatePartitionFailureEntry`.

Errores

- `InvalidInputException`
- `EntityNotFoundException`

- `OperationTimeoutException`
- `InternalServiceException`
- `GlueEncryptionException`

Acción GetColumnStatisticsForPartition (Python: get_column_statistics_for_partition)

Recupera estadísticas de las columnas de las particiones.

El permiso de Identity and Access Management (IAM) necesario para esta operación es `GetPartition`.

Solicitud

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del Catálogo de datos donde residen las particiones en cuestión. Si no se proporciona ninguno, el ID de cuenta de AWS se usará de forma predeterminada.
- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos de catálogos donde residen las particiones.
- `TableName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre de la tabla de las particiones.
- `PartitionValues` – Obligatorio: una matriz de cadenas UTF-8.

  Una lista de los valores de las particiones que identifican la partición.
- `ColumnNames` – Obligatorio: matriz de cadenas UTF-8, con 100 cadenas como máximo.

  Una lista de los nombres de las columnas.

Respuesta

- `ColumnStatisticsList`: matriz de objetos ColumnStatistics.

  Lista de ColumnStatistics que no se pudieron recuperar.

- `Errors`: matriz de objetos ColumnError.

  Error al recuperar los datos estadísticos de la columna.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`

Acción UpdateColumnStatisticsForPartition (Python: update_column_statistics_for_partition)

Crea o actualiza las estadísticas de las columnas de las particiones.

El permiso de Identity and Access Management (IAM) necesario para esta operación es `UpdatePartition`.

Solicitud

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del Catálogo de datos donde residen las particiones en cuestión. Si no se proporciona ninguno, el ID de cuenta de AWS se usará de forma predeterminada.
- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos de catálogos donde residen las particiones.
- `TableName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre de la tabla de las particiones.
- `PartitionValues` – Obligatorio: una matriz de cadenas UTF-8.

  Una lista de los valores de las particiones que identifican la partición.

- `ColumnStatisticsList` – Obligatorio: matriz de objetos ColumnStatistics, con 25 estructuras como máximo.

  Una lista de las estadísticas de las columnas.

Respuesta

- `Errors`: matriz de objetos ColumnaStatisticsError.

  Error al actualizar los datos de estadísticas de columna.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`

Acción DeleteColumnStatisticsForPartition (Python: delete_column_statistics_for_partition)

Elimine las estadísticas de columnas de la partición de una columna.

El permiso de Identity and Access Management (IAM) necesario para esta operación es `DeletePartition`.

Solicitud

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del Catálogo de datos donde residen las particiones en cuestión. Si no se proporciona ninguno, el ID de cuenta de AWS se usará de forma predeterminada.
- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos de catálogos donde residen las particiones.

- `TableName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre de la tabla de las particiones.

- `PartitionValues` – Obligatorio: una matriz de cadenas UTF-8.

  Una lista de los valores de las particiones que identifican la partición.

- `ColumnName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la columna.

Respuesta

- Sin parámetros de respuesta.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`

API de conexión

La API de conexión describe los tipos de datos y las API relacionadas con el trabajo con conexiones en AWS Glue.

Temas

- API de conexión
- API de tipos de conexión
- API de vista previa y metadatos de conexión

API de conexión

La API de conexión describe los tipos de datos de conexión de AWS Glue y la API de creación, eliminación, actualización y creación de listados de conexiones.

Tipos de datos

- Estructura Connection
- Estructura ConnectionInput
- Estructura TestConnectionInput
- Estructura PhysicalConnectionRequirements
- Estructura GetConnectionsFilter
- Estructura AuthenticationConfiguration
- Estructura AuthenticationConfigurationInput
- Estructura OAuth2Properties
- Estructura OAuth2PropertiesInput
- Estructura OAuth2ClientApplication
- Estructura AuthorizationCodeProperties
- Estructura BasicAuthenticationCredentials
- Estructura OAuth2Credentials

Estructura Connection

Define una conexión a un origen de datos.

Campos

- `Name` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la definición de la conexión.

- `Description` – cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  La descripción de la conexión.

- `ConnectionType` – Cadena UTF-8 (valores válidos: `JDBC` | `SFTP` | `MONGODB` | `KAFKA` | `NETWORK` | `MARKETPLACE` | `CUSTOM` | `SALESFORCE` | `VIEW_VALIDATION_REDSHIFT` | `VIEW_VALIDATION_ATHENA` | `GOOGLEADS` | `GOOGLESHEETS` | `GOOGLEANALYTICS4` | `SERVICENOW` | `MARKETO` | `SAPODATA` | `ZENDESK` | `JIRACLOUD` | `NETSUITEERP` | `HUBSPOT` | `FACEBOOKADS` | `INSTAGRAMADS` | `ZOHOCRM` | `SALESFORCEPARDOT` | `SALESFORCEMARKETINGCLOUD` | `ADOBEANALYTICS` | `SLACK` | `LINKEDIN` | `MIXPANEL` | `ASANA` | `STRIPE` | `SMARTSHEET` | `DATADOG` | `WOOCOMMERCE` | `INTERCOM` | `SNAPCHATADS` | `PAYPAL` | `QUICKBOOKS` | `FACEBOOKPAGEINSIGHTS` | `FRESHDESK` | `TWILIO` | `DOCUSIGNMONITOR` | `FRESHSALES` | `ZOOM` | `GOOGLESEARCHCONSOLE` | `SALESFORCECOMMERCECLOUD` | `SAPCONCUR` | `DYNATRACE` | `MICROSOFTDYNAMIC365FINANCEANDOPS` | `MICROSOFTTEAMS` | `BLACKBAUDRAISEREDGENXT` | `MAILCHIMP` | `GITLAB` | `PENDO` | `PRODUCTBOARD` | `CIRCLECI` | `PIPEDIVE` | `SENDGRID` | `AZURECOSMOS` | `AZURESQL` | `BIGQUERY` | `BLACKBAUD` | `CLOUDERAHIVE` | `CLOUDERAIMPALA` | `CLOUDWATCH` | `CLOUDWATCHMETRICS` | `CMDB` | `DATALAKEGEN2` | `DB2` | `DB2AS400` | `DOCUMENTDB` | `DOMO` | `DYNAMODB` | `GOOGLECLOUDSTORAGE` | `HBASE` | `KUSTOMER` | `MICROSOFTDYNAMICS365CRM` | `MONDAY` | `MYSQL` | `OKTA` | `OPENSEARCH` | `ORACLE` | `PIPEDRIVE` | `POSTGRESQL` | `SAPHANA` | `SQLSERVER` | `SYNAPSE` | `TERADATA` | `TERADATANOS` | `TIMESTREAM` | `TPCDS` | `VERTICA`).

  Tipo de la conexión. Actualmente, SFTP no es compatible.

- `MatchCriteria`: matriz de cadenas UTF-8, con 10 cadenas como máximo.

  Una lista de criterios que se pueden usar para seleccionar esta conexión.

- `ConnectionProperties`: matriz de mapas de pares de clave-valor, con 100 pares como máximo.

  Cada clave es una cadena UTF-8 (valores válidos: `HOST` | `PORT` | `USERNAME="USER_NAME"` | `PASSWORD` | `ENCRYPTED_PASSWORD` | `JDBC_DRIVER_JAR_URI` | `JDBC_DRIVER_CLASS_NAME` | `JDBC_ENGINE` | `JDBC_ENGINE_VERSION` | `CONFIG_FILES` | `INSTANCE_ID` | `JDBC_CONNECTION_URL` | `JDBC_ENFORCE_SSL` | `CUSTOM_JDBC_CERT` | `SKIP_CUSTOM_JDBC_CERT_VALIDATION` | `CUSTOM_JDBC_CERT_STRING` | `CONNECTION_URL` | `KAFKA_BOOTSTRAP_SERVERS` | `KAFKA_SSL_ENABLED` | `KAFKA_CUSTOM_CERT` | `KAFKA_SKIP_CUSTOM_CERT_VALIDATION` | `KAFKA_CLIENT_KEYSTORE` | `KAFKA_CLIENT_KEYSTORE_PASSWORD` | `KAFKA_CLIENT_KEY_PASSWORD` | `ENCRYPTED_KAFKA_CLIENT_KEYSTORE_PASSWORD` | `ENCRYPTED_KAFKA_CLIENT_KEY_PASSWORD` | `KAFKA_SASL_MECHANISM` | `KAFKA_SASL_PLAIN_USERNAME` | `KAFKA_SASL_PLAIN_PASSWORD` | `ENCRYPTED_KAFKA_SASL_PLAIN_PASSWORD` | `KAFKA_SASL_SCRAM_USERNAME`

| KAFKA_SASL_SCRAM_PASSWORD | KAFKA_SASL_SCRAM_SECRETS_ARN | ENCRYPTED_KAFKA_SASL_SCRAM_PASSWORD | KAFKA_SASL_GSSAPI_KEYTAB | KAFKA_SASL_GSSAPI_KRB5_CONF | KAFKA_SASL_GSSAPI_SERVICE | KAFKA_SASL_GSSAPI_PRINCIPAL | SECRET_ID | CONNECTOR_URL | CONNECTOR_TYPE | CONNECTOR_CLASS_NAME | ENDPOINT | ENDPOINT_TYPE | ROLE_ARN | REGION | WORKGROUP_NAME | CLUSTER_IDENTIFIER | DATABASE).

Cada valor es una cadena Valor con una extensión de 1 byte como mínimo o 1024 bytes como máximo.

Estos pares de clave-valor definen los parámetros de la conexión cuando se utiliza el esquema de conexión de la versión 1:

- HOST: el URI de host, ya sea el nombre de dominio completo (FQDN) o la dirección IPv4 del host de la base de datos.
- PORT: el número de puerto, entre 1024 y 65535, del puerto en el que el host de la base de datos escucha las conexiones de la base de datos.
- USER_NAME: el nombre con el que iniciar sesión en la base de datos. La cadena de valor de USER_NAME es “USERNAME”.
- PASSWORD: contraseña, si se utiliza una, del nombre de usuario.
- ENCRYPTED_PASSWORD: cuando habilita la protección de la contraseña de conexión al establecer ConnectionPasswordEncryption en la configuración de cifrado del Catálogo de datos, este campo almacena la contraseña cifrada.
- JDBC_DRIVER_JAR_URI: la ruta de Amazon Simple Storage Service (Amazon S3) al archivo JAR que contiene el controlador JDBC que se va a utilizar.
- JDBC_DRIVER_CLASS_NAME: el nombre de la clase de controlador de JDBC que se va a utilizar.
- JDBC_ENGINE: nombre del motor JDBC que se va a utilizar.
- JDBC_ENGINE_VERSION: la versión del motor JDBC que se va a utilizar.
- CONFIG_FILES: (reservado para uso futuro).
- INSTANCE_ID: la ID de instancia que se va a utilizar.
- JDBC_CONNECTION_URL: la URL para conectarse a un origen de datos JDBC.
- JDBC_ENFORCE_SSL: una cadena booleana que no distingue mayúsculas de minúsculas (true, false) que especifica si se aplicará la coincidencia de capa de sockets seguros (SSL) con el nombre de host para la conexión JDBC en el cliente. El valor predeterminado es false.

- `CUSTOM_JDBC_CERT`: una ubicación de Amazon S3 que especifica el certificado raíz del cliente. AWS Glue utiliza este certificado raíz para validar el certificado del cliente al conectarse a la base de datos del cliente. AWS Glue solo gestiona certificados X.509. El certificado proporcionado debe estar codificado en DER y suministrarse en formato PEM de codificación Base64.
- `SKIP_CUSTOM_JDBC_CERT_VALIDATION`: predeterminado en `false`. AWS Glue valida el algoritmo de firma y el algoritmo de clave pública de sujeto para el certificado de cliente. Los únicos algoritmos permitidos para el algoritmo de firma son SHA256withRSA, SHA384withRSA o SHA512withRSA. Para el algoritmo de clave pública del sujeto, la longitud de la clave debe ser de al menos 2048. Puede establecer el valor de esta propiedad en para `true` omitir la validación del certificado de cliente por parte de AWS Glue.
- `CUSTOM_JDBC_CERT_STRING` : cadena de certificado JDBC personalizada que se utiliza para la coincidencia de dominio o la coincidencia de nombre distinguido para evitar un ataque man-in-the-middle. En la base de datos de Oracle, se utiliza como `SSL_SERVER_CERT_DN`; en Microsoft SQL Server, se utiliza como `hostNameInCertificate`.
- `CONNECTION_URL`: la URL para conectarse a un origen de datos general (no JDBC).
- `SECRET_ID`: la ID secreta utilizada para el administrador secreto de credenciales.
- `CONNECTOR_URL`: la URL del conector para una conexión MARKETPLACE o CUSTOM.
- `CONNECTOR_TYPE`: el tipo de conector para una conexión MARKETPLACE o CUSTOM.
- `CONNECTOR_CLASS_NAME`: el nombre de la clase del conector para una conexión MARKETPLACE o CUSTOM.
- `KAFKA_BOOTSTRAP_SERVERS`: una lista separada por comas de los pares de hosts y puertos que son las direcciones de los agentes de Apache Kafka en un clúster de Kafka al que un cliente Kafka se conectará y se arrancará.
- `KAFKA_SSL_ENABLED`: para habilitar o desactivar SSL en una conexión de Apache Kafka. El valor predeterminado es “verdadero”.
- `KAFKA_CUSTOM_CERT`: la URL de Amazon S3 para el archivo de certificado de CA privado (formato .pem). El valor predeterminado es una cadena vacía.
- `KAFKA_SKIP_CUSTOM_CERT_VALIDATION`: para omitir la validación del archivo certificado de CA o no. AWS Glue valida para tres algoritmos: SHA256withRSA, SHA384withRSA y SHA512withRSA. El valor predeterminado es “falso”.
- `KAFKA_CLIENT_KEYSTORE`: la ubicación de Amazon S3 del archivo de almacén de claves del cliente para la autenticación del lado del cliente Kafka (opcional).

- KAFKA_CLIENT_KEYSTORE_PASSWORD: la contraseña para acceder al almacén de claves proporcionado (opcional).
- KAFKA_CLIENT_KEY_PASSWORD: un almacén de claves puede consistir en varias claves, por lo que esta es la contraseña para acceder a la clave del cliente que se utilizará con la clave del lado del servidor Kafka (opcional).
- ENCRYPTED_KAFKA_CLIENT_KEYSTORE_PASSWORD: la versión cifrada de la contraseña del almacén de claves del cliente de Kafka (si el usuario ha seleccionado la configuración de cifrar contraseñas de AWS Glue).
- ENCRYPTED_KAFKA_CLIENT_KEY_PASSWORD: la versión cifrada de la contraseña de la clave del cliente de Kafka (si el usuario ha seleccionado la configuración de cifrar contraseñas de AWS Glue).
- KAFKA_SASL_MECHANISM: "SCRAM-SHA-512", "GSSAPI", "AWS_MSK_IAM" o "PLAIN". Estos son los mecanismos SASL compatibles.
- KAFKA_SASL_PLAIN_USERNAME: un nombre de usuario sin formato utilizado para la autenticación con el mecanismo “PLAIN”.
- KAFKA_SASL_PLAIN_PASSWORD: una contraseña sin formato utilizada para la autenticación con el mecanismo “PLAIN”.
- ENCRYPTED_KAFKA_SASL_PLAIN_PASSWORD: la versión cifrada de la contraseña de SASL PLAIN de Kafka (si el usuario seleccionó la configuración de cifrado de contraseñas de AWS Glue).
- KAFKA_SASL_SCRAM_USERNAME: nombre de usuario de texto sin formato utilizado para autenticarse con el mecanismo “SCRAM-SHA-512”.
- KAFKA_SASL_SCRAM_PASSWORD: contraseña de texto sin formato utilizada para autenticarse con el mecanismo “SCRAM-SHA-512”.
- ENCRYPTED_KAFKA_SASL_SCRAM_PASSWORD: la versión cifrada de la contraseña SASL SCRAM de Kafka (si el usuario ha seleccionado la configuración de cifrado de contraseñas de AWS Glue).
- KAFKA_SASL_SCRAM_SECRETS_ARN: El nombre de recurso de Amazon (ARN) de un secreto en Secrets Manager AWS.
- KAFKA_SASL_GSSAPI_KEYTAB: la ubicación S3 de un archivo keytab de Kerberos. Una keytab almacena claves a largo plazo para uno o varias entidades principales. Para obtener más información, consulte MIT Kerberos Documentation: Keytab (Documentación de MIT Kerberos: Keytab).

- `KAFKA_SASL_GSSAPI_KRB5_CONF`: la ubicación S3 de un archivo `krb5.conf` de Kerberos. Un krb5.conf almacena información de configuración de Kerberos, como la ubicación del servidor KDC. Para obtener más información, consulte MIT Kerberos Documentation: krb5.conf (Documentación de MIT Kerberos: krb5.conf).
- `KAFKA_SASL_GSSAPI_SERVICE`: el nombre del servicio Kerberos, tal como se establece con `sasl.kerberos.service.name` en la configuración de Kafka.
- `KAFKA_SASL_GSSAPI_PRINCIPAL` - el nombre de la entidad principal de Kerberos que utiliza AWS Glue. Para obtener más información, consulte Kafka Documentation: Configuring Kafka Brokers (Documentación de Kafka: Configuración de los agentes de Kafka).
- `ROLE_ARN`: el rol que se utilizará para ejecutar consultas.
- `REGION`: la región de AWS en la que se ejecutarán las consultas.
- `WORKGROUP_NAME`: el nombre del grupo de trabajo de Amazon Redshift sin servidor o del grupo de trabajo de Amazon Athena en el que se ejecutarán las consultas.
- `CLUSTER_IDENTIFIER`: el identificador de clúster de un clúster de Amazon Redshift en el que se ejecutarán las consultas.
- `DATABASE`: la base de datos de Amazon Redshift a la que se está conectando.

- `SparkProperties`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es una cadena UTF-8 con una extensión de 1 byte como mínimo o 2048 bytes como máximo.

  Propiedades de conexión específicas del entorno de computación de Spark.
- `AthenaProperties`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es una cadena UTF-8 con una extensión de 1 byte como mínimo o 2048 bytes como máximo.

  Propiedades de conexión específicas del entorno de computación de Athena.
- `PythonProperties`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

Cada valor es una cadena UTF-8 con una extensión de 1 byte como mínimo o 2048 bytes como máximo.

Propiedades de conexión específicas del entorno de computación de Python.

- `PhysicalConnectionRequirements`: un objeto PhysicalConnectionRequirements.

  Los requisitos de conexión física, como la nube privada virtual (VPC) y `SecurityGroup`, que se necesitan para crear la conexión correctamente.
- `CreationTime`: marca temporal.

  La marca temporal del momento en que se creó esta definición de conexión.
- `LastUpdatedTime`: marca temporal.

  La marca temporal de la última vez que se actualizó la definición de conexión.
- `LastUpdatedBy` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El usuario, el grupo o el rol que actualizaron por última vez la definición de esta conexión.
- `Status` – Cadena UTF-8 (valores válidos: `READY` | `IN_PROGRESS` | `FAILED`).

  El estado de la conexión. Puede ser: `READY`, `IN_PROGRESS` o `FAILED`.
- `StatusReason`: Cadena UTF-8 con 1 byte de largo como mínimo o 16 384 como máximo.

  Motivo del estado de la conexión.
- `LastConnectionValidationTime`: marca temporal.

  Una marca temporal de la última vez que se validó esta conexión.
- `AuthenticationConfiguration`: un objeto AuthenticationConfiguration.

  Las propiedades de autenticación de la conexión.
- `ConnectionSchemaVersion`: número (entero), mayor que 1 y menor que 2.

  La versión del esquema de conexión de esta conexión. La versión 2 admite propiedades para entornos de computación específicos.
- `CompatibleComputeEnvironments`: matriz de cadenas UTF-8.

  Una lista de entornos de computación compatibles con la conexión.

Estructura ConnectionInput

Una estructura que se usa para especificar una conexión que se va a crear o a actualizar.

Campos

- Name: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la conexión.

- Description – cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  La descripción de la conexión.

- ConnectionType – Obligatorio: cadena UTF-8 (valores válidos: JDBC | SFTP | MONGODB | KAFKA | NETWORK | MARKETPLACE | CUSTOM | SALESFORCE | VIEW_VALIDATION_REDSHIFT | VIEW_VALIDATION_ATHENA | GOOGLEADS | GOOGLESHEETS | GOOGLEANALYTICS4 | SERVICENOW | MARKETO | SAPODATA | ZENDESK | JIRACLOUD | NETSUITEERP | HUBSPOT | FACEBOOKADS | INSTAGRAMADS | ZOHOCRM | SALESFORCEPARDOT | SALESFORCEMARKETINGCLOUD | ADOBEANALYTICS | SLACK | LINKEDIN | MIXPANEL | ASANA | STRIPE | SMARTSHEET | DATADOG | WOOCOMMERCE | INTERCOM | SNAPCHATADS | PAYPAL | QUICKBOOKS | FACEBOOKPAGEINSIGHTS | FRESHDESK | TWILIO | DOCUSIGNMONITOR | FRESHSALES | ZOOM | GOOGLESEARCHCONSOLE | SALESFORCECOMMERCECLOUD | SAPCONCUR | DYNATRACE | MICROSOFTDYNAMIC365FINANCEANDOPS | MICROSOFTTEAMS | BLACKBAUDRAISEREDGENXT | MAILCHIMP | GITLAB | PENDO | PRODUCTBOARD | CIRCLECI | PIPEDIVE | SENDGRID | AZURECOSMOS | AZURESQL | BIGQUERY | BLACKBAUD | CLOUDERAHIVE | CLOUDERAIMPALA | CLOUDWATCH | CLOUDWATCHMETRICS | CMDB | DATALAKEGEN2 | DB2 | DB2AS400 | DOCUMENTDB | DOMO | DYNAMODB | GOOGLECLOUDSTORAGE | HBASE | KUSTOMER | MICROSOFTDYNAMICS365CRM | MONDAY | MYSQL | OKTA | OPENSEARCH | ORACLE | PIPEDRIVE | POSTGRESQL | SAPHANA | SQLSERVER | SYNAPSE | TERADATA | TERADATANOS | TIMESTREAM | TPCDS | VERTICA).

  Tipo de la conexión. Actualmente, estos tipos son compatibles:

  - JDBC: designa una conexión a una base de datos a través de Java Database Connectivity (JDBC).

    Las conexiones JDBC utilizan los siguientes parámetros ConnectionParameters.

    - Obligatorios: todos estos: HOST, PORT, JDBC_ENGINE; o bien JDBC_CONNECTION_URL.

- Obligatorios: todos estos: `USERNAME`, `PASSWORD`; o bien `SECRET_ID`.
- Opcionales: `JDBC_ENFORCE_SSL`, `CUSTOM_JDBC_CERT`, `CUSTOM_JDBC_CERT_STRING`, `SKIP_CUSTOM_JDBC_CERT_VALIDATION`. Estos parámetros se utilizan para configurar SSL con JDBC.

- `KAFKA`: designa una conexión a una plataforma de streaming Apache Kafka.

  Las conexiones `KAFKA` utilizan los siguientes parámetros ConnectionParameters.

  - Obligatorio: `KAFKA_BOOTSTRAP_SERVERS`.
  - Opcionales: `KAFKA_SSL_ENABLED`, `KAFKA_CUSTOM_CERT`, `KAFKA_SKIP_CUSTOM_CERT_VALIDATION`. Estos parámetros se utilizan para configurar SSL con `KAFKA`.
  - Opcionales: `KAFKA_CLIENT_KEYSTORE`, `KAFKA_CLIENT_KEYSTORE_PASSWORD`, `KAFKA_CLIENT_KEY_PASSWORD`, `ENCRYPTED_KAFKA_CLIENT_KEYSTORE_PASSWORD`, `ENCRYPTED_KAFKA_CLIENT_KEY_PASSWORD`. Estos parámetros se utilizan para establecer la configuración del cliente TLS con SSL en `KAFKA`.
  - Opcional: `KAFKA_SASL_MECHANISM`. Se puede especificar como `SCRAM-SHA-512`, `GSSAPI` o `AWS_MSK_IAM`.
  - Opcionales: `KAFKA_SASL_SCRAM_USERNAME`, `KAFKA_SASL_SCRAM_PASSWORD`, `ENCRYPTED_KAFKA_SASL_SCRAM_PASSWORD`. Estos parámetros se utilizan para configurar la autenticación SASL/SCRAM-SHA-512 con `KAFKA`.
  - Opcionales: `KAFKA_SASL_GSSAPI_KEYTAB`, `KAFKA_SASL_GSSAPI_KRB5_CONF`, `KAFKA_SASL_GSSAPI_SERVICE`, `KAFKA_SASL_GSSAPI_PRINCIPAL`. Estos parámetros se utilizan para configurar la autenticación SASL/GSSAPI con `KAFKA`.

- `MONGODB`: designa una conexión a una base de datos de documentos MongoDB.

  Las conexiones `MONGODB` utilizan los siguientes parámetros ConnectionParameters.

  - Obligatorio: `CONNECTION_URL`.
  - Obligatorios: todos estos: `USERNAME`, `PASSWORD`; o bien `SECRET_ID`.

- `VIEW_VALIDATION_REDSHIFT`: designa una conexión que Amazon Redshift utiliza para la validación de vistas.
- `VIEW_VALIDATION_ATHENA`: designa una conexión que Amazon Athena utiliza para la validación de vistas.
- `NETWORK`: designa una conexión de red a un origen de datos dentro de un entorno de Amazon Virtual Private Cloud (Amazon VPC).

Las conexiones NETWORK no requieren parámetros ConnectionParameters. En su lugar, proporcione un requisito PhysicalConnectionRequirements.

- MARKETPLACE: utiliza los ajustes de configuración contenidos en un conector adquirido de AWS Marketplace para leer y escribir en almacenes de datos que no son soportados de forma nativa por AWS Glue.

  Las conexiones MARKETPLACE utilizan los siguientes parámetros ConnectionParameters.

  - Obligatorios: CONNECTOR_TYPE, CONNECTOR_URL, CONNECTOR_CLASS_NAME, CONNECTION_URL.
  - Obligatorios para conexiones JDBC CONNECTOR_TYPE: todos estos: USERNAME, PASSWORD; o bien SECRET_ID.
- CUSTOM - utiliza los ajustes de configuración contenidos en un conector personalizado para leer y escribir en almacenes de datos que no son soportados de forma nativa por AWS Glue.

Si quiere obtener más información sobre los parámetros de conexión necesarios para un conector concreto, consulte la documentación del conector en Añadir una conexión AWS Glue en la Guía del usuario AWS Glue.

SFTP no se admite.

Para obtener más información sobre cómo se pueden utilizar propiedades ConnectionProperties opcionales para configurar características en AWS Glue, consulte Propiedades de las conexiones de AWS Glue.

Para obtener más información sobre cómo se pueden utilizar propiedades ConnectionProperties opcionales para configurar características en AWS Glue Studio, consulte Uso de conectores y conexiones.

- MatchCriteria: matriz de cadenas UTF-8, con 10 cadenas como máximo.

  Una lista de criterios que se pueden usar para seleccionar esta conexión.
- ConnectionProperties – Obligatorio: matriz de mapas de pares clave-valor, con 100 pares como máximo.

  Cada clave es una cadena UTF-8 (valores válidos: HOST | PORT | USERNAME="USER_NAME" | PASSWORD | ENCRYPTED_PASSWORD | JDBC_DRIVER_JAR_URI | JDBC_DRIVER_CLASS_NAME | JDBC_ENGINE | JDBC_ENGINE_VERSION | CONFIG_FILES | INSTANCE_ID | JDBC_CONNECTION_URL | JDBC_ENFORCE_SSL | CUSTOM_JDBC_CERT |

SKIP_CUSTOM_JDBC_CERT_VALIDATION | CUSTOM_JDBC_CERT_STRING | CONNECTION_URL | KAFKA_BOOTSTRAP_SERVERS | KAFKA_SSL_ENABLED | KAFKA_CUSTOM_CERT | KAFKA_SKIP_CUSTOM_CERT_VALIDATION | KAFKA_CLIENT_KEYSTORE | KAFKA_CLIENT_KEYSTORE_PASSWORD | KAFKA_CLIENT_KEY_PASSWORD | ENCRYPTED_KAFKA_CLIENT_KEYSTORE_PASSWORD | ENCRYPTED_KAFKA_CLIENT_KEY_PASSWORD | KAFKA_SASL_MECHANISM | KAFKA_SASL_PLAIN_USERNAME | KAFKA_SASL_PLAIN_PASSWORD | ENCRYPTED_KAFKA_SASL_PLAIN_PASSWORD | KAFKA_SASL_SCRAM_USERNAME | KAFKA_SASL_SCRAM_PASSWORD | KAFKA_SASL_SCRAM_SECRETS_ARN | ENCRYPTED_KAFKA_SASL_SCRAM_PASSWORD | KAFKA_SASL_GSSAPI_KEYTAB | KAFKA_SASL_GSSAPI_KRB5_CONF | KAFKA_SASL_GSSAPI_SERVICE | KAFKA_SASL_GSSAPI_PRINCIPAL | SECRET_ID | CONNECTOR_URL | CONNECTOR_TYPE | CONNECTOR_CLASS_NAME | ENDPOINT | ENDPOINT_TYPE | ROLE_ARN | REGION | WORKGROUP_NAME | CLUSTER_IDENTIFIER | DATABASE).

Cada valor es una cadena Valor con una extensión de 1 byte como mínimo o 1024 bytes como máximo.

Estos pares de clave-valor definen parámetros para la conexión.

- `SparkProperties`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es una cadena UTF-8 con una extensión de 1 byte como mínimo o 2048 bytes como máximo.

  Propiedades de conexión específicas del entorno de computación de Spark.

- `AthenaProperties`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es una cadena UTF-8 con una extensión de 1 byte como mínimo o 2048 bytes como máximo.

  Propiedades de conexión específicas del entorno de computación de Athena.

- `PythonProperties`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

Cada valor es una cadena UTF-8 con una extensión de 1 byte como mínimo o 2048 bytes como máximo.

Propiedades de conexión específicas del entorno de computación de Python.

- `PhysicalConnectionRequirements`: un objeto PhysicalConnectionRequirements.

  Los requisitos de conexión física, como la nube privada virtual (VPC) y `SecurityGroup`, que se necesitan para crear esta conexión correctamente.

- `AuthenticationConfiguration`: un objeto AuthenticationConfigurationInput.

  Las propiedades de autenticación de la conexión.

- `ValidateCredentials`: booleano.

  Un indicador para validar las credenciales durante la creación de la conexión. El valor predeterminado es verdadero.

- `ValidateForComputeEnvironments`: matriz de cadenas UTF-8.

  Entornos de computación en los que se validan las propiedades de conexión especificadas.

Estructura TestConnectionInput

Estructura que se usa para especificar la prueba de una conexión a un servicio.

Campos

- `ConnectionType` – Obligatorio: cadena UTF-8 (valores válidos: `JDBC` | `SFTP` | `MONGODB` | `KAFKA` | `NETWORK` | `MARKETPLACE` | `CUSTOM` | `SALESFORCE` | `VIEW_VALIDATION_REDSHIFT` | `VIEW_VALIDATION_ATHENA` | `GOOGLEADS` | `GOOGLESHEETS` | `GOOGLEANALYTICS4` | `SERVICENOW` | `MARKETO` | `SAPODATA` | `ZENDESK` | `JIRACLOUD` | `NETSUITEERP` | `HUBSPOT` | `FACEBOOKADS` | `INSTAGRAMADS` | `ZOHOCRM` | `SALESFORCEPARDOT` | `SALESFORCEMARKETINGCLOUD` | `ADOBEANALYTICS` | `SLACK` | `LINKEDIN` | `MIXPANEL` | `ASANA` | `STRIPE` | `SMARTSHEET` | `DATADOG` | `WOOCOMMERCE` | `INTERCOM` | `SNAPCHATADS` | `PAYPAL` | `QUICKBOOKS` | `FACEBOOKPAGEINSIGHTS` | `FRESHDESK` | `TWILIO` | `DOCUSIGNMONITOR` | `FRESHSALES` | `ZOOM` | `GOOGLESEARCHCONSOLE` | `SALESFORCECOMMERCECLOUD` | `SAPCONCUR` | `DYNATRACE` | `MICROSOFTDYNAMIC365FINANCEANDOPS` | `MICROSOFTTEAMS` | `BLACKBAUDRAISEREDGENXT` | `MAILCHIMP` | `GITLAB` | `PENDO` | `PRODUCTBOARD` | `CIRCLECI` | `PIPEDIVE` | `SENDGRID` | `AZURECOSMOS` | `AZURESQL` | `BIGQUERY` | `BLACKBAUD` | `CLOUDERAHIVE`

| CLOUDERAIMPALA | CLOUDWATCH | CLOUDWATCHMETRICS | CMDB | DATALAKEGEN2 | DB2 | DB2AS400 | DOCUMENTDB | DOMO | DYNAMODB | GOOGLECLOUDSTORAGE | HBASE | KUSTOMER | MICROSOFTDYNAMICS365CRM | MONDAY | MYSQL | OKTA | OPENSEARCH | ORACLE | PIPEDRIVE | POSTGRESQL | SAPHANA | SQLSERVER | SYNAPSE | TERADATA | TERADATANOS | TIMESTREAM | TPCDS | VERTICA).

Tipo de conexión que se va a probar. Esta operación solo está disponible para los tipos de conexión JDBC o SALESFORCE.

- ConnectionProperties – Obligatorio: matriz de mapas de pares clave-valor, con 100 pares como máximo.

  Cada clave es una cadena UTF-8 (valores válidos: HOST | PORT | USERNAME="USER_NAME" | PASSWORD | ENCRYPTED_PASSWORD | JDBC_DRIVER_JAR_URI | JDBC_DRIVER_CLASS_NAME | JDBC_ENGINE | JDBC_ENGINE_VERSION | CONFIG_FILES | INSTANCE_ID | JDBC_CONNECTION_URL | JDBC_ENFORCE_SSL | CUSTOM_JDBC_CERT | SKIP_CUSTOM_JDBC_CERT_VALIDATION | CUSTOM_JDBC_CERT_STRING | CONNECTION_URL | KAFKA_BOOTSTRAP_SERVERS | KAFKA_SSL_ENABLED | KAFKA_CUSTOM_CERT | KAFKA_SKIP_CUSTOM_CERT_VALIDATION | KAFKA_CLIENT_KEYSTORE | KAFKA_CLIENT_KEYSTORE_PASSWORD | KAFKA_CLIENT_KEY_PASSWORD | ENCRYPTED_KAFKA_CLIENT_KEYSTORE_PASSWORD | ENCRYPTED_KAFKA_CLIENT_KEY_PASSWORD | KAFKA_SASL_MECHANISM | KAFKA_SASL_PLAIN_USERNAME | KAFKA_SASL_PLAIN_PASSWORD | ENCRYPTED_KAFKA_SASL_PLAIN_PASSWORD | KAFKA_SASL_SCRAM_USERNAME | KAFKA_SASL_SCRAM_PASSWORD | KAFKA_SASL_SCRAM_SECRETS_ARN | ENCRYPTED_KAFKA_SASL_SCRAM_PASSWORD | KAFKA_SASL_GSSAPI_KEYTAB | KAFKA_SASL_GSSAPI_KRB5_CONF | KAFKA_SASL_GSSAPI_SERVICE | KAFKA_SASL_GSSAPI_PRINCIPAL | SECRET_ID | CONNECTOR_URL | CONNECTOR_TYPE | CONNECTOR_CLASS_NAME | ENDPOINT | ENDPOINT_TYPE | ROLE_ARN | REGION | WORKGROUP_NAME | CLUSTER_IDENTIFIER | DATABASE).

  Cada valor es una cadena Valor con una extensión de 1 byte como mínimo o 1024 bytes como máximo.

  Estos pares de clave-valor definen parámetros para la conexión.

  Las conexiones JDBC utilizan las siguientes propiedades de conexión:

  - Obligatorios: todos estos: HOST, PORT, JDBC_ENGINE; o bien JDBC_CONNECTION_URL.

- Obligatorios: todos estos: `USERNAME`, `PASSWORD`; o bien `SECRET_ID`.
- Opcionales: `JDBC_ENFORCE_SSL`, `CUSTOM_JDBC_CERT`, `CUSTOM_JDBC_CERT_STRING`, `SKIP_CUSTOM_JDBC_CERT_VALIDATION`. Estos parámetros se utilizan para configurar SSL con JDBC.

Las conexiones de SALESFORCE requieren que se configure el miembro `AuthenticationConfiguration`.

- `AuthenticationConfiguration`: un objeto AuthenticationConfigurationInput.

  Estructura que contiene la configuración de la autenticación en la solicitud TestConnection. Es necesario para realizar una conexión a Salesforce mediante la autenticación OAuth.

Estructura PhysicalConnectionRequirements

La aplicación cliente de OAuth en la respuesta GetConnection.

Campos

- `SubnetId` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de subred utilizado por la conexión.
- `SecurityGroupIdList`: matriz de cadenas UTF-8, con 50 cadenas como máximo.

  La lista de ID de grupo de seguridad usados por la conexión.
- `AvailabilityZone` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  La zona de disponibilidad de la conexión.

Estructura GetConnectionsFilter

Filtra las definiciones de conexión que devuelve la operación de la API `GetConnections`.

Campos

- `MatchCriteria`: matriz de cadenas UTF-8, con 10 cadenas como máximo.

Una cadena de criterios que debe coincidir con los criterios registrados en la definición de la conexión para que dicha definición se devuelva.

- `ConnectionType` – Cadena UTF-8 (valores válidos: `JDBC` | `SFTP` | `MONGODB` | `KAFKA` | `NETWORK` | `MARKETPLACE` | `CUSTOM` | `SALESFORCE` | `VIEW_VALIDATION_REDSHIFT` | `VIEW_VALIDATION_ATHENA` | `GOOGLEADS` | `GOOGLESHEETS` | `GOOGLEANALYTICS4` | `SERVICENOW` | `MARKETO` | `SAPODATA` | `ZENDESK` | `JIRACLOUD` | `NETSUITEERP` | `HUBSPOT` | `FACEBOOKADS` | `INSTAGRAMADS` | `ZOHOCRM` | `SALESFORCEPARDOT` | `SALESFORCEMARKETINGCLOUD` | `ADOBEANALYTICS` | `SLACK` | `LINKEDIN` | `MIXPANEL` | `ASANA` | `STRIPE` | `SMARTSHEET` | `DATADOG` | `WOOCOMMERCE` | `INTERCOM` | `SNAPCHATADS` | `PAYPAL` | `QUICKBOOKS` | `FACEBOOKPAGEINSIGHTS` | `FRESHDESK` | `TWILIO` | `DOCUSIGNMONITOR` | `FRESHSALES` | `ZOOM` | `GOOGLESEARCHCONSOLE` | `SALESFORCECOMMERCECLOUD` | `SAPCONCUR` | `DYNATRACE` | `MICROSOFTDYNAMIC365FINANCEANDOPS` | `MICROSOFTTEAMS` | `BLACKBAUDRAISEREDGENXT` | `MAILCHIMP` | `GITLAB` | `PENDO` | `PRODUCTBOARD` | `CIRCLECI` | `PIPEDIVE` | `SENDGRID` | `AZURECOSMOS` | `AZURESQL` | `BIGQUERY` | `BLACKBAUD` | `CLOUDERAHIVE` | `CLOUDERAIMPALA` | `CLOUDWATCH` | `CLOUDWATCHMETRICS` | `CMDB` | `DATALAKEGEN2` | `DB2` | `DB2AS400` | `DOCUMENTDB` | `DOMO` | `DYNAMODB` | `GOOGLECLOUDSTORAGE` | `HBASE` | `KUSTOMER` | `MICROSOFTDYNAMICS365CRM` | `MONDAY` | `MYSQL` | `OKTA` | `OPENSEARCH` | `ORACLE` | `PIPEDRIVE` | `POSTGRESQL` | `SAPHANA` | `SQLSERVER` | `SYNAPSE` | `TERADATA` | `TERADATANOS` | `TIMESTREAM` | `TPCDS` | `VERTICA`).

  Tipo de conexiones que se van a devolver. Actualmente, SFTP no es compatible.

- `ConnectionSchemaVersion`: número (entero), mayor que 1 y menor que 2.

  Indica si la conexión se creó con la versión 1 o 2 del esquema.

Estructura AuthenticationConfiguration

Estructura que contiene la configuración de la autenticación.

Campos

- `AuthenticationType` – Cadena UTF-8 (valores válidos: `BASIC` | `OAUTH2` | `CUSTOM` | `IAM`).

  Estructura que contiene la configuración de la autenticación.

- `SecretArn` – cadena UTF-8 que coincide con el Custom string pattern #36.

  El ARN de Secrets Manager para almacenar las credenciales.

- `KmsKeyArn` – cadena UTF-8 que coincide con el Custom string pattern #42.

  Nombre de recurso de Amazon (ARN) de la clave de KMS usada para cifrar la información confidencial de autenticación. Esta clave protege las credenciales y otros datos confidenciales almacenados en la configuración de autenticación.
- `OAuth2Properties`: un objeto OAuth2Properties.

  Las propiedades para la autenticación de OAuth2.

Estructura AuthenticationConfigurationInput

Estructura que contiene la configuración de la autenticación en la solicitud CreateConnection.

Campos

- `AuthenticationType` – Cadena UTF-8 (valores válidos: `BASIC` | `OAUTH2` | `CUSTOM` | `IAM`).

  Estructura que contiene la configuración de la autenticación en la solicitud CreateConnection.
- `OAuth2Properties`: un objeto OAuth2PropertiesInput.

  Las propiedades de la autenticación de OAuth2 en la solicitud CreateConnection.
- `SecretArn` – cadena UTF-8 que coincide con el Custom string pattern #36.

  El ARN de Secrets Manager para almacenar las credenciales en la solicitud CreateConnection.
- `KmsKeyArn` – cadena UTF-8 que coincide con el Custom string pattern #42.

  El ARN de la clave de KMS que se utiliza para cifrar la conexión. Solo se usa como entrada en la solicitud y se almacena en Secret Manager.
- `BasicAuthenticationCredentials`: un objeto BasicAuthenticationCredentials.

  Credenciales que se usan cuando el tipo de autenticación es la autenticación básica.
- `CustomAuthenticationCredentials`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es una cadena UTF-8 con una extensión de 1 byte como mínimo o 2048 bytes como máximo.

  Credenciales que se usan cuando el tipo de autenticación es una autenticación personalizada.

Estructura OAuth2Properties

Una estructura que contiene propiedades para la autenticación de OAuth2.

Campos

- `OAuth2GrantType` – Cadena UTF-8 (valores válidos: `AUTHORIZATION_CODE` | `CLIENT_CREDENTIALS` | `JWT_BEARER`).

  El tipo de concesión de OAuth2. Por ejemplo, `AUTHORIZATION_CODE`, `JWT_BEARER` o `CLIENT_CREDENTIALS`.

- `OAuth2ClientApplication`: un objeto OAuth2ClientApplication.

  El tipo de aplicación cliente. Por ejemplo, AWS_MANAGED o USER_MANAGED.

- `TokenUrl` – cadena UTF-8, de 256 bytes de largo como máximo, que coincide con Custom string pattern #40.

  La URL del servidor de autenticación del proveedor para intercambiar un código de autorización por un token de acceso.

- `TokenUrlParametersMap`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es una cadena UTF-8 con 1 byte de largo como mínimo o 512 como máximo.

  Un mapa de parámetros que se añaden a la solicitud `GET` de token.

Estructura OAuth2PropertiesInput

Estructura que contiene las propiedades para OAuth2 en la solicitud CreateConnection.

Campos

- `OAuth2GrantType` – Cadena UTF-8 (valores válidos: `AUTHORIZATION_CODE` | `CLIENT_CREDENTIALS` | `JWT_BEARER`).

  El tipo de concesión de OAuth2 en la solicitud CreateConnection. Por ejemplo, `AUTHORIZATION_CODE`, `JWT_BEARER` o `CLIENT_CREDENTIALS`.

- `OAuth2ClientApplication`: un objeto OAuth2ClientApplication.

El tipo de aplicación cliente en la solicitud CreateConnection. Por ejemplo, `AWS_MANAGED` o `USER_MANAGED`.

- `TokenUrl` – cadena UTF-8, de 256 bytes de largo como máximo, que coincide con Custom string pattern #40.

  La URL del servidor de autenticación del proveedor para intercambiar un código de autorización por un token de acceso.

- `TokenUrlParametersMap`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es una cadena UTF-8 con 1 byte de largo como mínimo o 512 como máximo.

  Un mapa de parámetros que se añaden a la solicitud `GET` de token.

- `AuthorizationCodeProperties`: un objeto AuthorizationCodeProperties.

  El conjunto de propiedades necesarias para el tipo de concesión `AUTHORIZATION_CODE` de OAuth2.

- `OAuth2Credentials`: un objeto OAuth2Credentials.

  Credenciales que se usan cuando el tipo de autenticación es una autenticación OAuth2.

Estructura OAuth2ClientApplication

La aplicación cliente de OAuth2 que se usa para la conexión.

Campos

- `UserManagedClientApplicationClientId` – cadena UTF-8 con un máximo de 2048 bytes de largo, que coincide con el Custom string pattern #37.

  El ClientID de la aplicación cliente si el tipo de aplicación cliente es `USER_MANAGED`.

- `AWSManagedClientApplicationReference` – cadena UTF-8 con un máximo de 2048 bytes de largo, que coincide con el Custom string pattern #37.

  La referencia a la aplicación cliente del lado SaaS administrada por AWS.

Estructura AuthorizationCodeProperties

El conjunto de propiedades necesario para el flujo de trabajo del tipo de concesión `AUTHORIZATION_CODE` de OAuth2.

Campos

- `AuthorizationCode` – Cadena UTF-8 con 1 byte de largo como mínimo o 4096 como máximo, que coincide con Custom string pattern #37.

  Un código de autorización que se usará en la tercera fase del flujo de trabajo de la concesión `AUTHORIZATION_CODE`. Se trata de un código de un solo uso que deja de ser válido una vez que se intercambia por un token de acceso, por lo que es aceptable tener este valor como parámetro de solicitud.
- `RedirectUri` – Cadena UTF-8 con 512 bytes de largo como máximo, que coincide con Custom string pattern #41.

  El URI de redireccionamiento al que el servidor de autorización redirige al usuario al emitir un código de autorización. El URI se usa posteriormente cuando el código de autorización se intercambia por un token de acceso.

Estructura BasicAuthenticationCredentials

Para proporcionar credenciales de autenticación básica cuando no se suministra un valor `SecretArn`.

Campos

- `Username` – Cadena UTF-8 con 512 bytes de largo como máximo, que coincide con Custom string pattern #37.

  El nombre de usuario para conectarse al origen de datos.
- `Password` – Cadena UTF-8 con 512 bytes de largo como máximo, que coincide con Custom string pattern #33.

  La contraseña para conectarse al origen de datos.

Estructura OAuth2Credentials

Credenciales que se usan cuando el tipo de autenticación es una autenticación OAuth2.

Campos

- `UserManagedClientApplicationClientSecret` – Cadena UTF-8 con 512 bytes de largo como máximo, que coincide con Custom string pattern #38.

  El secreto del cliente de la aplicación si la aplicación cliente es administrada por el usuario.

- `AccessToken`: cadena UTF-8 con una extensión de 4096 bytes como máximo, que coincide con Custom string pattern #38.

  El token de acceso que se utiliza cuando el tipo de autenticación es OAuth2.

- `RefreshToken`: cadena UTF-8 con una extensión de 4096 bytes como máximo, que coincide con Custom string pattern #38.

  El token de actualización que se utiliza cuando el tipo de autenticación es OAuth2.

- `JwtToken`: Cadena UTF-8 con una extensión de 8000 bytes como máximo, que coincide con Custom string pattern #39.

  El token web JSON (JWT) que se utiliza cuando el tipo de autenticación es OAuth2.

Operaciones

- Acción CreateConnection (Python: create_connection)
- Acción DeleteConnection (Python: delete_connection)
- Acción GetConnection (Python: get_connection)
- Acción GetConnections (Python: get_connections)
- Acción UpdateConnection (Python: update_connection)
- Acción TestConnection (Python: test_connection)
- Acción BatchDeleteConnection (Python: batch_delete_connection)

Acción CreateConnection (Python: create_connection)

Crea una definición de la conexión en el Catálogo de datos.

Las conexiones utilizadas para crear recursos federados requieren el permiso `glue:PassConnection` de IAM.

Solicitud

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del Catálogo de datos donde se crea la conexión. Si no se proporciona ninguno, se usará de forma predeterminada el ID de cuenta de AWS.
- `ConnectionInput`: obligatorio: objeto ConnectionInput.

  Objeto `ConnectionInput` que define la conexión que se va a crear.
- `Tags`: matriz de mapas de pares de clave-valor, con 50 pares como máximo.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es una cadena UTF-8 que no tiene más de 256 bytes de largo.

  Etiquetas que asigna a la conexión.

Respuesta

- `CreateConnectionStatus` – Cadena UTF-8 (valores válidos: `READY` | `IN_PROGRESS` | `FAILED`).

  El estado de la solicitud de creación de conexión. La solicitud puede llevar tiempo en algunos tipos de autenticación, por ejemplo, cuando se crea una conexión OAuth con intercambio de tokens por medio de una VPC.

Errores

- `AlreadyExistsException`
- `InvalidInputException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`
- `GlueEncryptionException`

Acción DeleteConnection (Python: delete_connection)

Elimina una conexión del Catálogo de datos.

Solicitud

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del Catálogo de datos donde reside la conexión. Si no se proporciona ninguno, se usará de forma predeterminada el ID de cuenta de AWS.
- `ConnectionName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la conexión que se va a eliminar.

Respuesta

- Sin parámetros de respuesta.

Errores

- `EntityNotFoundException`
- `OperationTimeoutException`

Acción GetConnection (Python: get_connection)

Recupera una definición de la conexión del Catálogo de datos.

Solicitud

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del Catálogo de datos donde reside la conexión. Si no se proporciona ninguno, se usará de forma predeterminada el ID de cuenta de AWS.
- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la definición de la conexión que se va a recuperar.
- `HidePassword`: booleano.

Le permite recuperar los metadatos de conexión sin devolver la contraseña. Por ejemplo, la consola de AWS Glue utiliza esta marca para recuperar la conexión y no muestra la contraseña. Establezca este parámetro cuando es posible que el que realiza la llamada no tenga permiso para usar la clave AWS KMS para descifrar la contraseña, pero tenga permiso para acceder al resto de las propiedades de conexión.

- `ApplyOverrideForComputeEnvironment` – Cadena UTF-8 (valores válidos: `SPARK` | `ATHENA` | `PYTHON`).

  En el caso de las conexiones que se pueden utilizar en varios servicios, especifica las propiedades que se devuelven para el entorno de computación especificado.

Respuesta

- `Connection`: un objeto Connection.

  La definición de la conexión solicitada.

Errores

- `EntityNotFoundException`
- `OperationTimeoutException`
- `InvalidInputException`
- `GlueEncryptionException`

Acción GetConnections (Python: get_connections)

Recupera una lista de definiciones de la conexión del Catálogo de datos.

Solicitud

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del Catálogo de datos donde residen las conexiones. Si no se proporciona ninguno, se usará de forma predeterminada el ID de cuenta de AWS.

- `Filter`: un objeto GetConnectionsFilter.

Un filtro que controla las conexiones que se devolverán.

- `HidePassword`: booleano.

  Le permite recuperar los metadatos de conexión sin devolver la contraseña. Por ejemplo, la consola de AWS Glue utiliza esta marca para recuperar la conexión y no muestra la contraseña. Establezca este parámetro cuando es posible que el que realiza la llamada no tenga permiso para usar la clave AWS KMS para descifrar la contraseña, pero tenga permiso para acceder al resto de las propiedades de conexión.

- `NextToken`: cadena UTF-8.

  Token de continuación si se trata de una llamada de continuidad.

- `MaxResults`: número (entero) que no es inferior a 1 ni es superior a 1000.

  El número máximo de conexiones que se devuelven en una respuesta.

Respuesta

- `ConnectionList`: matriz de objetos Connection.

  Una lista de definiciones de la conexión solicitadas.

- `NextToken`: cadena UTF-8.

  Un token de continuación, si la lista de conexiones que se devuelve no incluye la última conexión filtrada.

Errores

- `EntityNotFoundException`
- `OperationTimeoutException`
- `InvalidInputException`
- `GlueEncryptionException`

Acción UpdateConnection (Python: update_connection)

Actualiza una definición de la conexión en el Catálogo de datos.

Solicitud

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del Catálogo de datos donde reside la conexión. Si no se proporciona ninguno, se usará de forma predeterminada el ID de cuenta de AWS.
- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la definición de la conexión que se va a actualizar.
- `ConnectionInput`: obligatorio: objeto ConnectionInput.

  Un objeto `ConnectionInput` que redefine la conexión en cuestión.

Respuesta

- Sin parámetros de respuesta.

Errores

- `InvalidInputException`
- `EntityNotFoundException`
- `OperationTimeoutException`
- `InvalidInputException`
- `GlueEncryptionException`

Acción TestConnection (Python: test_connection)

Prueba una conexión a un servicio para validar las credenciales de servicio que proporcione.

Puede proporcionar un nombre de conexión existente o `TestConnectionInput` para probar una entrada de conexión que no exista. Si proporciona ambos elementos al mismo tiempo, se producirá un error.

Si la acción se realiza correctamente, el servicio devuelve una respuesta HTTP 200.

Solicitud

- `ConnectionName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Opcional. Es el nombre de la conexión que se va a probar. Si solo proporciona el nombre, la operación obtendrá la conexión y la usará para realizar las pruebas.
- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del catálogo donde se encuentra la conexión.
- `TestConnectionInput`: un objeto TestConnectionInput.

  Estructura que se usa para especificar la prueba de una conexión a un servicio.

Respuesta

- Sin parámetros de respuesta.

Errores

- `InvalidInputException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`
- `GlueEncryptionException`
- `FederationSourceException`
- `AccessDeniedException`
- `EntityNotFoundException`
- `ConflictException`
- `InternalServiceException`

Acción BatchDeleteConnection (Python: batch_delete_connection)

Elimina una lista de definiciones de la conexión del Catálogo de datos.

Solicitud

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del Catálogo de datos donde residen las conexiones. Si no se proporciona ninguno, se usará de forma predeterminada el ID de cuenta de AWS.
- `ConnectionNameList` – Obligatorio: matriz de cadenas UTF-8, con 25 cadenas como máximo.

  Una lista de nombres de las conexiones que se van a eliminar.

Respuesta

- `Succeeded`: matriz de cadenas UTF-8.

  Una lista de nombres de las definiciones de la conexión que se eliminaron con éxito.
- `Errors`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Cada valor es un objeto ErrorDetail.

  Una asignación de los nombres de conexiones que no se eliminaron con éxito a los detalles del error.

Errores

- `InternalServiceException`
- `OperationTimeoutException`

API de tipos de conexión

La API de tipos de conexión describe las API AWS Glue relacionadas con la descripción de los tipos de conexión.

API de administración de conexiones

- Acción DescribeConnectionType (Python: describe_connection_type)

- Acción ListConnectionTypes (Python: list_connection_types)
- Estructura ConnectionTypeBrief
- Estructura ConnectionTypeVariant

Acción DescribeConnectionType (Python: describe_connection_type)

La API `DescribeConnectionType` proporciona todos los detalles de las opciones admitidas para un tipo de conexión determinado en AWS Glue.

Solicitud

- `ConnectionType`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del tipo de conexión que se va a describir.

Respuesta

- `ConnectionType` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del tipo de conexión.
- `Description`: cadena UTF-8, no más de 1024 bytes de largo.

  Descripción del tipo de conexión.
- `Capabilities`: un objeto Capacidades.

  Los tipos de autenticación, los tipos de interfaz de datos (entornos de computación) y las operaciones de datos del conector compatibles.
- `ConnectionProperties`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es un objeto A Propiedad.

  Propiedades de conexión que son comunes en todos los entornos de computación.
- `ConnectionOptions`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

Cada valor es un objeto A Propiedad.

Devuelve las propiedades que se pueden establecer al crear una conexión en `ConnectionInput.ConnectionProperties`. `ConnectionOptions` define los parámetros que se pueden configurar en un script ETL de Spark en el mapa de opciones de conexión que se pasa a un marco de datos.

- `AuthenticationConfiguration`: un objeto AuthConfiguration.

  El tipo de autenticación que se va a utilizar para la conexión.

- `ComputeEnvironmentConfigurations`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es un objeto A ComputeEnvironmentConfiguration.

  Entornos de computación compatibles con la conexión.

- `PhysicalConnectionRequirements`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es un objeto A Propiedad.

  Requisitos físicos de una conexión, como las especificaciones de VPC, subred y grupo de seguridad.

- `AthenaConnectionProperties`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es un objeto A Propiedad.

  Propiedades de conexión específicas del entorno de computación de Athena.

- `PythonConnectionProperties`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es un objeto A Propiedad.

  Propiedades de conexión específicas del entorno de computación de Python.

- `SparkConnectionProperties`: matriz de mapas de pares clave-valor.

Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

Cada valor es un objeto A Propiedad.

Propiedades de conexión específicas del entorno de computación de Spark.

Errores

- `ValidationException`
- `InvalidInputException`
- `InternalServiceException`

Acción ListConnectionTypes (Python: list_connection_types)

La API `ListConnectionTypes` proporciona un mecanismo de detección para saber cuáles son los tipos de conexión disponibles en AWS Glue. La respuesta contiene una lista de tipos de conexión con información extremadamente detallada sobre qué se admite en cada tipo de conexión. Los tipos de conexión que se muestran son el un conjunto de opciones compatibles para el valor `ConnectionType` de la API `CreateConnection`.

Solicitud

- `MaxResults`: número (entero) que no es inferior a 1 ni es superior a 1000.

  El número máximo de resultados que devolver.
- `NextToken` – cadena UTF-8, con 1 byte de largo como mínimo y 2048 bytes de largo como máximo, que coincide con el Custom string pattern #11.

  Token de continuación si se trata de una llamada de continuidad.

Respuesta

- `ConnectionTypes`: matriz de objetos ConnectionTypeBrief.

  Una lista de objetos `ConnectionTypeBrief` que contiene información breve sobre los tipos de conexión compatibles.
- `NextToken` – cadena UTF-8, con 1 byte de largo como mínimo y 2048 bytes de largo como máximo, que coincide con el Custom string pattern #11.

Un token de continuación, que está presente si el segmento de lista actual no es el último.

Errores

- `InternalServiceException`

Estructura ConnectionTypeBrief

Información breve sobre un tipo de conexión compatible que devuelve la API `ListConnectionTypes`.

Campos

- `ConnectionType` – Cadena UTF-8 (valores válidos: `JDBC` | `SFTP` | `MONGODB` | `KAFKA` | `NETWORK` | `MARKETPLACE` | `CUSTOM` | `SALESFORCE` | `VIEW_VALIDATION_REDSHIFT` | `VIEW_VALIDATION_ATHENA` | `GOOGLEADS` | `GOOGLESHEETS` | `GOOGLEANALYTICS4` | `SERVICENOW` | `MARKETO` | `SAPODATA` | `ZENDESK` | `JIRACLOUD` | `NETSUITEERP` | `HUBSPOT` | `FACEBOOKADS` | `INSTAGRAMADS` | `ZOHOCRM` | `SALESFORCEPARDOT` | `SALESFORCEMARKETINGCLOUD` | `ADOBEANALYTICS` | `SLACK` | `LINKEDIN` | `MIXPANEL` | `ASANA` | `STRIPE` | `SMARTSHEET` | `DATADOG` | `WOOCOMMERCE` | `INTERCOM` | `SNAPCHATADS` | `PAYPAL` | `QUICKBOOKS` | `FACEBOOKPAGEINSIGHTS` | `FRESHDESK` | `TWILIO` | `DOCUSIGNMONITOR` | `FRESHSALES` | `ZOOM` | `GOOGLESEARCHCONSOLE` | `SALESFORCECOMMERCECLOUD` | `SAPCONCUR` | `DYNATRACE` | `MICROSOFTDYNAMIC365FINANCEANDOPS` | `MICROSOFTTEAMS` | `BLACKBAUDRAISEREDGENXT` | `MAILCHIMP` | `GITLAB` | `PENDO` | `PRODUCTBOARD` | `CIRCLECI` | `PIPEDIVE` | `SENDGRID` | `AZURECOSMOS` | `AZURESQL` | `BIGQUERY` | `BLACKBAUD` | `CLOUDERAHIVE` | `CLOUDERAIMPALA` | `CLOUDWATCH` | `CLOUDWATCHMETRICS` | `CMDB` | `DATALAKEGEN2` | `DB2` | `DB2AS400` | `DOCUMENTDB` | `DOMO` | `DYNAMODB` | `GOOGLECLOUDSTORAGE` | `HBASE` | `KUSTOMER` | `MICROSOFTDYNAMICS365CRM` | `MONDAY` | `MYSQL` | `OKTA` | `OPENSEARCH` | `ORACLE` | `PIPEDRIVE` | `POSTGRESQL` | `SAPHANA` | `SQLSERVER` | `SYNAPSE` | `TERADATA` | `TERADATANOS` | `TIMESTREAM` | `TPCDS` | `VERTICA`).

  El nombre del tipo de conexión.

- `DisplayName`: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo.

  El nombre en formato legible para humanos del tipo de conexión que aparece en la consola de AWS Glue.

- `Vendor`: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo.

  El nombre del vendedor o proveedor que creó o mantiene este tipo de conexión.

- `Description`: cadena UTF-8, no más de 1024 bytes de largo.

  Descripción del tipo de conexión.

- `Categories` – .

  Lista de las categorías a las que pertenece este tipo de conexión. Las categorías permiten a los usuarios filtrar y encontrar los tipos de conexión adecuados según los casos de uso.

- `Capabilities`: un objeto Capacidades.

  Los tipos de autenticación, los tipos de interfaz de datos (entornos de computación) y las operaciones de datos del conector compatibles.

- `LogoUrl`: cadena UTF-8.

  URL del logotipo asociado a un tipo de conexión.

- `ConnectionTypeVariants`: matriz de objetos ConnectionTypeVariant.

  Lista de variantes disponibles para este tipo de conexión. Las distintas variantes pueden ofrecer configuraciones especializadas para casos de uso específicos o implementaciones dentro del mismo tipo general de conexión.

Estructura ConnectionTypeVariant

Representa una variante de un tipo de conexión en el Catálogo de datos de AWS Glue. Las variantes de tipo de conexión ofrecen configuraciones y comportamientos específicos para distintas implementaciones del mismo tipo general de conexión.

Campos

- `ConnectionTypeVariantName`: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo.

  Identificador único de la variante de tipo de conexión. Este nombre se usa internamente para identificar la variante específica de un tipo de conexión.

- `DisplayName`: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo.

El nombre en formato legible para humanos de la variante del tipo de conexión que aparece en la consola de AWS Glue.

- `Description`: cadena UTF-8, no más de 1024 bytes de largo.

  Descripción detallada de la variante del tipo de conexión, que incluye su propósito, casos de uso y cualquier requisito de configuración específico.
- `LogoUrl`: cadena UTF-8.

  URL del logotipo asociado a una variante de tipo de conexión.

datatypes

- Estructura de Validación
- Estructura AuthConfiguration
- Estructura de capacidades
- Estructura de propiedad
- Estructura AllowedValue
- Estructura ComputeEnvironmentConfiguration

Estructura de Validación

Define cómo se realiza una validación en una propiedad de conexión.

Campos

- `ValidationType`: obligatorio: cadena UTF-8 (valores válidos: `REGEX` | `RANGE`).

  El tipo de validación que se va a realizar, como `REGEX`.
- `Patterns` – .

  Una lista con los patrones que se aplican a la validación.
- `Description`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 1024 como máximo.

  Una descripción de la validación.
- `MaxLength`: número (entero).

Longitud máxima de una propiedad de conexión de cadenas.

- `Maximum`: número (entero).

  Valor máximo al especificar un tipo de validación `RANGE`.

- `Minimum`: número (entero).

  Valor mínimo al especificar un tipo de validación `RANGE`.

Estructura AuthConfiguration

Es la configuración de autenticación de una conexión que devuelve la API `DescribeConnectionType`.

Campos

- `AuthenticationType`: obligatorio: objeto Propiedad.

  El tipo de autenticación de una conexión.

- `SecretArn`: un objeto Propiedad.

  El nombre de recurso de Amazon (ARN) de Secrets Manager.

- `OAuth2Properties`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es un objeto A Propiedad.

  Asignación de pares clave-valor para las propiedades de OAuth2. Cada valor es un objeto `Property`.

- `BasicAuthenticationProperties`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es un objeto A Propiedad.

  Asignación de pares clave-valor para las propiedades de OAuth2. Cada valor es un objeto `Property`.

- `CustomAuthenticationProperties`: matriz de mapas de pares clave-valor.

Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

Cada valor es un objeto A Propiedad.

Asignación de pares clave-valor para las propiedades de autenticación personalizadas. Cada valor es un objeto `Property`.

Estructura de capacidades

Especifica los tipos de autenticación compatibles que devuelve la API `DescribeConnectionType`.

Campos

- `SupportedAuthenticationTypes`: obligatorio: una matriz de cadenas UTF-8.

  Una lista de los tipos de autenticación compatibles.
- `SupportedDataOperations`: obligatorio: una matriz de cadenas UTF-8.

  Una lista de las operaciones de datos compatibles.
- `SupportedComputeEnvironments`: obligatorio: una matriz de cadenas UTF-8.

  Una lista de los entornos de computación compatibles.

Estructura de propiedad

Objeto que define un tipo de conexión para un entorno de computación.

Campos

- `Name`: requerido: cadena UTF-8 con una extensión de 1 byte como mínimo y 128 bytes como máximo.

  El nombre de la propiedad.
- `Description`: requerido: cadena UTF-8 con una extensión de 1024 bytes como máximo.

  Una descripción de la propiedad.
- `Required` – Obligatorio: Booleano.

  Indica si la propiedad es necesaria.

- `PropertyTypes`: obligatorio: una matriz de cadenas UTF-8.

  Describe el tipo de propiedad.
- `AllowedValues`: matriz de objetos AllowedValue.

  Lista de objetos `AllowedValue` que representan los valores permitidos en la propiedad.
- `DataOperationScopes`: matriz de cadenas UTF-8.

  Indica qué operaciones de datos se aplican a la propiedad.

Estructura AllowedValue

Objeto que representa un valor permitido en la propiedad.

Campos

- `Description`: cadena UTF-8, no más de 1024 bytes de largo.

  Descripción del valor permitido.
- `Value`: requerido: cadena UTF-8 con una extensión de 1 byte como mínimo y 128 bytes como máximo.

  El valor permitido de la propiedad.

Estructura ComputeEnvironmentConfiguration

Un objeto que contiene la configuración de un entorno de computación (como Spark, Python o Athena) y que devuelve la API `DescribeConnectionType`.

Campos

- `Name`: requerido: cadena UTF-8 con una extensión de 1 byte como mínimo y 128 bytes como máximo.

  Nombre para la configuración del entorno de computación.
- `Description`: requerido: cadena UTF-8 con una extensión de 1024 bytes como máximo.

  La descripción del entorno de computación.
- `ComputeEnvironment` – Obligatorio: cadena UTF-8 (valores válidos: `SPARK` | `ATHENA` | `PYTHON`).

El tipo de entorno de computación.

- `SupportedAuthenticationTypes`: obligatorio: una matriz de cadenas UTF-8.

  Tipos de autenticación compatibles en el entorno de computación.

- `ConnectionOptions` – Obligatorio: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es un objeto A Propiedad.

  Parámetros que se usan como opciones de conexión en el entorno de computación.

- `ConnectionPropertyNameOverrides` – Obligatorio: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es una cadena UTF-8 con una extensión de 1 byte como mínimo o 128 bytes como máximo.

  El nombre de la propiedad de conexión se anula en el entorno de computación.

- `ConnectionOptionNameOverrides` – Obligatorio: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es una cadena UTF-8 con una extensión de 1 byte como mínimo o 128 bytes como máximo.

  El nombre de la opción de conexión se anula en el entorno de computación.

- `ConnectionPropertiesRequiredOverrides` – Requerido: .

  Propiedades de conexión que son necesarias para realizar anulaciones en el entorno de computación.

- `PhysicalConnectionPropertiesRequired`: booleano.

  Indica si `PhysicalConnectionProperties` son necesarias en el entorno de computación.

API de vista previa y metadatos de conexión

Las siguientes API de conexión describen las operaciones que se utilizan para describir los metadatos de conexión.

Tipos de datos

- Estructura de la entidad
- Estructura de campo

Estructura de la entidad

Entidad respaldada por un elemento `ConnectionType`.

Campos

- `EntityName`: cadena UTF-8.

  El nombre de la entidad.

- `Label`: cadena UTF-8.

  Etiqueta que se utiliza en la entidad.

- `IsParentEntity`: booleano.

  Un valor booleano que le permite determinar si hay objetos secundarios que se puedan enumerar.

- `Description`: cadena UTF-8.

  Descripción de la entidad.

- `Category`: cadena UTF-8.

  El tipo de entidades que están presentes en la respuesta. Este valor depende del origen de la conexión. Por ejemplo, esto es `SObjects` para Salesforce y `databases` o `schemas` o `tables` para orígenes como Amazon Redshift.

- `CustomProperties` –

  Mapa opcional de claves que un conector puede devolver a una entidad.

Estructura de campo

El objeto `Field` contiene información sobre las distintas propiedades asociadas a un campo del conector.

Campos

- `FieldName`: cadena UTF-8.

  Identificador único del campo.

- `Label`: cadena UTF-8.

  Etiqueta legible que se utiliza en el campo.

- `Description`: cadena UTF-8.

  Descripción del campo.

- `FieldType` – Cadena UTF-8 (valores válidos: `INT` | `SMALLINT` | `BIGINT` | `FLOAT` | `LONG` | `DATE` | `BOOLEAN` | `MAP` | `ARRAY` | `STRING` | `TIMESTAMP` | `DECIMAL` | `BYTE` | `SHORT` | `DOUBLE` | `STRUCT`).

  Tipo de datos en el campo.

- `IsPrimaryKey`: booleano.

  Indica si este campo se puede utilizar como clave principal en la entidad determinada.

- `IsNullable`: booleano.

  Indica si este campo se puede anular o no.

- `IsRetrievable`: booleano.

  Indica si este campo se puede agregar a la cláusula Select de una consulta de SQL o si se puede recuperar.

- `IsFilterable`: booleano.

  Indica si este campo se puede utilizar en una cláusula de filtro (cláusula `WHERE`) de una instrucción de SQL al consultar datos.

- `IsPartitionable`: booleano.

  Indica si un campo determinado se puede utilizar para particionar la consulta realizada en SaaS.

- `IsCreateable`: booleano.

  Indica si este campo se puede crear como parte de una escritura de destino.

- `IsUpdateable`: booleano.

  Indica si este campo se puede actualizar como parte de una escritura de destino.

- `IsUpsertable`: booleano.

  Indica si este campo se puede actualizar o insertar como parte de una escritura de destino.

- `IsDefaultOnCreate`: booleano.

  Indica si este campo se rellena automáticamente cuando se crea el objeto; por ejemplo, si se crea en una marca de tiempo.

- `SupportedValues` – .

  Lista de valores admitidos para el campo especificado.

- `SupportedFilterOperators`: matriz de cadenas UTF-8.

  Indica los operadores de filtro compatibles con este campo.

- `CustomProperties` –

  Mapa opcional de claves que se pueden devolver.

Operaciones

- Acción ListEntities (Python: list_entities)
- Acción DescribeEntity (Python: describe_entity)
- Acción GetEntityRecords (Python: get_entity_records)

Acción ListEntities (Python: list_entities)

Devuelve las entidades disponibles que admite el tipo de conexión.

Solicitud

- `ConnectionName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre de la conexión que tiene las credenciales necesarias para consultar cualquier tipo de conexión.

- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

Identificador del catálogo que contiene la conexión. Puede ser nulo, pero, de forma predeterminada, el ID de cuenta de AWS es el ID del catálogo.

- `ParentEntityName`: cadena UTF-8.

  Nombre de la entidad principal para la que desea enumerar todas las entidades secundarias. Este parámetro toma una ruta completa de la entidad para enumerar las entidades secundarias.

- `NextToken` – cadena UTF-8, con 1 byte de largo como mínimo y 2048 bytes de largo como máximo, que coincide con el Custom string pattern #11.

  Token de continuación, incluido si se trata de una llamada de continuidad.

- `DataStoreApiVersion` – cadena UTF-8, con 1 byte de largo como mínimo y 256 bytes de largo como máximo, que coincide con el Custom string pattern #23.

  Versión API del conector de SaaS.

Respuesta

- `Entities`: matriz de objetos Entidad.

  Una lista de objetos `Entity`.

- `NextToken` – cadena UTF-8, con 1 byte de largo como mínimo y 2048 bytes de largo como máximo, que coincide con el Custom string pattern #11.

  Un token de continuación, presente si el segmento de lista actual no es el último.

Errores

- `EntityNotFoundException`
- `OperationTimeoutException`
- `InvalidInputException`
- `GlueEncryptionException`
- `ValidationException`
- `FederationSourceException`
- `AccessDeniedException`

Acción DescribeEntity (Python: describe_entity)

Proporciona detalles sobre la entidad que se utiliza con el tipo de conexión, además de una descripción del modelo de datos para cada campo de la entidad seleccionada.

La respuesta incluye todos los campos que componen la entidad.

Solicitud

- `ConnectionName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre de la conexión que contiene las credenciales del tipo de conexión.
- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Identificador del catálogo que contiene la conexión. Puede ser nulo, pero, de forma predeterminada, el ID de cuenta de AWS es el ID del catálogo.
- `EntityName` – Obligatorio: cadena UTF-8.

  El nombre de la entidad que desea describir desde el tipo de conexión.
- `NextToken` – cadena UTF-8, con 1 byte de largo como mínimo y 2048 bytes de largo como máximo, que coincide con el Custom string pattern #11.

  Token de continuación, incluido si se trata de una llamada de continuidad.
- `DataStoreApiVersion` – cadena UTF-8, con 1 byte de largo como mínimo y 256 bytes de largo como máximo, que coincide con el Custom string pattern #23.

  La versión de la API que se utiliza en el almacén de datos.

Respuesta

- `Fields`: matriz de objetos Campo.

  Describe los campos de esa entidad de conector. Esta es la lista de objetos `Field`. `Field` es muy similar a una columna de una base de datos. El objeto `Field` contiene información sobre las distintas propiedades asociadas a los campos del conector.
- `NextToken` – cadena UTF-8, con 1 byte de largo como mínimo y 2048 bytes de largo como máximo, que coincide con el Custom string pattern #11.

Un token de continuación, presente si el segmento de lista actual no es el último.

Errores

- `EntityNotFoundException`
- `OperationTimeoutException`
- `InvalidInputException`
- `GlueEncryptionException`
- `ValidationException`
- `FederationSourceException`
- `AccessDeniedException`

Acción GetEntityRecords (Python: get_entity_records)

Esta API se utiliza para consultar datos de vista previa de un tipo de conexión determinado o de un catálogo de datos nativo AWS Glue basado en Amazon S3.

Devuelve los registros como una matriz de blobs de JSON. Cada registro se formatea mediante el nodo JSON de Jackson en función del tipo de campo que haya definido la API `DescribeEntity`.

Los conectores de Spark generan esquemas siguiendo la misma asignación de tipos de datos que tiene la API `DescribeEntity`. Los conectores de Spark convierten los datos en los tipos de datos adecuados que coinciden con el esquema al devolver filas.

Solicitud

- `ConnectionName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre de la conexión que contiene las credenciales del tipo de conexión.
- `CatalogId` – cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Identificador del catálogo que contiene la conexión. Puede ser nulo, pero, de forma predeterminada, el ID de cuenta de AWS es el ID del catálogo.
- `EntityName` – Obligatorio: cadena UTF-8.

Nombre de la entidad en la que quiere consultar los datos de vista previa de un tipo de conexión determinado.

- `NextToken` – cadena UTF-8, con 1 byte de largo como mínimo y 2048 bytes de largo como máximo, que coincide con el Custom string pattern #11.

  Token de continuación, incluido si se trata de una llamada de continuidad.

- `DataStoreApiVersion` – cadena UTF-8, con 1 byte de largo como mínimo y 256 bytes de largo como máximo, que coincide con el Custom string pattern #23.

  Versión API del conector de SaaS.

- `ConnectionOptions`: matriz de mapas de pares de clave-valor, con 100 pares como máximo.

  Cada clave es una cadena UTF-8 con una extensión de 1 byte como mínimo y 256 bytes como máximo y que coincide con Custom string pattern #18.

  Cada valor es una cadena UTF-8 con una extensión de 1 byte como mínimo y 256 bytes como máximo y que coincide con Custom string pattern #17.

  Opciones de conector que se requieren para consultar los datos.

- `FilterPredicate`: Cadena UTF-8 con una extensión de 1 byte como mínimo o 100 000 como máximo.

  Predicado de filtro que puede aplicar en la solicitud de consulta.

- `Limit` (requerido): número (largo) que no es menor que 1 ni mayor que 1000.

  Limita el número de registros que se obtienen en cada solicitud.

- `SelectedFields`: matriz de cadenas UTF-8 que no tiene menos de 1 cadena ni más de 1000.

  Lista de los campos que quiere obtener como parte de los datos de vista previa.

Respuesta

- `Records`: un conjunto de estructuras.

  Una lista de los objetos solicitados.

- `NextToken` – cadena UTF-8, con 1 byte de largo como mínimo y 2048 bytes de largo como máximo, que coincide con el Custom string pattern #11.

Un token de continuación, presente si el segmento de lista actual no es el último.

Errores

- `EntityNotFoundException`
- `OperationTimeoutException`
- `InvalidInputException`
- `GlueEncryptionException`
- `ValidationException`
- `FederationSourceException`
- `AccessDeniedException`

API de funciones definidas por el usuario

La API de funciones definidas por el usuario describe los tipos de datos y las operaciones de AWS Glue que se utilizan para trabajar con funciones.

Tipos de datos

- Estructura UserDefinedFunction
- Estructura UserDefinedFunctionInput

Estructura UserDefinedFunction

Representa el equivalente a una definición de función Hive definida por el usuario (`UDF`).

Campos

- `FunctionName`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la función.
- `DatabaseName`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre de la base de datos del catálogo que contiene la función.

- `ClassName`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  La clase de Java que contiene el código de la función.

- `OwnerName`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El propietario de la función.

- `OwnerType`: cadena UTF-8 (valores válidos: `USER` | `ROLE` | `GROUP`).

  El tipo de propietario.

- `CreateTime`: marca temporal.

  La hora a la que se creó la función.

- `ResourceUris`: matriz de objetos ResourceUri, con 1000 estructuras como máximo.

  Los URI del recurso para la función.

- `CatalogId`: cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del Catálogo de datos donde reside la función.

Estructura UserDefinedFunctionInput

Un estructura que se utiliza para crear o actualizar funciones definidas por el usuario.

Campos

- `FunctionName`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la función.

- `ClassName`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  La clase de Java que contiene el código de la función.

- `OwnerName`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

El propietario de la función.

- `OwnerType`: cadena UTF-8 (valores válidos: `USER` | `ROLE` | `GROUP`).

  El tipo de propietario.

- `ResourceUris`: matriz de objetos ResourceUri, con 1000 estructuras como máximo.

  Los URI del recurso para la función.

Operaciones

- Acción CreateUserDefinedFunction (Python: create_user_defined_function)
- Acción UpdateUserDefinedFunction (Python: update_user_defined_function)
- Acción DeleteUserDefinedFunction (Python: delete_user_defined_function)
- Acción GetUserDefinedFunction (Python: get_user_defined_function)
- Acción GetUserDefinedFunctions (Python: get_user_defined_functions)

Acción CreateUserDefinedFunction (Python: create_user_defined_function)

Crea una nueva definición de función en el Catálogo de datos.

Solicitud

- `CatalogId`: cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del Catálogo de datos donde se crea la función. Si no se proporciona ninguno, se usará de forma predeterminada el ID de cuenta de AWS.

- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos de catálogos donde se crea la función.

- `FunctionInput` – Obligatorio: objeto UserDefinedFunctionInput.

  Objeto `FunctionInput` que define la función que se va a crear en el Catálogo de datos.

Respuesta

- Sin parámetros de respuesta.

Errores

- `AlreadyExistsException`
- `InvalidInputException`
- `InternalServiceException`
- `EntityNotFoundException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`
- `GlueEncryptionException`

Acción UpdateUserDefinedFunction (Python: update_user_defined_function)

Actualiza una definición de función existente en el Catálogo de datos.

Solicitud

- `CatalogId`: cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del Catálogo de datos donde se encuentra la función que se va a actualizar. Si no se proporciona ninguno, se usará de forma predeterminada el ID de cuenta de AWS.
- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos de catálogos donde se encuentra la función que se va a actualizar.
- `FunctionName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la función.
- `FunctionInput` – Obligatorio: objeto UserDefinedFunctionInput.

  Un objeto `FunctionInput` que redefine la función que en el Catálogo de datos.

Respuesta

- Sin parámetros de respuesta.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`

Acción DeleteUserDefinedFunction (Python: delete_user_defined_function)

Elimina una definición de función existente del Catálogo de datos.

Solicitud

- `CatalogId`: cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del Catálogo de datos donde se encuentra la función que se va a eliminar. Si no se proporciona ninguno, el ID de cuenta de AWS se usará de forma predeterminada.
- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos de catálogos donde se encuentra la función.
- `FunctionName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la definición de la función que se va a eliminar.

Respuesta

- Sin parámetros de respuesta.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

Acción GetUserDefinedFunction (Python: get_user_defined_function)

Recupera una definición de función especificada del Catálogo de datos.

Solicitud

- `CatalogId`: cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del Catálogo de datos donde se encuentra la función que se va a recuperar. Si no se proporciona ninguno, se usará de forma predeterminada el ID de cuenta de AWS.
- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos de catálogos donde se encuentra la función.
- `FunctionName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la función.

Respuesta

- `UserDefinedFunction`: un objeto UserDefinedFunction.

  La definición de la función solicitada.

Errores

- `EntityNotFoundException`
- `InvalidInputException`

- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`

Acción GetUserDefinedFunctions (Python: get_user_defined_functions)

Recupera varias definiciones de función del Catálogo de datos.

Solicitud

- `CatalogId`: cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del Catálogo de datos donde se encuentran las funciones que se van a recuperar. Si no se proporciona ninguno, se usará de forma predeterminada el ID de cuenta de AWS.
- `DatabaseName`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos de catálogos donde se encuentra las funciones. Si no se proporciona ninguno, se devolverán las funciones de todas las bases de datos del catálogo.
- `Pattern`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Cadena con patrón nombre-de-función opcional que filtra las definiciones de función que se devuelven.
- `NextToken`: cadena UTF-8.

  Token de continuación si se trata de una llamada de continuidad.
- `MaxResults`: número (entero) que no es inferior a 1 ni es superior a 100.

  El número máximo de funciones que se devuelven en una respuesta.

Respuesta

- `UserDefinedFunctions`: matriz de objetos UserDefinedFunction.

  Lista de las definiciones de función solicitadas.
- `NextToken`: cadena UTF-8.

Token de continuación, si la lista de funciones que se devuelve no incluye la última función solicitada.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`
- `GlueEncryptionException`

Importación de un catálogo de Athena a AWS Glue

La API de migración describe los tipos de datos y las operaciones de AWS Glue relativos a la migración de un Catálogo de datos de Athena a AWS Glue.

Tipos de datos

- Estructura CatalogImportStatus

Estructura CatalogImportStatus

Estructura que contiene información sobre el estado de la migración.

Campos

- `ImportCompleted`: booleano.

  `True` si la migración se ha completado; o `False` en caso contrario,.
- `ImportTime`: marca temporal.

  La hora en que comenzó la migración.
- `ImportedBy`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la persona que inició la migración.

Operaciones

- Acción ImportCatalogToGlue (Python: import_catalog_to_glue)
- Acción GetCatalogImportStatus (Python: get_catalog_import_status)

Acción ImportCatalogToGlue (Python: import_catalog_to_glue)

Importa un Catálogo de datos de Amazon Athena existente a AWS Glue.

Solicitud

- `CatalogId`: cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del catálogo que se va a importar. En la actualidad, debe ser el ID de cuenta de AWS.

Respuesta

- Sin parámetros de respuesta.

Errores

- `InternalServiceException`
- `OperationTimeoutException`

Acción GetCatalogImportStatus (Python: get_catalog_import_status)

Recupera el estado de una operación de migración.

Solicitud

- `CatalogId`: cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del catálogo que se va a migrar. En la actualidad, debe ser el ID de cuenta de AWS.

Respuesta

- `ImportStatus`: un objeto CatalogImportStatus.

  El estado de la migración del catálogo especificado.

Errores

- `InternalServiceException`
- `OperationTimeoutException`

API del optimizador de tablas

La API del optimizador de tablas describe la API de AWS Glue que permite la compactación para mejorar el rendimiento de lectura.

Tipos de datos

- Estructura de TableOptimizer
- Estructura de TableOptimizerConfiguration
- Estructura de TableOptimizerVpcConfiguration
- Estructura CompactionConfiguration
- Estructura IcebergCompactionConfiguration
- Estructura de TableOptimizerRun
- Estructura de BatchGetTableOptimizerEntry
- Estructura de BatchTableOptimizer
- Estructura de BatchGetTableOptimizerError
- Estructura de RetentionConfiguration
- Estructura de IcebergRetentionConfiguration
- Estructura de OrphanFileDeletionConfiguration
- Estructura de IcebergOrphanFileDeletionConfiguration
- Estructura de CompactionMetrics
- Estructura de RetentionMetrics
- Estructura de OrphanFileDeletionMetrics

- Estructura de IcebergCompactionMetrics
- Estructura de IcebergRetentionMetrics
- Estructura de IcebergOrphanFileDeletionMetrics
- Estructura RunMetrics

Estructura de TableOptimizer

Contiene detalles sobre un optimizador asociado a una tabla.

Campos

- `type`: cadena UTF-8 (valores válidos: `compaction="COMPACTION"` | `retention="RETENTION"` | `orphan_file_deletion="ORPHAN_FILE_DELETION"`).

  El tipo de optimizador de tabla. Los valores válidos son:

  - `compaction`: para administrar la compactación con un optimizador de tablas.
  - `retention`: para administrar la retención de instantáneas con un optimizador de tablas.
  - `orphan_file_deletion`: para administrar la eliminación de archivos huérfanos con un optimizador de tablas.
- `configuration`: un objeto TableOptimizerConfiguration.

  Un objeto `TableOptimizerConfiguration` que se especificó al crear o actualizar un optimizador de tablas.
- `lastRun`: un objeto TableOptimizerRun.

  Un objeto `TableOptimizerRun` que representa la última ejecución del optimizador de tablas.
- `configurationSource`: cadena UTF-8 (valores válidos: `catalog="CATALOG"` | `table="TABLE"`).

  Especifica el origen de la configuración del optimizador. Esto indica cómo se configuró el optimizador de tablas y qué entidad o servicio inició la configuración.

Estructura de TableOptimizerConfiguration

Contiene detalles sobre la configuración de un optimizador de tablas. Esta configuración se transfiere al crear o actualizar un optimizador de tablas.

Campos

- `roleArn`: cadena UTF-8, con 20 bytes como mínimo o más de 2048 bytes de largo, que coincide con el Single-line string pattern.

  Un rol transferido por la persona que llama y que permite al servicio actualizar los recursos asociados al optimizador en nombre de la persona que llama.
- `enabled`: booleano.

  Si la optimización de tablas está habilitada.
- `vpcConfiguration`: un objeto TableOptimizerVpcConfiguration.

  Un objeto `TableOptimizerVpcConfiguration` que representa la configuración de la VPC para un optimizador de tablas.

  Esta configuración es necesaria para llevar a cabo la optimización en las tablas que se encuentran en una VPC del cliente.
- `compactionConfiguration`: un objeto CompactionConfiguration.

  La configuración de un optimizador de compactación. Esta configuración define cómo se compactarán los archivos de datos en la tabla para mejorar el rendimiento de las consultas y reducir los costos de almacenamiento.
- `retentionConfiguration`: un objeto RetentionConfiguration.

  Configuración de un optimizador de retención de instantáneas.
- `orphanFileDeletionConfiguration`: un objeto OrphanFileDeletionConfiguration.

  Configuración de un optimizador de eliminación de archivos huérfanos.

Estructura de TableOptimizerVpcConfiguration

Un objeto que describe la configuración de la VPC para un optimizador de tablas.

Esta configuración es necesaria para llevar a cabo la optimización en las tablas que se encuentran en una VPC del cliente.

Campos

- `glueConnectionName`: cadena UTF-8 de 1 byte de largo como mínimo.

El nombre de la conexión de AWS Glue usada para la VPC del optimizador de tablas.

Estructura CompactionConfiguration

La configuración de un optimizador de compactación. Esta configuración define cómo se compactarán los archivos de datos en la tabla para mejorar el rendimiento de las consultas y reducir los costos de almacenamiento.

Campos

- `icebergConfiguration`: un objeto IcebergCompactionConfiguration.

  La configuración de un optimizador de compactación de Iceberg.

Estructura IcebergCompactionConfiguration

La configuración de un optimizador de compactación de Iceberg. Esta configuración define los parámetros para optimizar la distribución de los archivos de datos en las tablas de Iceberg.

Campos

- `strategy`: cadena UTF-8 (valores válidos: `binpack="BINPACK"` | `sort="SORT"` | `z-order="ZORDER"`).

  La estrategia que se utilizará para la compactación. Los valores válidos son:
  - `binpack`: combina archivos pequeños en archivos más grandes, normalmente con un tamaño superior a 100 MB, y aplica las eliminaciones pendientes. Esta es la estrategia de compactación recomendada para la mayoría de los casos de uso.
  - `sort`: organiza los datos según columnas especificadas, que se ordenan jerárquicamente durante la compactación, lo que mejora el rendimiento de las consultas en operaciones que aplican filtros. Esta estrategia se recomienda cuando las consultas filtran con frecuencia sobre columnas específicas. Para utilizar esta estrategia, primero debe definir un orden de clasificación en las propiedades de la tabla de Iceberg mediante la propiedad de tabla `sort_order`.
  - `z-order`: optimiza la organización de los datos al combinar múltiples atributos en un único valor escalar que se puede utilizar para la ordenación, lo que permite consultas eficientes en varias dimensiones. Esta estrategia se recomienda cuando se necesita consultar datos en varias dimensiones simultáneamente. Para utilizar esta estrategia, primero debe definir un

orden de clasificación en las propiedades de la tabla de Iceberg mediante la propiedad de tabla `sort_order`.

Si no se proporciona una entrada, se utilizará el valor predeterminado “binpack”.

- `minInputFiles`: número (entero).

  La cantidad mínima de archivos de datos que deben estar presentes en una partición antes de que la compactación realmente compacte los archivos. Este parámetro ayuda a controlar cuándo se activa la compactación y evita operaciones de compactación innecesarias en particiones con pocos archivos. Si no se proporciona ninguna entrada, se utiliza el valor predeterminado, que es 100.

- `deleteFileThreshold`: número (entero).

  El número mínimo de eliminaciones que debe contener un archivo de datos para que sea elegible para la compactación. Este parámetro ayuda a optimizar la compactación, ya que se centra en los archivos que contienen un número significativo de operaciones de eliminación, y esto puede mejorar el rendimiento de las consultas porque borra los registros eliminados. Si no se proporciona ninguna entrada, se utiliza el valor predeterminado, que es 1.

Estructura de TableOptimizerRun

Contiene detalles de una ejecución del optimizador de tablas.

Campos

- `eventType`: cadena UTF-8 (valores válidos: `starting="STARTING"` | `completed="COMPLETED"` | `failed="FAILED"` | `in_progress="IN_PROGRESS"`).

  Un tipo de evento que representa el estado de la ejecución del optimizador de tablas.

- `startTimestamp`: marca temporal.

  Representa la marca temporal de la época en la que se inició el trabajo de compactación en Lake Formation.

- `endTimestamp`: marca temporal.

  Representa la marca temporal de la época en la que finalizó el trabajo de compactación.

- `metrics`: un objeto RunMetrics.

Un objeto `RunMetrics` que contiene las métricas de la ejecución del optimizador.

Este miembro ya no está disponible. Consulte los miembros individuales de la métrica para la compactación, la retención y la eliminación de archivos huérfanos.

- `error`: cadena UTF-8.

  Un error que se produjo durante la ejecución del optimizador.

- `compactionMetrics`: un objeto CompactionMetrics.

  Un objeto `CompactionMetrics` que contiene las métricas de la ejecución del optimizador.

- `compactionStrategy`: cadena UTF-8 (valores válidos: `binpack="BINPACK"` | `sort="SORT"` | `z-order="ZORDER"`).

  La estrategia utilizada para la ejecución de la compactación. Indica qué algoritmo se aplicó para determinar cómo se seleccionaron y combinaron los archivos durante el proceso de compactación. Los valores válidos son:

  - `binpack`: combina archivos pequeños en archivos más grandes, normalmente con un tamaño superior a 100 MB, y aplica las eliminaciones pendientes. Esta es la estrategia de compactación recomendada para la mayoría de los casos de uso.
  - `sort`: organiza los datos según columnas especificadas, que se ordenan jerárquicamente durante la compactación, lo que mejora el rendimiento de las consultas en operaciones que aplican filtros. Esta estrategia se recomienda cuando las consultas filtran con frecuencia sobre columnas específicas. Para utilizar esta estrategia, primero debe definir un orden de clasificación en las propiedades de la tabla de Iceberg mediante la propiedad de tabla `sort_order`.
  - `z-order`: optimiza la organización de los datos al combinar múltiples atributos en un único valor escalar que se puede utilizar para la ordenación, lo que permite consultas eficientes en varias dimensiones. Esta estrategia se recomienda cuando se necesita consultar datos en varias dimensiones simultáneamente. Para utilizar esta estrategia, primero debe definir un orden de clasificación en las propiedades de la tabla de Iceberg mediante la propiedad de tabla `sort_order`.

- `retentionMetrics`: un objeto RetentionMetrics.

  Un objeto `RetentionMetrics` que contiene las métricas de la ejecución del optimizador.

- `orphanFileDeletionMetrics`: un objeto OrphanFileDeletionMetrics.

Objeto `OrphanFileDeletionMetrics` que contiene las métricas de la ejecución del optimizador.

Estructura de BatchGetTableOptimizerEntry

Representa un optimizador de tablas que se va a recuperar en la operación `BatchGetTableOptimizer`.

Campos

- `catalogId`: cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de catálogo de la tabla.
- `databaseName`: cadena UTF-8 de 1 byte de largo como mínimo.

  El nombre de la base de datos en el catálogo donde reside la tabla.
- `tableName`: cadena UTF-8 de 1 byte de largo como mínimo.

  El nombre de la tabla.
- `type`: cadena UTF-8 (valores válidos: `compaction="COMPACTION"` | `retention="RETENTION"` | `orphan_file_deletion="ORPHAN_FILE_DELETION"`).

  El tipo de optimizador de tabla.

Estructura de BatchTableOptimizer

Contiene detalles de uno de los optimizadores de tablas devueltos por la operación `BatchGetTableOptimizer`.

Campos

- `catalogId`: cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de catálogo de la tabla.
- `databaseName`: cadena UTF-8 de 1 byte de largo como mínimo.

El nombre de la base de datos en el catálogo donde reside la tabla.

- `tableName`: cadena UTF-8 de 1 byte de largo como mínimo.

  El nombre de la tabla.

- `tableOptimizer`: un objeto TableOptimizer.

  Un objeto `TableOptimizer` que contiene detalles sobre la configuración y la última ejecución de un optimizador de tabla.

Estructura de BatchGetTableOptimizerError

Contiene detalles sobre uno de los errores de la lista de errores devuelta por la operación `BatchGetTableOptimizer`.

Campos

- `error`: un objeto ErrorDetail.

  Un objeto `ErrorDetail` que contiene detalles de mensaje y código acerca del error.

- `catalogId`: cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de catálogo de la tabla.

- `databaseName`: cadena UTF-8 de 1 byte de largo como mínimo.

  El nombre de la base de datos en el catálogo donde reside la tabla.

- `tableName`: cadena UTF-8 de 1 byte de largo como mínimo.

  El nombre de la tabla.

- `type`: cadena UTF-8 (valores válidos: `compaction="COMPACTION"` | `retention="RETENTION"` | `orphan_file_deletion="ORPHAN_FILE_DELETION"`).

  El tipo de optimizador de tabla.

Estructura de RetentionConfiguration

Configuración de un optimizador de retención de instantáneas.

Campos

- `icebergConfiguration`: un objeto IcebergRetentionConfiguration.

  Configuración de un optimizador de retención de instantáneas de Iceberg.

Estructura de IcebergRetentionConfiguration

Configuración de un optimizador de retención de instantáneas de Iceberg.

Campos

- `snapshotRetentionPeriodInDays`: número (entero).

  Número de días que se retienen las instantáneas de Iceberg. Si no se proporciona ninguna entrada, se utilizará el campo de configuración de la tabla de Iceberg correspondiente o, si no está presente, se utilizará el valor predeterminado 5.

- `numberOfSnapshotsToRetain`: número (entero).

  Número de instantáneas de Iceberg que se van a retener durante el periodo de retención. Si no se proporciona ninguna entrada, se utilizará el campo de configuración de la tabla de Iceberg correspondiente o, si no está presente, se utilizará el valor predeterminado 1.

- `cleanExpiredFiles`: booleano.

  Si se establece en falso, las instantáneas solo se eliminan de los metadatos de la tabla y no se eliminan los archivos de datos y metadatos subyacentes.

- `runRateInHours`: número (entero).

  El intervalo en horas entre las ejecuciones de los trabajos de retención. Este parámetro controla la frecuencia con la que se ejecutará el optimizador de retención para limpiar las instantáneas caducadas. Este valor debe estar entre 3 y 168 horas (7 días). Si no se proporciona ninguna entrada, se utiliza el valor predeterminado, que es 24.

Estructura de OrphanFileDeletionConfiguration

Configuración de un optimizador de eliminación de archivos huérfanos.

Campos

- `icebergConfiguration`: un objeto IcebergOrphanFileDeletionConfiguration.

  Configuración de un optimizador de eliminación de archivos huérfanos de Iceberg.

Estructura de IcebergOrphanFileDeletionConfiguration

Configuración de un optimizador de eliminación de archivos huérfanos de Iceberg.

Campos

- `orphanFileRetentionPeriodInDays`: número (entero).

  Número de días que deben retenerse los archivos huérfanos antes de eliminarlos. Si no se proporciona ninguna entrada, se utiliza el valor predeterminado 3.

- `location`: cadena UTF-8.

  Especifica un directorio en el que buscar los archivos (por defecto es la ubicación de la tabla). Puede elegir un subdirectorio en lugar de la ubicación de la tabla de nivel superior.

- `runRateInHours`: número (entero).

  El intervalo en horas entre las ejecuciones del trabajo de eliminación de archivos huérfanos. Este parámetro controla la frecuencia con la que se ejecutará el optimizador de eliminación de archivos huérfanos para limpiar los archivos huérfanos. Este valor debe estar entre 3 y 168 horas (7 días). Si no se proporciona ninguna entrada, se utiliza el valor predeterminado, que es 24.

Estructura de CompactionMetrics

Estructura que contiene las métricas de compactación de la ejecución del optimizador.

Campos

- `IcebergMetrics`: un objeto IcebergCompactionMetrics.

  Estructura que contiene las métricas de compactación de Iceberg de la ejecución del optimizador.

Estructura de RetentionMetrics

Estructura que contiene las métricas de retención de la ejecución del optimizador.

Campos

- `IcebergMetrics`: un objeto IcebergRetentionMetrics.

  Estructura que contiene las métricas de retención de Iceberg de la ejecución del optimizador.

Estructura de OrphanFileDeletionMetrics

Estructura que contiene las métricas de eliminación de archivos huérfanos de la ejecución del optimizador.

Campos

- `IcebergMetrics`: un objeto IcebergOrphanFileDeletionMetrics.

  Estructura que contiene las métricas de eliminación de archivos huérfanos de Iceberg de la ejecución del optimizador.

Estructura de IcebergCompactionMetrics

Métricas de compactación de Iceberg de la ejecución del optimizador.

Campos

- `DpuHours`: número (doble).

  El número de horas de DPU consumidas por el trabajo.
- `NumberOfDpus`: número (entero).

  El número de DPU consumidas por el trabajo, redondeado al número entero más cercano.
- `JobDurationInHour`: número (doble).

  La duración del trabajo en horas.

Estructura de IcebergRetentionMetrics

Métricas de retención de instantáneas de Iceberg de la ejecución del optimizador.

Campos

- `DpuHours`: número (doble).

  El número de horas de DPU consumidas por el trabajo.
- `NumberOfDpus`: número (entero).

  El número de DPU consumidas por el trabajo, redondeado al número entero más cercano.
- `JobDurationInHour`: número (doble).

  La duración del trabajo en horas.

Estructura de IcebergOrphanFileDeletionMetrics

Métricas de eliminación de archivos huérfanos de Iceberg de la ejecución del optimizador.

Campos

- `DpuHours`: número (doble).

  El número de horas de DPU consumidas por el trabajo.
- `NumberOfDpus`: número (entero).

  El número de DPU consumidas por el trabajo, redondeado al número entero más cercano.
- `JobDurationInHour`: número (doble).

  La duración del trabajo en horas.

Estructura RunMetrics

Métricas de la ejecución del optimizador.

Esta estructura está obsoleta. Consulte los miembros individuales de la métrica para la compactación, la retención y la eliminación de archivos huérfanos.

Campos

- `NumberOfBytesCompacted`: cadena UTF-8.

  El número de bytes eliminados por la ejecución del trabajo de compactación.
- `NumberOfFilesCompacted`: cadena UTF-8.

  El número de archivos eliminados por la ejecución del trabajo de compactación.
- `NumberOfDpus`: cadena UTF-8.

  El número de DPU consumidas por el trabajo, redondeado al número entero más cercano.
- `JobDurationInHour`: cadena UTF-8.

  La duración del trabajo en horas.

Operaciones

- Acción GetTableOptimizer (Python: get_table_optimizer)
- Acción BatchGetTableOptimizer (Python: batch_get_table_optimizer)
- Acción ListTableOptimizerRuns (Python: list_table_optimizer_runs)
- Cción CreateTableOptimizer (Python: create_table_optimizer)
- Acción DeleteTableOptimizer (Python: delete_table_optimizer)
- Acción UpdateTableOptimizer (Python: update_table_optimizer)

Acción GetTableOptimizer (Python: get_table_optimizer)

Devuelve la configuración de todos los optimizadores asociados a una tabla especificada.

Solicitud

- `CatalogId`: Obligatorio: cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de catálogo de la tabla.
- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

El nombre de la base de datos en el catálogo donde reside la tabla.

- `TableName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la tabla.

- `Type` – Obligatorio: cadena UTF-8 (valores válidos: `compaction="COMPACTION"` | `retention="RETENTION"` | `orphan_file_deletion="ORPHAN_FILE_DELETION"`).

  El tipo de optimizador de tabla.

Respuesta

- `CatalogId`: cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de catálogo de la tabla.

- `DatabaseName`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos en el catálogo donde reside la tabla.

- `TableName`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la tabla.

- `TableOptimizer`: un objeto TableOptimizer.

  El optimizador asociado a la tabla especificada.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `AccessDeniedException`
- `InternalServiceException`
- `ThrottlingException`

Acción BatchGetTableOptimizer (Python: batch_get_table_optimizer)

Devuelve la configuración de los optimizadores de la tabla especificados.

Solicitud

- `Entries` (obligatorio): una matriz de objetos BatchGetTableOptimizerEntry.

  Una lista de objetos `BatchGetTableOptimizerEntry` que especifican los optimizadores de tabla que se van a recuperar.

Respuesta

- `TableOptimizers`: matriz de objetos BatchTableOptimizer.

  Una lista de objetos `BatchTableOptimizer`.
- `Failures`: matriz de objetos BatchGetTableOptimizerError.

  Una lista de errores de la operación.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `AccessDeniedException`
- `InternalServiceException`
- `ThrottlingException`

Acción ListTableOptimizerRuns (Python: list_table_optimizer_runs)

Muestra el historial de las ejecuciones anteriores del optimizador para una tabla específica.

Solicitud

- `CatalogId`: Obligatorio: cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de catálogo de la tabla.

- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos en el catálogo donde reside la tabla.
- `TableName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la tabla.
- `Type` – Obligatorio: cadena UTF-8 (valores válidos: `compaction="COMPACTION"` | `retention="RETENTION"` | `orphan_file_deletion="ORPHAN_FILE_DELETION"`).

  El tipo de optimizador de tabla.
- `MaxResults`: número (entero).

  El número máximo de ejecuciones del optimizador que se devolverán en cada llamada.
- `NextToken`: cadena UTF-8.

  Token de continuación si se trata de una llamada de continuidad.

Respuesta

- `CatalogId`: cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de catálogo de la tabla.
- `DatabaseName`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos en el catálogo donde reside la tabla.
- `TableName`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la tabla.
- `NextToken`: cadena UTF-8.

  Token de continuación para paginar la lista obtenida; se devuelve si el segmento actual de la lista no es el último.
- `TableOptimizerRuns`: matriz de objetos TableOptimizerRun.

Lista de las ejecuciones del optimizador asociadas a una tabla.

Errores

- `EntityNotFoundException`
- `AccessDeniedException`
- `InvalidInputException`
- `ValidationException`
- `InternalServiceException`
- `ThrottlingException`

Cción CreateTableOptimizer (Python: create_table_optimizer)

Crea un nuevo optimizador de tablas para una función específica.

Solicitud

- `CatalogId`: Obligatorio: cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de catálogo de la tabla.
- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos en el catálogo donde reside la tabla.
- `TableName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la tabla.
- `Type` – Obligatorio: cadena UTF-8 (valores válidos: `compaction="COMPACTION"` | `retention="RETENTION"` | `orphan_file_deletion="ORPHAN_FILE_DELETION"`).

  El tipo de optimizador de tabla.
- `TableOptimizerConfiguration`: obligatorio: objeto TableOptimizerConfiguration.

Un objeto `TableOptimizerConfiguration` que representa la configuración de un optimizador de tablas.

Respuesta

- Sin parámetros de respuesta.

Errores

- `EntityNotFoundException`
- `ValidationException`
- `InvalidInputException`
- `AccessDeniedException`
- `AlreadyExistsException`
- `InternalServiceException`
- `ThrottlingException`

Acción DeleteTableOptimizer (Python: delete_table_optimizer)

Elimina un optimizador y todos los metadatos asociados a una tabla. La optimización ya no se realizará en la tabla.

Solicitud

- `CatalogId`: Obligatorio: cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de catálogo de la tabla.
- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos en el catálogo donde reside la tabla.
- `TableName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la tabla.

- `Type` – Obligatorio: cadena UTF-8 (valores válidos: `compaction="COMPACTION"` | `retention="RETENTION"` | `orphan_file_deletion="ORPHAN_FILE_DELETION"`).

  El tipo de optimizador de tabla.

Respuesta

- Sin parámetros de respuesta.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `AccessDeniedException`
- `InternalServiceException`
- `ThrottlingException`

Acción UpdateTableOptimizer (Python: update_table_optimizer)

Actualiza la configuración de un optimizador de tablas existente.

Solicitud

- `CatalogId`: Obligatorio: cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de catálogo de la tabla.
- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos en el catálogo donde reside la tabla.
- `TableName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la tabla.
- `Type` – Obligatorio: cadena UTF-8 (valores válidos: `compaction="COMPACTION"` | `retention="RETENTION"` | `orphan_file_deletion="ORPHAN_FILE_DELETION"`).

El tipo de optimizador de tabla.

- `TableOptimizerConfiguration`: obligatorio: objeto TableOptimizerConfiguration.

  Un objeto `TableOptimizerConfiguration` que representa la configuración de un optimizador de tablas.

Respuesta

- Sin parámetros de respuesta.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `AccessDeniedException`
- `ValidationException`
- `InternalServiceException`
- `ThrottlingException`
- `ConcurrentModificationException`

API de rastreadores y clasificadores

La API de rastreadores y clasificadores describe los tipos de datos de rastreadores y clasificadores de AWS Glue e incluye la API para crear, eliminar, actualizar y ver listas de rastreadores o clasificadores.

Temas

- API de clasificador
- La API del rastreador
- API de estadísticas de columna
- API del programador del rastreador

API de clasificador

La API de clasificador describe los tipos de datos de clasificador de AWS Glue e incluye la API de creación, eliminación, actualización y creación de listados de clasificadores.

Tipos de datos

- Estructura Classifier
- Estructura GrokClassifier
- Estructura XMLClassifier
- Estructura JsonClassifier
- Estructura CsvClassifier
- Estructura CreateGrokClassifierRequest
- Estructura UpdateGrokClassifierRequest
- Estructura CreateXMLClassifierRequest
- Estructura UpdateXMLClassifierRequest
- Estructura CreateJsonClassifierRequest
- Estructura UpdateJsonClassifierRequest
- Estructura CreateCsvClassifierRequest
- Estructura UpdateCsvClassifierRequest

Estructura Classifier

Los clasificadores se disparan durante una tarea de rastreo. Un clasificador comprueba si un determinado archivo está en un formato que puede administrar. En caso afirmativo, el clasificador crea un esquema en forma de un objeto `StructType` que coincida con formato de datos.

Puede utilizar los clasificadores estándar que suministra AWS Glue o puede escribir sus propios clasificadores para clasificar mejor los orígenes de datos y especificar los esquemas adecuados para usar con ellos. Una clasificador puede ser un clasificador `grok`, un clasificador `XML`, un clasificador `JSON` o un clasificador `CSV` personalizado, en función de lo que se especifique en uno de los campos del objeto `Classifier`.

Campos

- `GrokClassifier`: un objeto GrokClassifier.

Un clasificador que utiliza `grok`.

- `XMLClassifier`: un objeto XMLClassifier.

  Un clasificador de contenido XML.

- `JsonClassifier`: un objeto JsonClassifier.

  Un clasificador de contenido JSON.

- `CsvClassifier`: un objeto CsvClassifier.

  Un clasificador de valores separados por comas (CSV).

Estructura GrokClassifier

Un clasificador que utiliza patrones `grok`.

Campos

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del clasificador.

- `Classification` – Obligatorio: cadena UTF-8.

  Identificador del formato de los datos que el clasificador correlaciona; por ejemplo, Twitter, JSON, registros de Omniture, etc.

- `CreationTime`: marca temporal.

  La hora de registro de este clasificador.

- `LastUpdated`: marca temporal.

  La hora de actualización de este clasificador.

- `Version`: número (largo).

  Versión de este clasificador.

- `GrokPattern` – Obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 2048 bytes de largo como máximo, que coincide con el A Logstash Grok string pattern.

El patrón grok que este clasificador aplica a un almacén de datos. Para obtener más información, consulte los patrones integrados en Escritura de clasificadores personalizados.

- `CustomPatterns`: cadena UTF-8 con un máximo de 16000 bytes de largo, que coincide con el URI address multi-line string pattern.

  Patrones de grok personalizados opcionales definidos por este clasificador. Para obtener más información, consulte los patrones personalizados en Escritura de clasificadores personalizados.

Estructura XMLClassifier

Un clasificador de contenido `XML`.

Campos

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del clasificador.

- `Classification` – Obligatorio: cadena UTF-8.

  Identificador del formato de datos que el clasificador correlaciona.

- `CreationTime`: marca temporal.

  La hora de registro de este clasificador.

- `LastUpdated`: marca temporal.

  La hora de actualización de este clasificador.

- `Version`: número (largo).

  Versión de este clasificador.

- `RowTag`: cadena UTF-8.

  La etiqueta XML que designa el elemento que contiene cada registro en un documento XML que se está analizando. Esto no puede identificar un elemento de cierre (cerrado por `/>`). Un elemento de fila vacío que solo contenga atributos puede analizarse siempre y cuando finalice con una etiqueta de cierre (por ejemplo, `<row item_a="A" item_b="B"></row>` es correcto, pero `<row item_a="A" item_b="B" />` no lo es).

Estructura JsonClassifier

Un clasificador de contenido `JSON`.

Campos

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del clasificador.
- `CreationTime`: marca temporal.

  La hora de registro de este clasificador.
- `LastUpdated`: marca temporal.

  La hora de actualización de este clasificador.
- `Version`: número (largo).

  Versión de este clasificador.
- `JsonPath` – Obligatorio: cadena UTF-8.

  Una cadena `JsonPath` que define los datos JSON que el clasificador debe clasificar. AWS Glue soporta un subconjunto de operadores de JsonPath, tal y como se describe en Escritura de clasificadores personalizados de JsonPath.

Estructura CsvClassifier

Clasificador de contenido `CSV` personalizado.

Campos

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del clasificador.
- `CreationTime`: marca temporal.

  La hora de registro de este clasificador.
- `LastUpdated`: marca temporal.

La hora de actualización de este clasificador.

- `Version`: número (largo).

  Versión de este clasificador.

- `Delimiter`: cadena UTF-8, con 1 byte de largo como mínimo y 1 byte de largo como máximo, que coincide con el Custom string pattern #26.

  Símbolo personalizado que indica qué elemento va a separar cada entrada de columna en la fila.

- `QuoteSymbol`: cadena UTF-8, con 1 byte de largo como mínimo y 1 byte de largo como máximo, que coincide con el Custom string pattern #26.

  Símbolo personalizado que indica qué elemento va a combinar contenido en un valor de columna único. Debe ser distinto al delimitador de columnas.

- `ContainsHeader`: cadena UTF-8 (valores válidos: `UNKNOWN` | `PRESENT` | `ABSENT`).

  Indica si el archivo CSV contiene un encabezado.

- `Header`: matriz de cadenas UTF-8.

  Lista de cadenas que representan nombres de columnas.

- `DisableValueTrimming`: booleano.

  Indica que los valores no deben recortarse antes de identificar el tipo de valores de columna. El valor predeterminado es `true`.

- `AllowSingleColumn`: booleano.

  Permite procesar los archivos que contienen una sola columna.

- `CustomDatatypeConfigured`: booleano.

  Permite configurar el tipo de datos personalizado.

- `CustomDatatypes`: matriz de cadenas UTF-8.

  Lista de tipos de datos personalizados que incluyen "BINARIO", "BOOLEANO", "FECHA", "DECIMAL", "DOUBLE", "FLOAT", "INT", "LONG", "SHORT", "STRING", "TIMESTAMP".

- `Serde`: cadena UTF-8 (valores válidos: `OpenCSVSerDe` | `LazySimpleSerDe` | `None`).

Establece el SerDe para procesar CSV en el clasificador, que se aplicará en el catálogo de datos. Los valores válidos son `OpenCSVSerDe`, `LazySimpleSerDe` y `None`. Puede especificar el valor `None` cuando desee que el rastreador realice la detección.

Estructura CreateGrokClassifierRequest

Especifica un clasificador `grok` para que `CreateClassifier` lo cree.

Campos

- `Classification` – Obligatorio: cadena UTF-8.

  Identificador del formato de los datos que el clasificador correlaciona; por ejemplo, Twitter, JSON, registros de Omniture, Amazon CloudWatch Logs, etc.
- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del nuevo clasificador.
- `GrokPattern` – Obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 2048 bytes de largo como máximo, que coincide con el A Logstash Grok string pattern.

  Patrón de grok que este clasificador utiliza.
- `CustomPatterns`: cadena UTF-8 con un máximo de 16000 bytes de largo, que coincide con el URI address multi-line string pattern.

  Patrones de grok personalizados opcionales utilizados por este clasificador.

Estructura UpdateGrokClassifierRequest

Especifica un clasificador de grok que debe actualizarse cuando se pase a `UpdateClassifier`.

Campos

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del elemento `GrokClassifier`.
- `Classification`: cadena UTF-8.

Identificador del formato de los datos que el clasificador correlaciona; por ejemplo, Twitter, JSON, registros de Omniture, Amazon CloudWatch Logs, etc.

- `GrokPattern`: cadena UTF-8, con 1 byte de largo como mínimo y 2048 bytes de largo como máximo, que coincide con el A Logstash Grok string pattern.

  Patrón de grok que este clasificador utiliza.

- `CustomPatterns`: cadena UTF-8 con un máximo de 16000 bytes de largo, que coincide con el URI address multi-line string pattern.

  Patrones de grok personalizados opcionales utilizados por este clasificador.

Estructura CreateXMLClassifierRequest

Especifica un clasificador de XML para que `CreateClassifier` lo cree.

Campos

- `Classification` – Obligatorio: cadena UTF-8.

  Identificador del formato de datos que el clasificador correlaciona.

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del clasificador.

- `RowTag`: cadena UTF-8.

  La etiqueta XML que designa el elemento que contiene cada registro en un documento XML que se está analizando. Esto no puede identificar un elemento de cierre (cerrado por `/>`). Un elemento de fila vacío que solo contenga atributos puede analizarse siempre y cuando finalice con una etiqueta de cierre (por ejemplo, `<row item_a="A" item_b="B"></row>` es correcto, pero `<row item_a="A" item_b="B" />` no lo es).

Estructura UpdateXMLClassifierRequest

Especifica un clasificador de XML que debe actualizarse.

Campos

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del clasificador.

- `Classification`: cadena UTF-8.

  Identificador del formato de datos que el clasificador correlaciona.

- `RowTag`: cadena UTF-8.

  La etiqueta XML que designa el elemento que contiene cada registro en un documento XML que se está analizando. Tenga en cuenta que no puede identificar un elemento que se autocierra (cerrado con `/>`). Un elemento de fila vacío que solo contenga atributos puede analizarse siempre y cuando finalice con una etiqueta de cierre (por ejemplo, `<row item_a="A" item_b="B"></row>` es correcto, pero `<row item_a="A" item_b="B" />` no lo es).

Estructura CreateJsonClassifierRequest

Especifica un clasificador de JSON para que `CreateClassifier` lo cree.

Campos

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del clasificador.

- `JsonPath` – Obligatorio: cadena UTF-8.

  Una cadena `JsonPath` que define los datos JSON que el clasificador debe clasificar. AWS Glue soporta un subconjunto de operadores de JsonPath, tal y como se describe en Escritura de clasificadores personalizados de JsonPath.

Estructura UpdateJsonClassifierRequest

Especifica un clasificador de JSON que debe actualizarse.

Campos

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del clasificador.

- `JsonPath`: cadena UTF-8.

  Una cadena `JsonPath` que define los datos JSON que el clasificador debe clasificar. AWS Glue soporta un subconjunto de operadores de JsonPath, tal y como se describe en Escritura de clasificadores personalizados de JsonPath.

Estructura CreateCsvClassifierRequest

Especifica un clasificador CSV personalizado para que `CreateClassifier` lo cree.

Campos

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del clasificador.

- `Delimiter`: cadena UTF-8, con 1 byte de largo como mínimo y 1 byte de largo como máximo, que coincide con el Custom string pattern #26.

  Símbolo personalizado que indica qué elemento va a separar cada entrada de columna en la fila.

- `QuoteSymbol`: cadena UTF-8, con 1 byte de largo como mínimo y 1 byte de largo como máximo, que coincide con el Custom string pattern #26.

  Símbolo personalizado que indica qué elemento va a combinar contenido en un valor de columna único. Debe ser diferente al delimitador de columnas.

- `ContainsHeader`: cadena UTF-8 (valores válidos: `UNKNOWN` | `PRESENT` | `ABSENT`).

  Indica si el archivo CSV contiene un encabezado.

- `Header`: matriz de cadenas UTF-8.

  Lista de cadenas que representan nombres de columnas.

- `DisableValueTrimming`: booleano.

Indica que los valores no deben recortarse antes de identificar el tipo de valores de columna. El valor predeterminado es true.

- `AllowSingleColumn`: booleano.

  Permite procesar los archivos que contienen una sola columna.

- `CustomDatatypeConfigured`: booleano.

  Permite la configuración de tipos de datos personalizados.

- `CustomDatatypes`: matriz de cadenas UTF-8.

  Crea una lista de tipos de datos personalizados compatibles.

- `Serde`: cadena UTF-8 (valores válidos: `OpenCSVSerDe` | `LazySimpleSerDe` | `None`).

  Establece el SerDe para procesar CSV en el clasificador, que se aplicará en el catálogo de datos. Los valores válidos son `OpenCSVSerDe`, `LazySimpleSerDe` y `None`. Puede especificar el valor `None` cuando desee que el rastreador realice la detección.

Estructura UpdateCsvClassifierRequest

Especifica un clasificador CSV personalizado para que se actualice.

Campos

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del clasificador.

- `Delimiter`: cadena UTF-8, con 1 byte de largo como mínimo y 1 byte de largo como máximo, que coincide con el Custom string pattern #26.

  Símbolo personalizado que indica qué elemento va a separar cada entrada de columna en la fila.

- `QuoteSymbol`: cadena UTF-8, con 1 byte de largo como mínimo y 1 byte de largo como máximo, que coincide con el Custom string pattern #26.

  Símbolo personalizado que indica qué elemento va a combinar contenido en un valor de columna único. Debe ser distinto al delimitador de columnas.

- `ContainsHeader`: cadena UTF-8 (valores válidos: `UNKNOWN` | `PRESENT` | `ABSENT`).

Indica si el archivo CSV contiene un encabezado.

- `Header`: matriz de cadenas UTF-8.

  Lista de cadenas que representan nombres de columnas.

- `DisableValueTrimming`: booleano.

  Indica que los valores no deben recortarse antes de identificar el tipo de valores de columna. El valor predeterminado es true.

- `AllowSingleColumn`: booleano.

  Permite procesar los archivos que contienen una sola columna.

- `CustomDatatypeConfigured`: booleano.

  Especifica la configuración de los tipos de datos personalizados.

- `CustomDatatypes`: matriz de cadenas UTF-8.

  Especifica una lista de tipos de datos personalizados compatibles.

- `Serde`: cadena UTF-8 (valores válidos: `OpenCSVSerDe` | `LazySimpleSerDe` | `None`).

  Establece el SerDe para procesar CSV en el clasificador, que se aplicará en el catálogo de datos. Los valores válidos son `OpenCSVSerDe`, `LazySimpleSerDe` y `None`. Puede especificar el valor `None` cuando desee que el rastreador realice la detección.

Operaciones

- Acción CreateClassifier (Python: create_classifier)
- Acción DeleteClassifier (Python: delete_classifier)
- Acción GetClassifier (Python: get_classifier)
- Acción GetClassifiers (Python: get_classifiers)
- Acción UpdateClassifier (Python: update_classifier)

Acción CreateClassifier (Python: create_classifier)

Crea un clasificador en la cuenta del usuario. Puede ser `GrokClassifier`, `XMLClassifier`, `JsonClassifier` o `CsvClassifier`, en función de qué campo de la solicitud esté presente.

Solicitud

- `GrokClassifier`: un objeto CreateGrokClassifierRequest.

  Objeto `GrokClassifier` que especifica el clasificador que debe crearse.
- `XMLClassifier`: un objeto CreateXMLClassifierRequest.

  Objeto `XMLClassifier` que especifica el clasificador que debe crearse.
- `JsonClassifier`: un objeto CreateJsonClassifierRequest.

  Objeto `JsonClassifier` que especifica el clasificador que debe crearse.
- `CsvClassifier`: un objeto CreateCsvClassifierRequest.

  Objeto `CsvClassifier` que especifica el clasificador que debe crearse.

Respuesta

- Sin parámetros de respuesta.

Errores

- `AlreadyExistsException`
- `InvalidInputException`
- `OperationTimeoutException`

Acción DeleteClassifier (Python: delete_classifier)

Quita un clasificador del catálogo de datos.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del clasificador que debe eliminarse.

Respuesta

- Sin parámetros de respuesta.

Errores

- `EntityNotFoundException`
- `OperationTimeoutException`

Acción GetClassifier (Python: get_classifier)

Recupera un clasificador por su nombre.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del clasificador que debe recuperarse.

Respuesta

- `Classifier`: un objeto Clasificador.

  El clasificador solicitado.

Errores

- `EntityNotFoundException`
- `OperationTimeoutException`

Acción GetClassifiers (Python: get_classifiers)

Muestra todos los objetos de tipo clasificador del catálogo de datos.

Solicitud

- `MaxResults`: número (entero) que no es inferior a 1 ni es superior a 1000.

Tamaño de la lista que se devolverá (opcional).

- `NextToken`: cadena UTF-8.

  Token de continuación opcional.

Respuesta

- `Classifiers`: matriz de objetos Clasificador.

  La lista de objetos de tipo clasificador solicitada.

- `NextToken`: cadena UTF-8.

  Token de continuación.

Errores

- `OperationTimeoutException`

Acción UpdateClassifier (Python: update_classifier)

Modifica un clasificador existente (`GrokClassifier`, `XMLClassifier`, `JsonClassifier` o `CsvClassifier`, en función del campo que esté presente).

Solicitud

- `GrokClassifier`: un objeto UpdateGrokClassifierRequest.

  Objeto `GrokClassifier` con campos actualizados.

- `XMLClassifier`: un objeto UpdateXMLClassifierRequest.

  Objeto `XMLClassifier` con campos actualizados.

- `JsonClassifier`: un objeto UpdateJsonClassifierRequest.

  Objeto `JsonClassifier` con campos actualizados.

- `CsvClassifier`: un objeto UpdateCsvClassifierRequest.

  Objeto `CsvClassifier` con campos actualizados.

Respuesta

- Sin parámetros de respuesta.

Errores

- `InvalidInputException`
- `VersionMismatchException`
- `EntityNotFoundException`
- `OperationTimeoutException`

La API del rastreador

La API del rastreador describe los tipos de datos del rastreador de AWS Glue, junto con la API de creación, eliminación, actualización y creación de listados de rastreadores.

Tipos de datos

- Estructura de rastreador
- Estructura de programación
- Estructura CrawlerTargets
- Estructura S3Target
- Estructura de S3DeltaCatalogTarget
- Estructura de S3DeltaDirectTarget
- Estructura JdbcTarget
- Estructura MongoDBTarget
- Estructura DynamoDBTarget
- Estructura DeltaTarget
- Estructura de IcebergTarget
- Estructura de HudiTarget
- Estructura CatalogTarget
- Estructura CrawlerMetrics

- Estructura de CrawlerHistory
- Estructura de CrawlsFilter
- Estructura SchemaChangePolicy
- Estructura LastCrawlInfo
- Estructura RecrawlPolicy
- Estructura LineageConfiguration
- Estructura LakeFormationConfiguration

Estructura de rastreador

Especifica un programa de rastreador que examina un origen de datos y utiliza clasificadores para intentar determinar su esquema. Si ejecuta la operación correctamente, el rastreador registra los metadatos relativos al origen de los datos en AWS Glue Data Catalog.

Campos

- `Name` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del rastreador.

- `Role`: cadena UTF-8.

  El nombre de recurso de Amazon (ARN) de un rol de IAM que se utiliza para obtener acceso a los recursos del cliente como, por ejemplo, los datos de Amazon Simple Storage Service (Amazon S3).

- `Targets`: un objeto CrawlerTargets.

  Colección de objetivos del rastreo.

- `DatabaseName`: cadena UTF-8.

  El nombre de la base de datos donde se almacena la salida del rastreador.

- `Description` – cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Descripción del rastreador.

- `Classifiers`: matriz de cadenas UTF-8.

Una lista de cadenas UTF-8 que especifican los clasificadores personalizados que están asociados al rastreador.

- `RecrawlPolicy`: un objeto RecrawlPolicy.

  Política que especifica si se debe rastrear de nuevo todo el conjunto de datos o si se deben rastrear sólo las carpetas que se agregaron desde la última ejecución del rastreador.

- `SchemaChangePolicy`: un objeto SchemaChangePolicy.

  La política que especifica los comportamientos de actualización y eliminación del rastreador.

- `LineageConfiguration`: un objeto LineageConfiguration.

  Configuración que especifica si el linaje de datos está habilitado para el rastreador.

- `State` – Cadena UTF-8 (valores válidos: `READY` | `RUNNING` | `STOPPING`).

  Indica si el rastreador se está ejecutando o si queda pendiente una ejecución.

- `TablePrefix`: cadena UTF-8 de 128 bytes de largo como máximo.

  Prefijo añadido a los nombres de tablas que se crean.

- `Schedule`: un objeto Programación.

  En rastreadores programados, el programa cuando se ejecuta el rastreador.

- `CrawlElapsedTime`: número (largo).

  Si el rastreador se está ejecutando, contiene el tiempo transcurrido total desde que comenzó el último rastreo.

- `CreationTime`: marca temporal.

  La hora de creación del rastreador.

- `LastUpdated`: marca temporal.

  La hora de la última actualización del rastreador.

- `LastCrawl`: un objeto LastCrawlInfo.

  Estado del último rastreo e información de error potencial si se produjo un error.

- `Version`: número (largo).

  Versión del rastreador.

- `Configuration`: cadena UTF-8.

  Información de configuración del rastreador. Esta cadena JSON con varias versiones permite a los usuarios especificar aspectos del comportamiento de un rastreador. Para obtener más información, consulte Establecimiento de opciones de configuración de rastreadores.

- `CrawlerSecurityConfiguration`: cadena UTF-8 de 128 bytes de largo como máximo.

  El nombre de la estructura `SecurityConfiguration` que va a utilizar este rastreador.

- `LakeFormationConfiguration`: un objeto LakeFormationConfiguration.

  Especifica si el rastreador debe utilizar credenciales de AWS Lake Formation para el rastreador en lugar de las credenciales de rol de IAM.

Estructura de programación

Objeto de programación que usa una instrucción `cron` para programar un evento.

Campos

- `ScheduleExpression`: cadena UTF-8.

  Expresión `cron` utilizada para especificar el programa (consulte Programaciones basadas en tiempo para trabajos y rastreadores). Por ejemplo, para ejecutar algo todos los días a las 12:15 UTC, especifique: `cron(15 12 * * ? *)`.

- `State` – Cadena UTF-8 (valores válidos: `SCHEDULED` | `NOT_SCHEDULED` | `TRANSITIONING`).

  Estado del programa.

Estructura CrawlerTargets

Especifica los almacenes de datos que deben rastrearse.

Campos

- `S3Targets`: matriz de objetos S3Target.

  Especifica los destinos de Amazon Simple Storage Service (Amazon S3).

- `JdbcTargets`: matriz de objetos JdbcTarget.

Especifica los destinos de JDBC.

- `MongoDBTargets`: matriz de objetos MongoDBTarget.

  Especifica los orígenes de Amazon DocumentDB o MongoDB.
- `DynamoDBTargets`: matriz de objetos DynamoDBTarget.

  Especifica los destinos de Amazon DynamoDB.
- `CatalogTargets`: matriz de objetos CatalogTarget.

  Especifica orígenes de AWS Glue Data Catalog.
- `DeltaTargets`: matriz de objetos DeltaTarget.

  Especifica los destinos de almacenamiento de datos Delta.
- `IcebergTargets`: matriz de objetos IcebergTarget.

  Especifica los destinos de almacenamiento de datos Apache Iceberg.
- `HudiTargets`: matriz de objetos HudiTarget.

  Especifica los destinos de almacenamiento de datos Apache Hudi.

Estructura S3Target

Especifica un almacén de datos en Amazon Simple Storage Service (Amazon S3).

Campos

- `Path`: cadena UTF-8.

  Ruta al destino de Amazon S3.
- `Exclusions`: matriz de cadenas UTF-8.

  Lista de patrones glob utilizados para excluir elementos del rastreo. Para obtener más información, consulte la sección acerca de cómo Catalogar tablas con un rastreador.
- `ConnectionName`: cadena UTF-8 con una extensión de 1 byte como mínimo o 2048 bytes como máximo.

  Nombre de una conexión que permite a un trabajo o rastreador acceder a los datos de Amazon S3 dentro de un entorno de Amazon Virtual Private Cloud (Amazon VPC).

- `SampleSize`: número (entero).

  Establece el número de archivos de cada carpeta que se van a rastrear al rastrear archivos de ejemplo en un conjunto de datos. Si no se establece, se rastrean todos los archivos. Un valor válido es un entero entre 1 y 249.
- `EventQueueArn`: cadena UTF-8.

  Un ARN de Amazon SQS válido. Por ejemplo, `arn:aws:sqs:region:account:sqs`.
- `DlqEventQueueArn`: cadena UTF-8.

  Un ARN de Amazon SQS válido con mensajes fallidos. Por ejemplo, `arn:aws:sqs:region:account:deadLetterQueue`.

Estructura de S3DeltaCatalogTarget

Especifica un destino que escribe en un origen de datos de Delta Lake en el Catálogo de datos de AWS Glue.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del destino de datos.
- `Inputs`: Obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y una cadena como máximo.

  Los nodos que son entradas para el destino de datos.
- `PartitionKeys`: matriz de cadenas UTF-8.

  Especifica la partición nativa mediante una secuencia de claves.
- `Table`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la tabla de la base de datos de escritura.
- `Database`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la base de datos de escritura.
- `AdditionalOptions`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 que coincide con el Custom string pattern #61.

Cada valor es una cadena UTF-8 que coincide con el Custom string pattern #61.

Especifica opciones de conexión adicionales para el conector.

- `SchemaChangePolicy`: un objeto CatalogSchemaChangePolicy.

  Una política que especifica los comportamientos de actualización del rastreador.

- `AutoDataQuality`: un objeto AutoDataQuality.

  Especifica si se habilita automáticamente la evaluación de la calidad de los datos para el destino del catálogo de Delta de S3. Si se establece en `true`, las comprobaciones de calidad de los datos se realizan automáticamente durante la operación de escritura.

- `OutputSchemas`: matriz de objetos GlueSchema.

  Especifica el esquema de datos para el destino del catálogo de Delta de S3.

Estructura de S3DeltaDirectTarget

Especifica un destino que escribe en un origen de datos de Delta Lake en el Amazon S3.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del destino de datos.

- `Inputs`: Obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y una cadena como máximo.

  Los nodos que son entradas para el destino de datos.

- `PartitionKeys`: matriz de cadenas UTF-8.

  Especifica la partición nativa mediante una secuencia de claves.

- `Path`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  La ruta de Amazon S3 del origen de datos de Delta Lake en la que desea escribir.

- `Compression`: obligatorio: cadena UTF-8 (valores válidos: `uncompressed="UNCOMPRESSED"` | `snappy="SNAPPY"`).

Especifica la forma en que los datos se comprimen. Po lo general no es necesario si los datos tienen una extensión de archivo estándar. Los posibles valores son "gzip" y "bzip").

- NumberTargetPartitions: cadena UTF-8.

  Especifica cuántas particiones de destino se utilizan para distribuir los archivos del conjunto de datos de Delta Lake en Amazon S3.

- Format: Obligatorio: cadena UTF-8 (valores válidos: json="JSON" | csv="CSV" | avro="AVRO" | orc="ORC" | parquet="PARQUET" | hudi="HUDI" | delta="DELTA" | iceberg="ICEBERG" | hyper="HYPER" | xml="XML").

  Especifica el formato de salida de datos para el destino.

- AdditionalOptions: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 que coincide con el Custom string pattern #61.

  Cada valor es una cadena UTF-8 que coincide con el Custom string pattern #61.

  Especifica opciones de conexión adicionales para el conector.

- SchemaChangePolicy: un objeto DirectSchemaChangePolicy.

  Una política que especifica los comportamientos de actualización del rastreador.

- AutoDataQuality: un objeto AutoDataQuality.

  Especifica si se debe habilitar automáticamente la evaluación de la calidad de los datos para el destino directo de Delta de S3. Si se establece en true, las comprobaciones de calidad de los datos se realizan automáticamente durante la operación de escritura.

Estructura JdbcTarget

Especifica un almacén de datos JDBC donde efectuar el rastreo.

Campos

- ConnectionName: cadena UTF-8 con una extensión de 1 byte como mínimo o 2048 bytes como máximo.

  Nombre de la conexión que se utilizará para establecer conexión con el destino de JDBC.

- Path: cadena UTF-8.

Ruta del destino de JDBC.

- `Exclusions`: matriz de cadenas UTF-8.

  Lista de patrones glob utilizados para excluir elementos del rastreo. Para obtener más información, consulte la sección acerca de cómo Catalogar tablas con un rastreador.

- `EnableAdditionalMetadata`: matriz de cadenas UTF-8.

  Especifique un valor de `RAWTYPES` o `COMMENTS` para habilitar metadatos adicionales en las respuestas de la tabla. `RAWTYPES` proporciona el tipo de datos de nivel nativo. `COMMENTS` proporciona comentarios asociados a una columna o tabla de la base de datos.

  Si no necesita metadatos adicionales, mantenga el campo vacío.

Estructura MongoDBTarget

Especifica un almacén de datos Amazon DocumentDB o MongoDB donde realizar el rastreo.

Campos

- `ConnectionName`: cadena UTF-8 con una extensión de 1 byte como mínimo o 2048 bytes como máximo.

  Nombre de la conexión que se utilizará para establecer conexión con el origen de Amazon DocumentDB o MongoDB.

- `Path`: cadena UTF-8.

  Ruta de acceso del origen de Amazon DocumentDB o MongoDB (base de datos/recopilación).

- `ScanAll`: booleano.

  Indica si se deben analizar todos los registros o si se deben muestrear filas de la tabla. Escanear todos los registros puede tardar mucho tiempo cuando la tabla no es una tabla de alto rendimiento.

  Un valor de `true` significa que hay que escanear todos los registros, mientras que un valor de `false` significa que se deben muestrear los registros. Si no se especifica ningún valor, el valor predeterminado es `true`.

Estructura DynamoDBTarget

Especifica una tabla de Amazon DynamoDB para rastrear.

Campos

- `Path`: cadena UTF-8.

  Nombre de la tabla de DynamoDB donde efectuar el rastreo.
- `scanAll`: booleano.

  Indica si se deben analizar todos los registros o si se deben muestrear filas de la tabla. Escanear todos los registros puede tardar mucho tiempo cuando la tabla no es una tabla de alto rendimiento.

  Un valor de `true` significa que hay que escanear todos los registros, mientras que un valor de `false` significa que se deben muestrear los registros. Si no se especifica ningún valor, el valor predeterminado es `true`.
- `scanRate`: número (doble).

  El porcentaje de las unidades de capacidad de lectura configuradas que utilizará el rastreador de AWS Glue. Unidades de capacidad de lectura es un término definido por DynamoDB y es un valor numérico que actúa como limitador de velocidad del número de lecturas que se pueden realizar en esa tabla por segundo.

  Los valores válidos son nulos o un valor entre 0,1 y 1,5. Se utiliza un valor nulo cuando el usuario no proporciona un valor y el valor predeterminado es 0,5 de la unidad de capacidad de lectura configurada (en tablas aprovisionadas) o 0,25 de la unidad de capacidad de lectura máxima configurada (en tablas que utilizan el modo bajo demanda).

Estructura DeltaTarget

Especifica un almacenamiento de datos Delta para rastrear una o más tablas Delta.

Campos

- `DeltaTables`: matriz de cadenas UTF-8.

  Una lista de las rutas de Simple Storage Service (Amazon S3) hacia las tablas Delta.
- `ConnectionName`: cadena UTF-8 con una extensión de 1 byte como mínimo o 2048 bytes como máximo.

Nombre de la conexión que se utilizará para establecer conexión con el destino de la tabla Delta.

- `WriteManifest`: booleano.

  Especifica si se deben escribir los archivos de manifiesto en la ruta de la tabla Delta.

- `CreateNativeDeltaTable`: booleano.

  Especifica si el rastreador creará tablas nativas para permitir la integración con los motores de consulta que permiten consultar directamente el registro de transacciones de Delta.

Estructura de IcebergTarget

Especifica un origen de datos de Apache Iceberg en la que se almacenan las tablas de Iceberg en Amazon S3.

Campos

- `Paths`: matriz de cadenas UTF-8.

  Una o más rutas de Amazon S3 que contienen carpetas de metadatos de Iceberg como `s3://bucket/prefix`.

- `ConnectionName`: cadena UTF-8 con una extensión de 1 byte como mínimo o 2048 bytes como máximo.

  Nombre de la conexión que se utilizará para establecer conexión con el destino de Iceberg.

- `Exclusions`: matriz de cadenas UTF-8.

  Lista de patrones glob utilizados para excluir elementos del rastreo. Para obtener más información, consulte la sección acerca de cómo Catalogar tablas con un rastreador.

- `MaximumTraversalDepth`: número (entero).

  La profundidad máxima de las rutas de Amazon S3 que el rastreador puede recorrer para descubrir la carpeta de metadatos de Iceberg en la ruta de Amazon S3. Se utiliza para limitar el tiempo de ejecución del rastreador.

Estructura de HudiTarget

Especifica un origen de datos Apache Hudi.

Campos

- `Paths`: matriz de cadenas UTF-8.

  Matriz de cadenas de ubicación de Amazon S3 para Hudi, cada una de las cuales indica la carpeta raíz con la que residen los archivos de metadatos de una tabla Hudi. La carpeta Hudi puede estar ubicada en una carpeta secundaria de la carpeta raíz.

  El rastreador escaneará todas las carpetas situadas debajo de una ruta para una carpeta Hudi.

- `ConnectionName`: cadena UTF-8 con una extensión de 1 byte como mínimo o 2048 bytes como máximo.

  Nombre de la conexión que se utilizará para establecer conexión con el destino de Hudi. Si sus archivos Hudi están almacenados en buckets que requieren autorización de VPC, puede configurar sus propiedades de conexión aquí.

- `Exclusions`: matriz de cadenas UTF-8.

  Lista de patrones glob utilizados para excluir elementos del rastreo. Para obtener más información, consulte la sección acerca de cómo Catalogar tablas con un rastreador.

- `MaximumTraversalDepth`: número (entero).

  La profundidad máxima de las rutas de Amazon S3 que el rastreador puede recorrer para descubrir la carpeta de metadatos de Hudi en la ruta de Amazon S3. Se utiliza para limitar el tiempo de ejecución del rastreador.

Estructura CatalogTarget

Especifica un origen de AWS Glue Data Catalog.

Campos

- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre de la base de datos que se va a sincronizar.

- `Tables`: obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo.

  Lista de las tablas que se van a sincronizar.

- `ConnectionName`: cadena UTF-8 con una extensión de 1 byte como mínimo o 2048 bytes como máximo.

  El nombre de la conexión de una tabla del Catálogo de datos respaldada por Amazon S3 que se rastreará al utilizar un tipo de conexión `Catalog` emparejado con un tipo de conexión `NETWORK`.
- `EventQueueArn`: cadena UTF-8.

  Un ARN de Amazon SQS válido. Por ejemplo, `arn:aws:sqs:region:account:sqs`.
- `DlqEventQueueArn`: cadena UTF-8.

  Un ARN de Amazon SQS válido con mensajes fallidos. Por ejemplo, `arn:aws:sqs:region:account:deadLetterQueue`.

Estructura CrawlerMetrics

Métricas de un rastreador especificado.

Campos

- `CrawlerName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del rastreador.
- `TimeLeftSeconds`: número (doble), cero como máximo.

  Tiempo estimado que queda para completar un rastreo que se está ejecutando.
- `StillEstimating`: booleano.

  True si el rastreador sigue calculando cuánto tiempo se tardará en completar esta ejecución.
- `LastRuntimeSeconds`: número (doble), cero como máximo.

  Duración de la ejecución más reciente del rastreador indicada en segundos.
- `MedianRuntimeSeconds`: número (doble), cero como máximo.

  Duración media de las ejecuciones de este rastreador indicada en segundos.
- `TablesCreated`: número (entero), cero como máximo.

  Número de tablas creadas por este rastreador.
- `TablesUpdated`: número (entero), cero como máximo.

Número de tablas actualizadas por este rastreador.

- `TablesDeleted`: número (entero), cero como máximo.

  Número de tablas eliminadas por este rastreador.

Estructura de CrawlerHistory

Contiene la información de la ejecución de un rastreador.

Campos

- `CrawlId`: cadena UTF-8.

  Identificador UUID de cada rastreo.
- `State` – Cadena UTF-8 (valores válidos: `RUNNING` | `COMPLETED` | `FAILED` | `STOPPED`).

  El estado del rastreo.
- `StartTime`: marca temporal.

  La fecha y hora en las que se inició el rastreo.
- `EndTime`: marca temporal.

  La fecha y hora en las que terminó el rastreo.
- `Summary` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Un resumen de la ejecución del rastreo específico en JSON. Contiene las tablas y particiones del catálogo que se agregaron, actualizaron o eliminaron.
- `ErrorMessage` – cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Si se produjo un error, el mensaje de error asociado con el rastreo.
- `LogGroup` – cadena UTF-8, con 1 byte de largo como mínimo y 512 bytes de largo como máximo, que coincide con el Log group string pattern.

  El grupo de registros asociado al rastreo.
- `LogStream` – cadena UTF-8, con 1 byte de largo como mínimo y 512 bytes de largo como máximo, que coincide con el Log-stream string pattern.

El flujo de registros asociado al rastreo.

- `MessagePrefix` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El prefijo para un mensaje de CloudWatch sobre este rastreo.

- `DPUHour`: número (doble), cero como máximo.

  El número de unidades de procesamiento de datos (DPU) utilizadas en horas para el rastreo.

Estructura de CrawlsFilter

Una lista de campos, comparadores y valores que se pueden utilizar para filtrar las ejecuciones de rastreador de un rastreador específico.

Campos

- `FieldName` – Cadena UTF-8 (valores válidos: `CRAWL_ID` | `STATE` | `START_TIME` | `END_TIME` | `DPU_HOUR`).

  Una clave que se utiliza para filtrar las ejecuciones del rastreador para un rastreador específico. Los valores válidos para cada uno de los nombres de campo son:

  - `CRAWL_ID`: cadena que representa el identificador de UUID de un rastreo.
  - `STATE`: una cadena de caracteres que representa el estado del rastreo.
  - `START_TIME` y `END_TIME`: la marca de tiempo Epoch en milisegundos.
  - `DPU_HOUR`: el número de horas de unidad de procesamiento de datos (DPU) utilizadas para el rastreo.

- `FilterOperator` – Cadena UTF-8 (valores válidos: `GT` | `GE` | `LT` | `LE` | `EQ` | `NE`).

  Un comparador definido que opera con el valor. Los operadores disponibles son:

  - `GT`: mayor que.
  - `GE`: mayor o igual que.
  - `LT`: menor que.
  - `LE`: menor o igual que.
  - `EQ`: igual que.
  - `NE`: no es igual que.

- `FieldValue`: cadena UTF-8.

  El valor proporcionado para la comparación en el campo de rastreo.

Estructura SchemaChangePolicy

Una política que especifica los comportamientos de actualización y eliminación del rastreador.

Campos

- `UpdateBehavior` – Cadena UTF-8 (valores válidos: `LOG` | `UPDATE_IN_DATABASE`).

  Comportamiento de actualización cuando el rastreador encuentra un esquema cambiado.
- `DeleteBehavior` – Cadena UTF-8 (valores válidos: `LOG` | `DELETE_FROM_DATABASE` | `DEPRECATE_IN_DATABASE`).

  Comportamiento de eliminación cuando el rastreador encuentra un objeto eliminado.

Estructura LastCrawlInfo

Información de estado y de error sobre el rastreo más reciente.

Campos

- `Status` – Cadena UTF-8 (valores válidos: `SUCCEEDED` | `CANCELLED` | `FAILED`).

  Estado del último rastreo.
- `ErrorMessage` – cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Si se produjo un error, la información de error sobre el último rastreo.
- `LogGroup` – cadena UTF-8, con 1 byte de largo como mínimo y 512 bytes de largo como máximo, que coincide con el Log group string pattern.

  Grupo de registros del último rastreo.
- `LogStream` – cadena UTF-8, con 1 byte de largo como mínimo y 512 bytes de largo como máximo, que coincide con el Log-stream string pattern.

  Flujo de registros del último rastreo.

- `MessagePrefix` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Prefijo de un mensaje sobre este rastreo.
- `StartTime`: marca temporal.

  Hora en la que se inició el rastreo.

Estructura RecrawlPolicy

Al rastrear un origen de datos de Amazon S3 después de completar el primer rastreo, especifica si se debe rastrear de nuevo todo el conjunto de datos o si se deben rastrear sólo las carpetas que se agregaron desde la última ejecución del rastreador. Para obtener más información, consulte Rastreo progresivo en AWS Glue en la guía para desarrolladores.

Campos

- `RecrawlBehavior` – Cadena UTF-8 (valores válidos: `CRAWL_EVERYTHING` | `CRAWL_NEW_FOLDERS_ONLY` | `CRAWL_EVENT_MODE`).

  Especifica si se debe rastrear de nuevo todo el conjunto de datos o si se deben rastrear sólo las carpetas que se agregaron desde la última ejecución del rastreador.

  Un valor de `CRAWL_EVERYTHING` especifica volver a rastrear todo el conjunto de datos.

  Un valor de `CRAWL_NEW_FOLDERS_ONLY` especifica el rastreo sólo de carpetas que se agregaron desde la última ejecución del rastreador.

  Un valor de `CRAWL_EVENT_MODE` especifica rastrear solo los cambios identificados por los eventos de Amazon S3.

Estructura LineageConfiguration

Especifica los parámetros de configuración del linaje de datos para el rastreador.

Campos

- `CrawlerLineageSettings` – Cadena UTF-8 (valores válidos: `ENABLE` | `DISABLE`).

  Especifica si el linaje de datos está habilitado para el rastreador. Los valores válidos son:

- HABILITAR: habilita el linaje de datos para el rastreador
- DESHABILITAR: deshabilita el linaje de datos para el rastreador

Estructura LakeFormationConfiguration

Especifica los parámetros de configuración de AWS Lake Formation para el rastreador.

Campos

- `UseLakeFormationCredentials`: booleano.

  Especifica si se debe utilizar credenciales AWS Lake Formation para el rastreador en lugar de las credenciales de rol de IAM.
- `AccountId`: cadena UTF-8, no más de 12 bytes de largo.

  Necesaria para rastreos de cuentas cruzadas. Para los mismos rastreos de cuentas que los datos de destino, esto se puede dejar como nulo.

Operaciones

- Acción CreateCrawler (Python: create_crawler)
- Acción DeleteCrawler (Python: delete_crawler)
- Acción GetCrawler (Python: get_crawler)
- Acción GetCrawlers (Python: get_crawlers)
- Acción GetCrawlerMetrics (Python: get_crawler_metrics)
- Acción UpdateCrawler (Python: update_crawler)
- Acción StartCrawler (Python: start_crawler)
- Acción StopCrawler (Python: stop_crawler)
- Acción BatchGetCrawlers (Python: batch_get_crawlers)
- Acción ListCrawlers (Python: list_crawlers)
- Acción ListCrawls (Python: list_crawls)

Acción CreateCrawler (Python: create_crawler)

Crea un nuevo rastreador con objetivos, rol, configuración y programación opcional especificados. Se debe especificar al menos un objetivo de rastreo, en el campo `s3Targets`, el campo `jdbcTargets` o el campo `DynamoDBTargets`.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del rastreador nuevo.
- `Role` – Obligatorio: cadena UTF-8.

  El rol de IAM o nombre de recursos de Amazon (ARN) de un rol de IAM que el nuevo rastreador utiliza para obtener acceso a recursos de los clientes.
- `DatabaseName`: cadena UTF-8.

  La base de datos de AWS Glue donde se escriben los resultados como, por ejemplo, `arn:aws:daylight:us-east-1::database/sometable/*`.
- `Description` – cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Descripción del nuevo rastreador.
- `Targets`: obligatorio: objeto CrawlerTargets.

  Lista de colecciones de objetivos donde realizar el rastreo.
- `Schedule`: cadena UTF-8.

  Expresión `cron` utilizada para especificar el programa (consulte Programaciones basadas en tiempo para trabajos y rastreadores). Por ejemplo, para ejecutar algo todos los días a las 12:15 UTC, especifique: `cron(15 12 * * ? *)`.
- `Classifiers`: matriz de cadenas UTF-8.

  Lista de clasificadores personalizados que el usuario ha registrado. De forma predeterminada, todos los clasificadores integrados se incluyen en un rastreo, pero estos clasificadores personalizados siempre anulan los clasificadores predeterminados de una determinada clasificación.

- `TablePrefix`: cadena UTF-8 de 128 bytes de largo como máximo.

  Prefijo de tabla utilizado para las tablas de catálogo que se crean.

- `SchemaChangePolicy`: un objeto SchemaChangePolicy.

  La política para el comportamiento de actualización y eliminación del rastreador.

- `RecrawlPolicy`: un objeto RecrawlPolicy.

  Política que especifica si se debe rastrear de nuevo todo el conjunto de datos o si se deben rastrear sólo las carpetas que se agregaron desde la última ejecución del rastreador.

- `LineageConfiguration`: un objeto LineageConfiguration.

  Especifica los parámetros de configuración del linaje de datos para el rastreador.

- `LakeFormationConfiguration`: un objeto LakeFormationConfiguration.

  Especifica los parámetros de configuración de AWS Lake Formation para el rastreador.

- `Configuration`: cadena UTF-8.

  Información de configuración del rastreador. Esta cadena JSON con varias versiones permite a los usuarios especificar aspectos del comportamiento de un rastreador. Para obtener más información, consulte Establecimiento de opciones de configuración de rastreadores.

- `CrawlerSecurityConfiguration`: cadena UTF-8 de 128 bytes de largo como máximo.

  El nombre de la estructura `SecurityConfiguration` que va a utilizar este rastreador.

- `Tags`: matriz de mapas de pares de clave-valor, con 50 pares como máximo.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es una cadena UTF-8 que no tiene más de 256 bytes de largo.

  Etiquetas que se van a utilizar con esta solicitud de rastreador. Puede utilizar etiquetas para limitar el acceso al rastreador. Para obtener más información acerca de las etiquetas en AWS Glue, consulte Etiquetas de AWS en AWS Glue en la guía para desarrolladores.

Respuesta

- Sin parámetros de respuesta.

Errores

- `InvalidInputException`
- `AlreadyExistsException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`

Acción DeleteCrawler (Python: delete_crawler)

Elimina un rastreador especificado de AWS Glue Data Catalog, a menos que el estado del rastreador sea `RUNNING`.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del rastreador que se eliminará.

Respuesta

- Sin parámetros de respuesta.

Errores

- `EntityNotFoundException`
- `CrawlerRunningException`
- `SchedulerTransitioningException`
- `OperationTimeoutException`

Acción GetCrawler (Python: get_crawler)

Recupera metadatos para un rastreador especificado.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del rastreador para el que se recuperarán los metadatos.

Respuesta

- `Crawler`: un objeto Rastreador.

  Los metadatos para el rastreador especificado.

Errores

- `EntityNotFoundException`
- `OperationTimeoutException`

Acción GetCrawlers (Python: get_crawlers)

Recupera metadatos para todos los rastreadores definidos en la cuenta del cliente.

Solicitud

- `MaxResults`: número (entero) que no es inferior a 1 ni es superior a 1000.

  Número de rastreadores que se devolverá en cada llamada.
- `NextToken`: cadena UTF-8.

  Token de continuación, si se trata de una solicitud de continuidad.

Respuesta

- `Crawlers`: matriz de objetos Rastreador.

  Lista de metadatos de rastreador.
- `NextToken`: cadena UTF-8.

Token de continuación, si la lista devuelta no ha llegado al final de los metadatos definidos en esta cuenta de cliente.

Errores

- `OperationTimeoutException`

Acción GetCrawlerMetrics (Python: get_crawler_metrics)

Recupera métricas sobre rastreadores especificados.

Solicitud

- `CrawlerNameList`: matriz de cadenas UTF-8, con 100 cadenas como máximo.

  Lista de los nombres de rastreadores sobre los que se recuperarán métricas.
- `MaxResults`: número (entero) que no es inferior a 1 ni es superior a 1000.

  Tamaño máximo de una lista que se devolverá.
- `NextToken`: cadena UTF-8.

  Token de continuación si se trata de una llamada de continuidad.

Respuesta

- `CrawlerMetricsList`: matriz de objetos CrawlerMetrics.

  Lista de métricas para el rastreador especificado.
- `NextToken`: cadena UTF-8.

  Token de continuación, si la lista devuelta no contiene la última métrica disponible.

Errores

- `OperationTimeoutException`

Acción UpdateCrawler (Python: update_crawler)

Actualiza un rastreador. Si un rastreador se está ejecutando, debe detenerlo utilizando `StopCrawler` antes de actualizarlo.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del rastreador nuevo.
- `Role`: cadena UTF-8.

  El rol de IAM o nombre de recurso de Amazon (ARN) de un rol de IAM que utiliza el nuevo rastreador para acceder a los recursos del cliente.
- `DatabaseName`: cadena UTF-8.

  La base de datos de AWS Glue donde se almacenan los resultados como, por ejemplo, `arn:aws:daylight:us-east-1::database/sometable/*`.
- `Description` – cadena UTF-8 con un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Descripción del nuevo rastreador.
- `Targets`: un objeto CrawlerTargets.

  Lista de objetivos del rastreo.
- `Schedule`: cadena UTF-8.

  Expresión `cron` utilizada para especificar el programa (consulte Programaciones basadas en tiempo para trabajos y rastreadores). Por ejemplo, para ejecutar algo todos los días a las 12:15 UTC, especifique: `cron(15 12 * * ? *)`.
- `Classifiers`: matriz de cadenas UTF-8.

  Lista de clasificadores personalizados que el usuario ha registrado. De forma predeterminada, todos los clasificadores integrados se incluyen en un rastreo, pero estos clasificadores personalizados siempre anulan los clasificadores predeterminados de una determinada clasificación.
- `TablePrefix`: cadena UTF-8 de 128 bytes de largo como máximo.

Prefijo de tabla utilizado para las tablas de catálogo que se crean.

- `SchemaChangePolicy`: un objeto SchemaChangePolicy.

  La política para el comportamiento de actualización y eliminación del rastreador.

- `RecrawlPolicy`: un objeto RecrawlPolicy.

  Política que especifica si se debe rastrear de nuevo todo el conjunto de datos o si se deben rastrear sólo las carpetas que se agregaron desde la última ejecución del rastreador.

- `LineageConfiguration`: un objeto LineageConfiguration.

  Especifica los parámetros de configuración del linaje de datos para el rastreador.

- `LakeFormationConfiguration`: un objeto LakeFormationConfiguration.

  Especifica los parámetros de configuración de AWS Lake Formation para el rastreador.

- `Configuration`: cadena UTF-8.

  Información de configuración del rastreador. Esta cadena JSON con varias versiones permite a los usuarios especificar aspectos del comportamiento de un rastreador. Para obtener más información, consulte Establecimiento de opciones de configuración de rastreadores.

- `CrawlerSecurityConfiguration`: cadena UTF-8 de 128 bytes de largo como máximo.

  El nombre de la estructura `SecurityConfiguration` que va a utilizar este rastreador.

Respuesta

- Sin parámetros de respuesta.

Errores

- `InvalidInputException`
- `VersionMismatchException`
- `EntityNotFoundException`
- `CrawlerRunningException`
- `OperationTimeoutException`

Acción StartCrawler (Python: start_crawler)

Comienza un rastreo utilizando el rastreo especificado, independientemente de lo que esté programado. Si el rastreador ya está en ejecución, devuelve CrawlerRunningException.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del rastreador que se iniciará.

Respuesta

- Sin parámetros de respuesta.

Errores

- `EntityNotFoundException`
- `CrawlerRunningException`
- `OperationTimeoutException`

Acción StopCrawler (Python: stop_crawler)

Si el rastreador especificado está en ejecución, se detiene el rastreo.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del rastreador que se detendrá.

Respuesta

- Sin parámetros de respuesta.

Errores

- `EntityNotFoundException`
- `CrawlerNotRunningException`
- `CrawlerStoppingException`
- `OperationTimeoutException`

Acción BatchGetCrawlers (Python: batch_get_crawlers)

Devuelve la lista de metadatos de recursos de una determinada lista de nombres de rastreadores. Después de llamar a la operación `ListCrawlers`, puede llamar a esta operación para obtener acceso a los datos a los que ha concedido permisos. Esta operación admite todos los permisos de IAM, incluidas las condiciones de permisos que utilizan etiquetas.

Solicitud

- `CrawlerNames` – Obligatorio: matriz de cadenas UTF-8, con 100 cadenas como máximo.

  Una lista de nombres de rastreadores, que pueden ser los nombres devueltos en la operación `ListCrawlers`.

Respuesta

- `Crawlers`: matriz de objetos Rastreador.

  Lista de definiciones de rastreadores.
- `CrawlersNotFound`: matriz de cadenas UTF-8, con 100 cadenas como máximo.

  Una lista de nombres de rastreadores que no se han encontrado.

Errores

- `InvalidInputException`
- `OperationTimeoutException`

Acción ListCrawlers (Python: list_crawlers)

Recupera los nombres de todos los recursos de rastreadores de esta cuenta de AWS o los recursos con la etiqueta especificada. Esta operación permite ver qué recursos están disponibles en la cuenta y sus nombres.

Esta operación toma el campo `Tags` opcional, que se puede utilizar como filtro en la respuesta para que los recursos etiquetados se devuelvan agrupados. Si decide utilizar el filtrado de etiquetas, solo se devolverán los recursos con la etiqueta especificada.

Solicitud

- `MaxResults`: número (entero) que no es inferior a 1 ni es superior a 1000.

  Tamaño máximo de una lista que se devolverá.
- `NextToken`: cadena UTF-8.

  Token de continuación, si se trata de una solicitud de continuidad.
- `Tags`: matriz de mapas de pares de clave-valor, con 50 pares como máximo.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es una cadena UTF-8 que no tiene más de 256 bytes de largo.

  Especifica que se devuelvan solamente los recursos etiquetados.

Respuesta

- `CrawlerNames`: matriz de cadenas UTF-8, con 100 cadenas como máximo.

  Nombres de todos los rastreadores de la cuenta o de los rastreadores con las etiquetas especificadas.
- `NextToken`: cadena UTF-8.

  Token de continuación, si la lista devuelta no contiene la última métrica disponible.

Errores

- `OperationTimeoutException`

Acción ListCrawls (Python: list_crawls)

Devuelve todos los rastreos de un rastreador especificado. Devuelve solo los rastreos que se han producido desde la fecha de lanzamiento de la función de historial del rastreador y solo conserva hasta 12 meses de rastreo. No se devolverán los rastreos más antiguos.

Puede utilizar esta API para:

- Recupera todos los rastreos de un rastreador especificado.
- Recupera todos los rastreos de un rastreador específico dentro de un recuento limitado.
- Recupera todos los rastreos de un rastreador específico en un rango de tiempo específico.
- Recupera todos los rastreos de un rastreador especificado con un estado, un ID de rastreo o un valor de hora de DPU en particular.

Solicitud

- `CrawlerName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del rastreador cuyo valor desea recuperar.
- `MaxResults`: número (entero) que no es inferior a 1 ni es superior a 1000.

  El número máximo de resultados que devolver. El valor predeterminado es 20 y el máximo es 100.
- `Filters`: matriz de objetos CrawlsFilter.

  Filtra los rastreos de acuerdo con los criterios especificados en una lista de objetos de `CrawlsFilter`.
- `NextToken`: cadena UTF-8.

  Token de continuación si se trata de una llamada de continuidad.

Respuesta

- `Crawls`: matriz de objetos CrawlerHistory.

  Una lista de objetos de `CrawlerHistory` que representan las ejecuciones de rastreo que cumplen sus criterios.
- `NextToken`: cadena UTF-8.

Token de continuación para paginar la lista de tokens obtenida; se devuelve si el segmento actual de la lista no es el último.

Errores

- `EntityNotFoundException`
- `OperationTimeoutException`
- `InvalidInputException`

API de estadísticas de columna

La API de estadísticas de columnas describe las API de AWS Glue para devolver las estadísticas de las columnas de una tabla.

Tipos de datos

- Estructura ColumnStatisticsTaskRun
- Estructura ColumnStatisticsTaskSettings
- Estructura ExecutionAttempt

Estructura ColumnStatisticsTaskRun

El objeto que muestra los detalles de la ejecución de las estadísticas de la columna.

Campos

- `CustomerId`: cadena UTF-8, no más de 12 bytes de largo.

  El ID de la cuenta de AWS.
- `ColumnStatisticsTaskRunId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El identificador de la ejecución de la tarea de estadísticas de columna en particular.
- `DatabaseName`: cadena UTF-8.

  La base de datos en la que se encuentra la tabla.
- `TableName`: cadena UTF-8.

El nombre de la tabla para la que se generan las estadísticas de las columnas.

- `ColumnNameList`: matriz de cadenas UTF-8.

  Una lista de los nombres de las columnas. Si no se proporciona ninguno, todos los nombres de columna de la tabla se usarán de forma predeterminada.

- `CatalogID`: cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del Catálogo de datos donde reside la tabla. Si no se proporciona ninguno, el ID de cuenta de AWS se usará de forma predeterminada.

- `Role`: cadena UTF-8.

  El rol de IAM que el servicio asume para generar estadísticas.

- `SampleSize`: número (doble), 100 como máximo.

  El porcentaje de filas que se utilizan para generar estadísticas. Si no se proporciona ninguno, la tabla completa se usará para generar estadísticas.

- `SecurityConfiguration`: cadena UTF-8 de 128 bytes de largo como máximo.

  Nombre de la configuración de seguridad que se utiliza para cifrar los registros de CloudWatch para la ejecución de la tarea de estadísticas de columnas.

- `NumberOfWorkers`: número (entero), como mínimo 1.

  El número de empleados utilizados para generar las estadísticas de las columnas. El trabajo está preconfigurado para escalar automáticamente hasta 25 instancias.

- `WorkerType`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El tipo de trabajadores que se utilizan para generar estadísticas. El valor predeterminado es `g.1x`.

- `ComputationType`: cadena UTF-8 (valores válidos: `FULL` | `INCREMENTAL`).

  El tipo de computación de las estadísticas de columnas.

- `Status`: cadena UTF-8 (valores válidos: `STARTING` | `RUNNING` | `SUCCEEDED` | `FAILED` | `STOPPED`).

  El estado de la ejecución de la tarea.

- `CreationTime`: marca temporal.

La hora en que se creó esta tarea.

- `LastUpdated`: marca temporal.

  El último punto temporal en que se modificó esta tarea.

- `StartTime`: marca temporal.

  La hora de inicio de la tarea.

- `EndTime`: marca temporal.

  La hora de finalización de la tarea.

- `ErrorMessage`: cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  El mensaje de error del trabajo.

- `DPUSeconds`: número (doble), cero como máximo.

  El uso de la DPU calculado en segundos para todos los trabajadores con escalado automático.

Estructura ColumnStatisticsTaskSettings

Configuración de una tarea de estadísticas de columnas.

Campos

- `DatabaseName`: cadena UTF-8.

  El nombre de la base de datos donde reside la tabla.

- `TableName`: cadena UTF-8.

  El nombre de la tabla para la que se generan las estadísticas de columnas.

- `Schedule`: un objeto Programación.

  Una programación para ejecutar las estadísticas de columnas, especificado en la sintaxis CRON.

- `ColumnNameList`: matriz de cadenas UTF-8.

  Una lista de los nombres de columnas en las que se ejecutan las estadísticas.

- `CatalogID`: cadena de ID de catálogo, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

El ID del Catálogo de datos donde reside la base de datos.

- `Role`: cadena UTF-8.

  El rol que se utiliza para ejecutar las estadísticas de columnas.

- `SampleSize`: número (doble), 100 como máximo.

  El porcentaje de datos que se van a usar como muestra.

- `SecurityConfiguration`: cadena UTF-8 de 128 bytes de largo como máximo.

  Nombre de la configuración de seguridad que se utiliza para cifrar los registros de CloudWatch.

- `ScheduleType`: cadena UTF-8 (valores válidos: `CRON` | `AUTO`).

  El tipo de programación de una tarea de estadísticas de columnas. Los valores posibles pueden ser `CRON` o `AUTO`.

- `SettingSource`: cadena UTF-8 (valores válidos: `CATALOG` | `TABLE`).

  El origen de la configuración de la tarea de estadísticas de columnas. Los valores posibles pueden ser `CATALOG` o `TABLE`.

- `LastExecutionAttempt`: un objeto ExecutionAttempt.

  El último `ExecutionAttempt` para la ejecución de la tarea de estadísticas de columnas.

Estructura ExecutionAttempt

Intento de ejecución de una tarea de estadísticas de columnas.

Campos

- `Status`: cadena UTF-8 (valores válidos: `FAILED` | `STARTED`).

  El estado de la última ejecución de la tarea de estadísticas de columnas.

- `ColumnStatisticsTaskRunId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  ID de ejecución de tarea para la última ejecución de la tarea de estadísticas de columnas.

- `ExecutionTimestamp`: marca temporal.

  Una marca de tiempo para la última ejecución de la tarea de estadísticas de columnas.

- `ErrorMessage`: cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Un mensaje de error asociado a la última ejecución de la tarea de estadísticas de columnas.

Operaciones

- StartColumnStatisticsTaskRun action (Python: start_column_statistics_task_run)
- GetColumnStatisticsTaskRun action (Python: get_column_statistics_task_run)
- GetColumnStatisticsTaskRuns action (Python: get_column_statistics_task_runs)
- ListColumnStatisticsTaskRuns action (Python: list_column_statistics_task_runs)
- StopColumnStatisticsTaskRun action (Python: stop_column_statistics_task_run)
- Acción CreateColumnStatisticsTaskSettings (Python: create_column_statistics_task_settings)
- Acción UpdateColumnStatisticsTaskSettings (Python: update_column_statistics_task_settings)
- Acción GetColumnStatisticsTaskSettings (Python: get_column_statistics_task_settings)
- Acción DeleteColumnStatisticsTaskSettings (Python: delete_column_statistics_task_settings)
- Acción StartColumnStatisticsTaskRunSchedule (Python: start_column_statistics_task_run_schedule)
- Acción StopColumnStatisticsTaskRunSchedule (Python: stop_column_statistics_task_run_schedule)

StartColumnStatisticsTaskRun action (Python: start_column_statistics_task_run)

Inicia la ejecución de una tarea de estadísticas de columnas para una tabla y columnas especificadas.

Solicitud

- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos donde reside la tabla.
- `TableName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la tabla con que se van a generar estadísticas.

- `ColumnNameList`: matriz de cadenas UTF-8.

  Una lista de los nombres de las columnas para generar estadísticas. Si no se proporciona ninguno, todos los nombres de columna de la tabla se usarán de forma predeterminada.

- `Role`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El rol de IAM que el servicio asume para generar estadísticas.

- `SampleSize`: número (doble), 100 como máximo.

  El porcentaje de filas que se utilizan para generar estadísticas. Si no se proporciona ninguno, la tabla completa se usará para generar estadísticas.

- `CatalogID`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del catálogo de datos donde reside la tabla. Si no se proporciona ninguno, el ID de cuenta de AWS se usará de forma predeterminada.

- `SecurityConfiguration`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre de la configuración de seguridad que se utiliza para cifrar los registros de CloudWatch para la ejecución de la tarea de estadísticas de columnas.

Respuesta

- `ColumnStatisticsTaskRunId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El identificador de ejecución de la tarea de estadísticas de las columnas.

Errores

- `AccessDeniedException`
- `EntityNotFoundException`
- `ColumnStatisticsTaskRunningException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`

- `InvalidInputException`

GetColumnStatisticsTaskRun action (Python: get_column_statistics_task_run)

Obtenga los metadatos o la información asociados a la ejecución de una tarea, con un identificador de ejecución de la tarea determinado.

Solicitud

- `ColumnStatisticsTaskRunId`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El identificador de la ejecución de la tarea de estadísticas de columna en particular.

Respuesta

- `ColumnStatisticsTaskRun`: un objeto ColumnStatisticsTaskRun.

  Un objeto de `ColumnStatisticsTaskRun` que representa los detalles de la ejecución de las estadísticas de la columna.

Errores

- `EntityNotFoundException`
- `OperationTimeoutException`
- `InvalidInputException`

GetColumnStatisticsTaskRuns action (Python: get_column_statistics_task_runs)

Recupera información sobre todas las ejecuciones asociadas a la tabla especificada.

Solicitud

- `DatabaseName` – Obligatorio: cadena UTF-8.

  El nombre de la base de datos donde reside la tabla.
- `TableName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

El nombre de la tabla.

- `MaxResults`: número (entero) que no es inferior a 1 ni es superior a 1000.

  Tamaño máximo de la respuesta.

- `NextToken`: cadena UTF-8.

  Token de continuación si se trata de una llamada de continuidad.

Respuesta

- `ColumnStatisticsTaskRuns`: matriz de objetos ColumnStatisticsTaskRun.

  Una lista de las ejecuciones de tareas de estadísticas de las columnas.

- `NextToken`: cadena UTF-8.

  Un token de continuación, si todavía no se han devuelto todas las ejecuciones de tareas.

Errores

- `OperationTimeoutException`

ListColumnStatisticsTaskRuns action (Python: list_column_statistics_task_runs)

Enumera todas las ejecuciones de tareas para una cuenta en particular.

Solicitud

- `MaxResults`: número (entero) que no es inferior a 1 ni es superior a 1000.

  Tamaño máximo de la respuesta.

- `NextToken`: cadena UTF-8.

  Token de continuación si se trata de una llamada de continuidad.

Respuesta

- `ColumnStatisticsTaskRunIds`: matriz de cadenas UTF-8, con 100 cadenas como máximo.

Una lista de los identificadores de ejecución de las tareas de estadísticas de las columnas.

- `NextToken`: cadena UTF-8.

  Un token de continuación, si todavía no se han devuelto todos los identificadores de ejecución de tareas.

Errores

- `OperationTimeoutException`

StopColumnStatisticsTaskRun action (Python: stop_column_statistics_task_run)

Detiene la ejecución de una tarea para la tabla especificada.

Solicitud

- `DatabaseName` – Obligatorio: cadena UTF-8.

  El nombre de la base de datos donde reside la tabla.

- `TableName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la tabla.

Respuesta

- Sin parámetros de respuesta.

Errores

- `EntityNotFoundException`
- `ColumnStatisticsTaskNotRunningException`
- `ColumnStatisticsTaskStoppingException`
- `OperationTimeoutException`

Acción CreateColumnStatisticsTaskSettings (Python: create_column_statistics_task_settings)

Crea la configuración de una tarea de estadísticas de columnas.

Solicitud

- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos donde reside la tabla.
- `TableName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la tabla para la que se generan las estadísticas de columnas.
- `Role`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El rol que se utiliza para ejecutar las estadísticas de columnas.
- `Schedule`: cadena UTF-8.

  Una programación para ejecutar las estadísticas de columnas, especificado en la sintaxis CRON.
- `ColumnNameList`: matriz de cadenas UTF-8.

  Una lista de los nombres de columnas en las que se ejecutan las estadísticas.
- `SampleSize`: número (doble), 100 como máximo.

  El porcentaje de datos que se van a usar como muestra.
- `CatalogID`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del Catálogo de datos donde reside la base de datos.
- `SecurityConfiguration`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre de la configuración de seguridad que se utiliza para cifrar los registros de CloudWatch.
- `Tags`: matriz de mapas de pares de clave-valor, con 50 pares como máximo.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

Cada valor es una cadena UTF-8 que no tiene más de 256 bytes de largo.

Mapa de etiquetas.

Respuesta

- Sin parámetros de respuesta.

Errores

- `AlreadyExistsException`
- `AccessDeniedException`
- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`
- `ColumnStatisticsTaskRunningException`

Acción UpdateColumnStatisticsTaskSettings (Python: update_column_statistics_task_settings)

Actualiza la configuración de una tarea de estadísticas de columnas.

Solicitud

- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos donde reside la tabla.
- `TableName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la tabla para la que se generan las estadísticas de columnas.
- `Role`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

El rol que se utiliza para ejecutar las estadísticas de columnas.

- `Schedule`: cadena UTF-8.

  Una programación para ejecutar las estadísticas de columnas, especificado en la sintaxis CRON.

- `ColumnNameList`: matriz de cadenas UTF-8.

  Una lista de los nombres de columnas en las que se ejecutan las estadísticas.

- `SampleSize`: número (doble), 100 como máximo.

  El porcentaje de datos que se van a usar como muestra.

- `CatalogID`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del Catálogo de datos donde reside la base de datos.

- `SecurityConfiguration`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre de la configuración de seguridad que se utiliza para cifrar los registros de CloudWatch.

Respuesta

- Sin parámetros de respuesta.

Errores

- `AccessDeniedException`
- `EntityNotFoundException`
- `InvalidInputException`
- `VersionMismatchException`
- `OperationTimeoutException`

Acción GetColumnStatisticsTaskSettings (Python: get_column_statistics_task_settings)

Obtiene la configuración de una tarea de estadísticas de columnas.

Solicitud

- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos donde reside la tabla.

- `TableName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la tabla de la que se recuperan las estadísticas de columnas.

Respuesta

- `ColumnStatisticsTaskSettings`: un objeto ColumnStatisticsTaskSettings.

  Un objeto `ColumnStatisticsTaskSettings` que representa la configuración de la tarea de estadísticas de columnas.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`

Acción DeleteColumnStatisticsTaskSettings (Python: delete_column_statistics_task_settings)

Elimina la configuración de una tarea de estadísticas de columnas.

Solicitud

- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos donde reside la tabla.

- `TableName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

El nombre de la tabla de la que se eliminan las estadísticas de columnas.

Respuesta

- Sin parámetros de respuesta.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`

Acción StartColumnStatisticsTaskRunSchedule (Python: start_column_statistics_task_run_schedule)

Inicia una programación de ejecución de tareas de estadísticas de columnas.

Solicitud

- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos donde reside la tabla.
- `TableName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la tabla en la que se va a iniciar una programación de ejecución de tareas de estadísticas de columnas.

Respuesta

- Sin parámetros de respuesta.

Errores

- `AccessDeniedException`

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`

Acción StopColumnStatisticsTaskRunSchedule (Python: stop_column_statistics_task_run_schedule)

Detiene la programación de ejecución de una tarea de estadísticas de columnas.

Solicitud

- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos donde reside la tabla.
- `TableName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la tabla en la que se va a detener una programación de ejecución de tareas de estadísticas de columnas.

Respuesta

- Sin parámetros de respuesta.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`

Excepciones

- Estructura ColumnStatisticsTaskRunningException
- Estructura ColumnStatisticsTaskNotRunningException
- Estructura ColumnStatisticsTaskStopingException

- Estructura ColumnStatisticsTaskAutoConcurrencyLimitException
- Estructura InvalidCatalogSettingException

Estructura ColumnStatisticsTaskRunningException

Se produce una excepción cuando se intenta iniciar otro trabajo mientras se ejecuta un trabajo de generación de estadísticas de columnas.

Campos

- `Message`: cadena UTF-8.

  Mensaje que describe el problema.

Estructura ColumnStatisticsTaskNotRunningException

Una excepción que se produce cuando se intenta detener la ejecución de una tarea cuando no hay ninguna tarea en ejecución.

Campos

- `Message`: cadena UTF-8.

  Mensaje que describe el problema.

Estructura ColumnStatisticsTaskStopingException

Una excepción que se produce cuando se intenta detener la ejecución de una tarea.

Campos

- `Message`: cadena UTF-8.

  Mensaje que describe el problema.

Estructura ColumnStatisticsTaskAutoConcurrencyLimitException

Se produce una excepción cuando alcanza el límite de trabajos de estadísticas automáticos y simultáneos.

Campos

- `Message`: cadena UTF-8.

  Mensaje que describe el problema.

Estructura InvalidCatalogSettingException

Se produce una excepción cuando hay un problema con la configuración del catálogo.

Campos

- `Message`: cadena UTF-8.

  Mensaje que describe el problema.

API del programador del rastreador

La API del programador de rastreadores describe los tipos de datos de rastreadores de AWS Glue, junto con la API para crear, eliminar, actualizar y ver listas de rastreadores.

Tipos de datos

- Estructura de programación

Estructura de programación

Objeto de programación que usa una instrucción `cron` para programar un evento.

Campos

- `ScheduleExpression`: cadena UTF-8.

  Expresión `cron` utilizada para especificar el programa (consulte Programaciones basadas en tiempo para trabajos y rastreadores). Por ejemplo, para ejecutar algo todos los días a las 12:15 UTC, especifique: `cron(15 12 * * ? *)`.
- `State`: cadena UTF-8 (valores válidos: `SCHEDULED` | `NOT_SCHEDULED` | `TRANSITIONING`).

  Estado del programa.

Operaciones

- Acción UpdateCrawlerSchedule (Python: update_crawler_schedule)
- Acción StartCrawlerSchedule (Python: start_crawler_schedule)
- Acción StopCrawlerSchedule (Python: stop_crawler_schedule)

Acción UpdateCrawlerSchedule (Python: update_crawler_schedule)

Actualiza la programación de un rastreador mediante una expresión `cron`.

Solicitud

- `CrawlerName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del rastreador cuya programación se debe actualizar.
- `Schedule`: cadena UTF-8.

  La expresión `cron` actualizada que se utiliza para especificar el programa (consulte el tema sobre programaciones basadas en tiempo para trabajos y rastreadores). Por ejemplo, para ejecutar algo todos los días a las 12:15 UTC, especifique: `cron(15 12 * * ? *)`.

Respuesta

- Sin parámetros de respuesta.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `VersionMismatchException`
- `SchedulerTransitioningException`
- `OperationTimeoutException`

Acción StartCrawlerSchedule (Python: start_crawler_schedule)

Cambia el estado de programación del rastreador especificado para `SCHEDULED`, salvo que el rastreador ya se esté ejecutando o el estado de programación ya esté en `SCHEDULED`.

Solicitud

- `CrawlerName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del rastreador que se va a programar.

Respuesta

- Sin parámetros de respuesta.

Errores

- `EntityNotFoundException`
- `SchedulerRunningException`
- `SchedulerTransitioningException`
- `NoScheduleException`
- `OperationTimeoutException`

Acción StopCrawlerSchedule (Python: stop_crawler_schedule)

Establece el estado del programador del rastreador especificado en `NOT_SCHEDULED`, pero no detiene el rastreador si ya se está ejecutando.

Solicitud

- `CrawlerName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del rastreador cuyo estado de programación se va a definir.

Respuesta

- Sin parámetros de respuesta.

Errores

- `EntityNotFoundException`
- `SchedulerNotRunningException`
- `SchedulerTransitioningException`
- `OperationTimeoutException`

API de generación automática de scripts de ETL

La API de generación de scripts de ETL describe los tipos de datos y la API de generación de scripts de ETL en AWS Glue.

Tipos de datos

- Estructura CodeGenNode
- Estructura CodeGenNodeArg
- Estructura CodeGenEdge
- Estructura de ubicación
- Estructura CatalogEntry
- Estructura MappingEntry

Estructura CodeGenNode

Representa un nodo en gráficos acíclicos dirigidos (DAG)

Campos

- `Id`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Identifier string pattern.

  Identificador de nodo que es único en el gráfico de nodos.
- `NodeType` – Obligatorio: cadena UTF-8.

El tipo de nodo de que se trata.

- `Args` – Obligatorio: matriz de objetos CodeGenNodeArg, con 50 estructuras como máximo.

  Propiedades del nodo, en forma de pares nombre-valor.

- `LineNumber`: número (entero).

  El número de la línea del nodo.

Estructura CodeGenNodeArg

Argumento o propiedad de un nodo.

Campos

- `Name` – Obligatorio: cadena UTF-8.

  El nombre del argumento o la propiedad.

- `Value` – Obligatorio: cadena UTF-8.

  El valor del argumento o la propiedad.

- `Param`: booleano.

  True si el valor se utiliza como un parámetro.

Estructura CodeGenEdge

Representa un límite direccional en un gráfico acíclico dirigido (DAG).

Campos

- `Source`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Identifier string pattern.

  El ID del nodo donde comienza el límite.

- `Target`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Identifier string pattern.

  El ID del nodo donde finaliza el límite.

- `TargetParameter`: cadena UTF-8.

  El destino del límite.

Estructura de ubicación

La ubicación de los recursos.

Campos

- `Jdbc`: matriz de objetos CodeGenNodeArg, con 50 estructuras como máximo.

  Una ubicación de JDBC.
- `S3`: matriz de objetos CodeGenNodeArg, con 50 estructuras como máximo.

  Una ubicación de Amazon Simple Storage Service (Amazon S3).
- `DynamoDB`: matriz de objetos CodeGenNodeArg, con 50 estructuras como máximo.

  Una ubicación de tabla de Amazon DynamoDB.

Estructura CatalogEntry

Especifica una definición de tabla en el AWS Glue Data Catalog.

Campos

- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  La base de datos en la que se encuentran los metadatos de la tabla.
- `TableName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre de la tabla en cuestión.

Estructura MappingEntry

Define un mapeo.

Campos

- `SourceTable`: cadena UTF-8.

  El nombre de la tabla de origen.

- `SourcePath`: cadena UTF-8.

  La ruta de origen de .

- `SourceType`: cadena UTF-8.

  El tipo de origen.

- `TargetTable`: cadena UTF-8.

  La tabla de destino.

- `TargetPath`: cadena UTF-8.

  La ruta de destino.

- `TargetType`: cadena UTF-8.

  El tipo de destino.

Operaciones

- Acción CreateScript (Python: create_script)
- Acción GetDataflowGraph (Python: get_dataflow_graph)
- Acción GetMapping (Python: get_mapping)
- Acción GetPlan (Python: get_plan)

Acción CreateScript (Python: create_script)

Transforma gráficos acíclicos dirigidos (DAG) en código.

Solicitud

- `DagNodes`: matriz de objetos CodeGenNode.

  Lista de los nodos en el DAG.

- `DagEdges`: matriz de objetos CodeGenEdge.

  Lista de los límites en el DAG.
- `Language`: cadena UTF-8 (valores válidos: `PYTHON` | `SCALA`).

  El lenguaje de programación del código que genera el DAG.

Respuesta

- `PythonScript`: cadena UTF-8.

  El script de Python generado desde el DAG.
- `ScalaCode`: cadena UTF-8.

  El código Scala generado desde el DAG.

Errores

- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

Acción GetDataflowGraph (Python: get_dataflow_graph)

Transforma scripts de Python en gráficos acíclicos dirigidos (DAG).

Solicitud

- `PythonScript`: cadena UTF-8.

  El script de Python que se va a transformar.

Respuesta

- `DagNodes`: matriz de objetos CodeGenNode.

  Lista de los nodos en el DAG resultante.
- `DagEdges`: matriz de objetos CodeGenEdge.

Lista de los límites en el DAG resultante.

Errores

- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

Acción GetMapping (Python: get_mapping)

Crea mapeos.

Solicitud

- `Source`: obligatorio: objeto CatalogEntry.

  Especifica la tabla de origen.
- `Sinks`: matriz de objetos CatalogEntry.

  Lista de las tablas de destino.
- `Location`: un objeto Ubicación.

  Parámetros para el mapeo.

Respuesta

- `Mapping` (obligatorio): una matriz de objetos MappingEntry.

  Lista de mapeos para los destinos especificados.

Errores

- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `EntityNotFoundException`

Acción GetPlan (Python: get_plan)

Obtiene código para realizar un mapeo especificado.

Solicitud

- `Mapping` (obligatorio): una matriz de objetos MappingEntry.

  La lista de mapeos desde una tabla de origen a las tablas de destino.
- `Source`: obligatorio: objeto CatalogEntry.

  La tabla de origen.
- `Sinks`: matriz de objetos CatalogEntry.

  Las tablas de destino.
- `Location`: un objeto Ubicación.

  Los parámetros para el mapeo.
- `Language`: cadena UTF-8 (valores válidos: `PYTHON` | `SCALA`).

  El lenguaje de programación del código para realizar el mapeo.
- `AdditionalPlanOptionsMap`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8.

  Cada valor es una cadena UTF-8.

  Un mapa para contener parámetros opcionales de clave-valor adicionales.

  Actualmente, se soportan los siguientes pares clave-valor:

  - `inferSchema`: especifica si se debe configurar `inferSchema` como verdadero o falso para el script predeterminado generado por un trabajo de AWS Glue. Por ejemplo, para configurar `inferSchema` como verdadero, transfiera el siguiente par de clave-valor:

    ```
    --additional-plan-options-map '{"inferSchema":"true"}'
    ```

Respuesta

- `PythonScript`: cadena UTF-8.

Script de Python para realizar el mapeo.

- `ScalaCode`: cadena UTF-8.

  Código de Scala para realizar el mapeo.

Errores

- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

API de Visual Job

La API de Visual Job le permite crear trabajos de integración de datos mediante la API de AWS Glue a partir de un objeto JSON que representa una configuración visual de un trabajo de AWS Glue.

Se proporciona una lista de `CodeGenConfigurationNodes` a una API de creación o actualización de trabajos a fin de registrar un DAG en AWS Glue Studio para el trabajo creado y generar el código asociado.

Tipos de datos

- Estructura CodeGenConfigurationNode
- Estructura JDBCConnectorOptions
- Estructura StreamingDataPreviewOptions
- Estructura AthenaConnectorSource
- Estructura JDBCConnectorSource
- Estructura SparkConnectorSource
- Estructura CatalogSource
- Estructura MySQLCatalogSource
- Estructura PostgreSQLCatalogSource
- Estructura OracleSQLCatalogSource
- Estructura MicrosoftSQLServerCatalog

- Estructura CatalogKinesisSource
- Estructura DirectKinesisSource
- Estructura KinesisStreamingSourceOptions
- Estructura CatalogKafkaSource
- Estructura DirectKafkaSource
- Estructura KafkaStreamingSourceOptions
- Estructura RedshiftSource
- Estructura de AmazonRedshiftSource
- Estructura de AmazonRedshiftNodeData
- Estructura de AmazonRedshiftAdvancedOption
- Estructura de opción
- Estructura S3CatalogSource
- Estructura S3SourceAdditionalOptions
- Estructura S3CsvSource
- Estructura DirectJDBCSource
- Estructura S3DirectSourceAdditionalOptions
- Estructura S3JsonSource
- Estructura S3ParquetSource
- Estructura de S3DeltaSource
- Estructura de S3CatalogDeltaSource
- Estructura de CatalogDeltaSource
- Estructura S3HudiSource
- Estructura S3CatalogHudiSource
- Estructura S3ExcelSource
- Estructura CatalogHudiSource
- Estructura DynamoDBCatalogSource
- Estructura RelationalCatalogSource
- Estructura JDBCConnectorTarget
- Estructura SparkConnectorTarget

- Estructura BasicCatalogTarget
- Estructura MySQLCatalogTarget
- Estructura PostgreSQLCatalogSourceTarget
- Estructura OracleSQLCatalogTarget
- Estructura MicrosoftSQLServerCatalogTarget
- Estructura RedshiftTarget
- Estructura de AmazonRedshiftTarget
- Estructura UpsertRedShiftTargetOptions
- Estructura S3CatalogTarget
- Estructura S3GlueParquetTarget
- Estructura CatalogSchemaChangePolicy
- Estructura S3DirectTarget
- Estructura S3HudiCatalogTarget
- Estructura S3HudiDirectTarget
- Estructura de S3DeltaCatalogTarget
- Estructura de S3DeltaDirectTarget
- Estructura S3HyperDirectTarget
- Estructura S3IcebergDirectTarget
- Estructura DirectSchemaChangePolicy
- Estructura ApplyMapping
- Estructura de asignación
- Estructura SelectFields
- Estructura DropFields
- Estructura RenameField
- Estructura Spigot
- Estructura Join
- Estructura JoinColumn
- Estructura SplitFields
- Estructura SelectFromCollection

- Estructura FillMissingValues
- Estructura Filter
- Estructura FilterExpression
- Estructura FilterValue
- Estructura CustomCode
- Estructura SparkSQL
- Estructura SQLAlias
- Estructura DropNullFields
- Estructura NullCheckBoxList
- Estructura NullValueField
- Estructura Datatype
- Estructura Merge
- Estructura Union
- Estructura PIIDetection
- Estructura Aggregate
- Estructura DropDuplicates
- Estructura GovernedCatalogTarget
- Estructura GovernedCatalogSource
- Estructura AggregateOperation
- Estructura GlueSchema
- Estructura GlueStudioSchemaColumn
- Estructura GluStudioColumn
- Estructura de DynamicTransform
- Estructura de TransformConfigParameter
- Estructura de EvaluateDataQuality
- Estructura de DQResultsPublishingOptions
- Estructura de DQStopJobOnFailureOptions
- Estructura EvaluateDataQualityMultiFrame
- Estructura de receta

- Estructura RecipeReference
- Estructura de SnowflakeNodeData
- Estructura de SnowflakeSource
- Estructura de SnowflakeTarget
- Estructura de ConnectorDataSource
- Estructura de ConnectorDataTarget
- Estructura de RecipeStep
- Estructura de RecipeAction
- Estructura de ConditionExpression
- Estructura S3CatalogIcebergSource
- Estructura CatalogIcebergSource
- Estructura S3IcebergCatalogTarget
- Estructura DynamoDBELTConnectorSource
- Estructura DDBELTConnectionOptions
- Estructura DDBELTCatalogAdditionalOptions
- Estructura de rutas
- Estructura GroupFilters
- Estructura AutoDataQuality

Estructura CodeGenConfigurationNode

`CodeGenConfigurationNode` enumera todos los tipos de nodos válidos. Se puede completar una y solo una de sus variables miembro.

Campos

- `AthenaConnectorSource`: un objeto AthenaConnectorSource.

  Especifica un conector a un origen de datos de Amazon Athena.

- `JDBCConnectorSource`: un objeto JDBCConnectorSource.

  Especifica un conector a un origen de datos JDBC.

- `SparkConnectorSource`: un objeto SparkConnectorSource.

  Especifica un conector a un origen de datos de Apache Spark.

- `CatalogSource`: un objeto CatalogSource.

  Especifica un almacén de datos en AWS Glue Data Catalog.

- `RedshiftSource`: un objeto RedshiftSource.

  Especifica un almacén de datos de Amazon Redshift.

- `S3CatalogSource`: un objeto S3CatalogSource.

  Especifica un almacén de datos de Amazon S3 en AWS Glue Data Catalog.

- `S3CsvSource`: un objeto S3CsvSource.

  Especifica un almacén de datos de valores separados por comas (CSV) almacenado en Amazon S3.

- `S3JsonSource`: un objeto S3JsonSource.

  Especifica un almacén de datos JSON almacenado en Amazon S3.

- `S3ParquetSource`: un objeto S3ParquetSource.

  Especifica un almacén de datos de Apache Parquet almacenado en Amazon S3.

- `RelationalCatalogSource`: un objeto RelationalCatalogSource.

  Especifica un almacén de datos de catálogo relacional en el Catálogo de datos de AWS Glue.

- `DynamoDBCatalogSource`: un objeto DynamoDBCatalogSource.

  Especifica un almacén de datos del catálogo de DynamoDBC en el Catálogo de datos de AWS Glue.

- `JDBCConnectorTarget`: un objeto JDBCConnectorTarget.

  Especifica un destino de datos que escribe en Amazon S3 en el almacenamiento en columnas de Apache Parquet.

- `SparkConnectorTarget`: un objeto SparkConnectorTarget.

  Especifica un destino que utiliza un conector de Apache Spark.

- `CatalogTarget`: un objeto BasicCatalogTarget.

Especifica un destino que utiliza una tabla de AWS Glue Data Catalog.

- `RedshiftTarget`: un objeto RedshiftTarget.

  Especifica un destino que utiliza Amazon Redshift.

- `S3CatalogTarget`: un objeto S3CatalogTarget.

  Especifica un destino de datos que escribe en Amazon S3 mediante AWS Glue Data Catalog.

- `S3GlueParquetTarget`: un objeto S3GlueParquetTarget.

  Especifica un destino de datos que escribe en Amazon S3 en el almacenamiento en columnas de Apache Parquet.

- `S3DirectTarget`: un objeto S3DirectTarget.

  Especifica un destino de datos que escribe en Amazon S3.

- `ApplyMapping`: un objeto ApplyMapping.

  Especifica una transformación que asigna claves de propiedad de datos en el origen de datos a claves de propiedad de datos en el destino de datos. Puede cambiar el nombre de las claves, modificar los tipos de datos de las claves y elegir las claves que desea descartar del conjunto de datos.

- `SelectFields`: un objeto SelectFields.

  Especifica una transformación que elige las claves de propiedad de datos que desea conservar.

- `DropFields`: un objeto DropFields.

  Especifica una transformación que elige las claves de propiedad de datos que desea eliminar.

- `RenameField`: un objeto RenameField.

  Especifica una transformación que cambia el nombre de una única clave de propiedad de datos.

- `Spigot`: un objeto Spigot.

  Especifica una transformación que escribe ejemplos de los datos en un bucket de Amazon S3.

- `Join`: un objeto Join.

  Especifica una transformación que une dos conjuntos de datos en uno mediante una frase de comparación en las claves de propiedad de datos especificadas. Puede utilizar combinaciones interna, externa, izquierda, derecha, semicombinación izquierda y anticombinación izquierda.

- `SplitFields`: un objeto SplitFields.

  Especifica una transformación que divide las claves de propiedad de datos en dos `DynamicFrames`. La salida es una recopilación de `DynamicFrames`: uno con las claves de propiedad de datos seleccionadas y el otro con las claves de propiedad de datos restantes.

- `SelectFromCollection`: un objeto SelectFromCollection.

  Especifica una transformación que elige un `DynamicFrame` de una recopilación de `DynamicFrames`. El resultado es el seleccionado `DynamicFrame`

- `FillMissingValues`: un objeto FillMissingValues.

  Especifica una transformación que localiza registros en el conjunto de datos que tienen valores faltantes y agrega un nuevo campo con un valor determinado por imputación. El conjunto de datos de entrada se utiliza para formar al modelo de machine learning que determina cuál debe ser el valor que falta.

- `Filter`: un objeto Filtro.

  Especifica una transformación que divide un conjunto de datos en dos, en función de una condición de filtro.

- `CustomCode`: un objeto CustomCode.

  Especifica una transformación que utiliza el código personalizado que proporciona el usuario para llevar a cabo la transformación de datos. La salida es una recopilación de DynamicFrames.

- `SparkSQL`: un objeto SparkSQL.

  Especifica una transformación en la que se ingresa una consulta SQL mediante la sintaxis de Spark SQL para transformar los datos. La salida es un único `DynamicFrame`.

- `DirectKinesisSource`: un objeto DirectKinesisSource.

  Especifica un origen de datos directo de Amazon Kinesis.

- `DirectKafkaSource`: un objeto DirectKafkaSource.

  Especifica un almacén de datos de Apache Kafka.

- `CatalogKinesisSource`: un objeto CatalogKinesisSource.

  Especifica un origen de datos de Kinesis en AWS Glue Data Catalog.

- `CatalogKafkaSource`: un objeto CatalogKafkaSource.

Especifica un almacén de datos de Apache Kafka en Data Catalog.

- `DropNullFields`: un objeto DropNullFields.

  Especifica una transformación que elimina columnas del conjunto de datos si todos los valores de la columna son “nulos”. De forma predeterminada, AWS Glue Studio reconocerá los objetos nulos, pero algunos valores, como las cadenas vacías, las cadenas que son “nulas”, los enteros -1 u otros marcadores de posición, como los ceros, no se reconocen de manera automática como nulos.

- `Merge`: un objeto Merge.

  Especifica una transformación que fusiona un `DynamicFrame` con una instancia provisional de `DynamicFrame` en función de las claves principales especificadas para identificar registros. Los registros duplicados (registros con las mismas claves principales) no se eliminan.

- `Union`: un objeto Unión.

  Especifica una transformación que combina las filas de dos o más conjuntos de datos en un único resultado.

- `PIIDetection`: un objeto PIIDetection.

  Especifica una transformación que identifica, elimina o enmascara datos PII.

- `Aggregate`: un objeto Agregado.

  Especifica una transformación que agrupa las filas según los campos elegidos y calcula el valor agregado mediante una función especificada.

- `DropDuplicates`: un objeto DropDuplicates.

  Especifica una transformación que elimina las filas de datos repetidos de un conjunto de datos.

- `GovernedCatalogTarget`: un objeto GovernedCatalogTarget.

  Especifica un destino de datos que escribe en un catálogo gobernado.

- `GovernedCatalogSource`: un objeto GovernedCatalogSource.

  Especifica un origen de datos en un Data Catalog gobernado.

- `MicrosoftSQLServerCatalogSource`: un objeto MicrosoftSQLServerCatalogSource.

  Especifica un origen de datos de Microsoft SQL server en AWS Glue Data Catalog.

- `MySQLCatalogSource`: un objeto MySQLCatalogSource.

Especifica un origen de datos de MySQL en AWS Glue Data Catalog.

- `OracleSQLCatalogSource`: un objeto OracleSQLCatalogSource.

  Especifica un origen de datos de Oracle en AWS Glue Data Catalog.

- `PostgreSQLCatalogSource`: un objeto PostgreSQLCatalogSource.

  Especifica un origen de datos de PostgreSQL en AWS Glue Data Catalog.

- `MicrosoftSQLServerCatalogTarget`: un objeto MicrosoftSQLServerCatalogTarget.

  Especifica un destino que utiliza Microsoft SQL.

- `MySQLCatalogTarget`: un objeto MySQLCatalogTarget.

  Especifica un destino que utiliza MySQL.

- `OracleSQLCatalogTarget`: un objeto OracleSQLCatalogTarget.

  Especifica un destino que utiliza Oracle SQL.

- `PostgreSQLCatalogTarget`: un objeto PostgreSQLCatalogTarget.

  Especifica un destino que utiliza PostgreSQL.

- `Route`: un objeto Ruta.

  Especifica un nodo de ruta que dirige los datos a diferentes rutas de salida en función de las condiciones de filtrado definidas.

- `DynamicTransform`: un objeto DynamicTransform.

  Especifica una transformación visual personalizada que haya creado un usuario.

- `EvaluateDataQuality`: un objeto EvaluateDataQuality.

  Especifica los criterios de evaluación de la calidad de los datos.

- `S3CatalogHudiSource`: un objeto S3CatalogHudiSource.

  Especifica un origen de datos de Hudi que está registrado en el Catálogo de datos de AWS Glue. El origen de datos debe almacenarse en Amazon S3.

- `CatalogHudiSource`: un objeto CatalogHudiSource.

  Especifica un origen de datos de Hudi que está registrado en el Catálogo de datos de AWS Glue.

- `S3HudiSource`: un objeto S3HudiSource.

Especifica un origen de datos de Hudi almacenado en Amazon S3.

- `S3HudiCatalogTarget`: un objeto S3HudiCatalogTarget.

  Especifica un destino que escribe en un origen de datos de Hudi en el Catálogo de datos de AWS Glue.

- `S3HudiDirectTarget`: un objeto S3HudiDirectTarget.

  Especifica un destino que escribe en un origen de datos de Hudi en Amazon S3.

- `S3CatalogDeltaSource`: un objeto S3CatalogDeltaSource.

  Especifica un origen de datos de Delta Lake que está registrado en el Catálogo de datos de AWS Glue. El origen de datos debe almacenarse en Amazon S3.

- `CatalogDeltaSource`: un objeto CatalogDeltaSource.

  Especifica un origen de datos de Delta Lake que está registrado en el Catálogo de datos de AWS Glue.

- `S3DeltaSource`: un objeto S3DeltaSource.

  Especifica un origen de datos de Delta Lake almacenado en Amazon S3.

- `S3DeltaCatalogTarget`: un objeto S3DeltaCatalogTarget.

  Especifica un destino que escribe en un origen de datos de Delta Lake en el Catálogo de datos de AWS Glue.

- `S3DeltaDirectTarget`: un objeto S3DeltaDirectTarget.

  Especifica un destino que escribe en un origen de datos de Delta Lake en el Amazon S3.

- `AmazonRedshiftSource`: un objeto AmazonRedshiftSource.

  Especifica un destino que escribe en un origen de datos en Amazon Redshift.

- `AmazonRedshiftTarget`: un objeto AmazonRedshiftTarget.

  Especifica un destino que escribe en un destino de datos en Amazon Redshift.

- `EvaluateDataQualityMultiFrame`: un objeto EvaluateDataQualityMultiFrame.

  Especifica los criterios de evaluación de la calidad de los datos. Permite múltiples datos de entrada y devuelve una colección de marcos dinámicos.

- `Recipe`: un objeto Recipe.

Especifica un nodo de receta de AWS Glue DataBrew.

- `SnowflakeSource`: un objeto SnowflakeSource.

  Especifica un origen de datos de Snowflake.

- `SnowflakeTarget`: un objeto SnowflakeTarget.

  Especifica un destino que escribe en un origen de datos de Snowflake.

- `ConnectorDataSource`: un objeto ConnectorDataSource.

  Especifica una fuente generada con opciones de conexión estándar.

- `ConnectorDataTarget`: un objeto ConnectorDataTarget.

  Especifica un destino generado con opciones de conexión estándar.

- `S3CatalogIcebergSource`: un objeto S3CatalogIcebergSource.

  Especifica un origen de datos de Apache Iceberg que está registrado en el Catálogo de datos de AWS Glue. El origen de datos de Iceberg debe almacenarse en Amazon S3.

- `CatalogIcebergSource`: un objeto CatalogIcebergSource.

  Especifica un origen de datos de Apache Iceberg que está registrado en el Catálogo de datos de AWS Glue.

- `S3IcebergCatalogTarget`: un objeto S3IcebergCatalogTarget.

  Especifica un destino del catálogo de Apache Iceberg que escribe datos en Amazon S3 y registra la tabla en el Catálogo de datos de AWS Glue.

- `S3IcebergDirectTarget`: un objeto S3IcebergDirectTarget structure.

  Define los parámetros de configuración para la escritura de datos en Amazon S3 como una tabla Apache Iceberg.

- `S3ExcelSource`: un objeto S3ExcelSource.

  Define los parámetros de configuración para la lectura de archivos de Excel en Amazon S3.

- `S3HyperDirectTarget`: un objeto S3HyperDirectTarget.

  Define los parámetros de configuración para la escritura de datos en Amazon S3 con la optimización HyperDirect.

- `DynamoDBELTConnectorSource`: un objeto DynamoDBELTConnectorSource.

Especifica un origen del conector ELT de DynamoDB para extraer datos de las tablas de DynamoDB.

Estructura JDBCConnectorOptions

Opciones de conexión adicionales para el conector.

Campos

- `FilterPredicate` – cadena UTF-8 que coincide con el Custom string pattern #61.

  Cláusula de condición adicional para filtrar datos desde el origen. Por ejemplo:

  ```
  BillingCity='Mountain View'
  ```

  Cuando se utiliza una consulta en lugar de una tabla, se debe validar que la consulta funciona con el especificado `filterPredicate`.
- `PartitionColumn` – cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de una columna entera que se utiliza para particionar. Esta opción solo funciona cuando está incluida con `lowerBound`, `upperBound` y `numPartitions`. Esta opción funciona de la misma manera que en el lector JDBC de Spark SQL.
- `LowerBound`: número (largo), cero como máximo.

  El valor mínimo de `partitionColumn` que se utiliza para decidir el intervalo de partición.
- `UpperBound`: número (largo), cero como máximo.

  El valor máximo de `partitionColumn` que se utiliza para decidir el intervalo de partición.
- `NumPartitions`: número (largo), cero como máximo.

  El número de particiones. Este valor, junto con `lowerBound` (inclusive) y `upperBound` (exclusivo), forma intervalos de partición para expresiones de la cláusula `WHERE` generadas, que se utilizan para dividir la `partitionColumn`.
- `JobBookmarkKeys`: matriz de cadenas UTF-8.

  El nombre de las claves favoritas de trabajo en las que se ordenará.
- `JobBookmarkKeysSortOrder` – cadena UTF-8 que coincide con el Custom string pattern #61.

Especifica el orden de clasificación ascendente o descendente.

- `DataTypeMapping`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 (valores válidos: `ARRAY` | `BIGINT` | `BINARY` | `BIT` | `BLOB` | `BOOLEAN` | `CHAR` | `CLOB` | `DATALINK` | `DATE` | `DECIMAL` | `DISTINCT` | `DOUBLE` | `FLOAT` | `INTEGER` | `JAVA_OBJECT` | `LONGNVARCHAR` | `LONGVARBINARY` | `LONGVARCHAR` | `NCHAR` | `NCLOB` | `NULL` | `NUMERIC` | `NVARCHAR` | `OTHER` | `REAL` | `REF` | `REF_CURSOR` | `ROWID` | `SMALLINT` | `SQLXML` | `STRUCT` | `TIME` | `TIME_WITH_TIMEZONE` | `TIMESTAMP` | `TIMESTAMP_WITH_TIMEZONE` | `TINYINT` | `VARBINARY` | `VARCHAR`).

  Cada valor es una cadena UTF-8 (valores válidos: `DATE` | `STRING` | `TIMESTAMP` | `INT` | `FLOAT` | `LONG` | `BIGDECIMAL` | `BYTE` | `SHORT` | `DOUBLE`).

  Asignación de tipos de datos personalizada, que crea una asignación a partir de un tipo de datos JDBC a un tipo de datos de AWS Glue. Por ejemplo, la opción `"dataTypeMapping":{"FLOAT":"STRING"}` asigna campos de datos de tipo JDBC `FLOAT` al tipo Java `String` al invocar el método `ResultSet.getString()` del controlador y lo utiliza para crear registros de AWS Glue. Cada controlador implementa el objeto `ResultSet`, por lo que el comportamiento es específico del controlador que se utiliza. Consulte la documentación del controlador JDBC para comprender cómo el controlador realiza las conversiones.

Estructura StreamingDataPreviewOptions

Especifica las opciones relacionadas con la versión preliminar de datos para ver una muestra de los datos.

Campos

- `PollingTime`: número (largo), como mínimo 10.

  El tiempo de sondeo en milisegundos.

- `RecordPollingLimit`: número (largo), como mínimo 1.

  El límite del número de registros sondeados.

Estructura AthenaConnectorSource

Especifica un conector a un origen de datos de Amazon Athena.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del origen de datos.
- `ConnectionName`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la conexión asociada al conector.
- `ConnectorName`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de un conector que ayuda a acceder al almacén de datos en AWS Glue Studio.
- `ConnectionType`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El tipo de conexión, como marketplace.athena o custom.athena, que designa una conexión a un almacén de datos de Amazon Athena.
- `ConnectionTable` – cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la tabla en el origen de datos.
- `SchemaName`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre del grupo de registro de CloudWatch de lectura. Por ejemplo, `/aws-glue/jobs/output`.
- `OutputSchemas`: matriz de objetos GlueSchema.

  Especifica el esquema de datos del origen de Athena personalizado.

Estructura JDBCConnectorSource

Especifica un conector a un origen de datos JDBC.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del origen de datos.

- `ConnectionName`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la conexión asociada al conector.
- `ConnectorName`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de un conector que ayuda a acceder al almacén de datos en AWS Glue Studio.
- `ConnectionType`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El tipo de conexión, como marketplace.jdbc o custom.jdbc, que designa una conexión a un almacén de datos JDBC.
- `AdditionalOptions`: un objeto JDBCConnectorOptions.

  Opciones de conexión adicionales para el conector.
- `ConnectionTable` – cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la tabla en el origen de datos.
- `Query` – cadena UTF-8 que coincide con el Custom string pattern #62.

  La tabla o consulta SQL de la que se obtienen los datos. Puede especificar `ConnectionTable` o `query`, pero no ambos.
- `OutputSchemas`: matriz de objetos GlueSchema.

  Especifica el esquema de datos del origen de JDBC personalizado.

Estructura SparkConnectorSource

Especifica un conector a un origen de datos de Apache Spark.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del origen de datos.
- `ConnectionName`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la conexión asociada al conector.
- `ConnectorName`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de un conector que ayuda a acceder al almacén de datos en AWS Glue Studio.

- `ConnectionType`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El tipo de conexión, como marketplace.spark o custom.spark, que designa una conexión a un almacén de datos de Apache Spark.
- `AdditionalOptions`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 que coincide con el Custom string pattern #61.

  Cada valor es una cadena UTF-8 que coincide con el Custom string pattern #61.

  Opciones de conexión adicionales para el conector.
- `OutputSchemas`: matriz de objetos GlueSchema.

  Especifica el esquema de datos del origen de spark personalizado.

Estructura CatalogSource

Especifica un almacén de datos en AWS Glue Data Catalog.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del almacén de datos.
- `Database`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la base de datos de lectura.
- `Table`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la tabla en la base de datos de lectura.
- `PartitionPredicate` – cadena UTF-8 que coincide con el Custom string pattern #61.

  Se eliminan las particiones que cumplen con este predicado. Los archivos comprendidos en el período de retención de estas particiones no se eliminan.
- `OutputSchemas`: matriz de objetos GlueSchema.

  Especifica el esquema de datos para el origen del catálogo.

Estructura MySQLCatalogSource

Especifica un origen de datos de MySQL en AWS Glue Data Catalog.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del origen de datos.
- `Database`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la base de datos de lectura.
- `Table`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la tabla en la base de datos de lectura.

Estructura PostgreSQLCatalogSource

Especifica un origen de datos de PostgreSQL en AWS Glue Data Catalog.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del origen de datos.
- `Database`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la base de datos de lectura.
- `Table`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la tabla en la base de datos de lectura.

Estructura OracleSQLCatalogSource

Especifica un origen de datos de Oracle en AWS Glue Data Catalog.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

El nombre del origen de datos.

- `Database`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la base de datos de lectura.

- `Table`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la tabla en la base de datos de lectura.

Estructura MicrosoftSQLServerCatalog

Especifica un origen de datos de Microsoft SQL server en AWS Glue Data Catalog.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del origen de datos.

- `Database`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la base de datos de lectura.

- `Table`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la tabla en la base de datos de lectura.

Estructura CatalogKinesisSource

Especifica un origen de datos de Kinesis en AWS Glue Data Catalog.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del origen de datos.

- `WindowSize`: número (entero), cero como máximo.

  La cantidad de tiempo que se debe dedicar al procesamiento de cada microlote.

- `DetectSchema`: booleano.

Si se debe determinar automáticamente el esquema a partir de los datos entrantes.

- `Table`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la tabla en la base de datos de lectura.

- `Database`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la base de datos de lectura.

- `StreamingOptions`: un objeto KinesisStreamingSourceOptions.

  Opciones adicionales para el origen de datos de streaming de Kinesis.

- `DataPreviewOptions`: un objeto StreamingDataPreviewOptions.

  Opciones adicionales para la versión preliminar de datos.

Estructura DirectKinesisSource

Especifica un origen de datos directo de Amazon Kinesis.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del origen de datos.

- `WindowSize`: número (entero), cero como máximo.

  La cantidad de tiempo que se debe dedicar al procesamiento de cada microlote.

- `DetectSchema`: booleano.

  Si se debe determinar automáticamente el esquema a partir de los datos entrantes.

- `StreamingOptions`: un objeto KinesisStreamingSourceOptions.

  Opciones adicionales para el origen de datos de streaming de Kinesis.

- `DataPreviewOptions`: un objeto StreamingDataPreviewOptions.

  Opciones adicionales para la versión preliminar de datos.

Estructura KinesisStreamingSourceOptions

Opciones adicionales para el origen de datos de streaming de Amazon Kinesis.

Campos

- `EndpointUrl` – cadena UTF-8 que coincide con el Custom string pattern #61.

  La URL del punto de conexión de Kinesis.
- `StreamName` – cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre del flujo de datos de Kinesis.
- `Classification` – cadena UTF-8 que coincide con el Custom string pattern #61.

  Una clasificación opcional.
- `Delimiter` – cadena UTF-8 que coincide con el Custom string pattern #61.

  Especifica el carácter delimitador.
- `StartingPosition` – Cadena UTF-8 (valores válidos: `latest="LATEST"` | `trim_horizon="TRIM_HORIZON"` | `earliest="EARLIEST"` | `timestamp="TIMESTAMP"`).

  La posición inicial en el flujo de datos de Kinesis para leer los datos. Los valores posibles son `"latest"`, `"trim_horizon"`, `"earliest"` o una cadena de marca de tiempo en formato UTC en el patrón `yyyy-mm-ddTHH:MM:SSZ` (donde `Z` representa un desplazamiento de zona horaria UTC con un +/-. Por ejemplo, “04-04-2023 T 08:00:00-04:00”). El valor predeterminado es `"latest"`.

  Nota: El uso de un valor que sea una cadena de marca de tiempo en formato UTC para “startingPosition” solo se admite en la versión 4.0 de AWS Glue o posterior.
- `MaxFetchTimeInMs`: número (largo), cero como máximo.

  El tiempo máximo que le tomó al ejecutor del trabajo leer los registros del lote actual en el flujo de datos de Kinesis, especificado en milisegundos (ms). Pueden realizarse varias llamadas a la API de `GetRecords` durante este tiempo. El valor predeterminado es `1000`.
- `MaxFetchRecordsPerShard`: número (largo), cero como máximo.

  El número máximo de registros que se recuperará por partición en el flujo de datos de Kinesis por microlote. Nota: El cliente puede exceder este límite si el trabajo de streaming ya leyó registros adicionales de Kinesis (en la misma llamada de obtención de registros). Si

`MaxFetchRecordsPerShard` tiene que ser preciso, entonces tiene que ser un múltiplo de `MaxRecordPerRead`. El valor predeterminado es `100000`.

- `MaxRecordPerRead`: número (largo), cero como máximo.

  El número máximo de registros que se recuperará del flujo de datos de Kinesis en cada operación getRecords. El valor predeterminado es `10000`.

- `AddIdleTimeBetweenReads`: booleano.

  Agrega un retardo de tiempo entre dos operaciones getRecords consecutivas. El valor predeterminado es `"False"`. Esta opción sólo se puede configurar para AWS Glue versión 2.0 y superior.

- `IdleTimeBetweenReadsInMs`: número (largo), cero como máximo.

  El retardo de tiempo mínimo entre dos operaciones getRecords consecutivas, especificado en ms. El valor predeterminado es `1000`. Esta opción sólo se puede configurar para AWS Glue versión 2.0 y superior.

- `DescribeShardInterval`: número (largo), cero como máximo.

  El intervalo mínimo de tiempo entre dos llamadas a la API ListShards para que su script considere cambios en las particiones. El valor predeterminado es `1s`.

- `NumRetries`: número (entero), cero como máximo.

  El número máximo de reintentos para las solicitudes de la API de Kinesis Data Streams. El valor predeterminado es `3`.

- `RetryIntervalMs`: número (largo), cero como máximo.

  El periodo de enfriamiento (especificado en ms) antes de volver a intentar la llamada a la API de Kinesis Data Streams. El valor predeterminado es `1000`.

- `MaxRetryIntervalMs`: número (largo), cero como máximo.

  El periodo de enfriamiento máximo (especificado en ms) entre dos intentos de llamada a la API de Kinesis Data Streams. El valor predeterminado es `10000`.

- `AvoidEmptyBatches`: booleano.

  Evita crear un trabajo de microlotes vacío al comprobar si hay datos no leídos en el flujo de datos de Kinesis antes de que se inicie el lote. El valor predeterminado es `"False"`.

- `StreamArn` – cadena UTF-8 que coincide con el Custom string pattern #61.

El nombre de recurso de Amazon (ARN) del flujo de datos de Kinesis.

- `RoleArn` – cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de recurso de Amazon (ARN) del rol que se va a asumir mediante AWS Security Token Service (AWS STS). Este rol debe tener permisos para describir o leer operaciones de registros del flujo de datos de Kinesis. Debe utilizar este parámetro para acceder a un flujo de datos de otra cuenta. Se utiliza junto con `"awsSTSSessionName"`.

- `RoleSessionName` – cadena UTF-8 que coincide con el Custom string pattern #61.

  Un identificador para la sesión que asume el rol mediante AWS STS. Debe utilizar este parámetro para acceder a un flujo de datos de otra cuenta. Se utiliza junto con `"awsSTSRoleARN"`.

- `AddRecordTimestamp` – cadena UTF-8 que coincide con el Custom string pattern #61.

  Cuando esta opción se establece en “true”, la salida de datos contendrá una columna adicional denominada “__src_timestamp” que indica la hora en la que el flujo recibió el registro correspondiente. El valor predeterminado es “false”. Esta opción es compatible con la versión 4.0 o posterior de AWS Glue.

- `EmitConsumerLagMetrics` – cadena UTF-8 que coincide con el Custom string pattern #61.

  Cuando esta opción se establece en “verdadera”, para cada lote, emitirá las métricas correspondientes al período comprendido entre el registro más antiguo recibido por el flujo y el momento en que llegue a AWS Glue en CloudWatch. El nombre de la métrica es “glue.driver.streaming.maxConsumerLagInMs”. El valor predeterminado es “false”. Esta opción es compatible con la versión 4.0 o posterior de AWS Glue.

- `StartingTimestamp`: cadena UTF-8.

  La marca de tiempo del registro del flujo de datos de Kinesis desde la que empezar a leer los datos. Los valores posibles son una cadena de marca de tiempo en formato UTC en el patrón `yyyy-mm-ddTHH:MM:SSZ` (donde Z representa un desplazamiento de zona horaria UTC con un +/-. Por ejemplo, “2023-04-04T08:00:00+08:00”).

- `FanoutConsumerARN` – cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de recurso de Amazon (ARN) del consumidor con distribución ramificada mejorada del flujo de datos de Kinesis. Cuando se especifica, permite una distribución ramificada mejorada para obtener un rendimiento dedicado y reducir la latencia en el consumo de datos.

Estructura CatalogKafkaSource

Especifica un almacén de datos de Apache Kafka en Data Catalog.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del almacén de datos.
- `WindowSize`: número (entero), cero como máximo.

  La cantidad de tiempo que se debe dedicar al procesamiento de cada microlote.
- `DetectSchema`: booleano.

  Si se debe determinar automáticamente el esquema a partir de los datos entrantes.
- `Table`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la tabla en la base de datos de lectura.
- `Database`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la base de datos de lectura.
- `StreamingOptions`: un objeto KafkaStreamingSourceOptions.

  Especifica las opciones de streaming.
- `DataPreviewOptions`: un objeto StreamingDataPreviewOptions.

  Especifica las opciones relacionadas con la versión preliminar de datos para ver una muestra de los datos.

Estructura DirectKafkaSource

Especifica un almacén de datos de Apache Kafka.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del almacén de datos.
- `StreamingOptions`: un objeto KafkaStreamingSourceOptions.

Especifica las opciones de streaming.

- `WindowSize`: número (entero), cero como máximo.

  La cantidad de tiempo que se debe dedicar al procesamiento de cada microlote.

- `DetectSchema`: booleano.

  Si se debe determinar automáticamente el esquema a partir de los datos entrantes.

- `DataPreviewOptions`: un objeto StreamingDataPreviewOptions.

  Especifica las opciones relacionadas con la versión preliminar de datos para ver una muestra de los datos.

Estructura KafkaStreamingSourceOptions

Opciones adicionales para streaming.

Campos

- `BootstrapServers` – cadena UTF-8 que coincide con el Custom string pattern #61.

  Una lista de direcciones URL de servidor Bootstrap, por ejemplo, como `b-1.vpc-test-2.o4q88o.c6.kafka.us-east-1.amazonaws.com:9094`. Esta opción debe especificarse en la llamada a la API o definirse en los metadatos de la tabla en el Data Catalog.

- `SecurityProtocol` – cadena UTF-8 que coincide con el Custom string pattern #61.

  El protocolo utilizado para la comunicación con los agentes. Los valores posibles son `"SSL"` o.`"PLAINTEXT"`

- `ConnectionName` – cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la conexión.

- `TopicName` – cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre del tema como se especifica en Apache Kafka. Debe especificar al menos una opción entre `"topicName"`, `"assign"` o `"subscribePattern"`.

- `Assign` – cadena UTF-8 que coincide con el Custom string pattern #61.

  Las `TopicPartitions` específicas que se utilizarán. Debe especificar al menos una opción entre `"topicName"`, `"assign"` o `"subscribePattern"`.

- `SubscribePattern` – cadena UTF-8 que coincide con el Custom string pattern #61.

  Una cadena de expresiones regulares de Java que identifica la lista de temas a la que desea suscribirse. Debe especificar al menos una opción entre `"topicName"`, `"assign"` o `"subscribePattern"`.
- `Classification` – cadena UTF-8 que coincide con el Custom string pattern #61.

  Una clasificación opcional.
- `Delimiter` – cadena UTF-8 que coincide con el Custom string pattern #61.

  Especifica el carácter delimitador.
- `StartingOffsets` – cadena UTF-8 que coincide con el Custom string pattern #61.

  La posición inicial en el tema de Kafka para leer los datos. Los valores posibles son `"earliest"` o.`"latest"` El valor predeterminado es `"latest"`.
- `EndingOffsets` – cadena UTF-8 que coincide con el Custom string pattern #61.

  El punto de conexión cuando finaliza una consulta por lotes. Los valores posibles son `"latest"` o una cadena JSON que especifica una compensación final para cada `TopicPartition`.
- `PollTimeoutMs`: número (largo), cero como máximo.

  El tiempo de espera en milisegundos para sondear datos de Kafka en ejecutores de trabajos de Spark. El valor predeterminado es `512`.
- `NumRetries`: número (entero), cero como máximo.

  El número de veces que se reintenta antes de no obtener las compensaciones de Kafka. El valor predeterminado es `3`.
- `RetryIntervalMs`: número (largo), cero como máximo.

  El tiempo en milisegundos para esperar antes de volver a intentar obtener compensaciones Kafka. El valor predeterminado es `10`.
- `MaxOffsetsPerTrigger`: número (largo), cero como máximo.

  El límite de velocidad en el número máximo de compensaciones que se procesan por intervalo de desencadenador. El número total de compensaciones especificado se divide de forma proporcional entre `topicPartitions` de diferentes volúmenes. El valor predeterminado es nulo, lo que significa que el consumidor lee todos las compensaciones hasta la última compensación conocida.
- `MinPartitions`: número (entero), cero como máximo.

El número mínimo deseado de particiones para leer desde Kafka. El valor predeterminado es nulo, lo que significa que el número de particiones de Spark es igual al número de particiones de Kafka.

- `IncludeHeaders`: booleano.

  Si se incluyen los encabezados de Kafka. Cuando la opción se establece en “true”, la salida de datos contendrá una columna adicional denominada “glue_streaming_kafka_headers” con el tipo `Array[Struct(key: String, value: String)]`. El valor predeterminado es “false”. Esta opción solo se encuentra disponible en la versión 3.0 o posterior de AWS Glue.

- `AddRecordTimestamp` – cadena UTF-8 que coincide con el Custom string pattern #61.

  Cuando esta opción se establece en “true”, la salida de datos contendrá una columna adicional denominada “__src_timestamp” que indica la hora en la que el tema recibió el registro correspondiente. El valor predeterminado es “false”. Esta opción es compatible con la versión 4.0 o posterior de AWS Glue.

- `EmitConsumerLagMetrics` – cadena UTF-8 que coincide con el Custom string pattern #61.

  Cuando esta opción se establece en “verdadera”, para cada lote, emitirá las métricas correspondientes al período comprendido entre el registro más antiguo recibido por el tema y el momento en que llegue a AWS Glue en CloudWatch. El nombre de la métrica es “glue.driver.streaming.maxConsumerLagInMs”. El valor predeterminado es “false”. Esta opción es compatible con la versión 4.0 o posterior de AWS Glue.

- `StartingTimestamp`: cadena UTF-8.

  La marca de tiempo del registro en el tema de Kafka desde el que empezar a leer los datos. Los valores posibles son una cadena de marca de tiempo en formato UTC en el patrón `yyyy-mm-ddTHH:MM:SSZ` (donde Z representa un desplazamiento de zona horaria UTC con un +/-. Por ejemplo, “2023-04-04T08:00:00+08:00”).

  Solo se debe configurar una de `StartingTimestamp` o `StartingOffsets`.

Estructura RedshiftSource

Especifica un almacén de datos de Amazon Redshift.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

El nombre del almacén de datos de Amazon Redshift.

- `Database`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  La base de datos de lectura.

- `Table`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  La tabla de base de datos de lectura.

- `RedshiftTmpDir` – cadena UTF-8 que coincide con el Custom string pattern #61.

  La ruta de Amazon S3 donde se pueden almacenar datos temporales al copiar desde la base de datos.

- `TmpDirIAMRole` – cadena UTF-8 que coincide con el Custom string pattern #61.

  El rol de IAM con permisos.

Estructura de AmazonRedshiftSource

Especifica el origen de Amazon Redshift.

Campos

- `Name` – cadena UTF-8 que coincide con el Custom string pattern #63.

  Nombre del origen de Amazon Redshift.

- `Data`: un objeto AmazonRedshiftNodeData.

  Especifica los datos del nodo de origen de Amazon Redshift.

Estructura de AmazonRedshiftNodeData

Especifica un nodo de Amazon Redshift.

Campos

- `AccessType` – cadena UTF-8 que coincide con el Custom string pattern #60.

  El tipo de acceso para la conexión de Redshift. Puede ser una conexión directa o una conexión de catálogo.

- `SourceType` – cadena UTF-8 que coincide con el Custom string pattern #60.

  El tipo de origen para especificar si una tabla específica es el origen o una consulta personalizada.
- `Connection`: un objeto Opción.

  La conexión de AWS Glue al clúster de Redshift.
- `Schema`: un objeto Opción.

  El nombre del esquema de Redshift cuando se trabaja con una conexión directa.
- `Table`: un objeto Opción.

  El nombre de la tabla de Redshift cuando se trabaja con una conexión directa.
- `CatalogDatabase`: un objeto Opción.

  El nombre de la base de datos del Catálogo de datos de AWS Glue cuando se trabaja con un catálogo de datos.
- `CatalogTable`: un objeto Opción.

  El nombre de la tabla del Catálogo de datos de AWS Glue cuando se trabaja con un catálogo de datos.
- `CatalogRedshiftSchema`: cadena UTF-8.

  El nombre del esquema de Redshift cuando se trabaja con un catálogo de datos.
- `CatalogRedshiftTable`: cadena UTF-8.

  La tabla de base de datos de lectura.
- `TempDir` – cadena UTF-8 que coincide con el Custom string pattern #61.

  La ruta de Amazon S3 donde se pueden almacenar datos temporales al copiar desde la base de datos.
- `IamRole`: un objeto Opción.

  Opcional. El nombre del rol que se utiliza al conectarse a S3. El rol de IAM será la función del trabajo de forma predeterminada si se deja en blanco.
- `AdvancedOptions`: matriz de objetos AmazonRedshiftAdvancedOption.

  Valores opcionales al conectarse al clúster de Redshift.
- `SampleQuery`: cadena UTF-8.

El SQL que se utiliza para obtener los datos de un origen de Redshift cuando SourceType es “consulta”.

- `PreAction`: cadena UTF-8.

  El SQL utilizado antes de ejecutar un comando MERGE o APPEND con upsert.

- `PostAction`: cadena UTF-8.

  El SQL utilizado antes de ejecutar un comando MERGE o APPEND con upsert.

- `Action`: cadena UTF-8.

  Especifica cómo se escribirá en un clúster de Redshift.

- `TablePrefix` – cadena UTF-8 que coincide con el Custom string pattern #60.

  Especifica el prefijo a una tabla.

- `Upsert`: booleano.

  La acción utilizada en Redshift se hunde al realizar un APPEND.

- `MergeAction` – cadena UTF-8 que coincide con el Custom string pattern #60.

  La acción que se utiliza para determinar cómo se gestionará un MERGE en un receptor de Redshift.

- `MergeWhenMatched` – cadena UTF-8 que coincide con el Custom string pattern #60.

  La acción que se utiliza para determinar cómo se gestionará un MERGE en un receptor de Redshift cuando un registro existente coincida con un registro nuevo.

- `MergeWhenNotMatched` – cadena UTF-8 que coincide con el Custom string pattern #60.

  La acción que se utiliza para determinar cómo se gestionará un MERGE en un receptor de Redshift cuando un registro existente no coincida con un registro nuevo.

- `MergeClause`: cadena UTF-8.

  El SQL utilizado en una combinación personalizada para tratar los registros coincidentes.

- `CrawlerConnection`: cadena UTF-8.

  Especifica el nombre de la conexión asociada con la tabla de catálogo utilizada.

- `TableSchema`: matriz de objetos Opción.

La matriz de salida del esquema para un nodo determinado.

- `StagingTable`: cadena UTF-8.

  El nombre de la tabla provisional temporal que se utiliza al realizar MERGE o APPEND con upsert.

- `SelectedColumns`: matriz de objetos Opción.

  La lista de nombres de columnas que se utiliza para determinar un registro coincidente al realizar un MERGE o APPEND con upsert.

Estructura de AmazonRedshiftAdvancedOption

Especifica un valor opcional al conectarse al clúster de Redshift.

Campos

- `Key`: cadena UTF-8.

  La clave de la opción de conexión adicional.

- `Value`: cadena UTF-8.

  El valor de la opción de conexión adicional.

Estructura de opción

Especifica un valor de opción.

Campos

- `Value` – cadena UTF-8 que coincide con el Custom string pattern #61.

  Especifica el valor de la opción.

- `Label` – cadena UTF-8 que coincide con el Custom string pattern #61.

  Especifica la etiqueta de la opción.

- `Description` – cadena UTF-8 que coincide con el Custom string pattern #61.

  Especifica la descripción de la opción.

Estructura S3CatalogSource

Especifica un almacén de datos de Amazon S3 en AWS Glue Data Catalog.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del almacén de datos.

- `Database`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  La base de datos de lectura.

- `Table`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  La tabla de base de datos de lectura.

- `PartitionPredicate` – cadena UTF-8 que coincide con el Custom string pattern #61.

  Se eliminan las particiones que cumplen con este predicado. Los archivos comprendidos en el período de retención de estas particiones no se eliminan. Configurar en `""`, valor vacío de forma predeterminada.

- `AdditionalOptions`: un objeto S3SourceAdditionalOptions.

  Especifica opciones de conexión adicionales.

Estructura S3SourceAdditionalOptions

Especifica opciones de conexión adicionales para el almacén de datos de Amazon S3.

Campos

- `BoundedSize`: número (largo).

  Establece el límite superior del tamaño objetivo del conjunto de datos en bytes que se procesará.

- `BoundedFiles`: número (largo).

  Establece el límite superior del número objetivo de archivos que se procesarán.

Estructura S3CsvSource

Especifica un almacén de datos de valores separados por comas (CSV) almacenado en Amazon S3.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del almacén de datos.
- `Paths`: obligatorio: una matriz de cadenas UTF-8.

  Una lista de las rutas de Amazon S3 desde las que se leerá.
- `CompressionType` – cadena UTF-8 (valores válidos: `gzip="GZIP"` | `bzip2="BZIP2"`).

  Especifica la forma en que los datos se comprimen. Po lo general no es necesario si los datos tienen una extensión de archivo estándar. Los posibles valores son `"gzip"` y `"bzip"`).
- `Exclusions`: matriz de cadenas UTF-8.

  Una cadena que contiene una lista JSON de patrones glob de estilo Unix para excluir. Por ejemplo, “[\“**.pdf \”]” excluye todos los archivos PDF.
- `GroupSize` – cadena UTF-8 que coincide con el Custom string pattern #61.

  El tamaño del grupo de destino en bytes. El valor predeterminado se calcula en función del tamaño de los datos de entrada y el tamaño de su clúster. Cuando hay menos de 50 000 archivos de entrada, `"groupFiles"` debe establecerse en `"inPartition"` para que este valor surta efecto.
- `GroupFiles` – cadena UTF-8 que coincide con el Custom string pattern #61.

  La agrupación de archivos se habilita de forma predeterminada cuando la entrada contiene más de 50 000 archivos. Para habilitar las agrupaciones con menos de 50 000 archivos, establezca este parámetro en “inPartition”. Para deshabilitar las agrupaciones con más de 50 000 archivos, establezca este parámetro en `"none"`.
- `Recurse`: booleano.

  Si se establece en verdadero, lee recursivamente archivos en todos los subdirectorios de las rutas especificadas.
- `MaxBand`: número (entero), cero como máximo.

  Esta opción controla la duración en milisegundos después de la que es probable que el listado de s3 sea coherente. Se realiza un seguimiento de los archivos cuyas marcas de tiempo de

modificación estén comprendidas en los últimos milisegundos de maxBand, en especial cuando se utilizan JobBookmarks para obtener coherencia final de Amazon S3. La mayoría de los usuarios no tienen que establecer esta opción. El valor predeterminado es 900 000 milisegundos, o 15 minutos.

- `MaxFilesInBand`: número (entero), cero como máximo.

  Esta opción especifica el número máximo de archivos que deben guardarse desde los últimos segundos de maxBand. Si se supera este número, los archivos adicionales se omiten y solo se procesarán en la siguiente ejecución del flujo de trabajo.

- `AdditionalOptions`: un objeto S3DirectSourceAdditionalOptions.

  Especifica opciones de conexión adicionales.

- `Separator`: obligatorio: cadena de UTF-8 (valores válidos: `comma="COMMA"` | `ctrla="CTRLA"` | `pipe="PIPE"` | `semicolon="SEMICOLON"` | `tab="TAB"`).

  Especifica el carácter delimitador. El valor predeterminado es una coma: “,”; pero puede especificarse cualquier otro carácter.

- `Escaper` – cadena UTF-8 que coincide con el Custom string pattern #61.

  Especifica un carácter que se usar para aplicar escape. Esta opción solo se usa cuando se leen archivos CSV. El valor predeterminado es `none`. Si se habilita, el carácter que va inmediatamente después se usa tal cual, excepto un pequeño conjunto de escapes conocidos (`\n`, `\r`, `\t` y `\0`).

- `QuoteChar`: obligatorio: cadena UTF-8 (valores válidos: `quote="QUOTE"` | `quillemet="QUILLEMET"` | `single_quote="SINGLE_QUOTE"` | `disabled="DISABLED"`).

  Especifica el carácter que se usar para aplicar comillas. El carácter predeterminado es una comilla doble: `'"'`. Establezca esta opción en `-1` para desactivar las comillas por completo.

- `Multiline`: booleano.

  Un valor booleano que especifica si un solo registro puede abarcar varias líneas. Esto puede suceder cuando un campo contiene un carácter de nueva línea entre comillas. Debe configurar esta opción en verdadero si un registro abarca varias líneas. El valor predeterminado es `False`, que permite una división de archivo más dinámica durante el análisis.

- `WithHeader`: booleano.

  Un valor booleano que especifica si la primera línea se debe tratar como un encabezado. El valor predeterminado es `False`.

- `WriteHeader`: booleano.

Un valor booleano que especifica si se debe escribir el encabezado en la salida. El valor predeterminado es `True`.

- `SkipFirst`: booleano.

  Un valor booleano que especifica si se debe omitir la primera línea de datos. El valor predeterminado es `False`.

- `OptimizePerformance`: booleano.

  Un valor booleano que especifica si se debe utilizar el lector CSV SIMD avanzado junto con los formatos de memoria columnar con base en Apache Arrow. Disponible únicamente en la versión 3.0 de AWS Glue.

- `OutputSchemas`: matriz de objetos GlueSchema.

  Especifica el esquema de datos del origen de S3 con formato CSV.

Estructura DirectJDBCSource

Especifica la conexión de origen JDBC directa.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre de la conexión de origen de JDBC.

- `Database`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  La base de datos de la conexión de origen de JDBC.

- `Table`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  La tabla de la conexión de origen de JDBC.

- `ConnectionName`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la conexión del origen de JDBC.

- `ConnectionType`: obligatorio: cadena de UTF-8 (valores válidos: `sqlserver` | `mysql` | `oracle` | `postgresql` | `redshift`).

  El tipo de conexión del origen de JDBC.

- `RedshiftTmpDir` – cadena UTF-8 que coincide con el Custom string pattern #61.

  El directorio temporal del origen de JDBC Redshift.
- `OutputSchemas`: matriz de objetos GlueSchema.

  Especifica el esquema de datos para el origen directo de JDBC.

Estructura S3DirectSourceAdditionalOptions

Especifica opciones de conexión adicionales para el almacén de datos de Amazon S3.

Campos

- `BoundedSize`: número (largo).

  Establece el límite superior del tamaño objetivo del conjunto de datos en bytes que se procesará.
- `BoundedFiles`: número (largo).

  Establece el límite superior del número objetivo de archivos que se procesarán.
- `EnableSamplePath`: booleano.

  Establece la opción para habilitar una ruta de ejemplo.
- `SamplePath` – cadena UTF-8 que coincide con el Custom string pattern #61.

  Si está habilitado, especifica la ruta de ejemplo.

Estructura S3JsonSource

Especifica un almacén de datos JSON almacenado en Amazon S3.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del almacén de datos.
- `Paths`: obligatorio: una matriz de cadenas UTF-8.

  Una lista de las rutas de Amazon S3 desde las que se leerá.
- `CompressionType` – cadena UTF-8 (valores válidos: `gzip="GZIP"` | `bzip2="BZIP2"`).

Especifica la forma en que los datos se comprimen. Po lo general no es necesario si los datos tienen una extensión de archivo estándar. Los posibles valores son `"gzip"` y `"bzip"`).

- `Exclusions`: matriz de cadenas UTF-8.

  Una cadena que contiene una lista JSON de patrones glob de estilo Unix para excluir. Por ejemplo, “[\“**.pdf \”]” excluye todos los archivos PDF.

- `GroupSize` – cadena UTF-8 que coincide con el Custom string pattern #61.

  El tamaño del grupo de destino en bytes. El valor predeterminado se calcula en función del tamaño de los datos de entrada y el tamaño de su clúster. Cuando hay menos de 50 000 archivos de entrada, `"groupFiles"` debe establecerse en `"inPartition"` para que este valor surta efecto.

- `GroupFiles` – cadena UTF-8 que coincide con el Custom string pattern #61.

  La agrupación de archivos se habilita de forma predeterminada cuando la entrada contiene más de 50 000 archivos. Para habilitar las agrupaciones con menos de 50 000 archivos, establezca este parámetro en “inPartition”. Para deshabilitar las agrupaciones con más de 50 000 archivos, establezca este parámetro en `"none"`.

- `Recurse`: booleano.

  Si se establece en verdadero, lee recursivamente archivos en todos los subdirectorios de las rutas especificadas.

- `MaxBand`: número (entero), cero como máximo.

  Esta opción controla la duración en milisegundos después de la que es probable que el listado de s3 sea coherente. Se realiza un seguimiento de los archivos cuyas marcas de tiempo de modificación estén comprendidas en los últimos milisegundos de maxBand, en especial cuando se utilizan JobBookmarks para obtener coherencia final de Amazon S3. La mayoría de los usuarios no tienen que establecer esta opción. El valor predeterminado es 900 000 milisegundos, o 15 minutos.

- `MaxFilesInBand`: número (entero), cero como máximo.

  Esta opción especifica el número máximo de archivos que deben guardarse desde los últimos segundos de maxBand. Si se supera este número, los archivos adicionales se omiten y solo se procesarán en la siguiente ejecución del flujo de trabajo.

- `AdditionalOptions`: un objeto S3DirectSourceAdditionalOptions.

  Especifica opciones de conexión adicionales.

- `JsonPath` – cadena UTF-8 que coincide con el Custom string pattern #61.

  Una cadena JsonPath que define los datos JSON.

- `Multiline`: booleano.

  Un valor booleano que especifica si un solo registro puede abarcar varias líneas. Esto puede suceder cuando un campo contiene un carácter de nueva línea entre comillas. Debe configurar esta opción en verdadero si un registro abarca varias líneas. El valor predeterminado es `False`, que permite una división de archivo más dinámica durante el análisis.

- `OutputSchemas`: matriz de objetos GlueSchema.

  Especifica el esquema de datos del origen de S3 con formato JSON.

Estructura S3ParquetSource

Especifica un almacén de datos de Apache Parquet almacenado en Amazon S3.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del almacén de datos.

- `Paths`: obligatorio: una matriz de cadenas UTF-8.

  Una lista de las rutas de Amazon S3 desde las que se leerá.

- `CompressionType` – cadena UTF-8 (valores válidos: `snappy="SNAPPY"` | `lzo="LZO"` | `gzip="GZIP"` | `brotli="BROTLI"` | `lz4="LZ4"` | `uncompressed="UNCOMPRESSED"` | `none="NONE"`).

  Especifica la forma en que los datos se comprimen. Po lo general no es necesario si los datos tienen una extensión de archivo estándar. Los posibles valores son `"gzip"` y `"bzip"`).

- `Exclusions`: matriz de cadenas UTF-8.

  Una cadena que contiene una lista JSON de patrones glob de estilo Unix para excluir. Por ejemplo, “[\“**.pdf \”]” excluye todos los archivos PDF.

- `GroupSize` – cadena UTF-8 que coincide con el Custom string pattern #61.

El tamaño del grupo de destino en bytes. El valor predeterminado se calcula en función del tamaño de los datos de entrada y el tamaño de su clúster. Cuando hay menos de 50 000 archivos de entrada, `"groupFiles"` debe establecerse en `"inPartition"` para que este valor surta efecto.

- `GroupFiles` – cadena UTF-8 que coincide con el Custom string pattern #61.

  La agrupación de archivos se habilita de forma predeterminada cuando la entrada contiene más de 50 000 archivos. Para habilitar las agrupaciones con menos de 50 000 archivos, establezca este parámetro en “inPartition”. Para deshabilitar las agrupaciones con más de 50 000 archivos, establezca este parámetro en `"none"`.

- `Recurse`: booleano.

  Si se establece en verdadero, lee recursivamente archivos en todos los subdirectorios de las rutas especificadas.

- `MaxBand`: número (entero), cero como máximo.

  Esta opción controla la duración en milisegundos después de la que es probable que el listado de s3 sea coherente. Se realiza un seguimiento de los archivos cuyas marcas de tiempo de modificación estén comprendidas en los últimos milisegundos de maxBand, en especial cuando se utilizan JobBookmarks para obtener coherencia final de Amazon S3. La mayoría de los usuarios no tienen que establecer esta opción. El valor predeterminado es 900 000 milisegundos, o 15 minutos.

- `MaxFilesInBand`: número (entero), cero como máximo.

  Esta opción especifica el número máximo de archivos que deben guardarse desde los últimos segundos de maxBand. Si se supera este número, los archivos adicionales se omiten y solo se procesarán en la siguiente ejecución del flujo de trabajo.

- `AdditionalOptions`: un objeto S3DirectSourceAdditionalOptions.

  Especifica opciones de conexión adicionales.

- `OutputSchemas`: matriz de objetos GlueSchema.

  Especifica el esquema de datos del origen de S3 con formato Parquet.

Estructura de S3DeltaSource

Especifica un origen de datos de Delta Lake almacenado en Amazon S3.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del origen del Delta Lake.
- `Paths`: obligatorio: una matriz de cadenas UTF-8.

  Una lista de las rutas de Amazon S3 desde las que se leerá.
- `AdditionalDeltaOptions`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 que coincide con el Custom string pattern #61.

  Cada valor es una cadena UTF-8 que coincide con el Custom string pattern #61.

  Especifica opciones de conexión adicionales.
- `AdditionalOptions`: un objeto S3DirectSourceAdditionalOptions.

  Especifica las opciones adicionales para el conector.
- `OutputSchemas`: matriz de objetos GlueSchema.

  Especifica el esquema de datos para el origen de Delta Lake.

Estructura de S3CatalogDeltaSource

Especifica un origen de datos de Delta Lake que está registrado en el Catálogo de datos de AWS Glue. El origen de datos debe almacenarse en Amazon S3.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del origen de datos de Delta Lake.
- `Database`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la base de datos de lectura.
- `Table`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la tabla en la base de datos de lectura.
- `AdditionalDeltaOptions`: matriz de mapas de pares clave-valor.

Cada clave es una cadena UTF-8 que coincide con el Custom string pattern #61.

Cada valor es una cadena UTF-8 que coincide con el Custom string pattern #61.

Especifica opciones de conexión adicionales.

- `OutputSchemas`: matriz de objetos GlueSchema.

  Especifica el esquema de datos para el origen de Delta Lake.

Estructura de CatalogDeltaSource

Especifica un origen de datos de Delta Lake que está registrado en el Catálogo de datos de AWS Glue.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del origen de datos de Delta Lake.
- `Database`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la base de datos de lectura.
- `Table`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la tabla en la base de datos de lectura.
- `AdditionalDeltaOptions`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 que coincide con el Custom string pattern #61.

  Cada valor es una cadena UTF-8 que coincide con el Custom string pattern #61.

  Especifica opciones de conexión adicionales.
- `OutputSchemas`: matriz de objetos GlueSchema.

  Especifica el esquema de datos para el origen de Delta Lake.

Estructura S3HudiSource

Especifica un origen de datos de Hudi almacenado en Amazon S3.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del origen de Hudi.
- `Paths`: obligatorio: una matriz de cadenas UTF-8.

  Una lista de las rutas de Amazon S3 desde las que se leerá.
- `AdditionalHudiOptions`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 que coincide con el Custom string pattern #61.

  Cada valor es una cadena UTF-8 que coincide con el Custom string pattern #61.

  Especifica opciones de conexión adicionales.
- `AdditionalOptions`: un objeto S3DirectSourceAdditionalOptions.

  Especifica las opciones adicionales para el conector.
- `OutputSchemas`: matriz de objetos GlueSchema.

  Especifica el esquema de datos para el origen de Hudi.

Estructura S3CatalogHudiSource

Especifica un origen de datos de Hudi que está registrado en el Catálogo de datos de AWS Glue. El origen de datos de Hudi debe almacenarse en Amazon S3.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del origen de datos de Hudi.
- `Database`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la base de datos de lectura.

- `Table`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la tabla en la base de datos de lectura.
- `AdditionalHudiOptions`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 que coincide con el Custom string pattern #61.

  Cada valor es una cadena UTF-8 que coincide con el Custom string pattern #61.

  Especifica opciones de conexión adicionales.
- `OutputSchemas`: matriz de objetos GlueSchema.

  Especifica el esquema de datos para el origen de Hudi.

Estructura S3ExcelSource

Especifica un origen de datos de Excel en S3.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del origen de datos de Excel en S3.
- `Paths`: obligatorio: una matriz de cadenas UTF-8.

  Las rutas de S3 donde se encuentran los archivos de Excel.
- `CompressionType` – Cadena UTF-8 (valores válidos: `snappy="SNAPPY"` | `lzo="LZO"` | `gzip="GZIP"` | `brotli="BROTLI"` | `lz4="LZ4"` | `uncompressed="UNCOMPRESSED"` | `none="NONE"`).

  El formato de compresión utilizado para los archivos de Excel.
- `Exclusions`: matriz de cadenas UTF-8.

  Patrones para excluir archivos o rutas específicos del procesamiento.
- `GroupSize` – cadena UTF-8 que coincide con el Custom string pattern #61.

  Define el tamaño de los grupos de archivos para el procesamiento por lotes.
- `GroupFiles` – cadena UTF-8 que coincide con el Custom string pattern #61.

Especifica la forma en que se agrupan los archivos para su procesamiento.

- `Recurse`: booleano.

  Indica si se deben procesar los subdirectorios de forma recursiva.

- `MaxBand`: número (entero), cero como máximo.

  Cantidad máxima de bandas de procesamiento que se utilizarán.

- `MaxFilesInBand`: número (entero), cero como máximo.

  Cantidad máxima de archivos que se procesarán en cada banda.

- `AdditionalOptions`: un objeto S3DirectSourceAdditionalOptions.

  Opciones de configuración adicionales para el procesamiento directo desde S3 como origen.

- `NumberRows`: número (largo).

  Cantidad de filas a procesar de cada archivo de Excel.

- `SkipFooter`: número (entero), cero como máximo.

  Cantidad de filas que se deben omitir al final de cada archivo de Excel.

- `OutputSchemas`: matriz de objetos GlueSchema.

  Esquemas de AWS Glue que se aplicarán a los datos procesados.

Estructura CatalogHudiSource

Especifica un origen de datos de Hudi que está registrado en el Catálogo de datos de AWS Glue.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del origen de datos de Hudi.

- `Database`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la base de datos de lectura.

- `Table`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la tabla en la base de datos de lectura.

- `AdditionalHudiOptions`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 que coincide con el Custom string pattern #61.

  Cada valor es una cadena UTF-8 que coincide con el Custom string pattern #61.

  Especifica opciones de conexión adicionales.
- `OutputSchemas`: matriz de objetos GlueSchema.

  Especifica el esquema de datos para el origen de Hudi.

Estructura DynamoDBCatalogSource

Especifica un origen de datos de DynamoDB en AWS Glue Data Catalog.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del origen de datos.
- `Database`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la base de datos de lectura.
- `Table`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la tabla en la base de datos de lectura.
- `PitrEnabled`: booleano.

  Especifica si la recuperación en un momento dado (PITR) está habilitada para la tabla de DynamoDB. Cuando se establece en `true`, permite leer desde un momento específico. El valor predeterminado es `false`.
- `AdditionalOptions`: un objeto DDBELTCatalogAdditionalOptions.

  Especifica opciones de conexión adicionales para el origen de datos de DynamoDB.

Estructura RelationalCatalogSource

Especifica un origen de datos de base de datos relacional en AWS Glue Data Catalog.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del origen de datos.
- `Database`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la base de datos de lectura.
- `Table`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la tabla en la base de datos de lectura.

Estructura JDBCConnectorTarget

Especifica un destino de datos que escribe en Amazon S3 en el almacenamiento en columnas de Apache Parquet.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del destino de datos.
- `Inputs`: Obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y una cadena como máximo.

  Los nodos que son entradas para el destino de datos.
- `ConnectionName`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la conexión asociada al conector.
- `ConnectionTable`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la tabla en el destino de datos.
- `ConnectorName`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de un conector que se utilizará.
- `ConnectionType`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El tipo de conexión, como marketplace.jdbc o custom.jdbc, que designa una conexión a un destino de datos JDBC.

- `AdditionalOptions`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 que coincide con el Custom string pattern #61.

  Cada valor es una cadena UTF-8 que coincide con el Custom string pattern #61.

  Opciones de conexión adicionales para el conector.
- `OutputSchemas`: matriz de objetos GlueSchema.

  Especifica el esquema de datos del destino de JDBC.

Estructura SparkConnectorTarget

Especifica un destino que utiliza un conector de Apache Spark.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del destino de datos.
- `Inputs`: Obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y una cadena como máximo.

  Los nodos que son entradas para el destino de datos.
- `ConnectionName`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de una conexión de un conector de Apache Spark.
- `ConnectorName`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de un conector de Apache Spark.
- `ConnectionType`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El tipo de conexión, como marketplace.spark o custom.spark, que designa una conexión a un almacén de datos de Apache Spark.
- `AdditionalOptions`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 que coincide con el Custom string pattern #61.

  Cada valor es una cadena UTF-8 que coincide con el Custom string pattern #61.

Opciones de conexión adicionales para el conector.

- `OutputSchemas`: matriz de objetos GlueSchema.

  Especifica el esquema de datos del destino de spark personalizado.

Estructura BasicCatalogTarget

Especifica un destino que utiliza una tabla de AWS Glue Data Catalog.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del destino de datos.
- `Inputs`: Obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y una cadena como máximo.

  Los nodos que son entradas para el destino de datos.
- `PartitionKeys`: matriz de cadenas UTF-8.

  Las claves de partición que se utilizan para distribuir los datos entre varias particiones o fragmentos en función de una clave o conjunto de claves específicos.
- `Database`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  La base de datos que contiene la tabla que desea utilizar como destino. Esta base de datos ya debe existir en el Catálogo de datos.
- `Table`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  La tabla que define el esquema de los datos de salida. Esta tabla ya debe existir en el Catálogo de datos.

Estructura MySQLCatalogTarget

Especifica un destino que utiliza MySQL.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

El nombre del destino de datos.

- `Inputs`: Obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y una cadena como máximo.

  Los nodos que son entradas para el destino de datos.

- `Database`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la base de datos de escritura.

- `Table`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la tabla de la base de datos de escritura.

Estructura PostgreSQLCatalogSourceTarget

Especifica un destino que utiliza PostgreSQL.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del destino de datos.

- `Inputs`: Obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y una cadena como máximo.

  Los nodos que son entradas para el destino de datos.

- `Database`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la base de datos de escritura.

- `Table`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la tabla de la base de datos de escritura.

Estructura OracleSQLCatalogTarget

Especifica un destino que utiliza Oracle SQL.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del destino de datos.
- `Inputs`: Obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y una cadena como máximo.

  Los nodos que son entradas para el destino de datos.
- `Database`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la base de datos de escritura.
- `Table`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la tabla de la base de datos de escritura.

Estructura MicrosoftSQLServerCatalogTarget

Especifica un destino que utiliza Microsoft SQL.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del destino de datos.
- `Inputs`: Obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y una cadena como máximo.

  Los nodos que son entradas para el destino de datos.
- `Database`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la base de datos de escritura.
- `Table`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la tabla de la base de datos de escritura.

Estructura RedshiftTarget

Especifica un destino que utiliza Amazon Redshift.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del destino de datos.
- `Inputs`: Obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y una cadena como máximo.

  Los nodos que son entradas para el destino de datos.
- `Database`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la base de datos de escritura.
- `Table`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la tabla de la base de datos de escritura.
- `RedshiftTmpDir` – cadena UTF-8 que coincide con el Custom string pattern #61.

  La ruta de Amazon S3 donde se pueden almacenar datos temporales al copiar desde la base de datos.
- `TmpDirIAMRole` – cadena UTF-8 que coincide con el Custom string pattern #61.

  El rol de IAM con permisos.
- `UpsertRedshiftOptions`: un objeto UpsertRedshiftTargetOptions.

  Conjunto de opciones para configurar una operación upsert al escribir en un destino de Redshift.

Estructura de AmazonRedshiftTarget

Especifica un destino de Amazon Redshift.

Campos

- `Name` – cadena UTF-8 que coincide con el Custom string pattern #63.

  Nombre del destino de Amazon Redshift.
- `Data`: un objeto AmazonRedshiftNodeData.

  Especifica los datos del nodo de destino de Amazon Redshift.
- `Inputs`: matriz de cadenas UTF-8, no menos de una cadena o más de una.

Los nodos que son entradas para el destino de datos.

Estructura UpsertRedShiftTargetOptions

Opciones para configurar una operación upsert al escribir en un destino de Redshift.

Campos

- `TableLocation` – cadena UTF-8 que coincide con el Custom string pattern #61.

  Ubicación física de la tabla de Redshift.
- `ConnectionName` – cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la conexión que se utilizará para escribir en Redshift.
- `UpsertKeys`: matriz de cadenas UTF-8.

  Claves utilizadas para determinar si se debe realizar una actualización o una inserción.

Estructura S3CatalogTarget

Especifica un destino de datos que escribe en Amazon S3 mediante AWS Glue Data Catalog.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del destino de datos.
- `Inputs`: Obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y una cadena como máximo.

  Los nodos que son entradas para el destino de datos.
- `PartitionKeys`: matriz de cadenas UTF-8.

  Especifica la partición nativa mediante una secuencia de claves.
- `Table`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la tabla de la base de datos de escritura.
- `Database`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

El nombre de la base de datos de escritura.

- `SchemaChangePolicy`: un objeto CatalogSchemaChangePolicy.

  Una política que especifica los comportamientos de actualización del rastreador.

- `AutoDataQuality`: un objeto AutoDataQuality.

  Especifica si se debe habilitar automáticamente la evaluación de la calidad de los datos para el destino del catálogo de S3. Si se establece en `true`, las comprobaciones de calidad de los datos se realizan automáticamente durante la operación de escritura.

Estructura S3GlueParquetTarget

Especifica un destino de datos que escribe en Amazon S3 en el almacenamiento en columnas de Apache Parquet.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del destino de datos.

- `Inputs`: Obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y una cadena como máximo.

  Los nodos que son entradas para el destino de datos.

- `PartitionKeys`: matriz de cadenas UTF-8.

  Especifica la partición nativa mediante una secuencia de claves.

- `Path`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  Una única ruta de Amazon S3 de escritura.

- `Compression` – cadena UTF-8 (valores válidos: `snappy="SNAPPY"` | `lzo="LZO"` | `gzip="GZIP"` | `brotli="BROTLI"` | `lz4="LZ4"` | `uncompressed="UNCOMPRESSED"` | `none="NONE"`).

  Especifica la forma en que los datos se comprimen. Po lo general no es necesario si los datos tienen una extensión de archivo estándar. Los posibles valores son `"gzip"` y `"bzip"`).

- `NumberTargetPartitions`: cadena UTF-8.

Especifica la cantidad de particiones de destino para los archivos Parquet al escribir en Amazon S3 con AWS Glue.

- `SchemaChangePolicy`: un objeto DirectSchemaChangePolicy.

  Una política que especifica los comportamientos de actualización del rastreador.

- `AutoDataQuality`: un objeto AutoDataQuality.

  Especifica si se debe habilitar automáticamente la evaluación de la calidad de los datos para el destino de Parquet en AWS Glue de S3. Si se establece en `true`, las comprobaciones de calidad de los datos se realizan automáticamente durante la operación de escritura.

Estructura CatalogSchemaChangePolicy

Una política que especifica los comportamientos de actualización del rastreador.

Campos

- `EnableUpdateCatalog`: booleano.

  Si utilizar o no el comportamiento de actualización especificado cuando el rastreador encuentra un esquema cambiado.

- `UpdateBehavior` – Cadena UTF-8 (valores válidos: `UPDATE_IN_DATABASE` | `LOG`).

  Comportamiento de actualización cuando el rastreador encuentra un esquema cambiado.

Estructura S3DirectTarget

Especifica un destino de datos que escribe en Amazon S3.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del destino de datos.

- `Inputs`: Obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y una cadena como máximo.

  Los nodos que son entradas para el destino de datos.

- `PartitionKeys`: matriz de cadenas UTF-8.

  Especifica la partición nativa mediante una secuencia de claves.

- `Path`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  Una única ruta de Amazon S3 de escritura.

- `Compression` – cadena UTF-8 que coincide con el Custom string pattern #61.

  Especifica la forma en que los datos se comprimen. Po lo general no es necesario si los datos tienen una extensión de archivo estándar. Los posibles valores son `"gzip"` y `"bzip"`).

- `NumberTargetPartitions`: cadena UTF-8.

  Especifica la cantidad de particiones de destino al escribir datos directamente en Amazon S3.

- `Format`: Obligatorio: cadena UTF-8 (valores válidos: `json="JSON"` | `csv="CSV"` | `avro="AVRO"` | `orc="ORC"` | `parquet="PARQUET"` | `hudi="HUDI"` | `delta="DELTA"` | `iceberg="ICEBERG"` | `hyper="HYPER"` | `xml="XML"`).

  Especifica el formato de salida de datos para el destino.

- `SchemaChangePolicy`: un objeto DirectSchemaChangePolicy.

  Una política que especifica los comportamientos de actualización del rastreador.

- `AutoDataQuality`: un objeto AutoDataQuality.

  Especifica si se debe habilitar automáticamente la evaluación de la calidad de los datos para el destino directo de S3. Si se establece en `true`, las comprobaciones de calidad de los datos se realizan automáticamente durante la operación de escritura.

- `OutputSchemas`: matriz de objetos GlueSchema.

  Especifica el esquema de datos para el destino directo de S3.

Estructura S3HudiCatalogTarget

Especifica un destino que escribe en un origen de datos de Hudi en el Catálogo de datos de AWS Glue.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

El nombre del destino de datos.

- `Inputs`: Obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y una cadena como máximo.

  Los nodos que son entradas para el destino de datos.

- `PartitionKeys`: matriz de cadenas UTF-8.

  Especifica la partición nativa mediante una secuencia de claves.

- `Table`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la tabla de la base de datos de escritura.

- `Database`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la base de datos de escritura.

- `AdditionalOptions` – Obligatorio: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 que coincide con el Custom string pattern #61.

  Cada valor es una cadena UTF-8 que coincide con el Custom string pattern #61.

  Especifica opciones de conexión adicionales para el conector.

- `SchemaChangePolicy`: un objeto CatalogSchemaChangePolicy.

  Una política que especifica los comportamientos de actualización del rastreador.

- `AutoDataQuality`: un objeto AutoDataQuality.

  Especifica si se debe habilitar automáticamente la evaluación de la calidad de los datos para el destino del catálogo de Hudi de S3. Si se establece en `true`, las comprobaciones de calidad de los datos se realizan automáticamente durante la operación de escritura.

- `OutputSchemas`: matriz de objetos GlueSchema.

  Especifica el esquema de datos para el destino del catálogo de Hudi de S3.

Estructura S3HudiDirectTarget

Especifica un destino que escribe en un origen de datos de Hudi en Amazon S3.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del destino de datos.

- `Inputs`: Obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y una cadena como máximo.

  Los nodos que son entradas para el destino de datos.

- `Path`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  La ruta de Amazon S3 del origen de datos de Hudi en la que desea escribir.

- `Compression`: obligatorio: cadena UTF-8 (valores válidos: `gzip="GZIP"` | `lzo="LZO"` | `uncompressed="UNCOMPRESSED"` | `snappy="SNAPPY"`).

  Especifica la forma en que los datos se comprimen. Po lo general no es necesario si los datos tienen una extensión de archivo estándar. Los posibles valores son `"gzip"` y `"bzip"`).

- `NumberTargetPartitions`: cadena UTF-8.

  Especifica la cantidad de particiones de destino para distribuir los archivos del conjunto de datos Hudi en Amazon S3.

- `PartitionKeys`: matriz de cadenas UTF-8.

  Especifica la partición nativa mediante una secuencia de claves.

- `Format`: Obligatorio: cadena UTF-8 (valores válidos: `json="JSON"` | `csv="CSV"` | `avro="AVRO"` | `orc="ORC"` | `parquet="PARQUET"` | `hudi="HUDI"` | `delta="DELTA"` | `iceberg="ICEBERG"` | `hyper="HYPER"` | `xml="XML"`).

  Especifica el formato de salida de datos para el destino.

- `AdditionalOptions` – Obligatorio: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 que coincide con el Custom string pattern #61.

  Cada valor es una cadena UTF-8 que coincide con el Custom string pattern #61.

  Especifica opciones de conexión adicionales para el conector.

- `SchemaChangePolicy`: un objeto DirectSchemaChangePolicy.

  Una política que especifica los comportamientos de actualización del rastreador.

- `AutoDataQuality`: un objeto AutoDataQuality.

  Especifica si se debe habilitar automáticamente la evaluación de la calidad de los datos para el destino directo de Hudi de S3. Si se establece en `true`, las comprobaciones de calidad de los datos se realizan automáticamente durante la operación de escritura.

Estructura de S3DeltaCatalogTarget

Especifica un destino que escribe en un origen de datos de Delta Lake en el Catálogo de datos de AWS Glue.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del destino de datos.
- `Inputs`: Obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y una cadena como máximo.

  Los nodos que son entradas para el destino de datos.
- `PartitionKeys`: matriz de cadenas UTF-8.

  Especifica la partición nativa mediante una secuencia de claves.
- `Table`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la tabla de la base de datos de escritura.
- `Database`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la base de datos de escritura.
- `AdditionalOptions`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 que coincide con el Custom string pattern #61.

  Cada valor es una cadena UTF-8 que coincide con el Custom string pattern #61.

  Especifica opciones de conexión adicionales para el conector.
- `SchemaChangePolicy`: un objeto CatalogSchemaChangePolicy.

  Una política que especifica los comportamientos de actualización del rastreador.

- `AutoDataQuality`: un objeto AutoDataQuality.

  Especifica si se habilita automáticamente la evaluación de la calidad de los datos para el destino del catálogo de Delta de S3. Si se establece en `true`, las comprobaciones de calidad de los datos se realizan automáticamente durante la operación de escritura.

- `OutputSchemas`: matriz de objetos GlueSchema.

  Especifica el esquema de datos para el destino del catálogo de Delta de S3.

Estructura de S3DeltaDirectTarget

Especifica un destino que escribe en un origen de datos de Delta Lake en el Amazon S3.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del destino de datos.

- `Inputs`: Obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y una cadena como máximo.

  Los nodos que son entradas para el destino de datos.

- `PartitionKeys`: matriz de cadenas UTF-8.

  Especifica la partición nativa mediante una secuencia de claves.

- `Path`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  La ruta de Amazon S3 del origen de datos de Delta Lake en la que desea escribir.

- `Compression`: obligatorio: cadena UTF-8 (valores válidos: `uncompressed="UNCOMPRESSED"` | `snappy="SNAPPY"`).

  Especifica la forma en que los datos se comprimen. Po lo general no es necesario si los datos tienen una extensión de archivo estándar. Los posibles valores son `"gzip"` y `"bzip"`).

- `NumberTargetPartitions`: cadena UTF-8.

  Especifica cuántas particiones de destino se utilizan para distribuir los archivos del conjunto de datos de Delta Lake en Amazon S3.

- `Format`: Obligatorio: cadena UTF-8 (valores válidos: `json="JSON"` | `csv="CSV"` | `avro="AVRO"` | `orc="ORC"` | `parquet="PARQUET"` | `hudi="HUDI"` | `delta="DELTA"` | `iceberg="ICEBERG"` | `hyper="HYPER"` | `xml="XML"`).

  Especifica el formato de salida de datos para el destino.
- `AdditionalOptions`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 que coincide con el Custom string pattern #61.

  Cada valor es una cadena UTF-8 que coincide con el Custom string pattern #61.

  Especifica opciones de conexión adicionales para el conector.
- `SchemaChangePolicy`: un objeto DirectSchemaChangePolicy.

  Una política que especifica los comportamientos de actualización del rastreador.
- `AutoDataQuality`: un objeto AutoDataQuality.

  Especifica si se debe habilitar automáticamente la evaluación de la calidad de los datos para el destino directo de Delta de S3. Si se establece en `true`, las comprobaciones de calidad de los datos se realizan automáticamente durante la operación de escritura.

Estructura S3HyperDirectTarget

Especifica un destino de datos de HyperDirect que escribe en Amazon S3.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  Identificador único del nodo de destino de HyperDirect.
- `Inputs`: obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y una cadena como máximo.

  Especifica el origen de entrada para el destino de HyperDirect.
- `Format` – Cadena UTF-8 (valores válidos: `json="JSON"` | `csv="CSV"` | `avro="AVRO"` | `orc="ORC"` | `parquet="PARQUET"` | `hudi="HUDI"` | `delta="DELTA"` | `iceberg="ICEBERG"` | `hyper="HYPER"` | `xml="XML"`).

  Especifica el formato de salida de datos para el destino de HyperDirect.

- `PartitionKeys`: matriz de cadenas UTF-8.

  Define la estrategia de partición para los datos de salida.
- `Path`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  Ubicación de S3 en la que se escribirán los datos de salida.
- `Compression` – Cadena UTF-8 (valores válidos: `uncompressed="UNCOMPRESSED"`).

  El tipo de compresión que se aplicará a los datos de salida.
- `SchemaChangePolicy`: un objeto DirectSchemaChangePolicy.

  Define cómo se gestionan los cambios de esquema durante las operaciones de escritura.
- `AutoDataQuality`: un objeto AutoDataQuality.

  Especifica si se habilita automáticamente la evaluación de la calidad de los datos para el destino directo de Hyper de S3. Si se establece en `true`, las comprobaciones de calidad de los datos se realizan automáticamente durante la operación de escritura.
- `OutputSchemas`: matriz de objetos GlueSchema.

  Especifica el esquema de datos para el destino directo de Hyper de S3.

Estructura S3IcebergDirectTarget

Especifica un destino que escribe en un origen de datos de Iceberg en Amazon S3.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  Especifica el identificador único del nodo de destino de Iceberg en la canalización de datos.
- `Inputs`: obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y una cadena como máximo.

  Define el único origen de entrada que proporciona datos a este destino de Iceberg.
- `PartitionKeys`: matriz de cadenas UTF-8.

  Especifica las columnas utilizadas para particionar los datos de la tabla de Iceberg en S3.
- `Path`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

Define la ubicación de S3 en la que se almacenarán los datos de la tabla de Iceberg.

- `Format`: Obligatorio: cadena UTF-8 (valores válidos: `json="JSON"` | `csv="CSV"` | `avro="AVRO"` | `orc="ORC"` | `parquet="PARQUET"` | `hudi="HUDI"` | `delta="DELTA"` | `iceberg="ICEBERG"` | `hyper="HYPER"` | `xml="XML"`).

  Especifica el formato de archivo utilizado para almacenar los datos de la tabla de Iceberg (por ejemplo, Parquet, ORC).

- `AdditionalOptions`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 que coincide con el Custom string pattern #61.

  Cada valor es una cadena UTF-8 que coincide con el Custom string pattern #61.

  Proporciona opciones de configuración adicionales para personalizar el comportamiento de la tabla de Iceberg.

- `SchemaChangePolicy`: un objeto DirectSchemaChangePolicy.

  Define cómo se gestionan los cambios de esquema al escribir datos en la tabla de Iceberg.

- `Compression`: obligatorio: cadena UTF-8 (valores válidos: `gzip="GZIP"` | `lzo="LZO"` | `uncompressed="UNCOMPRESSED"` | `snappy="SNAPPY"`).

  Especifica el códec de compresión utilizado para los archivos de la tabla de Iceberg en S3.

- `NumberTargetPartitions`: cadena UTF-8.

  Establece la cantidad de particiones de destino para distribuir los archivos de la tabla de Iceberg en S3.

- `OutputSchemas`: matriz de objetos GlueSchema.

  Especifica el esquema de datos para el destino directo de Iceberg de S3.

Estructura DirectSchemaChangePolicy

Una política que especifica los comportamientos de actualización del rastreador.

Campos

- `EnableUpdateCatalog`: booleano.

Si utilizar o no el comportamiento de actualización especificado cuando el rastreador encuentra un esquema cambiado.

- `UpdateBehavior` – Cadena UTF-8 (valores válidos: `UPDATE_IN_DATABASE` | `LOG`).

  Comportamiento de actualización cuando el rastreador encuentra un esquema cambiado.

- `Table` – cadena UTF-8 que coincide con el Custom string pattern #61.

  Especifica la tabla de la base de datos a la que se aplica la política de cambio de esquema.

- `Database` – cadena UTF-8 que coincide con el Custom string pattern #61.

  Especifica la base de datos a la que se aplica la política de cambio de esquema.

Estructura ApplyMapping

Especifica una transformación que asigna claves de propiedad de datos en el origen de datos a claves de propiedad de datos en el destino de datos. Puede cambiar el nombre de las claves, modificar los tipos de datos de las claves y elegir las claves que desea descartar del conjunto de datos.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del nodo de transformación.

- `Inputs`: obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y una cadena como máximo.

  Las entradas de datos identificadas por los nombres de sus nodos.

- `Mapping` (obligatorio): una matriz de objetos Correspondencia.

  Especifica la asignación de claves de propiedad de datos en el origen de datos a claves de propiedad de datos en el destino de datos.

Estructura de asignación

Especifica la asignación de claves de propiedad de datos.

Campos

- `ToKey` – cadena UTF-8 que coincide con el Custom string pattern #61.

  Después de aplicar la asignación, cuál debe ser el nombre de la columna. Puede ser igual que `FromPath`.

- `FromPath`: matriz de cadenas UTF-8.

  La tabla o columna que se va a modificar.

- `FromType` – cadena UTF-8 que coincide con el Custom string pattern #61.

  El tipo de datos que se van a modificar.

- `ToType` – cadena UTF-8 que coincide con el Custom string pattern #61.

  El tipo de datos al que se van a modificar los datos.

- `Dropped`: booleano.

  Si se establece en verdadero, se quita la columna.

- `Children`: matriz de objetos Correspondencia.

  Solo aplicable a estructuras de datos anidadas. Si desea cambiar la estructura principal, pero también una de las secundarias, puede rellenar esta estructura de datos. También es `Mapping`, pero su `FromPath` será el `FromPath` de la principal más el `FromPath` de esta estructura.

  Para las partes secundarias, suponga que tiene la estructura:

  ```
  { "FromPath": "OuterStructure", "ToKey": "OuterStructure", "ToType":
  "Struct", "Dropped": false, "Chidlren": [{ "FromPath": "inner", "ToKey":
  "inner", "ToType": "Double", "Dropped": false, }] }
  ```

  Puede especificar una `Mapping` que tiene este aspecto:

  ```
  { "FromPath": "OuterStructure", "ToKey": "OuterStructure", "ToType":
  "Struct", "Dropped": false, "Chidlren": [{ "FromPath": "inner", "ToKey":
  "inner", "ToType": "Double", "Dropped": false, }] }
  ```

Estructura SelectFields

Especifica una transformación que elige las claves de propiedad de datos que desea conservar.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del nodo de transformación.

- `Inputs`: obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y una cadena como máximo.

  Las entradas de datos identificadas por los nombres de sus nodos.

- `Paths`: obligatorio: una matriz de cadenas UTF-8.

  Una ruta JSON a una variable de la estructura de datos.

Estructura DropFields

Especifica una transformación que elige las claves de propiedad de datos que desea eliminar.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del nodo de transformación.

- `Inputs`: obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y una cadena como máximo.

  Las entradas de datos identificadas por los nombres de sus nodos.

- `Paths`: obligatorio: una matriz de cadenas UTF-8.

  Una ruta JSON a una variable de la estructura de datos.

Estructura RenameField

Especifica una transformación que cambia el nombre de una única clave de propiedad de datos.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del nodo de transformación.

- `Inputs`: obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y una cadena como máximo.

  Las entradas de datos identificadas por los nombres de sus nodos.
- `SourcePath`: obligatorio: una matriz de cadenas UTF-8.

  Una ruta JSON a una variable de la estructura de datos de los datos de origen.
- `TargetPath`: obligatorio: una matriz de cadenas UTF-8.

  Una ruta JSON a una variable de la estructura de datos de los datos de destino.

Estructura Spigot

Especifica una transformación que escribe ejemplos de los datos en un bucket de Amazon S3.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del nodo de transformación.
- `Inputs`: obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y una cadena como máximo.

  Las entradas de datos identificadas por los nombres de sus nodos.
- `Path`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  Una ruta en Amazon S3 donde la transformación escribe un subconjunto de registros del conjunto de datos en un archivo JSON en un bucket de Amazon S3.
- `Topk`: número (entero), 100 como máximo.

  Especifica un número de registros que se escribirán a partir del principio del conjunto de datos.
- `Prob`: número (doble), 1 como máximo.

  La probabilidad (un valor decimal con un valor máximo de 1) de seleccionar un registro determinado. Un valor 1 indica que cada fila leída del conjunto de datos debe incluirse en la salida de ejemplo.

Estructura Join

Especifica una transformación que une dos conjuntos de datos en uno mediante una frase de comparación en las claves de propiedad de datos especificadas. Puede utilizar combinaciones interna, externa, izquierda, derecha, semicombinación izquierda y anticombinación izquierda.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del nodo de transformación.

- `Inputs`: Obligatorio: matriz de cadenas UTF-8, con 2 cadenas como mínimo y 2 cadenas como máximo.

  Las entradas de datos identificadas por los nombres de sus nodos.

- `JoinType` Obligatorio: cadena UTF-8 (valores válidos: `equijoin="EQUIJOIN"` | `left="LEFT"` | `right="RIGHT"` | `outer="OUTER"` | `leftsemi="LEFT_SEMI"` | `leftanti="LEFT_ANTI"`).

  Especifica el tipo de unión que se va a realizar en los conjuntos de datos.

- `Columns`: Obligatorio: una matriz de objetos JoinColumn, con 2 estructuras como mínimo y 2 estructuras como máximo.

  Una lista de las dos columnas que se van a unir.

Estructura JoinColumn

Especifica una columna que se va a unir.

Campos

- `From`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  La columna que se va a unir.

- `Keys`: obligatorio: una matriz de cadenas UTF-8.

  La clave de la columna que se va a unir.

Estructura SplitFields

Especifica una transformación que divide las claves de propiedad de datos en dos `DynamicFrames`. La salida es una recopilación de `DynamicFrames`: uno con las claves de propiedad de datos seleccionadas y el otro con las claves de propiedad de datos restantes.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del nodo de transformación.

- `Inputs`: obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y una cadena como máximo.

  Las entradas de datos identificadas por los nombres de sus nodos.

- `Paths`: obligatorio: una matriz de cadenas UTF-8.

  Una ruta JSON a una variable de la estructura de datos.

Estructura SelectFromCollection

Especifica una transformación que elige un `DynamicFrame` de una recopilación de `DynamicFrames`. El resultado es el seleccionado `DynamicFrame`

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del nodo de transformación.

- `Inputs`: obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y una cadena como máximo.

  Las entradas de datos identificadas por los nombres de sus nodos.

- `Index` – Obligatorio: número (entero), cero como máximo.

  Índice del DynamicFrame que se va a seleccionar.

Estructura FillMissingValues

Especifica una transformación que localiza registros en el conjunto de datos que tienen valores faltantes y agrega un nuevo campo con un valor determinado por imputación. El conjunto de datos de entrada se utiliza para formar al modelo de machine learning que determina cuál debe ser el valor que falta.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del nodo de transformación.

- `Inputs`: obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y una cadena como máximo.

  Las entradas de datos identificadas por los nombres de sus nodos.

- `ImputedPath`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  Una ruta JSON a una variable de la estructura de datos del conjunto de datos que se imputa.

- `FilledPath` – cadena UTF-8 que coincide con el Custom string pattern #61.

  Una ruta JSON a una variable de la estructura de datos del conjunto de datos que se rellena.

Estructura Filter

Especifica una transformación que divide un conjunto de datos en dos, en función de una condición de filtro.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del nodo de transformación.

- `Inputs`: obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y una cadena como máximo.

  Las entradas de datos identificadas por los nombres de sus nodos.

- `LogicalOperator`: obligatorio: cadena UTF-8 (valores válidos: `AND` | `OR`).

El operador utilizado para filtrar filas mediante la comparación del valor de clave con un valor especificado.

- `Filters` (obligatorio): una matriz de objetos FilterExpression.

  Especifica una expresión de filtro.

Estructura FilterExpression

Especifica una expresión de filtro.

Campos

- `Operation` – Obligatorio: cadena UTF-8 (valores válidos: `EQ` | `LT` | `GT` | `LTE` | `GTE` | `REGEX` | `ISNULL`).

  El tipo de operación que se va a realizar en la expresión.

- `Negated`: booleano.

  Si se va a negar la expresión.

- `Values` (obligatorio): una matriz de objetos FilterValue.

  Una lista de valores de filtro.

Estructura FilterValue

Representa una única entrada en la lista de valores de una `FilterExpression`.

Campos

- `Type`: obligatorio: cadena UTF-8 (valores válidos: `COLUMNEXTRACTED` | `CONSTANT`).

  El tipo de valor de filtro.

- `Value`: obligatorio: una matriz de cadenas UTF-8.

  El valor que se va a asociar.

Estructura CustomCode

Especifica una transformación que utiliza el código personalizado que proporciona el usuario para llevar a cabo la transformación de datos. La salida es una recopilación de DynamicFrames.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del nodo de transformación.
- `Inputs`: obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo.

  Las entradas de datos identificadas por los nombres de sus nodos.
- `Code`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #54.

  El código personalizado que se utiliza para llevar a cabo la transformación de datos.
- `ClassName`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre definido para la clase de nodo de código personalizado.
- `OutputSchemas`: matriz de objetos GlueSchema.

  Especifica el esquema de datos para la transformación de código personalizada.

Estructura SparkSQL

Especifica una transformación en la que se ingresa una consulta SQL mediante la sintaxis de Spark SQL para transformar los datos. La salida es un único `DynamicFrame`.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del nodo de transformación.
- `Inputs`: obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo.

  Las entradas de datos identificadas por los nombres de sus nodos. Puede asociar un nombre de tabla a cada nodo de entrada para utilizarlo en la consulta SQL. El nombre que elija debe cumplir las restricciones de nomenclatura de Spark SQL.
- `SqlQuery`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #62.

Una consulta SQL que debe utilizar la sintaxis de Spark SQL y devolver un único conjunto de datos.

- `SqlAliases` (obligatorio): una matriz de objetos SQLAlias.

  Una lista de alias. Un alias permite especificar qué nombre se va a utilizar en SQL para una entrada determinada. Por ejemplo, tiene un origen de datos denominado “MyDataSource“. Si especifica `From` como MyDataSource y `Alias` como SQLName, luego, en su SQL puede hacer lo siguiente:

  ```
  select * from SqlName
  ```

  y eso obtiene datos de MyDataSource.

- `OutputSchemas`: matriz de objetos GlueSchema.

  Especifica el esquema de datos para la transformación de SparkSQL.

Estructura SQLAlias

Representa una única entrada en la lista de valores de `SqlAliases`.

Campos

- `From`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #60.

  Una tabla o columna de una tabla.

- `Alias`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  Un nombre temporal dado a una tabla o a una columna de una tabla.

Estructura DropNullFields

Especifica una transformación que elimina columnas del conjunto de datos si todos los valores de la columna son “nulos”. De forma predeterminada, AWS Glue Studio reconocerá los objetos nulos, pero algunos valores, como las cadenas vacías, las cadenas que son “nulas”, los enteros -1 u otros marcadores de posición, como los ceros, no se reconocen de manera automática como nulos.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del nodo de transformación.

- `Inputs`: obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y una cadena como máximo.

  Las entradas de datos identificadas por los nombres de sus nodos.

- `NullCheckBoxList`: un objeto NullCheckBoxList.

  Una estructura que representa si ciertos valores se reconocen como valores nulos para su eliminación.

- `NullTextList`: matriz de objetos NullValueField, con 50 estructuras como máximo.

  Una estructura que especifica una lista de estructuras NullValueField que representan un valor nulo personalizado, como cero u otro valor que se utiliza como marcador de posición nulo exclusivo del conjunto de datos.

  La transformación `DropNullFields` elimina los valores nulos personalizados solo si tanto el valor del marcador de posición nulo como el tipo de datos coinciden con los datos.

Estructura NullCheckBoxList

Representa si ciertos valores se reconocen como valores nulos para su eliminación.

Campos

- `IsEmpty`: booleano.

  Especifica que una cadena vacía se considera un valor nulo.

- `IsNullString`: booleano.

  Especifica que un valor que deletrea la palabra “nulo” se considera un valor nulo.

- `IsNegOne`: booleano.

  Especifica que un valor entero de -1 se considera un valor nulo.

Estructura NullValueField

Representa un valor nulo personalizado, como ceros u otro valor que se utiliza como marcador de posición nulo exclusivo del conjunto de datos.

Campos

- `Value`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El valor del marcador de posición nulo.
- `Datatype`: obligatorio: objeto Tipo de datos.

  El tipo de datos del valor.

Estructura Datatype

Una estructura que representa el tipo de datos del valor.

Campos

- `Id`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #60.

  El tipo de datos del valor.
- `Label`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #60.

  Una etiqueta asignada al tipo de datos.

Estructura Merge

Especifica una transformación que fusiona un `DynamicFrame` con una instancia provisional de `DynamicFrame` en función de las claves principales especificadas para identificar registros. Los registros duplicados (registros con las mismas claves principales) no se eliminan.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del nodo de transformación.
- `Inputs`: Obligatorio: matriz de cadenas UTF-8, con 2 cadenas como mínimo y 2 cadenas como máximo.

Las entradas de datos identificadas por los nombres de sus nodos.

- `Source`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #60.

  El `DynamicFrame` de origen que se fusionará con un `DynamicFrame` de instancia provisional.

- `PrimaryKeys`: obligatorio: una matriz de cadenas UTF-8.

  La lista de campos de clave principal para hacer coincidir los registros de los marcos dinámicos de origen y provisionales.

Estructura Union

Especifica una transformación que combina las filas de dos o más conjuntos de datos en un único resultado.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del nodo de transformación.

- `Inputs`: Obligatorio: matriz de cadenas UTF-8, con 2 cadenas como mínimo y 2 cadenas como máximo.

  Las entradas del ID de nodo a la transformación.

- `UnionType`: obligatorio: cadena UTF-8 (valores válidos: `ALL` | `DISTINCT`).

  Indica el tipo de transformación de combinación.

  Especifique `ALL` para unir todas las filas de los orígenes de datos al DynamicFrame resultante. La combinación resultante no elimina las filas duplicadas.

  Especifique `DISTINCT` para eliminar filas duplicadas en el DynamicFrame resultante.

Estructura PIIDetection

Especifica una transformación que identifica, elimina o enmascara datos PII.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del nodo de transformación.

- `Inputs`: obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y una cadena como máximo.

  Las entradas del ID de nodo a la transformación.

- `PiiType` – Obligatorio: cadena UTF-8 (valores válidos: `RowAudit` | `RowHashing` | `RowMasking` | `RowPartialMasking` | `ColumnAudit` | `ColumnHashing` | `ColumnMasking`).

  Indica el tipo de transformación PIIDDetection.

- `EntityTypesToDetect`: obligatorio: una matriz de cadenas UTF-8.

  Indica los tipos de entidades que la transformación PIIDProtection identificará como datos PII.

  Las entidades de tipo PII incluyen: PERSON_NAME, DATE, USA_SNN, EMAIL, USA_ITIN, USA_PASSPORT_NUMBER, PHONE_NUMBER, BANK_ACCOUNT, IP_ADDRESS, MAC_ADDRESS, USA_CPT_CODE, USA_HCPCS_CODE, USA_NATIONAL_DRUG_CODE, USA_MEDICARE_BENEFICIARY_IDENTIFIER, USA_HEALTH_INSURANCE_CLAIM_NUMBER,CREDIT_CARD,USA_NATIONAL_PROVIDER_IDENTIFI

- `OutputColumnName` – cadena UTF-8 que coincide con el Custom string pattern #61.

  Indica el nombre de columna de salida que contendrá cualquier tipo de entidad detectado en esa fila.

- `SampleFraction`: número (doble), 1 como máximo.

  Indica la fracción de los datos que se van a muestrear al buscar entidades PII.

- `ThresholdFraction`: número (doble), 1 como máximo.

  Indica la fracción de los datos que deben cumplirse para que una columna se identifique como datos de PII.

- `MaskValue` – cadena UTF-8, de 256 bytes de largo como máximo, que coincide con Custom string pattern #58.

  Indica el valor que sustituirá a la entidad detectada.

- `RedactText` – cadena UTF-8 que coincide con el Custom string pattern #61.

Especifica si se debe ocultar el texto de PII detectado. Si se establece en `true`, el contenido de PII se reemplaza por caracteres de ocultamiento.

- `RedactChar` – cadena UTF-8 que coincide con el Custom string pattern #61.

  El carácter que se usa para reemplazar el contenido de PII detectado cuando el ocultamiento está habilitado. El carácter de ocultamiento predeterminado es *.

- `MatchPattern` – cadena UTF-8 que coincide con el Custom string pattern #61.

  Un patrón de expresión regular que se utiliza para identificar contenido de PII adicional, sumado a los algoritmos de detección estándar.

- `NumLeftCharsToExclude`: número (entero), cero como máximo.

  El número de caracteres que se excluirán del ocultamiento en el lado izquierdo del contenido de PII detectado. Esto permite preservar el contexto en torno a la información confidencial.

- `NumRightCharsToExclude`: número (entero), cero como máximo.

  El número de caracteres que se excluirán del ocultamiento en el lado derecho del contenido de PII detectado. Esto permite preservar el contexto en torno a la información confidencial.

- `DetectionParameters` – cadena UTF-8 que coincide con el Custom string pattern #61.

  Parámetros adicionales para configurar el comportamiento de detección de PII y los ajustes de sensibilidad.

- `DetectionSensitivity` – cadena UTF-8 que coincide con el Custom string pattern #61.

  El nivel de sensibilidad para la detección de PII. Los niveles de sensibilidad más altos detectan más PII potencial, pero pueden generar más falsos positivos.

Estructura Aggregate

Especifica una transformación que agrupa las filas según los campos elegidos y calcula el valor agregado mediante una función especificada.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del nodo de transformación.

- `Inputs`: obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y una cadena como máximo.

  Especifica los campos y filas que se utilizarán como entradas para la transformación agregada.
- `Groups`: obligatorio: una matriz de cadenas UTF-8.

  Especifica los campos para agrupar.
- `Aggs`: obligatorio: una matriz de objetos AggregateOperation, con 1 estructura como mínimo y 30 estructuras como máximo.

  Especifica las funciones agregadas que se van a realizar en campos especificados.

Estructura DropDuplicates

Especifica una transformación que elimina las filas de datos repetidos de un conjunto de datos.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del nodo de transformación.
- `Inputs`: obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y una cadena como máximo.

  Las entradas de datos identificadas por los nombres de sus nodos.
- `Columns`: matriz de cadenas UTF-8.

  Nombre de las columnas que se van a fusionar o eliminar si se repiten.

Estructura GovernedCatalogTarget

Especifica un destino de datos que escribe en Amazon S3 mediante AWS Glue Data Catalog.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del destino de datos.

- `Inputs`: Obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y una cadena como máximo.

  Los nodos que son entradas para el destino de datos.
- `PartitionKeys`: matriz de cadenas UTF-8.

  Especifica la partición nativa mediante una secuencia de claves.
- `Table`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la tabla de la base de datos de escritura.
- `Database`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la base de datos de escritura.
- `SchemaChangePolicy`: un objeto CatalogSchemaChangePolicy.

  Una política que especifica los comportamientos de actualización del catálogo gobernado.

Estructura GovernedCatalogSource

Especifica un almacén de datos en el AWS Glue Data Catalog gobernado.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del almacén de datos.
- `Database`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  La base de datos de lectura.
- `Table`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  La tabla de base de datos de lectura.
- `PartitionPredicate` – cadena UTF-8 que coincide con el Custom string pattern #61.

  Se eliminan las particiones que cumplen con este predicado. Los archivos comprendidos en el período de retención de estas particiones no se eliminan. Configurar en `""`, valor vacío de forma predeterminada.
- `AdditionalOptions`: un objeto S3SourceAdditionalOptions.

Especifica opciones de conexión adicionales.

Estructura AggregateOperation

Especifica el conjunto de parámetros necesarios para llevar a cabo la agregación en la transformación de agregación.

Campos

- `Column`: obligatorio: una matriz de cadenas UTF-8.

  Especifica la columna del conjunto de datos en la que se aplicará la función de agregación.

- `AggFunc`: obligatorio: cadena UTF-8 (valores válidos: `avg` | `countDistinct` | `count` | `first` | `last` | `kurtosis` | `max` | `min` | `skewness` | `stddev_samp` | `stddev_pop` | `sum` | `sumDistinct` | `var_samp` | `var_pop`).

  Especifica la función de agregación que se aplicará.

  Las posibles funciones de agregación incluyen: avg countDistinct, count, first, last, kurtosis, max, min, skewness, stddev_samp, stddev_pop, sum, sumDistinct, var_samp, var_pop

Estructura GlueSchema

Especifica un esquema definido por el usuario cuando un esquema no puede determinarse mediante AWS Glue.

Campos

- `Columns`: matriz de objetos GlueStudioSchemaColumn.

  Especifica las definiciones de columna que componen un esquema de AWS Glue.

Estructura GlueStudioSchemaColumn

Especifica una sola columna en una definición de esquema de AWS Glue.

Campos

- `Name` – Obligatorio: cadena UTF-8, de 1024 bytes de largo como máximo, que coincide con Single-line string pattern.

  El nombre de la columna en el esquema de AWS Glue Studio.
- `Type` – cadena UTF-8 con un máximo de 131072 bytes de largo, que coincide con el Single-line string pattern.

  El tipo de Hive de esta columna del esquema de AWS Glue Studio.
- `GlueStudioType` – cadena UTF-8 con un máximo de 131072 bytes de largo, que coincide con el Single-line string pattern.

  El tipo de datos de la columna según se define en AWS Glue Studio.

Estructura GluStudioColumn

Especifica una sola columna en AWS Glue Studio.

Campos

- `Key`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  La clave de la columna en AWS Glue Studio.
- `FullPath`: obligatorio: una matriz de cadenas UTF-8.

  La dirección URL completa de la columna en AWS Glue Studio.
- `Type` – Obligatorio: matriz UTF-8 (valores válidos: `array="ARRAY"` | `bigint="BIGINT"` | `bigint array="BIGINT_ARRAY"` | `binary="BINARY"` | `binary array="BINARY_ARRAY"` | `boolean="BOOLEAN"` | `boolean array="BOOLEAN_ARRAY"` | `byte="BYTE"` | `byte array="BYTE_ARRAY"` | `char="CHAR"` | `char array="CHAR_ARRAY"` | `choice="CHOICE"` | `choice array="CHOICE_ARRAY"` | `date="DATE"` | `date array="DATE_ARRAY"` | `decimal="DECIMAL"` | `decimal array="DECIMAL_ARRAY"` | `double="DOUBLE"` | `double array="DOUBLE_ARRAY"` | `enum="ENUM"` | `enum array="ENUM_ARRAY"` | `float="FLOAT"` | `float array="FLOAT_ARRAY"` | `int="INT"` | `int array="INT_ARRAY"` | `interval="INTERVAL"` | `interval array="INTERVAL_ARRAY"` | `long="LONG"` | `long array="LONG_ARRAY"` | `object="OBJECT"` | `short="SHORT"` | `short array="SHORT_ARRAY"` | `smallint="SMALLINT"` | `smallint array="SMALLINT_ARRAY"`

| string="STRING" | string array="STRING_ARRAY" | timestamp="TIMESTAMP" | timestamp array="TIMESTAMP_ARRAY" | tinyint="TINYINT" | tinyint array="TINYINT_ARRAY" | varchar="VARCHAR" | varchar array="VARCHAR_ARRAY" | null="NULL" | unknown="UNKNOWN" | unknown array="UNKNOWN_ARRAY").

  El tipo de la columna en AWS Glue Studio.

- `Children`: un conjunto de estructuras.

  Los elementos secundarios de la columna principal de AWS Glue Studio.

- `GlueStudioType` – Cadena UTF-8 (valores válidos: `array="ARRAY" | bigint="BIGINT" | bigint array="BIGINT_ARRAY" | binary="BINARY" | binary array="BINARY_ARRAY" | boolean="BOOLEAN" | boolean array="BOOLEAN_ARRAY" | byte="BYTE" | byte array="BYTE_ARRAY" | char="CHAR" | char array="CHAR_ARRAY" | choice="CHOICE" | choice array="CHOICE_ARRAY" | date="DATE" | date array="DATE_ARRAY" | decimal="DECIMAL" | decimal array="DECIMAL_ARRAY" | double="DOUBLE" | double array="DOUBLE_ARRAY" | enum="ENUM" | enum array="ENUM_ARRAY" | float="FLOAT" | float array="FLOAT_ARRAY" | int="INT" | int array="INT_ARRAY" | interval="INTERVAL" | interval array="INTERVAL_ARRAY" | long="LONG" | long array="LONG_ARRAY" | object="OBJECT" | short="SHORT" | short array="SHORT_ARRAY" | smallint="SMALLINT" | smallint array="SMALLINT_ARRAY" | string="STRING" | string array="STRING_ARRAY" | timestamp="TIMESTAMP" | timestamp array="TIMESTAMP_ARRAY" | tinyint="TINYINT" | tinyint array="TINYINT_ARRAY" | varchar="VARCHAR" | varchar array="VARCHAR_ARRAY" | null="NULL" | unknown="UNKNOWN" | unknown array="UNKNOWN_ARRAY"`).

  El tipo de datos de la columna según se define en AWS Glue Studio.

Estructura de DynamicTransform

Especifica el conjunto de parámetros necesarios para hacer la transformación dinámica.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  Especifica el nombre de la transformación dinámica.

- `TransformName`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

Especifica el nombre de la transformación dinámica tal como aparece en el editor visual de AWS Glue Studio.

- `Inputs`: obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y una cadena como máximo.

  Especifica las entradas necesarias para la transformación dinámica.
- `Parameters`: matriz de objetos TransformConfigParameter.

  Especifica los parámetros de la transformación dinámica.
- `FunctionName`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  Especifica el nombre de la función de la transformación dinámica.
- `Path`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  Especifica la ruta de los archivos de origen y de configuración de la transformación dinámica.
- `Version` – cadena UTF-8 que coincide con el Custom string pattern #61.

  Este campo no se utiliza y quedará en desuso en la versión futura.
- `OutputSchemas`: matriz de objetos GlueSchema.

  Especifica el esquema de datos para la transformación dinámica.

Estructura de TransformConfigParameter

Especifica los parámetros de la transformación dinámica en el archivo de configuración.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  Especifica el nombre del parámetro de la transformación dinámica en el archivo de configuración.
- `Type` – Obligatorio: cadena UTF-8 (valores válidos: `str="STR"` | `int="INT"` | `float="FLOAT"` | `complex="COMPLEX"` | `bool="BOOL"` | `list="LIST"` | `null="NULL"`).

  Especifica el tipo de parámetro de la transformación dinámica en el archivo de configuración.
- `ValidationRule` – cadena UTF-8 que coincide con el Custom string pattern #61.

  Especifica la regla de validación de la transformación dinámica en el archivo de configuración.

- `ValidationMessage` – cadena UTF-8 que coincide con el Custom string pattern #61.

  Especifica el mensaje de validación de la transformación dinámica en el archivo de configuración.
- `Value`: matriz de cadenas UTF-8.

  Especifica el valor del parámetro de la transformación dinámica en el archivo de configuración.
- `ListType` – Cadena UTF-8 (valores válidos: `str="STR"` | `int="INT"` | `float="FLOAT"` | `complex="COMPLEX"` | `bool="BOOL"` | `list="LIST"` | `null="NULL"`).

  Especifica el tipo de lista del parámetro de la transformación dinámica en el archivo de configuración.
- `IsOptional`: booleano.

  Especifica si es opcional o no el parámetro de la transformación dinámica en el archivo de configuración.

Estructura de EvaluateDataQuality

Especifica los criterios de evaluación de la calidad de los datos.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre de la evaluación de la calidad de los datos.
- `Inputs`: obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y una cadena como máximo.

  Las entradas de la evaluación de la calidad de los datos.
- `Ruleset`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 65 536 bytes de largo como máximo, que coincide con Custom string pattern #59.

  El conjunto de reglas para la evaluación de la calidad de los datos.
- `Output` – Cadena UTF-8 (valores válidos: `PrimaryInput` | `EvaluationResults`).

  La salida de la evaluación de la calidad de los datos.
- `PublishingOptions`: un objeto DQResultsPublishingOptions.

  Opciones para configurar cómo se publican los resultados.

- `StopJobOnFailureOptions`: un objeto DQStopJobOnFailureOptions.

  Opciones para configurar la forma en que se detendrá el trabajo si se produce un error en la evaluación de la calidad de los datos.

Estructura de DQResultsPublishingOptions

Opciones para configurar cómo se publican los resultados de la evaluación de la calidad de los datos.

Campos

- `EvaluationContext` – cadena UTF-8 que coincide con el Custom string pattern #60.

  El contexto de la evaluación.

- `ResultsS3Prefix` – cadena UTF-8 que coincide con el Custom string pattern #61.

  El prefijo de Amazon S3 se antepuso a los resultados.

- `CloudWatchMetricsEnabled`: booleano.

  Habilite las métricas de los resultados de la calidad de datos.

- `ResultsPublishingEnabled`: booleano.

  Habilite la publicación de los resultados de la calidad de datos.

Estructura de DQStopJobOnFailureOptions

Opciones para configurar la forma en que se detendrá el trabajo si se produce un error en la evaluación de la calidad de los datos.

Campos

- `StopJobOnFailureTiming` – Cadena UTF-8 (valores válidos: `Immediate` | `AfterDataLoad`).

  Cuándo detener el trabajo si se produce un error en la evaluación de la calidad de los datos. Las opciones son Immediate o AfterDataLoad.

Estructura EvaluateDataQualityMultiFrame

Especifica los criterios de evaluación de la calidad de los datos.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre de la evaluación de la calidad de los datos.

- `Inputs`: obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo.

  Las entradas de la evaluación de la calidad de los datos. La primera entrada en esta lista es el origen de datos principal.

- `AdditionalDataSources`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 que coincide con el Custom string pattern #63.

  Cada valor es una cadena UTF-8 que coincide con el Custom string pattern #61.

  Los alias de todas los orígenes de datos excepto las principales.

- `Ruleset`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 65 536 bytes de largo como máximo, que coincide con Custom string pattern #59.

  El conjunto de reglas para la evaluación de la calidad de los datos.

- `PublishingOptions`: un objeto DQResultsPublishingOptions.

  Opciones para configurar cómo se publican los resultados.

- `AdditionalOptions`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 (valores válidos: `performanceTuning.caching="CacheOption"` | `observations.scope="ObservationsOption"` | `compositeRuleEvaluation.method="CompositeOption"`).

  Cada valor es una cadena UTF-8.

  Opciones para configurar el comportamiento de la transformación en tiempo de ejecución.

- `StopJobOnFailureOptions`: un objeto DQStopJobOnFailureOptions.

Opciones para configurar la forma en que se detendrá el trabajo si se produce un error en la evaluación de la calidad de los datos.

Estructura de receta

Un nodo de AWS Glue Studio que utiliza una receta de AWS Glue DataBrew en los trabajos de AWS Glue.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del nodo de AWS Glue Studio.

- `Inputs`: obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y una cadena como máximo.

  Los nodos de entrada al nodo de la receta, identificados mediante el ID.

- `RecipeReference`: un objeto RecipeReference.

  Una referencia a la receta de DataBrew utilizada por el nodo.

- `RecipeSteps`: matriz de objetos RecipeStep.

  Pasos de transformación utilizados en el nodo de receta.

Estructura RecipeReference

Una referencia a una receta de AWS Glue DataBrew.

Campos

- `RecipeArn`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El ARN de la receta de DataBrew.

- `RecipeVersion` - Obligatorio: cadena UTF-8, con no menos de 1 byte de largo o más de 16.

  La RecipeVersion de la receta de DataBrew.

Estructura de SnowflakeNodeData

Especifica la configuración de los nodos de Snowflake en AWS Glue Studio.

Campos

- `SourceType` – cadena UTF-8 que coincide con el Custom string pattern #60.

  Especifica cómo se especifican los datos recuperados. Valores válidos: `"table"`, `"query"`.
- `Connection`: un objeto Opción.

  Especifica una conexión del Catálogo de datos de AWS Glue a un punto de conexión de Snowflake.
- `Schema`: cadena UTF-8.

  Especifica un esquema de base de datos de Snowflake para que lo utilice el nodo.
- `Table`: cadena UTF-8.

  Especifica una tabla de Snowflake para que lo utilice el nodo.
- `Database`: cadena UTF-8.

  Especifica una base de datos de Snowflake para que lo utilice el nodo.
- `TempDir` – cadena UTF-8 que coincide con el Custom string pattern #61.

  En la actualidad no se utiliza.
- `IamRole`: un objeto Opción.

  En la actualidad no se utiliza.
- `AdditionalOptions`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 que coincide con el Custom string pattern #61.

  Cada valor es una cadena UTF-8 que coincide con el Custom string pattern #61.

  Especifica opciones adicionales que se pasan al conector de Snowflake. Si las opciones se especifican en otra parte de este nodo, esto tendrá prioridad.
- `SampleQuery`: cadena UTF-8.

  Una cadena de SQL que se utiliza para recuperar datos con el sourcetype `query`.

- `PreAction`: cadena UTF-8.

  Una cadena de SQL que se ejecuta antes de que el conector Snowflake lleve a cabo sus acciones estándar.

- `PostAction`: cadena UTF-8.

  Una cadena SQL que se ejecuta después de que el conector Snowflake lleve a cabo sus acciones estándar.

- `Action`: cadena UTF-8.

  Especifica qué acción se debe realizar al escribir en una tabla con datos preexistentes. Valores válidos: `append`, `merge`, `truncate`, `drop`.

- `Upsert`: booleano.

  Se utiliza cuando Action es `append`. Especifica el comportamiento de la resolución cuando ya existe una fila. Si es verdadero, se actualizarán las filas preexistentes. Si es falso, se insertarán esas filas.

- `MergeAction` – cadena UTF-8 que coincide con el Custom string pattern #60.

  Especifica una acción de combinación. Valores válidos: `simple`, `custom`. Si es simple, el comportamiento de combinación se define mediante `MergeWhenMatched` y `MergeWhenNotMatched`. Si es personalizado, se define mediante `MergeClause`.

- `MergeWhenMatched` – cadena UTF-8 que coincide con el Custom string pattern #60.

  Especifica cómo resolver los registros que coinciden con datos preexistentes al combinarlos. Valores válidos: `update`, `delete`.

- `MergeWhenNotMatched` – cadena UTF-8 que coincide con el Custom string pattern #60.

  Especifica cómo procesar los registros que no coinciden con los datos preexistentes al combinarlos. Valores válidos: `insert`, `none`.

- `MergeClause`: cadena UTF-8.

  Una instrucción de SQL que especifica un comportamiento de combinación personalizado.

- `StagingTable`: cadena UTF-8.

  El nombre de una tabla de preparación que se utiliza al realizar acciones `merge` o upsert `append`. Los datos se escriben en esta tabla y, a continuación, se mueven a `table` mediante una acción posterior generada.

- `SelectedColumns`: matriz de objetos Opción.

  Especifica las columnas combinadas para identificar un registro al detectar coincidencias de combinaciones y alteraciones. Una lista de estructuras con claves `value`, `label` y `description`. Cada estructura describe una columna.

- `AutoPushdown`: booleano.

  Especifica si está habilitada la delegación automática de consultas. Si la delegación está habilitada, cuando se ejecuta una consulta en Spark, si parte de la consulta se puede "delegar" al servidor de Snowflake, se delega. Esto mejora el rendimiento de algunas consultas.

- `TableSchema`: matriz de objetos Opción.

  Define manualmente el esquema de destino del nodo. Una lista de estructuras con claves `value`, `label` y `description`. Cada estructura describe una columna.

Estructura de SnowflakeSource

Especifica un origen de datos de Snowflake.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del origen de datos de Snowflake.

- `Data`: obligatorio: objeto SnowflakeNodeData.

  Configuración del origen de datos de Snowflake.

- `OutputSchemas`: matriz de objetos GlueSchema.

  Especifica los esquemas definidos por el usuario para los datos de salida.

Estructura de SnowflakeTarget

Especifica un destino de Snowflake.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

El nombre del origen de Snowflake.

- `Data`: obligatorio: objeto SnowflakeNodeData.

  Especifica los datos del nodo de destino de Snowflake.

- `Inputs`: matriz de cadenas UTF-8, no menos de una cadena o más de una.

  Los nodos que son entradas para el destino de datos.

Estructura de ConnectorDataSource

Especifica una fuente generada con opciones de conexión estándar.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre de este nodo de origen.

- `ConnectionType`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El `connectionType`, tal como se proporciona en la biblioteca subyacente de AWS Glue. Este tipo de nodo admite los siguientes tipos de conexión:

  - `opensearch`
  - `azuresql`
  - `azurecosmos`
  - `bigquery`
  - `saphana`
  - `teradata`
  - `vertica`

- `Data` – Obligatorio: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8.

  Cada valor es una cadena UTF-8.

Un mapa que especifica opciones de conexión para el nodo. Puede encontrar las opciones de conexión estándar para el tipo de conexión correspondiente en la sección Parámetros de conexión de la documentación de AWS Glue.

- `OutputSchemas`: matriz de objetos GlueSchema.

  Especifica el esquema de datos para este origen.

Estructura de ConnectorDataTarget

Especifica un destino generado con opciones de conexión estándar.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre de este nodo de destino.

- `ConnectionType`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El `connectionType`, tal como se proporciona en la biblioteca subyacente de AWS Glue. Este tipo de nodo admite los siguientes tipos de conexión:

  - `opensearch`
  - `azuresql`
  - `azurecosmos`
  - `bigquery`
  - `saphana`
  - `teradata`
  - `vertica`

- `Data` – Obligatorio: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8.

  Cada valor es una cadena UTF-8.

  Un mapa que especifica opciones de conexión para el nodo. Puede encontrar las opciones de conexión estándar para el tipo de conexión correspondiente en la sección Parámetros de conexión de la documentación de AWS Glue.

- `Inputs`: matriz de cadenas UTF-8, no menos de una cadena o más de una.

  Los nodos que son entradas para el destino de datos.

Estructura de RecipeStep

Paso de la receta utilizado en un nodo de receta de preparación de datos de AWS Glue Studio.

Campos

- `Action`: obligatorio: objeto RecipeAction.

  Acción de transformación del paso de la receta.
- `ConditionExpressions`: matriz de objetos ConditionExpression.

  Expresiones de condición para el paso de la receta.

Estructura de RecipeAction

Acciones definidas en el nodo de receta de preparación de datos de AWS Glue Studio.

Campos

- `Operation` – Obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo, que coincide con el Custom string pattern #56.

  Funcionamiento de la acción de la receta.
- `Parameters`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 con 1 byte de largo como mínimo y 128 bytes de largo como máximo, que coincide con Custom string pattern #57.

  Cada valor es una cadena UTF-8 con 1 byte de largo como mínimo o 32 768 como máximo.

  Parámetros de la acción de la receta.

Estructura de ConditionExpression

Expresión de la condición definida en el nodo de receta de preparación de datos de AWS Glue Studio.

Campos

- `Condition` – Obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo, que coincide con el Custom string pattern #56.

  Condición de la expresión de condición.
- `Value`: cadena UTF-8, no más de 1024 bytes de largo.

  Valor de la expresión de condición.
- `TargetColumn`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 1024 como máximo.

  Columna de destino de las expresiones de condición.

Estructura S3CatalogIcebergSource

Especifica un origen de datos de Apache Iceberg que está registrado en el Catálogo de datos de AWS Glue. El origen de datos de Iceberg debe almacenarse en Amazon S3.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del origen de datos de Iceberg.
- `Database`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la base de datos de lectura.
- `Table`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la tabla en la base de datos de lectura.
- `AdditionalIcebergOptions`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 que coincide con el Custom string pattern #61.

  Cada valor es una cadena UTF-8 que coincide con el Custom string pattern #61.

Especifica opciones de conexión adicionales para el origen de datos de Iceberg.

- `OutputSchemas`: matriz de objetos GlueSchema.

  Especifica el esquema de datos para el origen de Iceberg.

Estructura CatalogIcebergSource

Especifica un origen de datos de Apache Iceberg que está registrado en el Catálogo de datos de AWS Glue.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del origen de datos de Iceberg.

- `Database`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la base de datos de lectura.

- `Table`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la tabla en la base de datos de lectura.

- `AdditionalIcebergOptions`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 que coincide con el Custom string pattern #61.

  Cada valor es una cadena UTF-8 que coincide con el Custom string pattern #61.

  Especifica opciones de conexión adicionales para el origen de datos de Iceberg.

- `OutputSchemas`: matriz de objetos GlueSchema.

  Especifica el esquema de datos para el origen de Iceberg.

Estructura S3IcebergCatalogTarget

Especifica un destino del catálogo de Apache Iceberg que escribe datos en Amazon S3 y registra la tabla en el Catálogo de datos de AWS Glue.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del destino del catálogo de Iceberg.

- `Inputs`: obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y una cadena como máximo.

  La conexión de entrada para el destino del catálogo de Iceberg.

- `PartitionKeys`: matriz de cadenas UTF-8.

  Una lista de claves de partición para la tabla de Iceberg.

- `Table`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la tabla en la que se escribe en el catálogo.

- `Database`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de la base de datos de escritura.

- `AdditionalOptions`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 que coincide con el Custom string pattern #61.

  Cada valor es una cadena UTF-8 que coincide con el Custom string pattern #61.

  Especifica opciones de conexión adicionales para el destino del catálogo de Iceberg.

- `SchemaChangePolicy`: un objeto CatalogSchemaChangePolicy.

  La política para gestionar los cambios de esquema en el destino del catálogo.

- `AutoDataQuality`: un objeto AutoDataQuality.

  Especifica si se debe habilitar automáticamente la evaluación de la calidad de los datos para el destino del catálogo de Iceberg de S3. Si se establece en `true`, las comprobaciones de calidad de los datos se realizan automáticamente durante la operación de escritura.

Estructura DynamoDBELTConnectorSource

Especifica un origen del conector ELT de DynamoDB para extraer datos de las tablas de DynamoDB.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del origen del conector ELT de DynamoDB.
- `ConnectionOptions`: un objeto DDBELTConnectionOptions.

  Las opciones de conexión para el origen del conector ELT de DynamoDB.
- `OutputSchemas`: matriz de objetos GlueSchema.

  Especifica el esquema de datos para el origen del conector ELT de DynamoDB.

Estructura DDBELTConnectionOptions

Especifica las opciones de conexión para las operaciones de ELT (extracción, carga, transformación) de DynamoDB. Esta estructura contiene parámetros de configuración para conectarse a las tablas de DynamoDB y extraer datos de ellas mediante el conector ELT.

Campos

- `DynamodbExport` – Cadena UTF-8 (valores válidos: `ddb` | `s3`).

  Especifica el tipo de exportación para la extracción de datos de DynamoDB. Este parámetro determina cómo se exportan los datos de la tabla de DynamoDB durante el proceso de ELT.
- `DynamodbUnnestDDBJson`: booleano.

  Un valor booleano que especifica si se va a aplanar el formato JSON de DynamoDB durante la extracción de datos. Si se establece en `true`, el conector aplanará las estructuras JSON anidadas de los elementos de DynamoDB. Si se establece en `false`, se conserva la estructura JSON original de DynamoDB.
- `DynamodbTableArn`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de recurso de Amazon (ARN) de la tabla de DynamoDB de la que se extraerán datos. Este parámetro especifica la tabla de origen para la operación de ELT.
- `DynamodbS3Bucket` – cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre del bucket de Amazon S3 utilizado para el almacenamiento intermedio durante el proceso de ELT de DynamoDB. Este bucket se utiliza para almacenar temporalmente los datos exportados de DynamoDB antes de que los procese el trabajo de ELT.

- `DynamodbS3Prefix` – cadena UTF-8 que coincide con el Custom string pattern #61.

  El prefijo de clave de objeto de S3 para los archivos almacenados en el bucket de S3 intermedio durante el proceso de ELT de DynamoDB. Este prefijo ayuda a organizar e identificar los archivos temporales creados durante la extracción de datos.

- `DynamodbS3BucketOwner` – cadena UTF-8 que coincide con el Custom string pattern #61.

  ID de la cuenta de AWS del propietario del bucket de S3 especificado en `DynamodbS3Bucket`. Este parámetro es obligatorio cuando el bucket de S3 pertenece a una cuenta de AWS diferente a la que ejecuta el trabajo de ELT, ya que permite el acceso entre cuentas al bucket de almacenamiento intermedio.

- `DynamodbStsRoleArn` – cadena UTF-8 que coincide con el Custom string pattern #61.

  El nombre de recurso de Amazon (ARN) del rol de Security Token Service (STS) de AWS que se debe asumir para acceder a los recursos de DynamoDB y S3 durante la operación de ELT. Este rol debe tener los permisos necesarios para leer la tabla de DynamoDB y escribir en el bucket intermedio de S3.

Estructura DDBELTCatalogAdditionalOptions

Especifica opciones adicionales para las operaciones de catálogo de ELT de DynamoDB.

Campos

- `DynamodbExport` – cadena UTF-8 que coincide con el Custom string pattern #61.

  Especifica la configuración de exportación de DynamoDB para la operación de ELT.

- `DynamodbUnnestDDBJson`: booleano.

  Especifica si se va a aplanar el formato JSON de DynamoDB. Cuando se establece en `true`, las estructuras JSON anidadas de los elementos de DynamoDB se aplanan.

Estructura de rutas

Especifica un nodo de ruta que dirige los datos a diferentes rutas de salida en función de las condiciones de filtrado definidas.

Campos

- `Name`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #63.

  El nombre del nodo de ruta.
- `Inputs`: obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y una cadena como máximo.

  La conexión de entrada para el nodo de ruta.
- `GroupFiltersList` (obligatorio): una matriz de objetos GroupFilters.

  Una lista de filtros agrupados que definen las condiciones y los criterios de enrutamiento para dirigir los datos a diferentes rutas de salida.

Estructura GroupFilters

Especifica un grupo de filtros con un operador lógico que determina cómo se combinan los filtros para evaluar las condiciones de enrutamiento.

Campos

- `GroupName`: obligatorio: cadena UTF-8 que coincide con el Custom string pattern #60.

  El nombre del grupo de filtros.
- `Filters` (obligatorio): una matriz de objetos FilterExpression.

  Una lista de expresiones de filtro que definen las condiciones de este grupo.
- `LogicalOperator`: obligatorio: cadena UTF-8 (valores válidos: `AND` | `OR`).

  El operador lógico utilizado para combinar los filtros en este grupo. Determina si todos los filtros deben coincidir (Y) o si cualquier filtro puede coincidir (O).

Estructura AutoDataQuality

Especifica las opciones de configuración para la evaluación automática de la calidad de los datos en los trabajos de AWS Glue. Esta estructura habilita la supervisión y el control automatizados de la calidad de los datos durante las operaciones de ETL, lo que ayuda a garantizar la integridad y la fiabilidad de los datos sin intervención manual.

Campos

- `IsEnabled`: booleano.

  Especifica si está habilitada la evaluación automática de la calidad de los datos. Si se establece en `true`, las comprobaciones de calidad de los datos se realizan automáticamente.
- `EvaluationContext` – cadena UTF-8 que coincide con el Custom string pattern #61.

  El contexto de evaluación para los controles automáticos de la calidad de los datos. Esto define el alcance y los parámetros para la evaluación de la calidad de los datos.

API de trabajos

La API de trabajos describe los tipos de datos de trabajos y contiene las API para utilizar trabajos, ejecuciones de trabajos y desencadenadores en AWS Glue.

Temas

- Jobs
- Ejecuciones de trabajo
- Desencadenadores

Jobs

La API de trabajos describe los tipos de datos y la API relacionada con la creación, actualización, eliminación o visualización de trabajos en AWS Glue.

Tipos de datos

- Estructura de trabajo
- Estructura ExecutionProperty
- Estructura NotificationProperty
- Estructura JobCommand
- Estructura ConnectionsList
- Estructura JobUpdate
- Estructura SourceControlDetails

Estructura de trabajo

Especifica una definición de flujo de trabajo.

Campos

- `Name` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre que se asigna a esta definición de flujo de trabajo.
- `JobMode` – Cadena UTF-8 (valores válidos: `SCRIPT=""` | `VISUAL=""` | `NOTEBOOK=""`).

  Un modo que describe cómo se creó un trabajo. Los valores válidos son:
  - `SCRIPT`: El trabajo se creó con el editor de scripts de AWS Glue Studio.
  - `VISUAL`: El trabajo se creó con el editor visual de AWS Glue Studio.
  - `NOTEBOOK`: El trabajo se creó con un cuaderno de sesiones interactivo.

  Cuando el campo `JobMode` no aparece o es nulo, se asigna `SCRIPT` como valor predeterminado.
- `JobRunQueuingEnabled`: booleano.

  Especifica si la puesta en cola de las ejecuciones de trabajos está habilitada para las ejecuciones de este trabajo.

  Un valor verdadero significa que la puesta en cola de las ejecuciones de trabajos está habilitada para las ejecuciones. Si es falso o no se completa, los trabajos ejecutados no se considerarán para ingresar en la fila.

  Si este campo no coincide con el valor establecido en la ejecución del trabajo, se utilizará el valor proveniente del campo de ejecución del trabajo.
- `Description` – cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Una descripción del trabajo.
- `LogUri`: cadena UTF-8.

  Este campo se reserva para un uso ulterior.
- `Role`: cadena UTF-8.

  El nombre o nombre de recurso de Amazon (ARN) del rol de IAM asociado a este trabajo.

- `CreatedOn`: marca temporal.

  La fecha y hora en que se creó esta definición de flujo de trabajo.

- `LastModifiedOn`: marca temporal.

  La última vez en que se modificó esta definición de flujo de trabajo.

- `ExecutionProperty`: un objeto ExecutionProperty.

  Un `ExecutionProperty` que especifica el número máximo de ejecuciones simultáneas permitidas para este trabajo.

- `Command`: un objeto JobCommand.

  El `JobCommand` que ejecuta este trabajo.

- `DefaultArguments`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8.

  Cada valor es una cadena UTF-8.

  Los argumentos predeterminados para cada ejecución de este trabajo, que se especifican como pares nombre-valor.

  Aquí puede especificar argumentos que su propio script de ejecución de tareas consume, así como argumentos que AWS Glue consume.

  Es posible que se registren los argumentos del trabajo. No utilice secretos con formato de texto no cifrado como argumentos. Recupere los secretos desde una conexión de AWS Glue, AWS Secrets Manager u otro mecanismo de administración de secretos si tiene la intención de conservarlos dentro del trabajo.

  Para obtener información acerca de cómo especificar y utilizar sus propios argumentos de trabajo, consulte Llamadas a las API de AWS Glue en Python en la guía para desarrolladores.

  Para obtener información sobre los argumentos que puede proporcionar a este campo al configurar los trabajos de Spark, consulte el tema Parámetros especiales utilizados por AWS Glue en la guía para desarrolladores.

  Para obtener información sobre los argumentos que puede proporcionar a este campo al configurar los trabajos de Ray, consulte Utilizar parámetros de trabajo utilizados en trabajos de Ray en la guía para desarrolladores.

- `NonOverridableArguments`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8.

  Cada valor es una cadena UTF-8.

  Los argumentos para este trabajo que no se anulan cuando se proporcionan argumentos de trabajo en una ejecución de trabajos, se especifican como pares nombre-valor.

- `Connections`: un objeto ConnectionsList.

  Las conexiones que se utilizan para este flujo de trabajo.

- `MaxRetries`: número (entero).

  Número máximo de reintentos permitidos para este flujo de trabajo después de un error de JobRun.

- `AllocatedCapacity`: número (entero).

  Este campo está obsoleto. En su lugar, use `MaxCapacity`.

  El número de unidades de procesamiento de datos (DPU) de AWS Glue asignadas a las ejecuciones de este trabajo. Puede asignar un mínimo de 2 DPU; el valor predeterminado es 10. Una DPU es una medida relativa de la potencia de procesamiento que consta de 4 vCPU de capacidad de cómputo y 16 GB de memoria. Para obtener más información, consulte la página de precios de AWS Glue.

- `Timeout`: número (entero), como mínimo 1.

  El tiempo de espera del flujo de trabajo en minutos. Es el tiempo máximo que una ejecución de trabajo puede consumir recursos antes de que se termine y cambie al estado `TIMEOUT`.

  Los trabajos deben tener valores de tiempo de espera inferiores a 7 días o 10 080 minutos. De lo contrario, los trabajos arrojarán una excepción.

  Si el valor se deja vacío, el tiempo de espera se establece de forma predeterminada en 2880 minutos.

  Cualquier trabajo de AWS Glue existente con un valor de tiempo de espera superior a 7 días se establecerá de forma predeterminada en 7 días. Por ejemplo, si ha especificado un tiempo de espera de 20 días para un trabajo por lotes, este se detendrá el séptimo día.

Para trabajos de streaming, si ha configurado un período de mantenimiento, se reiniciará durante el período de mantenimiento a los 7 días.

- `MaxCapacity`: número (doble).

  Para trabajos de la versión 1.0 de Glue o anteriores, con el tipo de empleado estándar, debe especificar el número de unidades de procesamiento de datos (DPU) de AWS Glue que se pueden asignar cuando se ejecute este trabajo. Una DPU es una medida relativa de la potencia de procesamiento que consta de 4 vCPU de capacidad de cómputo y 16 GB de memoria. Para obtener más información, consulte la página de precios de AWS Glue.

  En los trabajos de Glue versión 2.0 o posterior, no puede especificar un `Maximum capacity`. En su lugar, debe especificar un `Worker type` y el `Number of workers`.

  No establezca `MaxCapacity` si utiliza `WorkerType` y `NumberOfWorkers`.

  El valor que se puede asignar a `MaxCapacity` depende de si se está ejecutando un trabajo de shell de Python, un trabajo de ETL de Apache Spark o un trabajo de ETL de streaming de Apache Spark:

  - Cuando especifica un trabajo de shell de Python (`JobCommand.Name`="pythonshell"), puede asignar 0,0625 o 1 DPU. El valor predeterminado es 0,0625 DPU.
  - Cuando especifica un trabajo ETL de Apache Spark (`JobCommand.Name`="glueetl") o un trabajo de ETL de streaming de Apache Spark (`JobCommand.Name`="gluestreaming"), puede asignar de 2 a 100 DPU. El valor predeterminado es 10 DPU. Este tipo de trabajo no puede tener una asignación de DPU fraccionaria.
- `WorkerType` – Cadena UTF-8 (valores válidos: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

  El tipo de proceso de trabajo predefinido que se asigna cuando se ejecuta un trabajo.

  AWS Glue proporciona varios tipos de trabajadores para adaptarse a diferentes requisitos de cargas de trabajo:

  Tipos de trabajadores G (trabajadores informáticos de uso general):

  - G.1X: 1 DPU (4 vCPU, 16 GB de memoria, 94 GB de disco)
  - G.2X: 2 DPU (8 vCPU, 32 GB de memoria, 138 GB de disco)
  - G.4X: 4 DPU (16 vCPU, 64 GB de memoria, 256 GB de disco)

- G.8X: 8 DPU (32 vCPU, 128 GB de memoria, 512 GB de disco)
- G.12X: 12 DPU (48 vCPU, 192 GB de memoria, 768 GB de disco)
- G.16X: 16 DPU (64 vCPU, 256 GB de memoria, 1024 GB de disco)

Tipos de trabajadores R (trabajadores con memoria optimizada):

- R.1X: 1 M-DPU (4 vCPU, 32 GB de memoria)
- R.2X: 2 M-DPU (8 vCPU, 64 GB de memoria)
- R.4X: 4 M-DPU (16 vCPU, 128 GB de memoria)
- R.8X: 8 M-DPU (32 vCPU, 256 GB de memoria)

- `NumberOfWorkers`: número (entero).

  El número de procesos de trabajo de `workerType` definido que se asignan cuando se ejecuta un trabajo.

- `SecurityConfiguration` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la estructura `SecurityConfiguration` que se va a utilizar con este trabajo.

- `NotificationProperty`: un objeto NotificationProperty.

  Especifica las propiedades de configuración de una notificación de flujo de trabajo.

- `Running`: booleano.

  Este campo se reserva para un uso ulterior.

- `GlueVersion` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #48.

  En los trabajos de Spark, `GlueVersion` determina las versiones de Apache Spark y Python que AWS Glue están disponibles en un trabajo. La versión de Python indica la versión admitida para trabajos de tipo Spark.

  Los trabajos de Ray se deben configurar `GlueVersion` en `4.0` o superior. Sin embargo, las versiones de Ray, Python y bibliotecas adicionales que están disponibles en el trabajo de Ray están determinadas por el parámetro `Runtime` del comando del trabajo.

  Para obtener más información acerca de las versiones de AWS Glue disponibles y las versiones de Spark y Python correspondientes, consulte Versión de Glue en la guía para desarrolladores.

Los trabajos que se crean sin especificar una versión de Glue se establecen de forma predeterminada en Glue 0.9.

- `CodeGenConfigurationNodes`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 que coincide con el Custom string pattern #60.

  Cada valor es un objeto A CodeGenConfigurationNode.

  La representación de un gráfico acíclico dirigido en el que se basa tanto el componente visual de Glue Studio como la generación de código de Glue Studio.

- `ExecutionClass`: cadena UTF-8 de 16 bytes de largo como máximo (valores válidos: `FLEX=""` | `STANDARD=""`).

  Indica si el trabajo se ejecuta con una clase de ejecución estándar o flexible. La clase de ejecución estándar es ideal para cargas de trabajo urgentes que requieren un inicio rápido de los trabajos y recursos dedicados.

  La clase de ejecución flexible es adecuada para trabajos no urgentes cuyos momentos de inicio y finalización pueden variar.

  Solo trabajos con AWS Glue versión 3.0 y posterior y tipo de comando `glueetl` podrán configurar `ExecutionClass` en `FLEX`. La clase de ejecución flexible está disponible para los trabajos de Spark.

- `SourceControlDetails`: un objeto SourceControlDetails.

  Los detalles de una configuración de control de código de origen para un trabajo, que permite la sincronización de los artefactos del trabajo hacia o desde un repositorio remoto.

- `MaintenanceWindow` – cadena UTF-8 que coincide con el Custom string pattern #34.

  Este campo especifica un día de la semana y una hora para el período de mantenimiento de los trabajos de streaming. AWS Glue lleva a cabo actividades de mantenimiento de forma periódica. Durante estos períodos de mantenimiento, AWS Glue tendrá que reiniciar sus trabajos de streaming.

  AWS Glue reiniciará el trabajo en un plazo de 3 horas a partir del inicio del período de mantenimiento especificado. Por ejemplo, si configura el período de mantenimiento para el lunes a las 10:00 h GMT, sus trabajos se reiniciarán entre las 10:00 h GMT y las 13:00 h GMT.

- `ProfileName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de un perfil de utilización de AWS Glue asociado al trabajo.

Estructura ExecutionProperty

Propiedad de ejecución de un flujo de trabajo.

Campos

- `MaxConcurrentRuns`: número (entero).

  El número máximo de ejecuciones simultáneas que están permitidas para el flujo de trabajo. El valor predeterminado es 1. Se produce un error cuando se llega a este umbral. El valor máximo que puede especificar se controla mediante un límite de servicio.

Estructura NotificationProperty

Especifica las propiedades de configuración de una notificación.

Campos

- `NotifyDelayAfter`: número (entero), como mínimo 1.

  Después de que comience una ejecución de flujo de trabajo, el número de minutos que se debe esperar antes de enviar una notificación de retraso de ejecución de un flujo de trabajo.

Estructura JobCommand

Especifica el código ejecutado cuando se ejecuta un trabajo.

Campos

- `Name`: cadena UTF-8.

  El nombre del comando de trabajo. Para un trabajo de ETL de Apache Spark, este debe ser `glueetl`. Para un trabajo de shell de Python, debe ser `pythonshell`. Para un trabajo de ETL de streaming Apache Spark, este debe ser `gluestreaming`. Para un trabajo de Ray, esto debe ser `glueray`.

- `ScriptLocation`: cadena UTF-8 de 400 000 bytes de largo como máximo.

  Especifica la ruta de Amazon Simple Storage Service (Amazon S3) a un script que ejecuta un trabajo.
- `PythonVersion` – cadena UTF-8 que coincide con el Custom string pattern #49.

  La versión de Python que se utiliza para ejecutar un trabajo de shell de Python. Los valores permitidos son 2 o 3.
- `Runtime` – cadena UTF-8, de 64 bytes de largo como máximo, que coincide con Custom string pattern #33.

  En los trabajos de Ray, el tiempo de ejecución se utiliza para especificar las versiones de Ray, Python y bibliotecas adicionales disponibles en su entorno. Este campo no se usa en otros tipos de trabajos. Para ver los valores del entorno de tiempo de ejecución compatibles, consulte Entornos de tiempo de ejecución de Ray compatibles en la Guía de desarrolladores de AWS Glue.

Estructura ConnectionsList

Especifica las conexiones que utiliza un flujo de trabajo.

Campos

- `Connections`: una matriz de cadenas UTF-8, con 1000 cadenas como máximo.

  Lista de conexiones que utiliza el flujo de trabajo.

Estructura JobUpdate

Especifica la información que se utiliza para actualizar una definición de trabajo existente. Esta información sobrescribe por completo la definición del trabajo anterior.

Campos

- `JobMode` – Cadena UTF-8 (valores válidos: `SCRIPT=""` | `VISUAL=""` | `NOTEBOOK=""`).

  Un modo que describe cómo se creó un trabajo. Los valores válidos son:
  - `SCRIPT`: El trabajo se creó con el editor de scripts de AWS Glue Studio.
  - `VISUAL`: El trabajo se creó con el editor visual de AWS Glue Studio.
  - `NOTEBOOK`: El trabajo se creó con un cuaderno de sesiones interactivo.

Cuando el campo `JobMode` no aparece o es nulo, se asigna `SCRIPT` como valor predeterminado.

- `JobRunQueuingEnabled`: booleano.

  Especifica si la puesta en cola de las ejecuciones de trabajos está habilitada para las ejecuciones de este trabajo.

  Un valor verdadero significa que la puesta en cola de las ejecuciones de trabajos está habilitada para las ejecuciones. Si es falso o no se completa, los trabajos ejecutados no se considerarán para ingresar en la fila.

  Si este campo no coincide con el valor establecido en la ejecución del trabajo, se utilizará el valor proveniente del campo de ejecución del trabajo.

- `Description` – cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Descripción del flujo de trabajo que se va a definir.

- `LogUri`: cadena UTF-8.

  Este campo se reserva para un uso ulterior.

- `Role`: cadena UTF-8.

  El nombre o nombre de recurso de Amazon (ARN) del rol de IAM asociado a este trabajo (obligatorio).

- `ExecutionProperty`: un objeto ExecutionProperty.

  Un `ExecutionProperty` que especifica el número máximo de ejecuciones simultáneas permitidas para este trabajo.

- `Command`: un objeto JobCommand.

  El `JobCommand` que ejecuta este trabajo (obligatorio).

- `DefaultArguments`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8.

  Cada valor es una cadena UTF-8.

  Los argumentos predeterminados para cada ejecución de este trabajo, que se especifican como pares nombre-valor.

Aquí puede especificar argumentos que su propio script de ejecución de tareas consume, así como argumentos que AWS Glue consume.

Es posible que se registren los argumentos del trabajo. No utilice secretos con formato de texto no cifrado como argumentos. Recupere los secretos desde una conexión de AWS Glue, AWS Secrets Manager u otro mecanismo de administración de secretos si tiene la intención de conservarlos dentro del trabajo.

Para obtener información acerca de cómo especificar y utilizar sus propios argumentos de trabajo, consulte Llamadas a las API de AWS Glue en Python en la guía para desarrolladores.

Para obtener información sobre los argumentos que puede proporcionar a este campo al configurar los trabajos de Spark, consulte el tema Parámetros especiales utilizados por AWS Glue en la guía para desarrolladores.

Para obtener información sobre los argumentos que puede proporcionar a este campo al configurar los trabajos de Ray, consulte Utilizar parámetros de trabajo utilizados en trabajos de Ray en la guía para desarrolladores.

- `NonOverridableArguments`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8.

  Cada valor es una cadena UTF-8.

  Los argumentos para este trabajo que no se anulan cuando se proporcionan argumentos de trabajo en una ejecución de trabajos, se especifican como pares nombre-valor.

- `Connections`: un objeto ConnectionsList.

  Las conexiones que se utilizan para este flujo de trabajo.

- `MaxRetries`: número (entero).

  Número máximo de reintentos permitidos para esta tarea si se genera un error.

- `AllocatedCapacity`: número (entero).

  Este campo está obsoleto. En su lugar, use `MaxCapacity`.

  El número de unidades de procesamiento de datos (DPU) de AWS Glue que se van a asignar a este trabajo. Puede asignar un mínimo de 2 DPU; el valor predeterminado es 10. Una DPU es una

medida relativa de la potencia de procesamiento que consta de 4 vCPU de capacidad de cómputo y 16 GB de memoria. Para obtener más información, consulte la página de precios de AWS Glue.

- `Timeout`: número (entero), como mínimo 1.

  El tiempo de espera del flujo de trabajo en minutos. Es el tiempo máximo que una ejecución de trabajo puede consumir recursos antes de que se termine y cambie al estado `TIMEOUT`.

  Los trabajos deben tener valores de tiempo de espera inferiores a 7 días o 10 080 minutos. De lo contrario, los trabajos arrojarán una excepción.

  Si el valor se deja vacío, el tiempo de espera se establece de forma predeterminada en 2880 minutos.

  Cualquier trabajo de AWS Glue existente con un valor de tiempo de espera superior a 7 días se establecerá de forma predeterminada en 7 días. Por ejemplo, si ha especificado un tiempo de espera de 20 días para un trabajo por lotes, este se detendrá el séptimo día.

  Para trabajos de streaming, si ha configurado un período de mantenimiento, se reiniciará durante el período de mantenimiento a los 7 días.

- `MaxCapacity`: número (doble).

  Para trabajos de la versión 1.0 de Glue o anteriores, con el tipo de empleado estándar, debe especificar el número de unidades de procesamiento de datos (DPU) de AWS Glue que se pueden asignar cuando se ejecute este trabajo. Una DPU es una medida relativa de la potencia de procesamiento que consta de 4 vCPU de capacidad de cómputo y 16 GB de memoria. Para obtener más información, consulte la página de precios de AWS Glue.

  En los trabajos de Glue versión 2.0+, no puede especificar un `Maximum capacity`. En su lugar, debe especificar un `Worker type` y el `Number of workers`.

  No establezca `MaxCapacity` si utiliza `WorkerType` y `NumberOfWorkers`.

  El valor que se puede asignar a `MaxCapacity` depende de si se está ejecutando un trabajo de shell de Python, un trabajo de ETL de Apache Spark o un trabajo de ETL de streaming de Apache Spark:

  - Cuando especifica un trabajo de shell de Python (`JobCommand.Name`="pythonshell"), puede asignar 0,0625 o 1 DPU. El valor predeterminado es 0,0625 DPU.
  - Cuando especifica un trabajo ETL de Apache Spark (`JobCommand.Name`="glueetl") o un trabajo de ETL de streaming de Apache Spark (`JobCommand.Name`="gluestreaming"), puede asignar

de 2 a 100 DPU. El valor predeterminado es 10 DPU. Este tipo de trabajo no puede tener una asignación de DPU fraccionaria.

- `WorkerType` – Cadena UTF-8 (valores válidos: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

  El tipo de proceso de trabajo predefinido que se asigna cuando se ejecuta un trabajo. Acepta un valor de G.1X, G.2X, G.4X, G.8X o G.025X para los trabajos de Spark. Acepta el valor Z.2X para los trabajos Ray. Para obtener más información, consulte Definición de las propiedades de trabajos de Spark

- `NumberOfWorkers`: número (entero).

  El número de procesos de trabajo de `workerType` definido que se asignan cuando se ejecuta un trabajo.

- `SecurityConfiguration` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la estructura `SecurityConfiguration` que se va a utilizar con este trabajo.

- `NotificationProperty`: un objeto NotificationProperty.

  Especifica las propiedades de configuración de una notificación de trabajo.

- `GlueVersion` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #48.

  En los trabajos de Spark, `GlueVersion` determina las versiones de Apache Spark y Python que AWS Glue están disponibles en un trabajo. La versión de Python indica la versión admitida para trabajos de tipo Spark.

  Los trabajos de Ray se deben configurar `GlueVersion` en `4.0` o superior. Sin embargo, las versiones de Ray, Python y bibliotecas adicionales que están disponibles en el trabajo de Ray están determinadas por el parámetro `Runtime` del comando del trabajo.

  Para obtener más información acerca de las versiones de AWS Glue disponibles y las versiones de Spark y Python correspondientes, consulte Versión de Glue en la guía para desarrolladores.

  Los trabajos que se crean sin especificar una versión de Glue se establecen de forma predeterminada en Glue 0.9.

- `CodeGenConfigurationNodes`: matriz de mapas de pares clave-valor.

Cada clave es una cadena UTF-8 que coincide con el Custom string pattern #60.

Cada valor es un objeto A CodeGenConfigurationNode.

La representación de un gráfico acíclico dirigido en el que se basa tanto el componente visual de Glue Studio como la generación de código de Glue Studio.

- `ExecutionClass`: cadena UTF-8 de 16 bytes de largo como máximo (valores válidos: `FLEX=""` | `STANDARD=""`).

  Indica si el trabajo se ejecuta con una clase de ejecución estándar o flexible. La clase de ejecución estándar es ideal para cargas de trabajo urgentes que requieren un inicio rápido de los trabajos y recursos dedicados.

  La clase de ejecución flexible es adecuada para trabajos no urgentes cuyos momentos de inicio y finalización pueden variar.

  Solo trabajos con AWS Glue versión 3.0 y posterior y tipo de comando `glueetl` podrán configurar `ExecutionClass` en `FLEX`. La clase de ejecución flexible está disponible para los trabajos de Spark.

- `SourceControlDetails`: un objeto SourceControlDetails.

  Los detalles de una configuración de control de código de origen para un trabajo, que permite la sincronización de los artefactos del trabajo hacia o desde un repositorio remoto.

- `MaintenanceWindow` – cadena UTF-8 que coincide con el Custom string pattern #34.

  Este campo especifica un día de la semana y una hora para el período de mantenimiento de los trabajos de streaming. AWS Glue lleva a cabo actividades de mantenimiento de forma periódica. Durante estos períodos de mantenimiento, AWS Glue tendrá que reiniciar sus trabajos de streaming.

  AWS Glue reiniciará el trabajo en un plazo de 3 horas a partir del inicio del período de mantenimiento especificado. Por ejemplo, si configura el período de mantenimiento para el lunes a las 10:00 h GMT, sus trabajos se reiniciarán entre las 10:00 h GMT y las 13:00 h GMT.

- `ProfileName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de un perfil de utilización de AWS Glue asociado al trabajo.

Estructura SourceControlDetails

Los detalles de una configuración de control de código de origen para un trabajo, que permite la sincronización de los artefactos del trabajo hacia o desde un repositorio remoto.

Campos

- `Provider` – Cadena UTF-8 (valores válidos: `GITHUB` | `AWS_CODE_COMMIT`).

  El proveedor del repositorio remoto.
- `Repository`: cadena UTF-8, con 1 byte de largo como mínimo y 512 bytes de largo como máximo.

  Nombre del repositorio remoto que contiene los artefactos del trabajo.
- `Owner`: cadena UTF-8, con 1 byte de largo como mínimo y 512 bytes de largo como máximo.

  Propietario del repositorio remoto que contiene los artefactos del trabajo.
- `Branch`: cadena UTF-8, con 1 byte de largo como mínimo y 512 bytes de largo como máximo.

  Una rama opcional en el repositorio remoto.
- `Folder`: cadena UTF-8, con 1 byte de largo como mínimo y 512 bytes de largo como máximo.

  Una carpeta opcional en el repositorio remoto.
- `LastCommitId`: cadena UTF-8, con 1 byte de largo como mínimo y 512 bytes de largo como máximo.

  El último identificador de confirmación de una confirmación en el repositorio remoto.
- `LastSyncTimestamp`: cadena UTF-8, con 1 byte de largo como mínimo y 512 bytes de largo como máximo.

  La fecha y hora en que se realizó la última sincronización del trabajo.
- `AuthStrategy` – Cadena UTF-8 (valores válidos: `PERSONAL_ACCESS_TOKEN` | `AWS_SECRETS_MANAGER`).

  El tipo de autenticación, que puede ser un token de autenticación almacenado en elemento AWS de Secrets Manager o un token de acceso personal.
- `AuthToken`: cadena UTF-8, con 1 byte de largo como mínimo y 512 bytes de largo como máximo.

  El valor de un token de autorización.

Operaciones

- Acción CreateJob (Python: create_job)
- Acción UpdateJob (Python: update_job)
- Acción GetJob (Python: get_job)
- Acción GetJobs (Python: get_jobs)
- Acción DeleteJob (Python: delete_job)
- Acción ListJobs (Python: list_jobs)
- Acción BatchGetJobs (Python: batch_get_jobs)

Acción CreateJob (Python: create_job)

Crea una nueva definición de flujo de trabajo.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre que se asigna a esta definición de flujo de trabajo. Debe ser único en la cuenta.
- `JobMode` – Cadena UTF-8 (valores válidos: `SCRIPT=""` | `VISUAL=""` | `NOTEBOOK=""`).

  Un modo que describe cómo se creó un trabajo. Los valores válidos son:
  - `SCRIPT`: El trabajo se creó con el editor de scripts de AWS Glue Studio.
  - `VISUAL`: El trabajo se creó con el editor visual de AWS Glue Studio.
  - `NOTEBOOK`: El trabajo se creó con un cuaderno de sesiones interactivo.

  Cuando el campo `JobMode` no aparece o es nulo, se asigna `SCRIPT` como valor predeterminado.
- `JobRunQueuingEnabled`: booleano.

  Especifica si la puesta en cola de las ejecuciones de trabajos está habilitada para las ejecuciones de este trabajo.

  Un valor verdadero significa que la puesta en cola de las ejecuciones de trabajos está habilitada para las ejecuciones. Si es falso o no se completa, los trabajos ejecutados no se considerarán para ingresar en la fila.

Si este campo no coincide con el valor establecido en la ejecución del trabajo, se utilizará el valor proveniente del campo de ejecución del trabajo.

- `Description` – cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Descripción del flujo de trabajo que se va a definir.

- `LogUri`: cadena UTF-8.

  Este campo se reserva para un uso ulterior.

- `Role` – Obligatorio: cadena UTF-8.

  El nombre o nombre de recurso de Amazon (ARN) del rol de IAM asociado a este trabajo.

- `ExecutionProperty`: un objeto ExecutionProperty.

  Un `ExecutionProperty` que especifica el número máximo de ejecuciones simultáneas permitidas para este trabajo.

- `Command`: obligatorio: objeto JobCommand.

  El `JobCommand` que ejecuta este trabajo.

- `DefaultArguments`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8.

  Cada valor es una cadena UTF-8.

  Los argumentos predeterminados para cada ejecución de este trabajo, que se especifican como pares nombre-valor.

  Aquí puede especificar argumentos que su propio script de ejecución de tareas consume, así como argumentos que AWS Glue consume.

  Es posible que se registren los argumentos del trabajo. No utilice secretos con formato de texto no cifrado como argumentos. Recupere los secretos desde una conexión de AWS Glue, AWS Secrets Manager u otro mecanismo de administración de secretos si tiene la intención de conservarlos dentro del trabajo.

  Para obtener información acerca de cómo especificar y utilizar sus propios argumentos de trabajo, consulte Llamadas a las API de AWS Glue en Python en la guía para desarrolladores.

Para obtener información sobre los argumentos que puede proporcionar a este campo al configurar los trabajos de Spark, consulte el tema Parámetros especiales utilizados por AWS Glue en la guía para desarrolladores.

Para obtener información sobre los argumentos que puede proporcionar a este campo al configurar los trabajos de Ray, consulte Utilizar parámetros de trabajo utilizados en trabajos de Ray en la guía para desarrolladores.

- `NonOverridableArguments`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8.

  Cada valor es una cadena UTF-8.

  Los argumentos para este trabajo que no se anulan cuando se proporcionan argumentos de trabajo en una ejecución de trabajos, se especifican como pares nombre-valor.

- `Connections`: un objeto ConnectionsList.

  Las conexiones que se utilizan para este flujo de trabajo.

- `MaxRetries`: número (entero).

  Número máximo de reintentos permitidos para esta tarea si se genera un error.

- `AllocatedCapacity`: número (entero).

  Este parámetro se ha quedado obsoleto. En su lugar, use `MaxCapacity`.

  El número de unidades de procesamiento de datos (DPU) de AWS Glue que se van a asignar a este trabajo. Puede asignar un mínimo de 2 DPU; el valor predeterminado es 10. Una DPU es una medida relativa de la potencia de procesamiento que consta de 4 vCPU de capacidad de cómputo y 16 GB de memoria. Para obtener más información, consulte la página de precios de AWS Glue.

- `Timeout`: número (entero), como mínimo 1.

  El tiempo de espera del flujo de trabajo en minutos. Es el tiempo máximo que una ejecución de trabajo puede consumir recursos antes de que se termine y cambie al estado `TIMEOUT`.

  Los trabajos deben tener valores de tiempo de espera inferiores a 7 días o 10 080 minutos. De lo contrario, los trabajos arrojarán una excepción.

Si el valor se deja vacío, el tiempo de espera se establece de forma predeterminada en 2880 minutos.

Cualquier trabajo de AWS Glue existente con un valor de tiempo de espera superior a 7 días se establecerá de forma predeterminada en 7 días. Por ejemplo, si ha especificado un tiempo de espera de 20 días para un trabajo por lotes, este se detendrá el séptimo día.

Para trabajos de streaming, si ha configurado un período de mantenimiento, se reiniciará durante el período de mantenimiento a los 7 días.

- `MaxCapacity`: número (doble).

  Para trabajos de la versión 1.0 de Glue o anteriores, con el tipo de empleado estándar, debe especificar el número de unidades de procesamiento de datos (DPU) de AWS Glue que se pueden asignar cuando se ejecute este trabajo. Una DPU es una medida relativa de la potencia de procesamiento que consta de 4 vCPU de capacidad de cómputo y 16 GB de memoria. Para obtener más información, consulte la página de precios de AWS Glue.

  En los trabajos de Glue versión 2.0+, no puede especificar un `Maximum capacity`. En su lugar, debe especificar un `Worker type` y el `Number of workers`.

  No establezca `MaxCapacity` si utiliza `WorkerType` y `NumberOfWorkers`.

  El valor que se puede asignar a `MaxCapacity` depende de si se está ejecutando un trabajo de shell de Python, un trabajo de ETL de Apache Spark o un trabajo de ETL de streaming de Apache Spark:

  - Cuando especifica un trabajo de shell de Python (`JobCommand.Name`="pythonshell"), puede asignar 0,0625 o 1 DPU. El valor predeterminado es 0,0625 DPU.
  - Cuando especifica un trabajo ETL de Apache Spark (`JobCommand.Name`="glueetl") o un trabajo de ETL de streaming de Apache Spark (`JobCommand.Name`="gluestreaming"), puede asignar de 2 a 100 DPU. El valor predeterminado es 10 DPU. Este tipo de trabajo no puede tener una asignación de DPU fraccionaria.
- `SecurityConfiguration` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la estructura `SecurityConfiguration` que se va a utilizar con este trabajo.
- `Tags`: matriz de mapas de pares de clave-valor, con 50 pares como máximo.

Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

Cada valor es una cadena UTF-8 que no tiene más de 256 bytes de largo.

Etiquetas que se van a utilizar con este trabajo. Puede utilizar etiquetas para limitar el acceso al trabajo. Para obtener más información acerca de las etiquetas en AWS Glue, consulte Etiquetas de AWS en AWS Glue en la guía para desarrolladores.

- `NotificationProperty`: un objeto NotificationProperty.

  Especifica las propiedades de configuración de una notificación de flujo de trabajo.

- `GlueVersion` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #48.

  En los trabajos de Spark, `GlueVersion` determina las versiones de Apache Spark y Python que AWS Glue están disponibles en un trabajo. La versión de Python indica la versión admitida para trabajos de tipo Spark.

  Los trabajos de Ray se deben configurar `GlueVersion` en `4.0` o superior. Sin embargo, las versiones de Ray, Python y bibliotecas adicionales que están disponibles en el trabajo de Ray están determinadas por el parámetro `Runtime` del comando del trabajo.

  Para obtener más información acerca de las versiones de AWS Glue disponibles y las versiones de Spark y Python correspondientes, consulte Versión de Glue en la guía para desarrolladores.

  Los trabajos que se crean sin especificar una versión de Glue se establecen de forma predeterminada en Glue 0.9.

- `NumberOfWorkers`: número (entero).

  El número de procesos de trabajo de `workerType` definido que se asignan cuando se ejecuta un trabajo.

- `WorkerType` – Cadena UTF-8 (valores válidos: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

  El tipo de proceso de trabajo predefinido que se asigna cuando se ejecuta un trabajo. Acepta un valor de G.1X, G.2X, G.4X, G.8X o G.025X para los trabajos de Spark. Acepta el valor Z.2X para los trabajos Ray.

  - Para el tipo de proceso de trabajo `G.1X`, cada proceso de trabajo se asocia a 1 DPU (4 vCPU, 16 GB de memoria) con un disco de 94 GB y proporciona 1 ejecutor por proceso de trabajo.

Recomendamos este tipo de trabajador para cargas de trabajo como transformaciones de datos, uniones y consultas, ya que ofrece una forma escalable y rentable de ejecutar la mayoría de los trabajos.

- Para el tipo de proceso de trabajo `G.2X`, cada proceso de trabajo se asocia a 2 DPU (8 vCPU, 32 GB de memoria) con un disco de 138 GB y proporciona 1 ejecutor por proceso de trabajo. Recomendamos este tipo de trabajador para cargas de trabajo como transformaciones de datos, uniones y consultas, ya que ofrece una forma escalable y rentable de ejecutar la mayoría de los trabajos.
- Para el tipo de proceso de trabajo `G.4X`, cada proceso de trabajo se asocia a 4 DPU (16 vCPU, 64 GB de memoria) con un disco de 256 GB y proporciona 1 ejecutor por proceso de trabajo. Recomendamos este tipo de trabajador para los trabajos cuyas cargas de trabajo contengan las transformaciones, agregaciones, uniones y consultas más exigentes. Este tipo de trabajo solo está disponibles para los trabajos de Spark ETL, versión 3.0 de AWS Glue o posterior, en las siguientes Regiones de AWS: Este de EE. UU. (Ohio), Este de EE. UU. (Norte de Virginia), Oeste de EE. UU. (Norte de California), Oeste de EE. UU. (Oregón), Asia-Pacífico (Mumbai), Asia Pacífico (Seúl), Asia Pacífico (Singapur), Asia Pacífico (Sídney), Asia Pacífico (Tokio), Canadá (centro), Europa (Fráncfort), Europa (Irlanda), Europa (Londres), Europa (España), Europa (Estocolmo) y
- Para el tipo de proceso de trabajo `G.8X`, cada proceso de trabajo se asocia a 8 DPU (32 vCPU, 128 GB de memoria) con un disco de 512 GB y proporciona 1 ejecutor por proceso de trabajo. Recomendamos este tipo de trabajador para los trabajos cuyas cargas de trabajo contengan las transformaciones, agregaciones, uniones y consultas más exigentes. Este tipo de trabajador solo está disponible para los trabajos ETL de Spark de la versión 3.0 de AWS Glue o posteriores, en las mismas regiones de AWS compatibles con el tipo de trabajador `G.4X`.
- Para el tipo de proceso de trabajo `G.025X`, cada proceso de trabajo se asocia a 0,25 DPU (2 vCPU, 4 GB de memoria) con un disco de 84 GB y proporciona 1 ejecutor por proceso de trabajo. Le recomendamos este tipo de proceso de trabajo para trabajos de streaming de bajo volumen. Este tipo de proceso de trabajo solo está disponible para trabajos de transmisión con la versión 3.0 (o posterior) de AWS Glue.
- Para el tipo de proceso de trabajo `Z.2X`, cada proceso de trabajo se asocia a 2 M-DPU (8 vCPU, 64 GB de memoria) con un disco de 128 GB y proporciona hasta 8 procesos de trabajo de Ray en función del escalador automático.

- `CodeGenConfigurationNodes`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 que coincide con el Custom string pattern #60.

Cada valor es un objeto A CodeGenConfigurationNode.

La representación de un gráfico acíclico dirigido en el que se basa tanto el componente visual de Glue Studio como la generación de código de Glue Studio.

- `ExecutionClass`: cadena UTF-8 de 16 bytes de largo como máximo (valores válidos: `FLEX=""` | `STANDARD=""`).

  Indica si el trabajo se ejecuta con una clase de ejecución estándar o flexible. La clase de ejecución estándar es ideal para cargas de trabajo urgentes que requieren un inicio rápido de los trabajos y recursos dedicados.

  La clase de ejecución flexible es adecuada para trabajos no urgentes cuyos momentos de inicio y finalización pueden variar.

  Solo trabajos con AWS Glue versión 3.0 y posterior y tipo de comando `glueetl` podrán configurar `ExecutionClass` en `FLEX`. La clase de ejecución flexible está disponible para los trabajos de Spark.

- `SourceControlDetails`: un objeto SourceControlDetails.

  Los detalles de una configuración de control de código de origen para un trabajo, que permite la sincronización de los artefactos del trabajo hacia o desde un repositorio remoto.

- `MaintenanceWindow` – cadena UTF-8 que coincide con el Custom string pattern #34.

  Este campo especifica un día de la semana y una hora para el período de mantenimiento de los trabajos de streaming. AWS Glue lleva a cabo actividades de mantenimiento de forma periódica. Durante estos períodos de mantenimiento, AWS Glue tendrá que reiniciar sus trabajos de streaming.

  AWS Glue reiniciará el trabajo en un plazo de 3 horas a partir del inicio del período de mantenimiento especificado. Por ejemplo, si configura el período de mantenimiento para el lunes a las 10:00 h GMT, sus trabajos se reiniciarán entre las 10:00 h GMT y las 13:00 h GMT.

- `ProfileName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de un perfil de utilización de AWS Glue asociado al trabajo.

Respuesta

- Name – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre único que se proporcionó para esta definición de flujo de trabajo.

Errores

- `InvalidInputException`
- `IdempotentParameterMismatchException`
- `AlreadyExistsException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`
- `ConcurrentModificationException`

Acción UpdateJob (Python: update_job)

Actualiza una definición de trabajo existente. Esta información sobrescribe por completo la definición del trabajo anterior.

Solicitud

- `JobName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre de la definición de trabajo que se va a actualizar.
- `JobUpdate`: obligatorio: objeto JobUpdate.

  Especifica los valores con los que se va a actualizar la definición de flujo de trabajo. La configuración no especificada se elimina o se restablece a los valores predeterminados.
- `ProfileName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de un perfil de utilización de AWS Glue asociado al trabajo.

Respuesta

- `JobName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Devuelve el nombre de la definición de flujo de trabajo actualizada.

Errores

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ConcurrentModificationException`

Acción GetJob (Python: get_job)

Recupera una definición de trabajo existente.

Solicitud

- `JobName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la definición de flujo de trabajo que se va a recuperar.

Respuesta

- `Job`: un objeto Trabajo.

  La definición de flujo de trabajo solicitada.

Errores

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`

- `OperationTimeoutException`

Acción GetJobs (Python: get_jobs)

Recupera todas las definiciones de flujo de trabajo actuales.

Solicitud

- `NextToken`: cadena UTF-8.

  Token de continuación si se trata de una llamada de continuidad.
- `MaxResults`: número (entero) que no es inferior a 1 ni es superior a 1000.

  Tamaño máximo de la respuesta.

Respuesta

- `Jobs`: matriz de objetos Trabajo.

  Lista de definiciones de flujo de trabajo.
- `NextToken`: cadena UTF-8.

  Token de continuación si todavía no se han devuelto todas las definiciones de flujo de trabajo.

Errores

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`

Acción DeleteJob (Python: delete_job)

Elimina una definición de flujo de trabajo especificada. Si no se encuentra la definición de flujo de trabajo, no se genera una excepción.

Solicitud

- `JobName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la definición de flujo de trabajo que se va a eliminar.

Respuesta

- `JobName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre de la definición de flujo de trabajo que se eliminó.

Errores

- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

Acción ListJobs (Python: list_jobs)

Recupera los nombres de todos los recursos de trabajo de esta cuenta de AWS o los recursos con la etiqueta especificada. Esta operación permite ver qué recursos están disponibles en la cuenta y sus nombres.

Esta operación toma el campo `Tags` opcional, que se puede utilizar como filtro en la respuesta para que los recursos etiquetados se devuelvan agrupados. Si decide utilizar el filtrado de etiquetas, solo se devolverán los recursos con la etiqueta especificada.

Solicitud

- `NextToken`: cadena UTF-8.

  Token de continuación, si se trata de una solicitud de continuidad.
- `MaxResults`: número (entero) que no es inferior a 1 ni es superior a 1000.

  Tamaño máximo de una lista que se devolverá.

- `Tags`: matriz de mapas de pares de clave-valor, con 50 pares como máximo.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es una cadena UTF-8 que no tiene más de 256 bytes de largo.

  Especifica que se devuelvan solamente los recursos etiquetados.

Respuesta

- `JobNames`: matriz de cadenas UTF-8.

  Nombres de todos los trabajos de la cuenta o de los trabajos con las etiquetas especificadas.
- `NextToken`: cadena UTF-8.

  Token de continuación, si la lista devuelta no contiene la última métrica disponible.

Errores

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`

Acción BatchGetJobs (Python: batch_get_jobs)

Devuelve la lista de metadatos de recursos de una determinada lista de nombres de trabajos. Después de llamar a la operación `ListJobs`, puede llamar a esta operación para obtener acceso a los datos a los que ha concedido permisos. Esta operación admite todos los permisos de IAM, incluidas las condiciones de permisos que utilizan etiquetas.

Solicitud

- `JobNames` – Obligatorio: una matriz de cadenas UTF-8.

  Una lista de nombres de trabajos, que pueden ser los nombres devueltos en la operación `ListJobs`.

Respuesta

- `Jobs`: matriz de objetos Trabajo.

  Lista de definiciones de flujo de trabajo.

- `JobsNotFound`: matriz de cadenas UTF-8.

  No se encuentra ninguna lista de nombres de trabajos.

Errores

- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`

Ejecuciones de trabajo

La API de ejecuciones de trabajos describe los tipos de datos y la API relacionados con el inicio, la detención o la visualización de ejecuciones de trabajos, y el restablecimiento de marcadores de trabajos, en AWS Glue. El historial de ejecución de trabajos está disponible durante 90 días para su flujo de trabajo y ejecución de trabajos.

Tipos de datos

- Estructura JobRun
- Estructura Predecessor
- Estructura JobBookmarkEntry
- Estructura BatchStopJobRunSuccessfulSubmission
- Estructura BatchStopJobRunError
- Estructura NotificationProperty

Estructura JobRun

Contiene información acerca de una ejecución de flujo de trabajo.

Campos

- `Id` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de la ejecución de este flujo de trabajo.

- `Attempt`: número (entero).

  El número del intento de ejecución de este flujo de trabajo.

- `PreviousRunId` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de la ejecución anterior de este trabajo. Por ejemplo, el`JobRunId` especificado en la acción `StartJobRun`.

- `TriggerName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del disparador que inició esta ejecución de flujo de trabajo.

- `JobName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la definición de flujo de trabajo que se utiliza en esta ejecución.

- `JobMode` – Cadena UTF-8 (valores válidos: `SCRIPT=""` | `VISUAL=""` | `NOTEBOOK=""`).

  Un modo que describe cómo se creó un trabajo. Los valores válidos son:

  - `SCRIPT`: El trabajo se creó con el editor de scripts de AWS Glue Studio.
  - `VISUAL`: El trabajo se creó con el editor visual de AWS Glue Studio.
  - `NOTEBOOK`: El trabajo se creó con un cuaderno de sesiones interactivo.

  Cuando el campo `JobMode` no aparece o es nulo, se asigna `SCRIPT` como valor predeterminado.

- `JobRunQueuingEnabled`: booleano.

  Especifica si la puesta en cola de las ejecuciones de trabajos está habilitada para la ejecución del trabajo.

  Un valor verdadero significa que la puesta en cola de las ejecuciones de trabajos está habilitada para las ejecuciones. Si es falso o no está completo, los trabajos ejecutados no se considerarán para ingresar en la fila.

- `StartedOn`: marca temporal.

  La fecha y la hora en que se inició la ejecución de este flujo de trabajo.

- `LastModifiedOn`: marca temporal.

  Última modificación de la ejecución de este trabajo.

- `CompletedOn`: marca temporal.

  La fecha y la hora en que se completó la ejecución de este trabajo.

- `JobRunState`: Cadena UTF-8 (valores válidos: `STARTING` | `RUNNING` | `STOPPING` | `STOPPED` | `SUCCEEDED` | `FAILED` | `TIMEOUT` | `ERROR` | `WAITING` | `EXPIRED`).

  El estado actual de la ejecución de flujo de trabajo. Para obtener más información sobre los estados de los trabajos que han terminado de forma anormal, consulte Estados de ejecución de trabajos de AWS Glue.

- `Arguments`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8.

  Cada valor es una cadena UTF-8.

  Los argumentos de flujo de trabajo asociados a esta ejecución. En esta ejecución del trabajo, sustituyen a los argumentos predeterminados definidos en la propia definición del trabajo.

  Aquí puede especificar argumentos que su propio script de ejecución de tareas consume, así como argumentos que AWS Glue consume.

  Es posible que se registren los argumentos del trabajo. No utilice secretos con formato de texto no cifrado como argumentos. Recupere los secretos desde una conexión de AWS Glue, AWS Secrets Manager u otro mecanismo de administración de secretos si tiene la intención de conservarlos dentro del trabajo.

  Para obtener información acerca de cómo especificar y utilizar sus propios argumentos de trabajo, consulte Llamadas a las API de AWS Glue en Python en la guía para desarrolladores.

  Para obtener información sobre los argumentos que puede proporcionar a este campo al configurar los trabajos de Spark, consulte el tema Parámetros especiales utilizados por AWS Glue en la guía para desarrolladores.

Para obtener información sobre los argumentos que puede proporcionar a este campo al configurar los trabajos de Ray, consulte Utilizar parámetros de trabajo utilizados en trabajos de Ray en la guía para desarrolladores.

- `ErrorMessage`: cadena UTF-8.

  Un mensaje de error asociado a la ejecución de este flujo de trabajo.

- `PredecessorRuns`: matriz de objetos Predecessor.

  Una lista de predecesores a la ejecución de este flujo de trabajo.

- `AllocatedCapacity`: número (entero).

  Este campo está obsoleto. En su lugar, use `MaxCapacity`.

  El número de unidades de procesamiento de datos (DPU) de AWS Glue asignadas a este JobRun. Se pueden asignar entre 2 y 100 DPU; el valor predeterminado es 10. Una DPU es una medida relativa de la potencia de procesamiento que consta de 4 vCPU de capacidad de cómputo y 16 GB de memoria. Para obtener más información, consulte la página de precios de AWS Glue.

- `ExecutionTime`: número (entero).

  El periodo de tiempo (en segundos) que la ejecución de flujo de trabajo consumió recursos.

- `Timeout`: número (entero), como mínimo 1.

  Tiempo de espera de `JobRun` en minutos. Es el tiempo máximo que una ejecución de trabajo puede consumir recursos antes de que se termine y cambie al estado `TIMEOUT`. Este valor sustituye el valor de tiempo de espera establecido en el flujo de trabajo principal.

  Los trabajos deben tener valores de tiempo de espera inferiores a 7 días o 10 080 minutos. De lo contrario, los trabajos arrojarán una excepción.

  Si el valor se deja vacío, el tiempo de espera se establece de forma predeterminada en 2880 minutos.

  Cualquier trabajo de AWS Glue existente con un valor de tiempo de espera superior a 7 días se establecerá de forma predeterminada en 7 días. Por ejemplo, si ha especificado un tiempo de espera de 20 días para un trabajo por lotes, este se detendrá el séptimo día.

  Para trabajos de streaming, si ha configurado un período de mantenimiento, se reiniciará durante el período de mantenimiento a los 7 días.

- `MaxCapacity`: número (doble).

  Para trabajos de la versión 1.0 de Glue o anteriores, con el tipo de empleado estándar, debe especificar el número de unidades de procesamiento de datos (DPU) de AWS Glue que se pueden asignar cuando se ejecute este trabajo. Una DPU es una medida relativa de la potencia de procesamiento que consta de 4 vCPU de capacidad de cómputo y 16 GB de memoria. Para obtener más información, consulte la página de precios de AWS Glue.

  En los trabajos de Glue versión 2.0+, no puede especificar un `Maximum capacity`. En su lugar, debe especificar un `Worker type` y el `Number of workers`.

  No establezca `MaxCapacity` si utiliza `WorkerType` y `NumberOfWorkers`.

  El valor que se puede asignar a `MaxCapacity` depende de si se está ejecutando un trabajo de shell de Python, un trabajo de ETL de Apache Spark o un trabajo de ETL de streaming de Apache Spark:

  - Cuando especifica un trabajo de shell de Python (`JobCommand.Name`="pythonshell"), puede asignar 0,0625 o 1 DPU. El valor predeterminado es 0,0625 DPU.
  - Cuando especifica un trabajo ETL de Apache Spark (`JobCommand.Name`="glueetl") o un trabajo de ETL de streaming de Apache Spark (`JobCommand.Name`="gluestreaming"), puede asignar de 2 a 100 DPU. El valor predeterminado es 10 DPU. Este tipo de trabajo no puede tener una asignación de DPU fraccionaria.
- `WorkerType` – Cadena UTF-8 (valores válidos: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

  El tipo de proceso de trabajo predefinido que se asigna cuando se ejecuta un trabajo. Acepta un valor de G.1X, G.2X, G.4X, G.8X o G.025X para los trabajos de Spark. Acepta el valor Z.2X para los trabajos Ray.

  - Para el tipo de proceso de trabajo `G.1X`, cada proceso de trabajo se asocia a 1 DPU (4 vCPU, 16 GB de memoria) con un disco de 94 GB y proporciona 1 ejecutor por proceso de trabajo. Recomendamos este tipo de trabajador para cargas de trabajo como transformaciones de datos, uniones y consultas, ya que ofrece una forma escalable y rentable de ejecutar la mayoría de los trabajos.
  - Para el tipo de proceso de trabajo `G.2X`, cada proceso de trabajo se asocia a 2 DPU (8 vCPU, 32 GB de memoria) con un disco de 138 GB y proporciona 1 ejecutor por proceso de trabajo. Recomendamos este tipo de trabajador para cargas de trabajo como transformaciones de datos,

uniones y consultas, ya que ofrece una forma escalable y rentable de ejecutar la mayoría de los trabajos.

- Para el tipo de proceso de trabajo `G.4X`, cada proceso de trabajo se asocia a 4 DPU (16 vCPU, 64 GB de memoria) con un disco de 256 GB y proporciona 1 ejecutor por proceso de trabajo. Recomendamos este tipo de trabajador para los trabajos cuyas cargas de trabajo contengan las transformaciones, agregaciones, uniones y consultas más exigentes. Este tipo de trabajador solo está disponible para los trabajos de Spark ETL de la versión 3.0 de AWS Glue o posteriores en las siguientes regiones de AWS: Este de EE. UU. (Ohio), Este de EE. UU. (Norte de Virginia), Oeste de EE. UU. (Oregón), Asia Pacífico (Singapur), Asia Pacífico (Sídney), Asia Pacífico (Tokio), Canadá (centro), Europa (Fráncfort), Europa (Irlanda) y Europa (Estocolmo).
- Para el tipo de proceso de trabajo `G.8X`, cada proceso de trabajo se asocia a 8 DPU (32 vCPU, 128 GB de memoria) con un disco de 512 GB y proporciona 1 ejecutor por proceso de trabajo. Recomendamos este tipo de trabajador para los trabajos cuyas cargas de trabajo contengan las transformaciones, agregaciones, uniones y consultas más exigentes. Este tipo de trabajador solo está disponible para los trabajos ETL de Spark de la versión 3.0 de AWS Glue o posteriores, en las mismas regiones de AWS compatibles con el tipo de trabajador `G.4X`.
- Para el tipo de proceso de trabajo `G.025X`, cada proceso de trabajo se asocia a 0,25 DPU (2 vCPU, 4 GB de memoria) con un disco de 84 GB y proporciona 1 ejecutor por proceso de trabajo. Le recomendamos este tipo de proceso de trabajo para trabajos de streaming de bajo volumen. Este tipo de proceso de trabajo solo está disponible para trabajos de transmisión con la versión 3.0 (o posterior) de AWS Glue.
- Para el tipo de proceso de trabajo `Z.2X`, cada proceso de trabajo se asocia a 2 M-DPU (8 vCPU, 64 GB de memoria) con un disco de 128 GB y proporciona hasta 8 procesos de trabajo de Ray en función del escalador automático.

- `NumberOfWorkers`: número (entero).

  El número de procesos de trabajo de `workerType` definido que se asignan cuando se ejecuta un trabajo.

- `SecurityConfiguration` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la estructura `SecurityConfiguration` que se va a utilizar con este trabajo.

- `LogGroupName`: cadena UTF-8.

  El nombre del grupo de registros para proteger el registro, que se puede cifrar en el lado del servidor en Amazon CloudWatch con AWS KMS. Este nombre puede ser `/aws-glue/`

`jobs/`, en cuyo caso el cifrado predeterminado es `NONE`. Si añade un nombre de rol y el nombre `SecurityConfiguration` (en otras palabras, `/aws-glue/jobs-yourRoleName-yourSecurityConfigurationName/`), entonces dicha configuración de seguridad se utiliza para cifrar el grupo de registros.

- `NotificationProperty`: un objeto NotificationProperty.

  Especifica las propiedades de configuración de una notificación de ejecución de trabajo.

- `GlueVersion` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #48.

  En los trabajos de Spark, `GlueVersion` determina las versiones de Apache Spark y Python que AWS Glue están disponibles en un trabajo. La versión de Python indica la versión admitida para trabajos de tipo Spark.

  Los trabajos de Ray se deben configurar `GlueVersion` en `4.0` o superior. Sin embargo, las versiones de Ray, Python y bibliotecas adicionales que están disponibles en el trabajo de Ray están determinadas por el parámetro `Runtime` del comando del trabajo.

  Para obtener más información acerca de las versiones de AWS Glue disponibles y las versiones de Spark y Python correspondientes, consulte Versión de Glue en la guía para desarrolladores.

  Los trabajos que se crean sin especificar una versión de Glue se establecen de forma predeterminada en Glue 0.9.

- `DPUSeconds`: número (doble).

  Este campo puede configurarse para ejecuciones de trabajos con clase de ejecución `FLEX` o cuando el escalado automático está activado, y representa el tiempo total que estuvo activo cada ejecutor durante el ciclo de vida de una ejecución de trabajo en segundos, multiplicado por un factor de DPU (1 para trabajadores `G.1X`, 2 para `G.2X`, o 0,25 para `G.025X`). Este valor puede ser diferente del de `executionEngineRuntime` * `MaxCapacity`, como en el caso de los trabajos de Auto Scaling, ya que el número de ejecutores que están activos en un momento determinado puede ser inferior a `MaxCapacity`. Por lo tanto, es posible que el valor de `DPUSeconds` sea menor que `executionEngineRuntime` * `MaxCapacity`.

- `ExecutionClass`: cadena UTF-8 de 16 bytes de largo como máximo (valores válidos: `FLEX=""` | `STANDARD=""`).

Indica si el trabajo se ejecuta con una clase de ejecución estándar o flexible. La clase de ejecución estándar es ideal para cargas de trabajo urgentes que requieren un inicio rápido de los trabajos y recursos dedicados.

La clase de ejecución flexible es adecuada para trabajos no urgentes cuyos momentos de inicio y finalización pueden variar.

Solo trabajos con AWS Glue versión 3.0 y posterior y tipo de comando `glueetl` podrán configurar `ExecutionClass` en `FLEX`. La clase de ejecución flexible está disponible para los trabajos de Spark.

- `MaintenanceWindow` – cadena UTF-8 que coincide con el Custom string pattern #34.

  Este campo especifica un día de la semana y una hora para el período de mantenimiento de los trabajos de streaming. AWS Glue lleva a cabo actividades de mantenimiento de forma periódica. Durante estos períodos de mantenimiento, AWS Glue tendrá que reiniciar sus trabajos de streaming.

  AWS Glue reiniciará el trabajo en un plazo de 3 horas a partir del inicio del período de mantenimiento especificado. Por ejemplo, si configura el período de mantenimiento para el lunes a las 10:00 h GMT, sus trabajos se reiniciarán entre las 10:00 h GMT y las 13:00 h GMT.
- `ProfileName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de un perfil de utilización de AWS Glue asociado a la ejecución del trabajo.
- `StateDetail`: cadena UTF-8 de 400 000 bytes de largo como máximo.

  Este campo contiene detalles relacionados con el estado de la ejecución de un trabajo. El campo admite valores nulos.

  Por ejemplo, cuando la ejecución de un trabajo se encuentra en estado EN ESPERA debido a la puesta en cola de las ejecuciones de trabajos, el campo indica el motivo por el que la ejecución del trabajo se encuentra en ese estado.
- `ExecutionRoleSessionPolicy`: cadena UTF-8 con una extensión de 2 bytes como mínimo o 2048 bytes como máximo.

  Esta política de sesión integrada en la API StartJobrun le permite restringir dinámicamente los permisos del rol de ejecución especificado para el alcance del trabajo, sin necesidad de crear roles de IAM adicionales.

Estructura Predecessor

Una ejecución de flujo de trabajo que se usó en el predicado de un disparador condicional que activó la ejecución de este flujo de trabajo.

Campos

- `JobName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la definición de flujo de trabajo que usa la ejecución de flujo de trabajo del predecesor.
- `RunId` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de ejecución del flujo de trabajo de la ejecución de flujo de trabajo del predecesor.

Estructura JobBookmarkEntry

Define un momento en el que un trabajo puede reanudar el procesamiento.

Campos

- `JobName`: cadena UTF-8.

  Nombre del trabajo en cuestión.
- `Version`: número (entero).

  La versión del trabajo.
- `Run`: número (entero).

  El número de ID de ejecución.
- `Attempt`: número (entero).

  El número de ID de intento.
- `PreviousRunId`: cadena UTF-8.

  El identificador de ejecución único asociado a esta ejecución.
- `RunId`: cadena UTF-8.

El número de ID de ejecución.

- `JobBookmark`: cadena UTF-8.

  El propio marcador.

Estructura BatchStopJobRunSuccessfulSubmission

Registra una solicitud correcta para detener un objeto especificado `JobRun`.

Campos

- `JobName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la definición de flujo de trabajo usada en la ejecución de flujo de trabajo que se detuvo.
- `JobRunId` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El `JobRunId` de la ejecución de trabajo que se detuvo.

Estructura BatchStopJobRunError

Registra un error que se produjo al intentar detener una ejecución de flujo de trabajo especificada.

Campos

- `JobName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la definición de trabajo usada en la ejecución de trabajo en cuestión.
- `JobRunId` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El `JobRunId` de la ejecución de trabajo en cuestión.
- `ErrorDetail`: un objeto ErrorDetail.

  Especifica los detalles acerca del error que se encontró.

Estructura NotificationProperty

Especifica las propiedades de configuración de una notificación.

Campos

- `NotifyDelayAfter`: número (entero), como mínimo 1.

  Después de que comience una ejecución de flujo de trabajo, el número de minutos que se debe esperar antes de enviar una notificación de retraso de ejecución de un flujo de trabajo.

Operaciones

- Acción StartJobRun (Python: start_job_run)
- Acción BatchStopJobRun (Python: batch_stop_job_run)
- Acción GetJobRun (Python: get_job_run)
- Acción GetJobRuns (Python: get_job_runs)
- Acción GetJobBookmark (Python: get_job_bookmark)
- Acción GetJobBookmarks (Python: get_job_bookmarks)
- Acción ResetJobBookmark (Python: reset_job_bookmark)

Acción StartJobRun (Python: start_job_run)

Inicia una ejecución de flujo de trabajo con una definición de flujo de trabajo.

Solicitud

- `JobName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la definición de flujo de trabajo que se va a usar.
- `JobRunQueuingEnabled`: booleano.

  Especifica si la puesta en cola de las ejecuciones de trabajos está habilitada para la ejecución del trabajo.

Un valor verdadero significa que la puesta en cola de las ejecuciones de trabajos está habilitada para las ejecuciones. Si es falso o no está completo, los trabajos ejecutados no se considerarán para ingresar en la fila.

- `JobRunId` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de una `JobRun` anterior para volver a intentarlo.

- `Arguments`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8.

  Cada valor es una cadena UTF-8.

  Los argumentos de flujo de trabajo asociados a esta ejecución. En esta ejecución del trabajo, sustituyen a los argumentos predeterminados definidos en la propia definición del trabajo.

  Aquí puede especificar argumentos que su propio script de ejecución de tareas consume, así como argumentos que AWS Glue consume.

  Es posible que se registren los argumentos del trabajo. No utilice secretos con formato de texto no cifrado como argumentos. Recupere los secretos desde una conexión de AWS Glue, AWS Secrets Manager u otro mecanismo de administración de secretos si tiene la intención de conservarlos dentro del trabajo.

  Para obtener información acerca de cómo especificar y utilizar sus propios argumentos de trabajo, consulte Llamadas a las API de AWS Glue en Python en la guía para desarrolladores.

  Para obtener información sobre los argumentos que puede proporcionar a este campo al configurar los trabajos de Spark, consulte el tema Parámetros especiales utilizados por AWS Glue en la guía para desarrolladores.

  Para obtener información sobre los argumentos que puede proporcionar a este campo al configurar los trabajos de Ray, consulte Utilizar parámetros de trabajo utilizados en trabajos de Ray en la guía para desarrolladores.

- `AllocatedCapacity`: número (entero).

  Este campo está obsoleto. En su lugar, use `MaxCapacity`.

El número de unidades de procesamiento de datos (DPU) de AWS Glue que se van a asignar a este JobRun. Puede asignar un mínimo de 2 DPU; el valor predeterminado es 10. Una DPU es una medida relativa de la potencia de procesamiento que consta de 4 vCPU de capacidad de cómputo y 16 GB de memoria. Para obtener más información, consulte la página de precios de AWS Glue.

- `Timeout`: número (entero), como mínimo 1.

  Tiempo de espera de `JobRun` en minutos. Es el tiempo máximo que una ejecución de trabajo puede consumir recursos antes de que se termine y cambie al estado `TIMEOUT`. Este valor sustituye el valor de tiempo de espera establecido en el flujo de trabajo principal.

  Los trabajos deben tener valores de tiempo de espera inferiores a 7 días o 10 080 minutos. De lo contrario, los trabajos arrojarán una excepción.

  Si el valor se deja vacío, el tiempo de espera se establece de forma predeterminada en 2880 minutos.

  Cualquier trabajo de AWS Glue existente con un valor de tiempo de espera superior a 7 días se establecerá de forma predeterminada en 7 días. Por ejemplo, si ha especificado un tiempo de espera de 20 días para un trabajo por lotes, este se detendrá el séptimo día.

  Para trabajos de streaming, si ha configurado un período de mantenimiento, se reiniciará durante el período de mantenimiento a los 7 días.

- `MaxCapacity`: número (doble).

  Para trabajos de la versión 1.0 de Glue o anteriores, con el tipo de empleado estándar, debe especificar el número de unidades de procesamiento de datos (DPU) de AWS Glue que se pueden asignar cuando se ejecute este trabajo. Una DPU es una medida relativa de la potencia de procesamiento que consta de 4 vCPU de capacidad de cómputo y 16 GB de memoria. Para obtener más información, consulte la página de precios de AWS Glue.

  En los trabajos de Glue versión 2.0+, no puede especificar un `Maximum capacity`. En su lugar, debe especificar un `Worker type` y el `Number of workers`.

  No establezca `MaxCapacity` si utiliza `WorkerType` y `NumberOfWorkers`.

  El valor que se puede asignar a `MaxCapacity` depende de si se está ejecutando un trabajo de shell de Python, un trabajo de ETL de Apache Spark o un trabajo de ETL de streaming de Apache Spark:

  - Cuando especifica un trabajo de shell de Python (`JobCommand.Name`="pythonshell"), puede asignar 0,0625 o 1 DPU. El valor predeterminado es 0,0625 DPU.
  - Cuando especifica un trabajo ETL de Apache Spark (`JobCommand.Name`="glueetl") o un trabajo de ETL de streaming de Apache Spark (`JobCommand.Name`="gluestreaming"), puede asignar de 2 a 100 DPU. El valor predeterminado es 10 DPU. Este tipo de trabajo no puede tener una asignación de DPU fraccionaria.
- `SecurityConfiguration` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la estructura `SecurityConfiguration` que se va a utilizar con este trabajo.
- `NotificationProperty`: un objeto NotificationProperty.

  Especifica las propiedades de configuración de una notificación de ejecución de trabajo.
- `WorkerType` – Cadena UTF-8 (valores válidos: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

  El tipo de proceso de trabajo predefinido que se asigna cuando se ejecuta un trabajo. Acepta un valor de G.1X, G.2X, G.4X, G.8X o G.025X para los trabajos de Spark. Acepta el valor Z.2X para los trabajos Ray.
  - Para el tipo de proceso de trabajo `G.1X`, cada proceso de trabajo se asocia a 1 DPU (4 vCPU, 16 GB de memoria) con un disco de 94 GB y proporciona 1 ejecutor por proceso de trabajo. Recomendamos este tipo de trabajador para cargas de trabajo como transformaciones de datos, uniones y consultas, ya que ofrece una forma escalable y rentable de ejecutar la mayoría de los trabajos.
  - Para el tipo de proceso de trabajo `G.2X`, cada proceso de trabajo se asocia a 2 DPU (8 vCPU, 32 GB de memoria) con un disco de 138 GB y proporciona 1 ejecutor por proceso de trabajo. Recomendamos este tipo de trabajador para cargas de trabajo como transformaciones de datos, uniones y consultas, ya que ofrece una forma escalable y rentable de ejecutar la mayoría de los trabajos.
  - Para el tipo de proceso de trabajo `G.4X`, cada proceso de trabajo se asocia a 4 DPU (16 vCPU, 64 GB de memoria) con un disco de 256 GB y proporciona 1 ejecutor por proceso de trabajo. Recomendamos este tipo de trabajador para los trabajos cuyas cargas de trabajo contengan las transformaciones, agregaciones, uniones y consultas más exigentes. Este tipo de trabajador solo está disponible para los trabajos de Spark ETL de la versión 3.0 de AWS Glue o posteriores en las siguientes regiones de AWS: Este de EE. UU. (Ohio), Este de EE. UU. (Norte de Virginia),

Oeste de EE. UU. (Oregón), Asia Pacífico (Singapur), Asia Pacífico (Sídney), Asia Pacífico (Tokio), Canadá (centro), Europa (Fráncfort), Europa (Irlanda) y Europa (Estocolmo).

- Para el tipo de proceso de trabajo `G.8X`, cada proceso de trabajo se asocia a 8 DPU (32 vCPU, 128 GB de memoria) con un disco de 512 GB y proporciona 1 ejecutor por proceso de trabajo. Recomendamos este tipo de trabajador para los trabajos cuyas cargas de trabajo contengan las transformaciones, agregaciones, uniones y consultas más exigentes. Este tipo de trabajador solo está disponible para los trabajos ETL de Spark de la versión 3.0 de AWS Glue o posteriores, en las mismas regiones de AWS compatibles con el tipo de trabajador `G.4X`.
- Para el tipo de proceso de trabajo `G.025X`, cada proceso de trabajo se asocia a 0,25 DPU (2 vCPU, 4 GB de memoria) con un disco de 84 GB y proporciona 1 ejecutor por proceso de trabajo. Le recomendamos este tipo de proceso de trabajo para trabajos de streaming de bajo volumen. Este tipo de proceso de trabajo solo está disponible para trabajos de transmisión con la versión 3.0 (o posterior) de AWS Glue.
- Para el tipo de proceso de trabajo `Z.2X`, cada proceso de trabajo se asocia a 2 M-DPU (8 vCPU, 64 GB de memoria) con un disco de 128 GB y proporciona hasta 8 procesos de trabajo de Ray en función del escalador automático.

- `NumberOfWorkers`: número (entero).

  El número de procesos de trabajo de `workerType` definido que se asignan cuando se ejecuta un trabajo.

- `ExecutionClass`: cadena UTF-8 de 16 bytes de largo como máximo (valores válidos: `FLEX=""` | `STANDARD=""`).

  Indica si el trabajo se ejecuta con una clase de ejecución estándar o flexible. La clase de ejecución estándar es ideal para cargas de trabajo urgentes que requieren un inicio rápido de los trabajos y recursos dedicados.

  La clase de ejecución flexible es adecuada para trabajos no urgentes cuyos momentos de inicio y finalización pueden variar.

  Solo trabajos con AWS Glue versión 3.0 y posterior y tipo de comando `glueetl` podrán configurar `ExecutionClass` en `FLEX`. La clase de ejecución flexible está disponible para los trabajos de Spark.

- `ProfileName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de un perfil de utilización de AWS Glue asociado a la ejecución del trabajo.

- `ExecutionRoleSessionPolicy`: cadena UTF-8 con una extensión de 2 bytes como mínimo o 2048 bytes como máximo.

  Esta política de sesión integrada en la API StartJobrun le permite restringir dinámicamente los permisos del rol de ejecución especificado para el alcance del trabajo, sin necesidad de crear roles de IAM adicionales.

Respuesta

- `JobRunId` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID asignado a la ejecución de este flujo de trabajo.

Errores

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`
- `ConcurrentRunsExceededException`

Acción BatchStopJobRun (Python: batch_stop_job_run)

Detiene una o varias ejecuciones de flujo de trabajo para una definición flujo de trabajo especificada.

Solicitud

- `JobName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la definición de flujo de trabajo para la que se detienen las ejecuciones de flujo de trabajo.

- `JobRunIds` – Obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y 25 cadenas como máximo.

Una lista de los `JobRunIds` que se deben detener para esa definición de trabajo.

Respuesta

- `SuccessfulSubmissions`: matriz de objetos BatchStopJobRunSuccessfulSubmission.

  Una lista de los objetos JobRun que se enviaron correctamente para su detención.

- `Errors`: matriz de objetos BatchStopJobRunError.

  Una lista de los errores que se encontraron al intentar detener objetos `JobRuns`, incluidos el `JobRunId` para el que se encontró cada error y los detalles acerca del error.

Errores

- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

Acción GetJobRun (Python: get_job_run)

Recupera los metadatos para una ejecución de flujo de trabajo especificada. El historial de ejecución de trabajos está disponible durante 365 días para su flujo de trabajo y ejecución de trabajos.

Solicitud

- `JobName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre de la definición de flujo de trabajo que se ejecuta.

- `RunId`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de la ejecución de flujo de trabajo.

- `PredecessorsIncluded`: booleano.

  True si una lista de ejecuciones del predecesor debe devolverse.

Respuesta

- `JobRun`: un objeto JobRun.

  Los metadatos de ejecución de flujo de trabajo solicitados.

Errores

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`

Acción GetJobRuns (Python: get_job_runs)

Recupera los metadatos para todas las ejecuciones de una definición de flujo de trabajo especificada.

`GetJobRuns` devuelve las ejecuciones del trabajo en orden cronológico, con las tareas más recientes devueltas primero.

Solicitud

- `JobName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la definición de flujo de trabajo para la que se recuperarán todas las ejecuciones de flujo de trabajo.
- `NextToken`: cadena UTF-8.

  Token de continuación si se trata de una llamada de continuidad.
- `MaxResults`: número (entero), mayor que 1 y menor que 200.

  Tamaño máximo de la respuesta.

Respuesta

- `JobRuns`: matriz de objetos JobRun.

Una lista de objetos de metadatos de ejecución de trabajo

- `NextToken`: cadena UTF-8.

  Token de continuación, si no se han devuelto todas las ejecuciones de trabajos solicitadas.

Errores

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`

Acción GetJobBookmark (Python: get_job_bookmark)

Devuelve información sobre una entrada de marcador de trabajo.

Para más información acerca de la habilitación y el uso de marcadores de trabajo, consulte:

- Seguimiento de los datos procesados mediante marcadores de trabajo
- Parámetros de trabajo utilizados por AWS Glue
- Estructura de trabajo

Solicitud

- `JobName` – Obligatorio: cadena UTF-8.

  Nombre del trabajo en cuestión.

- `Version`: número (entero).

  La versión del trabajo.

- `RunId`: cadena UTF-8.

  El identificador de ejecución único asociado a esta ejecución.

Respuesta

- `JobBookmarkEntry`: un objeto JobBookmarkEntry.

  Estructura que define un punto en el que un trabajo puede reanudar el procesamiento.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ValidationException`

Acción GetJobBookmarks (Python: get_job_bookmarks)

Devuelve información sobre las entradas de marcador de trabajo. La lista se ordena en números de versión decrecientes.

Para más información acerca de la habilitación y el uso de marcadores de trabajo, consulte:

- Seguimiento de los datos procesados mediante marcadores de trabajo
- Parámetros de trabajo utilizados por AWS Glue
- Estructura de trabajo

Solicitud

- `JobName` – Obligatorio: cadena UTF-8.

  Nombre del trabajo en cuestión.
- `MaxResults`: número (entero).

  Tamaño máximo de la respuesta.
- `NextToken`: número (entero).

  Token de continuación si se trata de una llamada de continuidad.

Respuesta

- `JobBookmarkEntries`: matriz de objetos JobBookmarkEntry.

  Una lista de entradas de marcador de trabajo que define un punto en el que un trabajo puede reanudar su procesamiento.

- `NextToken`: número (entero).

  Un token de continuación, que tiene un valor de 1 si se devuelven todas las entradas, o mayor que 1 si no se han devuelto todas las ejecuciones de trabajo solicitadas.

Errores

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`

Acción ResetJobBookmark (Python: reset_job_bookmark)

Restablece una entrada de marcador.

Para más información acerca de la habilitación y el uso de marcadores de trabajo, consulte:

- Seguimiento de los datos procesados mediante marcadores de trabajo
- Parámetros de trabajo utilizados por AWS Glue
- Estructura de trabajo

Solicitud

- `JobName` – Obligatorio: cadena UTF-8.

  Nombre del trabajo en cuestión.

- `RunId`: cadena UTF-8.

  El identificador de ejecución único asociado a esta ejecución.

Respuesta

- `JobBookmarkEntry`: un objeto JobBookmarkEntry.

  La entrada de marcador de restablecimiento.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

Desencadenadores

La API de desencadenadores describe los tipos de datos y la API relacionados con la creación, actualización o eliminación, y el inicio y la detención de desencadenadores de trabajos en AWS Glue.

Tipos de datos

- Estructura del desencadenador
- Estructura de TriggerUpdate
- Estructura de Predicate
- Estructura de Condition
- Estructura de acción
- Estructura EventBatchingCondition

Estructura del desencadenador

Información sobre un disparador específico.

Campos

- `Name`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del desencadenador.

- `WorkflowName`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del flujo de trabajo asociado con el desencadenador.

- `Id`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Reservado para uso futuro.

- `Type`: cadena UTF-8 (valores válidos: `SCHEDULED` | `CONDITIONAL` | `ON_DEMAND` | `EVENT`).

  Tipo de desencadenador en cuestión.

- `State`: cadena UTF-8 (valores válidos: `CREATING` | `CREATED` | `ACTIVATING` | `ACTIVATED` | `DEACTIVATING` | `DEACTIVATED` | `DELETING` | `UPDATING`).

  Estado actual del disparador.

- `Description`: cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Descripción de este desencadenador.

- `Schedule`: cadena UTF-8.

  Expresión `cron` utilizada para especificar el programa (consulte Programaciones basadas en tiempo para trabajos y rastreadores). Por ejemplo, para ejecutar algo todos los días a las 12:15 UTC, especifique: `cron(15 12 * * ? *)`.

- `Actions`: matriz de objetos Acción.

  Acciones iniciadas por este desencadenador.

- `Predicate`: un objeto Predicate.

  Predicado de este desencadenador, que define el momento en que se desencadenará.

- `EventBatchingCondition`: un objeto EventBatchingCondition.

  Condición del lote que debe cumplirse (número especificado de eventos recibidos o ventana de tiempo del lote vencida) antes de que se desencadene el evento EventBridge.

Estructura de TriggerUpdate

Una estructura usada para proporcionar información que se emplea para actualizar un disparador. Este objeto actualizará la definición del disparador anterior sobrescribiéndola por completo.

Campos

- `Name`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Reservado para uso futuro.

- `Description`: cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Descripción de este desencadenador.

- `Schedule`: cadena UTF-8.

  Expresión `cron` utilizada para especificar el programa (consulte Programaciones basadas en tiempo para trabajos y rastreadores). Por ejemplo, para ejecutar algo todos los días a las 12:15 UTC, especifique: `cron(15 12 * * ? *)`.

- `Actions`: matriz de objetos Acción.

  Acciones iniciadas por este desencadenador.

- `Predicate`: un objeto Predicate.

  Predicado de este desencadenador, que define el momento en que se desencadenará.

- `EventBatchingCondition`: un objeto EventBatchingCondition.

  Condición del lote que debe cumplirse (número especificado de eventos recibidos o ventana de tiempo del lote vencida) antes de que se desencadene el evento EventBridge.

Estructura de Predicate

Define el predicado del disparador, que determina cuándo se activa este.

Campos

- `Logical`: cadena UTF-8 (valores válidos: `AND` | `ANY`).

Un campo opcional si solo se indica una condición. Si se indican varias condiciones, este campo es obligatorio.

- `Conditions`: matriz de objetos Condición, con 500 estructuras como máximo.

  Lista de condiciones que determinan cuándo se desencadenará el disparador.

Estructura de Condition

Define una condición en la que se desencadena un desencadenador.

Campos

- `LogicalOperator`: cadena UTF-8 (valores válidos: `EQUALS`).

  Operador lógico.

- `JobName`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del trabajo a cuyo `JobRuns` se aplica esta condición y en el que espera este disparador.

- `State`: Cadena UTF-8 (valores válidos: `STARTING` | `RUNNING` | `STOPPING` | `STOPPED` | `SUCCEEDED` | `FAILED` | `TIMEOUT` | `ERROR` | `WAITING` | `EXPIRED`).

  El estado de la condición. Actualmente, los únicos estados de trabajo que un desencadenador puede escuchar son `SUCCEEDED`, `STOPPED`, `FAILED`, y `TIMEOUT`. Los únicos estados de rastreadores que un disparador puede escuchar son `SUCCEEDED`, `FAILED`, y `CANCELLED`.

- `CrawlerName`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del rastreador al que se aplica esta condición.

- `CrawlState`: cadena UTF-8 (valores válidos: `RUNNING` | `CANCELLING` | `CANCELLED` | `SUCCEEDED` | `FAILED` | `ERROR`).

  El estado del rastreador al que se aplica esta condición.

Estructura de acción

Define la acción que un desencadenador iniciará.

Campos

- `JobName`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del trabajo que se ejecutará.

- `Arguments`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8.

  Cada valor es una cadena UTF-8.

  Argumentos de trabajo que se utilizan cuando se activa este desencadenador. En esta ejecución del trabajo, sustituyen a los argumentos predeterminados definidos en la propia definición del trabajo.

  Aquí puede especificar argumentos que su propio script de ejecución de tareas consume, así como argumentos que AWS Glue consume.

  Para obtener información acerca de cómo especificar y utilizar sus propios argumentos de trabajo, consulte Llamadas a las API de AWS Glue en Python en la guía para desarrolladores.

  Para obtener información acerca de los pares clave-valor que AWS Glue utiliza para configurar su trabajo, consulte el tema Parámetros especiales usados por AWS Glue en la guía para desarrolladores.

- `Timeout`: número (entero), como mínimo 1.

  Tiempo de espera de `JobRun` en minutos. Es el tiempo máximo que una ejecución de trabajo puede consumir recursos antes de que se termine y cambie al estado `TIMEOUT`. Sustituye el valor de tiempo de espera establecido en el flujo de trabajo principal.

  Los trabajos deben tener valores de tiempo de espera inferiores a 7 días o 10 080 minutos. De lo contrario, los trabajos arrojarán una excepción.

  Si el valor se deja vacío, el tiempo de espera se establece de forma predeterminada en 2880 minutos.

Cualquier trabajo de AWS Glue existente con un valor de tiempo de espera superior a 7 días se establecerá de forma predeterminada en 7 días. Por ejemplo, si ha especificado un tiempo de espera de 20 días para un trabajo por lotes, este se detendrá el séptimo día.

Para trabajos de streaming, si ha configurado un período de mantenimiento, se reiniciará durante el período de mantenimiento a los 7 días.

- `SecurityConfiguration`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la estructura `SecurityConfiguration` que se va a utilizar con esta acción.

- `NotificationProperty`: un objeto NotificationProperty.

  Especifica las propiedades de configuración de una notificación de ejecución de trabajo.

- `CrawlerName`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del rastreador que se va a utilizar con esta acción.

Estructura EventBatchingCondition

Condición del lote que debe cumplirse (número especificado de eventos recibidos o ventana de tiempo del lote vencida) antes de que se desencadene el evento EventBridge.

Campos

- `BatchSize` – Obligatorio: número (entero), que no es inferior a 1 ni es superior a 100.

  Número de eventos que se deben recibir de Amazon EventBridge antes de que se desencadene el evento EventBridge.

- `BatchWindow`: número (entero), que no es inferior a 1 ni es superior a 900.

  Ventana de tiempo en segundos después de la cual se activa el evento EventBridge. La ventana se inicia cuando se recibe el primer evento.

Operaciones

- Acción CreateTrigger (Python: create_trigger)

- Acción StartTrigger (Python: start_trigger)
- Acción GetTrigger (Python: get_trigger)
- Acción GetTriggers (Python: get_triggers)
- Acción UpdateTrigger (Python: update_trigger)
- Acción StopTrigger (Python: stop_trigger)
- Acción DeleteTrigger (Python: delete_trigger)
- Acción ListTriggers (Python: list_triggers)
- Acción BatchGetTriggers (Python: batch_get_triggers)

Acción CreateTrigger (Python: create_trigger)

Crea un nuevo disparador.

Es posible que se registren los argumentos del trabajo. No utilice secretos con formato de texto no cifrado como argumentos. Recupere los secretos desde una conexión de AWS Glue, AWS Secrets Manager u otro mecanismo de administración de secretos si tiene la intención de conservarlos en el trabajo.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del desencadenador.
- `WorkflowName`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del flujo de trabajo asociado con el desencadenador.
- `Type` – Obligatorio: cadena UTF-8 (valores válidos: `SCHEDULED` | `CONDITIONAL` | `ON_DEMAND` | `EVENT`).

  Tipo del nuevo disparador.
- `Schedule`: cadena UTF-8.

  Expresión `cron` utilizada para especificar el programa (consulte Programaciones basadas en tiempo para trabajos y rastreadores). Por ejemplo, para ejecutar algo todos los días a las 12:15 UTC, especifique: `cron(15 12 * * ? *)`.

Este campo es obligatorio cuando el tipo de disparador es SCHEDULED.

- `Predicate`: un objeto Predicate.

  Un predicado para especificar cuándo debe desencadenarse el nuevo disparador.

  Este campo es obligatorio cuando el tipo de disparador es `CONDITIONAL`.

- `Actions` (obligatorio): una matriz de objetos Acción.

  Acciones que inicia este disparador cuando se desencadena.

- `Description`: cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Descripción del nuevo disparador.

- `StartOnCreation`: booleano.

  Establezca este parámetro en `true` para iniciar los disparadores `SCHEDULED` y `CONDITIONAL` cuando se crea. True no es compatible con los disparadores `ON_DEMAND`.

- `Tags`: matriz de mapas de pares de clave-valor, con 50 pares como máximo.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es una cadena UTF-8 que no tiene más de 256 bytes de largo.

  Etiquetas que se van a utilizar con este desencadenador. Puede utilizar etiquetas para limitar el acceso al desencadenador. Para obtener más información acerca de las etiquetas en AWS Glue, consulte Etiquetas de AWS en AWS Glue en la guía para desarrolladores.

- `EventBatchingCondition`: un objeto EventBatchingCondition.

  Condición del lote que debe cumplirse (número especificado de eventos recibidos o ventana de tiempo del lote vencida) antes de que se desencadene el evento EventBridge.

Respuesta

- `Name`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del desencadenador.

Errores

- `AlreadyExistsException`
- `EntityNotFoundException`
- `InvalidInputException`
- `IdempotentParameterMismatchException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`
- `ConcurrentModificationException`

Acción StartTrigger (Python: start_trigger)

Inicia un disparador ya existente. Consulte Activación de trabajos para obtener información acerca de cómo se desencadenan los diferentes tipos de disparadores.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del disparador que debe iniciarse.

Respuesta

- `Name`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del disparador que se inició.

Errores

- `InvalidInputException`
- `InternalServiceException`
- `EntityNotFoundException`
- `OperationTimeoutException`

- `ResourceNumberLimitExceededException`
- `ConcurrentRunsExceededException`

Acción GetTrigger (Python: get_trigger)

Recupera la definición de un disparador.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del disparador que debe recuperarse.

Respuesta

- `Trigger`: un objeto Desencadenador.

  Definición del disparador solicitada.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

Acción GetTriggers (Python: get_triggers)

Obtiene todos los disparadores asociados a un flujo de trabajo.

Solicitud

- `NextToken`: cadena UTF-8.

  Token de continuación si se trata de una llamada de continuidad.
- `DependentJobName`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

El nombre del trabajo para recuperar disparadores. Se devolverá el disparador que puede iniciar este trabajo y, si dicho disparador no existe, se devolverán todos los disparadores.

- `MaxResults`: número (entero), mayor que 1 y menor que 200.

  Tamaño máximo de la respuesta.

Respuesta

- `Triggers`: matriz de objetos Desencadenador.

  Lista de disparadores para el flujo de trabajo especificado.
- `NextToken`: cadena UTF-8.

  Token de continuación si todavía no se han devuelto todos los disparadores solicitados.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

Acción UpdateTrigger (Python: update_trigger)

Actualiza una definición de disparador.

Es posible que se registren los argumentos del trabajo. No utilice secretos con formato de texto no cifrado como argumentos. Recupere los secretos desde una conexión de AWS Glue, AWS Secrets Manager u otro mecanismo de administración de secretos si tiene la intención de conservarlos en el trabajo.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del disparador que debe actualizarse.

- `TriggerUpdate`: obligatorio: objeto TriggerUpdate.

  Nuevos valores con los que se actualizará el disparador.

Respuesta

- `Trigger`: un objeto Desencadenador.

  Definición del disparador resultante.

Errores

- `InvalidInputException`
- `InternalServiceException`
- `EntityNotFoundException`
- `OperationTimeoutException`
- `ConcurrentModificationException`

Acción StopTrigger (Python: stop_trigger)

Detiene un disparador especificado.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del disparador que debe detenerse.

Respuesta

- `Name`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del disparador que se detuvo.

Errores

- `InvalidInputException`
- `InternalServiceException`
- `EntityNotFoundException`
- `OperationTimeoutException`
- `ConcurrentModificationException`

Acción DeleteTrigger (Python: delete_trigger)

Elimina un disparador especificado. Si no se encuentra el disparador, no se genera una excepción.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del disparador que se va a eliminar.

Respuesta

- `Name`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del disparador que se eliminó.

Errores

- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ConcurrentModificationException`

Acción ListTriggers (Python: list_triggers)

Recupera los nombres de todos los recursos de desencadenadores de esta cuenta de AWS o los recursos con la etiqueta especificada. Esta operación permite ver qué recursos están disponibles en la cuenta y sus nombres.

Esta operación toma el campo `Tags` opcional, que se puede utilizar como filtro en la respuesta para que los recursos etiquetados se devuelvan agrupados. Si decide utilizar el filtrado de etiquetas, solo se devolverán los recursos con la etiqueta especificada.

Solicitud

- `NextToken`: cadena UTF-8.

  Token de continuación, si se trata de una solicitud de continuidad.
- `DependentJobName`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del trabajo para el que se quieren recuperar disparadores. Se devuelve el disparador que puede comenzar este trabajo. Si no existe dicho disparador, se devuelven todos los disparadores.
- `MaxResults`: número (entero), mayor que 1 y menor que 200.

  Tamaño máximo de una lista que se devolverá.
- `Tags`: matriz de mapas de pares de clave-valor, con 50 pares como máximo.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es una cadena UTF-8 que no tiene más de 256 bytes de largo.

  Especifica que se devuelvan solamente los recursos etiquetados.

Respuesta

- `TriggerNames`: matriz de cadenas UTF-8.

  Nombres de todos los disparadores de la cuenta o de los disparadores con las etiquetas especificadas.
- `NextToken`: cadena UTF-8.

  Token de continuación, si la lista devuelta no contiene la última métrica disponible.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

Acción BatchGetTriggers (Python: batch_get_triggers)

Devuelve la lista de metadatos de recursos de una determinada lista de nombres de disparadores. Después de llamar a la operación `ListTriggers`, puede llamar a esta operación para obtener acceso a los datos a los que ha concedido permisos. Esta operación admite todos los permisos de IAM, incluidas las condiciones de permisos que utilizan etiquetas.

Solicitud

- `TriggerNames` – Obligatorio: una matriz de cadenas UTF-8.

  Lista de nombres de disparadores, que pueden ser los nombres devueltos en la operación `ListTriggers`.

Respuesta

- `Triggers`: matriz de objetos Desencadenador.

  Lista de definiciones de disparadores.
- `TriggersNotFound`: matriz de cadenas UTF-8.

  No se encuentra ninguna lista de nombres de disparadores.

Errores

- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`

API de integración en AWS Glue

Tipos de datos

- Estructura de integración
- Estructura IntegrationConfig
- Estructura IntegrationPartition
- Estructura IntegrationError
- Estructura IntegrationFilter
- Estructura InboundIntegration
- Estructura SourceProcessingProperties
- Estructura TargetProcessingProperties
- Estructura SourceTableConfig
- Estructura TargetTableConfig

Estructura de integración

Describe una integración sin ETL.

Campos

- `SourceArn`: requerido: cadena UTF-8 con una extensión de 1 byte como mínimo y 128 bytes como máximo.

  ARN del origen de la integración.
- `TargetArn`: requerido: cadena UTF-8 con una extensión de 1 byte como mínimo y 128 bytes como máximo.

  ARN del destino de la integración.
- `Description`: cadena UTF-8 con una extensión de 1000 bytes como máximo y que coincide con Custom string pattern #12.

  Una descripción de la integración.
- `IntegrationName`: requerido: cadena UTF-8 con una extensión de 1 byte como mínimo y 128 bytes como máximo.

Nombre único de la integración.

- `IntegrationArn`: requerido: cadena UTF-8 con una extensión de 1 byte como mínimo y 128 bytes como máximo.

  Nombre de recurso de Amazon (ARN) de la integración.

- `KmsKeyId`: cadena UTF-8 con una extensión de 1 byte como mínimo o 2048 bytes como máximo.

  ARN de una clave de KMS que se utiliza para cifrar el canal.

- `AdditionalEncryptionContext`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8.

  Cada valor es una cadena UTF-8.

  Conjunto opcional de pares clave-valor no secretos que contienen información contextual adicional para el cifrado. Esto solo se puede proporcionar si `KMSKeyId` también se proporciona.

- `Tags`: matriz de objetos Tag.

  Metadatos que se asignan a un recurso que consta de una lista de pares clave-valor.

- `Status` – Obligatorio: cadena UTF-8 (valores válidos: `CREATING` | `ACTIVE` | `MODIFYING` | `FAILED` | `DELETING` | `SYNCING` | `NEEDS_ATTENTION`).

  Los posibles estados son:

  - CREATING: la integración se está creando.
  - ACTIVE: la creación de la integración se realizó correctamente.
  - MODIFYING: la integración se está modificando.
  - ERROR: error en la creación de la integración.
  - DELETING: se elimina la integración.
  - SYNCING: La integración se está sincronizando.
  - NEEDS_ATTENTION: la integración requiere atención, por ejemplo, la sincronización.

- `CreateTime` – Obligatorio: marca temporal.

  Hora (UTC) en la que se creó la integración.

- `IntegrationConfig`: un objeto IntegrationConfig.

  Propiedades asociadas con la integración.

- `Errors`: matriz de objetos IntegrationError.

  Lista de errores asociados con la integración.

- `DataFilter`: cadena UTF-8 con una extensión de 1 byte como mínimo o 2048 bytes como máximo.

  Permite seleccionar las tablas de origen de la integración mediante la sintaxis de filtro de Maxwell.

Estructura IntegrationConfig

Propiedades asociadas con la integración.

Campos

- `RefreshInterval`: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo.

  Especifica la frecuencia con la que deben ocurrir las extracciones o cargas incrementales de CDC (captura de datos de cambio). Este parámetro proporciona flexibilidad para alinear la frecuencia de actualización con sus patrones específicos de actualización de datos, consideraciones de carga del sistema y objetivos de optimización del rendimiento. El incremento de tiempo se puede configurar desde 15 minutos hasta 8640 minutos (seis días).

- `SourceProperties`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8.

  Cada valor es una cadena UTF-8.

  Una colección de pares clave-valor que especifican propiedades adicionales para el origen de la integración. Estas propiedades proporcionan opciones de configuración que se pueden utilizar para personalizar el comportamiento del origen ODB durante las operaciones de integración de datos.

- `ContinuousSync`: booleano.

  Permite la sincronización continua para extracciones de datos bajo demanda desde aplicaciones SaaS a servicios de datos de AWS como Amazon Redshift y Amazon S3.

Estructura IntegrationPartition

Estructura que describe cómo se particionan los datos en el destino.

Campos

- `FieldName`: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo.

  El nombre del campo que se utiliza para particionar los datos en el destino. Evite usar columnas que tengan valores únicos para cada fila (por ejemplo, «LastModifiedTimestamp», «SystemModTimestamp») como columna de partición. Estas columnas no son adecuadas para particionar porque crean una gran cantidad de particiones pequeñas, lo que puede provocar problemas de rendimiento.
- `FunctionSpec`: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo.

  Especifica la función que se utiliza para particionar los datos en el destino. Los valores aceptados para este parámetro son:
  - `identity`: Utiliza los valores de origen directamente sin transformarlos
  - `year`: Extrae el año de los valores de marca de tiempo (por ejemplo, 2023)
  - `month`: Extrae el mes de los valores de marca de tiempo (por ejemplo, 2023-01)
  - `day`: Extrae el día de los valores de la marca de tiempo (por ejemplo, 2023-01-15)
  - `hour`: Extrae la hora de los valores de la marca de tiempo (por ejemplo, 2023-01-15-14)
- `ConversionSpec`: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo.

  Especifica el formato de marca de tiempo de los datos de origen. Los valores válidos son:
  - `epoch_sec`: marca de tiempo en formato de época Unix (segundos)
  - `epoch_milli`: marca de tiempo en formato de época Unix (milisegundos)
  - `iso`: marca de tiempo en formato ISO 8601

  > **Note**
  >
  > Especifique `ConversionSpec` solo cuando use funciones de partición basadas en marcas de tiempo: año, mes, día u hora. AWS Glue La solución sin ETL usa este parámetro para transformar correctamente los datos de origen al formato de marca de tiempo antes de aplicar la partición.

No utilice columnas de alta cardinalidad con la función de partición `identity`. Las columnas de alta cardinalidad incluyen:

- Claves principales
- Campos de marca de tiempo (como `LastModifiedTimestamp`, `CreatedDate`)
- Marcas de tiempo generadas por el sistema

El uso de columnas de alta cardinalidad con particionamiento por identidad crea muchas particiones pequeñas, lo que puede degradar significativamente el rendimiento de la ingestión.

Estructura IntegrationError

Error asociado con una integración sin ETL.

Campos

- `ErrorCode`: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo.

  El código asociado a este error.
- `ErrorMessage`: cadena UTF-8 con una extensión de 1 byte como mínimo o 2048 bytes como máximo.

  Mensaje que describe el error.

Estructura IntegrationFilter

Un filtro que se puede utilizar al invocar una solicitud `DescribeIntegrations`.

Campos

- `Name`: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo.

  El nombre del filtro.
- `Values`: matriz de cadenas UTF-8.

  Una lista de valores de filtro.

Estructura InboundIntegration

Estructura de una integración que escribe datos en un recurso.

Campos

- `SourceArn`: requerido: cadena UTF-8 con una extensión de 1 byte como mínimo y 128 bytes como máximo.

  ARN del recurso de origen para la integración.
- `TargetArn`: requerido: cadena UTF-8 con una extensión de 1 byte como mínimo y 128 bytes como máximo.

  ARN del recurso de destino para la integración.
- `IntegrationArn`: requerido: cadena UTF-8 con una extensión de 1 byte como mínimo y 128 bytes como máximo.

  ARN de la integración sin ETL.
- `Status` – Obligatorio: cadena UTF-8 (valores válidos: `CREATING` | `ACTIVE` | `MODIFYING` | `FAILED` | `DELETING` | `SYNCING` | `NEEDS_ATTENTION`).

  Los posibles estados son:
  - CREATING: la integración se está creando.
  - ACTIVE: la creación de la integración se realizó correctamente.
  - MODIFYING: la integración se está modificando.
  - ERROR: error en la creación de la integración.
  - DELETING: se elimina la integración.
  - SYNCING: La integración se está sincronizando.
  - NEEDS_ATTENTION: la integración requiere atención, por ejemplo, la sincronización.
- `CreateTime` – Obligatorio: marca temporal.

  Hora (UTC) en la que se creó la integración.
- `IntegrationConfig`: un objeto IntegrationConfig.

  Propiedades asociadas con la integración.
- `Errors`: matriz de objetos IntegrationError.

Lista de errores asociados con la integración.

Estructura SourceProcessingProperties

Propiedades de recurso asociadas con el origen de la integración.

Campos

- `RoleArn`: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo.

  Rol de IAM para acceder a la conexión AWS Glue.

Estructura TargetProcessingProperties

Propiedades del recurso asociadas con el destino de la integración.

Campos

- `RoleArn`: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo.

  Rol de IAM para acceder a la base de datos AWS Glue.
- `KmsArn`: cadena UTF-8 con una extensión de 1 byte como mínimo o 2048 bytes como máximo.

  ARN de la clave de KMS que se utiliza para el cifrado.
- `ConnectionName`: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo.

  La conexión de red AWS Glue para configurar el trabajo AWS Glue que se ejecuta en la VPC del cliente.
- `EventBusArn`: cadena UTF-8 con una extensión de 1 byte como mínimo o 2048 bytes como máximo.

  ARN de un bus de eventos de Eventbridge para recibir la notificación del estado de la integración.

Estructura SourceTableConfig

Propiedades que utiliza el tramo de origen para procesar los datos del origen.

Campos

- `Fields`: matriz de cadenas UTF-8.

  Lista de campos que se utilizan en el filtrado a nivel de columna. No se admite actualmente.

- `FilterPredicate`: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo.

  Cláusula de condición que se utiliza en el filtrado a nivel de fila. No se admite actualmente.

- `PrimaryKey`: matriz de cadenas UTF-8.

  Proporcione el conjunto de clave principal para esta tabla. Actualmente, se admite específicamente para entidades `EntityOf` de SAP bajo petición. Póngase en contacto con el soporte de AWS para que esta característica esté disponible.

- `RecordUpdateField`: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo.

  Campo basado en una marca de tiempo de extracción incremental. No se admite actualmente.

Estructura TargetTableConfig

Propiedades que utiliza el tramo de destino para particionar los datos en el destino.

Campos

- `UnnestSpec` – Cadena UTF-8 (valores válidos: `TOPLEVEL` | `FULL` | `NOUNNEST`).

  Especifica cómo se aplanan los objetos anidados para convertirlos en elementos de nivel superior. Los valores válidos son: “TOPLEVEL”, “FULL” o “NOUNNEST”.

- `PartitionSpec`: matriz de objetos IntegrationPartition.

  Determina el diseño del archivo en el destino.

- `TargetTableName`: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo.

  Nombre opcional de una tabla de destino.

Operaciones

- Acción CreateIntegration (Python: create_integration)
- Acción ModificyIntegration (Python: modify_integration)
- Acción DescribeIntegrations (Python: describe_integrations)
- Acción DeleteIntegration (Python: delete_integration)
- Acción DescribeInboundIntegrations (Python: describe_inbound_integrations)
- Acción CreateIntegrationTableProperties (Python: create_integration_table_properties)
- Acción UpdateIntegrationTableProperties (Python: update_integration_properties)
- Acción GetIntegrationTableProperties (Python: get_integration_table_properties)
- Acción DeleteIntegrationTableProperties (Python: delete_integration_table_properties)
- Acción CreateIntegrationResourceProperty (Python: create_integration_resource_property)
- Acción UpdateIntegrationResourceProperty (Python: update_integration_resource_property)
- Acción GetIntegrationResourceProperty (Python: get_integration_resource_property)
- Acción UntagResource (Python: untag_resource)
- Acción ListTagsForResource (Python: list_tags_for_resource)

Acción CreateIntegration (Python: create_integration)

Crea una integración sin ETL en la cuenta de la persona que llama entre dos recursos con nombres de recursos de Amazon (ARN): `SourceArn` y `TargetArn`.

Solicitud

- `IntegrationName`: requerido: cadena UTF-8 con una extensión de 1 byte como mínimo y 128 bytes como máximo.

  Nombre único de la integración en AWS Glue.
- `SourceArn`: requerido: cadena UTF-8 con una extensión de 1 byte como mínimo y 128 bytes como máximo.

  ARN del recurso de origen para la integración.
- `TargetArn`: requerido: cadena UTF-8 con una extensión de 1 byte como mínimo y 128 bytes como máximo.

ARN del recurso de destino para la integración.

- `Description`: cadena UTF-8 con una extensión de 1000 bytes como máximo y que coincide con Custom string pattern #12.

  Descripción de la integración.

- `DataFilter`: cadena UTF-8 con una extensión de 1 byte como mínimo o 2048 bytes como máximo.

  Permite seleccionar las tablas de origen de la integración mediante la sintaxis de filtro de Maxwell.

- `KmsKeyId`: cadena UTF-8 con una extensión de 1 byte como mínimo o 2048 bytes como máximo.

  ARN de una clave de KMS que se utiliza para cifrar el canal.

- `AdditionalEncryptionContext`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8.

  Cada valor es una cadena UTF-8.

  Conjunto opcional de pares clave-valor no secretos que contienen información contextual adicional para el cifrado. Esto solo se puede proporcionar si `KMSKeyId` también se proporciona.

- `Tags`: matriz de objetos Tag.

  Metadatos que se asignan a un recurso que consta de una lista de pares clave-valor.

- `IntegrationConfig`: un objeto IntegrationConfig.

  Los ajustes de configuración

Respuesta

- `SourceArn`: requerido: cadena UTF-8 con una extensión de 1 byte como mínimo y 128 bytes como máximo.

  ARN del recurso de origen para la integración.

- `TargetArn`: requerido: cadena UTF-8 con una extensión de 1 byte como mínimo y 128 bytes como máximo.

  ARN del recurso de destino para la integración.

- `IntegrationName`: requerido: cadena UTF-8 con una extensión de 1 byte como mínimo y 128 bytes como máximo.

  Nombre único de la integración en AWS Glue.

- `Description`: cadena UTF-8 con una extensión de 1000 bytes como máximo y que coincide con Custom string pattern #12.

  Descripción de la integración.

- `IntegrationArn`: requerido: cadena UTF-8 con una extensión de 1 byte como mínimo y 128 bytes como máximo.

  Nombre de recurso de Amazon (ARN) de la integración creada.

- `KmsKeyId`: cadena UTF-8 con una extensión de 1 byte como mínimo o 2048 bytes como máximo.

  ARN de una clave de KMS que se utiliza para cifrar el canal.

- `AdditionalEncryptionContext`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8.

  Cada valor es una cadena UTF-8.

  Conjunto opcional de pares clave-valor no secretos que contienen información contextual adicional para el cifrado.

- `Tags`: matriz de objetos Tag.

  Metadatos que se asignan a un recurso que consta de una lista de pares clave-valor.

- `Status` – Obligatorio: cadena UTF-8 (valores válidos: `CREATING` | `ACTIVE` | `MODIFYING` | `FAILED` | `DELETING` | `SYNCING` | `NEEDS_ATTENTION`).

  Estado de la integración que se va a crear.

  Los posibles estados son:

  - CREATING: la integración se está creando.
  - ACTIVE: la creación de la integración se realizó correctamente.
  - MODIFYING: la integración se está modificando.
  - ERROR: error en la creación de la integración.
  - DELETING: se elimina la integración.

  - SYNCING: La integración se está sincronizando.
  - NEEDS_ATTENTION: la integración requiere atención, por ejemplo, la sincronización.
- `CreateTime` – Obligatorio: marca temporal.

  Hora (UTC) en la que se creó la integración.
- `Errors`: matriz de objetos IntegrationError.

  Lista de errores asociados con la creación de la integración.
- `DataFilter`: cadena UTF-8 con una extensión de 1 byte como mínimo o 2048 bytes como máximo.

  Permite seleccionar las tablas de origen de la integración mediante la sintaxis de filtro de Maxwell.
- `IntegrationConfig`: un objeto IntegrationConfig.

  Los ajustes de configuración

Errores

- `ValidationException`
- `AccessDeniedException`
- `ResourceNotFoundException`
- `InternalServerException`
- `IntegrationConflictOperationFault`
- `IntegrationQuotaExceededFault`
- `KMSKeyNotAccessibleFault`
- `EntityNotFoundException`
- `InternalServiceException`
- `ConflictException`
- `ResourceNumberLimitExceededException`
- `InvalidInputException`

Acción ModificyIntegration (Python: modify_integration)

Modifica una integración sin ETL en la cuenta de la persona que llama.

Solicitud

- `IntegrationIdentifier`: requerido: cadena UTF-8 con una extensión de 1 byte como mínimo y 128 bytes como máximo.

  Nombre de recurso de Amazon (ARN) de la integración.
- `Description`: cadena UTF-8 con una extensión de 1000 bytes como máximo y que coincide con Custom string pattern #12.

  Descripción de la integración.
- `DataFilter`: cadena UTF-8 con una extensión de 1 byte como mínimo o 2048 bytes como máximo.

  Permite seleccionar las tablas de origen de la integración mediante la sintaxis de filtro de Maxwell.
- `IntegrationConfig`: un objeto IntegrationConfig.

  Los ajustes de configuración de la integración. Actualmente, solo se puede modificar el RefreshInterval.
- `IntegrationName`: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo.

  Nombre único de la integración en AWS Glue.

Respuesta

- `SourceArn`: requerido: cadena UTF-8 con una extensión de 1 byte como mínimo y 128 bytes como máximo.

  ARN del origen de la integración.
- `TargetArn`: requerido: cadena UTF-8 con una extensión de 1 byte como mínimo y 128 bytes como máximo.

  ARN del destino de la integración.
- `IntegrationName`: requerido: cadena UTF-8 con una extensión de 1 byte como mínimo y 128 bytes como máximo.

  Nombre único de la integración en AWS Glue.

- `Description`: cadena UTF-8 con una extensión de 1000 bytes como máximo y que coincide con Custom string pattern #12.

  Descripción de la integración.

- `IntegrationArn`: requerido: cadena UTF-8 con una extensión de 1 byte como mínimo y 128 bytes como máximo.

  Nombre de recurso de Amazon (ARN) de la integración.

- `KmsKeyId`: cadena UTF-8 con una extensión de 1 byte como mínimo o 2048 bytes como máximo.

  ARN de una clave de KMS que se utiliza para cifrar el canal.

- `AdditionalEncryptionContext`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8.

  Cada valor es una cadena UTF-8.

  Conjunto opcional de pares clave-valor no secretos que contienen información contextual adicional para el cifrado.

- `Tags`: matriz de objetos Tag.

  Metadatos que se asignan a un recurso que consta de una lista de pares clave-valor.

- `Status` – Obligatorio: cadena UTF-8 (valores válidos: `CREATING` | `ACTIVE` | `MODIFYING` | `FAILED` | `DELETING` | `SYNCING` | `NEEDS_ATTENTION`).

  Estado de la integración que se va a modificar.

  Los posibles estados son:

  - CREATING: la integración se está creando.
  - ACTIVE: la creación de la integración se realizó correctamente.
  - MODIFYING: la integración se está modificando.
  - ERROR: error en la creación de la integración.
  - DELETING: se elimina la integración.
  - SYNCING: La integración se está sincronizando.
  - NEEDS_ATTENTION: la integración requiere atención, por ejemplo, la sincronización.

- `CreateTime` – Obligatorio: marca temporal.

Hora (UTC) en la que se creó la integración.

- `Errors`: matriz de objetos IntegrationError.

  Lista de errores asociados a la modificación de la integración.

- `DataFilter`: cadena UTF-8 con una extensión de 1 byte como mínimo o 2048 bytes como máximo.

  Permite seleccionar las tablas de origen de la integración mediante la sintaxis de filtro de Maxwell.

- `IntegrationConfig`: un objeto IntegrationConfig.

  La configuración actualizada de la integración.

Errores

- `ValidationException`
- `AccessDeniedException`
- `InternalServerException`
- `IntegrationNotFoundFault`
- `IntegrationConflictOperationFault`
- `InvalidIntegrationStateFault`
- `EntityNotFoundException`
- `InternalServiceException`
- `ConflictException`
- `InvalidStateException`
- `InvalidInputException`

Acción DescribeIntegrations (Python: describe_integrations)

La API se utiliza para recuperar una lista de integraciones.

Solicitud

- `IntegrationIdentifier`: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo.

Nombre de recurso de Amazon (ARN) de la integración.

- `Marker`: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo.

  Valor que indica el punto de partida del siguiente conjunto de registros de respuesta en una solicitud posterior.

- `MaxRecords`: número (entero).

  El número total de elementos que se devuelven en la salida.

- `Filters`: matriz de objetos IntegrationFilter.

  Lista de claves y valores para filtrar los resultados. Las claves compatibles son “Status”, “IntegrationName” y “SourceArn”. IntegrationName está limitado a un solo valor.

Respuesta

- `Integrations`: matriz de objetos Integración.

  Una lista de integraciones sin ETL.

- `Marker`: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo.

  Valor que indica el punto de partida del siguiente conjunto de registros de respuesta en una solicitud posterior.

Errores

- `ValidationException`
- `AccessDeniedException`
- `InternalServerException`
- `IntegrationNotFoundFault`
- `EntityNotFoundException`
- `InternalServiceException`
- `InvalidInputException`

Acción DeleteIntegration (Python: delete_integration)

Elimina la integración sin ETL especificada.

Solicitud

- `IntegrationIdentifier`: requerido: cadena UTF-8 con una extensión de 1 byte como mínimo y 128 bytes como máximo.

  Nombre de recurso de Amazon (ARN) de la integración.

Respuesta

- `SourceArn`: requerido: cadena UTF-8 con una extensión de 1 byte como mínimo y 128 bytes como máximo.

  ARN del origen de la integración.
- `TargetArn`: requerido: cadena UTF-8 con una extensión de 1 byte como mínimo y 128 bytes como máximo.

  ARN del destino de la integración.
- `IntegrationName`: requerido: cadena UTF-8 con una extensión de 1 byte como mínimo y 128 bytes como máximo.

  Nombre único de la integración en AWS Glue.
- `Description`: cadena UTF-8 con una extensión de 1000 bytes como máximo y que coincide con Custom string pattern #12.

  Descripción de la integración.
- `IntegrationArn`: requerido: cadena UTF-8 con una extensión de 1 byte como mínimo y 128 bytes como máximo.

  Nombre de recurso de Amazon (ARN) de la integración.
- `KmsKeyId`: cadena UTF-8 con una extensión de 1 byte como mínimo o 2048 bytes como máximo.

  ARN de una clave de KMS que se utiliza para cifrar el canal.
- `AdditionalEncryptionContext`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8.

Cada valor es una cadena UTF-8.

Conjunto opcional de pares clave-valor no secretos que contienen información contextual adicional para el cifrado.

- `Tags`: matriz de objetos Tag.

  Metadatos que se asignan a un recurso que consta de una lista de pares clave-valor.

- `Status` – Obligatorio: cadena UTF-8 (valores válidos: `CREATING` | `ACTIVE` | `MODIFYING` | `FAILED` | `DELETING` | `SYNCING` | `NEEDS_ATTENTION`).

  Estado de la integración que se va a eliminar.

  Los posibles estados son:

  - CREATING: la integración se está creando.
  - ACTIVE: la creación de la integración se realizó correctamente.
  - MODIFYING: la integración se está modificando.
  - ERROR: error en la creación de la integración.
  - DELETING: se elimina la integración.
  - SYNCING: La integración se está sincronizando.
  - NEEDS_ATTENTION: la integración requiere atención, por ejemplo, la sincronización.

- `CreateTime` – Obligatorio: marca temporal.

  Hora (UTC) en la que se creó la integración.

- `Errors`: matriz de objetos IntegrationError.

  Lista de errores asociados con la integración.

- `DataFilter`: cadena UTF-8 con una extensión de 1 byte como mínimo o 2048 bytes como máximo.

  Permite seleccionar las tablas de origen de la integración mediante la sintaxis de filtro de Maxwell.

Errores

- `ValidationException`
- `AccessDeniedException`

- `InternalServerException`
- `IntegrationNotFoundFault`
- `IntegrationConflictOperationFault`
- `InvalidIntegrationStateFault`
- `EntityNotFoundException`
- `InternalServiceException`
- `ConflictException`
- `InvalidStateException`
- `InvalidInputException`

Acción DescribeInboundIntegrations (Python: describe_inbound_integrations)

Devuelve una lista de integraciones entrantes para la integración especificada.

Solicitud

- `IntegrationArn`: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo.

  Nombre de recurso de Amazon (ARN) de la integración.
- `Marker`: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo.

  Un token destinado a especificar dónde iniciar la paginación. Es el marcador de una respuesta truncada anteriormente.
- `MaxRecords`: número (entero).

  El número total de elementos que se devuelven en la salida.
- `TargetArn`: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo.

  Nombre de recurso de Amazon (ARN) del recurso de destino de la integración.

Respuesta

- `InboundIntegrations`: matriz de objetos InboundIntegration.

Lista de integraciones entrantes.

- `Marker`: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo.

  Valor que indica el punto de partida del siguiente conjunto de registros de respuesta en una solicitud posterior.

Errores

- `ValidationException`
- `AccessDeniedException`
- `InternalServerException`
- `IntegrationNotFoundFault`
- `TargetResourceNotFound`
- `OperationNotSupportedException`
- `EntityNotFoundException`
- `InternalServiceException`
- `InvalidInputException`

Acción CreateIntegrationTableProperties (Python: create_integration_table_properties)

Esta API se utiliza para proporcionar propiedades de anulación opcionales en las tablas que se deben replicar. Estas propiedades pueden incluir propiedades para filtrar y particionar las tablas de origen y destino. Para establecer las propiedades de origen y destino, debe invocar a la misma API con el ARN de conexión AWS Glue como `ResourceArn` con `SourceTableConfig`, y el ARN de la base de datos AWS Glue como `ResourceArn` con `TargetTableConfig` respectivamente.

Solicitud

- `ResourceArn`: requerido: cadena UTF-8 con una extensión de 1 byte como mínimo y 128 bytes como máximo.

  Nombre de recurso de Amazon (ARN) de la tabla de destino para la cual se crearán las propiedades de la tabla de integración. Actualmente, esta API solo admite la creación de

propiedades de tabla de integración para tablas de destino, y el ARN proporcionado debe corresponder al de la tabla de destino en el Catálogo de datos de AWS Glue. La posibilidad de crear propiedades de tablas de integración para conexiones de origen (mediante el ARN de la conexión) aún no está disponible y se incorporará en una versión futura.

- `TableName`: requerido: cadena UTF-8 con una extensión de 1 byte como mínimo y 128 bytes como máximo.

  El nombre de la tabla que se va a replicar.

- `SourceTableConfig`: un objeto SourceTableConfig.

  Una estructura para la configuración de la tabla de origen. Consulte la estructura `SourceTableConfig` para ver la lista de propiedades de origen compatibles.

- `TargetTableConfig`: un objeto TargetTableConfig.

  Una estructura para la configuración de la tabla de destino.

Respuesta

- Sin parámetros de respuesta.

Errores

- `ValidationException`
- `AccessDeniedException`
- `ResourceNotFoundException`
- `InternalServerException`
- `EntityNotFoundException`
- `InternalServiceException`
- `InvalidInputException`

Acción UpdateIntegrationTableProperties (Python: update_integration_properties)

Esta API se utiliza para proporcionar propiedades de anulación opcionales en las tablas que se deben replicar. Estas propiedades pueden incluir propiedades para filtrar y particionar las tablas de

origen y destino. Para establecer las propiedades de origen y destino, debe invocar a la misma API con el ARN de conexión AWS Glue como `ResourceArn` con `SourceTableConfig`, y el ARN de la base de datos AWS Glue como `ResourceArn` con `TargetTableConfig` respectivamente.

La anulación se reflejará en todas las integraciones que usen la misma `ResourceArn` y tabla de origen.

Solicitud

- `ResourceArn`: requerido: cadena UTF-8 con una extensión de 1 byte como mínimo y 128 bytes como máximo.

  ARN de conexión del origen o el ARN de la base de datos del destino.
- `TableName`: requerido: cadena UTF-8 con una extensión de 1 byte como mínimo y 128 bytes como máximo.

  El nombre de la tabla que se va a replicar.
- `SourceTableConfig`: un objeto SourceTableConfig.

  Una estructura para la configuración de la tabla de origen.
- `TargetTableConfig`: un objeto TargetTableConfig.

  Una estructura para la configuración de la tabla de destino.

Respuesta

- Sin parámetros de respuesta.

Errores

- `ValidationException`
- `AccessDeniedException`
- `ResourceNotFoundException`
- `InternalServerException`
- `EntityNotFoundException`
- `InternalServiceException`
- `InvalidInputException`

Acción GetIntegrationTableProperties (Python: get_integration_table_properties)

Esta API se utiliza para recuperar propiedades de anulación opcionales en las tablas que se deben replicar. Estas propiedades pueden incluir propiedades para filtrar y particionar las tablas de origen y destino.

Solicitud

- `ResourceArn`: requerido: cadena UTF-8 con una extensión de 1 byte como mínimo y 128 bytes como máximo.

  Nombre de recurso de Amazon (ARN) de la tabla de destino desde la cual se recuperarán las propiedades de la tabla de integración. Actualmente, esta API solo permite recuperar propiedades de tablas de destino, y el ARN proporcionado debe corresponder al de la tabla de destino en el Catálogo de datos de AWS Glue. Actualmente no está disponible la opción de recuperar las propiedades de la tabla de integración para conexiones de origen (mediante el ARN de la conexión). Esta funcionalidad se añadirá en una próxima versión.
- `TableName`: requerido: cadena UTF-8 con una extensión de 1 byte como mínimo y 128 bytes como máximo.

  El nombre de la tabla que se va a replicar.

Respuesta

- `ResourceArn`: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo.

  Nombre de recurso de Amazon (ARN) de la tabla de destino desde la cual se recuperarán las propiedades de la tabla de integración. Actualmente, esta API solo permite recuperar propiedades de tablas de destino, y el ARN proporcionado debe corresponder al de la tabla de destino en el Catálogo de datos de AWS Glue. Actualmente no está disponible la opción de recuperar las propiedades de la tabla de integración para conexiones de origen (mediante el ARN de la conexión). Esta funcionalidad se añadirá en una próxima versión.
- `TableName`: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo.

  El nombre de la tabla que se va a replicar.
- `SourceTableConfig`: un objeto SourceTableConfig.

Una estructura para la configuración de la tabla de origen.

- `TargetTableConfig`: un objeto TargetTableConfig.

  Una estructura para la configuración de la tabla de destino.

Errores

- `ValidationException`
- `AccessDeniedException`
- `ResourceNotFoundException`
- `InternalServerException`
- `EntityNotFoundException`
- `InternalServiceException`
- `InvalidInputException`

Acción DeleteIntegrationTableProperties (Python: delete_integration_table_properties)

Elimina las propiedades de la tabla que se crearon para las tablas que tenga que replicar.

Solicitud

- `ResourceArn`: requerido: cadena UTF-8 con una extensión de 1 byte como mínimo y 128 bytes como máximo.

  ARN de conexión del origen o el ARN de la base de datos del destino.
- `TableName`: requerido: cadena UTF-8 con una extensión de 1 byte como mínimo y 128 bytes como máximo.

  El nombre de la tabla que se va a replicar.

Respuesta

- Sin parámetros de respuesta.

Errores

- `ValidationException`
- `AccessDeniedException`
- `ResourceNotFoundException`
- `InternalServerException`
- `EntityNotFoundException`
- `InternalServiceException`
- `InvalidInputException`

Acción CreateIntegrationResourceProperty (Python: create_integration_resource_property)

Esta API se puede utilizar para configurar `ResourceProperty` de la conexión de AWS Glue (del origen) o el ARN de la base de datos de AWS Glue (del destino). Estas propiedades pueden incluir el rol de acceso a la conexión o base de datos. Para establecer las propiedades de origen y destino, debe invocar a la misma API con el ARN de conexión AWS Glue como `ResourceArn` con `SourceProcessingProperties`, y el ARN de la base de datos AWS Glue como `ResourceArn` con `TargetProcessingProperties` respectivamente.

Solicitud

- `ResourceArn`: requerido: cadena UTF-8 con una extensión de 1 byte como mínimo y 128 bytes como máximo.

  ARN de conexión del origen o el ARN de la base de datos del destino.
- `SourceProcessingProperties`: un objeto SourceProcessingProperties.

  Propiedades de recurso asociadas con el origen de la integración.
- `TargetProcessingProperties`: un objeto TargetProcessingProperties.

  Propiedades del recurso asociadas con el destino de la integración.

Respuesta

- `ResourceArn`: requerido: cadena UTF-8 con una extensión de 1 byte como mínimo y 128 bytes como máximo.

  ARN de conexión del origen o el ARN de la base de datos del destino.
- `SourceProcessingProperties`: un objeto SourceProcessingProperties.

  Propiedades de recurso asociadas con el origen de la integración.
- `TargetProcessingProperties`: un objeto TargetProcessingProperties.

  Propiedades del recurso asociadas con el destino de la integración.

Errores

- `ValidationException`
- `AccessDeniedException`
- `ConflictException`
- `InternalServerException`
- `ResourceNotFoundException`
- `EntityNotFoundException`
- `InternalServiceException`
- `InvalidInputException`

Acción UpdateIntegrationResourceProperty (Python: update_integration_resource_property)

Esta API se puede utilizar para actualizar `ResourceProperty` de la conexión de AWS Glue (del origen) o el ARN de la base de datos de AWS Glue (del destino). Estas propiedades pueden incluir el rol de acceso a la conexión o base de datos. Como el mismo recurso se puede utilizar en varias integraciones, la actualización de las propiedades del recurso afectará a todas las integraciones que lo utilicen.

Solicitud

- `ResourceArn`: requerido: cadena UTF-8 con una extensión de 1 byte como mínimo y 128 bytes como máximo.

  ARN de conexión del origen o el ARN de la base de datos del destino.
- `SourceProcessingProperties`: un objeto SourceProcessingProperties.

  Propiedades de recurso asociadas con el origen de la integración.
- `TargetProcessingProperties`: un objeto TargetProcessingProperties.

  Propiedades del recurso asociadas con el destino de la integración.

Respuesta

- `ResourceArn`: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo.

  ARN de conexión del origen o el ARN de la base de datos del destino.
- `SourceProcessingProperties`: un objeto SourceProcessingProperties.

  Propiedades de recurso asociadas con el origen de la integración.
- `TargetProcessingProperties`: un objeto TargetProcessingProperties.

  Propiedades del recurso asociadas con el destino de la integración.

Errores

- `ValidationException`
- `AccessDeniedException`
- `InternalServerException`
- `ResourceNotFoundException`
- `EntityNotFoundException`
- `InternalServiceException`
- `InvalidInputException`

Acción GetIntegrationResourceProperty (Python: get_integration_resource_property)

Esta API se puede utilizar para obtener `ResourceProperty` de la conexión de AWS Glue (del origen) o el ARN de la base de datos de AWS Glue (del destino).

Solicitud

- `ResourceArn`: requerido: cadena UTF-8 con una extensión de 1 byte como mínimo y 128 bytes como máximo.

  ARN de conexión del origen o el ARN de la base de datos del destino.

Respuesta

- `ResourceArn`: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo.

  ARN de conexión del origen o el ARN de la base de datos del destino.
- `SourceProcessingProperties`: un objeto SourceProcessingProperties.

  Propiedades de recurso asociadas con el origen de la integración.
- `TargetProcessingProperties`: un objeto TargetProcessingProperties.

  Propiedades del recurso asociadas con el destino de la integración.

Errores

- `ValidationException`
- `AccessDeniedException`
- `InternalServerException`
- `ResourceNotFoundException`
- `EntityNotFoundException`
- `InternalServiceException`
- `InvalidInputException`

Acción UntagResource (Python: untag_resource)

Quita las etiquetas especificadas de un recurso de integración.

Solicitud

- `ResourceArn` – Obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 10 240 bytes de largo como máximo, que coincide con el Custom string pattern #50.

  Nombre de recurso de Amazon (ARN) del recurso de integración.
- `TagsToRemove` – Obligatorio: matriz de cadenas UTF-8, con 50 cadenas como máximo.

  Una lista de las etiquetas de metadatos que se eliminará del recurso.

Respuesta

- Sin parámetros de respuesta.

Errores

- `ResourceNotFoundException`

Acción ListTagsForResource (Python: list_tags_for_resource)

Enumera las etiquetas de metadatos que asignó al recurso especificado.

Solicitud

- `ResourceARN` – Obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 10 240 bytes de largo como máximo, que coincide con el Custom string pattern #50.

  El ARN de recurso del recurso.

Respuesta

- `Tags`: matriz de objetos Tag, con 10 estructuras como máximo.

  Una lista de etiquetas.

Errores

- `ResourceNotFoundException`

Excepciones

- Estructura ResourceNotFoundException
- Estructura InternalServerException
- Estructura IntegrationAlreadyExistsFault
- Estructura IntegrationConflictOperationFault
- Estructura IntegrationQuotaExceededFault
- Estructura KMSKeyNotAccessibleFault
- Estructura IntegrationNotFoundFault
- Estructura TargetResourceNotFound
- Estructura InvalidIntegrationStateFault

Estructura ResourceNotFoundException

No se pudo encontrar el recurso.

Campos

- `Message`: cadena UTF-8.

  Mensaje que describe el problema.

Estructura InternalServerException

Se ha producido un error interno del servidor.

Campos

- `Message`: cadena UTF-8.

  Mensaje que describe el problema.

Estructura IntegrationAlreadyExistsFault

La integración especificada ya existe.

Campos

- `Message`: cadena UTF-8.

  Mensaje que describe el problema.

Estructura IntegrationConflictOperationFault

La operación solicitada entra en conflicto con otra operación.

Campos

- `Message`: cadena UTF-8.

  Mensaje que describe el problema.

Estructura IntegrationQuotaExceededFault

Los datos procesados a través de su integración superaron su cuota.

Campos

- `Message`: cadena UTF-8.

  Mensaje que describe el problema.

Estructura KMSKeyNotAccessibleFault

No se puede acceder a la clave KMS especificada.

Campos

- `Message`: cadena UTF-8.

  Mensaje que describe el problema.

Estructura IntegrationNotFoundFault

No se pudo encontrar la integración especificada.

Campos

- `Message`: cadena UTF-8.

  Mensaje que describe el problema.

Estructura TargetResourceNotFound

No se pudo encontrar el recurso de destino.

Campos

- `Message`: cadena UTF-8.

  Mensaje que describe el problema.

Estructura InvalidIntegrationStateFault

La integración se encuentra en un estado que no es válido.

Campos

- `Message`: cadena UTF-8.

  Mensaje que describe el problema.

API de sesiones interactivas

La API de sesiones interactivas describe la API AWS Glue relacionada con el uso de sesiones interactivas AWS Glue para crear y probar scripts de extracción, transformación y carga (ETL) para la integración de datos.

Tipos de datos

- Estructura de sesión

- Estructura SessionCommand
- Estructura de instrucción
- Estructura SchetumentOutput
- Estructura StatementOutputData
- Estructura ConnectionsList

Estructura de sesión

El período en el que se ejecuta un entorno en tiempo de ejecución de Spark remoto.

Campos

- `Id` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de la sesión.
- `CreatedOn`: marca temporal.

  La fecha y hora en que se creó la sesión.
- `Status` – cadena UTF-8 (valores válidos: `PROVISIONING` | `READY` | `FAILED` | `TIMEOUT` | `STOPPING` | `STOPPED`).

  El estado de la sesión.
- `ErrorMessage` – cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  El mensaje de error que se muestra durante la sesión.
- `Description` – cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  La descripción de la sesión.
- `Role` – cadena UTF-8, con 20 bytes como mínimo o más de 2048 bytes de largo, que coincide con el Custom string pattern #30.

  El nombre o nombre de recurso de Amazon (ARN) del rol de IAM asociado a la sesión.
- `Command`: un objeto SessionCommand.

El objeto de comando. Consulte SessionCommand.

- `DefaultArguments`: matriz de asignación de pares de clave-valor, con 75 pares como máximo.

  Cada clave es una cadena UTF-8 con 1 byte de largo como mínimo y 128 bytes de largo como máximo, que coincide con Custom string pattern #31.

  Cada valor es una cadena UTF-8, con 4096 bytes de largo como máximo, que coincide con URI address multi-line string pattern.

  Una matriz de mapas de pares clave-valor. El máximo es de 75 pares.

- `Connections`: un objeto ConnectionsList.

  El número de conexiones utilizadas para la sesión.

- `Progress`: número (doble).

  El progreso de la ejecución del código de la sesión.

- `MaxCapacity`: número (doble).

  El número de unidades de procesamiento de datos (DPU) de AWS Glue que se pueden asignar cuando se ejecute el trabajo. Una DPU es una medida relativa de la potencia de procesamiento que consta de 4 vCPU de capacidad de computación y 16 GB de memoria.

- `SecurityConfiguration` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la estructura SecurityConfiguration que se va a utilizar con la sesión.

- `GlueVersion` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #48.

  La versión de AWS Glue determina las versiones de Apache Spark y Python que admite AWS Glue. La GlueVersion debe ser superior a 2.0.

- `DataAccessId`: cadena UTF-8, con 1 byte como mínimo o más de 36 bytes de largo.

  El ID de acceso a datos de la sesión.

- `PartitionId`: cadena UTF-8, con 1 byte como mínimo o más de 36 bytes de largo.

  El ID de partición de la sesión.

- `NumberOfWorkers`: número (entero).

El número de trabajadores de una `WorkerType` definida para usar para la sesión.

- `WorkerType` – Cadena UTF-8 (valores válidos: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

  El tipo de trabajador predefinido que se asigna cuando se ejecuta una sesión. Acepta un valor de `G.1X`, `G.2X`, `G.4X` o `G.8X` para las sesiones de Spark. Acepta el valor `Z.2X` para las sesiones de Ray.
- `CompletedOn`: marca temporal.

  La fecha y la hora en que se completó la ejecución de esta sesión.
- `ExecutionTime`: número (doble).

  El tiempo total de duración de la sesión.
- `DPUSeconds`: número (doble).

  Las DPU consumidas por la sesión (fórmula: ExecutionTime * MaxCapacity).
- `IdleTimeout`: número (entero).

  Número de minutos sin actividad antes de que se agote el tiempo de espera de la sesión.
- `ProfileName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de un perfil de utilización de AWS Glue asociado a la sesión.

Estructura SessionCommand

El `SessionCommand` que ejecuta este trabajo.

Campos

- `Name` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Especifica el nombre del SessionCommand. Puede ser “glueetl” o “gluestreaming”.
- `PythonVersion` – cadena UTF-8 que coincide con el Custom string pattern #49.

  Especifica la versión de Python. La versión de Python indica la versión admitida para trabajos de tipo Spark.

Estructura de instrucción

La instrucción o solicitud de que se produzca una acción concreta en una sesión.

Campos

- `Id`: número (entero).

  El ID de la instrucción.
- `Code`: cadena UTF-8.

  El código de ejecución de la instrucción.
- `State` – cadena UTF-8 (valores válidos: `WAITING` | `RUNNING` | `AVAILABLE` | `CANCELLING` | `CANCELLED` | `ERROR`).

  El estado mientras se ejecuta la solicitud.
- `Output`: un objeto StatementOutput.

  El resultado en JSON.
- `Progress`: número (doble).

  El progreso de ejecución del código.
- `StartedOn`: número (largo).

  La fecha y hora unix en que se inició la definición del trabajo.
- `CompletedOn`: número (largo).

  La fecha y hora unix en que se completó la definición del trabajo.

Estructura SchetumentOutput

El resultado de la ejecución de código en formato JSON.

Campos

- `Data`: un objeto StatementOutputData.

  El resultado de la ejecución de código.
- `ExecutionCount`: número (entero).

El recuento de ejecución del resultado.

- `Status` – cadena UTF-8 (valores válidos: `WAITING` | `RUNNING` | `AVAILABLE` | `CANCELLING` | `CANCELLED` | `ERROR`).

  El estado del resultado de ejecución de código.

- `ErrorName`: cadena UTF-8.

  El nombre del error en el resultado.

- `ErrorValue`: cadena UTF-8.

  El valor de error del resultado.

- `Traceback`: matriz de cadenas UTF-8.

  El seguimiento del resultado.

Estructura StatementOutputData

El resultado de la ejecución de código en formato JSON.

Campos

- `TextPlain`: cadena UTF-8.

  El resultado de la ejecución de código en formato de texto.

Estructura ConnectionsList

Especifica las conexiones que utiliza un flujo de trabajo.

Campos

- `Connections`: una matriz de cadenas UTF-8, con 1000 cadenas como máximo.

  Lista de conexiones que utiliza el flujo de trabajo.

Operaciones

- Acción CreateSession (Python: create_session)

- Acción StopSession (Python: stop_session)
- Acción DeleteSession (Python: delete_session)
- Acción GetSession (Python: get_session)
- Acción ListSessions (Python: list_sessions)
- Acción RunStatement (Python: run_statement)
- Acción CancelStatement (Python: cancel_statement)
- Acción GetStatement (Python: get_statement)
- Acción ListStatements (Python: list_statement)
- Acción GetGlueIdentityCenterConfiguration (Python: get_glue_identity_center_configuration)
- Acción UpdateBlueIdentityCenterConfiguration (Python: update_glue_identity_center_configuration)
- Acción CreateBlueIdentityCenter_Configuration (Python: create_glue_identity_center_configuration)
- Acción DeleteGlueIdentityCenterConfiguration (Python: delete_glue_identity_center_configuration)

Acción CreateSession (Python: create_session)

Crea una nueva sesión.

Solicitud

Solicitud para crear una nueva sesión.

- `Id`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de la solicitud de sesión.
- `Description` – cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  La descripción de la sesión.
- `Role`: obligatorio: cadena UTF-8, con 20 bytes de largo o más de 2048 bytes de largo, que coincide con el Custom string pattern #30.

  El ARN del rol de IAM
- `Command`: obligatorio: objeto SessionCommand.

El `SessionCommand` que pone en marcha el trabajo.

- `Timeout`: número (entero), como mínimo 1.

  Número de minutos que deben transcurrir para que se agote el tiempo de espera de la sesión. El valor predeterminado para trabajos ETL de Spark es de 48 horas (2880 minutos). Consulte la documentación para otros tipos de trabajo.

- `IdleTimeout`: número (entero), como mínimo 1.

  Número de minutos sin actividad que deben transcurrir para que se agote el tiempo de espera de la sesión. El valor predeterminado para los trabajos de ETL de Spark es el valor de Tiempo de espera. Consulte la documentación para otros tipos de trabajo.

- `DefaultArguments`: matriz de asignación de pares de clave-valor, con 75 pares como máximo.

  Cada clave es una cadena UTF-8 con 1 byte de largo como mínimo y 128 bytes de largo como máximo, que coincide con Custom string pattern #31.

  Cada valor es una cadena UTF-8, con 4096 bytes de largo como máximo, que coincide con URI address multi-line string pattern.

  Una matriz de mapas de pares clave-valor. El máximo es de 75 pares.

- `Connections`: un objeto ConnectionsList.

  Número de conexiones que se van a utilizar para la sesión.

- `MaxCapacity`: número (doble).

  El número de unidades de procesamiento de datos (DPU) de AWS Glue que se pueden asignar cuando se ejecute el trabajo. Una DPU es una medida relativa de la potencia de procesamiento que consta de 4 vCPU de capacidad de computación y 16 GB de memoria.

- `NumberOfWorkers`: número (entero).

  El número de trabajadores de una `WorkerType` definida para usar para la sesión.

- `WorkerType` – Cadena UTF-8 (valores válidos: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

  El tipo de proceso de trabajo predefinido que se asigna cuando se ejecuta un trabajo. Acepta un valor de G.1X, G.2X, G.4X o G.8X para los trabajos de Spark. Acepta el valor Z.2X para los portátiles Ray.

- Para el tipo de proceso de trabajo `G.1X`, cada proceso de trabajo se asocia a 1 DPU (4 vCPU, 16 GB de memoria) con un disco de 94 GB y proporciona 1 ejecutor por proceso de trabajo. Recomendamos este tipo de trabajador para cargas de trabajo como transformaciones de datos, uniones y consultas, ya que ofrece una forma escalable y rentable de ejecutar la mayoría de los trabajos.
- Para el tipo de proceso de trabajo `G.2X`, cada proceso de trabajo se asocia a 2 DPU (8 vCPU, 32 GB de memoria) con un disco de 138 GB y proporciona 1 ejecutor por proceso de trabajo. Recomendamos este tipo de trabajador para cargas de trabajo como transformaciones de datos, uniones y consultas, ya que ofrece una forma escalable y rentable de ejecutar la mayoría de los trabajos.
- Para el tipo de proceso de trabajo `G.4X`, cada proceso de trabajo se asocia a 4 DPU (16 vCPU, 64 GB de memoria) con un disco de 256 GB y proporciona 1 ejecutor por proceso de trabajo. Recomendamos este tipo de trabajador para los trabajos cuyas cargas de trabajo contengan las transformaciones, agregaciones, uniones y consultas más exigentes. Este tipo de trabajador solo está disponible para los trabajos de Spark ETL de la versión 3.0 de AWS Glue o posteriores en las siguientes regiones de AWS: Este de EE. UU. (Ohio), Este de EE. UU. (Norte de Virginia), Oeste de EE. UU. (Oregón), Asia Pacífico (Singapur), Asia Pacífico (Sídney), Asia Pacífico (Tokio), Canadá (centro), Europa (Fráncfort), Europa (Irlanda) y Europa (Estocolmo).
- Para el tipo de proceso de trabajo `G.8X`, cada proceso de trabajo se asocia a 8 DPU (32 vCPU, 128 GB de memoria) con un disco de 512 GB y proporciona 1 ejecutor por proceso de trabajo. Recomendamos este tipo de trabajador para los trabajos cuyas cargas de trabajo contengan las transformaciones, agregaciones, uniones y consultas más exigentes. Este tipo de trabajador solo está disponible para los trabajos ETL de Spark de la versión 3.0 de AWS Glue o posteriores, en las mismas regiones de AWS compatibles con el tipo de trabajador `G.4X`.
- Para el tipo de proceso de trabajo `Z.2X`, cada proceso de trabajo se asocia a 2 M-DPU (8 vCPU, 64 GB de memoria) con un disco de 128 GB y proporciona hasta 8 procesos de trabajo de Ray en función del escalador automático.

- `SecurityConfiguration` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la estructura SecurityConfiguration que se va a utilizar con la sesión

- `GlueVersion` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #48.

  La versión de AWS Glue determina las versiones de Apache Spark y Python que admite AWS Glue. La GlueVersion debe ser superior a 2.0.

- `DataAccessId`: cadena UTF-8, con 1 byte como mínimo o más de 36 bytes de largo.

  El ID de acceso a datos de la sesión.
- `PartitionId`: cadena UTF-8, con 1 byte como mínimo o más de 36 bytes de largo.

  El ID de partición de la sesión.
- `Tags`: matriz de mapas de pares de clave-valor, con 50 pares como máximo.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es una cadena UTF-8 que no tiene más de 256 bytes de largo.

  El mapa de pares de valor de clave (etiquetas) pertenecientes a la sesión.
- `RequestOrigin` – cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo, que coincide con el Custom string pattern #31.

  El origen de la solicitud.
- `ProfileName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de un perfil de utilización de AWS Glue asociado a la sesión.

Respuesta

- `Session`: un objeto Sesión.

  Arroja el objeto de la sesión en la respuesta.

Errores

- `AccessDeniedException`
- `IdempotentParameterMismatchException`
- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`
- `ValidationException`
- `AlreadyExistsException`

- `ResourceNumberLimitExceededException`

Acción StopSession (Python: stop_session)

Detiene la sesión.

Solicitud

- `Id`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de la sesión que se va a detener.
- `RequestOrigin` – cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo, que coincide con el Custom string pattern #31.

  El origen de la solicitud.

Respuesta

- `Id` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Arroja el ID de la sesión detenida.

Errores

- `AccessDeniedException`
- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`
- `IllegalSessionStateException`
- `ConcurrentModificationException`

Acción DeleteSession (Python: delete_session)

Elimina la sesión.

Solicitud

- `Id`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de la sesión que se va a eliminar.
- `RequestOrigin` – cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo, que coincide con el Custom string pattern #31.

  El nombre del origen de la solicitud de eliminación de sesión.

Respuesta

- `Id` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Arroja el ID de la sesión eliminada.

Errores

- `AccessDeniedException`
- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`
- `IllegalSessionStateException`
- `ConcurrentModificationException`

Acción GetSession (Python: get_session)

Recupera la sesión.

Solicitud

- `Id`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Token de continuación si todavía no se arrojaron todas las instrucciones.

- `RequestOrigin` – cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo, que coincide con el Custom string pattern #31.

  El origen de la solicitud.

Respuesta

- `Session`: un objeto Sesión.

  Se recupera el objeto de la sesión en la respuesta.

Errores

- `AccessDeniedException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`

Acción ListSessions (Python: list_sessions)

Recupere una lista de sesiones.

Solicitud

- `NextToken`: cadena UTF-8 de 400 000 bytes de largo como máximo.

  El token para el próximo conjunto de resultados o nulo si no hay más resultados.
- `MaxResults`: número (entero) que no es inferior a 1 ni es superior a 1000.

  El número máximo de resultados.
- `Tags`: matriz de mapas de pares de clave-valor, con 50 pares como máximo.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es una cadena UTF-8 que no tiene más de 256 bytes de largo.

  Etiquetas pertenecientes a la sesión.

- `RequestOrigin` – cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo, que coincide con el Custom string pattern #31.

  El origen de la solicitud.

Respuesta

- `Ids`: matriz de cadenas UTF-8.

  Arroja el ID de la sesión.
- `Sessions`: matriz de objetos Sesión.

  Arroja el objeto de la sesión.
- `NextToken`: cadena UTF-8 de 400 000 bytes de largo como máximo.

  El token para el próximo conjunto de resultados o nulo si no hay más resultados.

Errores

- `AccessDeniedException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

Acción RunStatement (Python: run_statement)

Pone en marcha la instrucción.

Solicitud

- `SessionId`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de sesión de la instrucción que se ejecutará.
- `Code`: obligatorio: cadena UTF-8, de 68 000 bytes de largo como máximo.

  El código de instrucción que se pondrá en marcha.

- `RequestOrigin` – cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo, que coincide con el Custom string pattern #31.

  El origen de la solicitud.

Respuesta

- `Id`: número (entero).

  Arroja el ID de la instrucción que se puso en marcha.

Errores

- `EntityNotFoundException`
- `AccessDeniedException`
- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`
- `ValidationException`
- `ResourceNumberLimitExceededException`
- `IllegalSessionStateException`

Acción CancelStatement (Python: cancel_statement)

Cancela la instrucción.

Solicitud

- `SessionId`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de sesión de la instrucción que se va a cancelar.
- `Id` – Obligatorio: número (entero).

  El ID de la instrucción que se va a cancelar.

- `RequestOrigin` – cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo, que coincide con el Custom string pattern #31.

  El origen de la solicitud de cancelación de la instrucción.

Respuesta

- Sin parámetros de respuesta.

Errores

- `AccessDeniedException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`
- `IllegalSessionStateException`

Acción GetStatement (Python: get_statement)

Recupera la instrucción.

Solicitud

- `SessionId`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de sesión de la instrucción.

- `Id` – Obligatorio: número (entero).

  El ID de la instrucción.

- `RequestOrigin` – cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo, que coincide con el Custom string pattern #31.

  El origen de la solicitud.

Respuesta

- `Statement`: un objeto Instrucción.

  Arroja la instrucción.

Errores

- `AccessDeniedException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`
- `IllegalSessionStateException`

Acción ListStatements (Python: list_statement)

Muestra las instrucciones de la sesión.

Solicitud

- `SessionId`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de sesión de las instrucciones.
- `RequestOrigin` – cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo, que coincide con el Custom string pattern #31.

  El origen de la solicitud de enumeración de instrucciones.
- `NextToken`: cadena UTF-8 de 400 000 bytes de largo como máximo.

  Token de continuación si se trata de una llamada de continuidad.

Respuesta

- `Statements`: matriz de objetos Instrucción.

  Arroja la lista de instrucciones.

- `NextToken`: cadena UTF-8 de 400 000 bytes de largo como máximo.

  Token de continuación si todavía no se arrojaron todas las instrucciones.

Errores

- `AccessDeniedException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`
- `IllegalSessionStateException`

Acción GetGlueIdentityCenterConfiguration (Python: get_glue_identity_center_configuration)

Recupera los detalles de la configuración actual de AWS Glue Identity Center, incluida la información de la aplicación y la instancia de Identity Center asociadas.

Solicitud

- Ningún parámetro de solicitud.

Respuesta

Respuesta que contiene los detalles de configuración de AWS Glue Identity Center.

- `ApplicationArn`: cadena UTF-8 con una extensión de 10 bytes como mínimo o 1224 bytes como máximo.

  El nombre de recurso de Amazon (ARN) de la aplicación de Identity Center que está asociada a la configuración de AWS Glue.
- `InstanceArn`: cadena UTF-8 con una extensión de 10 bytes como mínimo o 1224 bytes como máximo.

  El nombre de recurso de Amazon (ARN) de la instancia de Identity Center que está asociada a la configuración de AWS Glue.

- `Scopes`: matriz de cadenas UTF-8.

  Una lista de los ámbitos de Identity Center que define los permisos y niveles de acceso de la configuración de AWS Glue.

Errores

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `AccessDeniedException`
- `ConcurrentModificationException`

Acción UpdateBlueIdentityCenterConfiguration (Python: update_glue_identity_center_configuration)

Actualiza la configuración existente de AWS Glue Identity Center, lo que permite modificar los ámbitos y permisos de la integración.

Solicitud

Solicitud para actualizar una configuración de AWS Glue Identity Center existente.

- `Scopes`: matriz de cadenas UTF-8, con una cadena como mínimo o más de 50 cadenas.

  Una lista de los ámbitos de Identity Center que define los permisos y niveles de acceso actualizados de la configuración de AWS Glue.

Respuesta

- Sin parámetros de respuesta.

Errores

- `InvalidInputException`
- `EntityNotFoundException`

- `InternalServiceException`
- `OperationTimeoutException`
- `AccessDeniedException`
- `ConcurrentModificationException`

Acción CreateBlueIdentityCenter_Configuration (Python: create_glue_identity_center_configuration)

Crea una nueva configuración de AWS Glue Identity Center para permitir la integración entre AWS Glue y AWS IAM Identity Center para la autenticación y la autorización.

Solicitud

Solicitud para crear una nueva configuración de AWS Glue Identity Center.

- `InstanceArn`: requerido: cadena UTF-8 con una extensión de 10 bytes como mínimo y 1224 bytes como máximo.

  El nombre de recurso de Amazon (ARN) de la instancia de Identity Center que se asociará a la configuración de AWS Glue.
- `Scopes`: matriz de cadenas UTF-8, con una cadena como mínimo o más de 50 cadenas.

  Una lista de los ámbitos de Identity Center que define los permisos y niveles de acceso de la configuración de AWS Glue.

Respuesta

Respuesta al crear una nueva configuración de AWS Glue Identity Center.

- `ApplicationArn`: cadena UTF-8 con una extensión de 10 bytes como mínimo o 1224 bytes como máximo.

  El nombre de recurso de Amazon (ARN) de la aplicación de Identity Center que se creó para la configuración de AWS Glue.

Errores

- `InvalidInputException`

- `AlreadyExistsException`
- `InternalServiceException`
- `OperationTimeoutException`
- `AccessDeniedException`
- `ConcurrentModificationException`

Acción DeleteGlueIdentityCenterConfiguration (Python: delete_glue_identity_center_configuration)

Elimina la configuración de AWS Glue Identity Center existente, lo que elimina la integración entre AWS Glue y AWS IAM Identity Center.

Solicitud

- Ningún parámetro de solicitud.

Respuesta

- Sin parámetros de respuesta.

Errores

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `AccessDeniedException`
- `ConcurrentModificationException`

API de puntos de conexión de desarrollo

La API de puntos de conexión de desarrollo describe la API de AWS Glue relacionada con las pruebas mediante un DevEndpoint (punto de conexión de desarrollo) personalizado.

Tipos de datos

- Estructura DevEndpoint
- Estructura DevEndpointCustomLibraries

Estructura DevEndpoint

Un punto de enlace de desarrollo en el que un desarrollador pueda depurar de forma remota scripts de extracción, transformación y carga (ETL).

Campos

- `EndpointName`: cadena UTF-8.

  Nombre del elemento `DevEndpoint`.
- `RoleArn` – cadena UTF-8 que coincide con el AWS IAM ARN string pattern.

  El nombre de recurso de Amazon (ARN) del rol de IAM que se utiliza en este `DevEndpoint`.
- `SecurityGroupIds`: matriz de cadenas UTF-8.

  Una lista de identificadores del grupo de seguridad que se utilizan en este `DevEndpoint`.
- `SubnetId`: cadena UTF-8.

  El ID de subred para este `DevEndpoint`.
- `YarnEndpointAddress`: cadena UTF-8.

  La dirección del punto de enlace de YARN que utiliza este `DevEndpoint`.
- `PrivateAddress`: cadena UTF-8.

  Una dirección IP privada para acceder al `DevEndpoint` dentro de una VPC si los datos `DevEndpoint` se crean dentro de una. El campo `PrivateAddress` está presente solo cuando se crea el `DevEndpoint` dentro de la VPC.
- `ZeppelinRemoteSparkInterpreterPort`: número (entero).

  El puerto de Apache Zeppelin para el intérprete remoto de Apache Spark.
- `PublicAddress`: cadena UTF-8.

La dirección IP pública que utiliza este `DevEndpoint`. El campo `PublicAddress` está presente solo cuando se crea un `DevEndpoint` no de nube privada virtual (VPC).

- `Status`: cadena UTF-8.

  El estado actual de este `DevEndpoint`.

- `WorkerType` – Cadena UTF-8 (valores válidos: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

  El tipo de proceso de trabajo predefinido que se asigna al punto de enlace de desarrollo. Admite un valor de Standard, G.1X o G.2X.

  - Para el tipo de proceso de trabajo `Standard`, cada proceso de trabajo proporciona 4 vCPU, 16 GB de memoria y un disco de 50 GB y 2 ejecutores por proceso de trabajo.
  - Para el tipo de proceso de trabajo `G.1X`, cada proceso de trabajo se asocia a 1 DPU (4 vCPU, 16 GB de memoria, disco de 64 GB) y proporciona 1 ejecutor por proceso de trabajo. Le recomendamos este tipo de proceso de trabajo para trabajos con un uso intensivo de la memoria.
  - Para el tipo de proceso de trabajo `G.2X`, cada proceso de trabajo se asocia a 2 DPU (8 vCPU, 32 GB de memoria, disco de 128 GB) y proporciona 1 ejecutor por proceso de trabajo. Le recomendamos este tipo de proceso de trabajo para trabajos con un uso intensivo de la memoria.

  Problema conocido: cuando se crea un punto de enlace de desarrollo con la configuración `G.2X` `WorkerType`, los controladores Spark para el punto de enlace de desarrollo se ejecutarán en 4 vCPU, 16 GB de memoria y un disco de 64 GB.

- `GlueVersion` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #48.

  La versión de Glue determina las versiones de Apache Spark y Python que admite AWS Glue. La versión de Python indica la versión admitida para ejecutar sus scripts de ETL en puntos de enlace de desarrollo.

  Para obtener más información acerca de las versiones de AWS Glue disponibles y las versiones de Spark y Python correspondientes, consulte Versión de Glue en la guía para desarrolladores.

  Los puntos de enlace de desarrollo que se crean sin especificar una versión de Glue se establecen de forma predeterminada en Glue 0.9.

Puede especificar una versión de Python compatible con puntos de enlace de desarrollo mediante el parámetro `Arguments` en las API `CreateDevEndpoint` o `UpdateDevEndpoint`. Si no se proporcionan argumentos, la versión es Python 2 de forma predeterminada.

- `NumberOfWorkers`: número (entero).

  El número de procesos de trabajo de un definido `workerType` que se asignan al punto de enlace de desarrollo.

  El número máximo de procesos de trabajo que puede definir son 299 para `G.1X` y 149 para `G.2X`.

- `NumberOfNodes`: número (entero).

  El número de unidades de procesamiento de datos (DPU) de AWS Glue asignadas a este `DevEndpoint`.

- `AvailabilityZone`: cadena UTF-8.

  La zona de disponibilidad de AWS en la que se encuentra este `DevEndpoint`.

- `VpcId`: cadena UTF-8.

  El ID de la nube privada virtual (VPC) que utiliza este `DevEndpoint`.

- `ExtraPythonLibsS3Path`: cadena UTF-8.

  Las rutas a una o varias bibliotecas Python en un bucket de Amazon S3 que debe estar cargado en su `DevEndpoint`. Varios valores deben ser rutas completas separadas por una coma.

  > **Note**
  >
  > Solo puede utilizar bibliotecas de Python puras con un `DevEndpoint`. Las bibliotecas que se basan en extensiones de C, como la biblioteca de análisis de datos de Python pandas, no se admiten actualmente.

- `ExtraJarsS3Path`: cadena UTF-8.

  La ruta a uno o más archivos `.jar` de Java en un bucket de S3 que se debe cargar en su `DevEndpoint`.

> **Note**
>
> Solo puede utilizar bibliotecas Java/Scala puras con un `DevEndpoint`.

- `FailureReason`: cadena UTF-8.

  El motivo de un error actual en este `DevEndpoint`.

- `LastUpdateStatus`: cadena UTF-8.

  El estado de la última actualización.

- `CreatedTimestamp`: marca temporal.

  El momento en que se creó este DevEndpoint.

- `LastModifiedTimestamp`: marca temporal.

  El punto en el que este `DevEndpoint` se modificó por última vez.

- `PublicKey`: cadena UTF-8.

  La clave pública que va a utilizar este `DevEndpoint` para autenticación. Este atributo se proporciona para compatibilidad con versiones anteriores, ya que el atributo que se recomienda usar son las claves públicas.

- `PublicKeys`: matriz de cadenas UTF-8, con 5 cadenas como máximo.

  Una lista de claves públicas que van a utilizar los `DevEndpoints` para autenticación. Se prefiere el uso de este atributo a una sola clave pública, ya que las claves públicas le permiten tener una clave privada diferente por cliente.

> **Note**
>
> Si ha creado previamente un punto de enlace con una clave pública, debe eliminar dicha clave para poder establecer una lista de claves públicas. Realice una llamada a la operación API `UpdateDevEndpoint` con el contenido de la clave pública en el atributo `deletePublicKeys` y la lista de nuevas claves en el atributo `addPublicKeys`.

- `SecurityConfiguration` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

El nombre de la estructura `SecurityConfiguration` que se va a utilizar con este `DevEndpoint`.

- `Arguments`: matriz de mapas de pares de clave-valor, con 100 pares como máximo.

  Cada clave es una cadena UTF-8.

  Cada valor es una cadena UTF-8.

  Mapa de argumentos que se utiliza para configurar `DevEndpoint`.

  Los argumentos válidos son:

  - `"--enable-glue-datacatalog": ""`

  Puede especificar una versión de Python compatible con puntos de enlace de desarrollo mediante el parámetro `Arguments` en las API `CreateDevEndpoint` o `UpdateDevEndpoint`. Si no se proporcionan argumentos, la versión es Python 2 de forma predeterminada.

Estructura DevEndpointCustomLibraries

Las bibliotecas personalizadas que se van a cargar en un punto de enlace.

Campos

- `ExtraPythonLibsS3Path`: cadena UTF-8.

  Las rutas a una o varias bibliotecas Python en un bucket de Amazon Simple Storage Service (Amazon S3) que deben cargarse en el `DevEndpoint`. Varios valores deben ser rutas completas separadas por una coma.

  > **Note**
  >
  > Solo puede utilizar bibliotecas de Python puras con un `DevEndpoint`. Las bibliotecas que se basan en extensiones de C, como la biblioteca de análisis de datos de Python pandas, no se admiten actualmente.

- `ExtraJarsS3Path`: cadena UTF-8.

  La ruta a uno o más archivos `.jar` de Java en un bucket de S3 que se debe cargar en su `DevEndpoint`.

> **Note**
>
> Solo puede utilizar bibliotecas Java/Scala puras con un `DevEndpoint`.

Operaciones

- Acción CreateDevEndpoint (Python: create_dev_endpoint)
- Acción UpdateDevEndpoint (Python: update_dev_endpoint)
- Acción DeleteDevEndpoint (Python: delete_dev_endpoint)
- Acción GetDevEndpoint (Python: get_dev_endpoint)
- Acción GetDevEndpoints (Python: get_dev_endpoints)
- Acción BatchGetDevEndpoints (Python: batch_get_dev_endpoints)
- Acción ListDevEndpoints (Python: list_dev_endpoints)

Acción CreateDevEndpoint (Python: create_dev_endpoint)

Crea un nuevo punto de enlace de desarrollo.

Solicitud

- `EndpointName` – Obligatorio: cadena UTF-8.

  El nombre que se va a asignar al nuevo `DevEndpoint`.
- `RoleArn`: obligatorio: cadena UTF-8 que coincide con el AWS IAM ARN string pattern.

  El rol de IAM para el `DevEndpoint`.
- `SecurityGroupIds`: matriz de cadenas UTF-8.

  Los ID de grupo de seguridad para los grupos de seguridad que va a utilizar el nuevo `DevEndpoint`.
- `SubnetId`: cadena UTF-8.

  El ID de subred para el nuevo `DevEndpoint` que se va a utilizar.
- `PublicKey`: cadena UTF-8.

La clave pública que va a utilizar este `DevEndpoint` para autenticación. Este atributo se proporciona para compatibilidad con versiones anteriores, ya que el atributo que se recomienda usar son las claves públicas.

- `PublicKeys`: matriz de cadenas UTF-8, con 5 cadenas como máximo.

  Lista de claves públicas que van a utilizar los puntos de enlace de desarrollo para la autenticación. Se prefiere el uso de este atributo a una sola clave pública, ya que las claves públicas le permiten tener una clave privada diferente por cliente.

  > **Note**
  >
  > Si ha creado previamente un punto de enlace con una clave pública, debe eliminar dicha clave para poder establecer una lista de claves públicas. Llame a la API `UpdateDevEndpoint` con el contenido de la clave pública en el atributo `deletePublicKeys` y la lista de nuevas claves en el atributo `addPublicKeys`.

- `NumberOfNodes`: número (entero).

  El número de unidades de procesamiento de datos (DPU) de AWS Glue que se van a asignar a este `DevEndpoint`.

- `WorkerType` – Cadena UTF-8 (valores válidos: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

  El tipo de proceso de trabajo predefinido que se asigna al punto de enlace de desarrollo. Admite un valor de Standard, G.1X o G.2X.

  - Para el tipo de proceso de trabajo `Standard`, cada proceso de trabajo proporciona 4 vCPU, 16 GB de memoria y un disco de 50 GB y 2 ejecutores por proceso de trabajo.
  - Para el tipo de proceso de trabajo `G.1X`, cada proceso de trabajo se asocia a 1 DPU (4 vCPU, 16 GB de memoria, disco de 64 GB) y proporciona 1 ejecutor por proceso de trabajo. Le recomendamos este tipo de proceso de trabajo para trabajos con un uso intensivo de la memoria.
  - Para el tipo de proceso de trabajo `G.2X`, cada proceso de trabajo se asocia a 2 DPU (8 vCPU, 32 GB de memoria, disco de 128 GB) y proporciona 1 ejecutor por proceso de trabajo. Le recomendamos este tipo de proceso de trabajo para trabajos con un uso intensivo de la memoria.

Problema conocido: cuando se crea un punto de enlace de desarrollo con la configuración `G.2X` `WorkerType`, los controladores Spark para el punto de enlace de desarrollo se ejecutarán en 4 vCPU, 16 GB de memoria y un disco de 64 GB.

- `GlueVersion` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #48.

  La versión de Glue determina las versiones de Apache Spark y Python que admite AWS Glue. La versión de Python indica la versión admitida para ejecutar sus scripts de ETL en puntos de enlace de desarrollo.

  Para obtener más información acerca de las versiones de AWS Glue disponibles y las versiones de Spark y Python correspondientes, consulte Versión de Glue en la guía para desarrolladores.

  Los puntos de enlace de desarrollo que se crean sin especificar una versión de Glue se establecen de forma predeterminada en Glue 0.9.

  Puede especificar una versión de Python compatible con puntos de enlace de desarrollo mediante el parámetro `Arguments` en las API `CreateDevEndpoint` o `UpdateDevEndpoint`. Si no se proporcionan argumentos, la versión es Python 2 de forma predeterminada.

- `NumberOfWorkers`: número (entero).

  El número de procesos de trabajo de un definido `workerType` que se asignan al punto de enlace de desarrollo.

  El número máximo de procesos de trabajo que puede definir son 299 para `G.1X` y 149 para `G.2X`.

- `ExtraPythonLibsS3Path`: cadena UTF-8.

  Las rutas a una o varias bibliotecas Python en un bucket de Amazon S3 que debe estar cargado en su `DevEndpoint`. Varios valores deben ser rutas completas separadas por una coma.

  > **Note**
  >
  > Solo puede utilizar bibliotecas de Python puras con un `DevEndpoint`. Todavía no se admiten las bibliotecas que se basan en las extensiones de C, como la biblioteca de análisis de datos Python pandas.

- `ExtraJarsS3Path`: cadena UTF-8.

La ruta a uno o más archivos `.jar` de Java en un bucket de S3 que se debe cargar en su `DevEndpoint`.

- `SecurityConfiguration` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la estructura `SecurityConfiguration` que se va a utilizar con este `DevEndpoint`.

- `Tags`: matriz de mapas de pares de clave-valor, con 50 pares como máximo.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es una cadena UTF-8 que no tiene más de 256 bytes de largo.

  Etiquetas que se van a utilizar con este objeto DevEndpoint. Puede utilizar etiquetas para limitar el acceso al objeto DevEndpoint. Para obtener más información acerca de las etiquetas en AWS Glue, consulte Etiquetas de AWS en AWS Glue en la guía para desarrolladores.

- `Arguments`: matriz de mapas de pares de clave-valor, con 100 pares como máximo.

  Cada clave es una cadena UTF-8.

  Cada valor es una cadena UTF-8.

  Mapa de argumentos que se utiliza para configurar `DevEndpoint`.

Respuesta

- `EndpointName`: cadena UTF-8.

  El nombre asignado a la nueva `DevEndpoint`.

- `Status`: cadena UTF-8.

  El estado actual del nuevo `DevEndpoint`.

- `SecurityGroupIds`: matriz de cadenas UTF-8.

  Los grupos de seguridad que se asignaron al nuevo `DevEndpoint`.

- `SubnetId`: cadena UTF-8.

  El ID de subred asignado al nuevo `DevEndpoint`.

- `RoleArn` – cadena UTF-8 que coincide con el AWS IAM ARN string pattern.

  El nombre de recurso de Amazon (ARN) del rol asignado al nuevo `DevEndpoint`.
- `YarnEndpointAddress`: cadena UTF-8.

  La dirección del punto de enlace de YARN que utiliza este `DevEndpoint`.
- `ZeppelinRemoteSparkInterpreterPort`: número (entero).

  El puerto de Apache Zeppelin para el intérprete remoto de Apache Spark.
- `NumberOfNodes`: número (entero).

  El número de unidades de procesamiento de datos de AWS Glue (DPU) asignadas a este punto de enlace de desarrollo.
- `WorkerType` – Cadena UTF-8 (valores válidos: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

  El tipo de proceso de trabajo predefinido que se asigna al punto de enlace de desarrollo. Puede ser un valor de Standard, G.1X o G.2X.
- `GlueVersion` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #48.

  La versión de Glue determina las versiones de Apache Spark y Python que admite AWS Glue. La versión de Python indica la versión admitida para ejecutar sus scripts de ETL en puntos de enlace de desarrollo.

  Para obtener más información acerca de las versiones de AWS Glue disponibles y las versiones de Spark y Python correspondientes, consulte Versión de Glue en la guía para desarrolladores.
- `NumberOfWorkers`: número (entero).

  El número de procesos de trabajo de un definido `workerType` que se asignan al punto de enlace de desarrollo.
- `AvailabilityZone`: cadena UTF-8.

  La zona de disponibilidad de AWS en la que se encuentra este `DevEndpoint`.
- `VpcId`: cadena UTF-8.

  El ID de la nube privada virtual (VPC) que utiliza este `DevEndpoint`.
- `ExtraPythonLibsS3Path`: cadena UTF-8.

Las rutas a una o varias bibliotecas Python en un bucket de S3 que se cargarán en el `DevEndpoint`.

- `ExtraJarsS3Path`: cadena UTF-8.

  Ruta a uno o varios archivos `.jar` de Java en un bucket de S3 que se cargarán en el `DevEndpoint`.

- `FailureReason`: cadena UTF-8.

  El motivo de un error actual en este `DevEndpoint`.

- `SecurityConfiguration` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la estructura `SecurityConfiguration` que se va a utilizar con este `DevEndpoint`.

- `CreatedTimestamp`: marca temporal.

  El punto en el que se creó este `DevEndpoint`.

- `Arguments`: matriz de mapas de pares de clave-valor, con 100 pares como máximo.

  Cada clave es una cadena UTF-8.

  Cada valor es una cadena UTF-8.

  Mapa de argumentos que se utiliza para configurar este `DevEndpoint`.

  Los argumentos válidos son:

  - `"--enable-glue-datacatalog": ""`

  Puede especificar una versión de Python compatible con puntos de enlace de desarrollo mediante el parámetro `Arguments` en las API `CreateDevEndpoint` o `UpdateDevEndpoint`. Si no se proporcionan argumentos, la versión es Python 2 de forma predeterminada.

Errores

- `AccessDeniedException`
- `AlreadyExistsException`
- `IdempotentParameterMismatchException`

- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`
- `ValidationException`
- `ResourceNumberLimitExceededException`

Acción UpdateDevEndpoint (Python: update_dev_endpoint)

Actualiza un punto de enlace de desarrollo especificado.

Solicitud

- `EndpointName` – Obligatorio: cadena UTF-8.

  El nombre del `DevEndpoint` que actualizar.
- `PublicKey`: cadena UTF-8.

  La clave pública del `DevEndpoint` que utilizar.
- `AddPublicKeys`: matriz de cadenas UTF-8, con 5 cadenas como máximo.

  La lista de las claves públicas del `DevEndpoint` que se va a utilizar.
- `DeletePublicKeys`: matriz de cadenas UTF-8, con 5 cadenas como máximo.

  Lista de claves públicas que se van a eliminar del `DevEndpoint`.
- `CustomLibraries`: un objeto DevEndpointCustomLibraries.

  Las bibliotecas Python o Java personalizadas que se van a cargar en el `DevEndpoint`.
- `UpdateEtlLibraries`: booleano.

  `True` si la lista de bibliotecas personalizadas que se va a cargar el punto de enlace de desarrollo debe actualizarse; `False` en caso contrario.
- `DeleteArguments`: matriz de cadenas UTF-8.

  Lista de claves de argumentos que se van a eliminar del mapa de argumentos utilizado para configurar el objeto `DevEndpoint`.
- `AddArguments`: matriz de mapas de pares de clave-valor, con 100 pares como máximo.

Cada clave es una cadena UTF-8.

Cada valor es una cadena UTF-8.

Mapa de argumentos que se va a añadir al mapa de argumentos utilizado para configurar el `DevEndpoint`.

Los argumentos válidos son:

- `"--enable-glue-datacatalog": ""`

Puede especificar una versión de Python compatible con puntos de enlace de desarrollo mediante el parámetro `Arguments` en las API `CreateDevEndpoint` o `UpdateDevEndpoint`. Si no se proporcionan argumentos, la versión es Python 2 de forma predeterminada.

Respuesta

- Sin parámetros de respuesta.

Errores

- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`
- `ValidationException`

Acción DeleteDevEndpoint (Python: delete_dev_endpoint)

Elimina un punto de enlace de desarrollo especificado.

Solicitud

- `EndpointName` – Obligatorio: cadena UTF-8.

  Nombre del elemento `DevEndpoint`.

Respuesta

- Sin parámetros de respuesta.

Errores

- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`

Acción GetDevEndpoint (Python: get_dev_endpoint)

Recupera información sobre un punto de enlace de desarrollo especificado.

> **Note**
>
> Cuando se crea un punto de enlace de desarrollo en una nube virtual privada (VPC), AWS Glue devuelve solamente una dirección IP privada y el campo de la dirección IP pública no se rellena. Al crear un punto de enlace de desarrollo que no pertenece a la VPC, AWS Glue devuelve solamente una dirección IP pública.

Solicitud

- `EndpointName` – Obligatorio: cadena UTF-8.

  Nombre del `DevEndpoint` para el que recuperar información.

Respuesta

- `DevEndpoint`: un objeto DevEndpoint.

  Una definición de `DevEndpoint`.

Errores

- `EntityNotFoundException`

- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`

Acción GetDevEndpoints (Python: get_dev_endpoints)

Recupera todos los puntos de enlace de desarrollo en esta cuenta de AWS.

> **Note**
>
> Cuando se crea un punto de enlace de desarrollo en una nube virtual privada (VPC), AWS Glue devuelve solamente una dirección IP privada y el campo de la dirección IP pública no se rellena. Al crear un punto de enlace de desarrollo que no pertenece a la VPC, AWS Glue devuelve solamente una dirección IP pública.

Solicitud

- `MaxResults`: número (entero) que no es inferior a 1 ni es superior a 1000.

  Tamaño máximo de la información que se devolverá.
- `NextToken`: cadena UTF-8.

  Token de continuación si se trata de una llamada de continuidad.

Respuesta

- `DevEndpoints`: matriz de objetos DevEndpoint.

  Una lista de definiciones de `DevEndpoint`.
- `NextToken`: cadena UTF-8.

  Un token de continuación si todavía no se han devuelto todas las definiciones de `DevEndpoint`.

Errores

- `EntityNotFoundException`

- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`

Acción BatchGetDevEndpoints (Python: batch_get_dev_endpoints)

Devuelve la lista de metadatos de recursos de una determinada lista de nombres de punto de enlace de desarrollo. Después de llamar a la operación `ListDevEndpoints`, puede llamar a esta operación para obtener acceso a los datos a los que ha concedido permisos. Esta operación admite todos los permisos de IAM, incluidas las condiciones de permisos que utilizan etiquetas.

Solicitud

- `customerAccountId`: cadena UTF-8.

  El ID de la cuenta de AWS.
- `DevEndpointNames` – Obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y 25 cadenas como máximo.

  La lista de nombres de `DevEndpoint`, que podrían ser los nombres devueltos desde la operación `ListDevEndpoint`.

Respuesta

- `DevEndpoints`: matriz de objetos DevEndpoint.

  Una lista de definiciones de `DevEndpoint`.
- `DevEndpointsNotFound`: matriz de cadenas UTF-8, con una cadena como mínimo y 25 cadenas como máximo.

  Una lista de `DevEndpoints` no encontrados.

Errores

- `AccessDeniedException`
- `InternalServiceException`
- `OperationTimeoutException`

- `InvalidInputException`

Acción ListDevEndpoints (Python: list_dev_endpoints)

Recupera los nombres de todos los recursos de `DevEndpoint` en esta cuenta de AWS, o los recursos con la etiqueta especificada. Esta operación permite ver qué recursos están disponibles en la cuenta y sus nombres.

Esta operación toma el campo `Tags` opcional, que se puede utilizar como filtro en la respuesta para que los recursos etiquetados se devuelvan agrupados. Si decide utilizar el filtrado de etiquetas, solo se devolverán los recursos con la etiqueta especificada.

Solicitud

- `NextToken`: cadena UTF-8.

  Token de continuación, si se trata de una solicitud de continuidad.
- `MaxResults`: número (entero) que no es inferior a 1 ni es superior a 1000.

  Tamaño máximo de una lista que se devolverá.
- `Tags`: matriz de mapas de pares de clave-valor, con 50 pares como máximo.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es una cadena UTF-8 que no tiene más de 256 bytes de largo.

  Especifica que se devuelvan solamente los recursos etiquetados.

Respuesta

- `DevEndpointNames`: matriz de cadenas UTF-8.

  Nombres de todos los `DevEndpoint` de la cuenta o de los `DevEndpoint` con las etiquetas especificadas.
- `NextToken`: cadena UTF-8.

  Token de continuación, si la lista devuelta no contiene la última métrica disponible.

Errores

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`

Schema Registry

La API de Schema Registry describe la API y los tipos de datos relacionados con el trabajo con esquemas en AWS Glue.

Tipos de datos

- Estructura RegistryId
- Estructura RegistryListItem
- Estructura MetadataInfo
- Estructura OtherMetadataValueListItem
- Estructura SchemaListItem
- Estructura SchemaVersionListItem
- Estructura MetadataKeyValuePair
- Estructura SchemaVersionErrorItem
- Estructura ErrorDetails
- Estructura SchemaVersionNumber
- Estructura SchemaId

Estructura RegistryId

Una estructura de encapsulador que puede contener el nombre de registro y el nombre de recurso de Amazon (ARN).

Campos

- `RegistryName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #46.

Nombre del registro. Sólo se utiliza para la búsqueda. Uno de `RegistryArn` o `RegistryName` debe ser proporcionado.

- `RegistryArn` – cadena UTF-8, con 1 byte de largo como mínimo y 10 240 bytes de largo como máximo, que coincide con el Custom string pattern #50.

  Arn del registro que se actualizará. Uno de `RegistryArn` o `RegistryName` debe ser proporcionado.

Estructura RegistryListItem

Una estructura que contiene los detalles de un registro.

Campos

- `RegistryName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #46.

  El nombre del registro.

- `RegistryArn` – cadena UTF-8, con 1 byte de largo como mínimo y 10 240 bytes de largo como máximo, que coincide con el Custom string pattern #50.

  Nombre de recurso de Amazon (ARN) del registro.

- `Description` – cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Es una descripción del recurso.

- `Status` – Cadena UTF-8 (valores válidos: `AVAILABLE` | `DELETING`).

  Estado del registro.

- `CreatedTime`: cadena UTF-8.

  La fecha en que se creó el registro.

- `UpdatedTime`: cadena UTF-8.

  La fecha en que se actualizó el registro.

Estructura MetadataInfo

Estructura que contiene información de metadatos para una versión de esquema.

Campos

- `MetadataValue` – cadena UTF-8, con 1 byte de largo como mínimo y 256 bytes de largo como máximo, que coincide con el Custom string pattern #14.

  Valor correspondiente de una clave de metadatos.

- `CreatedTime`: cadena UTF-8.

  La hora a la que se creó la entrada.

- `OtherMetadataValueList`: matriz de objetos OtherMetadataValueListItem.

  Otros metadatos pertenecientes a la misma clave de metadatos.

Estructura OtherMetadataValueListItem

Estructura que contiene otros metadatos para una versión de esquema que pertenece a la misma clave de metadatos.

Campos

- `MetadataValue` – cadena UTF-8, con 1 byte de largo como mínimo y 256 bytes de largo como máximo, que coincide con el Custom string pattern #14.

  El valor correspondiente de la clave de metadatos para los demás metadatos pertenecientes a la misma clave de metadatos.

- `CreatedTime`: cadena UTF-8.

  La hora a la que se creó la entrada.

Estructura SchemaListItem

Objeto que contiene detalles mínimos de un esquema.

Campos

- `RegistryName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #46.

  Nombre del registro donde reside el esquema.

- `SchemaName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #46.

  El nombre del esquema.

- `SchemaArn` – cadena UTF-8, con 1 byte de largo como mínimo y 10 240 bytes de largo como máximo, que coincide con el Custom string pattern #50.

  Nombre de recurso de Amazon (ARN) del esquema.

- `Description` – cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Una descripción del esquema.

- `SchemaStatus` – Cadena UTF-8 (valores válidos: `AVAILABLE` | `PENDING` | `DELETING`).

  Estado del esquema.

- `CreatedTime`: cadena UTF-8.

  La fecha y hora en que se creó el esquema.

- `UpdatedTime`: cadena UTF-8.

  La fecha y hora en que se actualizó el esquema.

Estructura SchemaVersionListItem

Objeto que contiene los detalles sobre una versión de esquema.

Campos

- `SchemaArn` – cadena UTF-8, con 1 byte de largo como mínimo y 10 240 bytes de largo como máximo, que coincide con el Custom string pattern #50.

  Nombre de recurso de Amazon (ARN) del esquema.

- `SchemaVersionId` – cadena UTF-8, con 36 bytes de largo como mínimo y 36 bytes de largo como máximo, que coincide con el Custom string pattern #45.

  El identificador único de la versión del esquema.
- `VersionNumber`: número (largo) que no es inferior a 1 ni es superior a 100 000.

  El número de versión del esquema.
- `Status` – cadena UTF-8 (valores válidos: `AVAILABLE` | `PENDING` | `FAILURE` | `DELETING`).

  El estado de la versión del esquema.
- `CreatedTime`: cadena UTF-8.

  La fecha y hora en que se creó la versión del esquema.

Estructura MetadataKeyValuePair

Una estructura que contiene un par de valor-clave para metadatos.

Campos

- `MetadataKey` – cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo, que coincide con el Custom string pattern #14.

  Una clave de metadatos.
- `MetadataValue` – cadena UTF-8, con 1 byte de largo como mínimo y 256 bytes de largo como máximo, que coincide con el Custom string pattern #14.

  Valor correspondiente de una clave de metadatos.

Estructura SchemaVersionErrorItem

Objeto que contiene los detalles de error de una operación en una versión de esquema.

Campos

- `VersionNumber`: número (largo) que no es inferior a 1 ni es superior a 100 000.

  El número de versión del esquema.
- `ErrorDetails`: un objeto ErrorDetails.

Detalles del error para la versión del esquema.

Estructura ErrorDetails

Objeto que contiene detalles de error.

Campos

- `ErrorCode`: cadena UTF-8.

  El código de error de un error.
- `ErrorMessage`: cadena UTF-8.

  El mensaje de un error.

Estructura SchemaVersionNumber

Una estructura que contiene la información de versión del esquema.

Campos

- `LatestVersion`: booleano.

  La última versión disponible para el esquema.
- `VersionNumber`: número (largo) que no es inferior a 1 ni es superior a 100 000.

  El número de versión del esquema.

Estructura SchemaId

ID único del esquema en el registro de esquemas de AWS Glue.

Campos

- `SchemaArn` – cadena UTF-8, con 1 byte de largo como mínimo y 10 240 bytes de largo como máximo, que coincide con el Custom string pattern #50.

  Nombre de recurso de Amazon (ARN) del esquema. Uno de `SchemaArn` o `SchemaName` debe ser proporcionado.

- `SchemaName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #46.

  El nombre del esquema. Uno de `SchemaArn` o `SchemaName` debe ser proporcionado.

- `RegistryName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #46.

  Nombre del registro de esquemas que contiene el esquema.

Operaciones

- Acción CreateRegistry (Python: create_registry)
- Acción CreateSchema (Python: create_schema)
- Acción GetSchema (Python: get_schema)
- Acción ListSchemaVersions (Python: list_schema_versions)
- Acción GetSchemaVersion (Python: get_schema_version)
- Acción GetSchemaVersionsDiff (Python: get_schema_versions_diff)
- Acción ListRegistries (Python: list_registries)
- Acción ListSchemas (Python: list_schemas)
- Acción RegisterSchemaVersion (Python: register_schema_version)
- Acción UpdateSchema (Python: update_schema)
- Acción CheckSchemaVersionValidity (Python: check_schema_version_validity)
- Acción UpdateRegistry (Python: update_registry)
- Acción GetSchemabyDefinition (Python: get_schema_by_definition)
- Acción GetRegistry (Python: get_registry)
- Acción PutSchemaVersionMetadata (Python: put_schema_version_metadata)
- Acción QuerySchemaVersionMetadata (Python: query_schema_version_metadata)
- Acción RemoveSchemaVersionMetadata (Python: remove_schema_version_metadata)
- Acción DeleteRegistry (Python: delete_registry)
- Acción DeleteSchema (Python: delete_schema)
- Acción DeleteSchemaVersions (Python: delete_schema_versions)

Acción CreateRegistry (Python: create_registry)

Crea un nuevo registro que se puede utilizar para contener una recopilación de esquemas.

Solicitud

- `RegistryName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #46.

  Nombre del registro que se va a crear con una longitud máxima de 255, solo puede contener letras, números, guión, guión bajo, signo de dólar o marca hash. Sin espacio en blanco.
- `Description` – cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Es una descripción del recurso. Si no se proporciona una descripción, no habrá ningún valor predeterminado para esto.
- `Tags`: matriz de mapas de pares de clave-valor, con 50 pares como máximo.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es una cadena UTF-8 que no tiene más de 256 bytes de largo.

  AWSEtiquetas de que contienen un par de valor-clave y se pueden buscar por consola, línea de comandos o API.

Respuesta

- `RegistryArn` – cadena UTF-8, con 1 byte de largo como mínimo y 10 240 bytes de largo como máximo, que coincide con el Custom string pattern #50.

  El nombre de recurso de Amazon (ARN) del registro recientemente creado.
- `RegistryName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #46.

  El nombre del registro.
- `Description` – cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Es una descripción del recurso.

- `Tags`: matriz de mapas de pares de clave-valor, con 50 pares como máximo.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es una cadena UTF-8 que no tiene más de 256 bytes de largo.

  Etiquetas para el registro.

Errores

- `InvalidInputException`
- `AccessDeniedException`
- `AlreadyExistsException`
- `ResourceNumberLimitExceededException`
- `ConcurrentModificationException`
- `ThrottlingException`
- `InternalServiceException`

Acción CreateSchema (Python: create_schema)

Crea un nuevo conjunto de esquemas y registra la definición de esquema. Devuelve un error si el conjunto de esquemas ya existe sin haber registrado realmente la versión.

Cuando se crea el conjunto de esquemas, se establecerá un punto de comprobación de versión en la primera versión. El modo de compatibilidad “DISABLED (DESACTIVADO)” restringe el agregado de versiones de esquema adicionales después de la primera versión del esquema. Para todos los demás modos de compatibilidad, la validación de la configuración de compatibilidad solo se aplicará a partir de la segunda versión cuando se utilice la API de `RegisterSchemaVersion`.

Cuando se llama a esta API sin un `RegistryId`, esto creará una entrada para un “registro predeterminado” en las tablas de la base de datos del registro, si aún no se encuentra incluido.

Solicitud

- `RegistryId`: un objeto RegistryId.

  Esta es una forma de encapsulador que contiene los campos de identidad del registro. Si no se proporciona, se usará el registro predeterminado. El formato del ARN para el mismo será:

`arn:aws:glue:us-east-2:<customer id>:registry/default-registry:random-5-letter-id`.

- `SchemaName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #46.

  Nombre del esquema que se va a crear con una longitud máxima de 255, y solo puede contener letras, números, guión, guión bajo, signo de dólar o marca hash. Sin espacio en blanco.

- `DataFormat` – Obligatorio: cadena UTF-8 (valores válidos: `AVRO` | `JSON` | `PROTOBUF`).

  El formato de datos de la definición de esquema. `AVRO`, `JSON` y `PROTOBUF` se admiten en la actualidad.

- `Compatibility` – Cadena UTF-8 (valores válidos: `NONE` | `DISABLED` | `BACKWARD` | `BACKWARD_ALL` | `FORWARD` | `FORWARD_ALL` | `FULL` | `FULL_ALL`).

  El modo de compatibilidad del esquema. Los valores posibles son:

  - NONE (NINGUNO): no se aplica ningún modo de compatibilidad. Puede utilizar esta opción en escenarios de desarrollo o si no conoce el modo de compatibilidad que desea aplicar a los esquemas. Cualquier nueva versión que se agregue será aceptada sin someterse a una comprobación de compatibilidad.
  - DISABLED (DESACTIVADO): esta opción de compatibilidad impide el control de versiones de un esquema en particular. Puede utilizar esta opción para evitar el control de versiones de un esquema a futuro.
  - BACKWARDS (HACIA ATRÁS): se recomienda esta opción de compatibilidad ya que permite a los receptores de datos leer tanto la versión actual como la anterior del esquema. Esto significa que, por ejemplo, una nueva versión de esquema no puede eliminar campos de datos ni cambiar el tipo de estos campos, por lo que los lectores no pueden leerlos con la versión anterior.
  - BACKWARD_ALL (HACIA ATRÁS_TODO): esta opción de compatibilidad permite a los receptores de datos leer tanto la versión actual como todas las versiones anteriores del esquema. Puede utilizar esta opción cuando necesite eliminar campos o agregar campos opcionales, y comprobar la compatibilidad con todas las versiones de esquema anteriores.
  - FORWARD (HACIA ADELANTE): esta opción de compatibilidad permite a los receptores de datos leer tanto la versión actual como la inmediatamente siguiente del esquema, pero no necesariamente versiones posteriores. Puede utilizar esta opción cuando necesite agregar campos o eliminar campos opcionales, pero comprobar la compatibilidad con la última versión del esquema únicamente.

  - FORWARD_ALL (HACIA ADELANTE_TODO): esta opción de compatibilidad permite a los receptores de datos leer datos escritos por los productores de cualquier nuevo esquema registrado. Puede utilizar esta opción cuando necesite agregar campos o eliminar campos opcionales, y comprobar la compatibilidad con todas las versiones de esquema anteriores.
  - FULL (COMPLETO): esta opción de compatibilidad permite a los receptores de datos leer los datos escritos por los productores utilizando la versión inmediatamente anterior o siguiente del esquema, pero no necesariamente versiones anteriores o posteriores. Puede utilizar esta opción cuando necesite agregar campos o eliminar campos opcionales, pero comprobar la compatibilidad con la última versión del esquema únicamente.
  - FULL_ALL (COMPLETO_TODO): esta opción de compatibilidad permite a los receptores de datos leer los datos escritos por los productores utilizando todas las versiones de esquema anteriores. Puede utilizar esta opción cuando necesite agregar campos o eliminar campos opcionales, y comprobar la compatibilidad con todas las versiones anteriores del esquema.
- `Description` – cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Una descripción opcional del esquema. Si no se proporciona una descripción, no habrá ningún valor predeterminado automático para esto.
- `Tags`: matriz de mapas de pares de clave-valor, con 50 pares como máximo.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es una cadena UTF-8 que no tiene más de 256 bytes de largo.

  AWSEtiquetas de que contienen un par de valor-clave y se pueden buscar por consola, línea de comandos o API. Si se especifica, sigue el patrón tags-on-create de AWS.
- `SchemaDefinition` – cadena UTF-8, con 1 byte de largo como mínimo y 170 000 bytes de largo como máximo, que coincide con el Custom string pattern #13.

  Definición de esquema que utiliza la configuración `DataFormat` de `SchemaName`.

Respuesta

- `RegistryName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #46.

  El nombre del registro.

- `RegistryArn` – cadena UTF-8, con 1 byte de largo como mínimo y 10 240 bytes de largo como máximo, que coincide con el Custom string pattern #50.

  Nombre de recurso de Amazon (ARN) del registro.
- `SchemaName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #46.

  El nombre del esquema.
- `SchemaArn` – cadena UTF-8, con 1 byte de largo como mínimo y 10 240 bytes de largo como máximo, que coincide con el Custom string pattern #50.

  Nombre de recurso de Amazon (ARN) del esquema.
- `Description` – cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Una descripción del esquema si se especifica cuando se crea.
- `DataFormat` – Cadena UTF-8 (valores válidos: `AVRO` | `JSON` | `PROTOBUF`).

  El formato de datos de la definición de esquema. `AVRO`, `JSON` y `PROTOBUF` se admiten en la actualidad.
- `Compatibility` – Cadena UTF-8 (valores válidos: `NONE` | `DISABLED` | `BACKWARD` | `BACKWARD_ALL` | `FORWARD` | `FORWARD_ALL` | `FULL` | `FULL_ALL`).

  El modo de compatibilidad del esquema.
- `SchemaCheckpoint`: número (largo) que no es inferior a 1 ni es superior a 100 000.

  El número de versión del punto de comprobación (la última vez que se cambió el modo de compatibilidad).
- `LatestSchemaVersion`: número (largo) que no es inferior a 1 ni es superior a 100 000.

  La última versión del esquema asociada a la definición del esquema devuelta.
- `NextSchemaVersion`: número (largo) que no es inferior a 1 ni es superior a 100 000.

  La siguiente versión del esquema asociada a la definición de esquema devuelta.
- `SchemaStatus` – Cadena UTF-8 (valores válidos: `AVAILABLE` | `PENDING` | `DELETING`).

  Estado del esquema.
- `Tags`: matriz de mapas de pares de clave-valor, con 50 pares como máximo.

Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

Cada valor es una cadena UTF-8 que no tiene más de 256 bytes de largo.

Etiquetas para el esquema.

- `SchemaVersionId` – cadena UTF-8, con 36 bytes de largo como mínimo y 36 bytes de largo como máximo, que coincide con el Custom string pattern #45.

  El identificador único de la primera versión del esquema.

- `SchemaVersionStatus` – cadena UTF-8 (valores válidos: `AVAILABLE` | `PENDING` | `FAILURE` | `DELETING`).

  El estado de la primera versión creada del esquema.

Errores

- `InvalidInputException`
- `AccessDeniedException`
- `EntityNotFoundException`
- `AlreadyExistsException`
- `ResourceNumberLimitExceededException`
- `ConcurrentModificationException`
- `ThrottlingException`
- `InternalServiceException`

Acción GetSchema (Python: get_schema)

Describe el esquema especificado en detalle.

Solicitud

- `SchemaId`: obligatorio: objeto SchemaId.

  Una estructura de encapsulador que contiene campos de identidad de esquema. La estructura contiene lo siguiente:

- SchemaId$SchemaArn: nombre del recurso de Amazon (ARN) del esquema. Se debe proporcionar `SchemaArn` o `SchemaName` y `RegistryName`.
- SchemaId$SchemaName: el nombre del esquema. Se debe proporcionar `SchemaArn` o `SchemaName` y `RegistryName`.

Respuesta

- `RegistryName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #46.

  El nombre del registro.
- `RegistryArn` – cadena UTF-8, con 1 byte de largo como mínimo y 10 240 bytes de largo como máximo, que coincide con el Custom string pattern #50.

  Nombre de recurso de Amazon (ARN) del registro.
- `SchemaName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #46.

  El nombre del esquema.
- `SchemaArn` – cadena UTF-8, con 1 byte de largo como mínimo y 10 240 bytes de largo como máximo, que coincide con el Custom string pattern #50.

  Nombre de recurso de Amazon (ARN) del esquema.
- `Description` – cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Se especifica una descripción del esquema en el momento de la creación
- `DataFormat` – Cadena UTF-8 (valores válidos: `AVRO` | `JSON` | `PROTOBUF`).

  El formato de datos de la definición de esquema. `AVRO`, `JSON` y `PROTOBUF` se admiten en la actualidad.
- `Compatibility` – Cadena UTF-8 (valores válidos: `NONE` | `DISABLED` | `BACKWARD` | `BACKWARD_ALL` | `FORWARD` | `FORWARD_ALL` | `FULL` | `FULL_ALL`).

  El modo de compatibilidad del esquema.
- `SchemaCheckpoint`: número (largo) que no es inferior a 1 ni es superior a 100 000.

El número de versión del punto de comprobación (la última vez que se cambió el modo de compatibilidad).

- `LatestSchemaVersion`: número (largo) que no es inferior a 1 ni es superior a 100 000.

  La última versión del esquema asociada a la definición del esquema devuelta.

- `NextSchemaVersion`: número (largo) que no es inferior a 1 ni es superior a 100 000.

  La siguiente versión del esquema asociada a la definición de esquema devuelta.

- `SchemaStatus` – Cadena UTF-8 (valores válidos: `AVAILABLE` | `PENDING` | `DELETING`).

  Estado del esquema.

- `CreatedTime`: cadena UTF-8.

  La fecha y hora en que se creó el esquema.

- `UpdatedTime`: cadena UTF-8.

  La fecha y hora en que se actualizó el esquema.

Errores

- `InvalidInputException`
- `AccessDeniedException`
- `EntityNotFoundException`
- `ThrottlingException`
- `InternalServiceException`

Acción ListSchemaVersions (Python: list_schema_versions)

Devuelve una lista de versiones de esquema que ha creado, con información mínima. Las versiones del esquema en estado Deleted (Eliminado) no se incluirán en los resultados. Los resultados vacíos se devolverán si no hay versiones de esquema disponibles.

Solicitud

- `SchemaId`: obligatorio: objeto SchemaId.

Una estructura de encapsulador que contiene campos de identidad de esquema. La estructura contiene lo siguiente:

- SchemaId$SchemaArn: nombre del recurso de Amazon (ARN) del esquema. Se debe proporcionar `SchemaArn` o `SchemaName` y `RegistryName`.
- SchemaId$SchemaName: el nombre del esquema. Se debe proporcionar `SchemaArn` o `SchemaName` y `RegistryName`.

- `MaxResults`: número (entero) que no es inferior a 1 ni es superior a 100.

  Número máximo de resultados requeridos por página. Si no se proporciona el valor, el valor predeterminado será 25 por página.
- `NextToken`: cadena UTF-8.

  Token de continuación si se trata de una llamada de continuidad.

Respuesta

- `Schemas`: matriz de objetos SchemaVersionListItem.

  Una matriz de objetos de `SchemaVersionList` que contiene detalles de cada versión del esquema.
- `NextToken`: cadena UTF-8.

  Token de continuación para paginar la lista de tokens obtenida; se devuelve si el segmento actual de la lista no es el último.

Errores

- `InvalidInputException`
- `AccessDeniedException`
- `EntityNotFoundException`
- `ThrottlingException`
- `InternalServiceException`

Acción GetSchemaVersion (Python: get_schema_version)

Obtenga el esquema especificado por su ID único asignado cuando se crea o registra una versión del esquema. Las versiones del esquema en estado Deleted (Eliminado) no se incluirán en los resultados.

Solicitud

- `SchemaId`: un objeto SchemaId.

  Una estructura de encapsulador que contiene campos de identidad de esquema. La estructura contiene lo siguiente:

  - SchemaId$SchemaArn: nombre del recurso de Amazon (ARN) del esquema. Se debe proporcionar `SchemaArn` o `SchemaName` y `RegistryName`.
  - SchemaId$SchemaName: el nombre del esquema. Se debe proporcionar `SchemaArn` o `SchemaName` y `RegistryName`.
- `SchemaVersionId` – cadena UTF-8, con 36 bytes de largo como mínimo y 36 bytes de largo como máximo, que coincide con el Custom string pattern #45.

  El `SchemaVersionId` de versión del esquema. Este campo es obligatorio para recuperar por ID de esquema. Se debe proporcionar este encapsulador o `SchemaId`.
- `SchemaVersionNumber`: un objeto SchemaVersionNumber.

  El número de versión del esquema.

Respuesta

- `SchemaVersionId` – cadena UTF-8, con 36 bytes de largo como mínimo y 36 bytes de largo como máximo, que coincide con el Custom string pattern #45.

  El `SchemaVersionId` de versión del esquema.
- `SchemaDefinition` – cadena UTF-8, con 1 byte de largo como mínimo y 170 000 bytes de largo como máximo, que coincide con el Custom string pattern #13.

  Definición de esquema para ID del esquema.
- `DataFormat` – Cadena UTF-8 (valores válidos: `AVRO` | `JSON` | `PROTOBUF`).

El formato de datos de la definición de esquema. `AVRO`, `JSON` y `PROTOBUF` se admiten en la actualidad.

- `SchemaArn` – cadena UTF-8, con 1 byte de largo como mínimo y 10 240 bytes de largo como máximo, que coincide con el Custom string pattern #50.

  Nombre de recurso de Amazon (ARN) del esquema.

- `VersionNumber`: número (largo) que no es inferior a 1 ni es superior a 100 000.

  El número de versión del esquema.

- `Status` – cadena UTF-8 (valores válidos: `AVAILABLE` | `PENDING` | `FAILURE` | `DELETING`).

  El estado de la versión del esquema.

- `CreatedTime`: cadena UTF-8.

  La fecha y hora en que se creó la versión del esquema.

Errores

- `InvalidInputException`
- `AccessDeniedException`
- `EntityNotFoundException`
- `ThrottlingException`
- `InternalServiceException`

Acción GetSchemaVersionsDiff (Python: get_schema_versions_diff)

Recupera la diferencia de versión del esquema en el tipo de diferencia especificado entre dos versiones de esquema almacenadas en el Schema Registry.

Esta API le permite comparar dos versiones entre dos definiciones de esquemas bajo el mismo esquema.

Solicitud

- `SchemaId`: obligatorio: objeto SchemaId.

Una estructura de encapsulador que contiene campos de identidad de esquema. La estructura contiene lo siguiente:

- SchemaId$SchemaArn: nombre del recurso de Amazon (ARN) del esquema. Uno de `SchemaArn` o `SchemaName` debe ser proporcionado.
- SchemaId$SchemaName: el nombre del esquema. Uno de `SchemaArn` o `SchemaName` debe ser proporcionado.

- `FirstSchemaVersionNumber`: obligatorio: objeto SchemaVersionNumber.

  La primera de las dos versiones de esquema que se van a comparar.

- `SecondSchemaVersionNumber`: obligatorio: objeto SchemaVersionNumber.

  La segunda de las dos versiones de esquema que se van a comparar.

- `SchemaDiffType` – Obligatorio: cadena UTF-8 (valores válidos: `SYNTAX_DIFF`).

  Se refiere a `SYNTAX_DIFF`, que es el tipo diferente que se soporta actualmente.

Respuesta

- `Diff` – cadena UTF-8, con 1 byte de largo como mínimo y 340 000 bytes de largo como máximo, que coincide con el Custom string pattern #13.

  La diferencia entre esquemas como una cadena en formato JsonPatch.

Errores

- `InvalidInputException`
- `EntityNotFoundException`
- `AccessDeniedException`
- `ThrottlingException`
- `InternalServiceException`

Acción ListRegistries (Python: list_registries)

Devuelve una lista de registros que ha creado, con información mínima del registro. Los registros con estado `Deleting` no se incluirá en los resultados. Se devolverán resultados vacíos si no hay registros disponibles.

Solicitud

- `MaxResults`: número (entero) que no es inferior a 1 ni es superior a 100.

  Número máximo de resultados requeridos por página. Si no se proporciona el valor, el valor predeterminado será 25 por página.
- `NextToken`: cadena UTF-8.

  Token de continuación si se trata de una llamada de continuidad.

Respuesta

- `Registries`: matriz de objetos RegistryListItem.

  Una matriz de objetos `RegistryDetailedListItem` que contienen detalles mínimos de cada registro.
- `NextToken`: cadena UTF-8.

  Token de continuación para paginar la lista de tokens obtenida; se devuelve si el segmento actual de la lista no es el último.

Errores

- `InvalidInputException`
- `AccessDeniedException`
- `ThrottlingException`
- `InternalServiceException`

Acción ListSchemas (Python: list_schemas)

Devuelve una lista de esquemas con detalles mínimos. Los esquemas con estado Deleting (Eliminación) no se incluirán en los resultados. Se devolverán resultados vacíos si no hay esquemas disponibles.

Cuando no se proporciona el `RegistryId`, todos los esquemas de los registros formarán parte de la respuesta de la API.

Solicitud

- `RegistryId`: un objeto RegistryId.

  Una estructura de encapsulador que puede contener el nombre de registro y el nombre de recurso de Amazon (ARN).
- `MaxResults`: número (entero) que no es inferior a 1 ni es superior a 100.

  Número máximo de resultados requeridos por página. Si no se proporciona el valor, el valor predeterminado será 25 por página.
- `NextToken`: cadena UTF-8.

  Token de continuación si se trata de una llamada de continuidad.

Respuesta

- `Schemas`: matriz de objetos SchemalistItem.

  Una matriz de objetos `SchemaListItem` que contienen detalles de cada esquema.
- `NextToken`: cadena UTF-8.

  Token de continuación para paginar la lista de tokens obtenida; se devuelve si el segmento actual de la lista no es el último.

Errores

- `InvalidInputException`
- `AccessDeniedException`
- `EntityNotFoundException`

- `ThrottlingException`
- `InternalServiceException`

Acción RegisterSchemaVersion (Python: register_schema_version)

Agrega una nueva versión al esquema existente. Devuelve un error si la nueva versión del esquema no cumple los requisitos de compatibilidad del conjunto de esquemas. Esta API no creará un nuevo conjunto de esquemas y devolverá un error 404 si el conjunto de esquemas no está ya presente en el Schema Registry.

Si esta es la primera definición de esquema que se registra en el Schema Registry, esta API almacenará la versión del esquema y la devolverá inmediatamente. De lo contrario, esta llamada tiene el potencial de ejecutarse más tiempo que otras operaciones debido a los modos de compatibilidad. Puede invocar la API de `GetSchemaVersion` con el `SchemaVersionId` para comprobar los modos de compatibilidad.

Si la misma definición de esquema ya está almacenada en el Schema Registry como una versión, el ID del esquema existente se devuelve al que realiza la llamada.

Solicitud

- `SchemaId`: obligatorio: objeto SchemaId.

  Una estructura de encapsulador que contiene campos de identidad de esquema. La estructura contiene lo siguiente:

  - SchemaId$SchemaArn: nombre del recurso de Amazon (ARN) del esquema. Se debe proporcionar `SchemaArn` o `SchemaName` y `RegistryName`.
  - SchemaId$SchemaName: el nombre del esquema. Se debe proporcionar `SchemaArn` o `SchemaName` y `RegistryName`.
- `SchemaDefinition` – Obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 170 000 bytes de largo como máximo, que coincide con el Custom string pattern #13.

  Definición de esquema que utiliza la configuración `DataFormat` para el `SchemaName`.

Respuesta

- `SchemaVersionId` – cadena UTF-8, con 36 bytes de largo como mínimo y 36 bytes de largo como máximo, que coincide con el Custom string pattern #45.

El ID único que representa la versión de este esquema.

- `VersionNumber`: número (largo) que no es inferior a 1 ni es superior a 100 000.

  La versión de este esquema (solo para flujo de sincronización, en caso de que sea la primera versión).

- `Status` – cadena UTF-8 (valores válidos: `AVAILABLE` | `PENDING` | `FAILURE` | `DELETING`).

  El estado de la versión del esquema.

Errores

- `InvalidInputException`
- `AccessDeniedException`
- `EntityNotFoundException`
- `ResourceNumberLimitExceededException`
- `ThrottlingException`
- `ConcurrentModificationException`
- `InternalServiceException`

Acción UpdateSchema (Python: update_schema)

Actualiza la descripción, la configuración de compatibilidad o el punto de comprobación de la versión de un conjunto de esquemas.

Para actualizar la configuración de compatibilidad, la llamada no validará la compatibilidad para todo el conjunto de versiones de esquema con la nueva configuración de compatibilidad. Si se proporciona el valor de `Compatibility`, también se requiere el `VersionNumber` (un punto de comprobación). La API validará el número de versión del punto de comprobación para fines de coherencia.

Si se proporciona el valor del `VersionNumber` (punto de comprobación), la `Compatibility` es opcional y esto se puede usar para establecer/restablecer un punto de comprobación para el esquema.

Esta actualización sólo se realizará si el esquema está en el estado AVAILABLE (DISPONIBLE).

Solicitud

- `SchemaId`: obligatorio: objeto SchemaId.

  Una estructura de encapsulador que contiene campos de identidad de esquema. La estructura contiene lo siguiente:

  - SchemaId$SchemaArn: nombre del recurso de Amazon (ARN) del esquema. Uno de `SchemaArn` o `SchemaName` debe ser proporcionado.
  - SchemaId$SchemaName: el nombre del esquema. Uno de `SchemaArn` o `SchemaName` debe ser proporcionado.
- `SchemaVersionNumber`: un objeto SchemaVersionNumber.

  Se requiere el número de versión para realizar la comprobación. Uno de `VersionNumber` o `Compatibility` debe ser proporcionado.
- `Compatibility` – Cadena UTF-8 (valores válidos: `NONE` | `DISABLED` | `BACKWARD` | `BACKWARD_ALL` | `FORWARD` | `FORWARD_ALL` | `FULL` | `FULL_ALL`).

  La nueva configuración de compatibilidad para el esquema.
- `Description` – cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  La nueva descripción del esquema.

Respuesta

- `SchemaArn` – cadena UTF-8, con 1 byte de largo como mínimo y 10 240 bytes de largo como máximo, que coincide con el Custom string pattern #50.

  Nombre de recurso de Amazon (ARN) del esquema.
- `SchemaName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #46.

  El nombre del esquema.
- `RegistryName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #46.

  Nombre del registro que contiene el esquema.

Errores

- `InvalidInputException`
- `AccessDeniedException`
- `EntityNotFoundException`
- `ConcurrentModificationException`
- `ThrottlingException`
- `InternalServiceException`

Acción CheckSchemaVersionValidity (Python: check_schema_version_validity)

Valida el esquema suministrado. Esta llamada no tiene efectos secundarios, simplemente valida el uso del esquema suministrado con `DataFormat` como el formato. Dado que no toma un nombre de conjunto de esquemas, no se realizan comprobaciones de compatibilidad.

Solicitud

- `DataFormat` – Obligatorio: cadena UTF-8 (valores válidos: `AVRO` | `JSON` | `PROTOBUF`).

  El formato de datos de la definición de esquema. `AVRO`, `JSON` y `PROTOBUF` se admiten en la actualidad.
- `SchemaDefinition` – Obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 170 000 bytes de largo como máximo, que coincide con el Custom string pattern #13.

  La definición del esquema que debe validarse.

Respuesta

- `Valid`: booleano.

  Devuelve verdadero, si el esquema es válido y falso en caso contrario.
- `Error`: cadena UTF-8, con 1 byte de largo como mínimo y 5000 bytes de largo como máximo.

  Mensaje de error por falla de validación.

Errores

- `InvalidInputException`
- `AccessDeniedException`
- `ThrottlingException`
- `InternalServiceException`

Acción UpdateRegistry (Python: update_registry)

Actualiza un registro existente que se utiliza para contener una recopilación de esquemas. Las propiedades actualizadas se relacionan con el registro y no modifican ninguno de los esquemas dentro del registro.

Solicitud

- `RegistryId`: obligatorio: objeto RegistryId.

  Una estructura de encapsulador que puede contener el nombre del registro y el nombre de recurso de Amazon (ARN).
- `Description` – Obligatorio: cadena de descripción, máximo de 2048 bytes de largo, que coincide con URI address multi-line string pattern.

  Es una descripción del recurso. Si no se proporciona una descripción, este campo no se actualizará.

Respuesta

- `RegistryName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #46.

  El nombre del registro actualizado.
- `RegistryArn` – cadena UTF-8, con 1 byte de largo como mínimo y 10 240 bytes de largo como máximo, que coincide con el Custom string pattern #50.

  Nombre de recurso de Amazon (ARN) del registro actualizado.

Errores

- `InvalidInputException`
- `AccessDeniedException`
- `EntityNotFoundException`
- `ConcurrentModificationException`
- `ThrottlingException`
- `InternalServiceException`

Acción GetSchemabyDefinition (Python: get_schema_by_definition)

Recupera un esquema mediante la `SchemaDefinition`. La definición de esquema se envía a Schema Registry, se canonicaliza y se resume en un hash. Si el hash se hace coincidir dentro del alcance del `SchemaName` o ARN (o el registro predeterminado, si no se proporciona ninguno), se devuelven los metadatos de ese esquema. De lo contrario, se devuelve un error 404 o NotFound (No encontrado). Las versiones del esquema con estado `Deleted` no se incluirán en los resultados.

Solicitud

- `SchemaId`: obligatorio: objeto SchemaId.

  Una estructura de encapsulador que contiene campos de identidad de esquema. La estructura contiene lo siguiente:

  - SchemaId$SchemaArn: nombre del recurso de Amazon (ARN) del esquema. Uno de `SchemaArn` o `SchemaName` debe ser proporcionado.
  - SchemaId$SchemaName: el nombre del esquema. Uno de `SchemaArn` o `SchemaName` debe ser proporcionado.
- `SchemaDefinition` – Obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 170 000 bytes de largo como máximo, que coincide con el Custom string pattern #13.

  Definición del esquema para el que se requieren detalles de esquema.

Respuesta

- `SchemaVersionId` – cadena UTF-8, con 36 bytes de largo como mínimo y 36 bytes de largo como máximo, que coincide con el Custom string pattern #45.

El ID de esquema de la versión del esquema.

- `SchemaArn` – cadena UTF-8, con 1 byte de largo como mínimo y 10 240 bytes de largo como máximo, que coincide con el Custom string pattern #50.

  Nombre de recurso de Amazon (ARN) del esquema.

- `DataFormat` – Cadena UTF-8 (valores válidos: `AVRO` | `JSON` | `PROTOBUF`).

  El formato de datos de la definición de esquema. `AVRO`, `JSON` y `PROTOBUF` se admiten en la actualidad.

- `Status` – cadena UTF-8 (valores válidos: `AVAILABLE` | `PENDING` | `FAILURE` | `DELETING`).

  El estado de la versión del esquema.

- `CreatedTime`: cadena UTF-8.

  La fecha y hora en que se creó el esquema.

Errores

- `InvalidInputException`
- `AccessDeniedException`
- `EntityNotFoundException`
- `ThrottlingException`
- `InternalServiceException`

Acción GetRegistry (Python: get_registry)

Describe el registro especificado en detalle.

Solicitud

- `RegistryId`: obligatorio: objeto RegistryId.

  Una estructura de encapsulador que puede contener el nombre del registro y el nombre de recurso de Amazon (ARN).

Respuesta

- `RegistryName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #46.

  El nombre del registro.

- `RegistryArn` – cadena UTF-8, con 1 byte de largo como mínimo y 10 240 bytes de largo como máximo, que coincide con el Custom string pattern #50.

  Nombre de recurso de Amazon (ARN) del registro.

- `Description` – cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Es una descripción del recurso.

- `Status` – Cadena UTF-8 (valores válidos: `AVAILABLE` | `DELETING`).

  Estado del registro.

- `CreatedTime`: cadena UTF-8.

  La fecha y hora en que se creó el registro.

- `UpdatedTime`: cadena UTF-8.

  La fecha y hora en que se actualizó el registro.

Errores

- `InvalidInputException`
- `AccessDeniedException`
- `EntityNotFoundException`
- `ThrottlingException`
- `InternalServiceException`

Acción PutSchemaVersionMetadata (Python: put_schema_version_metadata)

Coloca el par valor-clave de los metadatos para un ID de versión de esquema especificado. Se permitirá un máximo de 10 pares valor-clave por versión de esquema. Se pueden agregar a través de una o más llamadas.

Solicitud

- `SchemaId`: un objeto SchemaId.

  El ID único del esquema.
- `SchemaVersionNumber`: un objeto SchemaVersionNumber.

  El número de versión del esquema.
- `SchemaVersionId` – cadena UTF-8, con 36 bytes de largo como mínimo y 36 bytes de largo como máximo, que coincide con el Custom string pattern #45.

  El ID de versión único de la versión del esquema.
- `MetadataKeyValue`: obligatorio: objeto MetadataKeyValuePair.

  Valor correspondiente de una clave de metadatos.

Respuesta

- `SchemaArn` – cadena UTF-8, con 1 byte de largo como mínimo y 10 240 bytes de largo como máximo, que coincide con el Custom string pattern #50.

  Nombre de recurso de Amazon (ARN) del esquema.
- `SchemaName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #46.

  El nombre para el esquema.
- `RegistryName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #46.

  El nombre para el registro.
- `LatestVersion`: booleano.

La última versión del esquema.

- `VersionNumber`: número (largo) que no es inferior a 1 ni es superior a 100 000.

  El número de versión del esquema.

- `SchemaVersionId` – cadena UTF-8, con 36 bytes de largo como mínimo y 36 bytes de largo como máximo, que coincide con el Custom string pattern #45.

  El ID de versión único de la versión del esquema.

- `MetadataKey` – cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo, que coincide con el Custom string pattern #14.

  La clave de metadatos.

- `MetadataValue` – cadena UTF-8, con 1 byte de largo como mínimo y 256 bytes de largo como máximo, que coincide con el Custom string pattern #14.

  El valor de la clave de metadatos.

Errores

- `InvalidInputException`
- `AccessDeniedException`
- `AlreadyExistsException`
- `EntityNotFoundException`
- `ThrottlingException`
- `ResourceNumberLimitExceededException`

Acción QuerySchemaVersionMetadata (Python: query_schema_version_metadata)

Consulta la información de metadatos de versión del esquema.

Solicitud

- `SchemaId`: un objeto SchemaId.

Una estructura de encapsulador que puede contener el nombre del esquema y el nombre de recurso de Amazon (ARN).

- `SchemaVersionNumber`: un objeto SchemaVersionNumber.

  El número de versión del esquema.

- `SchemaVersionId` – cadena UTF-8, con 36 bytes de largo como mínimo y 36 bytes de largo como máximo, que coincide con el Custom string pattern #45.

  El ID de versión único de la versión del esquema.

- `MetadataList`: matriz de objetos MetadataKeyValuePair.

  Busca los pares clave-valor para los metadatos, si no se proporcionan se obtendrá toda la información de los metadatos.

- `MaxResults`: número (entero) que no es inferior a 1 ni es superior a 50.

  Número máximo de resultados requeridos por página. Si no se proporciona el valor, el valor predeterminado será 25 por página.

- `NextToken`: cadena UTF-8.

  Token de continuación si se trata de una llamada de continuidad.

Respuesta

- `MetadataInfoMap`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 con 1 byte de largo como mínimo y 128 bytes de largo como máximo, que coincide con Custom string pattern #14.

  Cada valor es un objeto A MetadataInfo.

  Mapa de una clave de metadatos y valores asociados.

- `SchemaVersionId` – cadena UTF-8, con 36 bytes de largo como mínimo y 36 bytes de largo como máximo, que coincide con el Custom string pattern #45.

  El ID de versión único de la versión del esquema.

- `NextToken`: cadena UTF-8.

Token de continuación para paginar la lista de tokens obtenida; se devuelve si el segmento actual de la lista no es el último.

Errores

- `InvalidInputException`
- `AccessDeniedException`
- `ThrottlingException`
- `EntityNotFoundException`

Acción RemoveSchemaVersionMetadata (Python: remove_schema_version_metadata)

Elimina un par valor-clave de los metadatos de la versión del esquema para el ID de versión de esquema especificado.

Solicitud

- `SchemaId`: un objeto SchemaId.

  Una estructura de encapsulador que puede contener el nombre del esquema y el nombre de recurso de Amazon (ARN).
- `SchemaVersionNumber`: un objeto SchemaVersionNumber.

  El número de versión del esquema.
- `SchemaVersionId` – cadena UTF-8, con 36 bytes de largo como mínimo y 36 bytes de largo como máximo, que coincide con el Custom string pattern #45.

  El ID de versión único de la versión del esquema.
- `MetadataKeyValue`: obligatorio: objeto MetadataKeyValuePair.

  El valor de la clave de metadatos.

Respuesta

- `SchemaArn` – cadena UTF-8, con 1 byte de largo como mínimo y 10 240 bytes de largo como máximo, que coincide con el Custom string pattern #50.

  Nombre de recurso de Amazon (ARN) del esquema.
- `SchemaName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #46.

  El nombre del esquema.
- `RegistryName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #46.

  El nombre del registro.
- `LatestVersion`: booleano.

  La última versión del esquema.
- `VersionNumber`: número (largo) que no es inferior a 1 ni es superior a 100 000.

  El número de versión del esquema.
- `SchemaVersionId` – cadena UTF-8, con 36 bytes de largo como mínimo y 36 bytes de largo como máximo, que coincide con el Custom string pattern #45.

  El ID de versión de la versión del esquema.
- `MetadataKey` – cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo, que coincide con el Custom string pattern #14.

  La clave de metadatos.
- `MetadataValue` – cadena UTF-8, con 1 byte de largo como mínimo y 256 bytes de largo como máximo, que coincide con el Custom string pattern #14.

  El valor de la clave de metadatos.

Errores

- `InvalidInputException`
- `AccessDeniedException`
- `ThrottlingException`

- `EntityNotFoundException`

Acción DeleteRegistry (Python: delete_registry)

Elimina todo el registro, incluido el esquema y todas sus versiones. Para obtener el estado de la operación de eliminación, puede llamar a la API `GetRegistry` después de la llamada asíncrona. Al eliminar un registro se desactivarán todas las operaciones en línea para el registro, como las API `UpdateRegistry`, `CreateSchema`, `UpdateSchema` y `RegisterSchemaVersion`.

Solicitud

- `RegistryId`: obligatorio: objeto RegistryId.

  Una estructura de encapsulador que puede contener el nombre del registro y el nombre de recurso de Amazon (ARN).

Respuesta

- `RegistryName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #46.

  El nombre del registro que se está eliminando.
- `RegistryArn` – cadena UTF-8, con 1 byte de largo como mínimo y 10 240 bytes de largo como máximo, que coincide con el Custom string pattern #50.

  El nombre de recurso de Amazon (ARN) del registro que se está eliminando.
- `Status` – Cadena UTF-8 (valores válidos: `AVAILABLE` | `DELETING`).

  Estado del registro. Una operación exitosa devolverá el estado `Deleting`.

Errores

- `InvalidInputException`
- `EntityNotFoundException`
- `AccessDeniedException`
- `ThrottlingException`
- `ConcurrentModificationException`

Acción DeleteSchema (Python: delete_schema)

Elimina todo el conjunto de esquemas, incluido el conjunto de esquemas y todas sus versiones. Para obtener el estado de la operación de eliminación, puede llamar a la API `GetSchema` después de la llamada asíncrona. Al eliminar un registro se desactivarán todas las operaciones en línea para el esquema, como las API `GetSchemaByDefinition` y `RegisterSchemaVersion`.

Solicitud

- `SchemaId`: obligatorio: objeto SchemaId.

  Es una estructura de encapsulador que puede contener el nombre del esquema y el nombre de recurso de Amazon (ARN).

Respuesta

- `SchemaArn` – cadena UTF-8, con 1 byte de largo como mínimo y 10 240 bytes de largo como máximo, que coincide con el Custom string pattern #50.

  Nombre de recurso de Amazon (ARN) del esquema que se está eliminando.
- `SchemaName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #46.

  El nombre del esquema que se está eliminando.
- `Status` – Cadena UTF-8 (valores válidos: `AVAILABLE` | `PENDING` | `DELETING`).

  Estado del esquema.

Errores

- `InvalidInputException`
- `EntityNotFoundException`
- `AccessDeniedException`
- `ThrottlingException`
- `ConcurrentModificationException`

Acción DeleteSchemaVersions (Python: delete_schema_versions)

Elimina versiones del esquema especificado. Se puede suministrar un número o rango de versiones. Si el modo de compatibilidad prohíbe eliminar una versión necesaria, como HACIA ATRÁS_COMPLETO, se devuelve un error. Llamar a la API `GetSchemaVersions` después de esta llamada arrojará una lista del estado de las versiones eliminadas.

Cuando el rango de números de versión contiene versiones de punto de comprobación, la API devolverá un conflicto 409 y no continuará con la eliminación. Primero debe eliminar el punto de comprobación con la API `DeleteSchemaCheckpoint`, antes de usar esta API.

No puede usar la API `DeleteSchemaVersions` para eliminar la primera versión del esquema de un conjunto de esquemas. La primera versión del esquema sólo puede ser eliminada por la API `DeleteSchema`. Esta operación también eliminará los `SchemaVersionMetadata` asociados con las versiones del esquema. Se aplicarán eliminaciones fragmentadas en la base de datos.

Si el modo de compatibilidad prohíbe eliminar una versión necesaria, como HACIA ATRÁS_COMPLETO, se devuelve un error.

Solicitud

- `SchemaId`: obligatorio: objeto SchemaId.

  Es una estructura de encapsulador que puede contener el nombre del esquema y el nombre de recurso de Amazon (ARN).

- `Versions` – Obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 100 000 bytes de largo como máximo, que coincide con el Custom string pattern #15.

  Puede suministrarse un rango de versiones que puede tener el siguiente formato:

  - un único número de versión, 5
  - un rango, 5-8: elimina las versiones 5, 6, 7, 8

Respuesta

- `SchemaVersionErrors`: matriz de objetos SchemaVersionErrorItem.

  Una lista de objetos `SchemaVersionErrorItem`, cada uno de los cuales contiene un error y una versión de esquema.

Errores

- `InvalidInputException`
- `EntityNotFoundException`
- `AccessDeniedException`
- `ThrottlingException`
- `ConcurrentModificationException`

Flujos de trabajo

La API de flujos de trabajo permite describir los tipos de datos y la API relacionados con la creación, actualización o visualización de flujos de trabajo en AWS Glue. El historial de ejecución de trabajos está disponible durante 90 días para su flujo de trabajo y ejecución de trabajos.

Tipos de datos

- Estructura JobNodeDetails
- Estructura CrawlerNodeDetails
- Estructura TriggerNodeDetails
- Estructura de rastreo
- Estructura de nodos
- Estructura perimetral
- Estructura de flujo de trabajo
- Estructura WorkflowGraph
- Estructura WorkflowRun
- Estructura WorkflowRunStatistics
- Estructura StartingEventBatchCondition
- Estructura de proyecto
- Estructura BlueprintDetails
- Estructura LastActiveDefinition
- Estructura BlueprintRun

Estructura JobNodeDetails

Los detalles de un nodo de trabajo presente en el flujo de trabajo.

Campos

- `JobRuns`: matriz de objetos JobRun.

  La información para las ejecuciones de trabajo representada por el nodo de trabajo.

Estructura CrawlerNodeDetails

Los detalles de un nodo de rastreador presente en el flujo de trabajo.

Campos

- `Crawls`: matriz de objetos Rastreo.

  Una lista de rastreadores representada por el nodo de rastreo.

Estructura TriggerNodeDetails

Los detalles de un nodo de desencadenador presente en el flujo de trabajo.

Campos

- `Trigger`: un objeto Desencadenador.

  La información del desencadenador representado por el nodo de desencadenador.

Estructura de rastreo

Los detalles de un rastreo en el flujo de trabajo.

Campos

- `State`: cadena UTF-8 (valores válidos: `RUNNING` | `CANCELLING` | `CANCELLED` | `SUCCEEDED` | `FAILED` | `ERROR`).

  El estado del rastreador.

- `StartedOn`: marca temporal.

  La fecha y hora en las que se inició el rastreo.

- `CompletedOn`: marca temporal.

  La fecha y hora en las que se completó el rastreo.

- `ErrorMessage`: cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  El mensaje de error asociado con el rastreo.

- `LogGroup`: cadena UTF-8, con 1 byte de largo como mínimo y 512 bytes de largo como máximo, que coincide con el Log group string pattern.

  El grupo de registros asociado al rastreo.

- `LogStream`: cadena UTF-8, con 1 byte de largo como mínimo y 512 bytes de largo como máximo, que coincide con el Log-stream string pattern.

  El flujo de registros asociado al rastreo.

Estructura de nodos

Un nodo representa un componente de AWS Glue (desencadenador, rastreador o trabajo) en un gráfico de flujo de trabajo.

Campos

- `Type`: cadena UTF-8 (valores válidos: `CRAWLER` | `JOB` | `TRIGGER`).

  El tipo de componente de AWS Glue representado por el nodo.

- `Name`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del componente de AWS Glue representado por el nodo.

- `UniqueId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID exclusivo asignado al nodo en el flujo de trabajo.

- `TriggerDetails`: un objeto TriggerNodeDetails.

Detalles del desencadenador cuando el nodo representa a un desencadenador.

- `JobDetails`: un objeto JobNodeDetails.

  Detalles del trabajo cuando el nodo representa a un trabajo.

- `CrawlerDetails`: un objeto CrawlerNodeDetails.

  Detalles del rastreador cuando el nodo representa a un rastreador.

Estructura perimetral

Un borde representa una conexión dirigida entre dos componentes de AWS Glue que forman parte del flujo de trabajo al que pertenece el borde.

Campos

- `SourceId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nodo único dentro del flujo de trabajo en el que se inicia el perímetro.

- `DestinationId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El único del nodo en el flujo de trabajo donde finaliza el perímetro.

Estructura de flujo de trabajo

Un flujo de trabajo es una recopilación de varios trabajos y rastreadores de AWS Glue que se ejecutan para completar una tarea ETL compleja. Los flujos de trabajo administran la ejecución y monitoreo de todos sus trabajos y rastreadores.

Campos

- `Name`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del flujo de trabajo.

- `Description`: cadena UTF-8.

Una descripción del flujo de trabajo.

- `DefaultRunProperties`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Cada valor es una cadena UTF-8.

  Una colección de propiedades que se va a utilizar como parte de cada ejecución del flujo de trabajo. Las propiedades de ejecución están disponibles para cada trabajo del flujo de trabajo. Un trabajo puede modificar las propiedades de los siguientes trabajos en el flujo.

- `CreatedOn`: marca temporal.

  La fecha y hora en las que se ha creado el flujo de trabajo.

- `LastModifiedOn`: marca temporal.

  La fecha y hora en las que se ha modificado el flujo de trabajo por última vez.

- `LastRun`: un objeto WorkflowRun.

  La información sobre la última ejecución del flujo de trabajo.

- `Graph`: un objeto WorkflowGraph.

  El gráfico que representa todos los componentes de AWS Glue que pertenecen al flujo de trabajo como nodos y conexiones dirigidas entre ellos como bordes.

- `CreationStatus`: cadena UTF-8 (valores válidos: `CREATING` | `CREATED` | `CREATION_FAILED`).

  El estado de creación del flujo de trabajo.

- `MaxConcurrentRuns`: número (entero).

  Puede utilizar este parámetro para evitar varias actualizaciones no deseadas de datos, para controlar los costos o, en algunos casos, para evitar que se supere el número máximo de ejecuciones concurrentes de cualquiera de los trabajos de los componentes. Si deja este parámetro en blanco, no hay límite en el número de ejecuciones concurrentes de flujos de trabajo.

- `BlueprintDetails`: un objeto BlueprintDetails.

  Esta estructura indica los detalles del proyecto desde el que se crea este flujo de trabajo en particular.

Estructura WorkflowGraph

Un gráfico de flujo de trabajo representa el flujo de trabajo completo que contiene todos los componentes de AWS Glue presentes en el flujo de trabajo y todas las conexiones dirigidas entre ellos.

Campos

- `Nodes`: matriz de objetos Nodo.

  Una lista de los componentes de AWS Glue que pertenecen al flujo de trabajo representados como nodos.

- `Edges`: matriz de objetos Periferia.

  Una lista de todas las conexiones dirigidas entre los nodos que pertenecen al flujo de trabajo.

Estructura WorkflowRun

Una ejecución de flujo de trabajo proporciona toda la información sobre el tiempo de ejecución.

Campos

- `Name`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del flujo de trabajo que se ejecutó.

- `WorkflowRunId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de esta ejecución de flujo de trabajo.

- `PreviousRunId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de la ejecución de flujo de trabajo anterior.

- `WorkflowRunProperties`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

Cada valor es una cadena UTF-8.

Las propiedades de ejecución de flujo de trabajo que se establecieron durante la ejecución.

- `StartedOn`: marca temporal.

  La fecha y hora en las que se inició la ejecución de flujo de trabajo.

- `CompletedOn`: marca temporal.

  La fecha y hora en las que se completó la ejecución de flujo de trabajo.

- `Status`: cadena UTF-8 (valores válidos: `RUNNING` | `COMPLETED` | `STOPPING` | `STOPPED` | `ERROR`).

  El estado de la ejecución de flujo de trabajo.

- `ErrorMessage`: cadena UTF-8.

  Este mensaje de error describe cualquier error que se haya producido al iniciar la ejecución del flujo de trabajo. Actualmente, el único mensaje de error es “Concurrent runs exceeded for workflow: `foo` (Exceso de ejecuciones simultáneas para el flujo de trabajo: foo)”.

- `Statistics`: un objeto WorkflowRunStatistics.

  Las estadísticas de la ejecución.

- `Graph`: un objeto WorkflowGraph.

  El gráfico que representa todos los componentes de AWS Glue que pertenecen al flujo de trabajo como nodos y conexiones dirigidas entre ellos como bordes.

- `StartingEventBatchCondition`: un objeto StartingEventBatchCondition.

  La condición del lote que inició la ejecución del flujo de trabajo.

Estructura WorkflowRunStatistics

Las estadísticas de ejecución de flujo de trabajo proporcionan estadísticas sobre la ejecución de flujo de trabajo.

Campos

- `TotalActions`: número (entero).

  Número total de acciones en la ejecución de flujo de trabajo.

- `TimeoutActions`: número (entero).

  Número total de acciones para las que se agotó el tiempo de espera.
- `FailedActions`: número (entero).

  Número total de acciones erróneas.
- `StoppedActions`: número (entero).

  Número total de acciones detenidas.
- `SucceededActions`: número (entero).

  Número total de acciones correctas.
- `RunningActions`: número (entero).

  Número total de acciones en estado de ejecución.
- `ErroredActions`: número (entero).

  Indica el recuento de ejecuciones de trabajos en estado ERROR en la ejecución del flujo de trabajo.
- `WaitingActions`: número (entero).

  Indica el recuento de ejecuciones de trabajos en estado WAITING (EN ESPERA) en la ejecución del flujo de trabajo.

Estructura StartingEventBatchCondition

La condición del lote que inició la ejecución del flujo de trabajo. El número de eventos indicado en el tamaño del lote llegó, en cuyo caso el miembro BatchSize es distinto de cero, o la ventana del lote venció, en cuyo caso el miembro BatchWindow es distinto de cero.

Campos

- `BatchSize`: número (entero).

  Número de eventos en el lote.
- `BatchWindow`: número (entero).

  Duración en segundos de la ventana del lote.

Estructura de proyecto

Los detalles de un proyecto.

Campos

- `Name`: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo, que coincide con el Custom string pattern #31.

  El nombre del proyecto.
- `Description`: cadena UTF-8, con 1 byte de largo como mínimo y 512 bytes de largo como máximo.

  Descripción del proyecto.
- `CreatedOn`: marca temporal.

  La fecha y la hora en que se registró el proyecto.
- `LastModifiedOn`: marca temporal.

  La fecha y hora en la que se modificó el proyecto por última vez.
- `ParameterSpec`: cadena UTF-8, con 1 byte de largo como mínimo y 131 072 bytes de largo como máximo.

  Cadena JSON que indica la lista de especificaciones de parámetros para el proyecto.
- `BlueprintLocation`: cadena UTF-8.

  Especifica la ruta en Amazon S3 donde se publica el proyecto.
- `BlueprintServiceLocation`: cadena UTF-8.

  Especifica una ruta en Amazon S3 donde se copia el proyecto cuando se llama a `CreateBlueprint/UpdateBlueprint` para registrar el proyecto en AWS Glue.
- `Status`: cadena UTF-8 (valores válidos: `CREATING` | `ACTIVE` | `UPDATING` | `FAILED`).

  El estado del registro del proyecto.
  - Creating (Creación): el registro del proyecto está en curso.
  - Active (Activo): el proyecto se ha registrado correctamente.
  - Updating (Actualización): está en curso una actualización al registro del proyecto.
  - Failed (Error): error en el registro del proyecto.

- `ErrorMessage`: cadena UTF-8.

  Mensaje de error.
- `LastActiveDefinition`: un objeto LastActiveDefinition.

  Cuando hay varias versiones de un proyecto y la última versión tiene algunos errores, este atributo indica la última definición del proyecto correcta que está disponible con el servicio.

Estructura BlueprintDetails

Los detalles de un proyecto.

Campos

- `BlueprintName`: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo, que coincide con el Custom string pattern #31.

  El nombre del proyecto.
- `RunId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de ejecución de este proyecto.

Estructura LastActiveDefinition

Cuando hay varias versiones de un proyecto y la última versión tiene algunos errores, este atributo indica la última definición del proyecto correcta que está disponible con el servicio.

Campos

- `Description`: cadena UTF-8, con 1 byte de largo como mínimo y 512 bytes de largo como máximo.

  Descripción del proyecto.
- `LastModifiedOn`: marca temporal.

  La fecha y hora en la que se modificó el proyecto por última vez.
- `ParameterSpec`: cadena UTF-8, con 1 byte de largo como mínimo y 131 072 bytes de largo como máximo.

Una cadena JSON que especifica los parámetros para el proyecto.

- `BlueprintLocation`: cadena UTF-8.

  Especifica una ruta en Amazon S3 donde el desarrollador de AWS Glue publica el proyecto.

- `BlueprintServiceLocation`: cadena UTF-8.

  Especifica una ruta en Amazon S3 donde se copia el esquema cuando se crea o actualiza el esquema.

Estructura BlueprintRun

Los detalles de una ejecución del proyecto.

Campos

- `BlueprintName`: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo, que coincide con el Custom string pattern #31.

  El nombre del proyecto.

- `RunId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de ejecución de esta ejecución del proyecto.

- `WorkflowName`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre de un flujo de trabajo que se crea como resultado de una ejecución correcta del proyecto. Si la ejecución del proyecto presenta un error, no se creará ningún flujo de trabajo.

- `State`: cadena UTF-8 (valores válidos: `RUNNING` | `SUCCEEDED` | `FAILED` | `ROLLING_BACK`).

  Estado de la ejecución del proyecto. Los valores posibles son los siguientes:

  - Running (Ejecución): la ejecución del proyecto está en curso.
  - Succeeded (Correcta): la ejecución del proyecto se completó correctamente.
  - Failed (Error): la ejecución del proyecto falló y se completó la restauración.
  - Rolling back (Restauración): la ejecución del proyecto falló y la restauración está en curso.

- `StartedOn`: marca temporal.

La fecha y la hora en las que se inició la ejecución del proyecto.

- `CompletedOn`: marca temporal.

  La fecha y la hora en las que se completó la ejecución de proyecto.

- `ErrorMessage`: cadena UTF-8.

  Indica los errores que se detectan al ejecutar el proyecto.

- `RollbackErrorMessage`: cadena UTF-8.

  Si hay algún error al crear las entidades de un flujo de trabajo, intentamos restaurar las entidades creadas hasta ese punto y eliminarlas. Este atributo indica los errores detectados al intentar eliminar las entidades que se crean.

- `Parameters`: cadena UTF-8, con 1 byte de largo como mínimo y 131 072 bytes de largo como máximo.

  Los parámetros del proyecto como una cadena. Será necesario que proporcione un valor para cada clave que se requiera a partir de la especificación de parámetros definida en la `Blueprint $ParameterSpec`.

- `RoleArn`: cadena UTF-8, con 1 byte como mínimo o más de 1024 bytes de largo, que coincide con el Custom string pattern #30.

  El ARN del rol. Este rol será asumido por el servicio de AWS Glue y se utilizará para crear el flujo de trabajo y otras entidades de un flujo de trabajo.

Operaciones

- Acción CreateWorkflow (Python: create_workflow)
- Acción UpdateWorkflow (Python: update_workflow)
- DeleteWorkflow Action (Python: delete_workflow)
- Acción GetWorkFlow (Python: get_workflow)
- Acción ListWorkflows (Python: list_workflows)
- Acción BatchGetWorkflows (Python: batch_get_workflows)
- Acción GetWorkflowRun (Python: get_workflow_run)
- Acción GetWorkflowRuns (Python: get_workflow_runs)

- Acción GetWorkflowRunProperties (Python: get_workflow_run_properties)
- PutWorkflowRunProperties Action (Python: put_workflow_run_properties)
- Acción CreateBlueprint (Python: create_blueprint)
- Acción UpdateBlueprint (Python: update_blueprint)
- Acción DeleteBlueprint (Python: delete_blueprint)
- Acción ListBlueprints (Python: list_blueprints)
- Acción BatchGetBlueprints (Python: batch_get_blueprints)
- Acción StartBlueprintRun (Python: start_blueprint_run)
- Acción GetBlueprintRun (Python: get_blueprint_run)
- Acción GetBlueprintRuns (Python: get_blueprint_runs)
- Acción StartWorkflowRun (Python: start_workflow_run)
- Acción StopWorkflowRun (Python: stop_workflow_run)
- Acción ResumeWorkflowRun (Python: resume_workflow_run)

Acción CreateWorkflow (Python: create_workflow)

Crea un nuevo flujo de trabajo.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre que se va a asignar al flujo de trabajo. Debe ser único en su cuenta.
- `Description`: cadena UTF-8, no más de 120 000 bytes de largo.

  Una descripción del flujo de trabajo.
- `DefaultRunProperties`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Cada valor es una cadena UTF-8.

  Una colección de propiedades que se va a utilizar como parte de cada ejecución del flujo de trabajo.

Es posible que se registren las propiedades de la ejecución. No utilice secretos con formato de texto no cifrado como propiedades. Recupere los secretos desde una conexión de AWS Glue, AWS Secrets Manager u otro mecanismo de administración de secretos si tiene la intención de usarlos en la ejecución del flujo de trabajo.

- `Tags`: matriz de mapas de pares de clave-valor, con 50 pares como máximo.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es una cadena UTF-8 que no tiene más de 256 bytes de largo.

  Las etiquetas que se van a utilizar con este flujo de trabajo.

- `MaxConcurrentRuns`: número (entero).

  Puede utilizar este parámetro para evitar varias actualizaciones no deseadas de datos, para controlar los costos o, en algunos casos, para evitar que se supere el número máximo de ejecuciones concurrentes de cualquiera de los trabajos de los componentes. Si deja este parámetro en blanco, no hay límite en el número de ejecuciones concurrentes de flujos de trabajo.

Respuesta

- `Name`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del flujo de trabajo que se proporcionó como parte de la solicitud.

Errores

- `AlreadyExistsException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`
- `ConcurrentModificationException`

Acción UpdateWorkflow (Python: update_workflow)

Actualiza un flujo de trabajo existente.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del flujo de trabajo que se va a actualizar.
- `Description`: cadena UTF-8, no más de 120 000 bytes de largo.

  La descripción del flujo de trabajo.
- `DefaultRunProperties`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Cada valor es una cadena UTF-8.

  Una colección de propiedades que se va a utilizar como parte de cada ejecución del flujo de trabajo.

  Es posible que se registren las propiedades de la ejecución. No utilice secretos con formato de texto no cifrado como propiedades. Recupere los secretos desde una conexión de AWS Glue, AWS Secrets Manager u otro mecanismo de administración de secretos si tiene la intención de usarlos en la ejecución del flujo de trabajo.
- `MaxConcurrentRuns`: número (entero).

  Puede utilizar este parámetro para evitar varias actualizaciones no deseadas de datos, para controlar los costos o, en algunos casos, para evitar que se supere el número máximo de ejecuciones concurrentes de cualquiera de los trabajos de los componentes. Si deja este parámetro en blanco, no hay límite en el número de ejecuciones concurrentes de flujos de trabajo.

Respuesta

- `Name`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

El nombre del flujo de trabajo que se especificó en la entrada.

Errores

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ConcurrentModificationException`

DeleteWorkflow Action (Python: delete_workflow)

Elimina un flujo de trabajo.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del flujo de trabajo que se va a eliminar.

Respuesta

- `Name`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del flujo de trabajo especificado en la entrada.

Errores

- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ConcurrentModificationException`

Acción GetWorkFlow (Python: get_workflow)

Recupera metadatos de recursos para un flujo de trabajo.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del flujo de trabajo que se va a recuperar.
- `IncludeGraph`: booleano.

  Especifica si se debe incluir un gráfico cuando se devuelven los metadatos de recursos de flujo de trabajo.

Respuesta

- `Workflow`: un objeto Flujo de trabajo.

  Metadatos de recursos para el flujo de trabajo.

Errores

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`

Acción ListWorkflows (Python: list_workflows)

Permite enumerar los nombres de flujos de trabajo creados en la cuenta.

Solicitud

- `NextToken`: cadena UTF-8.

  Token de continuación, si se trata de una solicitud de continuidad.
- `MaxResults`: número (entero), mayor que 1 y menor que 25.

Tamaño máximo de una lista que se devolverá.

Respuesta

- `Workflows`: matriz de cadenas UTF-8, con una cadena como mínimo y 25 cadenas como máximo.

  Lista de nombres de flujos de trabajo en la cuenta.
- `NextToken`: cadena UTF-8.

  Token de continuación, si no se han devuelto todos los nombres de flujo de trabajo.

Errores

- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

Acción BatchGetWorkflows (Python: batch_get_workflows)

Devuelve la lista de metadatos de recursos de una determinada lista de nombres de flujos de trabajo. Después de llamar a la operación `ListWorkflows`, puede llamar a esta operación para obtener acceso a los datos a los que ha concedido permisos. Esta operación admite todos los permisos de IAM, incluidas las condiciones de permisos que utilizan etiquetas.

Solicitud

- `Names` – Obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y 25 cadenas como máximo.

  Lista de nombres de flujos de trabajo, que pueden ser los nombres devueltos en la operación `ListWorkflows`.
- `IncludeGraph`: booleano.

  Especifica si se debe incluir un gráfico cuando se devuelven los metadatos de recursos de flujo de trabajo.

Respuesta

- `Workflows`: matriz de objetos Flujo de trabajo, con una estructura como mínimo y 25 estructuras como máximo.

  Una lista de los metadatos de recursos de flujo de trabajo.
- `MissingWorkflows`: matriz de cadenas UTF-8, con una cadena como mínimo y 25 cadenas como máximo.

  Una lista de nombres de flujos de trabajo no encontrados.

Errores

- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`

Acción GetWorkflowRun (Python: get_workflow_run)

Recupera los metadatos para una ejecución de flujo de trabajo especificada. El historial de ejecución de trabajos está disponible durante 90 días para su flujo de trabajo y ejecución de trabajos.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del flujo de trabajo en ejecución.
- `RunId`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de la ejecución de flujos de trabajo.
- `IncludeGraph`: booleano.

  Especifica si se debe incluir el gráfico de flujo de trabajo en la respuesta o no.

Respuesta

- `Run`: un objeto WorkflowRun.

  Los metadatos de ejecución de ejecución de flujo de trabajo solicitados.

Errores

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`

Acción GetWorkflowRuns (Python: get_workflow_runs)

Recupera los metadatos para todas las ejecuciones de un flujo de trabajo especificado.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del flujo de trabajo cuyos metadatos de ejecuciones deben devolverse.
- `IncludeGraph`: booleano.

  Especifica si se debe incluir el gráfico de flujo de trabajo en la respuesta o no.
- `NextToken`: cadena UTF-8.

  Tamaño máximo de la respuesta.
- `MaxResults`: número (entero) que no es inferior a 1 ni es superior a 1000.

  El número máximo de ejecuciones de flujo de trabajo que se incluirá en la respuesta.

Respuesta

- `Runs`: matriz de objetos WorkflowRun, con una estructura como mínimo y 1000 estructuras como máximo.

Una lista de objetos de metadatos de ejecución de flujo de trabajo.

- `NextToken`: cadena UTF-8.

  Token de continuación, si no se han devuelto todas las ejecuciones de flujo de trabajo solicitadas.

Errores

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`

Acción GetWorkflowRunProperties (Python: get_workflow_run_properties)

Permite recuperar las propiedades de ejecución de flujo de trabajo que se establecieron durante la ejecución.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del flujo de trabajo que se ejecutó.

- `RunId`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de la ejecución de flujo de trabajo cuyas propiedades de ejecución se deben devolver.

Respuesta

- `RunProperties`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Cada valor es una cadena UTF-8.

Las propiedades de ejecución de flujo de trabajo que se establecieron durante la ejecución especificada.

Errores

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`

PutWorkflowRunProperties Action (Python: put_workflow_run_properties)

Permite colocar las propiedades de ejecución del flujo de trabajo especificado para la ejecución del flujo de trabajo determinado. Si una propiedad ya existe para la ejecución especificada, sobrescribe el valor o añade la propiedad a las propiedades existentes.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del flujo de trabajo que se ejecutó.
- `RunId`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de la ejecución de flujo de trabajo para el que se deben actualizar las propiedades de ejecución.
- `RunProperties` – Obligatorio: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Cada valor es una cadena UTF-8.

  Las propiedades que colocar para la ejecución especificada.

Es posible que se registren las propiedades de la ejecución. No utilice secretos con formato de texto no cifrado como propiedades. Recupere los secretos desde una conexión de AWS Glue, AWS Secrets Manager u otro mecanismo de administración de secretos si tiene la intención de usarlos en la ejecución del flujo de trabajo.

Respuesta

- Sin parámetros de respuesta.

Errores

- `AlreadyExistsException`
- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`
- `ConcurrentModificationException`

Acción CreateBlueprint (Python: create_blueprint)

Registra un proyecto con AWS Glue.

Solicitud

- `Name` – Obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo, que coincide con el Custom string pattern #31.

  El nombre del proyecto.

- `Description`: cadena UTF-8, con 1 byte de largo como mínimo y 512 bytes de largo como máximo.

  Una descripción del proyecto.

- `BlueprintLocation` – Obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 8192 bytes de largo como máximo, que coincide con el Custom string pattern #32.

Especifica la ruta en Amazon S3 donde se publica el proyecto.

- `Tags`: matriz de mapas de pares de clave-valor, con 50 pares como máximo.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es una cadena UTF-8 que no tiene más de 256 bytes de largo.

  Las etiquetas que se van a aplicar a este proyecto.

Respuesta

- `Name`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Devuelve el nombre del proyecto que se registró.

Errores

- `AlreadyExistsException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`
- `ResourceNumberLimitExceededException`

Acción UpdateBlueprint (Python: update_blueprint)

Actualiza un proyecto registrado.

Solicitud

- `Name` – Obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo, que coincide con el Custom string pattern #31.

  El nombre del proyecto.

- `Description`: cadena UTF-8, con 1 byte de largo como mínimo y 512 bytes de largo como máximo.

Una descripción del proyecto.

- `BlueprintLocation` – Obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 8192 bytes de largo como máximo, que coincide con el Custom string pattern #32.

  Especifica la ruta en Amazon S3 donde se publica el proyecto.

Respuesta

- `Name`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Devuelve el nombre del proyecto que se actualizó.

Errores

- `EntityNotFoundException`
- `ConcurrentModificationException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`
- `IllegalBlueprintStateException`

Acción DeleteBlueprint (Python: delete_blueprint)

Elimina un proyecto existente.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del proyecto que se va a eliminar.

Respuesta

- `Name`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Devuelve el nombre del proyecto que se eliminó.

Errores

- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Acción ListBlueprints (Python: list_blueprints)

Muestra todos los nombres de proyecto de una cuenta.

Solicitud

- `NextToken`: cadena UTF-8.

  Token de continuación, si se trata de una solicitud de continuidad.
- `MaxResults`: número (entero), mayor que 1 y menor que 25.

  Tamaño máximo de una lista que se devolverá.
- `Tags`: matriz de mapas de pares de clave-valor, con 50 pares como máximo.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es una cadena UTF-8 que no tiene más de 256 bytes de largo.

  Filtra la lista por una etiqueta de recursos de AWS.

Respuesta

- `Blueprints`: matriz de cadenas UTF-8.

  Lista de los nombres del proyectos en la cuenta.
- `NextToken`: cadena UTF-8.

Un token de continuación, si no se han devuelto todos los nombres de proyectos.

Errores

- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

Acción BatchGetBlueprints (Python: batch_get_blueprints)

Recupera información sobre una lista de proyectos.

Solicitud

- `Names` – Obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y 25 cadenas como máximo.

  Una lista de nombres de proyectos.
- `IncludeBlueprint`: booleano.

  Especifica si se debe incluir el proyecto en la respuesta.
- `IncludeParameterSpec`: booleano.

  Especifica si se deben incluir los parámetros, como una cadena de JSON, para el proyecto en la respuesta.

Respuesta

- `Blueprints`: matriz de objetos Proyecto.

  Devuelve una lista de proyectos como un objeto `Blueprints`.
- `MissingBlueprints`: matriz de cadenas UTF-8.

  Devuelve una lista de `BlueprintNames` que no se encontraron.

Errores

- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`

Acción StartBlueprintRun (Python: start_blueprint_run)

Inicia una nueva ejecución del proyecto especificado.

Solicitud

- `BlueprintName` – Obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo, que coincide con el Custom string pattern #31.

  El nombre del proyecto.
- `Parameters`: cadena UTF-8, con 1 byte de largo como mínimo y 131 072 bytes de largo como máximo.

  Especifica los parámetros como un objeto `BlueprintParameters`.
- `RoleArn` – Obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 1024 bytes de largo como máximo, que coincide con el Custom string pattern #30.

  Especifica el rol de IAM utilizado para crear el flujo de trabajo.

Respuesta

- `RunId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de ejecución de esta ejecución del proyecto.

Errores

- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

- `ResourceNumberLimitExceededException`
- `EntityNotFoundException`
- `IllegalBlueprintStateException`

Acción GetBlueprintRun (Python: get_blueprint_run)

Recupera los detalles de una ejecución de proyecto.

Solicitud

- `BlueprintName` – Obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo, que coincide con el Custom string pattern #31.

  El nombre del proyecto.
- `RunId`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de ejecución de la ejecución de proyecto que desea recuperar.

Respuesta

- `BlueprintRun`: un objeto BlueprintRun.

  Devuelve un objeto `BlueprintRun`.

Errores

- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`

Acción GetBlueprintRuns (Python: get_blueprint_runs)

Recupera los detalles de las ejecuciones de proyecto de un proyecto especificado.

Solicitud

- `BlueprintName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del proyecto.
- `NextToken`: cadena UTF-8.

  Token de continuación, si se trata de una solicitud de continuidad.
- `MaxResults`: número (entero) que no es inferior a 1 ni es superior a 1000.

  Tamaño máximo de una lista que se devolverá.

Respuesta

- `BlueprintRuns`: matriz de objetos BlueprintRun.

  Devuelve una lista de objetos `BlueprintRun`.
- `NextToken`: cadena UTF-8.

  Un token de continuación, si no se han devuelto todas las ejecuciones de proyectos.

Errores

- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`

Acción StartWorkflowRun (Python: start_workflow_run)

Inicia una nueva ejecución del flujo de trabajo especificado.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

Nombre del flujo de trabajo que se va a iniciar.

- `RunProperties`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Cada valor es una cadena UTF-8.

  Las propiedades de ejecución del flujo de trabajo para la ejecución del flujo de trabajo nuevo.

  Es posible que se registren las propiedades de la ejecución. No utilice secretos con formato de texto no cifrado como propiedades. Recupere los secretos desde una conexión de AWS Glue, AWS Secrets Manager u otro mecanismo de administración de secretos si tiene la intención de usarlos en la ejecución del flujo de trabajo.

Respuesta

- `RunId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Una identificación para la nueva carrera.

Errores

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`
- `ConcurrentRunsExceededException`

Acción StopWorkflowRun (Python: stop_workflow_run)

Detiene la ejecución del flujo de trabajo especificado.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del flujo de trabajo que se va a detener.
- `RunId`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de los flujos de trabajo que se detendrán.

Respuesta

- Sin parámetros de respuesta.

Errores

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `IllegalWorkflowStateException`

Acción ResumeWorkflowRun (Python: resume_workflow_run)

Reinicia los nodos seleccionados de una ejecución de flujo de trabajo anterior parcialmente completada y reanuda la ejecución del flujo de trabajo. Se ejecutan los nodos seleccionados y todos los nodos descendentes a los nodos seleccionados.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del flujo de trabajo que se reanudará.
- `RunId`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

El ID de la ejecución del flujo de trabajo que se reanudará.

- `NodeIds` – Obligatorio: una matriz de cadenas UTF-8.

  Una lista de ID de nodos para los nodos que desea reiniciar. Los nodos que se reiniciarán deben tener un intento de ejecución en la ejecución original.

Respuesta

- `RunId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nuevo ID asignado a la ejecución del flujo de trabajo reanudado. Cada reanudación de una ejecución de flujo de trabajo tendrá un nuevo ID de ejecución.
- `NodeIds`: matriz de cadenas UTF-8.

  Una lista de los ID de los nodos para los nodos que realmente se reiniciaron.

Errores

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ConcurrentRunsExceededException`
- `IllegalWorkflowStateException`

Perfiles de uso

La API de perfiles de uso describe los tipos de datos y la API relacionados con la creación, actualización o visualización de los perfiles de uso en AWS Glue.

Tipos de datos

- Estructura ProfileConfiguration
- Estructura ConfigurationObject

- Estructura UsageProfileDefinition

Estructura ProfileConfiguration

Especifica los valores de trabajo y sesión que un administrador configura en un perfil de uso de AWS Glue.

Campos

- `SessionConfiguration`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Cada valor es un objeto A ConfigurationObject.

  Un mapa de clave-valor de los parámetros de configuración de las sesiones de AWS Glue.
- `JobConfiguration`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Cada valor es un objeto A ConfigurationObject.

  Un mapa de clave-valor de los parámetros de configuración de los trabajos de AWS Glue.

Estructura ConfigurationObject

Especifica los valores que un administrador establece para cada parámetro de trabajo o sesión configurado en un perfil de uso de AWS Glue.

Campos

- `DefaultValue`: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo, que coincide con el Custom string pattern #35.

  Un valor predeterminado para el parámetro.
- `AllowedValues`: matriz de cadenas UTF-8.

  Una lista de valores permitidos para el parámetro.

- `MinValue`: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo, que coincide con el Custom string pattern #35.

  Un valor mínimo permitido para el parámetro.
- `MaxValue`: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo, que coincide con el Custom string pattern #35.

  Un valor máximo permitido para el parámetro.

Estructura UsageProfileDefinition

Describe un perfil de uso de AWS Glue.

Campos

- `Name`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del perfil de uso.
- `Description`: cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Una descripción del perfil de uso.
- `CreatedOn`: marca temporal.

  La fecha y la hora en que se creó el perfil de uso.
- `LastModifiedOn`: marca temporal.

  La fecha y la hora en que se modificó el perfil de uso por última vez.

Operaciones

- Acción CreateUsageProfile (Python: create_usage_profile)
- Acción GetUsageProfile (Python: get_usage_profile)
- Acción UpdateUsageProfile (Python: update_usage_profile)
- Acción DeleteUsageProfile (Python: delete_usage_profile)
- Acción ListUsageProfiles (Python: list_usage_profiles)

Acción CreateUsageProfile (Python: create_usage_profile)

Crea un perfil de uso de AWS Glue.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del perfil de uso.
- `Description`: cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Una descripción del perfil de uso.
- `Configuration`: obligatorio: objeto ProfileConfiguration.

  Un objeto `ProfileConfiguration` que especifica los valores de trabajo y sesión del perfil.
- `Tags`: matriz de mapas de pares de clave-valor, con 50 pares como máximo.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es una cadena UTF-8 que no tiene más de 256 bytes de largo.

  Una lista de etiquetas aplicadas al perfil de uso.

Respuesta

- `Name`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del perfil de uso que se creó.

Errores

- `InvalidInputException`
- `InternalServiceException`
- `AlreadyExistsException`
- `OperationTimeoutException`

- `ResourceNumberLimitExceededException`
- `OperationNotSupportedException`

Acción GetUsageProfile (Python: get_usage_profile)

Recupera información sobre el perfil de uso de AWS Glue especificado.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del perfil de uso que se va a recuperar.

Respuesta

- `Name`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del perfil de uso.
- `Description`: cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Una descripción del perfil de uso.
- `Configuration`: un objeto ProfileConfiguration.

  Un objeto `ProfileConfiguration` que especifica los valores de trabajo y sesión del perfil.
- `CreatedOn`: marca temporal.

  La fecha y la hora en que se creó el perfil de uso.
- `LastModifiedOn`: marca temporal.

  La fecha y la hora en que se modificó el perfil de uso por última vez.

Errores

- `InvalidInputException`
- `InternalServiceException`

- `EntityNotFoundException`
- `OperationTimeoutException`
- `OperationNotSupportedException`

Acción UpdateUsageProfile (Python: update_usage_profile)

Actualiza un perfil de uso de AWS Glue.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del perfil de uso.
- `Description`: cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Una descripción del perfil de uso.
- `Configuration`: obligatorio: objeto ProfileConfiguration.

  Un objeto `ProfileConfiguration` que especifica los valores de trabajo y sesión del perfil.

Respuesta

- `Name`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del perfil de uso que se actualizó.

Errores

- `InvalidInputException`
- `InternalServiceException`
- `EntityNotFoundException`
- `OperationTimeoutException`
- `OperationNotSupportedException`

- `ConcurrentModificationException`

Acción DeleteUsageProfile (Python: delete_usage_profile)

Elimina el perfil de uso de AWS Glue especificado.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del perfil de uso que se va a eliminar.

Respuesta

- Sin parámetros de respuesta.

Errores

- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `OperationNotSupportedException`

Acción ListUsageProfiles (Python: list_usage_profiles)

Enumera todos los perfiles de uso de AWS Glue.

Solicitud

- `NextToken`: cadena UTF-8 de 400 000 bytes de largo como máximo.

  Token de continuación, incluido si se trata de una llamada de continuidad.
- `MaxResults`: número (entero), mayor que 1 y menor que 200.

  El número máximo de perfiles de uso que se devolverán en una sola respuesta.

Respuesta

- `Profiles`: matriz de objetos UsageProfileDefinition.

  Una lista de objetos del perfil de uso (`UsageProfileDefinition`).
- `NextToken`: cadena UTF-8 de 400 000 bytes de largo como máximo.

  Un token de continuación, presente si el segmento de lista actual no es el último.

Errores

- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`
- `OperationNotSupportedException`

API de machine learning

La API de machine learning describe los tipos de datos de machine learning e incluye la API para crear, eliminar o actualizar una transformación, o para iniciar la ejecución una tarea de machine learning.

Tipos de datos

- Estructura TransformParameters
- Estructura EvaluationMetrics
- Estructura MLTransform
- Estructura FindMatchesParameters
- Estructura FindMatchesMetrics
- Estructura ConfusionMatrix
- Estructura GlueTable
- Estructura TaskRun
- Estructura TransformFilterCriteria
- Estructura TransformSortCriteria
- Estructura TaskRunFilterCriteria

- Estructura TaskRunSortCriteria
- Estructura TaskRunProperties
- Estructura FindMatchesTaskRunProperties
- Estructura ImportLabelsTaskRunProperties
- Estructura ExportLabelsTaskRunProperties
- Estructura LabelingSetGenerationTaskRunProperties
- Estructura SchemaColumn
- Estructura TransformEncryption
- Estructura MLUserDataEncryption
- Estructura ColumnImportance

Estructura TransformParameters

Los parámetros específicos del algoritmo que están asociados a la transformación de machine learning.

Campos

- `TransformType` – Obligatorio: cadena UTF-8 (valores válidos: `FIND_MATCHES`).

  El tipo de transformación de machine learning.

  Para obtener más información sobre los tipos de transformaciones de machine learning, consulte Creación de transformaciones de machine learning.
- `FindMatchesParameters`: un objeto FindMatchesParameters.

  Los parámetros para el algoritmo de búsqueda de coincidencias.

Estructura EvaluationMetrics

Las métricas de evaluación proporcionan una estimación de la calidad de su transformación de machine learning.

Campos

- `TransformType` – Obligatorio: cadena UTF-8 (valores válidos: `FIND_MATCHES`).

El tipo de transformación de machine learning.

- `FindMatchesMetrics`: un objeto FindMatchesMetrics.

  Las métricas de evaluación para el algoritmo de búsqueda de coincidencias.

Estructura MLTransform

Una estructura para una transformación de machine learning.

Campos

- `TransformId` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de transformación único que se genera para la transformación de machine learning. Se garantiza que el ID es único y que no cambia.
- `Name` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Un nombre definido por el usuario para la transformación de machine learning. No se garantiza que los nombres sean únicos y se puedan cambiar en cualquier momento.
- `Description` – cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Un texto de descripción largo definido por el usuario para la transformación de machine learning. No se garantiza que las descripciones sean únicas y se puedan cambiar en cualquier momento.
- `Status` – Cadena UTF-8 (valores válidos: `NOT_READY` | `READY` | `DELETING`).

  El estado actual de la transformación de machine learning.
- `CreatedOn`: marca temporal.

  Una marca temporal. La fecha y hora en las que se creó esta transformación de machine learning.
- `LastModifiedOn`: marca temporal.

  Una marca temporal. El último momento en el que se modificó esta transformación de machine learning.
- `InputRecordTables`: matriz de objetos GlueTable, con 10 estructuras como máximo.

Una lista de definiciones de tabla de AWS Glue utilizadas por la transformación.

- `Parameters`: un objeto TransformParameters.

  Un objeto `TransformParameters`. Puede utilizar parámetros para ajustar (personalizar) el comportamiento de la transformación de machine learning mediante la especificación de los datos que aprende y sus preferencias en diversas compensaciones (como precisión frente a exhaustividad o exactitud frente a costo).

- `EvaluationMetrics`: un objeto EvaluationMetrics.

  Un objeto `EvaluationMetrics`. Las métricas de evaluación proporcionan una estimación de la calidad de su transformación de machine learning.

- `LabelCount`: número (entero).

  Un identificador de recuentos para los archivos de etiquetado generados por AWS Glue para esta transformación. A medida que se crea una mejor transformación, puede descargar, etiquetar y cargar de forma iterativa el archivo de etiquetado.

- `Schema`: matriz de objetos SchemaColumn, con 100 estructuras como máximo.

  Una asignación de pares clave-valor que representa las columnas y tipos de datos con la que se puede ejecutar esta transformación. Tiene un límite superior de 100 columnas.

- `Role`: cadena UTF-8.

  El nombre o nombre de recurso de Amazon (ARN) del rol de IAM con los permisos obligatorios. Los permisos necesarios incluyen tanto permisos de rol de servicio de AWS Glue para recursos de AWS Glue, como permisos de Amazon S3 requeridos por la transformación.

  - Este rol necesita permisos de rol de servicio de AWS Glue para permitir el acceso a los recursos de AWS Glue. Consulte Asociar una política a usuarios de IAM que obtienen acceso a AWS Glue.
  - Este rol necesita permiso para los orígenes, los destinos, los directorios temporales, los scripts y las bibliotecas de Amazon Simple Storage Service (Amazon S3) utilizados por la ejecución de tareas para esta plataforma.

- `GlueVersion` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #48.

  Este valor determina con qué versión de AWS Glue es compatible esta transformación de machine learning. Se recomienda Glue 1.0 para la mayoría de los clientes. Si el valor no está establecido,

la compatibilidad de Glue se establece de forma predeterminada en Glue 0.9. Para obtener más información, consulte las Versiones de AWS Glue en la guía para desarrolladores.

- `MaxCapacity`: número (doble).

  El número de unidades de procesamiento de datos (DPU) de AWS Glue que se asigna a ejecuciones de tareas para esta transformación. Puede asignar de 2 a 100 DPU; el valor predeterminado es 10. Una DPU es una medida relativa de la potencia de procesamiento que consta de 4 vCPU de capacidad de cómputo y 16 GB de memoria. Para obtener más información, consulte la página de precios de AWS Glue.

  `MaxCapacity` es una opción mutuamente excluyente con `NumberOfWorkers` y `WorkerType`.

  - Si se establecen `NumberOfWorkers` o `WorkerType`, no se puede establecer `MaxCapacity`.
  - Si `MaxCapacity` se establece, no se pueden establecer `NumberOfWorkers` ni `WorkerType`.
  - Si `WorkerType` se establece, `NumberOfWorkers` es obligatorio (y viceversa).
  - `MaxCapacity` y `NumberOfWorkers` deben ser al menos 1.

  Cuando el campo `WorkerType` se establece en un valor distinto a `Standard`, el campo `MaxCapacity` se establece automáticamente y se convierte a solo lectura.

- `WorkerType` – Cadena UTF-8 (valores válidos: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

  El tipo de proceso de trabajo predefinido que se asigna cuando se ejecuta una tarea de esta transformación. Admite un valor de Standard, G.1X o G.2X.

  - Para el tipo de proceso de trabajo `Standard`, cada proceso de trabajo proporciona 4 vCPU, 16 GB de memoria y un disco de 50 GB y 2 ejecutores por proceso de trabajo.
  - Para el tipo de proceso de trabajo `G.1X`, cada proceso de trabajo proporciona 4 vCPU, 16 GB de memoria y un disco de 64 GB y 1 ejecutor por proceso de trabajo.
  - Para el tipo de proceso de trabajo `G.2X`, cada proceso de trabajo proporciona 8 vCPU, 32 GB de memoria y un disco de 128 GB y 1 ejecutor por proceso de trabajo.

  `MaxCapacity` es una opción mutuamente excluyente con `NumberOfWorkers` y `WorkerType`.

  - Si se establecen `NumberOfWorkers` o `WorkerType`, no se puede establecer `MaxCapacity`.
  - Si `MaxCapacity` se establece, no se pueden establecer `NumberOfWorkers` ni `WorkerType`.
  - Si `WorkerType` se establece, `NumberOfWorkers` es obligatorio (y viceversa).
  - `MaxCapacity` y `NumberOfWorkers` deben ser al menos 1.

- `NumberOfWorkers`: número (entero).

  El número de procesos de trabajo de un `workerType` definido que se asigna cuando se ejecuta una tarea de la transformación.

  Si `WorkerType` se establece, `NumberOfWorkers` es obligatorio (y viceversa).

- `Timeout`: número (entero), como mínimo 1.

  El tiempo de espera en minutos de la transformación de machine learning.

- `MaxRetries`: número (entero).

  El número máximo de reintentos después de que se produzca un error de `MLTaskRun` de la transformación de machine learning.

- `TransformEncryption`: un objeto TransformEncryption.

  La configuración de cifrado en reposo de la transformación que se aplica al acceso a los datos del usuario. Las transformaciones de machine learning pueden acceder a los datos de usuario cifrados en Amazon S3 mediante KMS.

Estructura FindMatchesParameters

Los parámetros para configurar la transformación de búsquedas de coincidencias.

Campos

- `PrimaryKeyColumnName` – cadena UTF-8, con 1 byte como mínimo o más de 1024 bytes de largo, que coincide con el Single-line string pattern.

  El nombre de una columna que identifica de forma única las filas en la tabla de origen. Se utiliza para ayudar a identificar los registros coincidentes.

- `PrecisionRecallTradeoff`: número (doble), 1,0 como máximo.

  El valor seleccionado al ajustar su transformación para un equilibrio entre la precisión y la exhaustividad. Un valor de 0,5 implica que no hay preferencia; un valor de 1,0 significa un sesgo únicamente para precisión, y un valor de 0,0 implica un sesgo de exhaustividad. Puesto que se trata de una compensación, elegir valores próximos a 1,0 implica una exhaustividad menor y elegir resultados próximos a 0,0 origina una precisión muy baja.

La métrica de precisión indica la frecuencia con la que el modelo es correcto cuando predice una coincidencia.

La métrica de exhaustividad indica la frecuencia con la que el modelo predice la coincidencia en la coincidencia real.

- `AccuracyCostTradeoff`: número (doble), 1,0 como máximo.

  El valor seleccionado al ajustar su transformación para un equilibrio entre la exactitud y el costo. Un valor de 0,5 significa que el sistema equilibra los problemas de exactitud y costo. Un valor de 1,0 implica un sesgo únicamente para la exactitud, que normalmente da como resultado un costo considerablemente mayor, a veces bastante superior. Un valor de 0,0 hace referencia a un sesgo solo para el costo, lo que se traduce en una transformación `FindMatches` menos precisa, a veces con una exactitud inaceptable.

  La exactitud mide la facilidad con la que la transformación encuentra verdaderos positivos y verdaderos negativos. El aumento de la exactitud requiere más recursos informáticos y costos. Sin embargo, también genera una mayor exhaustividad.

  El costo mide la cantidad de recursos informáticos y, por lo tanto, dinero, necesario para ejecutar la transformación.

- `EnforceProvidedLabels`: booleano.

  El valor para activar o desactivar la opción para forzar la salida para que coincida con las etiquetas proporcionadas de los usuarios. Si el valor es `True`, la transformación `find matches` fuerza la salida para que coincida con las etiquetas proporcionadas. Los resultados anulan los resultados de combinación normales. Si el valor es `False`, la transformación `find matches` no que se respeten todas las etiquetas proporcionadas, y los resultados se basan en el modelo entrenado.

  Tenga en cuenta que si se establece este valor en true, el tiempo de ejecución de la combinación puede aumentar.

Estructura FindMatchesMetrics

Las métricas de evaluación para el algoritmo de búsqueda de coincidencias. La calidad de su transformación de machine learning se mide mediante su transformación para predecir algunas coincidencias y comparar los resultados con las coincidencias conocidas desde el mismo conjunto de datos. Las métricas de calidad se basan en un subconjunto de los datos, por lo que no son precisas.

Campos

- `AreaUnderPRCurve`: número (doble), 1,0 como máximo.

  El área bajo la curva de precisión/exhaustividad (AUPRC) es un número único que mide la calidad general de la transformación, que es independiente de la elección realizada para precisión en lugar de la exhaustividad. Los valores más altos indican que cuenta con una compensación de precisión frente a exhaustividad más atractiva.

  Para obtener más información, consulte Precisión y exhaustividad en Wikipedia.

- `Precision`: número (doble), 1,0 como máximo.

  La métrica de precisión indica la frecuencia con la que la transformación es correcta cuando predice una coincidencia. En concreto, mide la facilidad con la que de la transformación encuentra verdaderos positivos en el número total de verdaderos positivos posible.

  Para obtener más información, consulte Precisión y exhaustividad en Wikipedia.

- `Recall`: número (doble), 1,0 como máximo.

  La métrica de exhaustividad indica la frecuencia con la que la transformación predice la coincidencia en la coincidencia real. En concreto, mide la facilidad con la que de la transformación encuentra verdaderos positivos en los registros totales en los datos de origen.

  Para obtener más información, consulte Precisión y exhaustividad en Wikipedia.

- `F1`: número (doble), 1,0 como máximo.

  El valor-F máximo indica la exactitud de la transformación entre 0 y 1, donde 1 es la mejor exactitud.

  Para obtener más información, consulte Valor-F en Wikipedia.

- `ConfusionMatrix`: un objeto ConfusionMatrix.

  La matriz de confusión le muestra lo que la transformación está prediciendo de forma precisa y qué tipos de errores está realizando.

  Para obtener más información, consulte Matriz de confusión en Wikipedia.

- `ColumnImportances`: matriz de objetos ColumnImportance, con 100 estructuras como máximo.

Una lista de estructuras de `ColumnImportance` que contienen métricas de importancia de columna, clasificadas en orden de importancia descendente.

Estructura ConfusionMatrix

La matriz de confusión le muestra lo que la transformación está prediciendo de forma precisa y qué tipos de errores está realizando.

Para obtener más información, consulte Matriz de confusión en Wikipedia.

Campos

- `NumTruePositives`: número (largo).

  El número de coincidencias en los datos que ha detectado la transformación correctamente, en la matriz de confusión para la transformación.
- `NumFalsePositives`: número (largo).

  El número de no coincidencias en los datos que la transformación ha clasificado incorrectamente como una coincidencia en la matriz de confusión para la transformación.
- `NumTrueNegatives`: número (largo).

  El número de no coincidencias en los datos que ha rechazado la transformación correctamente en la matriz de confusión para la transformación.
- `NumFalseNegatives`: número (largo).

  El número de coincidencias en los datos que no ha detectado la transformación en la matriz de confusión para la transformación.

Estructura GlueTable

La base de datos y la tabla en el AWS Glue Data Catalog que se usa para los datos de entrada y salida.

Campos

- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

Un nombre de base de datos en el AWS Glue Data Catalog.

- `TableName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Un nombre de tabla en el AWS Glue Data Catalog.

- `CatalogId` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Un identificador único para el AWS Glue Data Catalog.

- `ConnectionName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la conexión a AWS Glue Data Catalog.

- `AdditionalOptions`: una matriz de asignación de pares de clave-valor, con 1 par como mínimo y 10 como máximo.

  Cada clave es una cadena UTF-8 con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Cada valor es una cadena Description (Descripción), con 2048 bytes de largo como máximo, que coincide con URI address multi-line string pattern.

  Opciones adicionales para la tabla. Actualmente se admiten dos claves:

  - `pushDownPredicate`: filtra particiones sin tener que enumerar y leer todos los archivos del conjunto de datos.
  - `catalogPartitionPredicate`: para utilizar la eliminación de particiones del lado del servidor mediante los índices de particiones de AWS Glue Data Catalog.

Estructura TaskRun

Los parámetros de muestreo que están asociados a la transformación de machine learning.

Campos

- `TransformId` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

El identificador único de la transformación.

- `TaskRunId` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El identificador único para esta ejecución de tareas.

- `Status` – Cadena UTF-8 (valores válidos: `RUNNING` | `FINISHED` | `FAILED` | `PENDING_EXECUTION` | `TIMED_OUT` | `CANCELING` | `CANCELED` | `RECEIVED_BY_TASKRUNNER`).

  El estado actual de la ejecución de tareas solicitada.

- `LogGroupName`: cadena UTF-8.

  Los nombres del grupo de registros para el registro segur asociados a esta ejecución de tareas.

- `Properties`: un objeto TaskRunProperties.

  Especifica las propiedades de configuración asociadas a esta ejecución de tareas.

- `ErrorString`: cadena UTF-8.

  La lista de cadenas de error asociadas a esta ejecución de tareas.

- `StartedOn`: marca temporal.

  La fecha y la hora en la que se inició esta tarea.

- `LastModifiedOn`: marca temporal.

  La última vez que se actualizó la ejecución de tareas solicitada.

- `CompletedOn`: marca temporal.

  La última vez que se completó la tarea solicitada.

- `ExecutionTime`: número (entero).

  El período (en segundos) que la ejecución de tareas consumió recursos.

Estructura TransformFilterCriteria

Los criterios utilizados para filtrar las transformaciones de machine learning.

Campos

- `Name` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Un nombre de transformación único que se utiliza para filtrar las transformaciones de machine learning.

- `TransformType` – Cadena UTF-8 (valores válidos: `FIND_MATCHES`).

  El tipo de transformación de machine learning que se utiliza para filtrar las transformaciones de machine learning.

- `Status` – Cadena UTF-8 (valores válidos: `NOT_READY` | `READY` | `DELETING`).

  Permite filtrar la lista de transformaciones de machine learning por el último estado conocido de las transformaciones (para indicar si una transformación se puede utilizar o no). Una de "NOT_READY", "READY" o "DELETING".

- `GlueVersion` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #48.

  Este valor determina con qué versión de AWS Glue es compatible esta transformación de machine learning. Se recomienda Glue 1.0 para la mayoría de los clientes. Si el valor no está establecido, la compatibilidad de Glue se establece de forma predeterminada en Glue 0.9. Para obtener más información, consulte las Versiones de AWS Glue en la guía para desarrolladores.

- `CreatedBefore`: marca temporal.

  La fecha y hora antes de las que se crearon las transformaciones.

- `CreatedAfter`: marca temporal.

  La fecha y hora después de las que se crearon las transformaciones.

- `LastModifiedBefore`: marca temporal.

  Permite filtrar por las últimas transformaciones modificadas antes de esta fecha.

- `LastModifiedAfter`: marca temporal.

  Permite filtrar por las últimas transformaciones modificadas después de esta fecha.

- `Schema`: matriz de objetos SchemaColumn, con 100 estructuras como máximo.

Permite filtrar por conjuntos de datos con un esquema específico. El objeto `Map<Column, Type>` es una matriz de pares clave-valor que representa el esquema que acepta esta transformación, donde `Column` es el nombre de una columna, y `Type` es el tipo de datos como, por ejemplo, un número entero o una cadena. Tiene un límite superior de 100 columnas.

Estructura TransformSortCriteria

Los criterios de ordenación que están asociados a la transformación de machine learning.

Campos

- `Column` – Obligatorio: cadena de UTF-8 (valores válidos: `NAME` | `TRANSFORM_TYPE` | `STATUS` | `CREATED` | `LAST_MODIFIED`).

  La columna que se va a utilizar en los criterios de ordenación que están asociados a la transformación de machine learning.
- `SortDirection`: obligatorio: cadena UTF-8 (valores válidos: `DESCENDING` | `ASCENDING`).

  La dirección de ordenación que se va a utilizar en los criterios de ordenación que están asociados a la transformación de machine learning.

Estructura TaskRunFilterCriteria

Los criterios que se utilizan para filtrar las ejecuciones de tareas durante la transformación de machine learning.

Campos

- `TaskRunType` – Cadena UTF-8 (valores válidos: `EVALUATION` | `LABELING_SET_GENERATION` | `IMPORT_LABELS` | `EXPORT_LABELS` | `FIND_MATCHES`).

  El tipo de ejecución de tareas.
- `Status` – Cadena UTF-8 (valores válidos: `RUNNING` | `FINISHED` | `FAILED` | `PENDING_EXECUTION` | `TIMED_OUT` | `CANCELING` | `CANCELED` | `RECEIVED_BY_TASKRUNNER`).

  El estado actual de la ejecución de tareas.
- `StartedBefore`: marca temporal.

Permite filtrar por ejecuciones de tareas iniciadas antes de esa fecha.

- `StartedAfter`: marca temporal.

  Permite filtrar por ejecuciones de tareas iniciadas después de esa fecha.

Estructura TaskRunSortCriteria

Los criterios de ordenación que se utilizan para filtrar la lista de ejecuciones de tareas durante la transformación de machine learning.

Campos

- `Column` – Obligatorio: cadena UTF-8 (valores válidos: `TASK_RUN_TYPE` | `STATUS` | `STARTED`).

  La columna que se va a utilizar para ordenar la lista de ejecuciones de tareas durante la transformación de machine learning.

- `SortDirection`: obligatorio: cadena UTF-8 (valores válidos: `DESCENDING` | `ASCENDING`).

  La dirección de ordenación que se va a utilizar para ordenar la lista de ejecuciones de tareas durante la transformación de machine learning.

Estructura TaskRunProperties

Las propiedades de configuración de la ejecución de tareas.

Campos

- `TaskType` – Cadena UTF-8 (valores válidos: `EVALUATION` | `LABELING_SET_GENERATION` | `IMPORT_LABELS` | `EXPORT_LABELS` | `FIND_MATCHES`).

  El tipo de ejecución de tareas.

- `ImportLabelsTaskRunProperties`: un objeto ImportLabelsTaskRunProperties.

  Las propiedades de configuración de una ejecución de tareas de etiquetas de importación.

- `ExportLabelsTaskRunProperties`: un objeto ExportLabelsTaskRunProperties.

  Las propiedades de configuración de una ejecución de tareas de etiquetas de exportación.

- `LabelingSetGenerationTaskRunProperties`: un objeto LabelingSetGenerationTaskRunProperties.

  Las propiedades de configuración de una ejecución de tareas de generación de conjuntos de etiquetas.
- `FindMatchesTaskRunProperties`: un objeto FindMatchesTaskRunProperties.

  Las propiedades de configuración para la ejecución de tareas de búsqueda de coincidencias.

Estructura FindMatchesTaskRunProperties

Especifica las propiedades de configuración para la ejecución de tareas de búsqueda de coincidencias.

Campos

- `JobId` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de trabajo para la ejecución de tareas de búsqueda de coincidencias.
- `JobName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre asignado al trabajo para la ejecución de tareas de búsqueda de coincidencias.
- `JobRunId` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de ejecución de tareas para la ejecución de tareas de búsqueda de coincidencias.

Estructura ImportLabelsTaskRunProperties

Especifica las propiedades de configuración de una ejecución de tareas de etiquetas de importación.

Campos

- `InputS3Path`: cadena UTF-8.

  La ruta de Amazon Simple Storage Service (Amazon S3) desde la que importará las etiquetas.
- `Replace`: booleano.

Indica si se van a sobrescribir las etiquetas existentes.

Estructura ExportLabelsTaskRunProperties

Especifica las propiedades de configuración de una ejecución de tareas de etiquetas de exportación.

Campos

- `OutputS3Path`: cadena UTF-8.

  La ruta de Amazon Simple Storage Service (Amazon S3) en la que exportará las etiquetas.

Estructura LabelingSetGenerationTaskRunProperties

Especifica las propiedades de configuración de una ejecución de tareas de generación de conjuntos de etiquetas.

Campos

- `OutputS3Path`: cadena UTF-8.

  La ruta de Amazon Simple Storage Service (Amazon S3) en la que generará el conjunto de etiquetas.

Estructura SchemaColumn

Un par clave-valor que representa una columna y tipo de datos con el que se puede ejecutar esta transformación. El parámetro `Schema` de `MLTransform` puede contener hasta 100 de estas estructuras.

Campos

- `Name` – cadena UTF-8, con 1 byte como mínimo o más de 1024 bytes de largo, que coincide con el Single-line string pattern.

  El nombre de la columna.
- `DataType` – cadena UTF-8 con un máximo de 131072 bytes de largo, que coincide con el Single-line string pattern.

El tipo de datos en la columna.

Estructura TransformEncryption

La configuración de cifrado en reposo de la transformación que se aplica al acceso a los datos del usuario. Las transformaciones de machine learning pueden acceder a los datos de usuario cifrados en Amazon S3 mediante KMS.

Además, las etiquetas importadas y las transformaciones entrenadas se pueden cifrar mediante una clave KMS proporcionada por el cliente.

Campos

- `MlUserDataEncryption`: un objeto MLUserDataEncryption.

  Objeto `MLUserDataEncryption` que contiene el modo de cifrado y el ID de clave KMS proporcionado por el cliente.
- `TaskRunSecurityConfigurationName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la configuración de seguridad.

Estructura MLUserDataEncryption

La configuración de cifrado en reposo de la transformación que se aplica al acceso a los datos del usuario.

Campos

- `MlUserDataEncryptionMode`: obligatorio: cadena UTF-8 (valores válidos: `DISABLED` | `SSE-KMS="SSEKMS"`).

  Modo de cifrado aplicado a los datos del usuario. Los valores válidos son:
  - DISABLED: el cifrado está desactivado
  - SSEKMS: uso del cifrado del lado del servidor con AWS Key Management Service (SSE-KMS) para los datos de usuario almacenados en Amazon S3.
- `KmsKeyId` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

ID de la clave KMS proporcionada por el cliente.

Estructura ColumnImportance

Estructura que contiene el nombre de columna y la puntuación de importancia de columna para una columna.

La importancia de columnas ayuda a comprender cómo contribuyen las columnas al modelo, al identificar qué columnas en sus registros son más importantes que otras.

Campos

- `ColumnName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de una columna.

- `Importance`: número (doble), 1,0 como máximo.

  Puntuación de importancia de columna para la columna, como decimal.

Operaciones

- Acción CreateMLTransform (Python: create_ml_transform)
- Acción UpdateMLTransform (Python: update_ml_transform)
- Acción DeleteMLTransform (Python: delete_ml_transform)
- Acción GetMLTransform (Python: get_ml_transform)
- Acción GetMLTransforms (Python: get_ml_transforms)
- Acción ListMLTransforms (Python: list_ml_transforms)
- Acción StartMLEvaluationTaskRun (Python: start_ml_evaluation_task_run)
- Acción StartMLLabelingSetGenerationTaskRun (Python: start_ml_labeling_set_generation_task_run)
- Acción GetMLTaskRun (Python: get_ml_task_run)
- Acción GetMLTaskRuns (Python: get_ml_task_runs)
- Acción CancelMLTaskRun (Python: cancel_ml_task_run)

- Acción StartExportLabelsTaskRun (Python: start_export_labels_task_run)
- Acción StartImportLabelsTaskRun (Python: start_import_labels_task_run)

Acción CreateMLTransform (Python: create_ml_transform)

Permite crear una transformación de machine learning de AWS Glue. En esta operación se crea la transformación y todos los parámetros necesarios para su entrenamiento.

Realice esta operación como el primer paso del proceso de uso de una transformación de machine learning (como la transformación `FindMatches`) para la deduplicación de datos. Puede proporcionar una `Description` opcional, además de los parámetros que desee utilizar para su algoritmo.

Además, debe especificar determinados parámetros para las tareas que AWS Glue ejecuta en su nombre como parte del aprendizaje a partir de los datos y la creación de una transformación de machine learning de alta calidad. Estos parámetros incluyen `Role` y, de forma opcional,, `AllocatedCapacity`, `Timeout` y `MaxRetries`. Para obtener más información, consulte Trabajos.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre único que asigna a la transformación cuando la creó.
- `Description` – cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Una descripción de la transformación de machine learning que se está definiendo. El valor predeterminado es una cadena vacía.
- `InputRecordTables` – Obligatorio: matriz de objetos GlueTable, con 10 estructuras como máximo.

  Una lista de definiciones de tabla de AWS Glue utilizadas por la transformación.
- `Parameters`: obligatorio: objeto TransformParameters.

  Los parámetros de algoritmo específicos para el tipo de transformación utilizado. Dependen condicionalmente del tipo de transformación.
- `Role` – Obligatorio: cadena UTF-8.

El nombre o nombre de recurso de Amazon (ARN) del rol de IAM con los permisos obligatorios. Los permisos necesarios incluyen tanto permisos de rol de servicio de AWS Glue para recursos de AWS Glue, como permisos de Amazon S3 requeridos por la transformación.

- Este rol necesita permisos de rol de servicio de AWS Glue para permitir el acceso a los recursos de AWS Glue. Consulte Asociar una política a usuarios de IAM que obtienen acceso a AWS Glue.
- Este rol necesita permiso para los orígenes, los destinos, los directorios temporales, los scripts y las bibliotecas de Amazon Simple Storage Service (Amazon S3) utilizados por la ejecución de tareas para esta plataforma.

- `GlueVersion` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #48.

  Este valor determina con qué versión de AWS Glue es compatible esta transformación de machine learning. Se recomienda Glue 1.0 para la mayoría de los clientes. Si el valor no está establecido, la compatibilidad de Glue se establece de forma predeterminada en Glue 0.9. Para obtener más información, consulte las Versiones de AWS Glue en la guía para desarrolladores.

- `MaxCapacity`: número (doble).

  El número de unidades de procesamiento de datos (DPU) de AWS Glue que se asigna a ejecuciones de tareas para esta transformación. Puede asignar de 2 a 100 DPU; el valor predeterminado es 10. Una DPU es una medida relativa de la potencia de procesamiento que consta de 4 vCPU de capacidad de cómputo y 16 GB de memoria. Para obtener más información, consulte la página de precios de AWS Glue.

  `MaxCapacity` es una opción mutuamente excluyente con `NumberOfWorkers` y `WorkerType`.

  - Si se establecen `NumberOfWorkers` o `WorkerType`, no se puede establecer `MaxCapacity`.
  - Si `MaxCapacity` se establece, no se pueden establecer `NumberOfWorkers` ni `WorkerType`.
  - Si `WorkerType` se establece, `NumberOfWorkers` es obligatorio (y viceversa).
  - `MaxCapacity` y `NumberOfWorkers` deben ser al menos 1.

  Cuando el campo `WorkerType` se establece en un valor distinto a `Standard`, el campo `MaxCapacity` se establece automáticamente y se convierte a solo lectura.

  Cuando el campo `WorkerType` se establece en un valor distinto a `Standard`, el campo `MaxCapacity` se establece automáticamente y se convierte a solo lectura.

- `WorkerType` – Cadena UTF-8 (valores válidos: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

  El tipo de proceso de trabajo predefinido que se asigna cuando se ejecuta esta tarea. Admite un valor de Standard, G.1X o G.2X.

  - Para el tipo de proceso de trabajo `Standard`, cada proceso de trabajo proporciona 4 vCPU, 16 GB de memoria y un disco de 50 GB y 2 ejecutores por proceso de trabajo.
  - Para el tipo de proceso de trabajo `G.1X`, cada proceso de trabajo proporciona 4 vCPU, 16 GB de memoria y un disco de 64 GB y 1 ejecutor por proceso de trabajo.
  - Para el tipo de proceso de trabajo `G.2X`, cada proceso de trabajo proporciona 8 vCPU, 32 GB de memoria y un disco de 128 GB y 1 ejecutor por proceso de trabajo.

  `MaxCapacity` es una opción mutuamente excluyente con `NumberOfWorkers` y `WorkerType`.

  - Si se establecen `NumberOfWorkers` o `WorkerType`, no se puede establecer `MaxCapacity`.
  - Si `MaxCapacity` se establece, no se pueden establecer `NumberOfWorkers` ni `WorkerType`.
  - Si `WorkerType` se establece, `NumberOfWorkers` es obligatorio (y viceversa).
  - `MaxCapacity` y `NumberOfWorkers` deben ser al menos 1.
- `NumberOfWorkers`: número (entero).

  El número de procesos de trabajo de `workerType` definido que se asignan cuando se ejecuta esta tarea.

  Si `WorkerType` se establece, `NumberOfWorkers` es obligatorio (y viceversa).
- `Timeout`: número (entero), como mínimo 1.

  El tiempo de espera de la ejecución de tareas para esta transformación en minutos. Es el tiempo máximo que una ejecución de flujo para esta transformación puede consumir recursos antes de que se termine y cambie al estado `TIMEOUT`. El valor predeterminado es 2880 minutos (48 horas).
- `MaxRetries`: número (entero).

  El número máximo de veces que se intenta una tarea para esta transformación después de que se produzca un error en una ejecución de tareas.
- `Tags`: matriz de mapas de pares de clave-valor, con 50 pares como máximo.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es una cadena UTF-8 que no tiene más de 256 bytes de largo.

Las etiquetas que se van a utilizar con esta transformación de machine learning. Puede utilizar etiquetas para limitar el acceso la transformación de machine learning. Para obtener más información acerca de las etiquetas en AWS Glue, consulte Etiquetas de AWS en AWS Glue en la guía para desarrolladores.

- `TransformEncryption`: un objeto TransformEncryption.

  La configuración de cifrado en reposo de la transformación que se aplica al acceso a los datos del usuario. Las transformaciones de machine learning pueden acceder a los datos de usuario cifrados en Amazon S3 mediante KMS.

Respuesta

- `TransformId` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Un identificador único que se genera para la transformación.

Errores

- `AlreadyExistsException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`
- `AccessDeniedException`
- `ResourceNumberLimitExceededException`
- `IdempotentParameterMismatchException`

Acción UpdateMLTransform (Python: update_ml_transform)

Permite actualizar una transformación de machine learning existente. Realice esta operación para ajustar los parámetros del algoritmo para conseguir mejores resultados.

Después de realizar esta operación, puede realizar la operación `StartMLEvaluationTaskRun` para evaluar la facilidad con la que los nuevos parámetros consiguieron sus objetivos (como la

mejora de la calidad de la transformación de machine learning o la transformación en una solución más rentable).

Solicitud

- `TransformId`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Un identificador único que se generó cuando se creó la transformación.

- `Name` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre único que asignó a la transformación cuando la creó.

- `Description` – cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Una descripción de la transformación. El valor predeterminado es una cadena vacía.

- `Parameters`: un objeto TransformParameters.

  Los parámetros de configuración específicos para el tipo de transformación (algoritmo) utilizado. Dependen condicionalmente del tipo de transformación.

- `Role`: cadena UTF-8.

  El nombre o nombre de recurso de Amazon (ARN) del rol de IAM con los permisos obligatorios.

- `GlueVersion` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #48.

  Este valor determina con qué versión de AWS Glue es compatible esta transformación de machine learning. Se recomienda Glue 1.0 para la mayoría de los clientes. Si el valor no está establecido, la compatibilidad de Glue se establece de forma predeterminada en Glue 0.9. Para obtener más información, consulte las Versiones de AWS Glue en la guía para desarrolladores.

- `MaxCapacity`: número (doble).

  El número de unidades de procesamiento de datos (DPU) de AWS Glue que se asigna a ejecuciones de tareas para esta transformación. Puede asignar de 2 a 100 DPU; el valor predeterminado es 10. Una DPU es una medida relativa de la potencia de procesamiento que consta de 4 vCPU de capacidad de cómputo y 16 GB de memoria. Para obtener más información, consulte la página de precios de AWS Glue.

Cuando el campo `WorkerType` se establece en un valor distinto a `Standard`, el campo `MaxCapacity` se establece automáticamente y se convierte a solo lectura.

- `WorkerType` – Cadena UTF-8 (valores válidos: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

  El tipo de proceso de trabajo predefinido que se asigna cuando se ejecuta esta tarea. Admite un valor de Standard, G.1X o G.2X.

  - Para el tipo de proceso de trabajo `Standard`, cada proceso de trabajo proporciona 4 vCPU, 16 GB de memoria y un disco de 50 GB y 2 ejecutores por proceso de trabajo.
  - Para el tipo de proceso de trabajo `G.1X`, cada proceso de trabajo proporciona 4 vCPU, 16 GB de memoria y un disco de 64 GB y 1 ejecutor por proceso de trabajo.
  - Para el tipo de proceso de trabajo `G.2X`, cada proceso de trabajo proporciona 8 vCPU, 32 GB de memoria y un disco de 128 GB y 1 ejecutor por proceso de trabajo.
- `NumberOfWorkers`: número (entero).

  El número de procesos de trabajo de `workerType` definido que se asignan cuando se ejecuta esta tarea.
- `Timeout`: número (entero), como mínimo 1.

  El tiempo de espera de una ejecución de tareas para esta transformación en minutos. Es el tiempo máximo que una ejecución de flujo para esta transformación puede consumir recursos antes de que se termine y cambie al estado `TIMEOUT`. El valor predeterminado es 2880 minutos (48 horas).
- `MaxRetries`: número (entero).

  El número máximo de veces que se intenta una tarea para esta transformación después de que se produzca un error en una ejecución de tareas.

Respuesta

- `TransformId` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El identificador único para la transformación que se ha actualizado.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`
- `AccessDeniedException`

Acción DeleteMLTransform (Python: delete_ml_transform)

Elimina una transformación de machine learning de AWS Glue. Las transformaciones de machine learning son un tipo especial de transformación que utiliza el machine learning para aprender los detalles de la transformación que se va a realizar a través del aprendizaje de ejemplos proporcionados por los humanos. Luego, guarda estas transformaciones AWS Glue. Si ya no necesita una transformación, puede eliminarla con `DeleteMLTransforms`. Sin embargo, los trabajos de AWS Glue que todavía hagan referencia a la transformación eliminada dejarán de ser correctos.

Solicitud

- `TransformId`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El identificador único de la transformación que eliminar.

Respuesta

- `TransformId` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El identificador único de la transformación que se ha eliminado.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`

- `InternalServiceException`

Acción GetMLTransform (Python: get_ml_transform)

Obtiene un artefacto de transformación de machine learning de AWS Glue y todos sus metadatos correspondientes. Las transformaciones de machine learning son un tipo especial de transformación que utiliza el machine learning para aprender los detalles de la transformación que se va a realizar a través del aprendizaje de ejemplos proporcionados por los humanos. Luego, guarda estas transformaciones AWS Glue. Puede recuperar sus metadatos con `GetMLTransform`.

Solicitud

- `TransformId`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El identificador único de la transformación, generado en el momento en que se creó la transformación.

Respuesta

- `TransformId` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El identificador único de la transformación, generado en el momento en que se creó la transformación.
- `Name` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre único proporcionado a la transformación en el momento en el que se creó.
- `Description` – cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Una descripción de la transformación.
- `Status` – Cadena UTF-8 (valores válidos: `NOT_READY` | `READY` | `DELETING`).

  El último estado conocido de la transformación (para indicar si se puede utilizar o no). Una de "NOT_READY", "READY" o "DELETING".
- `CreatedOn`: marca temporal.

La fecha y hora de cuando se creó la transformación.

- `LastModifiedOn`: marca temporal.

  La fecha y hora de cuando se modificó la transformación por última vez.

- `InputRecordTables`: matriz de objetos GlueTable, con 10 estructuras como máximo.

  Una lista de definiciones de tabla de AWS Glue utilizadas por la transformación.

- `Parameters`: un objeto TransformParameters.

  Los parámetros de configuración específicos para el algoritmo utilizado.

- `EvaluationMetrics`: un objeto EvaluationMetrics.

  Las métricas de evaluación más recientes.

- `LabelCount`: número (entero).

  El número de etiquetas disponibles para esta transformación.

- `Schema`: matriz de objetos SchemaColumn, con 100 estructuras como máximo.

  El objeto `Map<Column, Type>` que representa al esquema que acepta esta transformación. Tiene un límite superior de 100 columnas.

- `Role`: cadena UTF-8.

  El nombre o nombre de recurso de Amazon (ARN) del rol de IAM con los permisos obligatorios.

- `GlueVersion` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #48.

  Este valor determina con qué versión de AWS Glue es compatible esta transformación de machine learning. Se recomienda Glue 1.0 para la mayoría de los clientes. Si el valor no está establecido, la compatibilidad de Glue se establece de forma predeterminada en Glue 0.9. Para obtener más información, consulte las Versiones de AWS Glue en la guía para desarrolladores.

- `MaxCapacity`: número (doble).

  El número de unidades de procesamiento de datos (DPU) de AWS Glue que se asigna a ejecuciones de tareas para esta transformación. Puede asignar de 2 a 100 DPU; el valor predeterminado es 10. Una DPU es una medida relativa de la potencia de procesamiento que consta de 4 vCPU de capacidad de cómputo y 16 GB de memoria. Para obtener más información, consulte la página de precios de AWS Glue.

Cuando el campo `WorkerType` se establece en un valor distinto a `Standard`, el campo `MaxCapacity` se establece automáticamente y se convierte a solo lectura.

- `WorkerType` – Cadena UTF-8 (valores válidos: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

  El tipo de proceso de trabajo predefinido que se asigna cuando se ejecuta esta tarea. Admite un valor de Standard, G.1X o G.2X.

  - Para el tipo de proceso de trabajo `Standard`, cada proceso de trabajo proporciona 4 vCPU, 16 GB de memoria y un disco de 50 GB y 2 ejecutores por proceso de trabajo.
  - Para el tipo de proceso de trabajo `G.1X`, cada proceso de trabajo proporciona 4 vCPU, 16 GB de memoria y un disco de 64 GB y 1 ejecutor por proceso de trabajo.
  - Para el tipo de proceso de trabajo `G.2X`, cada proceso de trabajo proporciona 8 vCPU, 32 GB de memoria y un disco de 128 GB y 1 ejecutor por proceso de trabajo.
- `NumberOfWorkers`: número (entero).

  El número de procesos de trabajo de `workerType` definido que se asignan cuando se ejecuta esta tarea.
- `Timeout`: número (entero), como mínimo 1.

  El tiempo de espera de una ejecución de tareas para esta transformación en minutos. Es el tiempo máximo que una ejecución de flujo para esta transformación puede consumir recursos antes de que se termine y cambie al estado `TIMEOUT`. El valor predeterminado es 2880 minutos (48 horas).
- `MaxRetries`: número (entero).

  El número máximo de veces que se intenta una tarea para esta transformación después de que se produzca un error en una ejecución de tareas.
- `TransformEncryption`: un objeto TransformEncryption.

  La configuración de cifrado en reposo de la transformación que se aplica al acceso a los datos del usuario. Las transformaciones de machine learning pueden acceder a los datos de usuario cifrados en Amazon S3 mediante KMS.

Errores

- `EntityNotFoundException`
- `InvalidInputException`

- `OperationTimeoutException`
- `InternalServiceException`

Acción GetMLTransforms (Python: get_ml_transforms)

Permite obtener una lista ordenable y filtrable de transformaciones de machine learning de AWS Glue. Las transformaciones de machine learning son un tipo especial de transformación que utiliza el machine learning para aprender los detalles de la transformación que se va a realizar a través del aprendizaje de ejemplos proporcionados por los humanos. Luego, AWS Glue guarda estas transformaciones y el usuario puede recuperar metadatos con la llamada a `GetMLTransforms`.

Solicitud

- `NextToken`: cadena UTF-8.

  Un token paginado para compensar los resultados.
- `MaxResults`: número (entero) que no es inferior a 1 ni es superior a 1000.

  El número máximo de resultados que devolver.
- `Filter`: un objeto TransformFilterCriteria.

  Los criterios de transformación del filtro.
- `Sort`: un objeto TransformSortCriteria.

  Los criterios de ordenación.

Respuesta

- `Transforms` (obligatorio): una matriz de objetos MLTransform.

  Una lista de transformaciones de machine learning.
- `NextToken`: cadena UTF-8.

  Un token de paginación, si hay disponibles más resultados.

Errores

- `EntityNotFoundException`

- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Acción ListMLTransforms (Python: list_ml_transforms)

Recupera una lista ordenable y filtrable de las transformaciones de machine learning de AWS Glue existentes en esta cuenta de AWS, o los recursos con la etiqueta especificada. Esta operación toma el campo `Tags` opcional, que se puede utilizar como filtro en las respuestas para que los recursos etiquetados se devuelvan agrupados. Si elige utilizar el filtrado de etiquetas, solo se recuperan los recursos con las etiquetas especificadas.

Solicitud

- `NextToken`: cadena UTF-8.

  Token de continuación, si se trata de una solicitud de continuidad.
- `MaxResults`: número (entero) que no es inferior a 1 ni es superior a 1000.

  Tamaño máximo de una lista que se devolverá.
- `Filter`: un objeto TransformFilterCriteria.

  Valor `TransformFilterCriteria` utilizado para filtrar las transformaciones de machine learning.
- `Sort`: un objeto TransformSortCriteria.

  Valor `TransformSortCriteria` utilizado para ordenar las transformaciones de machine learning.
- `Tags`: matriz de mapas de pares de clave-valor, con 50 pares como máximo.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es una cadena UTF-8 que no tiene más de 256 bytes de largo.

  Especifica que se devuelvan solamente los recursos etiquetados.

Respuesta

- `TransformIds` – Obligatorio: una matriz de cadenas UTF-8.

  Los identificadores de todas las transformaciones de machine learning de la cuenta o las transformaciones de machine learning con las etiquetas especificadas.

- `NextToken`: cadena UTF-8.

  Token de continuación, si la lista devuelta no contiene la última métrica disponible.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Acción StartMLEvaluationTaskRun (Python: start_ml_evaluation_task_run)

Permite iniciar una tarea para calcular la calidad de la transformación.

Al proporcionar conjuntos de etiquetas como ejemplos de verdad, machine learning de AWS Glue utiliza algunos ejemplos para aprender de ellos. El resto de etiquetas se utilizan como una prueba para estimar la calidad.

Permite devolver un identificador único para la ejecución. Puede llamar a `GetMLTaskRun` para obtener más información sobre las estadísticas de `EvaluationTaskRun`.

Solicitud

- `TransformId`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El identificador único de la transformación de machine learning.

Respuesta

- `TaskRunId` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El identificador único asociado a esta ejecución.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`
- `ConcurrentRunsExceededException`
- `MLTransformNotReadyException`

Acción StartMLLabelingSetGenerationTaskRun (Python: start_ml_labeling_set_generation_task_run)

Permite iniciar el flujo de trabajo de aprendizaje activo para su transformación de machine learning para mejorar la calidad de la transformación mediante la generación de conjuntos de etiquetas y la adición de etiquetas.

Cuando `StartMLLabelingSetGenerationTaskRun` finaliza, AWS Glue dispondrá de un “conjunto de etiquetas” generado o un conjunto de preguntas que los humanos tendrán que responder.

En el caso de la transformación `FindMatches`, estas preguntas tienen la siguiente forma: "¿Cuál es la forma correcta de agrupar estas filas en grupos compuestos enteramente por registros coincidentes?".

Una vez que el proceso de etiquetado finalice, puede cargar etiquetas con una llamada a `StartImportLabelsTaskRun`. Una vez que `StartImportLabelsTaskRun` acabe, todas las ejecuciones futuras de la transformación de machine learning utilizarán las etiquetas nuevas y mejoradas, y realizarán una transformación de alta calidad.

Nota: El rol utilizado para escribir el conjunto de etiquetado generado en `OutputS3Path` es el rol asociado con la transformación de machine learning, definido en la API `CreateMLTransform`.

Solicitud

- `TransformId`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El identificador único de la transformación de machine learning.
- `OutputS3Path` – Obligatorio: cadena UTF-8.

  La ruta de Amazon Simple Storage Service (Amazon S3) en la que generará el conjunto de etiquetas.

Respuesta

- `TaskRunId` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El identificador de ejecución único que está asociado a esta ejecución de tareas.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`
- `ConcurrentRunsExceededException`

Acción GetMLTaskRun (Python: get_ml_task_run)

Permite obtener detalles para una ejecución de tareas específica en una transformación de machine learning. Las ejecuciones de tareas de machine learning son tareas asíncronas que AWS Glue ejecuta en nombre del usuario como parte de varios flujos de trabajo de machine learning. Puede comprobar las estadísticas de cualquier ejecución de tareas llamando a `GetMLTaskRun` con `TaskRunID` y `TransformID` de la transformación principal.

Solicitud

- `TransformId`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El identificador único de la transformación de machine learning.
- `TaskRunId`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El identificador único de la ejecución de tareas.

Respuesta

- `TransformId` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El identificador único de la ejecución de tareas.
- `TaskRunId` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El identificador de ejecución único asociado a esta ejecución.
- `Status` – Cadena UTF-8 (valores válidos: `RUNNING` | `FINISHED` | `FAILED` | `PENDING_EXECUTION` | `TIMED_OUT` | `CANCELING` | `CANCELED` | `RECEIVED_BY_TASKRUNNER`).

  El estado de esta ejecución de tareas.
- `LogGroupName`: cadena UTF-8.

  Los nombres de los grupos de registros asociados a la ejecución de tareas.
- `Properties`: un objeto TaskRunProperties.

  La lista de propiedades asociadas a la ejecución de tareas.
- `ErrorString`: cadena UTF-8.

  Las cadenas de error asociadas a la ejecución de tareas.
- `StartedOn`: marca temporal.

  La fecha y la hora en las que se inició esta ejecución de tareas.
- `LastModifiedOn`: marca temporal.

La fecha y hora de cuando se modificó esta ejecución de tareas por última vez.

- `CompletedOn`: marca temporal.

  La fecha y hora de cuando se completó esta ejecución de tareas.

- `ExecutionTime`: número (entero).

  El período (en segundos) que la ejecución de tareas consumió recursos.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Acción GetMLTaskRuns (Python: get_ml_task_runs)

Permite obtener una lista de ejecuciones para una transformación de machine learning. Las ejecuciones de tareas de machine learning son tareas asíncronas que AWS Glue ejecuta en nombre del usuario como parte de varios flujos de trabajo de machine learning. Puede obtener una lista ordenable y filtrable de ejecuciones de tareas de machine learning con `GetMLTaskRuns` con `TransformID` de la transformación principal y otros parámetros opcionales tal y como se indica en esta sección.

En esta operación se devuelve una lista de ejecuciones históricas y se debe paginar.

Solicitud

- `TransformId`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El identificador único de la transformación de machine learning.

- `NextToken`: cadena UTF-8.

  Un token para la paginación de los resultados. El valor predeterminado es vacío.

- `MaxResults`: número (entero) que no es inferior a 1 ni es superior a 1000.

El número máximo de resultados que devolver.

- `Filter`: un objeto TaskRunFilterCriteria.

  Los criterios de filtro, en la estructura `TaskRunFilterCriteria`, para la ejecución de tareas.

- `Sort`: un objeto TaskRunSortCriteria.

  Los criterios de ordenación, en la estructura `TaskRunSortCriteria`, para la ejecución de tareas.

Respuesta

- `TaskRuns`: matriz de objetos TaskRun.

  La lista de ejecuciones de tareas que se asocian a la transformación.

- `NextToken`: cadena UTF-8.

  Un token de paginación, si hay disponibles más resultados.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Acción CancelMLTaskRun (Python: cancel_ml_task_run)

Permite cancelar (detener) una ejecución de tareas. Las ejecuciones de tareas de machine learning son tareas asíncronas que AWS Glue ejecuta en nombre del usuario como parte de varios flujos de trabajo de machine learning. Puede cancelar una ejecución de tareas de machine learning en cualquier momento llamando a `CancelMLTaskRun` con `TransformID` de la transformación principal de una ejecución de tareas y `TaskRunId` de la ejecución de tareas.

Solicitud

- `TransformId`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

El identificador único de la transformación de machine learning.

- `TaskRunId`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Un identificador único de la ejecución de tareas.

Respuesta

- `TransformId` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El identificador único de la transformación de machine learning.
- `TaskRunId` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El identificador único de la ejecución de tareas.
- `Status` – Cadena UTF-8 (valores válidos: `RUNNING` | `FINISHED` | `FAILED` | `PENDING_EXECUTION` | `TIMED_OUT` | `CANCELING` | `CANCELED` | `RECEIVED_BY_TASKRUNNER`).

  El estado de esta ejecución.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Acción StartExportLabelsTaskRun (Python: start_export_labels_task_run)

Permite iniciar una tarea asíncrona para exportar todos los datos etiquetados para una transformación determinada. Esta tarea es la única llamada de la API relacionada con la etiqueta que no forma parte del flujo de trabajo de aprendizaje activo normal. Normalmente, utiliza `StartExportLabelsTaskRun` cuando desea trabajar con todas las etiquetas existentes a la vez, como cuando desea quitar o cambiar etiquetas que se enviaron anteriormente como verdad. Esta operación de la API permite aceptar `TransformId` cuyas etiquetas quiere exportar y una ruta

de Amazon Simple Storage Service (Amazon S3) en la que exportar las etiquetas. La operación devuelve `TaskRunId`. Puede comprobar el estado de su ejecución de tareas llamando a la API de `GetMLTaskRun`.

Solicitud

- `TransformId`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El identificador único de la transformación de machine learning.
- `OutputS3Path` – Obligatorio: cadena UTF-8.

  La ruta de Amazon S3 en la que exporta las etiquetas.

Respuesta

- `TaskRunId` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El identificador único de la ejecución de tareas.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Acción StartImportLabelsTaskRun (Python: start_import_labels_task_run)

Le permite proporcionar etiquetas adicionales (ejemplos de verdad) que se va a utilizar para enseñar a la transformación de machine learning y mejorar su calidad. Esta operación de la API se utiliza normalmente como parte del flujo de trabajo de aprendizaje activo que comienza con la llamada de `StartMLLabelingSetGenerationTaskRun` y que, en última instancia, da lugar a un aumento en la calidad de su transformación de machine learning.

Cuando `StartMLLabelingSetGenerationTaskRun` finaliza, machine learning de AWS Glue dispondrá de una serie de preguntas que los humanos tendrán que responder. (El proceso de

respuesta a estas preguntas se suele denominar "etiquetado" en los flujos de trabajo de machine learning). En el caso de la transformación `FindMatches`, estas preguntas tienen la siguiente forma: "¿Cuál es la forma correcta de agrupar estas filas en grupos compuestos enteramente por registros coincidentes?". Una vez que el proceso de etiquetado finaliza, los usuarios cargan sus respuestas/etiquetas con una llamada a `StartImportLabelsTaskRun`. Una vez que `StartImportLabelsTaskRun` acabe, todas las ejecuciones futuras de la transformación de machine learning utilizarán las etiquetas nuevas y mejoradas, y realizarán una transformación de alta calidad.

De forma predeterminada, `StartMLLabelingSetGenerationTaskRun` aprende continuamente de todas las etiquetas que carga, y las combina, a no ser que establezca `Replace` en true. Si define `Replace` en true, `StartImportLabelsTaskRun` elimina y olvida todas las etiquetas cargadas previamente y aprende solo del conjunto exacto que carga. El reemplazo de etiquetas puede resultar útil si se da cuenta de que ha cargado etiquetas incorrectas anteriormente y cree que tendrán un efecto negativo en la calidad de su transformación.

Puede comprobar el estado de su ejecución de tareas con la operación `GetMLTaskRun`.

Solicitud

- `TransformId`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El identificador único de la transformación de machine learning.
- `InputS3Path` – Obligatorio: cadena UTF-8.

  La ruta de Amazon Simple Storage Service (Amazon S3) desde la que importará las etiquetas.
- `ReplaceAllLabels`: booleano.

  Indica si se van a sobrescribir las etiquetas existentes.

Respuesta

- `TaskRunId` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El identificador único de la ejecución de tareas.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`
- `InternalServiceException`

API de Calidad de datos

La API de Calidad de datos describe los tipos de datos de la calidad de los datos e incluye la API para crear, eliminar o actualizar conjuntos de reglas, ejecuciones y evaluadores de la calidad de datos.

Tipos de datos

- Estructura de DataSource
- Estructura de DataQualityRulesetListDetails
- Estructura de DataQualityTargetTable
- Estructura de DataQualityRulesetEvaluationRunDescription
- Estructura de DataQualityRulesetEvaluationRunFilter
- Estructura de DataQualityEvaluationRunAdditionalRunOptions
- Estructura de DataQualityRuleRecommendationRunDescription
- Estructura de DataQualityRuleRecommendationRunFilter
- Estructura de DataQualityResult
- Estructura de DataQualityAnalyzerResult
- Estructura de DataQualityObservation
- Estructura de MetricBasedObservation
- Estructura de DataQualityMetricValues
- Estructura de DataQualityRuleResult
- Estructura de DataQualityResultDescription

- Estructura de DataQualityResultFilterCriteria
- Estructura de DataQualityRulesetFilterCriteria
- Estructura DataQualityAggregatedMetrics
- Estructura StatisticAnnotation
- Estructura TimestampedInclusionAnnotation
- Estructura AnnotationError
- Estructura DatapointInclusionAnnotation
- Lista StatisticSummaryList
- Estructura StatisticSummary
- Estructura RunIdentifier
- Estructura StatisticModelResult
- Estructura de DataQualityGlueTable

Estructura de DataSource

Un origen de datos (una tabla de AWS Glue) para obtener los resultados de la calidad de los datos.

Campos

- `GlueTable`: un objeto GlueTable.

  Una tabla de AWS Glue.
- `DataQualityGlueTable`: un objeto DataQualityGlueTable.

  Una tabla de AWS Glue para operaciones de calidad de datos.

Estructura de DataQualityRulesetListDetails

Describe un conjunto de reglas de la calidad de los datos devuelto por `GetDataQualityRuleset`.

Campos

- `Name`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

El nombre del conjunto de reglas de calidad de datos.

- `Description`: cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Una descripción del conjunto de reglas de calidad de datos.

- `CreatedOn`: marca temporal.

  La fecha y la hora en que se creó el conjunto de reglas de calidad de datos.

- `LastModifiedOn`: marca temporal.

  La fecha y la hora de la última modificación del conjunto de reglas de calidad de datos.

- `TargetTable`: un objeto DataQualityTargetTable.

  Un objeto que representa una tabla de AWS Glue.

- `RecommendationRunId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Cuando se crea un conjunto de reglas a partir de una ejecución de recomendación, se genera este ID de ejecución para vincularlos ambos.

- `RuleCount`: número (entero).

  La cantidad de reglas del conjunto de reglas.

Estructura de DataQualityTargetTable

Un objeto que representa una tabla de AWS Glue.

Campos

- `TableName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre de la tabla de AWS Glue.

- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la base de datos donde se encuentra la tabla de AWS Glue.

- `CatalogId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del catálogo donde reside la tabla AWS Glue.

Estructura de DataQualityRulesetEvaluationRunDescription

Describe el resultado de una ejecución de evaluación del conjunto de reglas de calidad de datos.

Campos

- `RunId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El identificador de ejecución único asociado a esta ejecución.
- `Status`: cadena UTF-8 (valores válidos: `RUNNING` | `FINISHED` | `FAILED` | `PENDING_EXECUTION` | `TIMED_OUT` | `CANCELING` | `CANCELED` | `RECEIVED_BY_TASKRUNNER`).

  El estado de esta ejecución.
- `StartedOn`: marca temporal.

  La fecha y la hora en que inició la ejecución.
- `DataSource`: un objeto DataSource.

  El origen de datos (una tabla de AWS Glue) asociado a la ejecución.

Estructura de DataQualityRulesetEvaluationRunFilter

Los criterios del filtro.

Campos

- `DataSource`: obligatorio: objeto DataSource.

  Filtre en función de un origen de datos (una tabla de AWS Glue) asociado a la ejecución.
- `StartedBefore`: marca temporal.

  Filtre los resultados por las ejecuciones que se iniciaron antes de esta hora.
- `StartedAfter`: marca temporal.

Filtre los resultados por las ejecuciones que se iniciaron después de esta hora.

Estructura de DataQualityEvaluationRunAdditionalRunOptions

Opciones de ejecución adicionales que puede especificar para una ejecución de evaluación.

Campos

- `CloudWatchMetricsEnabled`: booleano.

  Si se habilitan o no las métricas de CloudWatch.

- `ResultsS3Prefix`: cadena UTF-8.

  Prefijo para que Amazon S3 almacene los resultados.

- `CompositeRuleEvaluationMethod`: cadena UTF-8 (valores válidos: `COLUMN` | `ROW`).

  Establezca el método de evaluación para las reglas compuestas del conjunto de reglas en FILA/COLUMNA

Estructura de DataQualityRuleRecommendationRunDescription

Describe el resultado de una ejecución de recomendación de reglas de la calidad de los datos.

Campos

- `RunId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El identificador de ejecución único asociado a esta ejecución.

- `Status`: cadena UTF-8 (valores válidos: `RUNNING` | `FINISHED` | `FAILED` | `PENDING_EXECUTION` | `TIMED_OUT` | `CANCELING` | `CANCELED` | `RECEIVED_BY_TASKRUNNER`).

  El estado de esta ejecución.

- `StartedOn`: marca temporal.

  La fecha y la hora en las que se inició esta ejecución.

- `DataSource`: un objeto DataSource.

El origen de datos (tabla de AWS Glue) asociado a la ejecución de recomendación.

Estructura de DataQualityRuleRecommendationRunFilter

Se ejecuta un filtro para enumerar las ejecuciones de recomendación de la calidad de los datos.

Campos

- `DataSource`: obligatorio: objeto DataSource.

  Filtre en función de un origen de datos especificado (tabla de AWS Glue).
- `StartedBefore`: marca temporal.

  Filtre en función de la hora de los resultados que se iniciaron antes de la hora indicada.
- `StartedAfter`: marca temporal.

  Filtre en función de la hora de los resultados que se iniciaron después de la hora indicada.

Estructura de DataQualityResult

Describe un resultado de la calidad de los datos.

Campos

- `ResultId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Un identificador de resultado único para el resultado de la calidad de los datos.
- `ProfileId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de perfil para el resultado de la calidad de los datos.
- `Score`: número (doble), 1,0 como máximo.

  Una puntuación agregada de la calidad de los datos. Representa la relación entre las reglas aprobadas y la cantidad total de reglas.
- `DataSource`: un objeto DataSource.

La tabla asociada al resultado de calidad de datos, si existe.

- `RulesetName`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del conjunto de reglas asociado al resultado de calidad de datos.

- `EvaluationContext`: cadena UTF-8.

  En relación con un trabajo en AWS Glue Studio, a cada nodo del lienzo se le suele asignar algún tipo de nombre y los nodos de calidad de datos tendrán nombres. En el caso de varios nodos, `evaluationContext` puede diferenciar los nodos.

- `StartedOn`: marca temporal.

  La fecha y la hora en las que se inició esta ejecución de la calidad de los datos.

- `CompletedOn`: marca temporal.

  La fecha y la hora en las que finalizó esta ejecución de la calidad de los datos.

- `JobName`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del trabajo asociado al resultado de calidad de datos, si existe.

- `JobRunId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de la ejecución del trabajo asociado al resultado de calidad de datos, si existe.

- `RulesetEvaluationRunId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID único de la ejecución para la evaluación del conjunto de reglas de este resultado de calidad de datos.

- `RuleResults`: matriz de objetos DataQualityRuleResult, con 2000 estructuras como máximo.

  Una lista de objetos `DataQualityRuleResult` que representan los resultados de cada regla.

- `AnalyzerResults`: matriz de objetos DataQualityAnalyzerResult, con 2000 estructuras como máximo.

  Una lista de objetos `DataQualityAnalyzerResult` que representan los resultados de cada analizador.

- `Observations`: matriz de objetos DataQualityObservation, con 50 estructuras como máximo.

  Una lista de objetos `DataQualityObservation` que representan la observabilidad generada después de evaluar las reglas y los analizadores.

- `AggregatedMetrics`: un objeto DataQualityAggregatedMetrics.

  Un resumen de los objetos `DataQualityAggregatedMetrics` que muestra el total de filas y reglas procesadas, incluidas sus estadísticas de aprobación o fallo según los resultados a nivel de fila.

Estructura de DataQualityAnalyzerResult

Describe el resultado de la evaluación del analizador de la calidad de datos.

Campos

- `Name`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del analizador de la calidad de datos.

- `Description`: cadena UTF-8 con un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Descripción del analizador de la calidad de datos.

- `EvaluationMessage`: cadena UTF-8 con un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Un mensaje de evaluación.

- `EvaluatedMetrics`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Cada valor es un número (doble).

  Un mapa de las métricas asociadas a la evaluación del analizador.

Estructura de DataQualityObservation

Describe la observación generada luego de la evaluación de las reglas y los analizadores.

Campos

- `Description`: cadena UTF-8 con un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Una descripción de la observación de la calidad de datos.

- `MetricBasedObservation`: un objeto MetricBasedObservation.

  Un objeto de tipo `MetricBasedObservation` que representa la observación basada en las métricas evaluadas de la calidad de datos.

Estructura de MetricBasedObservation

Describe la observación generada según las métricas basada en las métricas evaluadas de la calidad de datos.

Campos

- `MetricName`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la métrica de calidad de datos utilizada para la generación de la observación.

- `StatisticId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de la estadística.

- `MetricValues`: un objeto DataQualityMetricValues.

  Un objeto de tipo `DataQualityMetricValues` que representa el análisis del valor de la métrica de la calidad de datos.

- `NewRules`: matriz de cadenas UTF-8.

  Una lista de reglas de calidad de datos nuevas generadas como parte de la observación basada en el valor de la métrica de la calidad de datos.

Estructura de DataQualityMetricValues

Describe el valor de la métrica de la calidad de datos según el análisis de los datos históricos.

Campos

- `ActualValue`: número (doble).

  El valor real de la métrica de la calidad de datos.
- `ExpectedValue`: número (doble).

  El valor esperado de la métrica de la calidad de datos según el análisis de los datos históricos.
- `LowerLimit`: número (doble).

  El valor más bajo del valor de la métrica de la calidad de datos según el análisis de los datos históricos.
- `UpperLimit`: número (doble).

  El valor más alto del valor de la métrica de la calidad de datos según el análisis de los datos históricos.

Estructura de DataQualityRuleResult

Describe el resultado de la evaluación de la regla de la calidad de datos.

Campos

- `Name`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la regla de la calidad de datos.
- `Description`: cadena UTF-8 con un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Descripción de la regla de la calidad de datos.
- `EvaluationMessage`: cadena UTF-8 con un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Un mensaje de evaluación.

- `Result`: cadena UTF-8 (valores válidos: `PASS` | `FAIL` | `ERROR`).

  Estado de aprobación o rechazo de la regla.

- `EvaluatedMetrics`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Cada valor es un número (doble).

  Un mapa de métricas asociadas a la evaluación de la regla.

- `EvaluatedRule`: cadena UTF-8 con un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  La regla evaluada.

- `RuleMetrics`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Cada valor es un número (doble).

  Un mapa que contiene métricas asociadas con la evaluación de la regla según los resultados a nivel de fila.

Estructura de DataQualityResultDescription

Describe un resultado de la calidad de los datos.

Campos

- `ResultId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El identificador único de este resultado de la calidad de datos.

- `DataSource`: un objeto DataSource.

  El nombre de la tabla asociada al resultado de la calidad de datos.

- `JobName`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del trabajo asociado al resultado de la calidad de datos.

- `JobRunId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El identificador de la ejecución del trabajo asociado al resultado de la calidad de datos.

- `StartedOn`: marca temporal.

  La hora a la que se inició la ejecución de este resultado de la calidad de datos.

Estructura de DataQualityResultFilterCriteria

Criterios utilizados para devolver los resultados de la calidad de los datos.

Campos

- `DataSource`: un objeto DataSource.

  Filtre los resultados por el origen de datos especificado. Por ejemplo, mediante la recuperación de todos los resultados de una tabla de AWS Glue.

- `JobName`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Filtre los resultados por el nombre de trabajo indicado.

- `JobRunId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Filtre los resultados por el identificador de la ejecución de trabajo indicado.

- `StartedAfter`: marca temporal.

  Filtre los resultados por las ejecuciones que se iniciaron después de esta hora.

- `StartedBefore`: marca temporal.

  Filtre los resultados por las ejecuciones que se iniciaron antes de esta hora.

Estructura de DataQualityRulesetFilterCriteria

Criterios utilizados para filtrar los conjuntos de reglas de calidad de datos.

Campos

- `Name`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de los criterios del filtro del conjunto de reglas.
- `Description`: cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  La descripción de los criterios del filtro del conjunto de reglas.
- `CreatedBefore`: marca temporal.

  Filtre los conjuntos de reglas creados antes de esta fecha.
- `CreatedAfter`: marca temporal.

  Filtre los conjuntos de reglas creados después de esta fecha.
- `LastModifiedBefore`: marca temporal.

  Filtre los últimos conjuntos de reglas modificados antes de esta fecha.
- `LastModifiedAfter`: marca temporal.

  Filtre los últimos conjuntos de reglas modificados después de esta fecha.
- `TargetTable`: un objeto DataQualityTargetTable.

  El nombre de la base de datos y el nombre de la tabla de destino.

Estructura DataQualityAggregatedMetrics

Un resumen de métricas que muestra el total de filas y reglas procesadas, incluidas sus estadísticas de aprobación o fallo según los resultados a nivel de fila.

Campos

- `TotalRowsProcessed`: número (doble).

La cantidad total de filas que se procesaron durante la evaluación de calidad de datos.

- `TotalRowsPassed`: número (doble).

  La cantidad total de filas que cumplieron todas las reglas aplicables de calidad de datos.

- `TotalRowsFailed`: número (doble).

  La cantidad total de filas que no cumplieron una o más reglas de calidad de datos.

- `TotalRulesProcessed`: número (doble).

  La cantidad total de reglas de calidad de datos que se evaluaron.

- `TotalRulesPassed`: número (doble).

  La cantidad total de reglas de calidad de datos que cumplieron sus criterios de evaluación.

- `TotalRulesFailed`: número (doble).

  La cantidad total de reglas de calidad de datos que no cumplieron sus criterios de evaluación.

Estructura StatisticAnnotation

Una anotación estadística.

Campos

- `ProfileId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de perfil.

- `StatisticId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de la estadística.

- `StatisticRecorded0n`: marca temporal.

  La marca de tiempo en la que se registró la estadística anotada.

- `InclusionAnnotation`: un objeto TimestampedInclusionAnnotation.

  La anotación de inclusión aplicada a la estadística.

Estructura TimestampedInclusionAnnotation

Una anotación de inclusión con fecha y hora.

Campos

- `Value`: cadena UTF-8 (valores válidos: `INCLUDE` | `EXCLUDE`).

  El valor de la anotación de inclusión.
- `LastModifiedOn`: marca temporal.

  La marca de tiempo en la que se modificó por última vez la anotación de inclusión.

Estructura AnnotationError

Una anotación fallida.

Campos

- `ProfileId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de perfil de la anotación fallida.
- `StatisticId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de estadística de la anotación fallida.
- `FailureReason`: cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  El motivo por el que se produjo un error en la anotación.

Estructura DatapointInclusionAnnotation

Una anotación de inclusión.

Campos

- `ProfileId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

El ID del perfil de calidad de los datos al que pertenece la estadística.

- `StatisticId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de la estadística.

- `InclusionAnnotation`: cadena UTF-8 (valores válidos: `INCLUDE` | `EXCLUDE`).

  El valor de la anotación de inclusión que se va a aplicar a la estadística.

Lista StatisticSummaryList

Lista de `StatisticSummary`.

Una matriz de objetos StatisticSummary.

Lista de `StatisticSummary`.

Estructura StatisticSummary

Información resumida sobre una estadística.

Campos

- `StatisticId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de la estadística.

- `ProfileId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de perfil.

- `RunIdentifier`: un objeto RunIdentifier.

  El identificador de ejecución

- `StatisticName`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Custom string pattern #16.

  El nombre de la estadística.

- `DoubleValue`: número (doble).

  El valor de la estadística.

- `EvaluationLevel`: cadena UTF-8 (valores válidos: `Dataset="DATASET"` | `Column="COLUMN"` | `Multicolumn="MULTICOLUMN"`).

  El nivel de evaluación de la estadística. Valores posibles: `Dataset`, `Column`, `Multicolumn`.

- `ColumnsReferenced`: matriz de cadenas UTF-8.

  La lista de columnas a las que hace referencia la estadística.

- `ReferencedDatasets`: matriz de cadenas UTF-8.

  La lista de conjuntos de datos a los que hace referencia la estadística.

- `StatisticProperties`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Cada valor es una cadena Description (Descripción), con 2048 bytes de largo como máximo, que coincide con URI address multi-line string pattern.

  Un `StatisticPropertiesMap`, que contiene una `NameString` y una `DescriptionString`

- `RecordedOn`: marca temporal.

  La marca de tiempo en la que se registró la estadística.

- `InclusionAnnotation`: un objeto TimestampedInclusionAnnotation.

  La anotación de inclusión de la estadística.

Estructura RunIdentifier

Un identificador de ejecución.

Campos

- `RunId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de ejecución.

- `JobRunId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de ejecución del trabajo.

Estructura StatisticModelResult

El resultado del modelo estadístico.

Campos

- `LowerBound`: número (doble).

  El límite inferior.
- `UpperBound`: número (doble).

  El límite superior.
- `PredictedValue`: número (doble).

  El valor previsto.
- `ActualValue`: número (doble).

  El valor real.
- `Date`: marca temporal.

  La fecha.
- `InclusionAnnotation`: cadena UTF-8 (valores válidos: `INCLUDE` | `EXCLUDE`).

  La anotación de inclusión.

Estructura de DataQualityGlueTable

La base de datos y la tabla en el AWS Glue Data Catalog que se usa para los datos de entrada y salida para las operaciones de calidad de datos.

Campos

- `DatabaseName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

Un nombre de base de datos en el AWS Glue Data Catalog.

- `TableName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Un nombre de tabla en el AWS Glue Data Catalog.

- `CatalogId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Un identificador único para el AWS Glue Data Catalog.

- `ConnectionName`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la conexión a AWS Glue Data Catalog.

- `AdditionalOptions`: una matriz de asignación de pares de clave-valor, con 1 par como mínimo y 10 como máximo.

  Cada clave es una cadena UTF-8 con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Cada valor es una cadena Description (Descripción), con 2048 bytes de largo como máximo, que coincide con URI address multi-line string pattern.

  Opciones adicionales para la tabla. Actualmente se admiten dos claves:

  - `pushDownPredicate`: filtra particiones sin tener que enumerar y leer todos los archivos del conjunto de datos.
  - `catalogPartitionPredicate`: para utilizar la eliminación de particiones del lado del servidor mediante los índices de particiones de AWS Glue Data Catalog.

- `PreProcessingQuery`: cadena UTF-8 con una extensión de 51 200 bytes como máximo y que coincide con URI address multi-line string pattern.

  Consulta de SQL en formato SparkSQL que se puede utilizar para preprocesar los datos de la tabla en AWS Glue Data Catalog, antes de ejecutar la operación de calidad de datos.

Operaciones

- Acción StartDataQualityRulesetEvaluationRun (Python: start_data_quality_ruleset_evaluation_run)

- Acción CancelDataQualityRulesetEvaluationRun (Python: cancel_data_quality_ruleset_evaluation_run)
- Acción GetDataQualityRulesetEvaluationRun (Python: get_data_quality_ruleset_evaluation_run)
- Acción ListDataQualityRulesetEvaluationRuns (Python: list_data_quality_ruleset_evaluation_runs)
- Acción StartDataQualityRuleRecommendationRun (Python: start_data_quality_rule_recommendation_run)
- Acción CancelDataQualityRuleRecommendationRun (Python: cancel_data_quality_rule_recommendation_run)
- Acción GetDataQualityRuleRecommendationRun (Python: get_data_quality_rule_recommendation_run)
- Acción ListDataQualityRuleRecommendationRuns (Python: list_data_quality_rule_recommendation_runs)
- Acción GetDataQualityResult (Python: get_data_quality_result)
- Acción BatchGetDataQualityResult (Python: batch_get_data_quality_result)
- Acción ListDataQualityResults (Python: list_data_quality_results)
- Acción CreateDataQualityRuleset (Python: create_data_quality_ruleset)
- Acción DeleteDataQualityRuleset (Python: delete_data_quality_ruleset)
- Acción GetDataQualityRuleset (Python: get_data_quality_ruleset)
- Acción ListDataQualityRulesets (Python: list_data_quality_rulesets)
- Acción UpdateDataQualityRuleset (Python: update_data_quality_ruleset)
- Acción ListDataQualityStatistics (Python: list_data_quality_statistics)
- Estructura TimestampFilter
- Estructura CreateDataQualityRulesetRequest
- Estructura GetDataQualityRulesetResponse
- Estructura GetDataQualityResultResponse
- Estructura StartDataQualityRuleRecommendationRunRequest
- Estructura GetDataQualityRuleRecommendationRunResponse
- Acción BatchPutDataQualityStatisticAnnotation (Python: batch_put_data_quality_statistic_annotation)
- Acción GetDataQualityModel (Python: get_data_quality_model)
- Acción GetDataQualityModelResult (Python: get_data_quality_model_result)

- Acción ListDataQualityStatisticAnnotations (Python: list_data_quality_statistic_annotations)
- Acción PutDataQualityProfileAnnotation (Python: put_data_quality_profile_annotation)

Acción StartDataQualityRulesetEvaluationRun (Python: start_data_quality_ruleset_evaluation_run)

Una vez que tenga una definición del conjunto de reglas (recomendada o propia), ejecute esta operación para evaluar el conjunto de reglas con respecto a un origen de datos (tabla de AWS Glue). La evaluación calcula los resultados que puede recuperar con la API de `GetDataQualityResult`.

Solicitud

- `DataSource`: obligatorio: objeto DataSource.

  El origen de datos (tabla de AWS Glue) asociado a esta ejecución.
- `Role` – Obligatorio: cadena UTF-8.

  Un rol de IAM que se proporciona para cifrar los resultados de la ejecución.
- `NumberOfWorkers`: número (entero).

  La cantidad de procesos de trabajo de `G.1X` utilizados para la ejecución. El valor predeterminado es 5.
- `Timeout`: número (entero), como mínimo 1.

  El tiempo de espera durante una ejecución en minutos. Es el tiempo máximo que una ejecución puede consumir recursos antes de que se termine y cambie al estado `TIMEOUT`. El valor predeterminado es 2880 minutos (48 horas).
- `ClientToken`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Se usa para la idempotencia y se recomienda establecerlo en un identificador aleatorio (como un UUID) para evitar crear o iniciar varias instancias del mismo recurso.
- `AdditionalRunOptions`: un objeto DataQualityEvaluationRunAdditionalRunOptions.

  Opciones de ejecución adicionales que puede especificar para una ejecución de evaluación.
- `RulesetNames`: obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y 10 cadenas como máximo.

Lista de nombres de conjuntos de reglas.

- `AdditionalDataSources`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Cada valor es un objeto A DataSource.

  Un mapa de cadenas de referencia a orígenes de datos adicionales que puede especificar para una ejecución de evaluación.

Respuesta

- `RunId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El identificador de ejecución único asociado a esta ejecución.

Errores

- `InvalidInputException`
- `EntityNotFoundException`
- `OperationTimeoutException`
- `InternalServiceException`
- `ConflictException`

Acción CancelDataQualityRulesetEvaluationRun (Python: cancel_data_quality_ruleset_evaluation_run)

Cancela una ejecución en la que se evalúa un conjunto de reglas con respecto a un origen de datos.

Solicitud

- `RunId`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El identificador de ejecución único asociado a esta ejecución.

Respuesta

- Sin parámetros de respuesta.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Acción GetDataQualityRulesetEvaluationRun (Python: get_data_quality_ruleset_evaluation_run)

Recupera una ejecución específica en la que se evalúa un conjunto de reglas con respecto a un origen de datos.

Solicitud

- `RunId`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El identificador de ejecución único asociado a esta ejecución.

Respuesta

- `RunId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El identificador de ejecución único asociado a esta ejecución.
- `DataSource`: un objeto DataSource.

  El origen de datos (una tabla de AWS Glue) asociado a esta ejecución de evaluación.
- `Role`: cadena UTF-8.

  Un rol de IAM que se proporciona para cifrar los resultados de la ejecución.
- `NumberOfWorkers`: número (entero).

La cantidad de procesos de trabajo de `G.1X` utilizados para la ejecución. El valor predeterminado es 5.

- `Timeout`: número (entero), como mínimo 1.

  El tiempo de espera durante una ejecución en minutos. Es el tiempo máximo que una ejecución puede consumir recursos antes de que se termine y cambie al estado `TIMEOUT`. El valor predeterminado es 2880 minutos (48 horas).
- `AdditionalRunOptions`: un objeto DataQualityEvaluationRunAdditionalRunOptions.

  Opciones de ejecución adicionales que puede especificar para una ejecución de evaluación.
- `Status`: cadena UTF-8 (valores válidos: `RUNNING` | `FINISHED` | `FAILED` | `PENDING_EXECUTION` | `TIMED_OUT` | `CANCELING` | `CANCELED` | `RECEIVED_BY_TASKRUNNER`).

  El estado de esta ejecución.
- `ErrorString`: cadena UTF-8.

  Las cadenas de error asociadas a la ejecución.
- `StartedOn`: marca temporal.

  La fecha y la hora en las que se inició esta ejecución.
- `LastModifiedOn`: marca temporal.

  Una marca temporal. El último momento dado en el que se modificó esta ejecución de recomendación de la regla de calidad de datos.
- `CompletedOn`: marca temporal.

  La fecha y la hora en las que se completó esta ejecución.
- `ExecutionTime`: número (entero).

  El tiempo (en segundos) que la ejecución de flujo de trabajo consumió recursos.
- `RulesetNames`: matriz de cadenas UTF-8, con una cadena como mínimo y 10 cadenas como máximo.

  Lista de los nombres de los conjuntos de reglas para la ejecución. Actualmente, este parámetro solo puede tener un nombre para el conjunto de reglas.
- `ResultIds`: matriz de cadenas UTF-8, con una cadena como mínimo y 10 cadenas como máximo.

Una lista de ID de los resultados de calidad de datos de la ejecución.

- `AdditionalDataSources`: matriz de mapas de pares clave-valor.

  Cada clave es una cadena UTF-8 con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Cada valor es un objeto A DataSource.

  Un mapa de cadenas de referencia a orígenes de datos adicionales que puede especificar para una ejecución de evaluación.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Acción ListDataQualityRulesetEvaluationRuns (Python: list_data_quality_ruleset_evaluation_runs)

Muestra todas las ejecuciones que cumplen los criterios del filtro, donde un conjunto de reglas se evalúa en relación con un origen de datos.

Solicitud

- `Filter`: un objeto DataQualityRulesetEvaluationRunFilter.

  Los criterios del filtro.

- `NextToken`: cadena UTF-8.

  Un token paginado para compensar los resultados.

- `MaxResults`: número (entero) que no es inferior a 1 ni es superior a 1000.

  El número máximo de resultados que devolver.

Respuesta

- `Runs`: matriz de objetos DataQualityRulesetEvaluationRunDescription.

  Una lista de objetos `DataQualityRulesetEvaluationRunDescription` que representa las ejecuciones de un conjunto de reglas de calidad de datos.

- `NextToken`: cadena UTF-8.

  Un token de paginación, si hay disponibles más resultados.

Errores

- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Acción StartDataQualityRuleRecommendationRun (Python: start_data_quality_rule_recommendation_run)

Inicia una ejecución de recomendación que se utiliza para generar reglas cuando no sabe qué reglas escribir. AWS Glue Calidad de datos analiza los datos y presenta recomendaciones para un posible conjunto de reglas. A continuación, puede clasificar el conjunto de reglas y modificar el conjunto de reglas generado a su gusto.

Las ejecuciones de recomendaciones se eliminan automáticamente después de 90 días.

Solicitud

La solicitud de recomendación de la regla de calidad de los datos.

- `DataSource`: obligatorio: objeto DataSource.

  El origen de datos (tabla de AWS Glue) asociado a esta ejecución.

- `Role` – Obligatorio: cadena UTF-8.

  Un rol de IAM que se proporciona para cifrar los resultados de la ejecución.

- `NumberOfWorkers`: número (entero).

La cantidad de procesos de trabajo de `G.1X` utilizados para la ejecución. El valor predeterminado es 5.

- `Timeout`: número (entero), como mínimo 1.

  El tiempo de espera durante una ejecución en minutos. Es el tiempo máximo que una ejecución puede consumir recursos antes de que se termine y cambie al estado `TIMEOUT`. El valor predeterminado es 2880 minutos (48 horas).

- `CreatedRulesetName`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Un nombre para el conjunto de reglas.

- `DataQualitySecurityConfiguration`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la configuración de seguridad que se creó con la opción de cifrado de la calidad de los datos.

- `ClientToken`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Se usa para la idempotencia y se recomienda establecerlo en un identificador aleatorio (como un UUID) para evitar crear o iniciar varias instancias del mismo recurso.

Respuesta

- `RunId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El identificador de ejecución único asociado a esta ejecución.

Errores

- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`
- `ConflictException`

Acción CancelDataQualityRuleRecommendationRun (Python: cancel_data_quality_rule_recommendation_run)

Cancela la ejecución de recomendación especificada que se utilizó para generar las reglas.

Solicitud

- `RunId`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El identificador de ejecución único asociado a esta ejecución.

Respuesta

- Sin parámetros de respuesta.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Acción GetDataQualityRuleRecommendationRun (Python: get_data_quality_rule_recommendation_run)

Obtiene la ejecución de recomendación especificada que se utilizó para generar las reglas.

Solicitud

- `RunId`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El identificador de ejecución único asociado a esta ejecución.

Respuesta

La respuesta a la ejecución de la recomendación de la regla de calidad de los datos.

- `RunId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El identificador de ejecución único asociado a esta ejecución.

- `DataSource`: un objeto DataSource.

  El origen de datos (una tabla de AWS Glue) asociado a esta ejecución.

- `Role`: cadena UTF-8.

  Un rol de IAM que se proporciona para cifrar los resultados de la ejecución.

- `NumberOfWorkers`: número (entero).

  La cantidad de procesos de trabajo de `G.1X` utilizados para la ejecución. El valor predeterminado es 5.

- `Timeout`: número (entero), como mínimo 1.

  El tiempo de espera durante una ejecución en minutos. Es el tiempo máximo que una ejecución puede consumir recursos antes de que se termine y cambie al estado `TIMEOUT`. El valor predeterminado es 2880 minutos (48 horas).

- `Status`: cadena UTF-8 (valores válidos: `RUNNING` | `FINISHED` | `FAILED` | `PENDING_EXECUTION` | `TIMED_OUT` | `CANCELING` | `CANCELED` | `RECEIVED_BY_TASKRUNNER`).

  El estado de esta ejecución.

- `ErrorString`: cadena UTF-8.

  Las cadenas de error asociadas a la ejecución.

- `StartedOn`: marca temporal.

  La fecha y la hora en las que se inició esta ejecución.

- `LastModifiedOn`: marca temporal.

  Una marca temporal. El último momento dado en el que se modificó esta ejecución de recomendación de la regla de calidad de datos.

- `CompletedOn`: marca temporal.

La fecha y la hora en las que se completó esta ejecución.

- `ExecutionTime`: número (entero).

  El tiempo (en segundos) que la ejecución de flujo de trabajo consumió recursos.

- `RecommendedRuleset`: cadena UTF-8, con 1 byte de largo como mínimo o 65 536 como máximo.

  Cuando se completa una ejecución de recomendación de reglas de inicio, se crea un conjunto de reglas recomendado (un conjunto de reglas). Este miembro tiene esas reglas en formato de lenguaje de definición de calidad de datos (DQDL).

- `CreatedRulesetName`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del conjunto de reglas que se creó durante la ejecución.

- `DataQualitySecurityConfiguration`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la configuración de seguridad que se creó con la opción de cifrado de la calidad de los datos.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Acción ListDataQualityRuleRecommendationRuns (Python: list_data_quality_rule_recommendation_runs)

Muestra las ejecuciones de recomendación que cumplen los criterios del filtro.

Solicitud

- `Filter`: un objeto DataQualityRuleRecommendationRunFilter.

Los criterios del filtro.

- `NextToken`: cadena UTF-8.

  Un token paginado para compensar los resultados.

- `MaxResults`: número (entero) que no es inferior a 1 ni es superior a 1000.

  El número máximo de resultados que devolver.

Respuesta

- `Runs`: matriz de objetos DataQualityRuleRecommendationRunDescription.

  Una lista de objetos `DataQualityRuleRecommendationRunDescription`.

- `NextToken`: cadena UTF-8.

  Un token de paginación, si hay disponibles más resultados.

Errores

- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Acción GetDataQualityResult (Python: get_data_quality_result)

Recupera el resultado de una evaluación de la regla de calidad de datos.

Solicitud

- `ResultId`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Un identificador de resultado único para el resultado de la calidad de los datos.

Respuesta

La respuesta al resultado de calidad de los datos.

- `ResultId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Un identificador de resultado único para el resultado de la calidad de los datos.

- `ProfileId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de perfil para el resultado de la calidad de los datos.

- `Score`: número (doble), 1,0 como máximo.

  Una puntuación agregada de la calidad de los datos. Representa la relación entre las reglas aprobadas y la cantidad total de reglas.

- `DataSource`: un objeto DataSource.

  La tabla asociada al resultado de calidad de datos, si existe.

- `RulesetName`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del conjunto de reglas asociado al resultado de calidad de datos.

- `EvaluationContext`: cadena UTF-8.

  En relación con un trabajo en AWS Glue Studio, a cada nodo del lienzo se le suele asignar algún tipo de nombre y los nodos de calidad de datos tendrán nombres. En el caso de varios nodos, `evaluationContext` puede diferenciar los nodos.

- `StartedOn`: marca temporal.

  La fecha y la hora en las que se inició la ejecución de este resultado de calidad de datos.

- `CompletedOn`: marca temporal.

  La fecha y la hora en las que se completó la ejecución de este resultado de calidad de datos.

- `JobName`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del trabajo asociado al resultado de calidad de datos, si existe.

- `JobRunId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de la ejecución del trabajo asociado al resultado de calidad de datos, si existe.

- `RulesetEvaluationRunId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID único de ejecución asociado a la evaluación del conjunto de reglas.
- `RuleResults`: matriz de objetos DataQualityRuleResult, con 2000 estructuras como máximo.

  Una lista de objetos `DataQualityRuleResult` que representan los resultados de cada regla.
- `AnalyzerResults`: matriz de objetos DataQualityAnalyzerResult, con 2000 estructuras como máximo.

  Una lista de objetos `DataQualityAnalyzerResult` que representan los resultados de cada analizador.
- `Observations`: matriz de objetos DataQualityObservation, con 50 estructuras como máximo.

  Una lista de objetos `DataQualityObservation` que representan la observabilidad generada después de evaluar las reglas y los analizadores.
- `AggregatedMetrics`: un objeto DataQualityAggregatedMetrics.

  Un resumen de los objetos `DataQualityAggregatedMetrics` que muestra el total de filas y reglas procesadas, incluidas sus estadísticas de aprobación o fallo según los resultados a nivel de fila.

Errores

- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`
- `EntityNotFoundException`

Acción BatchGetDataQualityResult (Python: batch_get_data_quality_result)

Recupera una lista de los resultados de calidad de datos para los ID de los resultados especificados.

Solicitud

- `ResultIds`: obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y 100 cadenas como máximo.

Una lista de identificadores únicos de los resultados de los resultados de calidad de datos.

Respuesta

- `Results` (obligatorio): una matriz de objetos DataQualityResult.

  Una lista de objetos `DataQualityResult` que representa los resultados de calidad de datos.
- `ResultsNotFound`: matriz de cadenas UTF-8, con una cadena como mínimo y 100 cadenas como máximo.

  Una lista de ID de los resultados para los que no se encontraron resultados.

Errores

- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Acción ListDataQualityResults (Python: list_data_quality_results)

Devuelve todos los resultados de la ejecución de calidad de datos de su cuenta.

Solicitud

- `Filter`: un objeto DataQualityResultFilterCriteria.

  Los criterios del filtro.
- `NextToken`: cadena UTF-8.

  Un token paginado para compensar los resultados.
- `MaxResults`: número (entero) que no es inferior a 1 ni es superior a 1000.

  El número máximo de resultados que devolver.

Respuesta

- `Results` (obligatorio): una matriz de objetos DataQualityResultDescription.

Una lista de objetos `DataQualityResultDescription`.

- `NextToken`: cadena UTF-8.

  Un token de paginación, si hay disponibles más resultados.

Errores

- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Acción CreateDataQualityRuleset (Python: create_data_quality_ruleset)

Crea un conjunto de reglas de la calidad de los datos con reglas de DQDL aplicadas a una tabla de AWS Glue especificada.

El conjunto de reglas se crea mediante lenguaje de definición de calidad de datos (DQDL). Para más información, consulte la Guía para desarrolladores de AWS Glue.

Solicitud

Una solicitud para crear un conjunto de reglas de calidad de datos.

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre único para el conjunto de reglas de la calidad de los datos.
- `Description`: cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Una descripción del conjunto de reglas de calidad de datos.
- `Ruleset`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 65 536 como máximo.

  Conjunto de reglas de lenguaje de definición de calidad de datos (DQDL). Para más información, consulte la Guía para desarrolladores de AWS Glue.
- `Tags`: matriz de mapas de pares de clave-valor, con 50 pares como máximo.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

Cada valor es una cadena UTF-8 que no tiene más de 256 bytes de largo.

Una lista de etiquetas aplicadas al conjunto de reglas de calidad de datos.

- `TargetTable`: un objeto DataQualityTargetTable.

  Una tabla de destino asociada al conjunto de reglas de calidad de datos.

- `RecommendationRunId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Un identificador único de ejecución para la ejecución de recomendación.

- `DataQualitySecurityConfiguration`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la configuración de seguridad que se creó con la opción de cifrado de la calidad de los datos.

- `ClientToken`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Se usa para la idempotencia y se recomienda establecerlo en un identificador aleatorio (como un UUID) para evitar crear o iniciar varias instancias del mismo recurso.

Respuesta

- `Name`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre único para el conjunto de reglas de la calidad de los datos.

Errores

- `InvalidInputException`
- `AlreadyExistsException`
- `OperationTimeoutException`
- `InternalServiceException`
- `ResourceNumberLimitExceededException`

Acción DeleteDataQualityRuleset (Python: delete_data_quality_ruleset)

Elimina un conjunto de reglas de la calidad de los datos.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Un nombre para el conjunto de reglas de calidad de datos.

Respuesta

- Sin parámetros de respuesta.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Acción GetDataQualityRuleset (Python: get_data_quality_ruleset)

Devuelve un conjunto de reglas existente por identificador o nombre.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del conjunto de reglas.

Respuesta

Devuelve la respuesta del resultado de calidad de los datos.

- `Name`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del conjunto de reglas.

- `Description`: cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Una descripción del conjunto de reglas.

- `Ruleset`: cadena UTF-8, con 1 byte de largo como mínimo o 65 536 como máximo.

  Conjunto de reglas de lenguaje de definición de calidad de datos (DQDL). Para más información, consulte la Guía para desarrolladores de AWS Glue.

- `TargetTable`: un objeto DataQualityTargetTable.

  El nombre de la base de datos y el nombre de la tabla de destino.

- `CreatedOn`: marca temporal.

  Una marca temporal. La fecha y la hora en las que se creó este conjunto de reglas de calidad de datos.

- `LastModifiedOn`: marca temporal.

  Una marca temporal. El último momento dado en el que se modificó este conjunto de reglas de calidad de datos.

- `RecommendationRunId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Cuando se crea un conjunto de reglas a partir de una ejecución de recomendación, se genera este ID de ejecución para vincularlos ambos.

- `DataQualitySecurityConfiguration`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la configuración de seguridad que se creó con la opción de cifrado de la calidad de los datos.

Errores

- `EntityNotFoundException`

- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Acción ListDataQualityRulesets (Python: list_data_quality_rulesets)

Devuelve una lista paginada de los conjuntos de reglas para la lista especificada de tablas de AWS Glue.

Solicitud

- `NextToken`: cadena UTF-8.

  Un token paginado para compensar los resultados.
- `MaxResults`: número (entero) que no es inferior a 1 ni es superior a 1000.

  El número máximo de resultados que devolver.
- `Filter`: un objeto DataQualityRulesetFilterCriteria.

  Los criterios del filtro.
- `Tags`: matriz de mapas de pares de clave-valor, con 50 pares como máximo.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es una cadena UTF-8 que no tiene más de 256 bytes de largo.

  Una lista de etiquetas de par clave-valor.

Respuesta

- `Rulesets`: matriz de objetos DataQualityRulesetListDetails.

  Una lista paginada de los conjuntos de reglas para la lista especificada de tablas de AWS Glue.
- `NextToken`: cadena UTF-8.

  Un token de paginación, si hay disponibles más resultados.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Acción UpdateDataQualityRuleset (Python: update_data_quality_ruleset)

Actualiza el conjunto de reglas de calidad de datos especificado.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del conjunto de reglas de calidad de datos.
- `Description`: cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Una descripción del conjunto de reglas.
- `Ruleset`: cadena UTF-8, con 1 byte de largo como mínimo o 65 536 como máximo.

  Conjunto de reglas de lenguaje de definición de calidad de datos (DQDL). Para más información, consulte la Guía para desarrolladores de AWS Glue.

Respuesta

- `Name`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del conjunto de reglas de calidad de datos.
- `Description`: cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Una descripción del conjunto de reglas.
- `Ruleset`: cadena UTF-8, con 1 byte de largo como mínimo o 65 536 como máximo.

Conjunto de reglas de lenguaje de definición de calidad de datos (DQDL). Para más información, consulte la Guía para desarrolladores de AWS Glue.

Errores

- `EntityNotFoundException`
- `AlreadyExistsException`
- `IdempotentParameterMismatchException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`
- `ResourceNumberLimitExceededException`

Acción ListDataQualityStatistics (Python: list_data_quality_statistics)

Recupera una lista de estadísticas de calidad de datos.

Solicitud

- `StatisticId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de la estadística.
- `ProfileId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de perfil.
- `TimestampFilter`: un objeto TimestampFilter.

  Un filtro de fecha y hora.
- `MaxResults`: número (entero) que no es inferior a 1 ni es superior a 1000.

  El número máximo de resultados que se devuelven en esta solicitud.
- `NextToken`: cadena UTF-8.

  Un token de paginación para solicitar la siguiente página de resultados.

Respuesta

- `Statistics`: matriz de objetos StatisticSummary.

  Una `StatisticSummaryList`.
- `NextToken`: cadena UTF-8.

  Un token de paginación para solicitar la siguiente página de resultados.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`

Estructura TimestampFilter

Un filtro de fecha y hora.

Campos

- `RecordedBefore`: marca temporal.

  La marca de tiempo antes de la cual se deben incluir las estadísticas en los resultados.
- `RecordedAfter`: marca temporal.

  La marca de tiempo después de la cual se deben incluir las estadísticas en los resultados.

Estructura CreateDataQualityRulesetRequest

Una solicitud para crear un conjunto de reglas de calidad de datos.

Campos

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre único para el conjunto de reglas de la calidad de los datos.

- `Description`: cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Una descripción del conjunto de reglas de calidad de datos.

- `Ruleset`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 65 536 como máximo.

  Conjunto de reglas de lenguaje de definición de calidad de datos (DQDL). Para más información, consulte la Guía para desarrolladores de AWS Glue.

- `Tags`: matriz de mapas de pares de clave-valor, con 50 pares como máximo.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es una cadena UTF-8 que no tiene más de 256 bytes de largo.

  Una lista de etiquetas aplicadas al conjunto de reglas de calidad de datos.

- `TargetTable`: un objeto DataQualityTargetTable.

  Una tabla de destino asociada al conjunto de reglas de calidad de datos.

- `RecommendationRunId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Un identificador único de ejecución para la ejecución de recomendación.

- `DataQualitySecurityConfiguration`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la configuración de seguridad que se creó con la opción de cifrado de la calidad de los datos.

- `ClientToken`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Se usa para la idempotencia y se recomienda establecerlo en un identificador aleatorio (como un UUID) para evitar crear o iniciar varias instancias del mismo recurso.

Estructura GetDataQualityRulesetResponse

Devuelve la respuesta del resultado de calidad de los datos.

Campos

- `Name`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del conjunto de reglas.

- `Description`: cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Una descripción del conjunto de reglas.

- `Ruleset`: cadena UTF-8, con 1 byte de largo como mínimo o 65 536 como máximo.

  Conjunto de reglas de lenguaje de definición de calidad de datos (DQDL). Para más información, consulte la Guía para desarrolladores de AWS Glue.

- `TargetTable`: un objeto DataQualityTargetTable.

  El nombre de la base de datos y el nombre de la tabla de destino.

- `CreatedOn`: marca temporal.

  Una marca temporal. La fecha y la hora en las que se creó este conjunto de reglas de calidad de datos.

- `LastModifiedOn`: marca temporal.

  Una marca temporal. El último momento dado en el que se modificó este conjunto de reglas de calidad de datos.

- `RecommendationRunId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Cuando se crea un conjunto de reglas a partir de una ejecución de recomendación, se genera este ID de ejecución para vincularlos ambos.

- `DataQualitySecurityConfiguration`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la configuración de seguridad que se creó con la opción de cifrado de la calidad de los datos.

Estructura GetDataQualityResultResponse

La respuesta al resultado de calidad de los datos.

Campos

- `ResultId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Un identificador de resultado único para el resultado de la calidad de los datos.
- `ProfileId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de perfil para el resultado de la calidad de los datos.
- `Score`: número (doble), 1,0 como máximo.

  Una puntuación agregada de la calidad de los datos. Representa la relación entre las reglas aprobadas y la cantidad total de reglas.
- `DataSource`: un objeto DataSource.

  La tabla asociada al resultado de calidad de datos, si existe.
- `RulesetName`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del conjunto de reglas asociado al resultado de calidad de datos.
- `EvaluationContext`: cadena UTF-8.

  En relación con un trabajo en AWS Glue Studio, a cada nodo del lienzo se le suele asignar algún tipo de nombre y los nodos de calidad de datos tendrán nombres. En el caso de varios nodos, `evaluationContext` puede diferenciar los nodos.
- `StartedOn`: marca temporal.

  La fecha y la hora en las que se inició la ejecución de este resultado de calidad de datos.
- `CompletedOn`: marca temporal.

  La fecha y la hora en las que se completó la ejecución de este resultado de calidad de datos.
- `JobName`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

El nombre del trabajo asociado al resultado de calidad de datos, si existe.

- `JobRunId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de la ejecución del trabajo asociado al resultado de calidad de datos, si existe.

- `RulesetEvaluationRunId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID único de ejecución asociado a la evaluación del conjunto de reglas.

- `RuleResults`: matriz de objetos DataQualityRuleResult, con 2000 estructuras como máximo.

  Una lista de objetos `DataQualityRuleResult` que representan los resultados de cada regla.

- `AnalyzerResults`: matriz de objetos DataQualityAnalyzerResult, con 2000 estructuras como máximo.

  Una lista de objetos `DataQualityAnalyzerResult` que representan los resultados de cada analizador.

- `Observations`: matriz de objetos DataQualityObservation, con 50 estructuras como máximo.

  Una lista de objetos `DataQualityObservation` que representan la observabilidad generada después de evaluar las reglas y los analizadores.

- `AggregatedMetrics`: un objeto DataQualityAggregatedMetrics.

  Un resumen de los objetos `DataQualityAggregatedMetrics` que muestra el total de filas y reglas procesadas, incluidas sus estadísticas de aprobación o fallo según los resultados a nivel de fila.

Estructura StartDataQualityRuleRecommendationRunRequest

La solicitud de recomendación de la regla de calidad de los datos.

Campos

- `DataSource`: obligatorio: objeto DataSource.

  El origen de datos (tabla de AWS Glue) asociado a esta ejecución.

- `Role` – Obligatorio: cadena UTF-8.

Un rol de IAM que se proporciona para cifrar los resultados de la ejecución.

- `NumberOfWorkers`: número (entero).

  La cantidad de procesos de trabajo de `G.1X` utilizados para la ejecución. El valor predeterminado es 5.

- `Timeout`: número (entero), como mínimo 1.

  El tiempo de espera durante una ejecución en minutos. Es el tiempo máximo que una ejecución puede consumir recursos antes de que se termine y cambie al estado `TIMEOUT`. El valor predeterminado es 2880 minutos (48 horas).

- `CreatedRulesetName`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Un nombre para el conjunto de reglas.

- `DataQualitySecurityConfiguration`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la configuración de seguridad que se creó con la opción de cifrado de la calidad de los datos.

- `ClientToken`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Se usa para la idempotencia y se recomienda establecerlo en un identificador aleatorio (como un UUID) para evitar crear o iniciar varias instancias del mismo recurso.

Estructura GetDataQualityRuleRecommendationRunResponse

La respuesta a la ejecución de la recomendación de la regla de calidad de los datos.

Campos

- `RunId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El identificador de ejecución único asociado a esta ejecución.

- `DataSource`: un objeto DataSource.

El origen de datos (una tabla de AWS Glue) asociado a esta ejecución.

- `Role`: cadena UTF-8.

  Un rol de IAM que se proporciona para cifrar los resultados de la ejecución.

- `NumberOfWorkers`: número (entero).

  La cantidad de procesos de trabajo de `G.1X` utilizados para la ejecución. El valor predeterminado es 5.

- `Timeout`: número (entero), como mínimo 1.

  El tiempo de espera durante una ejecución en minutos. Es el tiempo máximo que una ejecución puede consumir recursos antes de que se termine y cambie al estado `TIMEOUT`. El valor predeterminado es 2880 minutos (48 horas).

- `Status`: cadena UTF-8 (valores válidos: `RUNNING` | `FINISHED` | `FAILED` | `PENDING_EXECUTION` | `TIMED_OUT` | `CANCELING` | `CANCELED` | `RECEIVED_BY_TASKRUNNER`).

  El estado de esta ejecución.

- `ErrorString`: cadena UTF-8.

  Las cadenas de error asociadas a la ejecución.

- `StartedOn`: marca temporal.

  La fecha y la hora en las que se inició esta ejecución.

- `LastModifiedOn`: marca temporal.

  Una marca temporal. El último momento dado en el que se modificó esta ejecución de recomendación de la regla de calidad de datos.

- `CompletedOn`: marca temporal.

  La fecha y la hora en las que se completó esta ejecución.

- `ExecutionTime`: número (entero).

  El tiempo (en segundos) que la ejecución de flujo de trabajo consumió recursos.

- `RecommendedRuleset`: cadena UTF-8, con 1 byte de largo como mínimo o 65 536 como máximo.

Cuando se completa una ejecución de recomendación de reglas de inicio, se crea un conjunto de reglas recomendado (un conjunto de reglas). Este miembro tiene esas reglas en formato de lenguaje de definición de calidad de datos (DQDL).

- `CreatedRulesetName`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del conjunto de reglas que se creó durante la ejecución.

- `DataQualitySecurityConfiguration`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la configuración de seguridad que se creó con la opción de cifrado de la calidad de los datos.

Acción BatchPutDataQualityStatisticAnnotation (Python: batch_put_data_quality_statistic_annotation)

Anote los puntos de datos a lo largo del tiempo para obtener una estadística de calidad de datos específica. La API requiere tanto profileID como statisticID como parte de la entrada InclusionAnnotation. La API solo funciona para un único statisticID en varios perfiles.

Solicitud

- `InclusionAnnotations` (obligatorio): una matriz de objetos DatapointInclusionAnnotation.

  Una lista de `DatapointInclusionAnnotation`. InclusionAnnotations debe contener un profileId y un statisticId. Si hay varias InclusionAnnotations, la lista debe hacer referencia a un único statisticID entre varios profileIDs.

- `ClientToken`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Token de cliente.

Respuesta

- `FailedInclusionAnnotations`: matriz de objetos AnnotationError.

  Una lista de `AnnotationError`.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `ResourceNumberLimitExceededException`

Acción GetDataQualityModel (Python: get_data_quality_model)

Recupera el estado de entrenamiento del modelo junto con más información (CompletedOn, StartedOn, FailureReason).

Solicitud

- `StatisticId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de la estadística.
- `ProfileId`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de perfil.

Respuesta

- `Status`: cadena UTF-8 (valores válidos: `RUNNING` | `SUCCEEDED` | `FAILED`).

  El estado de entrenamiento del modelo de calidad de los datos.
- `StartedOn`: marca temporal.

  La marca de tiempo en la que se inició el entrenamiento del modelo de calidad de datos.
- `CompletedOn`: marca temporal.

  La marca de tiempo en la que se completó el entrenamiento del modelo de calidad de datos.
- `FailureReason`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El motivo del error del entrenamiento.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Acción GetDataQualityModelResult (Python: get_data_quality_model_result)

Recupera las predicciones de una estadística para un ID de perfil determinado.

Solicitud

- `StatisticId`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de la estadística.
- `ProfileId`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de perfil.

Respuesta

- `CompletedOn`: marca temporal.

  La marca de tiempo en la que se completó el entrenamiento del modelo de calidad de datos.
- `Model`: matriz de objetos StatisticModelResult.

  Una lista de `StatisticModelResult`

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Acción ListDataQualityStatisticAnnotations (Python: list_data_quality_statistic_annotations)

Recupera las anotaciones de una estadística de calidad de datos.

Solicitud

- `StatisticId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de la estadística.
- `ProfileId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de perfil.
- `TimestampFilter`: un objeto TimestampFilter.

  Un filtro de fecha y hora.
- `MaxResults`: número (entero) que no es inferior a 1 ni es superior a 1000.

  El número máximo de resultados que se devuelven en esta solicitud.
- `NextToken`: cadena UTF-8.

  Un token de paginación para recuperar el siguiente conjunto de resultados.

Respuesta

- `Annotations`: matriz de objetos StatisticAnnotation.

  Una lista de `StatisticAnnotation` que se aplica a la estadística
- `NextToken`: cadena UTF-8.

  Un token de paginación para recuperar el siguiente conjunto de resultados.

Errores

- `InvalidInputException`
- `InternalServiceException`

Acción PutDataQualityProfileAnnotation (Python: put_data_quality_profile_annotation)

Anote todos los puntos de datos de un perfil.

Solicitud

- `ProfileId`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID del perfil de supervisión de la calidad de los datos que se va a anotar.
- `InclusionAnnotation`: obligatorio: cadena UTF-8 (valores válidos: `INCLUDE` | `EXCLUDE`).

  El valor de la anotación de inclusión que se va a aplicar al perfil.

Respuesta

- Sin parámetros de respuesta.

Errores

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`

API de detección de información confidencial

La API de detección de información confidencial describe las API utilizadas para detectar información confidencial en las columnas y filas de los datos estructurados.

Tipos de datos

- Estructura CustomEntityType

Estructura CustomEntityType

Objeto que representa un patrón personalizado para detectar información confidencial en las columnas y filas de los datos estructurados.

Campos

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del patrón personalizado que permite recuperarlo o eliminarlo más adelante. Este nombre debe ser único por cuenta de AWS.
- `RegexString`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Cadena de expresión regular que se utiliza para detectar información confidencial en un patrón personalizado.
- `ContextWords`: matriz de cadenas UTF-8, con una cadena como mínimo o más de 20 cadenas.

  Lista de palabras contextuales. Si no se encuentra ninguna de estas palabras contextuales en las proximidades de la expresión regular, los datos no se detectarán como información confidencial.

  Si no se pasan palabras contextuales, solo se comprueba una expresión regular.

Operaciones

- Acción CreateCustomEntityType (Python: create_custom_entity_type)
- Acción DeleteCustomEntityType (Python: delete_custom_entity_type)
- Acción GetCustomEntityType (Python: get_custom_entity_type)
- Acción BatchGetCustomEntityTypes (Python: batch_get_custom_entity_types)
- Acción ListCustomEntityTypes (Python: list_custom_entity_types)

Acción CreateCustomEntityType (Python: create_custom_entity_type)

Crea un patrón personalizado que se utiliza para detectar información confidencial en las columnas y filas de los datos estructurados.

Cada patrón personalizado que cree especifica una expresión regular y una lista opcional de palabras contextuales. Si no se pasan palabras contextuales, solo se comprueba una expresión regular.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre del patrón personalizado que permite recuperarlo o eliminarlo más adelante. Este nombre debe ser único por cuenta de AWS.
- `RegexString`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Cadena de expresión regular que se utiliza para detectar información confidencial en un patrón personalizado.
- `ContextWords`: matriz de cadenas UTF-8, con una cadena como mínimo o más de 20 cadenas.

  Lista de palabras contextuales. Si no se encuentra ninguna de estas palabras contextuales en las proximidades de la expresión regular, los datos no se detectarán como información confidencial.

  Si no se pasan palabras contextuales, solo se comprueba una expresión regular.
- `Tags`: matriz de mapas de pares de clave-valor, con 50 pares como máximo.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es una cadena UTF-8 que no tiene más de 256 bytes de largo.

  Una lista de etiquetas aplicadas al tipo de entidad personalizada.

Respuesta

- `Name`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del patrón personalizado que ha creado.

Errores

- `AccessDeniedException`
- `AlreadyExistsException`
- `IdempotentParameterMismatchException`
- `InternalServiceException`
- `InvalidInputException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`

Acción DeleteCustomEntityType (Python: delete_custom_entity_type)

Elimina un patrón personalizado especificando su nombre.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del patrón personalizado que desea eliminar.

Respuesta

- `Name`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del patrón personalizado que ha eliminado.

Errores

- `EntityNotFoundException`
- `AccessDeniedException`
- `InternalServiceException`
- `InvalidInputException`
- `OperationTimeoutException`

Acción GetCustomEntityType (Python: get_custom_entity_type)

Recupera los detalles de un patrón personalizado especificando su nombre.

Solicitud

- `Name`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del patrón personalizado que desea recuperar.

Respuesta

- `Name`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre del patrón personalizado que ha recuperado.
- `RegexString`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Cadena de expresión regular que se utiliza para detectar información confidencial en un patrón personalizado.
- `ContextWords`: matriz de cadenas UTF-8, con una cadena como mínimo o más de 20 cadenas.

  Lista de palabras contextuales si se especifica al crear el patrón personalizado. Si no se encuentra ninguna de estas palabras contextuales en las proximidades de la expresión regular, los datos no se detectarán como información confidencial.

Errores

- `EntityNotFoundException`
- `AccessDeniedException`
- `InternalServiceException`
- `InvalidInputException`
- `OperationTimeoutException`

Acción BatchGetCustomEntityTypes (Python: batch_get_custom_entity_types)

Recupera los detalles de los patrones personalizados especificados por una lista de nombres.

Solicitud

- `Names`: Obligatorio: matriz de cadenas UTF-8, con una cadena como mínimo y 50 cadenas como máximo.

  Una lista de nombres de patrones personalizados que desea recuperar.

Respuesta

- `CustomEntityTypes`: matriz de objetos CustomEntityType.

  Una lista de objetos `CustomEntityType` que representan los patrones personalizados que se han creado.
- `CustomEntityTypesNotFound`: matriz de cadenas UTF-8, con una cadena como mínimo o más de 50 cadenas.

  Una lista de los nombres de patrones personalizados que no se han encontrado.

Errores

- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

Acción ListCustomEntityTypes (Python: list_custom_entity_types)

Enumera todos los patrones personalizados que se han creado.

Solicitud

- `NextToken`: cadena UTF-8.

  Un token paginado para compensar los resultados.

- `MaxResults`: número (entero) que no es inferior a 1 ni es superior a 1000.

  El número máximo de resultados que devolver.

- `Tags`: matriz de mapas de pares de clave-valor, con 50 pares como máximo.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es una cadena UTF-8 que no tiene más de 256 bytes de largo.

  Una lista de etiquetas de par clave-valor.

Respuesta

- `CustomEntityTypes`: matriz de objetos CustomEntityType.

  Una lista de objetos `CustomEntityType` que representan patrones personalizados.

- `NextToken`: cadena UTF-8.

  Un token de paginación, si hay disponibles más resultados.

Errores

- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

API de etiquetado en AWS Glue

Tipos de datos

- Estructura de etiquetas

Estructura de etiquetas

El objeto `Tag` representa una etiqueta que se puede asignar a un recurso de AWS. Cada etiqueta está formada por una clave y un valor opcional, ambos definidos por el usuario.

Para obtener más información acerca de las etiquetas y controlar el acceso a los recursos en AWS Glue, consulte Etiquetas de AWS en AWS Glue y Especificación de ARN de recursos de AWS Glue en la Guía para desarrolladores.

Campos

- `key`: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo.

  La clave de la etiqueta. La clave es necesaria para crear una etiqueta en un objeto. La clave distingue entre mayúsculas y minúsculas y no debe contener el prefijo aws.
- `value`: cadena UTF-8 de 256 bytes de largo como máximo.

  El valor de la etiqueta. El valor es opcional para crear una etiqueta en un objeto. El valor distingue entre mayúsculas y minúsculas y no debe contener el prefijo aws.

Operaciones

- Acción TagResource (Python: tag_resource)
- Acción UntagResource (Python: untag_resource)
- Acción GetTags (Python: get_tags)

Acción TagResource (Python: tag_resource)

Agrega etiquetas a un recurso. Una etiqueta es una marca que se puede asignar a un recurso de AWS. En AWS Glue, solamente se pueden etiquetar ciertos recursos. Para obtener más información acerca de qué recursos pueden etiquetarse, consulte Etiquetas de AWS en AWS Glue.

Además de los permisos de etiquetado para llamar a las API relacionadas con etiquetas, también necesita el permiso `glue:GetConnection` para llamar a las API de etiquetado en las conexiones y el permiso `glue:GetDatabase` para llamar a las API de etiquetado en las bases de datos.

Solicitud

- `ResourceArn` – Obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 10 240 bytes de largo como máximo, que coincide con el Custom string pattern #50.

ARN del recurso de AWS Glue al que se van a agregar las etiquetas. Para obtener más información acerca de los ARN de recursos de AWS Glue, consulte Patrones de cadena de ARN de AWS Glue.

- `TagsToAdd` – Obligatorio: matriz de mapas de pares clave-valor, con 50 pares como máximo.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es una cadena UTF-8 que no tiene más de 256 bytes de largo.

  Etiquetas que se van a añadir a este recurso.

Respuesta

- Sin parámetros de respuesta.

Errores

- `ResourceNotFoundException`

Acción UntagResource (Python: untag_resource)

Quita las etiquetas especificadas de un recurso de integración.

Solicitud

- `ResourceArn` – Obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 10 240 bytes de largo como máximo, que coincide con el Custom string pattern #50.

  Nombre de recurso de Amazon (ARN) del recurso de integración.

- `TagsToRemove` – Obligatorio: matriz de cadenas UTF-8, con 50 cadenas como máximo.

  Una lista de las etiquetas de metadatos que se eliminará del recurso.

Respuesta

- Sin parámetros de respuesta.

Errores

- `ResourceNotFoundException`

Acción GetTags (Python: get_tags)

Recupera una lista de etiquetas asociadas a un recurso.

Solicitud

- `ResourceArn` – Obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 10 240 bytes de largo como máximo, que coincide con el Custom string pattern #50.

  El nombre de recurso de Amazon (ARN) del recurso del que se van a recuperar etiquetas.

Respuesta

- `Tags`: matriz de mapas de pares de clave-valor, con 50 pares como máximo.

  Cada clave es una cadena UTF-8 con una longitud de entre 1 y 128 bytes.

  Cada valor es una cadena UTF-8 que no tiene más de 256 bytes de largo.

  Etiquetas solicitadas

Errores

- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `EntityNotFoundException`

Tipos de datos comunes

Los tipos de datos comunes describen diversos tipos de datos comunes en AWS Glue.

Estructura de etiquetas

El objeto Tag representa una etiqueta que se puede asignar a un recurso de AWS. Cada etiqueta está formada por una clave y un valor opcional, ambos definidos por el usuario.

Para obtener más información acerca de las etiquetas y controlar el acceso a los recursos en AWS Glue, consulte Etiquetas de AWS en AWS Glue y Especificación de ARN de recursos de AWS Glue en la Guía para desarrolladores.

Campos

- key: cadena UTF-8, con 1 byte de largo como mínimo y 128 bytes de largo como máximo.

  La clave de la etiqueta. La clave es necesaria para crear una etiqueta en un objeto. La clave distingue entre mayúsculas y minúsculas y no debe contener el prefijo aws.
- value: cadena UTF-8 de 256 bytes de largo como máximo.

  El valor de la etiqueta. El valor es opcional para crear una etiqueta en un objeto. El valor distingue entre mayúsculas y minúsculas y no debe contener el prefijo aws.

Estructura DecimalNumber

Contiene un valor numérico en formato decimal.

Campos

- UnscaledValue – Obligatorio: Blob.

  El valor numérico sin escala.
- Scale – Obligatorio: número (entero).

  Escala que determina la ubicación de punto decimal en el valor sin escala.

Estructura ErrorDetail

Contiene detalles sobre un error.

Campos

- `ErrorCode` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El código asociado a este error.
- `ErrorMessage` – cadena de descripción de un máximo de 2048 bytes de largo, que coincide con el URI address multi-line string pattern.

  Mensaje que describe el error.

Estructura PropertyPredicate

Define el predicado de una propiedad.

Campos

- `Key`: cadena de valor con una extensión de 1 byte como mínimo o 1024 bytes como máximo.

  La clave de la propiedad.
- `Value`: cadena de valor con una extensión de 1 byte como mínimo o 1024 bytes como máximo.

  El valor de la propiedad.
- `Comparator` – Cadena UTF-8 (valores válidos: `EQUALS` | `GREATER_THAN` | `LESS_THAN` | `GREATER_THAN_EQUALS` | `LESS_THAN_EQUALS`).

  El comparador utilizado para comparar esta propiedad con otras

Estructura ResourceUri

Las URI para los recursos de función.

Campos

- `ResourceType` – Cadena UTF-8 (valores válidos: `JAR` | `FILE` | `ARCHIVE`).

  El tipo de recurso.
- `Uri` – identificador uniforme de recursos (uri), con 1 byte de largo como mínimo y 1024 bytes de largo como máximo, que coincide con el URI address multi-line string pattern.

El URI para obtener acceso al recurso.

Estructura ColumnStatistics

Representa las estadísticas de nivel de columna generadas para una tabla o partición.

Campos

- `ColumnName`: obligatorio: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  Nombre de la columna a la que pertenecen las estadísticas.
- `ColumnType` – Obligatorio: nombre de tipo, de 20 000 bytes de largo como máximo, que coincide con Single-line string pattern.

  El tipo de datos de la columna.
- `AnalyzedTime` – Obligatorio: marca temporal.

  Marca temporal del momento en que se generaron las estadísticas de columna.
- `StatisticsData`: obligatorio: objeto ColumnStatisticsData.

  Objeto `ColumnStatisticData` que contiene los valores de datos estadísticos.

Estructura ColumnStatisticsError

Encapsula un objeto `ColumnStatistics` que presentó error y el motivo del error.

Campos

- `ColumnStatistics`: un objeto ColumnStatistics.

  Las `ColumnStatistics` de la columna.
- `Error`: un objeto ErrorDetail.

  Un mensaje de error con el motivo del error de una operación.

Estructura ColumnError

Encapsula un nombre columna que presentó error y el motivo del error.

Campos

- `ColumnName` – cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El nombre de la columna que presentó error.
- `Error`: un objeto ErrorDetail.

  Un mensaje de error con el motivo del error de una operación.

Estructura ColumnStatisticsData

Contiene los tipos individuales de datos estadísticos de columna. Solo se debe establecer un objeto de datos e indicar mediante el atributo `Type`.

Campos

- `Type` – Obligatorio: cadena UTF-8 (valores válidos: `BOOLEAN` | `DATE` | `DECIMAL` | `DOUBLE` | `LONG` | `STRING` | `BINARY`).

  Los datos estadísticos del tipo de columna.
- `BooleanColumnStatisticsData`: un objeto BooleanColumnStatisticsData.

  Datos estadísticos de columnas booleanas.
- `DateColumnStatisticsData`: un objeto DateColumnStatisticsData.

  Datos estadísticos de columnas de fecha.
- `DecimalColumnStatisticsData`: un objeto DecimalColumnStatisticsData.

  Datos estadísticos columnas de decimales. UnscaledValues dentro son objetos binarios codificados en Base64 que almacenan representaciones big-endian, complementarias de dos, del valor sin escala del decimal.
- `DoubleColumnStatisticsData`: un objeto DoubleColumnStatisticsData.

  Datos estadísticos de doble columna.

- `LongColumnStatisticsData`: un objeto LongColumnStatisticsData.

  Datos estadísticos de columna larga.
- `StringColumnStatisticsData`: un objeto StringColumnStatisticsData.

  Datos estadísticos de columnas de cadena.
- `BinaryColumnStatisticsData`: un objeto BinaryColumnStatisticsData.

  Datos estadísticos de columnas binarias.

Estructura BooleanColumnStatisticsData

Define las estadísticas de columna soportadas para las columnas de datos booleanos.

Campos

- `NumberOfTrues` – Obligatorio: número (largo), cero como máximo.

  El número de valores verdaderos en la columna.
- `NumberOfFalses` – Obligatorio: número (largo), cero como máximo.

  El número de valores falsos en la columna.
- `NumberOfNulls` – Obligatorio: número (largo), cero como máximo.

  El número de valores nulos en la columna.

Estructura DateColumnStatisticsData

Define las estadísticas de columna soportadas para las columnas de datos de marca temporal.

Campos

- `MinimumValue`: marca temporal.

  El valor más bajo de la columna.
- `MaximumValue`: marca temporal.

  El valor más alto de la columna.
- `NumberOfNulls` – Obligatorio: número (largo), cero como máximo.

El número de valores nulos en la columna.

- `NumberOfDistinctValues` – Obligatorio: número (largo), cero como máximo.

  El número de valores distintos de una columna.

Estructura DecimalColumnStatisticsData

Define las estadísticas de columna soportadas para las columnas de datos de números con coma fija.

Campos

- `MinimumValue`: un objeto DecimalNumber.

  El valor más bajo de la columna.
- `MaximumValue`: un objeto DecimalNumber.

  El valor más alto de la columna.
- `NumberOfNulls` – Obligatorio: número (largo), cero como máximo.

  El número de valores nulos en la columna.
- `NumberOfDistinctValues` – Obligatorio: número (largo), cero como máximo.

  El número de valores distintos de una columna.

Estructura DoubleColumnStatisticsData

Define las estadísticas de columna soportadas para las columnas de datos de números con coma flotante.

Campos

- `MinimumValue`: número (doble).

  El valor más bajo de la columna.
- `MaximumValue`: número (doble).

  El valor más alto de la columna.

- `NumberOfNulls` – Obligatorio: número (largo), cero como máximo.

  El número de valores nulos en la columna.
- `NumberOfDistinctValues` – Obligatorio: número (largo), cero como máximo.

  El número de valores distintos de una columna.

Estructura LongColumnStatisticsData

Define las estadísticas de columna soportadas para las columnas de datos enteros.

Campos

- `MinimumValue`: número (largo).

  El valor más bajo de la columna.
- `MaximumValue`: número (largo).

  El valor más alto de la columna.
- `NumberOfNulls` – Obligatorio: número (largo), cero como máximo.

  El número de valores nulos en la columna.
- `NumberOfDistinctValues` – Obligatorio: número (largo), cero como máximo.

  El número de valores distintos de una columna.

Estructura StringColumnStatisticsData

Define estadísticas de columna admitidas para valores de datos de secuencia de caracteres.

Campos

- `MaximumLength` – Obligatorio: número (largo), cero como máximo.

  El tamaño de la cadena más larga de la columna.
- `AverageLength` – Obligatorio: número (doble), cero como máximo.

  La longitud media de la cadena en la columna.
- `NumberOfNulls` – Obligatorio: número (largo), cero como máximo.

El número de valores nulos en la columna.

- `NumberOfDistinctValues` – Obligatorio: número (largo), cero como máximo.

  El número de valores distintos de una columna.

Estructura BinaryColumnStatisticsData

Define estadísticas de columna soportadas para valores de datos de secuencia de bits.

Campos

- `MaximumLength` – Obligatorio: número (largo), cero como máximo.

  El tamaño de la secuencia de bits más larga de la columna.
- `AverageLength` – Obligatorio: número (doble), cero como máximo.

  La longitud media de secuencia de bits en la columna.
- `NumberOfNulls` – Obligatorio: número (largo), cero como máximo.

  El número de valores nulos en la columna.

Patrones de cadena

La API utiliza las siguientes expresiones regulares para definir qué es un contenido válido para diversos miembros y parámetros de cadena:

- Patrón de cadena de línea única – `"[\u0020-\uD7FF\uE000-\uFFFD\uD800\uDC00-\uDBFF\uDFFF\t]*"`
- Patrón de cadena de varias líneas de la dirección URI – `"[\u0020-\uD7FF\uE000-\uFFFD\uD800\uDC00-\uDBFF\uDFFF\r\n\t]*"`
- Patrón de cadena Grok Logstash – `"[\u0020-\uD7FF\uE000-\uFFFD\uD800\uDC00-\uDBFF\uDFFF\r\t]*"`
- Patrón de cadena del identificador – `"[A-Za-z_][A-Za-z0-9_]*"`
- Patrón de cadena de ARN de AWS IAM – `"arn:aws:iam::\d{12}:role/.*"`
- Patrón de cadena de versión – `"^[a-zA-Z0-9-_]+$"`
- Patrón de cadena de grupo de registros – `"[\.\-_/#A-Za-z0-9]+"`

- Patrón de cadena de flujo de registro – `"[^:*]*"`
- Patrón de cadena personalizado n.º #10 – `"[a-zA-Z0-9-_]+"`
- Patrón de cadena personalizado n.º #11 – `"[-a-zA-Z0-9+=/:_]*"`
- Patrón de cadena personalizado n.º #12 – `"[\S\s]*"`
- Patrón de cadena personalizado n.º #13 – `".*\S.*"`
- Patrón de cadena personalizado n.º #14 – `"[a-zA-Z0-9-=._/@]+"`
- Patrón de cadena personalizado n.º #15 – `"[1-9][0-9]*|[1-9][0-9]*-[1-9][0-9]*"`
- Patrón de cadena personalizado n.º #16 – `"[A-Z][A-Za-z\.]+"`
- Patrón de cadena personalizado n.º #17 – `"[\S]*"`
- Patrón de cadena personalizado n.º #18 – `"[\w]*"`
- Patrón de cadena personalizado n.º #19 – `"arn:aws[a-z\-]*:iam::\d{12}:role/?[a-zA-Z_0-9+=,.@\-_/]+"`
- Patrón de cadena personalizado n.º #20 – `"subnet-[a-z0-9]+"`
- Patrón de cadena personalizado n.º #21 – `"\d{12}"`
- Patrón de cadena personalizado n.º #22 – `"([a-z]+)-([a-z]+-)?([a-z]+)-[0-9]+[a-z]+"`
- Patrón de cadena personalizado n.º #23 – `"[a-zA-Z0-9.-]*"`
- Patrón de cadena personalizado n.º #24 – `"arn:aws[a-z0-9\-]*:lambda:[a-z0-9\-]+:\d{12}:function:([\w\-]{1,64})"`
- Patrón de cadena personalizado n.º #25 – `"^(?!(.*[.\/\\]|aws:)).*$"`
- Patrón de cadena personalizado n.º #26 – `"[^\r\n]"`
- Patrón de cadena personalizado n.º #27 – `"^\w+\.\w+\.\w+$"`
- Patrón de cadena personalizado n.º #28 – `"^\w+\.\w+$"`
- Patrón de cadena personalizado n.º #29 – `"^$|arn:aws[a-z0-9-]*:kms:.*"`
- Patrón de cadena personalizado n.º #30 – `"arn:aws[^:]*:iam::[0-9]*:role/.+"`
- Patrón de cadena personalizado n.º #31 – `"[\.\-_A-Za-z0-9]+"`
- Patrón de cadena personalizado n.º #32 – `"^s3://([^/]+)/([^/]+/)*([^/]+)$"`
- Patrón de cadena personalizado n.º #33 – `".*"`
- Patrón de cadena personalizado n.º #34 – `"^(Sun|Mon|Tue|Wed|Thu|Fri|Sat):([01]?[0-9]|2[0-3])$"`
- Patrón de cadena personalizado n.º #35 – `"[a-zA-Z0-9_.-]+"`

- Patrón de cadena personalizado N.º #36 – "^arn:aws(-(cn|us-gov|iso(-[bef])?))?:secretsmanager:.*$"
- Patrón de cadena personalizado N.º #37 – "\S+"
- Patrón de cadena personalizado N.º #38 – "^[\x20-\x7E]*$"
- Patrón de cadena personalizado N.º #39 – "^([a-zA-Z0-9_=]+)\.([a-zA-Z0-9_=]+)\.([a-zA-Z0-9_\-\+\/=]*)"
- Patrón de cadena personalizado N.º #40 – "^(https?://[-a-zA-Z0-9+&@#/%?=~_|!:,.;]*[-a-zA-Z0-9+&@#/%=~_|]"
- Patrón de cadena personalizado N.º #41 – "^(https?):\/\/[^\s/$.?#].[^\s]*$"
- Patrón de cadena personalizado N.º #42 – "arn:aws:kms:.*"
- Patrón de cadena personalizado N.º #43 – "^subnet-[a-z0-9]+$"
- Patrón de cadena personalizado N.º #44 – "[\p{L}\p{N}\p{P}]*"
- Patrón de cadena personalizado N.º #45 – "[a-f0-9]{8}-[a-f0-9]{4}-[a-f0-9]{4}-[a-f0-9]{4}-[a-f0-9]{12}"
- Patrón de cadena personalizado N.º #46 – "[a-zA-Z0-9-_$#.]+"
- Patrón de cadena personalizado N.º #47 – "^\d{12}$"
- Patrón de cadena personalizado N.º #48 – "^(\w+\.)+\w+$"
- Patrón de cadena personalizado N.º #49 – "^([2-3]|3[.]9)$"
- Patrón de cadena personalizado N.º #50 – "arn:aws(-(cn|us-gov|iso(-[bef])?))?:glue:.*"
- Patrón de cadena personalizado N.º #51 – "[0-9a-fA-F]{8}-[0-9a-fA-F]{4}-[0-9a-fA-F]{4}-[0-9a-fA-F]{4}-[0-9a-fA-F]{12}"
- Patrón de cadena personalizado N.º #52 – "(^arn:aws(-(cn|us-gov|iso(-[bef])?))?:iam::\w{12}:root)"
- Patrón de cadena personalizado N.º #53 – "^arn:aws(-(cn|us-gov|iso(-[bef])?))?:iam::[0-9]{12}:role/.+"
- Patrón de cadena personalizado N.º #54 – "[\s\S]*"
- Patrón de cadena personalizado N.º #55 – "([\u0020-\uD7FF\uE000-\uFFFD\uD800\uDC00-\uDBFF\uDFFF]|[^\S\r\n"'= ;])*"
- Patrón de cadena personalizado N.º #56 – "^[A-Z_]+$"
- Patrón de cadena personalizado N.º #57 – "^[A-Za-z0-9]+$"
- Patrón de cadena personalizado N.º #58 – "[*A-Za-z0-9_-]*"

- Patrón de cadena personalizado N.º #59 – `"([\u0020-\u007E\r\s\n])*"`
- Patrón de cadena personalizado N.º #60 – `"[A-Za-z0-9_-]*"`
- Patrón de cadena personalizado N.º #61 – `"([\u0009\u000B\u000C\u0020-\uD7FF\uE000-\uFFFD\uD800\uDC00-\uDBFF\uDFFF])*"`
- Patrón de cadena personalizado N.º #62 – `"([\u0020-\uD7FF\uE000-\uFFFD\uD800\uDC00-\uDBFF\uDFFF\s])*"`
- Patrón de cadena personalizado n.º #63 – `"([^\r\n])*"`

Excepciones

En esta sección, se describen las excepciones de AWS Glue que puede utilizar para encontrar el origen de los problemas y solucionarlos. Para obtener más información sobre las cadenas y códigos de error HTTP de las excepciones relacionadas con el machine learning, consulte the section called "Excepciones de machine learning en AWS Glue".

Estructura AccessDeniedException

El acceso a un recurso se ha denegado.

Campos

- `Message`: cadena UTF-8.

  Mensaje que describe el problema.

Estructura de AlreadyExistsException

Un recurso que se va a crear o añadir ya existe.

Campos

- `Message`: cadena UTF-8.

  Mensaje que describe el problema.

Estructura ConcurrentModificationException

Dos procesos intentan modificar un recurso a la vez.

Campos

- `Message`: cadena UTF-8.

  Mensaje que describe el problema.

Estructura ConcurrentRunsExceededException

Demasiados trabajos se ejecutan al mismo tiempo.

Campos

- `Message`: cadena UTF-8.

  Mensaje que describe el problema.

Estructura CrawlerNotRunningException

El rastreador especificado no está ejecutándose.

Campos

- `Message`: cadena UTF-8.

  Mensaje que describe el problema.

Estructura CrawlerRunningException

La operación no se puede realizar porque el rastreador ya se está ejecutando.

Campos

- `Message`: cadena UTF-8.

  Mensaje que describe el problema.

Estructura CrawlerStoppingException

El rastreador especificado se está parando.

Campos

- `Message`: cadena UTF-8.

  Mensaje que describe el problema.

Estructura EntityNotFoundException

Una entidad especificada no existe.

Campos

- `Message`: cadena UTF-8.

  Mensaje que describe el problema.
- `FromFederationSource`: booleano.

  Indica si la excepción se refiere o no a un origen federado.

Estructura de FederationSourceException

Error en un origen de federación.

Campos

- `FederationSourceErrorCode`: Cadena UTF-8 (valores válidos: `AccessDeniedException` | `EntityNotFoundException` | `InvalidCredentialsException` | `InvalidInputException` | `InvalidResponseException` | `OperationTimeoutException` | `OperationNotSupportedException` | `InternalServiceException` | `PartialFailureException` | `ThrottlingException`).

  El código de error del problema.
- `Message`: cadena UTF-8.

  Mensaje que describe el problema.

Estructura de FederationSourceRetryableException

Se produjo un error en un origen de federación, pero es posible que se vuelva a intentar la operación.

Campos

- `Message`: cadena UTF-8.

  Mensaje que describe el problema.

Estructura GlueEncryptionException

Una operación de cifrado ha devuelto un error.

Campos

- `Message`: cadena UTF-8.

  Mensaje que describe el problema.

Estructura IdempotentParameterMismatchException

El mismo identificador único se asoció a dos registros diferentes.

Campos

- `Message`: cadena UTF-8.

  Mensaje que describe el problema.

Estructura IllegalWorkflowStateException

El flujo de trabajo está en un estado no válido para realizar una operación solicitada.

Campos

- `Message`: cadena UTF-8.

  Mensaje que describe el problema.

Estructura InternalServiceException

Se ha producido un error de servicio interno.

Campos

- `Message`: cadena UTF-8.

  Mensaje que describe el problema.

Estructura InvalidExecutionEngineException

Se ha especificado un motor de ejecución desconocido o no válido.

Campos

- `message`: cadena UTF-8.

  Mensaje que describe el problema.

Estructura InvalidInputException

La información de entrada proporcionada no es válida.

Campos

- `Message`: cadena UTF-8.

  Mensaje que describe el problema.
- `FromFederationSource`: booleano.

  Indica si la excepción se refiere o no a un origen federado.

Estructura InvalidStateException

Un error que indica que los datos se encuentran en un estado no válido.

Campos

- `Message`: cadena UTF-8.

  Mensaje que describe el problema.

Estructura InvalidTaskStatusTransitionException

Error en la transición correcta de una tarea a la siguiente.

Campos

- `message`: cadena UTF-8.

  Mensaje que describe el problema.

Estructura JobDefinitionErrorException

Una definición de trabajo no es válida.

Campos

- `message`: cadena UTF-8.

  Mensaje que describe el problema.

Estructura JobRunInTerminalStateException

El estado terminal de una ejecución de flujo de trabajo señala un error.

Campos

- `message`: cadena UTF-8.

  Mensaje que describe el problema.

Estructura JobRunInvalidStateTransitionException

Una ejecución de flujo de trabajo ha encontrado una transición no válida del estado de origen al de destino.

Campos

- `jobRunId`: cadena UTF-8, con 1 byte de largo como mínimo y 255 bytes de largo como máximo, que coincide con el Single-line string pattern.

  El ID de la ejecución de trabajo en cuestión.

- `message`: cadena UTF-8.

  Mensaje que describe el problema.

- `sourceState`: Cadena UTF-8 (valores válidos: `STARTING` | `RUNNING` | `STOPPING` | `STOPPED` | `SUCCEEDED` | `FAILED` | `TIMEOUT` | `ERROR` | `WAITING` | `EXPIRED`).

  El estado de origen.

- `targetState`: Cadena UTF-8 (valores válidos: `STARTING` | `RUNNING` | `STOPPING` | `STOPPED` | `SUCCEEDED` | `FAILED` | `TIMEOUT` | `ERROR` | `WAITING` | `EXPIRED`).

  El estado de destino.

Estructura JobRunNotInTerminalStateException

Una ejecución de flujo de trabajo no se encuentra en estado terminal.

Campos

- `message`: cadena UTF-8.

  Mensaje que describe el problema.

Estructura LateRunnerException

Un ejecutor de flujo de trabajo se ha atrasado.

Campos

- `Message`: cadena UTF-8.

  Mensaje que describe el problema.

Estructura NoScheduleException

No hay ningún programa aplicable.

Campos

- `Message`: cadena UTF-8.

Mensaje que describe el problema.

Estructura OperationTimeoutException

La operación ha agotado el tiempo de espera.

Campos

- `Message`: cadena UTF-8.

  Mensaje que describe el problema.

Estructura ResourceNotReadyException

Un recurso no estaba listo para una transacción.

Campos

- `Message`: cadena UTF-8.

  Mensaje que describe el problema.

Estructura ResourceNumberLimitExceededException

Un límite numérico de los recursos se ha superado.

Campos

- `Message`: cadena UTF-8.

  Mensaje que describe el problema.

Estructura SchedulerNotRunningException

El programador especificado no está ejecutándose.

Campos

- `Message`: cadena UTF-8.

Mensaje que describe el problema.

Estructura SchedulerRunningException

El programador especificado ya está ejecutándose.

Campos

- `Message`: cadena UTF-8.

  Mensaje que describe el problema.

Estructura SchedulerTransitioningException

El programador especificado se encuentra en transición.

Campos

- `Message`: cadena UTF-8.

  Mensaje que describe el problema.

Estructura UnrecognizedRunnerException

No se ha reconocido al ejecutor del flujo de trabajo.

Campos

- `Message`: cadena UTF-8.

  Mensaje que describe el problema.

Estructura ValidationException

No se ha podido validar a un valor.

Campos

- `Message`: cadena UTF-8.

Mensaje que describe el problema.

Estructura VersionMismatchException

Se ha producido un conflicto de versiones.

Campos

- `message`: cadena UTF-8.

  Mensaje que describe el problema.

Ejemplos de código de la API de AWS Glue con SDK de AWS

Los siguientes ejemplos de código muestran cómo utilizar AWS Glue con un kit de desarrollo de software (SDK) de AWS.

Los conceptos básicos son ejemplos de código que muestran cómo realizar las operaciones esenciales dentro de un servicio.

Las acciones son extractos de código de programas más grandes y deben ejecutarse en contexto. Las acciones muestran cómo llamar a las funciones de servicio individuales y es posible verlas en contexto en los escenarios relacionados.

Para obtener una lista completa de las guías para desarrolladores de AWS SDK y ejemplos de código, consulte Cómo utilizar este servicio con un AWS SDK. En este tema también se incluye información sobre cómo comenzar a utilizar el SDK y detalles sobre sus versiones anteriores.

Introducción

Introducción a AWS Glue

En los siguientes ejemplos de código se muestra cómo empezar a utilizar AWS Glue.

.NET

SDK para .NET

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
namespace GlueActions;

public class HelloGlue
{
    private static ILogger logger = null!;

    static async Task Main(string[] args)
```

```
    {
        // Set up dependency injection for AWS Glue.
        using var host = Host.CreateDefaultBuilder(args)
            .ConfigureLogging(logging =>
                logging.AddFilter("System", LogLevel.Debug)
                    .AddFilter<DebugLoggerProvider>("Microsoft",
 LogLevel.Information)
                    .AddFilter<ConsoleLoggerProvider>("Microsoft",
 LogLevel.Trace))
            .ConfigureServices((_, services) =>
                services.AddAWSService<IAmazonGlue>()
                .AddTransient<GlueWrapper>()
            )
            .Build();

        logger = LoggerFactory.Create(builder => { builder.AddConsole(); })
            .CreateLogger<HelloGlue>();
        var glueClient = host.Services.GetRequiredService<IAmazonGlue>();

        var request = new ListJobsRequest();

        var jobNames = new List<string>();

        do
        {
            var response = await glueClient.ListJobsAsync(request);
            jobNames.AddRange(response.JobNames);
            request.NextToken = response.NextToken;
        }
        while (request.NextToken is not null);

        Console.Clear();
        Console.WriteLine("Hello, Glue. Let's list your existing Glue Jobs:");
        if (jobNames.Count == 0)
        {
            Console.WriteLine("You don't have any AWS Glue jobs.");
        }
        else
        {
            jobNames.ForEach(Console.WriteLine);
        }
    }
}
```

- Para obtener información sobre la API, consulte ListJobs en la Referencia de la API de AWS SDK para .NET.

C++

SDK para C++

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

Código del archivo de CMake CMakeLists.txt.

```
# Set the minimum required version of CMake for this project.
cmake_minimum_required(VERSION 3.13)

# Set the AWS service components used by this project.
set(SERVICE_COMPONENTS glue)

# Set this project's name.
project("hello_glue")

# Set the C++ standard to use to build this target.
# At least C++ 11 is required for the AWS SDK for C++.
set(CMAKE_CXX_STANDARD 11)

# Use the MSVC variable to determine if this is a Windows build.
set(WINDOWS_BUILD ${MSVC})

if (WINDOWS_BUILD) # Set the location where CMake can find the installed
 libraries for the AWS SDK.
    string(REPLACE ";" "/aws-cpp-sdk-all;" SYSTEM_MODULE_PATH
 "${CMAKE_SYSTEM_PREFIX_PATH}/aws-cpp-sdk-all")
    list(APPEND CMAKE_PREFIX_PATH ${SYSTEM_MODULE_PATH})
endif ()

# Find the AWS SDK for C++ package.
find_package(AWSSDK REQUIRED COMPONENTS ${SERVICE_COMPONENTS})
```

```
if (WINDOWS_BUILD AND AWSSDK_INSTALL_AS_SHARED_LIBS)
     # Copy relevant AWS SDK for C++ libraries into the current binary directory
 for running and debugging.

     # set(BIN_SUB_DIR "/Debug") # if you are building from the command line you
 may need to uncomment this
                                     # and set the proper subdirectory to the
 executables' location.

     AWSSDK_CPY_DYN_LIBS(SERVICE_COMPONENTS ""
 ${CMAKE_CURRENT_BINARY_DIR}${BIN_SUB_DIR})
endif ()

add_executable(${PROJECT_NAME}
        hello_glue.cpp)

target_link_libraries(${PROJECT_NAME}
        ${AWSSDK_LINK_LIBRARIES})
```

Código del archivo de origen hello_glue.cpp.

```
#include <aws/core/Aws.h>
#include <aws/glue/GlueClient.h>
#include <aws/glue/model/ListJobsRequest.h>
#include <iostream>

/*
 *  A "Hello Glue" starter application which initializes an AWS Glue client and
 lists the
 *  AWS Glue job definitions.
 *
 *  main function
 *
 *  Usage: 'hello_glue'
 *
 */

int main(int argc, char **argv) {
    Aws::SDKOptions options;
    // Optionally change the log level for debugging.
//   options.loggingOptions.logLevel = Utils::Logging::LogLevel::Debug;
```

```
    Aws::InitAPI(options); // Should only be called once.
    int result = 0;
    {
        Aws::Client::ClientConfiguration clientConfig;
        // Optional: Set to the AWS Region (overrides config file).
        // clientConfig.region = "us-east-1";

        Aws::Glue::GlueClient glueClient(clientConfig);

        std::vector<Aws::String> jobs;

        Aws::String nextToken;  // Used for pagination.
        do {
            Aws::Glue::Model::ListJobsRequest listJobsRequest;
            if (!nextToken.empty()) {
                listJobsRequest.SetNextToken(nextToken);
            }

            Aws::Glue::Model::ListJobsOutcome listRunsOutcome =
glueClient.ListJobs(
                    listJobsRequest);

            if (listRunsOutcome.IsSuccess()) {
                const std::vector<Aws::String> &jobNames =
listRunsOutcome.GetResult().GetJobNames();
                jobs.insert(jobs.end(), jobNames.begin(), jobNames.end());

                nextToken = listRunsOutcome.GetResult().GetNextToken();
            } else {
                std::cerr << "Error listing jobs. "
                          << listRunsOutcome.GetError().GetMessage()
                          << std::endl;
                result = 1;
                break;
            }
        } while (!nextToken.empty());

        std::cout << "Your account has " << jobs.size() << " jobs."
                  << std::endl;
        for (size_t i = 0; i < jobs.size(); ++i) {
            std::cout << "   " << i + 1 << ". " << jobs[i] << std::endl;
        }
    }
    Aws::ShutdownAPI(options); // Should only be called once.
```

```
    return result;
}
```

- Para obtener información sobre la API, consulte ListJobs en la Referencia de la API de AWS SDK para C++.

Java

SDK para Java 2.x

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
package com.example.glue;

import software.amazon.awssdk.regions.Region;
import software.amazon.awssdk.services.glue.GlueClient;
import software.amazon.awssdk.services.glue.model.ListJobsRequest;
import software.amazon.awssdk.services.glue.model.ListJobsResponse;
import java.util.List;

public class HelloGlue {
    public static void main(String[] args) {
        GlueClient glueClient = GlueClient.builder()
                .region(Region.US_EAST_1)
                .build();

        listJobs(glueClient);
    }

    public static void listJobs(GlueClient glueClient) {
        ListJobsRequest request = ListJobsRequest.builder()
                .maxResults(10)
                .build();
        ListJobsResponse response = glueClient.listJobs(request);
        List<String> jobList = response.jobNames();
        jobList.forEach(job -> {
```

```
            System.out.println("Job Name: " + job);
        });
    }
}
```

- Para obtener información sobre la API, consulte ListJobs en la Referencia de la API de AWS SDK for Java 2.x.

JavaScript

SDK para JavaScript (v3)

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
import { ListJobsCommand, GlueClient } from "@aws-sdk/client-glue";

const client = new GlueClient({});

export const main = async () => {
  const command = new ListJobsCommand({});

  const { JobNames } = await client.send(command);
  const formattedJobNames = JobNames.join("\n");
  console.log("Job names: ");
  console.log(formattedJobNames);
  return JobNames;
};
```

- Para obtener información sobre la API, consulte ListJobs en la Referencia de la API de AWS SDK para JavaScript.

Python

SDK para Python (Boto3)

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
import boto3
from botocore.exceptions import ClientError


def hello_glue():
    """
    Lists the job definitions in your AWS Glue account, using the AWS SDK for
 Python (Boto3).
    """
    try:
        # Create the Glue client
        glue = boto3.client("glue")

        # List the jobs, limiting the results to 10 per page
        paginator = glue.get_paginator("get_jobs")
        response_iterator = paginator.paginate(
            PaginationConfig={"MaxItems": 10, "PageSize": 10}
        )

        # Print the job names
        print("Here are the jobs in your account:")
        for page in response_iterator:
            for job in page["Jobs"]:
                print(f"\t{job['Name']}")

    except ClientError as e:
        print(f"Error: {e}")


if __name__ == "__main__":
    hello_glue()
```

- Para obtener información sobre la API, consulte ListJobs en la Referencia de la API de AWS SDK para Python (Boto3).

Ruby

SDK para Ruby

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
require 'aws-sdk-glue'
require 'logger'

# GlueManager is a class responsible for managing AWS Glue operations
# such as listing all Glue jobs in the current AWS account.
class GlueManager
  def initialize(client)
    @client = client
    @logger = Logger.new($stdout)
  end

  # Lists and prints all Glue jobs in the current AWS account.
  def list_jobs
    @logger.info('Here are the Glue jobs in your account:')

    paginator = @client.get_jobs(max_results: 10)
    jobs = []

    paginator.each_page do |page|
      jobs.concat(page.jobs)
    end

    if jobs.empty?
      @logger.info("You don't have any Glue jobs.")
```

```
    else
      jobs.each do |job|
        @logger.info("- #{job.name}")
      end
    end
  end
end

if $PROGRAM_NAME == __FILE__
  glue_client = Aws::Glue::Client.new
  manager = GlueManager.new(glue_client)
  manager.list_jobs
end
```

- Para obtener información sobre la API, consulte ListJobs en la Referencia de la API de AWS SDK para Ruby.

Rust

SDK para Rust

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
        let mut list_jobs = glue.list_jobs().into_paginator().send();
        while let Some(list_jobs_output) = list_jobs.next().await {
            match list_jobs_output {
                Ok(list_jobs) => {
                    let names = list_jobs.job_names();
                    info!(?names, "Found these jobs")
                }
                Err(err) => return Err(GlueMvpError::from_glue_sdk(err)),
            }
        }
```

- Para obtener información sobre la API, consulte ListJobs en la Referencia de la API de AWS SDK para Rust.

Ejemplos de código de la API de AWS Glue

- Ejemplos básicos de código para AWS Glue mediante SDK de AWS
  - Introducción a AWS Glue
  - Aprenda los conceptos básicos de AWS Glue con un SDK de AWS
  - Acciones de AWS Glue con un AWS SDK
    - Cómo utilizar CreateCrawler con un AWS SDK
    - Uso de CreateJob con un SDK de AWS o la CLI
    - Cómo utilizar DeleteCrawler con un AWS SDK
    - Cómo utilizar DeleteDatabase con un AWS SDK
    - Uso de DeleteJob con un SDK de AWS o la CLI
    - Cómo utilizar DeleteTable con un AWS SDK
    - Cómo utilizar GetCrawler con un AWS SDK
    - Cómo utilizar GetDatabase con un AWS SDK
    - Uso de GetDatabases con un SDK de AWS o la CLI
    - Uso de GetJob con un SDK de AWS o la CLI
    - Uso de GetJobRun con un SDK de AWS o la CLI
    - Uso de GetJobRuns con un SDK de AWS o la CLI
    - Uso de GetTables con un SDK de AWS o la CLI
    - Cómo utilizar ListJobs con un AWS SDK
    - Uso de StartCrawler con un SDK de AWS o la CLI
    - Uso de StartJobRun con un SDK de AWS o la CLI

Ejemplos básicos de código para AWS Glue mediante SDK de AWS

Los siguientes ejemplos de código muestran cómo utilizar ejemplos básicos de AWS Glue con AWS SDK.

Ejemplos

- Introducción a AWS Glue
- Aprenda los conceptos básicos de AWS Glue con un SDK de AWS
- Acciones de AWS Glue con un AWS SDK
  - Cómo utilizar CreateCrawler con un AWS SDK
  - Uso de CreateJob con un SDK de AWS o la CLI
  - Cómo utilizar DeleteCrawler con un AWS SDK
  - Cómo utilizar DeleteDatabase con un AWS SDK
  - Uso de DeleteJob con un SDK de AWS o la CLI
  - Cómo utilizar DeleteTable con un AWS SDK
  - Cómo utilizar GetCrawler con un AWS SDK
  - Cómo utilizar GetDatabase con un AWS SDK
  - Uso de GetDatabases con un SDK de AWS o la CLI
  - Uso de GetJob con un SDK de AWS o la CLI
  - Uso de GetJobRun con un SDK de AWS o la CLI
  - Uso de GetJobRuns con un SDK de AWS o la CLI
  - Uso de GetTables con un SDK de AWS o la CLI
  - Cómo utilizar ListJobs con un AWS SDK
  - Uso de StartCrawler con un SDK de AWS o la CLI
  - Uso de StartJobRun con un SDK de AWS o la CLI

Introducción a AWS Glue

En los siguientes ejemplos de código se muestra cómo empezar a utilizar AWS Glue.

.NET

SDK para .NET

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
namespace GlueActions;

public class HelloGlue
{
    private static ILogger logger = null!;

    static async Task Main(string[] args)
    {
        // Set up dependency injection for AWS Glue.
        using var host = Host.CreateDefaultBuilder(args)
            .ConfigureLogging(logging =>
                logging.AddFilter("System", LogLevel.Debug)
                    .AddFilter<DebugLoggerProvider>("Microsoft",
 LogLevel.Information)
                    .AddFilter<ConsoleLoggerProvider>("Microsoft",
 LogLevel.Trace))
            .ConfigureServices((_, services) =>
                services.AddAWSService<IAmazonGlue>()
                .AddTransient<GlueWrapper>()
            )
            .Build();

        logger = LoggerFactory.Create(builder => { builder.AddConsole(); })
            .CreateLogger<HelloGlue>();
        var glueClient = host.Services.GetRequiredService<IAmazonGlue>();

        var request = new ListJobsRequest();

        var jobNames = new List<string>();

        do
        {
            var response = await glueClient.ListJobsAsync(request);
            jobNames.AddRange(response.JobNames);
            request.NextToken = response.NextToken;
        }
        while (request.NextToken is not null);

        Console.Clear();
        Console.WriteLine("Hello, Glue. Let's list your existing Glue Jobs:");
        if (jobNames.Count == 0)
        {
            Console.WriteLine("You don't have any AWS Glue jobs.");
```

```
        }
        else
        {
            jobNames.ForEach(Console.WriteLine);
        }
    }
}
```

- Para obtener información sobre la API, consulte ListJobs en la Referencia de la API de AWS SDK para .NET.

C++

SDK para C++

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

Código del archivo de CMake CMakeLists.txt.

```
# Set the minimum required version of CMake for this project.
cmake_minimum_required(VERSION 3.13)

# Set the AWS service components used by this project.
set(SERVICE_COMPONENTS glue)

# Set this project's name.
project("hello_glue")

# Set the C++ standard to use to build this target.
# At least C++ 11 is required for the AWS SDK for C++.
set(CMAKE_CXX_STANDARD 11)

# Use the MSVC variable to determine if this is a Windows build.
set(WINDOWS_BUILD ${MSVC})
```

```
if (WINDOWS_BUILD) # Set the location where CMake can find the installed
 libraries for the AWS SDK.
    string(REPLACE ";" "/aws-cpp-sdk-all;" SYSTEM_MODULE_PATH
 "${CMAKE_SYSTEM_PREFIX_PATH}/aws-cpp-sdk-all")
    list(APPEND CMAKE_PREFIX_PATH ${SYSTEM_MODULE_PATH})
endif ()

# Find the AWS SDK for C++ package.
find_package(AWSSDK REQUIRED COMPONENTS ${SERVICE_COMPONENTS})

if (WINDOWS_BUILD AND AWSSDK_INSTALL_AS_SHARED_LIBS)
     # Copy relevant AWS SDK for C++ libraries into the current binary directory
 for running and debugging.

     # set(BIN_SUB_DIR "/Debug") # if you are building from the command line you
 may need to uncomment this
                                     # and set the proper subdirectory to the
 executables' location.

     AWSSDK_CPY_DYN_LIBS(SERVICE_COMPONENTS ""
 ${CMAKE_CURRENT_BINARY_DIR}${BIN_SUB_DIR})
endif ()

add_executable(${PROJECT_NAME}
        hello_glue.cpp)

target_link_libraries(${PROJECT_NAME}
        ${AWSSDK_LINK_LIBRARIES})
```

Código del archivo de origen hello_glue.cpp.

```
#include <aws/core/Aws.h>
#include <aws/glue/GlueClient.h>
#include <aws/glue/model/ListJobsRequest.h>
#include <iostream>

/*
 *  A "Hello Glue" starter application which initializes an AWS Glue client and
 lists the
 *  AWS Glue job definitions.
 *
 *  main function
```

```
 *
 *  Usage: 'hello_glue'
 *
 */

int main(int argc, char **argv) {
    Aws::SDKOptions options;
    // Optionally change the log level for debugging.
//   options.loggingOptions.logLevel = Utils::Logging::LogLevel::Debug;
    Aws::InitAPI(options); // Should only be called once.
    int result = 0;
    {
        Aws::Client::ClientConfiguration clientConfig;
        // Optional: Set to the AWS Region (overrides config file).
        // clientConfig.region = "us-east-1";

        Aws::Glue::GlueClient glueClient(clientConfig);

        std::vector<Aws::String> jobs;

        Aws::String nextToken;  // Used for pagination.
        do {
            Aws::Glue::Model::ListJobsRequest listJobsRequest;
            if (!nextToken.empty()) {
                listJobsRequest.SetNextToken(nextToken);
            }

            Aws::Glue::Model::ListJobsOutcome listRunsOutcome =
 glueClient.ListJobs(
                    listJobsRequest);

            if (listRunsOutcome.IsSuccess()) {
                const std::vector<Aws::String> &jobNames =
 listRunsOutcome.GetResult().GetJobNames();
                jobs.insert(jobs.end(), jobNames.begin(), jobNames.end());

                nextToken = listRunsOutcome.GetResult().GetNextToken();
            } else {
                std::cerr << "Error listing jobs. "
                          << listRunsOutcome.GetError().GetMessage()
                          << std::endl;
                result = 1;
                break;
            }
```

```
        } while (!nextToken.empty());

        std::cout << "Your account has " << jobs.size() << " jobs."
                  << std::endl;
        for (size_t i = 0; i < jobs.size(); ++i) {
            std::cout << "   " << i + 1 << ". " << jobs[i] << std::endl;
        }
    }
    Aws::ShutdownAPI(options); // Should only be called once.
    return result;
}
```

- Para obtener información sobre la API, consulte ListJobs en la Referencia de la API de AWS SDK para C++.

Java

SDK para Java 2.x

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
package com.example.glue;

import software.amazon.awssdk.regions.Region;
import software.amazon.awssdk.services.glue.GlueClient;
import software.amazon.awssdk.services.glue.model.ListJobsRequest;
import software.amazon.awssdk.services.glue.model.ListJobsResponse;
import java.util.List;

public class HelloGlue {
    public static void main(String[] args) {
        GlueClient glueClient = GlueClient.builder()
                .region(Region.US_EAST_1)
                .build();

        listJobs(glueClient);
```

```
    }

    public static void listJobs(GlueClient glueClient) {
        ListJobsRequest request = ListJobsRequest.builder()
                .maxResults(10)
                .build();
        ListJobsResponse response = glueClient.listJobs(request);
        List<String> jobList = response.jobNames();
        jobList.forEach(job -> {
            System.out.println("Job Name: " + job);
        });
    }
}
```

- Para obtener información sobre la API, consulte ListJobs en la Referencia de la API de AWS SDK for Java 2.x.

JavaScript

SDK para JavaScript (v3)

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
import { ListJobsCommand, GlueClient } from "@aws-sdk/client-glue";

const client = new GlueClient({});

export const main = async () => {
  const command = new ListJobsCommand({});

  const { JobNames } = await client.send(command);
  const formattedJobNames = JobNames.join("\n");
  console.log("Job names: ");
  console.log(formattedJobNames);
  return JobNames;
};
```

- Para obtener información sobre la API, consulte ListJobs en la Referencia de la API de AWS SDK para JavaScript.

Python

SDK para Python (Boto3)

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
import boto3
from botocore.exceptions import ClientError


def hello_glue():
    """
    Lists the job definitions in your AWS Glue account, using the AWS SDK for
 Python (Boto3).
    """
    try:
        # Create the Glue client
        glue = boto3.client("glue")

        # List the jobs, limiting the results to 10 per page
        paginator = glue.get_paginator("get_jobs")
        response_iterator = paginator.paginate(
            PaginationConfig={"MaxItems": 10, "PageSize": 10}
        )

        # Print the job names
        print("Here are the jobs in your account:")
        for page in response_iterator:
            for job in page["Jobs"]:
                print(f"\t{job['Name']}")
```

```
    except ClientError as e:
        print(f"Error: {e}")


if __name__ == "__main__":
    hello_glue()
```

- Para obtener información sobre la API, consulte ListJobs en la Referencia de la API de AWS SDK para Python (Boto3).

Ruby

SDK para Ruby

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
require 'aws-sdk-glue'
require 'logger'

# GlueManager is a class responsible for managing AWS Glue operations
# such as listing all Glue jobs in the current AWS account.
class GlueManager
  def initialize(client)
    @client = client
    @logger = Logger.new($stdout)
  end

  # Lists and prints all Glue jobs in the current AWS account.
  def list_jobs
    @logger.info('Here are the Glue jobs in your account:')

    paginator = @client.get_jobs(max_results: 10)
    jobs = []
```

```
    paginator.each_page do |page|
      jobs.concat(page.jobs)
    end

    if jobs.empty?
      @logger.info("You don't have any Glue jobs.")
    else
      jobs.each do |job|
        @logger.info("- #{job.name}")
      end
    end
  end
end

if $PROGRAM_NAME == __FILE__
  glue_client = Aws::Glue::Client.new
  manager = GlueManager.new(glue_client)
  manager.list_jobs
end
```

- Para obtener información sobre la API, consulte ListJobs en la Referencia de la API de AWS SDK para Ruby.

Rust

SDK para Rust

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
        let mut list_jobs = glue.list_jobs().into_paginator().send();
        while let Some(list_jobs_output) = list_jobs.next().await {
            match list_jobs_output {
                Ok(list_jobs) => {
                    let names = list_jobs.job_names();
                    info!(?names, "Found these jobs")
```

```
                }
                Err(err) => return Err(GlueMvpError::from_glue_sdk(err)),
            }
        }
```

- Para obtener información acerca de la API, consulte ListJobs en la Referencia de la API del SDK de AWS para Rust.

Para obtener una lista completa de las guías para desarrolladores de AWS SDK y ejemplos de código, consulte Cómo utilizar este servicio con un AWS SDK. En este tema también se incluye información sobre cómo comenzar a utilizar el SDK y detalles sobre sus versiones anteriores.

Aprenda los conceptos básicos de AWS Glue con un SDK de AWS

En el siguiente ejemplo de código, se muestra cómo:

- Cree un rastreador que rastree un bucket de Amazon S3 público y genere una base de datos de metadatos con formato CSV.
- Incluya información sobre las bases de datos y las tablas en su AWS Glue Data Catalog.
- Crear un trabajo para extraer datos CSV del bucket de S3, transformar los datos y cargar el resultado con formato JSON en otro bucket de S3.
- Incluya información sobre las ejecuciones de trabajos, vea algunos de los datos transformados y limpie los recursos.

Para obtener más información, consulte Tutorial: Introducción a AWS Glue Studio.

.NET

SDK para .NET

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

Cree una clase que incluya las funciones de AWS Glue que se utilizan en el escenario.

```
using System.Net;

namespace GlueActions;

public class GlueWrapper
{
    private readonly IAmazonGlue _amazonGlue;

    /// <summary>
    /// Constructor for the AWS Glue actions wrapper.
    /// </summary>
    /// <param name="amazonGlue"></param>
    public GlueWrapper(IAmazonGlue amazonGlue)
    {
        _amazonGlue = amazonGlue;
    }

    /// <summary>
    /// Create an AWS Glue crawler.
    /// </summary>
    /// <param name="crawlerName">The name for the crawler.</param>
    /// <param name="crawlerDescription">A description of the crawler.</param>
    /// <param name="role">The AWS Identity and Access Management (IAM) role to
    /// be assumed by the crawler.</param>
    /// <param name="schedule">The schedule on which the crawler will be
 executed.</param>
    /// <param name="s3Path">The path to the Amazon Simple Storage Service
 (Amazon S3)
    /// bucket where the Python script has been stored.</param>
    /// <param name="dbName">The name to use for the database that will be
    /// created by the crawler.</param>
    /// <returns>A Boolean value indicating the success of the action.</returns>
    public async Task<bool> CreateCrawlerAsync(
        string crawlerName,
        string crawlerDescription,
        string role,
        string schedule,
        string s3Path,
        string dbName)
    {
        var s3Target = new S3Target
        {
```

```
            Path = s3Path,
        };

        var targetList = new List<S3Target>
        {
            s3Target,
        };

        var targets = new CrawlerTargets
        {
            S3Targets = targetList,
        };

        var crawlerRequest = new CreateCrawlerRequest
        {
            DatabaseName = dbName,
            Name = crawlerName,
            Description = crawlerDescription,
            Targets = targets,
            Role = role,
            Schedule = schedule,
        };

        var response = await _amazonGlue.CreateCrawlerAsync(crawlerRequest);
        return response.HttpStatusCode == System.Net.HttpStatusCode.OK;
    }


    /// <summary>
    /// Create an AWS Glue job.
    /// </summary>
    /// <param name="jobName">The name of the job.</param>
    /// <param name="roleName">The name of the IAM role to be assumed by
    /// the job.</param>
    /// <param name="description">A description of the job.</param>
    /// <param name="scriptUrl">The URL to the script.</param>
    /// <returns>A Boolean value indicating the success of the action.</returns>
    public async Task<bool> CreateJobAsync(string dbName, string tableName,
string bucketUrl, string jobName, string roleName, string description, string
scriptUrl)
    {
        var command = new JobCommand
        {
            PythonVersion = "3",
```

```
            Name = "glueetl",
            ScriptLocation = scriptUrl,
        };

        var arguments = new Dictionary<string, string>
        {
            { "--input_database", dbName },
            { "--input_table", tableName },
            { "--output_bucket_url", bucketUrl }
        };

        var request = new CreateJobRequest
        {
            Command = command,
            DefaultArguments = arguments,
            Description = description,
            GlueVersion = "3.0",
            Name = jobName,
            NumberOfWorkers = 10,
            Role = roleName,
            WorkerType = "G.1X"
        };

        var response = await _amazonGlue.CreateJobAsync(request);
        return response.HttpStatusCode == HttpStatusCode.OK;
    }


    /// <summary>
    /// Delete an AWS Glue crawler.
    /// </summary>
    /// <param name="crawlerName">The name of the crawler.</param>
    /// <returns>A Boolean value indicating the success of the action.</returns>
    public async Task<bool> DeleteCrawlerAsync(string crawlerName)
    {
        var response = await _amazonGlue.DeleteCrawlerAsync(new
DeleteCrawlerRequest { Name = crawlerName });
        return response.HttpStatusCode == HttpStatusCode.OK;
    }


    /// <summary>
    /// Delete the AWS Glue database.
    /// </summary>
```

```
    /// <param name="dbName">The name of the database.</param>
    /// <returns>A Boolean value indicating the success of the action.</returns>
    public async Task<bool> DeleteDatabaseAsync(string dbName)
    {
        var response = await _amazonGlue.DeleteDatabaseAsync(new
DeleteDatabaseRequest { Name = dbName });
        return response.HttpStatusCode == HttpStatusCode.OK;
    }


    /// <summary>
    /// Delete an AWS Glue job.
    /// </summary>
    /// <param name="jobName">The name of the job.</param>
    /// <returns>A Boolean value indicating the success of the action.</returns>
    public async Task<bool> DeleteJobAsync(string jobName)
    {
        var response = await _amazonGlue.DeleteJobAsync(new DeleteJobRequest
{ JobName = jobName });
        return response.HttpStatusCode == HttpStatusCode.OK;
    }


    /// <summary>
    /// Delete a table from an AWS Glue database.
    /// </summary>
    /// <param name="tableName">The table to delete.</param>
    /// <returns>A Boolean value indicating the success of the action.</returns>
    public async Task<bool> DeleteTableAsync(string dbName, string tableName)
    {
        var response = await _amazonGlue.DeleteTableAsync(new DeleteTableRequest
{ Name = tableName, DatabaseName = dbName });
        return response.HttpStatusCode == HttpStatusCode.OK;
    }


    /// <summary>
    /// Get information about an AWS Glue crawler.
    /// </summary>
    /// <param name="crawlerName">The name of the crawler.</param>
    /// <returns>A Crawler object describing the crawler.</returns>
    public async Task<Crawler?> GetCrawlerAsync(string crawlerName)
    {
        var crawlerRequest = new GetCrawlerRequest
```

```
        {
            Name = crawlerName,
        };

        var response = await _amazonGlue.GetCrawlerAsync(crawlerRequest);
        if (response.HttpStatusCode == System.Net.HttpStatusCode.OK)
        {
            var databaseName = response.Crawler.DatabaseName;
            Console.WriteLine($"{crawlerName} has the database {databaseName}");
            return response.Crawler;
        }

        Console.WriteLine($"No information regarding {crawlerName} could be
 found.");
        return null;
    }


    /// <summary>
    /// Get information about the state of an AWS Glue crawler.
    /// </summary>
    /// <param name="crawlerName">The name of the crawler.</param>
    /// <returns>A value describing the state of the crawler.</returns>
    public async Task<CrawlerState> GetCrawlerStateAsync(string crawlerName)
    {
        var response = await _amazonGlue.GetCrawlerAsync(
            new GetCrawlerRequest { Name = crawlerName });
        return response.Crawler.State;
    }


    /// <summary>
    /// Get information about an AWS Glue database.
    /// </summary>
    /// <param name="dbName">The name of the database.</param>
    /// <returns>A Database object containing information about the database.</
returns>
    public async Task<Database> GetDatabaseAsync(string dbName)
    {
        var databasesRequest = new GetDatabaseRequest
        {
            Name = dbName,
        };
```

```
        var response = await _amazonGlue.GetDatabaseAsync(databasesRequest);
        return response.Database;
    }


    /// <summary>
    /// Get information about a specific AWS Glue job run.
    /// </summary>
    /// <param name="jobName">The name of the job.</param>
    /// <param name="jobRunId">The Id of the job run.</param>
    /// <returns>A JobRun object with information about the job run.</returns>
    public async Task<JobRun> GetJobRunAsync(string jobName, string jobRunId)
    {
        var response = await _amazonGlue.GetJobRunAsync(new GetJobRunRequest
{ JobName = jobName, RunId = jobRunId });
        return response.JobRun;
    }


    /// <summary>
    /// Get information about all AWS Glue runs of a specific job.
    /// </summary>
    /// <param name="jobName">The name of the job.</param>
    /// <returns>A list of JobRun objects.</returns>
    public async Task<List<JobRun>> GetJobRunsAsync(string jobName)
    {
        var jobRuns = new List<JobRun>();

        var request = new GetJobRunsRequest
        {
            JobName = jobName,
        };

        // No need to loop to get all the log groups--the SDK does it for us
behind the scenes
        var paginatorForJobRuns =
            _amazonGlue.Paginators.GetJobRuns(request);

        await foreach (var response in paginatorForJobRuns.Responses)
        {
            response.JobRuns.ForEach(jobRun =>
            {
                jobRuns.Add(jobRun);
            });
```

```
        }

        return jobRuns;
    }


    /// <summary>
    /// Get a list of tables for an AWS Glue database.
    /// </summary>
    /// <param name="dbName">The name of the database.</param>
    /// <returns>A list of Table objects.</returns>
    public async Task<List<Table>> GetTablesAsync(string dbName)
    {
        var request = new GetTablesRequest { DatabaseName = dbName };
        var tables = new List<Table>();

        // Get a paginator for listing the tables.
        var tablePaginator = _amazonGlue.Paginators.GetTables(request);

        await foreach (var response in tablePaginator.Responses)
        {
            tables.AddRange(response.TableList);
        }

        return tables;
    }


    /// <summary>
    /// List AWS Glue jobs using a paginator.
    /// </summary>
    /// <returns>A list of AWS Glue job names.</returns>
    public async Task<List<string>> ListJobsAsync()
    {
        var jobNames = new List<string>();

        var listJobsPaginator = _amazonGlue.Paginators.ListJobs(new
ListJobsRequest { MaxResults = 10 });
        await foreach (var response in listJobsPaginator.Responses)
        {
            jobNames.AddRange(response.JobNames);
        }

        return jobNames;
```

```
    }


    /// <summary>
    /// Start an AWS Glue crawler.
    /// </summary>
    /// <param name="crawlerName">The name of the crawler.</param>
    /// <returns>A Boolean value indicating the success of the action.</returns>
    public async Task<bool> StartCrawlerAsync(string crawlerName)
    {
        var crawlerRequest = new StartCrawlerRequest
        {
            Name = crawlerName,
        };

        var response = await _amazonGlue.StartCrawlerAsync(crawlerRequest);

        return response.HttpStatusCode == System.Net.HttpStatusCode.OK;
    }


    /// <summary>
    /// Start an AWS Glue job run.
    /// </summary>
    /// <param name="jobName">The name of the job.</param>
    /// <returns>A string representing the job run Id.</returns>
    public async Task<string> StartJobRunAsync(
        string jobName,
        string inputDatabase,
        string inputTable,
        string bucketName)
    {
        var request = new StartJobRunRequest
        {
            JobName = jobName,
            Arguments = new Dictionary<string, string>
            {
                {"--input_database", inputDatabase},
                {"--input_table", inputTable},
                {"--output_bucket_url", $"s3://{bucketName}/"}
            }
        };

        var response = await _amazonGlue.StartJobRunAsync(request);
```

```
        return response.JobRunId;
    }

}
```

Cree una clase que ejecute el escenario.

```
global using Amazon.Glue;
global using GlueActions;
global using Microsoft.Extensions.Configuration;
global using Microsoft.Extensions.DependencyInjection;
global using Microsoft.Extensions.Hosting;
global using Microsoft.Extensions.Logging;
global using Microsoft.Extensions.Logging.Console;
global using Microsoft.Extensions.Logging.Debug;



using Amazon.Glue.Model;
using Amazon.S3;
using Amazon.S3.Model;

namespace GlueBasics;

public class GlueBasics
{
    private static ILogger logger = null!;
    private static IConfiguration _configuration = null!;

    static async Task Main(string[] args)
    {
        // Set up dependency injection for AWS Glue.
        using var host = Host.CreateDefaultBuilder(args)
            .ConfigureLogging(logging =>
                logging.AddFilter("System", LogLevel.Debug)
                    .AddFilter<DebugLoggerProvider>("Microsoft",
 LogLevel.Information)
                    .AddFilter<ConsoleLoggerProvider>("Microsoft",
 LogLevel.Trace))
            .ConfigureServices((_, services) =>
            services.AddAWSService<IAmazonGlue>()
```

```
            .AddTransient<GlueWrapper>()
            .AddTransient<UiWrapper>()
            )
            .Build();

        logger = LoggerFactory.Create(builder => { builder.AddConsole(); })
        .CreateLogger<GlueBasics>();

        _configuration = new ConfigurationBuilder()
            .SetBasePath(Directory.GetCurrentDirectory())
            .AddJsonFile("settings.json") // Load settings from .json file.
            .AddJsonFile("settings.local.json",
                true) // Optionally load local settings.
            .Build();

        // These values are stored in settings.json
        // Once you have run the CDK script to deploy the resources,
        // edit the file to set "BucketName", "RoleName", and "ScriptURL"
        // to the appropriate values. Also set "CrawlerName" to the name
        // you want to give the crawler when it is created.
        string bucketName = _configuration["BucketName"]!;
        string bucketUrl = _configuration["BucketUrl"]!;
        string crawlerName = _configuration["CrawlerName"]!;
        string roleName = _configuration["RoleName"]!;
        string sourceData = _configuration["SourceData"]!;
        string dbName = _configuration["DbName"]!;
        string cron = _configuration["Cron"]!;
        string scriptUrl = _configuration["ScriptURL"]!;
        string jobName = _configuration["JobName"]!;

        var wrapper = host.Services.GetRequiredService<GlueWrapper>();
        var uiWrapper = host.Services.GetRequiredService<UiWrapper>();

        uiWrapper.DisplayOverview();
        uiWrapper.PressEnter();

        // Create the crawler and wait for it to be ready.
        uiWrapper.DisplayTitle("Create AWS Glue crawler");
        Console.WriteLine("Let's begin by creating the AWS Glue crawler.");

        var crawlerDescription = "Crawler created for the AWS Glue Basics
scenario.";
        var crawlerCreated = await wrapper.CreateCrawlerAsync(crawlerName,
crawlerDescription, roleName, cron, sourceData, dbName);
```

```
        if (crawlerCreated)
        {
            Console.WriteLine($"The crawler: {crawlerName} has been created. Now
let's wait until it's ready.");
            CrawlerState crawlerState;
            do
            {
                crawlerState = await wrapper.GetCrawlerStateAsync(crawlerName);
            }
            while (crawlerState != "READY");
            Console.WriteLine($"The crawler {crawlerName} is now ready for
use.");
        }
        else
        {
            Console.WriteLine($"Couldn't create crawler {crawlerName}.");
            return; // Exit the application.
        }

        uiWrapper.DisplayTitle("Start AWS Glue crawler");
        Console.WriteLine("Now let's wait until the crawler has successfully
started.");
        var crawlerStarted = await wrapper.StartCrawlerAsync(crawlerName);
        if (crawlerStarted)
        {
            CrawlerState crawlerState;
            do
            {
                crawlerState = await wrapper.GetCrawlerStateAsync(crawlerName);
            }
            while (crawlerState != "READY");
            Console.WriteLine($"The crawler {crawlerName} is now ready for
use.");
        }
        else
        {
            Console.WriteLine($"Couldn't start the crawler {crawlerName}.");
            return; // Exit the application.
        }

        uiWrapper.PressEnter();

        Console.WriteLine($"\nLet's take a look at the database: {dbName}");
        var database = await wrapper.GetDatabaseAsync(dbName);
```

```
        if (database != null)
        {
            uiWrapper.DisplayTitle($"{database.Name} Details");
            Console.WriteLine($"{database.Name} created on
{database.CreateTime}");
            Console.WriteLine(database.Description);
        }

        uiWrapper.PressEnter();

        var tables = await wrapper.GetTablesAsync(dbName);
        if (tables.Count > 0)
        {
            tables.ForEach(table =>
            {
                Console.WriteLine($"{table.Name}\tCreated:
{table.CreateTime}\tUpdated: {table.UpdateTime}");
            });
        }

        uiWrapper.PressEnter();

        uiWrapper.DisplayTitle("Create AWS Glue job");
        Console.WriteLine("Creating a new AWS Glue job.");
        var description = "An AWS Glue job created using the AWS SDK for .NET";
        await wrapper.CreateJobAsync(dbName, tables[0].Name, bucketUrl, jobName,
roleName, description, scriptUrl);

        uiWrapper.PressEnter();

        uiWrapper.DisplayTitle("Starting AWS Glue job");
        Console.WriteLine("Starting the new AWS Glue job...");
        var jobRunId = await wrapper.StartJobRunAsync(jobName, dbName,
tables[0].Name, bucketName);
        var jobRunComplete = false;
        var jobRun = new JobRun();
        do
        {
            jobRun = await wrapper.GetJobRunAsync(jobName, jobRunId);
            if (jobRun.JobRunState == "SUCCEEDED" || jobRun.JobRunState ==
"STOPPED" ||
                jobRun.JobRunState == "FAILED" || jobRun.JobRunState ==
"TIMEOUT")
```

```
            {
                jobRunComplete = true;
            }
        } while (!jobRunComplete);

        uiWrapper.DisplayTitle($"Data in {bucketName}");

        // Get the list of data stored in the S3 bucket.
        var s3Client = new AmazonS3Client();

        var response = await s3Client.ListObjectsAsync(new ListObjectsRequest
{ BucketName = bucketName });
        response.S3Objects.ForEach(s3Object =>
        {
            Console.WriteLine(s3Object.Key);
        });

        uiWrapper.DisplayTitle("AWS Glue jobs");
        var jobNames = await wrapper.ListJobsAsync();
        jobNames.ForEach(jobName =>
        {
            Console.WriteLine(jobName);
        });

        uiWrapper.PressEnter();

        uiWrapper.DisplayTitle("Get AWS Glue job run information");
        Console.WriteLine("Getting information about the AWS Glue job.");
        var jobRuns = await wrapper.GetJobRunsAsync(jobName);

        jobRuns.ForEach(jobRun =>
        {

Console.WriteLine($"{jobRun.JobName}\t{jobRun.JobRunState}\t{jobRun.CompletedOn}");
        });

        uiWrapper.PressEnter();

        uiWrapper.DisplayTitle("Deleting resources");
        Console.WriteLine("Deleting the AWS Glue job used by the example.");
        await wrapper.DeleteJobAsync(jobName);

        Console.WriteLine("Deleting the tables from the database.");
        tables.ForEach(async table =>
```

```
        {
            await wrapper.DeleteTableAsync(dbName, table.Name);
        });

        Console.WriteLine("Deleting the database.");
        await wrapper.DeleteDatabaseAsync(dbName);

        Console.WriteLine("Deleting the AWS Glue crawler.");
        await wrapper.DeleteCrawlerAsync(crawlerName);

        Console.WriteLine("The AWS Glue scenario has completed.");
        uiWrapper.PressEnter();
    }
}


namespace GlueBasics;

public class UiWrapper
{
    public readonly string SepBar = new string('-', Console.WindowWidth);

    /// <summary>
    /// Show information about the scenario.
    /// </summary>
    public void DisplayOverview()
    {
        Console.Clear();
        DisplayTitle("Amazon Glue: get started with crawlers and jobs");

        Console.WriteLine("This example application does the following:");
        Console.WriteLine("\t 1. Create a crawler, pass it the IAM role and the
 URL to the public S3 bucket that contains the source data");
        Console.WriteLine("\t 2. Start the crawler.");
        Console.WriteLine("\t 3. Get the database created by the crawler and the
 tables in the database.");
        Console.WriteLine("\t 4. Create a job.");
        Console.WriteLine("\t 5. Start a job run.");
        Console.WriteLine("\t 6. Wait for the job run to complete.");
        Console.WriteLine("\t 7. Show the data stored in the bucket.");
        Console.WriteLine("\t 8. List jobs for the account.");
        Console.WriteLine("\t 9. Get job run details for the job that was run.");
        Console.WriteLine("\t10. Delete the demo job.");
```

```
        Console.WriteLine("\t11. Delete the database and tables created for the
 demo.");
        Console.WriteLine("\t12. Delete the crawler.");
    }

    /// <summary>
    /// Display a message and wait until the user presses enter.
    /// </summary>
    public void PressEnter()
    {
        Console.Write("\nPlease press <Enter> to continue. ");
        _ = Console.ReadLine();
    }

    /// <summary>
    /// Pad a string with spaces to center it on the console display.
    /// </summary>
    /// <param name="strToCenter">The string to center on the screen.</param>
    /// <returns>The string padded to make it center on the screen.</returns>
    public string CenterString(string strToCenter)
    {
        var padAmount = (Console.WindowWidth - strToCenter.Length) / 2;
        var leftPad = new string(' ', padAmount);
        return $"{leftPad}{strToCenter}";
    }

    /// <summary>
    /// Display a line of hyphens, the centered text of the title and another
    /// line of hyphens.
    /// </summary>
    /// <param name="strTitle">The string to be displayed.</param>
    public void DisplayTitle(string strTitle)
    {
        Console.WriteLine(SepBar);
        Console.WriteLine(CenterString(strTitle));
        Console.WriteLine(SepBar);
    }
}
```

- Para obtener información sobre la API, consulte los siguientes temas en la referencia de la API de AWS SDK para .NET.

- CreateCrawler
- CreateJob
- DeleteCrawler
- DeleteDatabase
- DeleteJob
- DeleteTable
- GetCrawler
- GetDatabase
- GetDatabases
- GetJob
- GetJobRun
- GetJobRuns
- GetTables
- ListJobs
- StartCrawler
- StartJobRun

C++

SDK para C++

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
//! Scenario which demonstrates using AWS Glue to add a crawler and run a job.
/*!
 \\sa runGettingStartedWithGlueScenario()
 \param bucketName: An S3 bucket created in the setup.
 \param roleName: An AWS Identity and Access Management (IAM) role created in the
 setup.
 \param clientConfig: AWS client configuration.
 \return bool: Successful completion.
```

```
 */

bool AwsDoc::Glue::runGettingStartedWithGlueScenario(const Aws::String
 &bucketName,
                                                     const Aws::String &roleName,
                                                     const
 Aws::Client::ClientConfiguration &clientConfig) {
    Aws::Glue::GlueClient client(clientConfig);

    Aws::String roleArn;
    if (!getRoleArn(roleName, roleArn, clientConfig)) {
        std::cerr << "Error getting role ARN for role." << std::endl;
        return false;
    }

    // 1. Upload the job script to the S3 bucket.
    {
        std::cout << "Uploading the job script '"
                  << AwsDoc::Glue::PYTHON_SCRIPT
                  << "'." << std::endl;

        if (!AwsDoc::Glue::uploadFile(bucketName,
                                      AwsDoc::Glue::PYTHON_SCRIPT_PATH,
                                      AwsDoc::Glue::PYTHON_SCRIPT,
                                      clientConfig)) {
            std::cerr << "Error uploading the job file." << std::endl;
            return false;
        }
    }

    // 2. Create a crawler.
    {
        Aws::Glue::Model::S3Target s3Target;
        s3Target.SetPath("s3://crawler-public-us-east-1/flight/2016/csv");
        Aws::Glue::Model::CrawlerTargets crawlerTargets;
        crawlerTargets.AddS3Targets(s3Target);

        Aws::Glue::Model::CreateCrawlerRequest request;
        request.SetTargets(crawlerTargets);
        request.SetName(CRAWLER_NAME);
        request.SetDatabaseName(CRAWLER_DATABASE_NAME);
        request.SetTablePrefix(CRAWLER_DATABASE_PREFIX);
        request.SetRole(roleArn);
```

```
        Aws::Glue::Model::CreateCrawlerOutcome outcome =
client.CreateCrawler(request);

        if (outcome.IsSuccess()) {
            std::cout << "Successfully created the crawler." << std::endl;
        }
        else {
            std::cerr << "Error creating a crawler. " <<
outcome.GetError().GetMessage()
                      << std::endl;
            deleteAssets("", CRAWLER_DATABASE_NAME, "", bucketName,
clientConfig);
            return false;
        }
    }

    // 3. Get a crawler.
    {
        Aws::Glue::Model::GetCrawlerRequest request;
        request.SetName(CRAWLER_NAME);

        Aws::Glue::Model::GetCrawlerOutcome outcome = client.GetCrawler(request);

        if (outcome.IsSuccess()) {
            Aws::Glue::Model::CrawlerState crawlerState =
outcome.GetResult().GetCrawler().GetState();
            std::cout << "Retrieved crawler with state " <<

Aws::Glue::Model::CrawlerStateMapper::GetNameForCrawlerState(
                              crawlerState)
                      << "." << std::endl;
        }
        else {
            std::cerr << "Error retrieving a crawler.  "
                      << outcome.GetError().GetMessage() << std::endl;
            deleteAssets(CRAWLER_NAME, CRAWLER_DATABASE_NAME, "", bucketName,
                         clientConfig);
            return false;
        }
    }

    // 4. Start a crawler.
    {
        Aws::Glue::Model::StartCrawlerRequest request;
```

```
        request.SetName(CRAWLER_NAME);

        Aws::Glue::Model::StartCrawlerOutcome outcome =
client.StartCrawler(request);


        if (outcome.IsSuccess() || (Aws::Glue::GlueErrors::CRAWLER_RUNNING ==
                                    outcome.GetError().GetErrorType())) {
            if (!outcome.IsSuccess()) {
                std::cout << "Crawler was already started." << std::endl;
            }
            else {
                std::cout << "Successfully started crawler." << std::endl;
            }

            std::cout << "This may take a while to run." << std::endl;

            Aws::Glue::Model::CrawlerState crawlerState =
Aws::Glue::Model::CrawlerState::NOT_SET;
            int iterations = 0;
            while (Aws::Glue::Model::CrawlerState::READY != crawlerState) {
                std::this_thread::sleep_for(std::chrono::seconds(1));
                ++iterations;
                if ((iterations % 10) == 0) { // Log status every 10 seconds.
                    std::cout << "Crawler status " <<

Aws::Glue::Model::CrawlerStateMapper::GetNameForCrawlerState(
                                        crawlerState)
                              << ". After " << iterations
                              << " seconds elapsed."
                              << std::endl;
                }
                Aws::Glue::Model::GetCrawlerRequest getCrawlerRequest;
                getCrawlerRequest.SetName(CRAWLER_NAME);

                Aws::Glue::Model::GetCrawlerOutcome getCrawlerOutcome =
client.GetCrawler(
                        getCrawlerRequest);

                if (getCrawlerOutcome.IsSuccess()) {
                    crawlerState =
getCrawlerOutcome.GetResult().GetCrawler().GetState();
                }
                else {
```

```
                    std::cerr << "Error getting crawler.  "
                              << getCrawlerOutcome.GetError().GetMessage() <<
std::endl;
                    break;
                }
            }

            if (Aws::Glue::Model::CrawlerState::READY == crawlerState) {
                std::cout << "Crawler finished running after " << iterations
                          << " seconds."
                          << std::endl;
            }
        }
        else {
            std::cerr << "Error starting a crawler.  "
                      << outcome.GetError().GetMessage()
                      << std::endl;

            deleteAssets(CRAWLER_NAME, CRAWLER_DATABASE_NAME, "", bucketName,
                         clientConfig);
            return false;
        }
    }

    // 5. Get a database.
    {
        Aws::Glue::Model::GetDatabaseRequest request;
        request.SetName(CRAWLER_DATABASE_NAME);

        Aws::Glue::Model::GetDatabaseOutcome outcome =
client.GetDatabase(request);

        if (outcome.IsSuccess()) {
            const Aws::Glue::Model::Database &database =
outcome.GetResult().GetDatabase();

            std::cout << "Successfully retrieve the database\n" <<
                      database.Jsonize().View().WriteReadable() << "'." <<
std::endl;
        }
        else {
            std::cerr << "Error getting the database.  "
                      << outcome.GetError().GetMessage() << std::endl;
            deleteAssets(CRAWLER_NAME, CRAWLER_DATABASE_NAME, "", bucketName,
```

```
                        clientConfig);
            return false;
        }
    }

    // 6. Get tables.
    Aws::String tableName;
    {
        Aws::Glue::Model::GetTablesRequest request;
        request.SetDatabaseName(CRAWLER_DATABASE_NAME);
        std::vector<Aws::Glue::Model::Table> all_tables;
        Aws::String nextToken; // Used for pagination.
        do {
            Aws::Glue::Model::GetTablesOutcome outcome =
client.GetTables(request);

            if (outcome.IsSuccess()) {
                const std::vector<Aws::Glue::Model::Table> &tables =
outcome.GetResult().GetTableList();
                all_tables.insert(all_tables.end(), tables.begin(),
tables.end());
                nextToken = outcome.GetResult().GetNextToken();
            }
            else {
                std::cerr << "Error getting the tables. "
                          << outcome.GetError().GetMessage()
                          << std::endl;
                deleteAssets(CRAWLER_NAME, CRAWLER_DATABASE_NAME, "", bucketName,
                             clientConfig);
                return false;
            }
        } while (!nextToken.empty());

        std::cout << "The database contains " << all_tables.size()
                  << (all_tables.size() == 1 ?
                      " table." : "tables.") << std::endl;
        std::cout << "Here is a list of the tables in the database.";
        for (size_t index = 0; index < all_tables.size(); ++index) {
            std::cout << "    " << index + 1 << ":  " <<
all_tables[index].GetName()
                      << std::endl;
        }

        if (!all_tables.empty()) {
```

```
            int tableIndex = askQuestionForIntRange(
                    "Enter an index to display the database detail ",
                    1, static_cast<int>(all_tables.size()));
            std::cout << all_tables[tableIndex -
1].Jsonize().View().WriteReadable()
                      << std::endl;

            tableName = all_tables[tableIndex - 1].GetName();
        }
    }

    // 7. Create a job.
    {
        Aws::Glue::Model::CreateJobRequest request;
        request.SetName(JOB_NAME);
        request.SetRole(roleArn);
        request.SetGlueVersion(GLUE_VERSION);

        Aws::Glue::Model::JobCommand command;
        command.SetName(JOB_COMMAND_NAME);
        command.SetPythonVersion(JOB_PYTHON_VERSION);
        command.SetScriptLocation(
                Aws::String("s3://") + bucketName + "/" + PYTHON_SCRIPT);
        request.SetCommand(command);

        Aws::Glue::Model::CreateJobOutcome outcome = client.CreateJob(request);

        if (outcome.IsSuccess()) {
            std::cout << "Successfully created the job." << std::endl;
        }
        else {
            std::cerr << "Error creating the job. " <<
outcome.GetError().GetMessage()
                      << std::endl;
            deleteAssets(CRAWLER_NAME, CRAWLER_DATABASE_NAME, "", bucketName,
                         clientConfig);
            return false;
        }
    }

    // 8. Start a job run.
    {
        Aws::Glue::Model::StartJobRunRequest request;
        request.SetJobName(JOB_NAME);
```

```
       Aws::Map<Aws::String, Aws::String> arguments;
       arguments["--input_database"] = CRAWLER_DATABASE_NAME;
       arguments["--input_table"] = tableName;
       arguments["--output_bucket_url"] = Aws::String("s3://") + bucketName +
"/";
       request.SetArguments(arguments);

       Aws::Glue::Model::StartJobRunOutcome outcome =
client.StartJobRun(request);

       if (outcome.IsSuccess()) {
           std::cout << "Successfully started the job." << std::endl;

           Aws::String jobRunId = outcome.GetResult().GetJobRunId();

           int iterator = 0;
           bool done = false;
           while (!done) {
               ++iterator;
               std::this_thread::sleep_for(std::chrono::seconds(1));
               Aws::Glue::Model::GetJobRunRequest jobRunRequest;
               jobRunRequest.SetJobName(JOB_NAME);
               jobRunRequest.SetRunId(jobRunId);

               Aws::Glue::Model::GetJobRunOutcome jobRunOutcome =
client.GetJobRun(
                       jobRunRequest);

               if (jobRunOutcome.IsSuccess()) {
                   const Aws::Glue::Model::JobRun &jobRun =
jobRunOutcome.GetResult().GetJobRun();
                   Aws::Glue::Model::JobRunState jobRunState =
jobRun.GetJobRunState();

                   if ((jobRunState == Aws::Glue::Model::JobRunState::STOPPED)
||
                       (jobRunState == Aws::Glue::Model::JobRunState::FAILED) ||
                       (jobRunState == Aws::Glue::Model::JobRunState::TIMEOUT))
{
                       std::cerr << "Error running job. "
                                 << jobRun.GetErrorMessage()
                                 << std::endl;
```

```
                        deleteAssets(CRAWLER_NAME, CRAWLER_DATABASE_NAME,
JOB_NAME,
                                     bucketName,
                                     clientConfig);
                        return false;
                    }
                    else if (jobRunState ==
                             Aws::Glue::Model::JobRunState::SUCCEEDED) {
                        std::cout << "Job run succeeded after  " << iterator <<
                                  " seconds elapsed." << std::endl;
                        done = true;
                    }
                    else if ((iterator % 10) == 0) { // Log status every 10
seconds.
                        std::cout << "Job run status " <<

Aws::Glue::Model::JobRunStateMapper::GetNameForJobRunState(
                                          jobRunState) <<
                                  ". " << iterator <<
                                  " seconds elapsed." << std::endl;
                    }
                }
                else {
                    std::cerr << "Error retrieving job run state. "
                              << jobRunOutcome.GetError().GetMessage()
                              << std::endl;
                    deleteAssets(CRAWLER_NAME, CRAWLER_DATABASE_NAME, JOB_NAME,
                                 bucketName, clientConfig);
                    return false;
                }
            }
        }
        else {
            std::cerr << "Error starting a job. " <<
outcome.GetError().GetMessage()
                      << std::endl;
            deleteAssets(CRAWLER_NAME, CRAWLER_DATABASE_NAME, JOB_NAME,
bucketName,
                         clientConfig);
            return false;
        }
    }

    // 9. List the output data stored in the S3 bucket.
```

```
   {
        Aws::S3::S3Client s3Client;
        Aws::S3::Model::ListObjectsV2Request request;
        request.SetBucket(bucketName);
        request.SetPrefix(OUTPUT_FILE_PREFIX);

        Aws::String continuationToken; // Used for pagination.
        std::vector<Aws::S3::Model::Object> allObjects;
        do {
            if (!continuationToken.empty()) {
                request.SetContinuationToken(continuationToken);
            }
            Aws::S3::Model::ListObjectsV2Outcome outcome =
s3Client.ListObjectsV2(
                    request);

            if (outcome.IsSuccess()) {
                const std::vector<Aws::S3::Model::Object> &objects =
                        outcome.GetResult().GetContents();
                allObjects.insert(allObjects.end(), objects.begin(),
objects.end());
                continuationToken =
outcome.GetResult().GetNextContinuationToken();
            }
            else {
                std::cerr << "Error listing objects. "
                          << outcome.GetError().GetMessage()
                          << std::endl;
                break;
            }
        } while (!continuationToken.empty());

        std::cout << "Data from your job is in " << allObjects.size() <<
                  " files in the S3 bucket, " << bucketName << "." << std::endl;

        for (size_t i = 0; i < allObjects.size(); ++i) {
            std::cout << "    " << i + 1 << ". " << allObjects[i].GetKey()
                      << std::endl;
        }

        int objectIndex = askQuestionForIntRange(
                std::string(
                        "Enter the number of a block to download it and see the
first ") +
```

```
                std::to_string(LINES_OF_RUN_FILE_TO_DISPLAY) +
                " lines of JSON output in the block: ", 1,
                static_cast<int>(allObjects.size()));

        Aws::String objectKey = allObjects[objectIndex - 1].GetKey();

        std::stringstream stringStream;
        if (getObjectFromBucket(bucketName, objectKey, stringStream,
                                clientConfig)) {
            for (int i = 0; i < LINES_OF_RUN_FILE_TO_DISPLAY && stringStream; +
+i) {
                std::string line;
                std::getline(stringStream, line);
                std::cout << "    " << line << std::endl;
            }
        }
        else {
            deleteAssets(CRAWLER_NAME, CRAWLER_DATABASE_NAME, JOB_NAME,
 bucketName,
                         clientConfig);
            return false;
        }
    }

    // 10. List all the jobs.
    Aws::String jobName;
    {
        Aws::Glue::Model::ListJobsRequest listJobsRequest;

        Aws::String nextToken;
        std::vector<Aws::String> allJobNames;

        do {
            if (!nextToken.empty()) {
                listJobsRequest.SetNextToken(nextToken);
            }
            Aws::Glue::Model::ListJobsOutcome listRunsOutcome = client.ListJobs(
                    listJobsRequest);

            if (listRunsOutcome.IsSuccess()) {
                const std::vector<Aws::String> &jobNames =
 listRunsOutcome.GetResult().GetJobNames();
                allJobNames.insert(allJobNames.end(), jobNames.begin(),
 jobNames.end());
```

```
                nextToken = listRunsOutcome.GetResult().GetNextToken();
            }
            else {
                std::cerr << "Error listing jobs. "
                          << listRunsOutcome.GetError().GetMessage()
                          << std::endl;
            }
        } while (!nextToken.empty());
        std::cout << "Your account has " << allJobNames.size() << " jobs."
                  << std::endl;
        for (size_t i = 0; i < allJobNames.size(); ++i) {
            std::cout << "   " << i + 1 << ". " << allJobNames[i] << std::endl;
        }
        int jobIndex = askQuestionForIntRange(
                Aws::String("Enter a number between 1 and ") +
                std::to_string(allJobNames.size()) +
                " to see the list of runs for a job: ",
                1, static_cast<int>(allJobNames.size()));

        jobName = allJobNames[jobIndex - 1];
    }

    // 11. Get the job runs for a job.
    Aws::String jobRunID;
    if (!jobName.empty()) {
        Aws::Glue::Model::GetJobRunsRequest getJobRunsRequest;
        getJobRunsRequest.SetJobName(jobName);

        Aws::String nextToken; // Used for pagination.
        std::vector<Aws::Glue::Model::JobRun> allJobRuns;
        do {
            if (!nextToken.empty()) {
                getJobRunsRequest.SetNextToken(nextToken);
            }
            Aws::Glue::Model::GetJobRunsOutcome jobRunsOutcome =
client.GetJobRuns(
                    getJobRunsRequest);

            if (jobRunsOutcome.IsSuccess()) {
                const std::vector<Aws::Glue::Model::JobRun> &jobRuns =
jobRunsOutcome.GetResult().GetJobRuns();
                allJobRuns.insert(allJobRuns.end(), jobRuns.begin(),
jobRuns.end());
```

```
                nextToken = jobRunsOutcome.GetResult().GetNextToken();
            }
            else {
                std::cerr << "Error getting job runs. "
                          << jobRunsOutcome.GetError().GetMessage()
                          << std::endl;
                break;
            }
        } while (!nextToken.empty());

        std::cout << "There are " << allJobRuns.size() << " runs in the job '"
                  <<
                  jobName << "'." << std::endl;

        for (size_t i = 0; i < allJobRuns.size(); ++i) {
            std::cout << "   " << i + 1 << ". " << allJobRuns[i].GetJobName()
                      << std::endl;
        }

        int runIndex = askQuestionForIntRange(
                Aws::String("Enter a number between 1 and ") +
                std::to_string(allJobRuns.size()) +
                " to see details for a run: ",
                1, static_cast<int>(allJobRuns.size()));
        jobRunID = allJobRuns[runIndex - 1].GetId();
    }

    // 12. Get a single job run.
    if (!jobRunID.empty()) {
        Aws::Glue::Model::GetJobRunRequest jobRunRequest;
        jobRunRequest.SetJobName(jobName);
        jobRunRequest.SetRunId(jobRunID);

        Aws::Glue::Model::GetJobRunOutcome jobRunOutcome = client.GetJobRun(
                jobRunRequest);

        if (jobRunOutcome.IsSuccess()) {
            std::cout << "Displaying the job run JSON description." << std::endl;
            std::cout
                    <<
jobRunOutcome.GetResult().GetJobRun().Jsonize().View().WriteReadable()
                    << std::endl;
        }
        else {
```

```
            std::cerr << "Error get a job run. "
                      << jobRunOutcome.GetError().GetMessage()
                      << std::endl;
        }
    }

    return deleteAssets(CRAWLER_NAME, CRAWLER_DATABASE_NAME, JOB_NAME,
 bucketName,
                        clientConfig);
}

//! Cleanup routine to delete created assets.
/*!
 \\sa deleteAssets()
 \param crawler: Name of an AWS Glue crawler.
 \param database: The name of an AWS Glue database.
 \param job: The name of an AWS Glue job.
 \param bucketName: The name of an S3 bucket.
 \param clientConfig: AWS client configuration.
 \return bool: Successful completion.
 */
bool AwsDoc::Glue::deleteAssets(const Aws::String &crawler, const Aws::String
 &database,
                                const Aws::String &job, const Aws::String
 &bucketName,
                                const Aws::Client::ClientConfiguration
 &clientConfig) {
    const Aws::Glue::GlueClient client(clientConfig);
    bool result = true;

    // 13. Delete a job.
    if (!job.empty()) {
        Aws::Glue::Model::DeleteJobRequest request;
        request.SetJobName(job);

        Aws::Glue::Model::DeleteJobOutcome outcome = client.DeleteJob(request);


        if (outcome.IsSuccess()) {
            std::cout << "Successfully deleted the job." << std::endl;
        }
        else {
            std::cerr << "Error deleting the job. " <<
 outcome.GetError().GetMessage()
```

```
                    << std::endl;
            result = false;
        }
    }

    // 14. Delete a database.
    if (!database.empty()) {
        Aws::Glue::Model::DeleteDatabaseRequest request;
        request.SetName(database);

        Aws::Glue::Model::DeleteDatabaseOutcome outcome = client.DeleteDatabase(
                request);

        if (outcome.IsSuccess()) {
            std::cout << "Successfully deleted the database." << std::endl;
        }
        else {
            std::cerr << "Error deleting database. " <<
outcome.GetError().GetMessage()
                    << std::endl;
            result = false;
        }
    }

    // 15. Delete a crawler.
    if (!crawler.empty()) {
        Aws::Glue::Model::DeleteCrawlerRequest request;
        request.SetName(crawler);

        Aws::Glue::Model::DeleteCrawlerOutcome outcome =
client.DeleteCrawler(request);

        if (outcome.IsSuccess()) {
            std::cout << "Successfully deleted the crawler." << std::endl;
        }
        else {
            std::cerr << "Error deleting the crawler. "
                    << outcome.GetError().GetMessage() << std::endl;
            result = false;
        }
    }

    // 16. Delete the job script and run data from the S3 bucket.
    result &= AwsDoc::Glue::deleteAllObjectsInS3Bucket(bucketName,
```

```
                                                        clientConfig);
    return result;
}

//! Routine which uploads a file to an S3 bucket.
/*!
 \\sa uploadFile()
 \param bucketName: An S3 bucket created in the setup.
 \param filePath: The path of the file to upload.
 \param fileName The name for the uploaded file.
 \param clientConfig: AWS client configuration.
 \return bool: Successful completion.
 */
bool
AwsDoc::Glue::uploadFile(const Aws::String &bucketName,
                         const Aws::String &filePath,
                         const Aws::String &fileName,
                         const Aws::Client::ClientConfiguration &clientConfig) {
    Aws::S3::S3Client s3_client(clientConfig);

    Aws::S3::Model::PutObjectRequest request;
    request.SetBucket(bucketName);
    request.SetKey(fileName);

    std::shared_ptr<Aws::IOStream> inputData =
            Aws::MakeShared<Aws::FStream>("SampleAllocationTag",
                                          filePath.c_str(),
                                          std::ios_base::in |
 std::ios_base::binary);

    if (!*inputData) {
        std::cerr << "Error unable to read file " << filePath << std::endl;
        return false;
    }

    request.SetBody(inputData);

    Aws::S3::Model::PutObjectOutcome outcome =
            s3_client.PutObject(request);

    if (!outcome.IsSuccess()) {
        std::cerr << "Error: PutObject: " <<
                  outcome.GetError().GetMessage() << std::endl;
    }
```

```
    else {
        std::cout << "Added object '" << filePath << "' to bucket '"
                  << bucketName << "'." << std::endl;
    }

    return outcome.IsSuccess();
}

//! Routine which deletes all objects in an S3 bucket.
/*!
 \\sa deleteAllObjectsInS3Bucket()
 \param bucketName: The S3 bucket name.
 \param clientConfig: AWS client configuration.
 \return bool: Successful completion.
 */
bool AwsDoc::Glue::deleteAllObjectsInS3Bucket(const Aws::String &bucketName,
                                              const
 Aws::Client::ClientConfiguration &clientConfig) {
    Aws::S3::S3Client client(clientConfig);
    Aws::S3::Model::ListObjectsV2Request listObjectsRequest;
    listObjectsRequest.SetBucket(bucketName);

    Aws::String continuationToken; // Used for pagination.
    bool result = true;
    do {
        if (!continuationToken.empty()) {
            listObjectsRequest.SetContinuationToken(continuationToken);
        }

        Aws::S3::Model::ListObjectsV2Outcome listObjectsOutcome =
 client.ListObjectsV2(
                listObjectsRequest);

        if (listObjectsOutcome.IsSuccess()) {
            const std::vector<Aws::S3::Model::Object> &objects =
 listObjectsOutcome.GetResult().GetContents();
            if (!objects.empty()) {
                Aws::S3::Model::DeleteObjectsRequest deleteObjectsRequest;
                deleteObjectsRequest.SetBucket(bucketName);

                std::vector<Aws::S3::Model::ObjectIdentifier> objectIdentifiers;
                for (const Aws::S3::Model::Object &object: objects) {
                    objectIdentifiers.push_back(
                            Aws::S3::Model::ObjectIdentifier().WithKey(
```

```
                                    object.GetKey()));
                }
                Aws::S3::Model::Delete objectsDelete;
                objectsDelete.SetObjects(objectIdentifiers);
                objectsDelete.SetQuiet(true);
                deleteObjectsRequest.SetDelete(objectsDelete);

                Aws::S3::Model::DeleteObjectsOutcome deleteObjectsOutcome =
                        client.DeleteObjects(deleteObjectsRequest);

                if (!deleteObjectsOutcome.IsSuccess()) {
                    std::cerr << "Error deleting objects. " <<
                              deleteObjectsOutcome.GetError().GetMessage() <<
 std::endl;
                    result = false;
                    break;
                }
                else {
                    std::cout << "Successfully deleted the objects." <<
 std::endl;

                }
            }
            else {
                std::cout << "No objects to delete in '" << bucketName << "'."
                          << std::endl;
            }

            continuationToken =
 listObjectsOutcome.GetResult().GetNextContinuationToken();
        }
        else {
            std::cerr << "Error listing objects. "
                      << listObjectsOutcome.GetError().GetMessage() << std::endl;
            result = false;
            break;
        }
    } while (!continuationToken.empty());

    return result;
}

//! Routine which retrieves an object from an S3 bucket.
/*!
```

```
 \\sa getObjectFromBucket()
 \param bucketName: The S3 bucket name.
 \param objectKey: The object's name.
 \param objectStream: A stream to receive the retrieved data.
 \param clientConfig: AWS client configuration.
 \return bool: Successful completion.
 */
bool AwsDoc::Glue::getObjectFromBucket(const Aws::String &bucketName,
                                       const Aws::String &objectKey,
                                       std::ostream &objectStream,
                                       const Aws::Client::ClientConfiguration
 &clientConfig) {
    Aws::S3::S3Client client(clientConfig);
    Aws::S3::Model::GetObjectRequest request;
    request.SetBucket(bucketName);
    request.SetKey(objectKey);

    Aws::S3::Model::GetObjectOutcome outcome = client.GetObject(request);


    if (outcome.IsSuccess()) {
        std::cout << "Successfully retrieved '" << objectKey << "'." <<
 std::endl;
        auto &body = outcome.GetResult().GetBody();
        objectStream << body.rdbuf();
    }
    else {
        std::cerr << "Error retrieving object. " <<
 outcome.GetError().GetMessage()
                  << std::endl;
    }

    return outcome.IsSuccess();
}
```

- Para obtener información sobre la API, consulte los siguientes temas en la referencia de la API de AWS SDK para C++.
  - CreateCrawler
  - CreateJob
  - DeleteCrawler

- DeleteDatabase
- DeleteJob
- DeleteTable
- GetCrawler
- GetDatabase
- GetDatabases
- GetJob
- GetJobRun
- GetJobRuns
- GetTables
- ListJobs
- StartCrawler
- StartJobRun

Java

SDK para Java 2.x

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
/**
 * Before running this Java V2 code example, set up your development
 * environment, including your credentials.
 * <p>
 * For more information, see the following documentation topic:
 *
 * https://docs.aws.amazon.com/sdk-for-java/latest/developer-guide/get-
started.html
 *
 * To set up the resources, see this documentation topic:
 *
```

```
 * https://docs.aws.amazon.com/glue/latest/ug/tutorial-add-crawler.html
 *
 * This example performs the following tasks:
 *
 * 1. Create a database.
 * 2. Create a crawler.
 * 3. Get a crawler.
 * 4. Start a crawler.
 * 5. Get a database.
 * 6. Get tables.
 * 7. Create a job.
 * 8. Start a job run.
 * 9. List all jobs.
 * 10. Get job runs.
 * 11. Delete a job.
 * 12. Delete a database.
 * 13. Delete a crawler.
 */

public class GlueScenario {
    public static final String DASHES = new String(new char[80]).replace("\0",
 "-");

    public static void main(String[] args) throws InterruptedException {
        final String usage = """

            Usage:
                <iam> <s3Path> <cron> <dbName> <crawlerName> <jobName>
 <scriptLocation> <locationUri> <bucketNameSc>\s

            Where:
                iam - The ARN of the IAM role that has AWS Glue and S3
 permissions.\s
                s3Path - The Amazon Simple Storage Service (Amazon S3) target
 that contains data (for example, s3://<bucket name>/read).
                cron - A cron expression used to specify the schedule  (i.e.,
 cron(15 12 * * ? *).
                dbName - The database name.\s
                crawlerName - The name of the crawler.\s
                jobName - The name you assign to this job definition.
                scriptLocation - The Amazon S3 path to a script that runs a job.
                locationUri - The location of the database (you can find this
 file in resources folder).
                bucketNameSc - The Amazon S3 bucket name used when creating a job
```

```
                """;

        if (args.length != 9) {
            System.out.println(usage);
            return;
        }
        Scanner scanner = new Scanner(System.in);
        String iam = args[0];
        String s3Path = args[1];
        String cron = args[2];
        String dbName = args[3];
        String crawlerName = args[4];
        String jobName = args[5];
        String scriptLocation = args[6];
        String locationUri = args[7];
        String bucketNameSc = args[8];

        Region region = Region.US_EAST_1;
        GlueClient glueClient = GlueClient.builder()
            .region(region)
            .build();
        System.out.println(DASHES);
        System.out.println("Welcome to the AWS Glue scenario.");
        System.out.println("""
            AWS Glue is a fully managed extract, transform, and load (ETL)
service provided by Amazon
            Web Services (AWS). It is designed to simplify the process of
building, running, and maintaining
            ETL pipelines, which are essential for data integration and data
warehousing tasks.

            One of the key features of AWS Glue is its ability to automatically
discover and catalog data
            stored in various sources, such as Amazon S3, Amazon RDS, Amazon
Redshift, and other databases.
            This cataloging process creates a central metadata repository, known
as the AWS Glue Data Catalog,
            which provides a unified view of an organization's data assets. This
metadata can then be used to
            create ETL jobs, which can be scheduled and run on-demand or on a
regular basis.

            Lets get started.
```

```
            """);
        waitForInputToContinue(scanner);
        System.out.println(DASHES);

        System.out.println(DASHES);
        System.out.println("1. Create a database.");
        try {
            createDatabase(glueClient, dbName, locationUri);
        } catch (GlueException e) {
            if (e.awsErrorDetails().errorMessage().equals("Database already
exists.")) {
                System.out.println("Database " + dbName + " already exists.
Skipping creation.");
            } else {
                System.err.println(e.awsErrorDetails().errorMessage());
                return;
            }
        }

        waitForInputToContinue(scanner);
        System.out.println(DASHES);

        System.out.println(DASHES);
        System.out.println("2. Create a crawler.");
        try {
            createGlueCrawler(glueClient, iam, s3Path, cron, dbName,
crawlerName);
        } catch (GlueException e) {
            if (e.awsErrorDetails().errorMessage().contains("already exists")) {
                System.out.println("Crawler " + crawlerName + " already exists.
Skipping creation.");
            } else {
                System.err.println(e.awsErrorDetails().errorMessage());
                System.exit(1);
            }
        }
        waitForInputToContinue(scanner);
        System.out.println(DASHES);

        System.out.println(DASHES);
        System.out.println("3. Get a crawler.");
        try {
            getSpecificCrawler(glueClient, crawlerName);
        } catch (GlueException e) {
```

```
            System.err.println(e.awsErrorDetails().errorMessage());
            return;
        }
        waitForInputToContinue(scanner);
        System.out.println(DASHES);

        System.out.println(DASHES);
        System.out.println("4. Start a crawler.");
        try {
            startSpecificCrawler(glueClient, crawlerName);
        } catch (GlueException e) {
            System.err.println(e.awsErrorDetails().errorMessage());
            return;
        }
        waitForInputToContinue(scanner);
        System.out.println(DASHES);

        System.out.println(DASHES);
        System.out.println("5. Get a database.");
        try {
            getSpecificDatabase(glueClient, dbName);
        } catch (GlueException e) {
            System.err.println(e.awsErrorDetails().errorMessage());
            return;
        }
        waitForInputToContinue(scanner);
        System.out.println(DASHES);

        System.out.println(DASHES);
        System.out.println("*** Wait 5 min for the tables to become available");
        TimeUnit.MINUTES.sleep(5);
        System.out.println("6. Get tables.");
        String myTableName;
        try {
            myTableName = getGlueTables(glueClient, dbName);
        } catch (GlueException e) {
            System.err.println(e.awsErrorDetails().errorMessage());
            return;
        }
        waitForInputToContinue(scanner);
        System.out.println(DASHES);

        System.out.println(DASHES);
        System.out.println("7. Create a job.");
```

```
        try {
            createJob(glueClient, jobName, iam, scriptLocation);
        } catch (GlueException e) {
            System.err.println(e.awsErrorDetails().errorMessage());
            return;
        }
        waitForInputToContinue(scanner);
        System.out.println(DASHES);

        System.out.println(DASHES);
        System.out.println("8. Start a Job run.");
        try {
            startJob(glueClient, jobName, dbName, myTableName, bucketNameSc);
        } catch (GlueException e) {
            System.err.println(e.awsErrorDetails().errorMessage());
            return;
        }
        waitForInputToContinue(scanner);
        System.out.println(DASHES);

        System.out.println(DASHES);
        System.out.println("9. List all jobs.");
        try {
            getAllJobs(glueClient);
        } catch (GlueException e) {
            System.err.println(e.awsErrorDetails().errorMessage());
            return;
        }
        waitForInputToContinue(scanner);
        System.out.println(DASHES);

        System.out.println(DASHES);
        System.out.println("10. Get job runs.");
        try {
            getJobRuns(glueClient, jobName);
        } catch (GlueException e) {
            System.err.println(e.awsErrorDetails().errorMessage());
            return;
        }
        waitForInputToContinue(scanner);
        System.out.println(DASHES);

        System.out.println(DASHES);
        System.out.println("11. Delete a job.");
```

```
        try {
            deleteJob(glueClient, jobName);
        } catch (GlueException e) {
            System.err.println(e.awsErrorDetails().errorMessage());
            return;
        }
        System.out.println("*** Wait 5 MIN for the " + crawlerName + " to stop");
        TimeUnit.MINUTES.sleep(5);
        waitForInputToContinue(scanner);
        System.out.println(DASHES);

        System.out.println(DASHES);
        System.out.println("12. Delete a database.");
        try {
            deleteDatabase(glueClient, dbName);
        } catch (GlueException e) {
            System.err.println(e.awsErrorDetails().errorMessage());
            return;
        }
        waitForInputToContinue(scanner);
        System.out.println(DASHES);

        System.out.println(DASHES);
        System.out.println("Delete a crawler.");
        try {
            deleteSpecificCrawler(glueClient, crawlerName);
        } catch (GlueException e) {
            System.err.println(e.awsErrorDetails().errorMessage());
            return;
        }
        waitForInputToContinue(scanner);
        System.out.println(DASHES);

        System.out.println(DASHES);
        System.out.println("Successfully completed the AWS Glue Scenario");
        System.out.println(DASHES);
    }


    /**
     * Creates a Glue database with the specified name and location URI.
     *
     * @param glueClient  The Glue client to use for the database creation.
     * @param dbName      The name of the database to create.
```

```
     * @param locationUri The location URI for the database.
     */
    public static void createDatabase(GlueClient glueClient, String dbName,
String locationUri) {
        try {
            DatabaseInput input = DatabaseInput.builder()
                .description("Built with the AWS SDK for Java V2")
                .name(dbName)
                .locationUri(locationUri)
                .build();

            CreateDatabaseRequest request = CreateDatabaseRequest.builder()
                .databaseInput(input)
                .build();

            glueClient.createDatabase(request);
            System.out.println(dbName + " was successfully created");

        } catch (GlueException e) {
            throw e;
        }
    }


    /**
     * Creates a new AWS Glue crawler using the AWS Glue Java API.
     *
     * @param glueClient  the AWS Glue client used to interact with the AWS Glue
service
     * @param iam         the IAM role that the crawler will use to access the
data source
     * @param s3Path      the S3 path that the crawler will scan for data
     * @param cron        the cron expression that defines the crawler's schedule
     * @param dbName      the name of the AWS Glue database where the crawler
will store the metadata
     * @param crawlerName the name of the crawler to be created
     */
    public static void createGlueCrawler(GlueClient glueClient,
                                         String iam,
                                         String s3Path,
                                         String cron,
                                         String dbName,
                                         String crawlerName) {
```

```
        try {
            S3Target s3Target = S3Target.builder()
                .path(s3Path)
                .build();

            List<S3Target> targetList = new ArrayList<>();
            targetList.add(s3Target);
            CrawlerTargets targets = CrawlerTargets.builder()
                .s3Targets(targetList)
                .build();

            CreateCrawlerRequest crawlerRequest = CreateCrawlerRequest.builder()
                .databaseName(dbName)
                .name(crawlerName)
                .description("Created by the AWS Glue Java API")
                .targets(targets)
                .role(iam)
                .schedule(cron)
                .build();

            glueClient.createCrawler(crawlerRequest);
            System.out.println(crawlerName + " was successfully created");

        } catch (GlueException e) {
            throw e;
        }
    }

    /**
     * Retrieves a specific crawler from the AWS Glue service and waits for it to
be in the "READY" state.
     *
     * @param glueClient  the AWS Glue client used to interact with the Glue
service
     * @param crawlerName the name of the crawler to be retrieved
     */
    public static void getSpecificCrawler(GlueClient glueClient, String
crawlerName) throws InterruptedException {
        try {
            GetCrawlerRequest crawlerRequest = GetCrawlerRequest.builder()
                .name(crawlerName)
                .build();

            boolean ready = false;
```

```
            while (!ready) {
                GetCrawlerResponse response =
glueClient.getCrawler(crawlerRequest);
                String status = response.crawler().stateAsString();
                if (status.compareTo("READY") == 0) {
                    ready = true;
                }
                Thread.sleep(3000);
            }

            System.out.println("The crawler is now ready");

        } catch (GlueException | InterruptedException e) {
            throw e;
        }
    }

    /**
     * Starts a specific AWS Glue crawler.
     *
     * @param glueClient  the AWS Glue client to use for the crawler operation
     * @param crawlerName the name of the crawler to start
     * @throws GlueException if there is an error starting the crawler
     */
    public static void startSpecificCrawler(GlueClient glueClient, String
crawlerName) {
        try {
            StartCrawlerRequest crawlerRequest = StartCrawlerRequest.builder()
                .name(crawlerName)
                .build();

            glueClient.startCrawler(crawlerRequest);
            System.out.println(crawlerName + " was successfully started!");

        } catch (GlueException e) {
            throw e;
        }
    }

    /**
     * Retrieves the specific database from the AWS Glue service.
     *
     * @param glueClient   an instance of the AWS Glue client used to interact
with the service
```

```
    * @param databaseName the name of the database to retrieve
    * @throws GlueException if there is an error retrieving the database from
the AWS Glue service
    */
   public static void getSpecificDatabase(GlueClient glueClient, String
databaseName) {
       try {
           GetDatabaseRequest databasesRequest = GetDatabaseRequest.builder()
               .name(databaseName)
               .build();

           GetDatabaseResponse response =
glueClient.getDatabase(databasesRequest);
           Instant createDate = response.database().createTime();

           // Convert the Instant to readable date.
           DateTimeFormatter formatter =
DateTimeFormatter.ofLocalizedDateTime(FormatStyle.SHORT)
               .withLocale(Locale.US)
               .withZone(ZoneId.systemDefault());

           formatter.format(createDate);
           System.out.println("The create date of the database is " +
createDate);

       } catch (GlueException e) {
           throw e;
       }
   }


   /**
    * Retrieves the names of the tables in the specified Glue database.
    *
    * @param glueClient the Glue client to use for the operation
    * @param dbName     the name of the Glue database to retrieve the table
names from
    * @return the name of the first table retrieved, or an empty string if no
tables were found
    */
   public static String getGlueTables(GlueClient glueClient, String dbName) {
       String myTableName = "";
       try {
           GetTablesRequest tableRequest = GetTablesRequest.builder()
```

```
                .databaseName(dbName)
                .build();

            GetTablesResponse response = glueClient.getTables(tableRequest);
            List<Table> tables = response.tableList();
            if (tables.isEmpty()) {
                System.out.println("No tables were returned");
            } else {
                for (Table table : tables) {
                    myTableName = table.name();
                    System.out.println("Table name is: " + myTableName);
                }
            }

        } catch (GlueException e) {
            throw e;
        }
        return myTableName;
    }


    /**
     * Starts a job run in AWS Glue.
     *
     * @param glueClient    the AWS Glue client to use for the job run
     * @param jobName       the name of the Glue job to run
     * @param inputDatabase the name of the input database
     * @param inputTable    the name of the input table
     * @param outBucket     the URL of the output S3 bucket
     * @throws GlueException if there is an error starting the job run
     */
    public static void startJob(GlueClient glueClient, String jobName, String
inputDatabase, String inputTable,
                                String outBucket) {
        try {
            Map<String, String> myMap = new HashMap<>();
            myMap.put("--input_database", inputDatabase);
            myMap.put("--input_table", inputTable);
            myMap.put("--output_bucket_url", outBucket);

            StartJobRunRequest runRequest = StartJobRunRequest.builder()
                .workerType(WorkerType.G_1_X)
                .numberOfWorkers(10)
                .arguments(myMap)
```

```
                .jobName(jobName)
                .build();

            StartJobRunResponse response = glueClient.startJobRun(runRequest);
            System.out.println("The request Id of the job is " +
response.responseMetadata().requestId());

        } catch (GlueException e) {
            throw e;
        }
    }


    /**
     * Creates a new AWS Glue job.
     *
     * @param glueClient     the AWS Glue client to use for the operation
     * @param jobName        the name of the job to create
     * @param iam            the IAM role to associate with the job
     * @param scriptLocation the location of the script to be used by the job
     * @throws GlueException if there is an error creating the job
     */
    public static void createJob(GlueClient glueClient, String jobName, String
iam, String scriptLocation) {
        try {
            JobCommand command = JobCommand.builder()
                .pythonVersion("3")
                .name("glueetl")
                .scriptLocation(scriptLocation)
                .build();

            CreateJobRequest jobRequest = CreateJobRequest.builder()
                .description("A Job created by using the AWS SDK for Java V2")
                .glueVersion("2.0")
                .workerType(WorkerType.G_1_X)
                .numberOfWorkers(10)
                .name(jobName)
                .role(iam)
                .command(command)
                .build();

            glueClient.createJob(jobRequest);
            System.out.println(jobName + " was successfully created.");
```

```
        } catch (GlueException e) {
            throw e;
        }
    }


    /**
     * Retrieves and prints information about all the jobs in the Glue data
catalog.
     *
     * @param glueClient the Glue client used to interact with the AWS Glue
service
     */
    public static void getAllJobs(GlueClient glueClient) {
        try {
            GetJobsRequest jobsRequest = GetJobsRequest.builder()
                .maxResults(10)
                .build();

            GetJobsResponse jobsResponse = glueClient.getJobs(jobsRequest);
            List<Job> jobs = jobsResponse.jobs();
            for (Job job : jobs) {
                System.out.println("Job name is : " + job.name());
                System.out.println("The job worker type is : " +
job.workerType().name());
            }

        } catch (GlueException e) {
            throw e;
        }
    }

    /**
     * Retrieves the job runs for a given Glue job and prints the status of the
job runs.
     *
     * @param glueClient the Glue client used to make API calls
     * @param jobName    the name of the Glue job to retrieve the job runs for
     */
    public static void getJobRuns(GlueClient glueClient, String jobName) {
        try {
            GetJobRunsRequest runsRequest = GetJobRunsRequest.builder()
                .jobName(jobName)
                .maxResults(20)
```

```
                .build();

            boolean jobDone = false;
            while (!jobDone) {
                GetJobRunsResponse response = glueClient.getJobRuns(runsRequest);
                List<JobRun> jobRuns = response.jobRuns();
                for (JobRun jobRun : jobRuns) {
                    String jobState = jobRun.jobRunState().name();
                    if (jobState.compareTo("SUCCEEDED") == 0) {
                        System.out.println(jobName + " has succeeded");
                        jobDone = true;

                    } else if (jobState.compareTo("STOPPED") == 0) {
                        System.out.println("Job run has stopped");
                        jobDone = true;

                    } else if (jobState.compareTo("FAILED") == 0) {
                        System.out.println("Job run has failed");
                        jobDone = true;

                    } else if (jobState.compareTo("TIMEOUT") == 0) {
                        System.out.println("Job run has timed out");
                        jobDone = true;

                    } else {
                        System.out.println("*** Job run state is " +
jobRun.jobRunState().name());
                        System.out.println("Job run Id is " + jobRun.id());
                        System.out.println("The Glue version is " +
jobRun.glueVersion());
                    }
                    TimeUnit.SECONDS.sleep(5);
                }
            }

        } catch (GlueException e) {
            throw e;
        } catch (InterruptedException e) {
            throw new RuntimeException(e);
        }
    }


    /**
```

```
     * Deletes a Glue job.
     *
     * @param glueClient the Glue client to use for the operation
     * @param jobName    the name of the job to be deleted
     * @throws GlueException if there is an error deleting the job
     */
    public static void deleteJob(GlueClient glueClient, String jobName) {
        try {
            DeleteJobRequest jobRequest = DeleteJobRequest.builder()
                .jobName(jobName)
                .build();

            glueClient.deleteJob(jobRequest);
            System.out.println(jobName + " was successfully deleted");

        } catch (GlueException e) {
            throw e;
        }
    }

    /**
     * Deletes a AWS Glue Database.
     *
     * @param glueClient   An instance of the AWS Glue client used to interact
with the AWS Glue service.
     * @param databaseName The name of the database to be deleted.
     * @throws GlueException If an error occurs while deleting the database.
     */
    public static void deleteDatabase(GlueClient glueClient, String databaseName)
{
        try {
            DeleteDatabaseRequest request = DeleteDatabaseRequest.builder()
                .name(databaseName)
                .build();

            glueClient.deleteDatabase(request);
            System.out.println(databaseName + " was successfully deleted");

        } catch (GlueException e) {
            throw e;
        }
    }
```

```
    /**
     * Deletes a specific AWS Glue crawler.
     *
     * @param glueClient  the AWS Glue client object
     * @param crawlerName the name of the crawler to be deleted
     * @throws GlueException if an error occurs during the deletion process
     */
    public static void deleteSpecificCrawler(GlueClient glueClient, String
 crawlerName) {
        try {
            DeleteCrawlerRequest deleteCrawlerRequest =
 DeleteCrawlerRequest.builder()
                .name(crawlerName)
                .build();

            glueClient.deleteCrawler(deleteCrawlerRequest);
            System.out.println(crawlerName + " was deleted");

        } catch (GlueException e) {
            throw e;
        }
    }

    private static void waitForInputToContinue(Scanner scanner) {
        while (true) {
            System.out.println("");
            System.out.println("Enter 'c' followed by <ENTER> to continue:");
            String input = scanner.nextLine();

            if (input.trim().equalsIgnoreCase("c")) {
                System.out.println("Continuing with the program...");
                System.out.println("");
                break;
            } else {
                // Handle invalid input.
                System.out.println("Invalid input. Please try again.");
            }
        }
    }
}
```

- Para obtener información sobre la API, consulte los siguientes temas en la referencia de la API de AWS SDK for Java 2.x.
  - CreateCrawler
  - CreateJob
  - DeleteCrawler
  - DeleteDatabase
  - DeleteJob
  - DeleteTable
  - GetCrawler
  - GetDatabase
  - GetDatabases
  - GetJob
  - GetJobRun
  - GetJobRuns
  - GetTables
  - ListJobs
  - StartCrawler
  - StartJobRun

JavaScript

SDK para JavaScript (v3)

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

Cree y ejecute un rastreador que rastree un bucket público de Amazon Simple Storage Service (Amazon S3) y genere una base de metadatos que describa los datos con formato CSV que encuentra.

```
const createCrawler = (name, role, dbName, tablePrefix, s3TargetPath) => {
```

```
  const client = new GlueClient({});

  const command = new CreateCrawlerCommand({
    Name: name,
    Role: role,
    DatabaseName: dbName,
    TablePrefix: tablePrefix,
    Targets: {
      S3Targets: [{ Path: s3TargetPath }],
    },
  });

  return client.send(command);
};

const getCrawler = (name) => {
  const client = new GlueClient({});

  const command = new GetCrawlerCommand({
    Name: name,
  });

  return client.send(command);
};

const startCrawler = (name) => {
  const client = new GlueClient({});

  const command = new StartCrawlerCommand({
    Name: name,
  });

  return client.send(command);
};

const crawlerExists = async ({ getCrawler }, crawlerName) => {
  try {
    await getCrawler(crawlerName);
    return true;
  } catch {
    return false;
  }
};
```

```
/**
 * @param {{ createCrawler: import('../../../actions/create-
crawler.js').createCrawler}} actions
 */
const makeCreateCrawlerStep = (actions) => async (context) => {
  if (await crawlerExists(actions, process.env.CRAWLER_NAME)) {
    log("Crawler already exists. Skipping creation.");
  } else {
    await actions.createCrawler(
      process.env.CRAWLER_NAME,
      process.env.ROLE_NAME,
      process.env.DATABASE_NAME,
      process.env.TABLE_PREFIX,
      process.env.S3_TARGET_PATH,
    );

    log("Crawler created successfully.", { type: "success" });
  }

  return { ...context };
};

/**
 * @param {(name: string) => Promise<import('@aws-sdk/client-
glue').GetCrawlerCommandOutput>} getCrawler
 * @param {string} crawlerName
 */
const waitForCrawler = async (getCrawler, crawlerName) => {
  const waitTimeInSeconds = 30;
  const { Crawler } = await getCrawler(crawlerName);

  if (!Crawler) {
    throw new Error(`Crawler with name ${crawlerName} not found.`);
  }

  if (Crawler.State === "READY") {
    return;
  }

  log(`Crawler is ${Crawler.State}. Waiting ${waitTimeInSeconds} seconds...`);
  await wait(waitTimeInSeconds);
  return waitForCrawler(getCrawler, crawlerName);
};
```

```
const makeStartCrawlerStep =
  ({ startCrawler, getCrawler }) =>
  async (context) => {
    log("Starting crawler.");
    await startCrawler(process.env.CRAWLER_NAME);
    log("Crawler started.", { type: "success" });

    log("Waiting for crawler to finish running. This can take a while.");
    await waitForCrawler(getCrawler, process.env.CRAWLER_NAME);
    log("Crawler ready.", { type: "success" });

    return { ...context };
  };
```

Incluya información sobre las bases de datos y las tablas en su AWS Glue Data Catalog.

```
const getDatabase = (name) => {
  const client = new GlueClient({});

  const command = new GetDatabaseCommand({
    Name: name,
  });

  return client.send(command);
};

const getTables = (databaseName) => {
  const client = new GlueClient({});

  const command = new GetTablesCommand({
    DatabaseName: databaseName,
  });

  return client.send(command);
};

const makeGetDatabaseStep =
  ({ getDatabase }) =>
  async (context) => {
    const {
      Database: { Name },
    } = await getDatabase(process.env.DATABASE_NAME);
```

```
    log(`Database: ${Name}`);
    return { ...context };
  };

/**
 * @param {{ getTables: () => Promise<import('@aws-sdk/client-
glue').GetTablesCommandOutput}} config
 */
const makeGetTablesStep =
  ({ getTables }) =>
  async (context) => {
    const { TableList } = await getTables(process.env.DATABASE_NAME);
    log("Tables:");
    log(TableList.map((table) => `  • ${table.Name}\n`));
    return { ...context };
  };
```

Cree y ejecute un trabajo que extraiga datos CSV del bucket de Amazon S3 de origen, los transforme quitando campos y cambiándoles el nombre, y cargue el resultado con formato JSON en otro bucket de Amazon S3.

```
const createJob = (name, role, scriptBucketName, scriptKey) => {
  const client = new GlueClient({});

  const command = new CreateJobCommand({
    Name: name,
    Role: role,
    Command: {
      Name: "glueetl",
      PythonVersion: "3",
      ScriptLocation: `s3://${scriptBucketName}/${scriptKey}`,
    },
    GlueVersion: "3.0",
  });

  return client.send(command);
};

const startJobRun = (jobName, dbName, tableName, bucketName) => {
  const client = new GlueClient({});

  const command = new StartJobRunCommand({
```

```
    JobName: jobName,
    Arguments: {
      "--input_database": dbName,
      "--input_table": tableName,
      "--output_bucket_url": `s3://${bucketName}/`,
    },
  });

  return client.send(command);
};

const makeCreateJobStep =
  ({ createJob }) =>
  async (context) => {
    log("Creating Job.");
    await createJob(
      process.env.JOB_NAME,
      process.env.ROLE_NAME,
      process.env.BUCKET_NAME,
      process.env.PYTHON_SCRIPT_KEY,
    );
    log("Job created.", { type: "success" });

    return { ...context };
  };

/**
 * @param {(name: string, runId: string) => Promise<import('@aws-sdk/client-
glue').GetJobRunCommandOutput> }  getJobRun
 * @param {string} jobName
 * @param {string} jobRunId
 */
const waitForJobRun = async (getJobRun, jobName, jobRunId) => {
  const waitTimeInSeconds = 30;
  const { JobRun } = await getJobRun(jobName, jobRunId);

  if (!JobRun) {
    throw new Error(`Job run with id ${jobRunId} not found.`);
  }

  switch (JobRun.JobRunState) {
    case "FAILED":
    case "TIMEOUT":
    case "STOPPED":
```

```
    case "ERROR":
      throw new Error(
        `Job ${JobRun.JobRunState}. Error: ${JobRun.ErrorMessage}`,
      );
    case "SUCCEEDED":
      return;
    default:
      break;
  }

  log(
    `Job ${JobRun.JobRunState}. Waiting ${waitTimeInSeconds} more seconds...`,
  );
  await wait(waitTimeInSeconds);
  return waitForJobRun(getJobRun, jobName, jobRunId);
};

/**
 * @param {{ prompter: { prompt: () => Promise<{ shouldOpen: boolean }>} }}
 context
 */
const promptToOpen = async (context) => {
  const { shouldOpen } = await context.prompter.prompt({
    name: "shouldOpen",
    type: "confirm",
    message: "Open the output bucket in your browser?",
  });

  if (shouldOpen) {
    return open(
      `https://s3.console.aws.amazon.com/s3/buckets/${process.env.BUCKET_NAME} to
 view the output.`,
    );
  }
};

const makeStartJobRunStep =
  ({ startJobRun, getJobRun }) =>
  async (context) => {
    log("Starting job.");
    const { JobRunId } = await startJobRun(
      process.env.JOB_NAME,
      process.env.DATABASE_NAME,
      process.env.TABLE_NAME,
```

```
      process.env.BUCKET_NAME,
    );
    log("Job started.", { type: "success" });

    log("Waiting for job to finish running. This can take a while.");
    await waitForJobRun(getJobRun, process.env.JOB_NAME, JobRunId);
    log("Job run succeeded.", { type: "success" });

    await promptToOpen(context);

    return { ...context };
  };
```

Incluya información sobre las ejecuciones de trabajos y vea algunos de los datos transformados.

```
const getJobRuns = (jobName) => {
  const client = new GlueClient({});
  const command = new GetJobRunsCommand({
    JobName: jobName,
  });

  return client.send(command);
};

const getJobRun = (jobName, jobRunId) => {
  const client = new GlueClient({});
  const command = new GetJobRunCommand({
    JobName: jobName,
    RunId: jobRunId,
  });

  return client.send(command);
};

/**
 * @typedef {{ prompter: { prompt: () => Promise<{jobName: string}> } }} Context
 */

/**
 * @typedef {() => Promise<import('@aws-sdk/client-
glue').GetJobRunCommandOutput>} getJobRun
```

```
 */

/**
 * @typedef {() => Promise<import('@aws-sdk/client-
glue').GetJobRunsCommandOutput} getJobRuns
 */

/**
 *
 * @param {getJobRun} getJobRun
 * @param {string} jobName
 * @param {string} jobRunId
 */
const logJobRunDetails = async (getJobRun, jobName, jobRunId) => {
  const { JobRun } = await getJobRun(jobName, jobRunId);
  log(JobRun, { type: "object" });
};

/**
 *
 * @param {{getJobRuns: getJobRuns, getJobRun: getJobRun }} funcs
 */
const makePickJobRunStep =
  ({ getJobRuns, getJobRun }) =>
  async (/** @type { Context } */ context) => {
    if (context.selectedJobName) {
      const { JobRuns } = await getJobRuns(context.selectedJobName);

      const { jobRunId } = await context.prompter.prompt({
        name: "jobRunId",
        type: "list",
        message: "Select a job run to see details.",
        choices: JobRuns.map((run) => run.Id),
      });

      logJobRunDetails(getJobRun, context.selectedJobName, jobRunId);
    }

    return { ...context };
  };
```

Elimine todos los recursos creados en la demostración.

```
const deleteJob = (jobName) => {
  const client = new GlueClient({});

  const command = new DeleteJobCommand({
    JobName: jobName,
  });

  return client.send(command);
};

const deleteTable = (databaseName, tableName) => {
  const client = new GlueClient({});

  const command = new DeleteTableCommand({
    DatabaseName: databaseName,
    Name: tableName,
  });

  return client.send(command);
};

const deleteDatabase = (databaseName) => {
  const client = new GlueClient({});

  const command = new DeleteDatabaseCommand({
    Name: databaseName,
  });

  return client.send(command);
};

const deleteCrawler = (crawlerName) => {
  const client = new GlueClient({});

  const command = new DeleteCrawlerCommand({
    Name: crawlerName,
  });

  return client.send(command);
};

/**
 *
```

```
 * @param {import('../../../actions/delete-job.js').deleteJob} deleteJobFn
 * @param {string[]} jobNames
 * @param {{ prompter: { prompt: () => Promise<any> }}} context
 */
const handleDeleteJobs = async (deleteJobFn, jobNames, context) => {
  /**
   * @type {{ selectedJobNames: string[] }}
   */
  const { selectedJobNames } = await context.prompter.prompt({
    name: "selectedJobNames",
    type: "checkbox",
    message: "Let's clean up jobs. Select jobs to delete.",
    choices: jobNames,
  });

  if (selectedJobNames.length === 0) {
    log("No jobs selected.");
  } else {
    log("Deleting jobs.");
    await Promise.all(
      selectedJobNames.map((n) => deleteJobFn(n).catch(console.error)),
    );
    log("Jobs deleted.", { type: "success" });
  }
};

/**
 * @param {{
 *   listJobs: import('../../../actions/list-jobs.js').listJobs,
 *   deleteJob: import('../../../actions/delete-job.js').deleteJob
 * }} config
 */
const makeCleanUpJobsStep =
  ({ listJobs, deleteJob }) =>
  async (context) => {
    const { JobNames } = await listJobs();
    if (JobNames.length > 0) {
      await handleDeleteJobs(deleteJob, JobNames, context);
    }

    return { ...context };
  };

/**
```

```
 * @param {import('../../../actions/delete-table.js').deleteTable} deleteTable
 * @param {string} databaseName
 * @param {string[]} tableNames
 */
const deleteTables = (deleteTable, databaseName, tableNames) =>
  Promise.all(
    tableNames.map((tableName) =>
      deleteTable(databaseName, tableName).catch(console.error),
    ),
  );

/**
 * @param {{
 *  getTables: import('../../../actions/get-tables.js').getTables,
 *  deleteTable: import('../../../actions/delete-table.js').deleteTable
 * }} config
 */
const makeCleanUpTablesStep =
  ({ getTables, deleteTable }) =>
  /**
   * @param {{ prompter: { prompt: () => Promise<any>}}} context
   */
  async (context) => {
    const { TableList } = await getTables(process.env.DATABASE_NAME).catch(
      () => ({ TableList: null }),
    );

    if (TableList && TableList.length > 0) {
      /**
       * @type {{ tableNames: string[] }}
       */
      const { tableNames } = await context.prompter.prompt({
        name: "tableNames",
        type: "checkbox",
        message: "Let's clean up tables. Select tables to delete.",
        choices: TableList.map((t) => t.Name),
      });

      if (tableNames.length === 0) {
        log("No tables selected.");
      } else {
        log("Deleting tables.");
        await deleteTables(deleteTable, process.env.DATABASE_NAME, tableNames);
        log("Tables deleted.", { type: "success" });
```

```
      }
    }

    return { ...context };
  };

/**
 * @param {import('../../../actions/delete-database.js').deleteDatabase}
 deleteDatabase
 * @param {string[]} databaseNames
 */
const deleteDatabases = (deleteDatabase, databaseNames) =>
  Promise.all(
    databaseNames.map((dbName) => deleteDatabase(dbName).catch(console.error)),
  );

/**
 * @param {{
 *   getDatabases: import('../../../actions/get-databases.js').getDatabases
 *   deleteDatabase: import('../../../actions/delete-database.js').deleteDatabase
 * }} config
 */
const makeCleanUpDatabasesStep =
  ({ getDatabases, deleteDatabase }) =>
  /**
   * @param {{ prompter: { prompt: () => Promise<any>}} context
   */
  async (context) => {
    const { DatabaseList } = await getDatabases();

    if (DatabaseList.length > 0) {
      /** @type {{ dbNames: string[] }} */
      const { dbNames } = await context.prompter.prompt({
        name: "dbNames",
        type: "checkbox",
        message: "Let's clean up databases. Select databases to delete.",
        choices: DatabaseList.map((db) => db.Name),
      });

      if (dbNames.length === 0) {
        log("No databases selected.");
      } else {
        log("Deleting databases.");
        await deleteDatabases(deleteDatabase, dbNames);
```

```
        log("Databases deleted.", { type: "success" });
      }
    }

    return { ...context };
  };

const cleanUpCrawlerStep = async (context) => {
  log("Deleting crawler.");

  try {
    await deleteCrawler(process.env.CRAWLER_NAME);
    log("Crawler deleted.", { type: "success" });
  } catch (err) {
    if (err.name === "EntityNotFoundException") {
      log("Crawler is already deleted.");
    } else {
      throw err;
    }
  }

  return { ...context };
};
```

- Para obtener información sobre la API, consulte los siguientes temas en la referencia de la API de AWS SDK para JavaScript.
  - CreateCrawler
  - CreateJob
  - DeleteCrawler
  - DeleteDatabase
  - DeleteJob
  - DeleteTable
  - GetCrawler
  - GetDatabase
  - GetDatabases
  - GetJob
  - GetJobRun

- GetJobRuns
- GetTables
- ListJobs
- StartCrawler
- StartJobRun

Kotlin

SDK para Kotlin

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
suspend fun main(args: Array<String>) {
    val usage = """
        Usage:
            <iam> <s3Path> <cron> <dbName> <crawlerName> <jobName>
 <scriptLocation> <locationUri>

        Where:
            iam - The Amazon Resource Name (ARN) of the AWS Identity and Access
 Management (IAM) role that has AWS Glue and Amazon Simple Storage Service
 (Amazon S3) permissions.
            s3Path - The Amazon Simple Storage Service (Amazon S3) target that
 contains data (for example, CSV data).
            cron - A cron expression used to specify the schedule (for example,
 cron(15 12 * * ? *).
            dbName - The database name.
            crawlerName - The name of the crawler.
            jobName - The name you assign to this job definition.
            scriptLocation - Specifies the Amazon S3 path to a script that runs a
 job.
            locationUri - Specifies the location of the database
        """

    if (args.size != 8) {
        println(usage)
```

```
        exitProcess(1)
    }

    val iam = args[0]
    val s3Path = args[1]
    val cron = args[2]
    val dbName = args[3]
    val crawlerName = args[4]
    val jobName = args[5]
    val scriptLocation = args[6]
    val locationUri = args[7]

    println("About to start the AWS Glue Scenario")
    createDatabase(dbName, locationUri)
    createCrawler(iam, s3Path, cron, dbName, crawlerName)
    getCrawler(crawlerName)
    startCrawler(crawlerName)
    getDatabase(dbName)
    getGlueTables(dbName)
    createJob(jobName, iam, scriptLocation)
    startJob(jobName)
    getJobs()
    getJobRuns(jobName)
    deleteJob(jobName)
    println("*** Wait for 5 MIN so the $crawlerName is ready to be deleted")
    TimeUnit.MINUTES.sleep(5)
    deleteMyDatabase(dbName)
    deleteCrawler(crawlerName)
}

suspend fun createDatabase(
    dbName: String?,
    locationUriVal: String?,
) {
    val input =
        DatabaseInput {
            description = "Built with the AWS SDK for Kotlin"
            name = dbName
            locationUri = locationUriVal
        }

    val request =
        CreateDatabaseRequest {
            databaseInput = input
```

```
        }

    GlueClient.fromEnvironment { region = "us-east-1" }.use { glueClient ->
        glueClient.createDatabase(request)
        println("The database was successfully created")
    }
}

suspend fun createCrawler(
    iam: String?,
    s3Path: String?,
    cron: String?,
    dbName: String?,
    crawlerName: String,
) {
    val s3Target =
        S3Target {
            path = s3Path
        }

    val targetList = ArrayList<S3Target>()
    targetList.add(s3Target)

    val targetOb =
        CrawlerTargets {
            s3Targets = targetList
        }

    val crawlerRequest =
        CreateCrawlerRequest {
            databaseName = dbName
            name = crawlerName
            description = "Created by the AWS Glue Java API"
            targets = targetOb
            role = iam
            schedule = cron
        }

    GlueClient.fromEnvironment { region = "us-east-1" }.use { glueClient ->
        glueClient.createCrawler(crawlerRequest)
        println("$crawlerName was successfully created")
    }
}
```

```
suspend fun getCrawler(crawlerName: String?) {
    val request =
        GetCrawlerRequest {
            name = crawlerName
        }

    GlueClient.fromEnvironment { region = "us-east-1" }.use { glueClient ->
        val response = glueClient.getCrawler(request)
        val role = response.crawler?.role
        println("The role associated with this crawler is $role")
    }
}

suspend fun startCrawler(crawlerName: String) {
    val crawlerRequest =
        StartCrawlerRequest {
            name = crawlerName
        }

    GlueClient.fromEnvironment { region = "us-east-1" }.use { glueClient ->
        glueClient.startCrawler(crawlerRequest)
        println("$crawlerName was successfully started.")
    }
}

suspend fun getDatabase(databaseName: String?) {
    val request =
        GetDatabaseRequest {
            name = databaseName
        }

    GlueClient.fromEnvironment { region = "us-east-1" }.use { glueClient ->
        val response = glueClient.getDatabase(request)
        val dbDesc = response.database?.description
        println("The database description is $dbDesc")
    }
}

suspend fun getGlueTables(dbName: String?) {
    val tableRequest =
        GetTablesRequest {
            databaseName = dbName
        }
```

```
    GlueClient.fromEnvironment { region = "us-east-1" }.use { glueClient ->
        val response = glueClient.getTables(tableRequest)
        response.tableList?.forEach { tableName ->
            println("Table name is ${tableName.name}")
        }
    }
}

suspend fun startJob(jobNameVal: String?) {
    val runRequest =
        StartJobRunRequest {
            workerType = WorkerType.G1X
            numberOfWorkers = 10
            jobName = jobNameVal
        }

    GlueClient.fromEnvironment { region = "us-east-1" }.use { glueClient ->
        val response = glueClient.startJobRun(runRequest)
        println("The job run Id is ${response.jobRunId}")
    }
}

suspend fun createJob(
    jobName: String,
    iam: String?,
    scriptLocationVal: String?,
) {
    val commandOb =
        JobCommand {
            pythonVersion = "3"
            name = "MyJob1"
            scriptLocation = scriptLocationVal
        }

    val jobRequest =
        CreateJobRequest {
            description = "A Job created by using the AWS SDK for Java V2"
            glueVersion = "2.0"
            workerType = WorkerType.G1X
            numberOfWorkers = 10
            name = jobName
            role = iam
            command = commandOb
        }
```

```
    GlueClient.fromEnvironment { region = "us-east-1" }.use { glueClient ->
        glueClient.createJob(jobRequest)
        println("$jobName was successfully created.")
    }
}

suspend fun getJobs() {
    val request =
        GetJobsRequest {
            maxResults = 10
        }

    GlueClient.fromEnvironment { region = "us-east-1" }.use { glueClient ->
        val response = glueClient.getJobs(request)
        response.jobs?.forEach { job ->
            println("Job name is ${job.name}")
        }
    }
}

suspend fun getJobRuns(jobNameVal: String?) {
    val request =
        GetJobRunsRequest {
            jobName = jobNameVal
        }

    GlueClient.fromEnvironment { region = "us-east-1" }.use { glueClient ->
        val response = glueClient.getJobRuns(request)
        response.jobRuns?.forEach { job ->
            println("Job name is ${job.jobName}")
        }
    }
}

suspend fun deleteJob(jobNameVal: String) {
    val jobRequest =
        DeleteJobRequest {
            jobName = jobNameVal
        }

    GlueClient.fromEnvironment { region = "us-east-1" }.use { glueClient ->
        glueClient.deleteJob(jobRequest)
        println("$jobNameVal was successfully deleted")
```

```
    }
}

suspend fun deleteMyDatabase(databaseName: String) {
    val request =
        DeleteDatabaseRequest {
            name = databaseName
        }

    GlueClient.fromEnvironment { region = "us-east-1" }.use { glueClient ->
        glueClient.deleteDatabase(request)
        println("$databaseName was successfully deleted")
    }
}

suspend fun deleteCrawler(crawlerName: String) {
    val request =
        DeleteCrawlerRequest {
            name = crawlerName
        }
    GlueClient.fromEnvironment { region = "us-east-1" }.use { glueClient ->
        glueClient.deleteCrawler(request)
        println("$crawlerName was deleted")
    }
}
```

- Para obtener información sobre la API, consulte los siguientes temas en la Referencia de la API de AWS SDK para Kotlin.
  - CreateCrawler
  - CreateJob
  - DeleteCrawler
  - DeleteDatabase
  - DeleteJob
  - DeleteTable
  - GetCrawler
  - GetDatabase
  - GetDatabases
  - GetJob

- GetJobRun
- GetJobRuns
- GetTables
- ListJobs
- StartCrawler
- StartJobRun

PHP

SDK para PHP

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
namespace Glue;

use Aws\Glue\GlueClient;
use Aws\S3\S3Client;
use AwsUtilities\AWSServiceClass;
use GuzzleHttp\Psr7\Stream;
use Iam\IAMService;

class GettingStartedWithGlue
{
    public function run()
    {
        echo("\n");
        echo("--------------------------------------\n");
        print("Welcome to the AWS Glue getting started demo using PHP!\n");
        echo("--------------------------------------\n");

        $clientArgs = [
            'region' => 'us-west-2',
            'version' => 'latest',
            'profile' => 'default',
        ];
```

```
        $uniqid = uniqid();

        $glueClient = new GlueClient($clientArgs);
        $glueService = new GlueService($glueClient);
        $iamService = new IAMService();
        $crawlerName = "example-crawler-test-" . $uniqid;

        AWSServiceClass::$waitTime = 5;
        AWSServiceClass::$maxWaitAttempts = 20;

        $role = $iamService->getRole("AWSGlueServiceRole-DocExample");

        $databaseName = "doc-example-database-$uniqid";
        $path = 's3://crawler-public-us-east-1/flight/2016/csv';
        $glueService->createCrawler($crawlerName, $role['Role']['Arn'],
$databaseName, $path);
        $glueService->startCrawler($crawlerName);

        echo "Waiting for crawler";
        do {
            $crawler = $glueService->getCrawler($crawlerName);
            echo ".";
            sleep(10);
        } while ($crawler['Crawler']['State'] != "READY");
        echo "\n";

        $database = $glueService->getDatabase($databaseName);
        echo "Found a database named " . $database['Database']['Name'] . "\n";

        //Upload job script
        $s3client = new S3Client($clientArgs);
        $bucketName = "test-glue-bucket-" . $uniqid;
        $s3client->createBucket([
            'Bucket' => $bucketName,
            'CreateBucketConfiguration' => ['LocationConstraint' => 'us-west-2'],
        ]);

        $s3client->putObject([
            'Bucket' => $bucketName,
            'Key' => 'run_job.py',
            'SourceFile' => __DIR__ . '/flight_etl_job_script.py'
        ]);
        $s3client->putObject([
            'Bucket' => $bucketName,
```

```
            'Key' => 'setup_scenario_getting_started.yaml',
            'SourceFile' => __DIR__ . '/setup_scenario_getting_started.yaml'
        ]);

        $tables = $glueService->getTables($databaseName);

        $jobName = 'test-job-' . $uniqid;
        $scriptLocation = "s3://$bucketName/run_job.py";
        $job = $glueService->createJob($jobName, $role['Role']['Arn'],
$scriptLocation);

        $outputBucketUrl = "s3://$bucketName";
        $runId = $glueService->startJobRun($jobName, $databaseName, $tables,
$outputBucketUrl)['JobRunId'];

        echo "waiting for job";
        do {
            $jobRun = $glueService->getJobRun($jobName, $runId);
            echo ".";
            sleep(10);
        } while (!array_intersect([$jobRun['JobRun']['JobRunState']],
['SUCCEEDED', 'STOPPED', 'FAILED', 'TIMEOUT']));
        echo "\n";

        $jobRuns = $glueService->getJobRuns($jobName);

        $objects = $s3client->listObjects([
            'Bucket' => $bucketName,
        ])['Contents'];

        foreach ($objects as $object) {
            echo $object['Key'] . "\n";
        }

        echo "Downloading " . $objects[1]['Key'] . "\n";
        /** @var Stream $downloadObject */
        $downloadObject = $s3client->getObject([
            'Bucket' => $bucketName,
            'Key' => $objects[1]['Key'],
        ])['Body']->getContents();
        echo "Here is the first 1000 characters in the object.";
        echo substr($downloadObject, 0, 1000);

        $jobs = $glueService->listJobs();
```

```
        echo "Current jobs:\n";
        foreach ($jobs['JobNames'] as $jobsName) {
            echo "{$jobsName}\n";
        }

        echo "Delete the job.\n";
        $glueClient->deleteJob([
            'JobName' => $job['Name'],
        ]);

        echo "Delete the tables.\n";
        foreach ($tables['TableList'] as $table) {
            $glueService->deleteTable($table['Name'], $databaseName);
        }

        echo "Delete the databases.\n";
        $glueClient->deleteDatabase([
            'Name' => $databaseName,
        ]);

        echo "Delete the crawler.\n";
        $glueClient->deleteCrawler([
            'Name' => $crawlerName,
        ]);

        $deleteObjects = $s3client->listObjectsV2([
            'Bucket' => $bucketName,
        ]);
        echo "Delete all objects in the bucket.\n";
        $deleteObjects = $s3client->deleteObjects([
            'Bucket' => $bucketName,
            'Delete' => [
                'Objects' => $deleteObjects['Contents'],
            ]
        ]);
        echo "Delete the bucket.\n";
        $s3client->deleteBucket(['Bucket' => $bucketName]);

        echo "This job was brought to you by the number $uniqid\n";
    }
}

namespace Glue;
```

```
use Aws\Glue\GlueClient;
use Aws\Result;

use function PHPUnit\Framework\isEmpty;

class GlueService extends \AwsUtilities\AWSServiceClass
{
    protected GlueClient $glueClient;

    public function __construct($glueClient)
    {
        $this->glueClient = $glueClient;
    }

    public function getCrawler($crawlerName)
    {
        return $this->customWaiter(function () use ($crawlerName) {
            return $this->glueClient->getCrawler([
                'Name' => $crawlerName,
            ]);
        });
    }

    public function createCrawler($crawlerName, $role, $databaseName, $path):
 Result
    {
        return $this->customWaiter(function () use ($crawlerName, $role,
 $databaseName, $path) {
            return $this->glueClient->createCrawler([
                'Name' => $crawlerName,
                'Role' => $role,
                'DatabaseName' => $databaseName,
                'Targets' => [
                    'S3Targets' =>
                        [[
                            'Path' => $path,
                        ]]
                ],
            ]);
        });
    }

    public function startCrawler($crawlerName): Result
    {
```

```
        return $this->glueClient->startCrawler([
            'Name' => $crawlerName,
        ]);
    }

    public function getDatabase(string $databaseName): Result
    {
        return $this->customWaiter(function () use ($databaseName) {
            return $this->glueClient->getDatabase([
                'Name' => $databaseName,
            ]);
        });
    }

    public function getTables($databaseName): Result
    {
        return $this->glueClient->getTables([
            'DatabaseName' => $databaseName,
        ]);
    }

    public function createJob($jobName, $role, $scriptLocation, $pythonVersion =
'3', $glueVersion = '3.0'): Result
    {
        return $this->glueClient->createJob([
            'Name' => $jobName,
            'Role' => $role,
            'Command' => [
                'Name' => 'glueetl',
                'ScriptLocation' => $scriptLocation,
                'PythonVersion' => $pythonVersion,
            ],
            'GlueVersion' => $glueVersion,
        ]);
    }

    public function startJobRun($jobName, $databaseName, $tables,
$outputBucketUrl): Result
    {
        return $this->glueClient->startJobRun([
            'JobName' => $jobName,
            'Arguments' => [
                'input_database' => $databaseName,
                'input_table' => $tables['TableList'][0]['Name'],
```

```
                'output_bucket_url' => $outputBucketUrl,
                '--input_database' => $databaseName,
                '--input_table' => $tables['TableList'][0]['Name'],
                '--output_bucket_url' => $outputBucketUrl,
            ],
        ]);
    }

    public function listJobs($maxResults = null, $nextToken = null, $tags = []):
Result
    {
        $arguments = [];
        if ($maxResults) {
            $arguments['MaxResults'] = $maxResults;
        }
        if ($nextToken) {
            $arguments['NextToken'] = $nextToken;
        }
        if (!empty($tags)) {
            $arguments['Tags'] = $tags;
        }
        return $this->glueClient->listJobs($arguments);
    }

    public function getJobRuns($jobName, $maxResults = 0, $nextToken = ''):
Result
    {
        $arguments = ['JobName' => $jobName];
        if ($maxResults) {
            $arguments['MaxResults'] = $maxResults;
        }
        if ($nextToken) {
            $arguments['NextToken'] = $nextToken;
        }
        return $this->glueClient->getJobRuns($arguments);
    }

    public function getJobRun($jobName, $runId, $predecessorsIncluded = false):
Result
    {
        return $this->glueClient->getJobRun([
            'JobName' => $jobName,
            'RunId' => $runId,
            'PredecessorsIncluded' => $predecessorsIncluded,
```

```
        ]);
    }

    public function deleteJob($jobName)
    {
        return $this->glueClient->deleteJob([
            'JobName' => $jobName,
        ]);
    }

    public function deleteTable($tableName, $databaseName)
    {
        return $this->glueClient->deleteTable([
            'DatabaseName' => $databaseName,
            'Name' => $tableName,
        ]);
    }

    public function deleteDatabase($databaseName)
    {
        return $this->glueClient->deleteDatabase([
            'Name' => $databaseName,
        ]);
    }

    public function deleteCrawler($crawlerName)
    {
        return $this->glueClient->deleteCrawler([
            'Name' => $crawlerName,
        ]);
    }
}
```

- Para obtener información sobre la API, consulte los siguientes temas en la referencia de la API de AWS SDK para PHP.
  - CreateCrawler
  - CreateJob
  - DeleteCrawler
  - DeleteDatabase
  - DeleteJob

- DeleteTable
- GetCrawler
- GetDatabase
- GetDatabases
- GetJob
- GetJobRun
- GetJobRuns
- GetTables
- ListJobs
- StartCrawler
- StartJobRun

Python

SDK para Python (Boto3)

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

Crear una clase que incluya las funciones de AWS Glue que se utilizan en el escenario.

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""

    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 Glue client.
        """
        self.glue_client = glue_client


    def get_crawler(self, name):
        """
        Gets information about a crawler.
```

```
        :param name: The name of the crawler to look up.
        :return: Data about the crawler.
        """
        crawler = None
        try:
            response = self.glue_client.get_crawler(Name=name)
            crawler = response["Crawler"]
        except ClientError as err:
            if err.response["Error"]["Code"] == "EntityNotFoundException":
                logger.info("Crawler %s doesn't exist.", name)
            else:
                logger.error(
                    "Couldn't get crawler %s. Here's why: %s: %s",
                    name,
                    err.response["Error"]["Code"],
                    err.response["Error"]["Message"],
                )
                raise
        return crawler


    def create_crawler(self, name, role_arn, db_name, db_prefix, s3_target):
        """
        Creates a crawler that can crawl the specified target and populate a
        database in your AWS Glue Data Catalog with metadata that describes the
data
        in the target.

        :param name: The name of the crawler.
        :param role_arn: The Amazon Resource Name (ARN) of an AWS Identity and
Access
                         Management (IAM) role that grants permission to let AWS
Glue
                         access the resources it needs.
        :param db_name: The name to give the database that is created by the
crawler.
        :param db_prefix: The prefix to give any database tables that are created
by
                          the crawler.
        :param s3_target: The URL to an S3 bucket that contains data that is
                          the target of the crawler.
        """
        try:
```

```
            self.glue_client.create_crawler(
                Name=name,
                Role=role_arn,
                DatabaseName=db_name,
                TablePrefix=db_prefix,
                Targets={"S3Targets": [{"Path": s3_target}]},
            )
        except ClientError as err:
            logger.error(
                "Couldn't create crawler. Here's why: %s: %s",
                err.response["Error"]["Code"],
                err.response["Error"]["Message"],
            )
            raise


    def start_crawler(self, name):
        """
        Starts a crawler. The crawler crawls its configured target and creates
        metadata that describes the data it finds in the target data source.

        :param name: The name of the crawler to start.
        """
        try:
            self.glue_client.start_crawler(Name=name)
        except ClientError as err:
            logger.error(
                "Couldn't start crawler %s. Here's why: %s: %s",
                name,
                err.response["Error"]["Code"],
                err.response["Error"]["Message"],
            )
            raise


    def get_database(self, name):
        """
        Gets information about a database in your Data Catalog.

        :param name: The name of the database to look up.
        :return: Information about the database.
        """
        try:
            response = self.glue_client.get_database(Name=name)
```

```
        except ClientError as err:
            logger.error(
                "Couldn't get database %s. Here's why: %s: %s",
                name,
                err.response["Error"]["Code"],
                err.response["Error"]["Message"],
            )
            raise
        else:
            return response["Database"]


    def get_tables(self, db_name):
        """
        Gets a list of tables in a Data Catalog database.

        :param db_name: The name of the database to query.
        :return: The list of tables in the database.
        """
        try:
            response = self.glue_client.get_tables(DatabaseName=db_name)
        except ClientError as err:
            logger.error(
                "Couldn't get tables %s. Here's why: %s: %s",
                db_name,
                err.response["Error"]["Code"],
                err.response["Error"]["Message"],
            )
            raise
        else:
            return response["TableList"]


    def create_job(self, name, description, role_arn, script_location):
        """
        Creates a job definition for an extract, transform, and load (ETL) job
that can
        be run by AWS Glue.

        :param name: The name of the job definition.
        :param description: The description of the job definition.
        :param role_arn: The ARN of an IAM role that grants AWS Glue the
permissions
                         it requires to run the job.
```

```
        :param script_location: The Amazon S3 URL of a Python ETL script that is
run as
                                part of the job. The script defines how the data
is
                                transformed.
        """
        try:
            self.glue_client.create_job(
                Name=name,
                Description=description,
                Role=role_arn,
                Command={
                    "Name": "glueetl",
                    "ScriptLocation": script_location,
                    "PythonVersion": "3",
                },
                GlueVersion="3.0",
            )
        except ClientError as err:
            logger.error(
                "Couldn't create job %s. Here's why: %s: %s",
                name,
                err.response["Error"]["Code"],
                err.response["Error"]["Message"],
            )
            raise


    def start_job_run(self, name, input_database, input_table,
output_bucket_name):
        """
        Starts a job run. A job run extracts data from the source, transforms it,
        and loads it to the output bucket.

        :param name: The name of the job definition.
        :param input_database: The name of the metadata database that contains
tables
                               that describe the source data. This is typically
created
                               by a crawler.
        :param input_table: The name of the table in the metadata database that
                            describes the source data.
        :param output_bucket_name: The S3 bucket where the output is written.
        :return: The ID of the job run.
```

```
        """
        try:
            # The custom Arguments that are passed to this function are used by
the
            # Python ETL script to determine the location of input and output
data.
            response = self.glue_client.start_job_run(
                JobName=name,
                Arguments={
                    "--input_database": input_database,
                    "--input_table": input_table,
                    "--output_bucket_url": f"s3://{output_bucket_name}/",
                },
            )
        except ClientError as err:
            logger.error(
                "Couldn't start job run %s. Here's why: %s: %s",
                name,
                err.response["Error"]["Code"],
                err.response["Error"]["Message"],
            )
            raise
        else:
            return response["JobRunId"]


    def list_jobs(self):
        """
        Lists the names of job definitions in your account.

        :return: The list of job definition names.
        """
        try:
            response = self.glue_client.list_jobs()
        except ClientError as err:
            logger.error(
                "Couldn't list jobs. Here's why: %s: %s",
                err.response["Error"]["Code"],
                err.response["Error"]["Message"],
            )
            raise
        else:
            return response["JobNames"]
```

```
    def get_job_runs(self, job_name):
        """
        Gets information about runs that have been performed for a specific job
        definition.

        :param job_name: The name of the job definition to look up.
        :return: The list of job runs.
        """
        try:
            response = self.glue_client.get_job_runs(JobName=job_name)
        except ClientError as err:
            logger.error(
                "Couldn't get job runs for %s. Here's why: %s: %s",
                job_name,
                err.response["Error"]["Code"],
                err.response["Error"]["Message"],
            )
            raise
        else:
            return response["JobRuns"]


    def get_job_run(self, name, run_id):
        """
        Gets information about a single job run.

        :param name: The name of the job definition for the run.
        :param run_id: The ID of the run.
        :return: Information about the run.
        """
        try:
            response = self.glue_client.get_job_run(JobName=name, RunId=run_id)
        except ClientError as err:
            logger.error(
                "Couldn't get job run %s/%s. Here's why: %s: %s",
                name,
                run_id,
                err.response["Error"]["Code"],
                err.response["Error"]["Message"],
            )
            raise
        else:
            return response["JobRun"]
```

```
    def delete_job(self, job_name):
        """
        Deletes a job definition. This also deletes data about all runs that are
        associated with this job definition.

        :param job_name: The name of the job definition to delete.
        """
        try:
            self.glue_client.delete_job(JobName=job_name)
        except ClientError as err:
            logger.error(
                "Couldn't delete job %s. Here's why: %s: %s",
                job_name,
                err.response["Error"]["Code"],
                err.response["Error"]["Message"],
            )
            raise


    def delete_table(self, db_name, table_name):
        """
        Deletes a table from a metadata database.

        :param db_name: The name of the database that contains the table.
        :param table_name: The name of the table to delete.
        """
        try:
            self.glue_client.delete_table(DatabaseName=db_name, Name=table_name)
        except ClientError as err:
            logger.error(
                "Couldn't delete table %s. Here's why: %s: %s",
                table_name,
                err.response["Error"]["Code"],
                err.response["Error"]["Message"],
            )
            raise


    def delete_database(self, name):
        """
        Deletes a metadata database from your Data Catalog.
```

```
        :param name: The name of the database to delete.
        """
        try:
            self.glue_client.delete_database(Name=name)
        except ClientError as err:
            logger.error(
                "Couldn't delete database %s. Here's why: %s: %s",
                name,
                err.response["Error"]["Code"],
                err.response["Error"]["Message"],
            )
            raise


    def delete_crawler(self, name):
        """
        Deletes a crawler.

        :param name: The name of the crawler to delete.
        """
        try:
            self.glue_client.delete_crawler(Name=name)
        except ClientError as err:
            logger.error(
                "Couldn't delete crawler %s. Here's why: %s: %s",
                name,
                err.response["Error"]["Code"],
                err.response["Error"]["Message"],
            )
            raise
```

Crear una clase que ejecute el escenario.

```
class GlueCrawlerJobScenario:
    """
    Encapsulates a scenario that shows how to create an AWS Glue crawler and job
 and use
    them to transform data from CSV to JSON format.
    """
```

```
    def __init__(self, glue_client, glue_service_role, glue_bucket):
        """
        :param glue_client: A Boto3 AWS Glue client.
        :param glue_service_role: An AWS Identity and Access Management (IAM)
role
                                  that AWS Glue can assume to gain access to the
                                  resources it requires.
        :param glue_bucket: An S3 bucket that can hold a job script and output
data
                            from AWS Glue job runs.
        """
        self.glue_client = glue_client
        self.glue_service_role = glue_service_role
        self.glue_bucket = glue_bucket

    @staticmethod
    def wait(seconds, tick=12):
        """
        Waits for a specified number of seconds, while also displaying an
animated
        spinner.

        :param seconds: The number of seconds to wait.
        :param tick: The number of frames per second used to animate the spinner.
        """
        progress = "|/-\\"
        waited = 0
        while waited < seconds:
            for frame in range(tick):
                sys.stdout.write(f"\r{progress[frame % len(progress)]}")
                sys.stdout.flush()
                time.sleep(1 / tick)
            waited += 1

    def upload_job_script(self, job_script):
        """
        Uploads a Python ETL script to an S3 bucket. The script is used by the
AWS Glue
        job to transform data.

        :param job_script: The relative path to the job script.
        """
        try:
```

```
            self.glue_bucket.upload_file(Filename=job_script, Key=job_script)
            print(f"Uploaded job script '{job_script}' to the example bucket.")
        except S3UploadFailedError as err:
            logger.error("Couldn't upload job script. Here's why: %s", err)
            raise

    def run(self, crawler_name, db_name, db_prefix, data_source, job_script,
job_name):
        """
        Runs the scenario. This is an interactive experience that runs at a
command
        prompt and asks you for input throughout.

        :param crawler_name: The name of the crawler used in the scenario. If the
                             crawler does not exist, it is created.
        :param db_name: The name to give the metadata database created by the
crawler.
        :param db_prefix: The prefix to give tables added to the database by the
                          crawler.
        :param data_source: The location of the data source that is targeted by
the
                            crawler and extracted during job runs.
        :param job_script: The job script that is used to transform data during
job
                           runs.
        :param job_name: The name to give the job definition that is created
during the
                         scenario.
        """
        wrapper = GlueWrapper(self.glue_client)
        print(f"Checking for crawler {crawler_name}.")
        crawler = wrapper.get_crawler(crawler_name)
        if crawler is None:
            print(f"Creating crawler {crawler_name}.")
            wrapper.create_crawler(
                crawler_name,
                self.glue_service_role.arn,
                db_name,
                db_prefix,
                data_source,
            )
            print(f"Created crawler {crawler_name}.")
            crawler = wrapper.get_crawler(crawler_name)
        pprint(crawler)
```

```
        print("-" * 88)

        print(
            f"When you run the crawler, it crawls data stored in {data_source}
and "
            f"creates a metadata database in the AWS Glue Data Catalog that
describes "
            f"the data in the data source."
        )
        print("In this example, the source data is in CSV format.")
        ready = False
        while not ready:
            ready = Question.ask_question(
                "Ready to start the crawler? (y/n) ", Question.is_yesno
            )
        wrapper.start_crawler(crawler_name)
        print("Let's wait for the crawler to run. This typically takes a few
minutes.")
        crawler_state = None
        while crawler_state != "READY":
            self.wait(10)
            crawler = wrapper.get_crawler(crawler_name)
            crawler_state = crawler["State"]
            print(f"Crawler is {crawler['State']}.")
        print("-" * 88)

        database = wrapper.get_database(db_name)
        print(f"The crawler created database {db_name}:")
        pprint(database)
        print(f"The database contains these tables:")
        tables = wrapper.get_tables(db_name)
        for index, table in enumerate(tables):
            print(f"\t{index + 1}. {table['Name']}")
        table_index = Question.ask_question(
            f"Enter the number of a table to see more detail: ",
            Question.is_int,
            Question.in_range(1, len(tables)),
        )
        pprint(tables[table_index - 1])
        print("-" * 88)

        print(f"Creating job definition {job_name}.")
        wrapper.create_job(
            job_name,
```

```
            "Getting started example job.",
            self.glue_service_role.arn,
            f"s3://{self.glue_bucket.name}/{job_script}",
        )
        print("Created job definition.")
        print(
            f"When you run the job, it extracts data from {data_source},
transforms it "
            f"by using the {job_script} script, and loads the output into "
            f"S3 bucket {self.glue_bucket.name}."
        )
        print(
            "In this example, the data is transformed from CSV to JSON, and only
a few "
            "fields are included in the output."
        )
        job_run_status = None
        if Question.ask_question(f"Ready to run? (y/n) ", Question.is_yesno):
            job_run_id = wrapper.start_job_run(
                job_name, db_name, tables[0]["Name"], self.glue_bucket.name
            )
            print(f"Job {job_name} started. Let's wait for it to run.")
            while job_run_status not in ["SUCCEEDED", "STOPPED", "FAILED",
"TIMEOUT"]:
                self.wait(10)
                job_run = wrapper.get_job_run(job_name, job_run_id)
                job_run_status = job_run["JobRunState"]
                print(f"Job {job_name}/{job_run_id} is {job_run_status}.")
        print("-" * 88)

        if job_run_status == "SUCCEEDED":
            print(
                f"Data from your job run is stored in your S3 bucket
'{self.glue_bucket.name}':"
            )
            try:
                keys = [
                    obj.key for obj in
self.glue_bucket.objects.filter(Prefix="run-")
                ]
                for index, key in enumerate(keys):
                    print(f"\t{index + 1}: {key}")
                lines = 4
                key_index = Question.ask_question(
```

```
                    f"Enter the number of a block to download it and see the
first {lines} "
                    f"lines of JSON output in the block: ",
                    Question.is_int,
                    Question.in_range(1, len(keys)),
                )
                job_data = io.BytesIO()
                self.glue_bucket.download_fileobj(keys[key_index - 1], job_data)
                job_data.seek(0)
                for _ in range(lines):
                    print(job_data.readline().decode("utf-8"))
            except ClientError as err:
                logger.error(
                    "Couldn't get job run data. Here's why: %s: %s",
                    err.response["Error"]["Code"],
                    err.response["Error"]["Message"],
                )
                raise
            print("-" * 88)

        job_names = wrapper.list_jobs()
        if job_names:
            print(f"Your account has {len(job_names)} jobs defined:")
            for index, job_name in enumerate(job_names):
                print(f"\t{index + 1}. {job_name}")
            job_index = Question.ask_question(
                f"Enter a number between 1 and {len(job_names)} to see the list
of runs for "
                f"a job: ",
                Question.is_int,
                Question.in_range(1, len(job_names)),
            )
            job_runs = wrapper.get_job_runs(job_names[job_index - 1])
            if job_runs:
                print(f"Found {len(job_runs)} runs for job {job_names[job_index -
1]}:")
                for index, job_run in enumerate(job_runs):
                    print(
                        f"\t{index + 1}. {job_run['JobRunState']} on "
                        f"{job_run['CompletedOn']:%Y-%m-%d %H:%M:%S}"
                    )
                run_index = Question.ask_question(
                    f"Enter a number between 1 and {len(job_runs)} to see details
for a run: ",
```

```
                    Question.is_int,
                    Question.in_range(1, len(job_runs)),
                )
                pprint(job_runs[run_index - 1])
            else:
                print(f"No runs found for job {job_names[job_index - 1]}")
        else:
            print("Your account doesn't have any jobs defined.")
        print("-" * 88)

        print(
            f"Let's clean up. During this example we created job definition
'{job_name}'."
        )
        if Question.ask_question(
            "Do you want to delete the definition and all runs? (y/n) ",
            Question.is_yesno,
        ):
            wrapper.delete_job(job_name)
            print(f"Job definition '{job_name}' deleted.")
        tables = wrapper.get_tables(db_name)
        print(f"We also created database '{db_name}' that contains these
tables:")
        for table in tables:
            print(f"\t{table['Name']}")
        if Question.ask_question(
            "Do you want to delete the tables and the database? (y/n) ",
            Question.is_yesno,
        ):
            for table in tables:
                wrapper.delete_table(db_name, table["Name"])
                print(f"Deleted table {table['Name']}.")
            wrapper.delete_database(db_name)
            print(f"Deleted database {db_name}.")
        print(f"We also created crawler '{crawler_name}'.")
        if Question.ask_question(
            "Do you want to delete the crawler? (y/n) ", Question.is_yesno
        ):
            wrapper.delete_crawler(crawler_name)
            print(f"Deleted crawler {crawler_name}.")
        print("-" * 88)


def parse_args(args):
```

```
    """
    Parse command line arguments.

    :param args: The command line arguments.
    :return: The parsed arguments.
    """
    parser = argparse.ArgumentParser(
        description="Runs the AWS Glue getting started with crawlers and jobs
 scenario. "
        "Before you run this scenario, set up scaffold resources by running "
        "'python scaffold.py deploy'."
    )
    parser.add_argument(
        "role_name",
        help="The name of an IAM role that AWS Glue can assume. This role must
 grant access "
        "to Amazon S3 and to the permissions granted by the AWSGlueServiceRole "
        "managed policy.",
    )
    parser.add_argument(
        "bucket_name",
        help="The name of an S3 bucket that AWS Glue can access to get the job
 script and "
        "put job results.",
    )
    parser.add_argument(
        "--job_script",
        default="flight_etl_job_script.py",
        help="The name of the job script file that is used in the scenario.",
    )
    return parser.parse_args(args)


def main():
    args = parse_args(sys.argv[1:])
    try:
        print("-" * 88)
        print(
            "Welcome to the AWS Glue getting started with crawlers and jobs
 scenario."
        )
        print("-" * 88)
        scenario = GlueCrawlerJobScenario(
            boto3.client("glue"),
```

```
            boto3.resource("iam").Role(args.role_name),
            boto3.resource("s3").Bucket(args.bucket_name),
        )
        scenario.upload_job_script(args.job_script)
        scenario.run(
            "doc-example-crawler",
            "doc-example-database",
            "doc-example-",
            "s3://crawler-public-us-east-1/flight/2016/csv",
            args.job_script,
            "doc-example-job",
        )
        print("-" * 88)
        print(
            "To destroy scaffold resources, including the IAM role and S3 bucket
 "
            "used in this scenario, run 'python scaffold.py destroy'."
        )
        print("\nThanks for watching!")
        print("-" * 88)
    except Exception:
        logging.exception("Something went wrong with the example.")
```

Cree un script de ETL que AWS Glue utilice para extraer, transformar y cargar datos durante las ejecuciones de trabajos.

```
import sys
from awsglue.transforms import *
from awsglue.utils import getResolvedOptions
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job

"""
These custom arguments must be passed as Arguments to the StartJobRun request.
    --input_database    The name of a metadata database that is contained in
 your
                        AWS Glue Data Catalog and that contains tables that
 describe
                        the data to be processed.
```

```
    --input_table       The name of a table in the database that describes the
 data to
                        be processed.
    --output_bucket_url An S3 bucket that receives the transformed output data.
"""
args = getResolvedOptions(
    sys.argv, ["JOB_NAME", "input_database", "input_table", "output_bucket_url"]
)
sc = SparkContext()
glueContext = GlueContext(sc)
spark = glueContext.spark_session
job = Job(glueContext)
job.init(args["JOB_NAME"], args)

# Script generated for node S3 Flight Data.
S3FlightData_node1 = glueContext.create_dynamic_frame.from_catalog(
    database=args["input_database"],
    table_name=args["input_table"],
    transformation_ctx="S3FlightData_node1",
)

# This mapping performs two main functions:
# 1. It simplifies the output by removing most of the fields from the data.
# 2. It renames some fields. For example, `fl_date` is renamed to `flight_date`.
ApplyMapping_node2 = ApplyMapping.apply(
    frame=S3FlightData_node1,
    mappings=[
        ("year", "long", "year", "long"),
        ("month", "long", "month", "tinyint"),
        ("day_of_month", "long", "day", "tinyint"),
        ("fl_date", "string", "flight_date", "string"),
        ("carrier", "string", "carrier", "string"),
        ("fl_num", "long", "flight_num", "long"),
        ("origin_city_name", "string", "origin_city_name", "string"),
        ("origin_state_abr", "string", "origin_state_abr", "string"),
        ("dest_city_name", "string", "dest_city_name", "string"),
        ("dest_state_abr", "string", "dest_state_abr", "string"),
        ("dep_time", "long", "departure_time", "long"),
        ("wheels_off", "long", "wheels_off", "long"),
        ("wheels_on", "long", "wheels_on", "long"),
        ("arr_time", "long", "arrival_time", "long"),
        ("mon", "string", "mon", "string"),
    ],
    transformation_ctx="ApplyMapping_node2",
```

```
)

# Script generated for node Revised Flight Data.
RevisedFlightData_node3 = glueContext.write_dynamic_frame.from_options(
    frame=ApplyMapping_node2,
    connection_type="s3",
    format="json",
    connection_options={"path": args["output_bucket_url"], "partitionKeys": []},
    transformation_ctx="RevisedFlightData_node3",
)

job.commit()
```

- Para obtener información sobre la API, consulte los siguientes temas en la Referencia de la API de AWS SDK para Python (Boto3).
  - CreateCrawler
  - CreateJob
  - DeleteCrawler
  - DeleteDatabase
  - DeleteJob
  - DeleteTable
  - GetCrawler
  - GetDatabase
  - GetDatabases
  - GetJob
  - GetJobRun
  - GetJobRuns
  - GetTables
  - ListJobs
  - StartCrawler
  - StartJobRun

Ruby

SDK para Ruby

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

Crear una clase que incluya las funciones de AWS Glue que se utilizan en el escenario.

```
# The `GlueWrapper` class serves as a wrapper around the AWS Glue API, providing
 a simplified interface for common operations.
# It encapsulates the functionality of the AWS SDK for Glue and provides methods
 for interacting with Glue crawlers, databases, tables, jobs, and S3 resources.
# The class initializes with a Glue client and a logger, allowing it to make API
 calls and log any errors or informational messages.
class GlueWrapper
  def initialize(glue_client, logger)
    @glue_client = glue_client
    @logger = logger
  end

  # Retrieves information about a specific crawler.
  #
  # @param name [String] The name of the crawler to retrieve information about.
  # @return [Aws::Glue::Types::Crawler, nil] The crawler object if found, or nil
 if not found.
  def get_crawler(name)
    @glue_client.get_crawler(name: name)
  rescue Aws::Glue::Errors::EntityNotFoundException
    @logger.info("Crawler #{name} doesn't exist.")
    false
  rescue Aws::Glue::Errors::GlueException => e
    @logger.error("Glue could not get crawler #{name}: \n#{e.message}")
    raise
  end

  # Creates a new crawler with the specified configuration.
  #
  # @param name [String] The name of the crawler.
```

```
 # @param role_arn [String] The ARN of the IAM role to be used by the crawler.
 # @param db_name [String] The name of the database where the crawler stores its
metadata.
 # @param db_prefix [String] The prefix to be added to the names of tables that
the crawler creates.
 # @param s3_target [String] The S3 path that the crawler will crawl.
 # @return [void]
 def create_crawler(name, role_arn, db_name, _db_prefix, s3_target)
   @glue_client.create_crawler(
     name: name,
     role: role_arn,
     database_name: db_name,
     targets: {
       s3_targets: [
         {
           path: s3_target
         }
       ]
     }
   )
 rescue Aws::Glue::Errors::GlueException => e
   @logger.error("Glue could not create crawler: \n#{e.message}")
   raise
 end

 # Starts a crawler with the specified name.
 #
 # @param name [String] The name of the crawler to start.
 # @return [void]
 def start_crawler(name)
   @glue_client.start_crawler(name: name)
 rescue Aws::Glue::Errors::ServiceError => e
   @logger.error("Glue could not start crawler #{name}: \n#{e.message}")
   raise
 end

 # Deletes a crawler with the specified name.
 #
 # @param name [String] The name of the crawler to delete.
 # @return [void]
 def delete_crawler(name)
   @glue_client.delete_crawler(name: name)
 rescue Aws::Glue::Errors::ServiceError => e
   @logger.error("Glue could not delete crawler #{name}: \n#{e.message}")
```

```
    raise
  end

  # Retrieves information about a specific database.
  #
  # @param name [String] The name of the database to retrieve information about.
  # @return [Aws::Glue::Types::Database, nil] The database object if found, or
nil if not found.
  def get_database(name)
    response = @glue_client.get_database(name: name)
    response.database
  rescue Aws::Glue::Errors::GlueException => e
    @logger.error("Glue could not get database #{name}: \n#{e.message}")
    raise
  end

  # Retrieves a list of tables in the specified database.
  #
  # @param db_name [String] The name of the database to retrieve tables from.
  # @return [Array<Aws::Glue::Types::Table>]
  def get_tables(db_name)
    response = @glue_client.get_tables(database_name: db_name)
    response.table_list
  rescue Aws::Glue::Errors::GlueException => e
    @logger.error("Glue could not get tables #{db_name}: \n#{e.message}")
    raise
  end

  # Creates a new job with the specified configuration.
  #
  # @param name [String] The name of the job.
  # @param description [String] The description of the job.
  # @param role_arn [String] The ARN of the IAM role to be used by the job.
  # @param script_location [String] The location of the ETL script for the job.
  # @return [void]
  def create_job(name, description, role_arn, script_location)
    @glue_client.create_job(
      name: name,
      description: description,
      role: role_arn,
      command: {
        name: 'glueetl',
        script_location: script_location,
        python_version: '3'
```

```
      },
      glue_version: '3.0'
    )
  rescue Aws::Glue::Errors::GlueException => e
    @logger.error("Glue could not create job #{name}: \n#{e.message}")
    raise
  end

  # Starts a job run for the specified job.
  #
  # @param name [String] The name of the job to start the run for.
  # @param input_database [String] The name of the input database for the job.
  # @param input_table [String] The name of the input table for the job.
  # @param output_bucket_name [String] The name of the output S3 bucket for the
job.
  # @return [String] The ID of the started job run.
  def start_job_run(name, input_database, input_table, output_bucket_name)
    response = @glue_client.start_job_run(
      job_name: name,
      arguments: {
        '--input_database': input_database,
        '--input_table': input_table,
        '--output_bucket_url': "s3://#{output_bucket_name}/"
      }
    )
    response.job_run_id
  rescue Aws::Glue::Errors::GlueException => e
    @logger.error("Glue could not start job run #{name}: \n#{e.message}")
    raise
  end

  # Retrieves a list of jobs in AWS Glue.
  #
  # @return [Aws::Glue::Types::ListJobsResponse]
  def list_jobs
    @glue_client.list_jobs
  rescue Aws::Glue::Errors::GlueException => e
    @logger.error("Glue could not list jobs: \n#{e.message}")
    raise
  end

  # Retrieves a list of job runs for the specified job.
  #
  # @param job_name [String] The name of the job to retrieve job runs for.
```

```
  # @return [Array<Aws::Glue::Types::JobRun>]
  def get_job_runs(job_name)
    response = @glue_client.get_job_runs(job_name: job_name)
    response.job_runs
  rescue Aws::Glue::Errors::GlueException => e
    @logger.error("Glue could not get job runs: \n#{e.message}")
  end

  # Retrieves data for a specific job run.
  #
  # @param job_name [String] The name of the job run to retrieve data for.
  # @return [Glue::Types::GetJobRunResponse]
  def get_job_run(job_name, run_id)
    @glue_client.get_job_run(job_name: job_name, run_id: run_id)
  rescue Aws::Glue::Errors::GlueException => e
    @logger.error("Glue could not get job runs: \n#{e.message}")
  end

  # Deletes a job with the specified name.
  #
  # @param job_name [String] The name of the job to delete.
  # @return [void]
  def delete_job(job_name)
    @glue_client.delete_job(job_name: job_name)
  rescue Aws::Glue::Errors::ServiceError => e
    @logger.error("Glue could not delete job: \n#{e.message}")
  end

  # Deletes a table with the specified name.
  #
  # @param database_name [String] The name of the catalog database in which the
table resides.
  # @param table_name [String] The name of the table to be deleted.
  # @return [void]
  def delete_table(database_name, table_name)
    @glue_client.delete_table(database_name: database_name, name: table_name)
  rescue Aws::Glue::Errors::ServiceError => e
    @logger.error("Glue could not delete job: \n#{e.message}")
  end

  # Removes a specified database from a Data Catalog.
  #
  # @param database_name [String] The name of the database to delete.
  # @return [void]
```

```
  def delete_database(database_name)
    @glue_client.delete_database(name: database_name)
  rescue Aws::Glue::Errors::ServiceError => e
    @logger.error("Glue could not delete database: \n#{e.message}")
  end

  # Uploads a job script file to an S3 bucket.
  #
  # @param file_path [String] The local path of the job script file.
  # @param bucket_resource [Aws::S3::Bucket] The S3 bucket resource to upload the
 file to.
  # @return [void]
  def upload_job_script(file_path, bucket_resource)
    File.open(file_path) do |file|
      bucket_resource.client.put_object({
                                          body: file,
                                          bucket: bucket_resource.name,
                                          key: file_path
                                        })
    end
  rescue Aws::S3::Errors::S3UploadFailedError => e
    @logger.error("S3 could not upload job script: \n#{e.message}")
    raise
  end
end
```

Crear una clase que ejecute el escenario.

```
class GlueCrawlerJobScenario
  def initialize(glue_client, glue_service_role, glue_bucket, logger)
    @glue_client = glue_client
    @glue_service_role = glue_service_role
    @glue_bucket = glue_bucket
    @logger = logger
  end

  def run(crawler_name, db_name, db_prefix, data_source, job_script, job_name)
    wrapper = GlueWrapper.new(@glue_client, @logger)
    setup_crawler(wrapper, crawler_name, db_name, db_prefix, data_source)
    query_database(wrapper, crawler_name, db_name)
    create_and_run_job(wrapper, job_script, job_name, db_name)
  end
```

```
  private

  def setup_crawler(wrapper, crawler_name, db_name, db_prefix, data_source)
    new_step(1, 'Create a crawler')
    crawler = wrapper.get_crawler(crawler_name)
    unless crawler
      puts "Creating crawler #{crawler_name}."
      wrapper.create_crawler(crawler_name, @glue_service_role.arn, db_name,
 db_prefix, data_source)
      puts "Successfully created #{crawler_name}."
    end
    wrapper.start_crawler(crawler_name)
    monitor_crawler(wrapper, crawler_name)
  end

  def monitor_crawler(wrapper, crawler_name)
    new_step(2, 'Monitor Crawler')
    crawler_state = nil
    until crawler_state == 'READY'
      custom_wait(15)
      crawler = wrapper.get_crawler(crawler_name)
      crawler_state = crawler[0]['state']
      print "Crawler status: #{crawler_state}".yellow
    end
  end

  def query_database(wrapper, _crawler_name, db_name)
    new_step(3, 'Query the database.')
    wrapper.get_database(db_name)
    puts "The crawler created database #{db_name}:"
    puts "Database contains tables: #{wrapper.get_tables(db_name).map { |t|
 t['name'] }}"
  end

  def create_and_run_job(wrapper, job_script, job_name, db_name)
    new_step(4, 'Create and run job.')
    wrapper.upload_job_script(job_script, @glue_bucket)
    wrapper.create_job(job_name, 'ETL Job', @glue_service_role.arn, "s3://
#{@glue_bucket.name}/#{job_script}")
    run_job(wrapper, job_name, db_name)
  end

  def run_job(wrapper, job_name, db_name)
```

```
    new_step(5, 'Run the job.')
    wrapper.start_job_run(job_name, db_name, wrapper.get_tables(db_name)[0]
['name'], @glue_bucket.name)
    job_run_status = nil
    until %w[SUCCEEDED FAILED STOPPED].include?(job_run_status)
      custom_wait(10)
      job_run = wrapper.get_job_runs(job_name)
      job_run_status = job_run[0]['job_run_state']
      print "Job #{job_name} status: #{job_run_status}".yellow
    end
  end
end

def main
  banner('../../helpers/banner.txt')
  puts 'Starting AWS Glue demo...'

  # Load resource names from YAML.
  resource_names = YAML.load_file('resource_names.yaml')

  # Setup services and resources.
  iam_role = Aws::IAM::Resource.new(region: 'us-
east-1').role(resource_names['glue_service_role'])
  s3_bucket = Aws::S3::Resource.new(region: 'us-
east-1').bucket(resource_names['glue_bucket'])

  # Instantiate scenario and run.
  scenario = GlueCrawlerJobScenario.new(Aws::Glue::Client.new(region: 'us-
east-1'), iam_role, s3_bucket, @logger)
  random_suffix = rand(10**4)
  scenario.run("crawler-#{random_suffix}", "db-#{random_suffix}", "prefix-
#{random_suffix}-", 's3://data_source',
               'job_script.py', "job-#{random_suffix}")

  puts 'Demo complete.'
end
```

Crear un script de ETL que AWS Glue utilice para extraer, transformar y cargar datos durante las ejecuciones de trabajos.

```
import sys
from awsglue.transforms import *
```

```
from awsglue.utils import getResolvedOptions
from pyspark.context import SparkContext
from awsglue.context import GlueContext
from awsglue.job import Job

"""
These custom arguments must be passed as Arguments to the StartJobRun request.
    --input_database    The name of a metadata database that is contained in
 your
                        AWS Glue Data Catalog and that contains tables that
 describe
                        the data to be processed.
    --input_table       The name of a table in the database that describes the
 data to
                        be processed.
    --output_bucket_url An S3 bucket that receives the transformed output data.
"""
args = getResolvedOptions(
    sys.argv, ["JOB_NAME", "input_database", "input_table", "output_bucket_url"]
)
sc = SparkContext()
glueContext = GlueContext(sc)
spark = glueContext.spark_session
job = Job(glueContext)
job.init(args["JOB_NAME"], args)

# Script generated for node S3 Flight Data.
S3FlightData_node1 = glueContext.create_dynamic_frame.from_catalog(
    database=args["input_database"],
    table_name=args["input_table"],
    transformation_ctx="S3FlightData_node1",
)

# This mapping performs two main functions:
# 1. It simplifies the output by removing most of the fields from the data.
# 2. It renames some fields. For example, `fl_date` is renamed to `flight_date`.
ApplyMapping_node2 = ApplyMapping.apply(
    frame=S3FlightData_node1,
    mappings=[
        ("year", "long", "year", "long"),
        ("month", "long", "month", "tinyint"),
        ("day_of_month", "long", "day", "tinyint"),
        ("fl_date", "string", "flight_date", "string"),
        ("carrier", "string", "carrier", "string"),
```

```
        ("fl_num", "long", "flight_num", "long"),
        ("origin_city_name", "string", "origin_city_name", "string"),
        ("origin_state_abr", "string", "origin_state_abr", "string"),
        ("dest_city_name", "string", "dest_city_name", "string"),
        ("dest_state_abr", "string", "dest_state_abr", "string"),
        ("dep_time", "long", "departure_time", "long"),
        ("wheels_off", "long", "wheels_off", "long"),
        ("wheels_on", "long", "wheels_on", "long"),
        ("arr_time", "long", "arrival_time", "long"),
        ("mon", "string", "mon", "string"),
    ],
    transformation_ctx="ApplyMapping_node2",
)

# Script generated for node Revised Flight Data.
RevisedFlightData_node3 = glueContext.write_dynamic_frame.from_options(
    frame=ApplyMapping_node2,
    connection_type="s3",
    format="json",
    connection_options={"path": args["output_bucket_url"], "partitionKeys": []},
    transformation_ctx="RevisedFlightData_node3",
)

job.commit()
```

- Para obtener información sobre la API, consulte los siguientes temas en la referencia de la API de AWS SDK para Ruby.
  - CreateCrawler
  - CreateJob
  - DeleteCrawler
  - DeleteDatabase
  - DeleteJob
  - DeleteTable
  - GetCrawler
  - GetDatabase
  - GetDatabases
  - GetJob
  - GetJobRun

- GetJobRuns
- GetTables
- ListJobs
- StartCrawler
- StartJobRun

Rust

SDK para Rust

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

Cree y ejecute un rastreador que rastree un bucket público de Amazon Simple Storage Service (Amazon S3) y genere una base de metadatos que describa los datos con formato CSV que encuentra.

```
        let create_crawler = glue
            .create_crawler()
            .name(self.crawler())
            .database_name(self.database())
            .role(self.iam_role.expose_secret())
            .targets(
                CrawlerTargets::builder()
                    .s3_targets(S3Target::builder().path(CRAWLER_TARGET).build())
                    .build(),
            )
            .send()
            .await;

        match create_crawler {
            Err(err) => {
                let glue_err: aws_sdk_glue::Error = err.into();
                match glue_err {
                    aws_sdk_glue::Error::AlreadyExistsException(_) => {
                        info!("Using existing crawler");
```

```
                        Ok(())
                    }
                    _ => Err(GlueMvpError::GlueSdk(glue_err)),
                }
            }
            Ok(_) => Ok(()),
        }?;

        let start_crawler =
glue.start_crawler().name(self.crawler()).send().await;

        match start_crawler {
            Ok(_) => Ok(()),
            Err(err) => {
                let glue_err: aws_sdk_glue::Error = err.into();
                match glue_err {
                    aws_sdk_glue::Error::CrawlerRunningException(_) => Ok(()),
                    _ => Err(GlueMvpError::GlueSdk(glue_err)),
                }
            }
        }?;
```

Incluya información sobre las bases de datos y las tablas en su AWS Glue Data Catalog.

```
        let database = glue
            .get_database()
            .name(self.database())
            .send()
            .await
            .map_err(GlueMvpError::from_glue_sdk)?
            .to_owned();
        let database = database
            .database()
            .ok_or_else(|| GlueMvpError::Unknown("Could not find
database".into()))?;

        let tables = glue
            .get_tables()
            .database_name(self.database())
            .send()
            .await
            .map_err(GlueMvpError::from_glue_sdk)?;
```

```
        let tables = tables.table_list();
```

Cree y ejecute un trabajo que extraiga datos CSV del bucket de Amazon S3 de origen, los transforme quitando campos y cambiándoles el nombre, y cargue el resultado con formato JSON en otro bucket de Amazon S3.

```
        let create_job = glue
            .create_job()
            .name(self.job())
            .role(self.iam_role.expose_secret())
            .command(
                JobCommand::builder()
                    .name("glueetl")
                    .python_version("3")
                    .script_location(format!("s3://{}/job.py", self.bucket()))
                    .build(),
            )
            .glue_version("3.0")
            .send()
            .await
            .map_err(GlueMvpError::from_glue_sdk)?;

        let job_name = create_job.name().ok_or_else(|| {
            GlueMvpError::Unknown("Did not get job name after creating
job".into())
        })?;

        let job_run_output = glue
            .start_job_run()
            .job_name(self.job())
            .arguments("--input_database", self.database())
            .arguments(
                "--input_table",
                self.tables
                    .first()
                    .ok_or_else(|| GlueMvpError::Unknown("Missing crawler
table".into()))?
                    .name(),
            )
            .arguments("--output_bucket_url", self.bucket())
            .send()
```

```
            .await
            .map_err(GlueMvpError::from_glue_sdk)?;

        let job = job_run_output
            .job_run_id()
            .ok_or_else(|| GlueMvpError::Unknown("Missing run id from just
started job".into()))?
            .to_string();
```

Elimine todos los recursos creados en la demostración.

```
        glue.delete_job()
            .job_name(self.job())
            .send()
            .await
            .map_err(GlueMvpError::from_glue_sdk)?;

        for t in &self.tables {
            glue.delete_table()
                .name(t.name())
                .database_name(self.database())
                .send()
                .await
                .map_err(GlueMvpError::from_glue_sdk)?;
        }

        glue.delete_database()
            .name(self.database())
            .send()
            .await
            .map_err(GlueMvpError::from_glue_sdk)?;

        glue.delete_crawler()
            .name(self.crawler())
            .send()
            .await
            .map_err(GlueMvpError::from_glue_sdk)?;
```

- Para obtener información sobre la API, consulte los siguientes temas en la Referencia de la API de AWS SDK para Rust.

- CreateCrawler
- CreateJob
- DeleteCrawler
- DeleteDatabase
- DeleteJob
- DeleteTable
- GetCrawler
- GetDatabase
- GetDatabases
- GetJob
- GetJobRun
- GetJobRuns
- GetTables
- ListJobs
- StartCrawler
- StartJobRun

Swift

SDK para Swift

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

El archivo `Package.swift`.

```
// swift-tools-version: 5.9
//
// The swift-tools-version declares the minimum version of Swift required to
// build this package.

import PackageDescription
```

```
let package = Package(
    name: "glue-scenario",
    // Let Xcode know the minimum Apple platforms supported.
    platforms: [
        .macOS(.v13),
        .iOS(.v15)
    ],
    dependencies: [
        // Dependencies declare other packages that this package depends on.
        .package(
            url: "https://github.com/awslabs/aws-sdk-swift",
            from: "1.0.0"),
        .package(
            url: "https://github.com/apple/swift-argument-parser.git",
            branch: "main"
        )
    ],
    targets: [
        // Targets are the basic building blocks of a package, defining a module
 or a test suite.
        // Targets can depend on other targets in this package and products
        // from dependencies.
        .executableTarget(
            name: "glue-scenario",
            dependencies: [
                .product(name: "AWSGlue", package: "aws-sdk-swift"),
                .product(name: "AWSS3", package: "aws-sdk-swift"),
                .product(name: "ArgumentParser", package: "swift-argument-
parser")
            ],
            path: "Sources")

    ]
)
```

El archivo de código Swift, `entry.swift`.

```
// An example that shows how to use the AWS SDK for Swift to demonstrate
// creating and using crawlers and jobs using AWS Glue.
//
// 0. Upload the Python job script to Amazon S3 so it can be used when
```

```
//    calling `startJobRun()` later.
// 1. Create a crawler, pass it the IAM role and the URL of the public Amazon
//    S3 bucket that contains the source data:
//    s3://crawler-public-us-east-1/flight/2016/csv.
// 2. Start the crawler. This takes time, so after starting it, use a loop
//    that calls `getCrawler()` until the state is "READY".
// 3. Get the database created by the crawler, and the tables in the
//    database. Display them to the user.
// 4. Create a job. Pass it the IAM role and the URL to a Python ETL script
//    previously uploaded to the user's S3 bucket.
// 5. Start a job run, passing the following custom arguments. These are
//    expected by the ETL script, so must exactly match.
//    * `--input_database: <name of the database created by the crawler>`
//    * `--input_table: <name of the table created by the crawler>`
//    * `--output_bucket_url: <URL to the scaffold bucket created for the
//      user>`
// 6. Loop and get the job run until it returns one of the following states:
//    "SUCCEEDED", "STOPPED", "FAILED", or "TIMEOUT".
// 7. Output data is stored in a group of files in the user's S3 bucket.
//    Either direct the user to their location or download a file and display
//    the results inline.
// 8. List the jobs for the user's account.
// 9. Get job run details for a job run.
// 10. Delete the demo job.
// 11. Delete the database and tables created by the example.
// 12. Delete the crawler created by the example.

import ArgumentParser
import AWSS3
import Foundation
import Smithy

import AWSClientRuntime
import AWSGlue

struct ExampleCommand: ParsableCommand {
    @Option(help: "The AWS IAM role to use for AWS Glue calls.")
    var role: String

    @Option(help: "The Amazon S3 bucket to use for this example.")
    var bucket: String

    @Option(help: "The Amazon S3 URL of the data to crawl.")
    var s3url: String = "s3://crawler-public-us-east-1/flight/2016/csv"
```

```
    @Option(help: "The Python script to run as a job with AWS Glue.")
    var script: String = "./flight_etl_job_script.py"

    @Option(help: "The AWS Region to run AWS API calls in.")
    var awsRegion = "us-east-1"

    @Option(help: "A prefix string to use when naming tables.")
    var tablePrefix = "swift-glue-basics-table"

    @Option(
        help: ArgumentHelp("The level of logging for the Swift SDK to perform."),
        completion: .list([
            "critical",
            "debug",
            "error",
            "info",
            "notice",
            "trace",
            "warning"
        ])
    )
    var logLevel: String = "error"

    static var configuration = CommandConfiguration(
        commandName: "glue-scenario",
        abstract: """
        Demonstrates various features of AWS Glue.
        """,
        discussion: """
        An example showing how to use AWS Glue to create, run, and monitor
        crawlers and jobs.
        """
    )

    /// Generate and return a unique file name that begins with the specified
    /// string.
    ///
    /// - Parameters:
    ///   - prefix: Text to use at the beginning of the returned name.
    ///
    /// - Returns: A string containing a unique filename that begins with the
    ///   specified `prefix`.
    ///
```

```
    /// The returned name uses a random number between 1 million and 1 billion to
    /// provide reasonable certainty of uniqueness for the purposes of this
    /// example.
    func tempName(prefix: String) -> String {
        return "\(prefix)-\(Int.random(in: 1000000..<1000000000))"
    }

    /// Upload a file to an Amazon S3 bucket.
    ///
    /// - Parameters:
    ///   - s3Client: The S3 client to use when uploading the file.
    ///   - path: The local path of the source file to upload.
    ///   - toBucket: The name of the S3 bucket into which to upload the file.
    ///   - key: The key (name) to give the file in the S3 bucket.
    ///
    /// - Returns: `true` if the file is uploaded successfully, otherwise
`false`.
    func uploadFile(s3Client: S3Client, path: String, toBucket: String, key:
String) async -> Bool {
        do {
            let fileData: Data = try Data(contentsOf: URL(fileURLWithPath: path))
            let dataStream = ByteStream.data(fileData)
            _ = try await s3Client.putObject(
                input: PutObjectInput(
                    body: dataStream,
                    bucket: toBucket,
                    key: key
                )
            )
        } catch {
            print("*** An unexpected error occurred uploading the script to the
Amazon S3 bucket \"\(bucket)\".")
            return false
        }

        return true
    }

    /// Create a new AWS Glue crawler.
    ///
    /// - Parameters:
    ///   - glueClient: An AWS Glue client to use for the crawler.
    ///   - crawlerName: A name for the new crawler.
    ///   - iamRole: The name of an Amazon IAM role for the crawler to use.
```

```
   ///   - s3Path: The path of an Amazon S3 folder to use as a target location.
   ///   - cronSchedule: A `cron` schedule indicating when to run the crawler.
   ///   - databaseName: The name of an AWS Glue database to operate on.
   ///
   /// - Returns: `true` if the crawler is created successfully, otherwise
`false`.
   func createCrawler(glueClient: GlueClient, crawlerName: String, iamRole:
String,
                      s3Path: String, cronSchedule: String, databaseName:
String) async -> Bool {
       let s3Target = GlueClientTypes.S3Target(path: s3url)
       let targetList = GlueClientTypes.CrawlerTargets(s3Targets: [s3Target])

       do {
           _ = try await glueClient.createCrawler(
               input: CreateCrawlerInput(
                   databaseName: databaseName,
                   description: "Created by the AWS SDK for Swift Scenario
Example for AWS Glue.",
                   name: crawlerName,
                   role: iamRole,
                   schedule: cronSchedule,
                   tablePrefix: tablePrefix,
                   targets: targetList
               )
           )
       } catch _ as AlreadyExistsException {
           print("*** A crawler named \"\(crawlerName)\" already exists.")
           return false
       } catch _ as OperationTimeoutException {
           print("*** The attempt to create the AWS Glue crawler timed out.")
           return false
       } catch {
           print("*** An unexpected error occurred creating the AWS Glue
crawler: \(error.localizedDescription)")
           return false
       }

       return true
   }

   /// Delete an AWS Glue crawler.
   ///
   /// - Parameters:
```

```
    ///   - glueClient: The AWS Glue client to use.
    ///   - name: The name of the crawler to delete.
    ///
    /// - Returns: `true` if successful, otherwise `false`.
    func deleteCrawler(glueClient: GlueClient, name: String) async -> Bool {
        do {
            _ = try await glueClient.deleteCrawler(
                input: DeleteCrawlerInput(name: name)
            )
        } catch {
            return false
        }
        return true
    }

    /// Start running an AWS Glue crawler.
    ///
    /// - Parameters:
    ///   - glueClient: The AWS Glue client to use when starting the crawler.
    ///   - name: The name of the crawler to start running.
    ///
    /// - Returns: `true` if the crawler is started successfully, otherwise
`false`.
    func startCrawler(glueClient: GlueClient, name: String) async -> Bool {
        do {
            _ = try await glueClient.startCrawler(
                input: StartCrawlerInput(name: name)
            )
        } catch {
            print("*** An unexpected error occurred starting the crawler.")
            return false
        }

        return true
    }

    /// Get the state of the specified AWS Glue crawler.
    ///
    /// - Parameters:
    ///   - glueClient: The AWS Glue client to use.
    ///   - name: The name of the crawler whose state should be returned.
    ///
    /// - Returns: A `GlueClientTypes.CrawlerState` value describing the
    ///   state of the crawler.
```

```
   func getCrawlerState(glueClient: GlueClient, name: String) async ->
GlueClientTypes.CrawlerState {
       do {
           let output = try await glueClient.getCrawler(
               input: GetCrawlerInput(name: name)
           )

           // If the crawler or its state is `nil`, report that the crawler
           // is stopping. This may not be what you want for your
           // application but it works for this one!

           guard let crawler = output.crawler else {
               return GlueClientTypes.CrawlerState.stopping
           }
           guard let state = crawler.state else {
               return GlueClientTypes.CrawlerState.stopping
           }
           return state
       } catch {
           return GlueClientTypes.CrawlerState.stopping
       }
   }

   /// Wait until the specified crawler is ready to run.
   ///
   /// - Parameters:
   ///   - glueClient: The AWS Glue client to use.
   ///   - name: The name of the crawler to wait for.
   ///
   /// - Returns: `true` if the crawler is ready, `false` if the client is
   ///   stopping (and will therefore never be ready).
   func waitUntilCrawlerReady(glueClient: GlueClient, name: String) async ->
Bool {
       while true {
           let state = await getCrawlerState(glueClient: glueClient, name: name)

           if state == .ready {
               return true
           } else if state == .stopping {
               return false
           }

           // Wait four seconds before trying again.
```

```
            do {
                try await Task.sleep(for: .seconds(4))
            } catch {
                print("*** Error pausing the task.")
            }
        }
    }

    /// Create a new AWS Glue job.
    ///
    /// - Parameters:
    ///   - glueClient: The AWS Glue client to use.
    ///   - jobName: The name to give the new job.
    ///   - role: The IAM role for the job to use when accessing AWS services.
    ///   - scriptLocation: The AWS S3 URI of the script to be run by the job.
    ///
    /// - Returns: `true` if the job is created successfully, otherwise `false`.
    func createJob(glueClient: GlueClient, name jobName: String, role: String,
                   scriptLocation: String) async -> Bool {
        let command = GlueClientTypes.JobCommand(
            name: "glueetl",
            pythonVersion: "3",
            scriptLocation: scriptLocation
        )

        do {
            _ = try await glueClient.createJob(
                input: CreateJobInput(
                    command: command,
                    description: "Created by the AWS SDK for Swift Glue basic
scenario example.",
                    glueVersion: "3.0",
                    name: jobName,
                    numberOfWorkers: 10,
                    role: role,
                    workerType: .g1x
                )
            )
        } catch {
            return false
        }
        return true
    }
```

```
    /// Return a list of the AWS Glue jobs listed on the user's account.
    ///
    /// - Parameters:
    ///   - glueClient: The AWS Glue client to use.
    ///   - maxJobs: The maximum number of jobs to return (default: 100).
    ///
    /// - Returns: An array of strings listing the names of all available AWS
    ///   Glue jobs.
    func listJobs(glueClient: GlueClient, maxJobs: Int = 100) async -> [String] {
        var jobList: [String] = []
        var nextToken: String?

        repeat {
            do {
                let output = try await glueClient.listJobs(
                    input: ListJobsInput(
                        maxResults: maxJobs,
                        nextToken: nextToken
                    )
                )

                guard let jobs = output.jobNames else {
                    return jobList
                }

                jobList = jobList + jobs
                nextToken = output.nextToken
            } catch {
                return jobList
            }
        } while (nextToken != nil)

        return jobList
    }

    /// Delete an AWS Glue job.
    ///
    /// - Parameters:
    ///   - glueClient: The AWS Glue client to use.
    ///   - jobName: The name of the job to delete.
    ///
    /// - Returns: `true` if the job is successfully deleted, otherwise `false`.
    func deleteJob(glueClient: GlueClient, name jobName: String) async -> Bool {
        do {
```

```
            _ = try await glueClient.deleteJob(
                input: DeleteJobInput(jobName: jobName)
            )
        } catch {
            return false
        }
        return true
    }

    /// Create an AWS Glue database.
    ///
    /// - Parameters:
    ///   - glueClient: The AWS Glue client to use.
    ///   - databaseName: The name to give the new database.
    ///   - location: The URL of the source data to use with AWS Glue.
    ///
    /// - Returns: `true` if the database is created successfully, otherwise
`false`.
    func createDatabase(glueClient: GlueClient, name databaseName: String,
location: String) async -> Bool {
        let databaseInput = GlueClientTypes.DatabaseInput(
            description: "Created by the AWS SDK for Swift Glue basic scenario
example.",
            locationUri: location,
            name: databaseName
        )

        do {
            _ = try await glueClient.createDatabase(
                input: CreateDatabaseInput(
                    databaseInput: databaseInput
                )
            )
        } catch {
            return false
        }

        return true
    }

    /// Get the AWS Glue database with the specified name.
    ///
    /// - Parameters:
    ///   - glueClient: The AWS Glue client to use.
```

```
    ///   - name: The name of the database to return.
    ///
    /// - Returns: The `GlueClientTypes.Database` object describing the
    ///   specified database, or `nil` if an error occurs or the database
    ///   isn't found.
    func getDatabase(glueClient: GlueClient, name: String) async ->
GlueClientTypes.Database? {
        do {
            let output = try await glueClient.getDatabase(
                input: GetDatabaseInput(name: name)
            )

            return output.database
        } catch {
            return nil
        }
    }

    /// Returns a list of the tables in the specified database.
    ///
    /// - Parameters:
    ///   - glueClient: The AWS Glue client to use.
    ///   - databaseName: The name of the database whose tables are to be
    ///     returned.
    ///
    /// - Returns: An array of `GlueClientTypes.Table` objects, each
    ///   describing one table in the named database. An empty array indicates
    ///   that there are either no tables in the database, or an error
    ///   occurred before any tables could be found.
    func getTablesInDatabase(glueClient: GlueClient, databaseName: String) async
-> [GlueClientTypes.Table] {
        var tables: [GlueClientTypes.Table] = []
        var nextToken: String?

        repeat {
            do {
                let output = try await glueClient.getTables(
                    input: GetTablesInput(
                        databaseName: databaseName,
                        nextToken: nextToken
                    )
                )

                guard let tableList = output.tableList else {
```

```
                    return tables
                }

                tables = tables + tableList
                nextToken = output.nextToken
            } catch {
                return tables
            }
        } while nextToken != nil

        return tables
    }

    /// Delete the specified database.
    ///
    /// - Parameters:
    ///   - glueClient: The AWS Glue client to use.
    ///   - databaseName: The name of the database to delete.
    ///   - deleteTables: A Bool indicating whether or not to delete the
    ///     tables in the database before attempting to delete the database.
    ///
    /// - Returns: `true` if the database (and optionally its tables) are
    ///   deleted, otherwise `false`.
    func deleteDatabase(glueClient: GlueClient, name databaseName: String,
                        withTables deleteTables: Bool = false) async -> Bool {
        if deleteTables {
            var tableNames: [String] = []

            // Get a list of the names of all of the tables in the database.

            let tableList = await self.getTablesInDatabase(glueClient:
glueClient, databaseName: databaseName)
            for table in tableList {
                guard let name = table.name else {
                    continue
                }
                tableNames.append(name)
            }

            // Delete the tables. If there's only one table, use
            // `deleteTable()`, otherwise, use `batchDeleteTable()`. You can
            // use `batchDeleteTable()` for a single table, but this
            // demonstrates the use of `deleteTable()`.
```

```
            if tableNames.count == 1 {
                do {
                    print("    Deleting table...")
                    _ = try await glueClient.deleteTable(
                        input: DeleteTableInput(
                            databaseName: databaseName,
                            name: tableNames[0]
                        )
                    )
                } catch {
                    print("*** Unable to delete the table.")
                }
            } else {
                do {
                    print("    Deleting tables...")
                    _ = try await glueClient.batchDeleteTable(
                        input: BatchDeleteTableInput(
                            databaseName: databaseName,
                            tablesToDelete: tableNames
                        )
                    )
                } catch {
                    print("*** Unable to delete the tables.")
                }
            }
        }

        // Delete the database itself.

        do {
            print("    Deleting the database itself...")
            _ = try await glueClient.deleteDatabase(
                input: DeleteDatabaseInput(name: databaseName)
            )
        } catch {
            print("*** Unable to delete the database.")
            return false
        }
        return true
    }

    /// Start an AWS Glue job run.
    ///
    /// - Parameters:
```

```
    ///   - glueClient: The AWS Glue client to use.
    ///   - jobName: The name of the job to run.
    ///   - databaseName: The name of the AWS Glue database to run the job
against.
    ///   - tableName: The name of the table in the database to run the job
against.
    ///   - outputURL: The AWS S3 URI of the bucket location into which to
    ///     write the resulting output.
    ///
    /// - Returns: `true` if the job run is started successfully, otherwise
`false`.
    func startJobRun(glueClient: GlueClient, name jobName: String, databaseName:
String,
                     tableName: String, outputURL: String) async -> String? {
        do {
            let output = try await glueClient.startJobRun(
                input: StartJobRunInput(
                    arguments: [
                        "--input_database": databaseName,
                        "--input_table": tableName,
                        "--output_bucket_url": outputURL
                    ],
                    jobName: jobName,
                    numberOfWorkers: 10,
                    workerType: .g1x
                )
            )

            guard let id = output.jobRunId else {
                return nil
            }

            return id
        } catch {
            return nil
        }
    }

    /// Return a list of the job runs for the specified job.
    ///
    /// - Parameters:
    ///   - glueClient: The AWS Glue client to use.
    ///   - jobName: The name of the job for which to return its job runs.
    ///   - maxResults: The maximum number of job runs to return (default:
```

```
    ///     1000).
    ///
    /// - Returns: An array of `GlueClientTypes.JobRun` objects describing
    ///   each job run.
    func getJobRuns(glueClient: GlueClient, name jobName: String, maxResults:
Int? = nil) async -> [GlueClientTypes.JobRun] {
        do {
            let output = try await glueClient.getJobRuns(
                input: GetJobRunsInput(
                    jobName: jobName,
                    maxResults: maxResults
                )
            )

            guard let jobRuns = output.jobRuns else {
                print("*** No job runs found.")
                return []
            }

            return jobRuns
        } catch is EntityNotFoundException {
            print("*** The specified job name, \(jobName), doesn't exist.")
            return []
        } catch {
            print("*** Unexpected error getting job runs:")
            dump(error)
            return []
        }
    }

    /// Get information about a specific AWS Glue job run.
    ///
    /// - Parameters:
    ///   - glueClient: The AWS Glue client to use.
    ///   - jobName: The name of the job to return job run data for.
    ///   - id: The run ID of the specific job run to return.
    ///
    /// - Returns: A `GlueClientTypes.JobRun` object describing the state of
    ///   the job run, or `nil` if an error occurs.
    func getJobRun(glueClient: GlueClient, name jobName: String, id: String)
async -> GlueClientTypes.JobRun? {
        do {
            let output = try await glueClient.getJobRun(
                input: GetJobRunInput(
```

```
                    jobName: jobName,
                    runId: id
                )
            )

            return output.jobRun
        } catch {
            return nil
        }
    }

    /// Called by ``main()`` to run the bulk of the example.
    func runAsync() async throws {
        // A name to give the Python script upon upload to the Amazon S3
        // bucket.
        let scriptName = "jobscript.py"

        // Schedule string in `cron` format, as described here:
        // https://docs.aws.amazon.com/glue/latest/dg/monitor-data-warehouse-
schedule.html
        let cron = "cron(15 12 * * ? *)"

        let glueConfig = try await GlueClient.GlueClientConfiguration(region:
 awsRegion)
        let glueClient = GlueClient(config: glueConfig)

        let s3Config = try await S3Client.S3ClientConfiguration(region:
 awsRegion)
        let s3Client = S3Client(config: s3Config)

        // Create random names for things that need them.

        let crawlerName = tempName(prefix: "swift-glue-basics-crawler")
        let databaseName = tempName(prefix: "swift-glue-basics-db")

        // Create a name for the AWS Glue job.

        let jobName = tempName(prefix: "scenario-job")

        // The URL of the Python script on S3.

        let scriptURL = "s3://\(bucket)/\(scriptName)"

        print("Welcome to the AWS SDK for Swift basic scenario for AWS Glue!")
```

```
        //===================================================================
        // 0. Upload the Python script to the target bucket so it's available
        //    for use by the Amazon Glue service.
        //===================================================================

        print("Uploading the Python script: \(script) as key \(scriptName)")
        print("Destination bucket: \(bucket)")
        if !(await uploadFile(s3Client: s3Client, path: script, toBucket: bucket,
key: scriptName)) {
            return
        }

        //===================================================================
        // 1. Create the database and crawler using the randomized names
        //    generated previously.
        //===================================================================

        print("Creating database \"\(databaseName)\"...")
        if !(await createDatabase(glueClient: glueClient, name: databaseName,
location: s3url)) {
            print("*** Unable to create the database.")
            return
        }

        print("Creating crawler \"\(crawlerName)\"...")
        if !(await createCrawler(glueClient: glueClient, crawlerName:
crawlerName,
                                 iamRole: role, s3Path: s3url, cronSchedule:
cron,
                                 databaseName: databaseName)) {
            return
        }

        //===================================================================
        // 2. Start the crawler, then wait for it to be ready.
        //===================================================================

        print("Starting the crawler and waiting until it's ready...")
        if !(await startCrawler(glueClient: glueClient, name: crawlerName)) {
            _ = await deleteCrawler(glueClient: glueClient, name: crawlerName)
            return
        }
```

```
        if !(await waitUntilCrawlerReady(glueClient: glueClient, name:
crawlerName)) {
            _ = await deleteCrawler(glueClient: glueClient, name: crawlerName)
        }

        //=========================================================================
        // 3. Get the database and table created by the crawler.
        //=========================================================================

        print("Getting the crawler's database...")
        let database = await getDatabase(glueClient: glueClient, name:
databaseName)

        guard let database else {
            print("*** Unable to get the database.")
            return
        }
        print("Database URI: \(database.locationUri ?? "<unknown>")")

        let tableList = await getTablesInDatabase(glueClient: glueClient,
databaseName: databaseName)

        print("Found \(tableList.count) table(s):")
        for table in tableList {
            print("  \(table.name ?? "<unnamed>")")
        }

        if tableList.count != 1 {
            print("*** Incorrect number of tables found. There should only be
one.")
            _ = await deleteDatabase(glueClient: glueClient, name: databaseName,
withTables: true)
            _ = await deleteCrawler(glueClient: glueClient, name: crawlerName)
            return
        }

        guard let tableName = tableList[0].name else {
            print("*** Table is unnamed.")
            _ = await deleteDatabase(glueClient: glueClient, name: databaseName,
withTables: true)
            _ = await deleteCrawler(glueClient: glueClient, name: crawlerName)
            return
        }
```

```
        //====================================================================
        // 4. Create a job.
        //====================================================================

        print("Creating a job...")
        if !(await createJob(glueClient: glueClient, name: jobName, role: role,
                             scriptLocation: scriptURL)) {
            _ = await deleteDatabase(glueClient: glueClient, name: databaseName,
withTables: true)
            _ = await deleteCrawler(glueClient: glueClient, name: crawlerName)
            return
        }

        //====================================================================
        // 5. Start a job run.
        //====================================================================

        print("Starting the job...")

        // Construct the Amazon S3 URL for the job run's output. This is in
        // the bucket specified on the command line, with a folder name that's
        // unique for this job run.

        let timeStamp = Date().timeIntervalSince1970
        let jobPath = "\(jobName)-\(Int(timeStamp))"
        let outputURL = "s3://\(bucket)/\(jobPath)"

        // Start the job run.

        let jobRunID = await startJobRun(glueClient: glueClient, name: jobName,
                                         databaseName: databaseName,
                                         tableName: tableName,
                                         outputURL: outputURL)

        guard let jobRunID else {
            print("*** Job run ID is invalid.")
            _ = await deleteJob(glueClient: glueClient, name: jobName)
            _ = await deleteDatabase(glueClient: glueClient, name: databaseName,
withTables: true)
            _ = await deleteCrawler(glueClient: glueClient, name: crawlerName)
            return
        }

        //====================================================================
```

```
        // 6. Wait for the job run to indicate that the run is complete.
        //=====================================================================

        print("Waiting for job run to end...")

        var jobRunFinished = false
        var jobRunState: GlueClientTypes.JobRunState

        repeat {
            let jobRun = await getJobRun(glueClient: glueClient, name: jobName,
 id: jobRunID)
            guard let jobRun else {
                print("*** Unable to get the job run.")
                _ = await deleteJob(glueClient: glueClient, name: jobName)
                _ = await deleteDatabase(glueClient: glueClient, name:
 databaseName, withTables: true)
                _ = await deleteCrawler(glueClient: glueClient, name:
 crawlerName)
                return
            }
            jobRunState = jobRun.jobRunState ?? .failed

            //
=====================================================================
            // 7. Output where to find the data if the job run was successful.
            //    If the job run failed for any reason, output an appropriate
            //    error message.
            //
=====================================================================

            switch jobRunState {
                case .succeeded:
                    print("Job run succeeded. JSON files are in the Amazon S3
 path:")
                    print("    \(outputURL)")
                    jobRunFinished = true
                case .stopped:
                    jobRunFinished = true
                case .error:
                    print("*** Error: Job run ended in an error.
 \(jobRun.errorMessage ?? "")")
                    jobRunFinished = true
                case .failed:
```

```
                    print("*** Error: Job run failed. \(jobRun.errorMessage ??
""")")
                    jobRunFinished = true
                case .timeout:
                    print("*** Warning: Job run timed out.")
                    jobRunFinished = true
                default:
                    do {
                        try await Task.sleep(for: .milliseconds(250))
                    } catch {
                        print("*** Error pausing the task.")
                    }
            }
        } while jobRunFinished != true

        //=========================================================================
        // 7.5. List the job runs for this job, showing each job run's ID and
        // its execution time.
        //=========================================================================

        print("Getting all job runs for the job \(jobName):")
        let jobRuns = await getJobRuns(glueClient: glueClient, name: jobName)

        if jobRuns.count == 0 {
            print("    <no job runs found>")
        } else {
            print("Found \(jobRuns.count) job runs... listing execution times:")
            for jobRun in jobRuns {
                print("    \(jobRun.id ?? "<unnamed>"): \(jobRun.executionTime)
seconds")
            }
        }

        //=========================================================================
        // 8. List the jobs for the user's account.
        //=========================================================================

        print("\nThe account has the following jobs:")
        let jobs = await listJobs(glueClient: glueClient)

        if jobs.count == 0 {
            print("    <no jobs found>")
        } else {
            for job in jobs {
```

```
                print("    \(job)")
            }
        }

        //===========================================================================
        // 9. Get the job run details for a job run.
        //===========================================================================

        print("Information about the job run:")
        let jobRun = await getJobRun(glueClient: glueClient, name: jobName, id:
jobRunID)

        guard let jobRun else {
            print("*** Unable to retrieve the job run.")
            _ = await deleteJob(glueClient: glueClient, name: jobName)
            _ = await deleteDatabase(glueClient: glueClient, name: databaseName,
withTables: true)
            _ = await deleteCrawler(glueClient: glueClient, name: crawlerName)
            return
        }

        let startDate = jobRun.startedOn ?? Date(timeIntervalSince1970: 0)
        let endDate = jobRun.completedOn ?? Date(timeIntervalSince1970: 0)
        let dateFormatter: DateFormatter = DateFormatter()
        dateFormatter.dateStyle = .long
        dateFormatter.timeStyle = .long

        print("    Started at: \(dateFormatter.string(from: startDate))")
        print("  Completed at: \(dateFormatter.string(from: endDate))")

        //===========================================================================
        // 10. Delete the job.
        //===========================================================================

        print("\nDeleting the job...")
        _ = await deleteJob(glueClient: glueClient, name: jobName)

        //===========================================================================
        // 11. Delete the database and tables created by this example.
        //===========================================================================

        print("Deleting the database...")
        _ = await deleteDatabase(glueClient: glueClient, name: databaseName,
withTables: true)
```

```
        //===========================================================================
        // 12. Delete the crawler.
        //===========================================================================

        print("Deleting the crawler...")
        if !(await deleteCrawler(glueClient: glueClient, name: crawlerName)) {
            return
        }
    }
}

/// The program's asynchronous entry point.
@main
struct Main {
    static func main() async {
        let args = Array(CommandLine.arguments.dropFirst())

        do {
            let command = try ExampleCommand.parse(args)
            try await command.runAsync()
        } catch {
            ExampleCommand.exit(withError: error)
        }
    }
}
```

- Para obtener información sobre la API, consulte los siguientes temas en la Referencia de la API de AWS SDK para Swift.
  - CreateCrawler
  - CreateJob
  - DeleteCrawler
  - DeleteDatabase
  - DeleteJob
  - DeleteTable
  - GetCrawler
  - GetDatabase
  - GetDatabases

- GetJob
- GetJobRun
- GetJobRuns
- GetTables
- ListJobs
- StartCrawler
- StartJobRun

Para obtener una lista completa de las guías para desarrolladores de AWS SDK y ejemplos de código, consulte Cómo utilizar este servicio con un AWS SDK. En este tema también se incluye información sobre cómo comenzar a utilizar el SDK y detalles sobre sus versiones anteriores.

Acciones de AWS Glue con un AWS SDK

Los siguientes ejemplos de código muestran cómo llevar a cabo acciones individuales de AWS Glue con AWS SDK. En cada ejemplo se incluye un enlace a GitHub, con instrucciones de configuración y ejecución del código.

Los siguientes ejemplos incluyen solo las acciones que se utilizan con mayor frecuencia. Para ver una lista completa, consulte la Referencia de la API de AWS Glue.

Ejemplos

- Cómo utilizar CreateCrawler con un AWS SDK
- Uso de CreateJob con un SDK de AWS o la CLI
- Cómo utilizar DeleteCrawler con un AWS SDK
- Cómo utilizar DeleteDatabase con un AWS SDK
- Uso de DeleteJob con un SDK de AWS o la CLI
- Cómo utilizar DeleteTable con un AWS SDK
- Cómo utilizar GetCrawler con un AWS SDK
- Cómo utilizar GetDatabase con un AWS SDK
- Uso de GetDatabases con un SDK de AWS o la CLI
- Uso de GetJob con un SDK de AWS o la CLI
- Uso de GetJobRun con un SDK de AWS o la CLI
- Uso de GetJobRuns con un SDK de AWS o la CLI

- Uso de GetTables con un SDK de AWS o la CLI
- Cómo utilizar ListJobs con un AWS SDK
- Uso de StartCrawler con un SDK de AWS o la CLI
- Uso de StartJobRun con un SDK de AWS o la CLI

Cómo utilizar **`CreateCrawler`** con un AWS SDK

Los ejemplos de códigos que se muestran a continuación muestran cómo se utiliza `CreateCrawler`.

Los ejemplos de acciones son extractos de código de programas más grandes y deben ejecutarse en contexto. Puede ver esta acción en contexto en el siguiente ejemplo de código:

- Conceptos básicos

.NET

SDK para .NET

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
    /// <summary>
    /// Create an AWS Glue crawler.
    /// </summary>
    /// <param name="crawlerName">The name for the crawler.</param>
    /// <param name="crawlerDescription">A description of the crawler.</param>
    /// <param name="role">The AWS Identity and Access Management (IAM) role to
    /// be assumed by the crawler.</param>
    /// <param name="schedule">The schedule on which the crawler will be
executed.</param>
    /// <param name="s3Path">The path to the Amazon Simple Storage Service
(Amazon S3)
    /// bucket where the Python script has been stored.</param>
    /// <param name="dbName">The name to use for the database that will be
    /// created by the crawler.</param>
```

```
    /// <returns>A Boolean value indicating the success of the action.</returns>
    public async Task<bool> CreateCrawlerAsync(
        string crawlerName,
        string crawlerDescription,
        string role,
        string schedule,
        string s3Path,
        string dbName)
    {
        var s3Target = new S3Target
        {
            Path = s3Path,
        };

        var targetList = new List<S3Target>
        {
            s3Target,
        };

        var targets = new CrawlerTargets
        {
            S3Targets = targetList,
        };

        var crawlerRequest = new CreateCrawlerRequest
        {
            DatabaseName = dbName,
            Name = crawlerName,
            Description = crawlerDescription,
            Targets = targets,
            Role = role,
            Schedule = schedule,
        };

        var response = await _amazonGlue.CreateCrawlerAsync(crawlerRequest);
        return response.HttpStatusCode == System.Net.HttpStatusCode.OK;
    }
```

- Para obtener información sobre la API, consulte CreateCrawler en la Referencia de la API de AWS SDK para .NET.

C++

SDK para C++

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
        Aws::Client::ClientConfiguration clientConfig;
        // Optional: Set to the AWS Region in which the bucket was created
(overrides config file).
        // clientConfig.region = "us-east-1";

    Aws::Glue::GlueClient client(clientConfig);

        Aws::Glue::Model::S3Target s3Target;
        s3Target.SetPath("s3://crawler-public-us-east-1/flight/2016/csv");
        Aws::Glue::Model::CrawlerTargets crawlerTargets;
        crawlerTargets.AddS3Targets(s3Target);

        Aws::Glue::Model::CreateCrawlerRequest request;
        request.SetTargets(crawlerTargets);
        request.SetName(CRAWLER_NAME);
        request.SetDatabaseName(CRAWLER_DATABASE_NAME);
        request.SetTablePrefix(CRAWLER_DATABASE_PREFIX);
        request.SetRole(roleArn);

        Aws::Glue::Model::CreateCrawlerOutcome outcome =
client.CreateCrawler(request);

        if (outcome.IsSuccess()) {
            std::cout << "Successfully created the crawler." << std::endl;
        }
        else {
            std::cerr << "Error creating a crawler. " <<
outcome.GetError().GetMessage()
                      << std::endl;
            deleteAssets("", CRAWLER_DATABASE_NAME, "", bucketName,
clientConfig);
            return false;
```

```
        }
```

- Para obtener información sobre la API, consulte CreateCrawler en la Referencia de la API de AWS SDK para C++.

Java

SDK para Java 2.x

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
   /**
    * Creates a new AWS Glue crawler using the AWS Glue Java API.
    *
    * @param glueClient  the AWS Glue client used to interact with the AWS Glue
service
    * @param iam         the IAM role that the crawler will use to access the
data source
    * @param s3Path      the S3 path that the crawler will scan for data
    * @param cron        the cron expression that defines the crawler's schedule
    * @param dbName      the name of the AWS Glue database where the crawler
will store the metadata
    * @param crawlerName the name of the crawler to be created
    */
   public static void createGlueCrawler(GlueClient glueClient,
                                         String iam,
                                         String s3Path,
                                         String cron,
                                         String dbName,
                                         String crawlerName) {

       try {
           S3Target s3Target = S3Target.builder()
               .path(s3Path)
               .build();
```

```
            List<S3Target> targetList = new ArrayList<>();
            targetList.add(s3Target);
            CrawlerTargets targets = CrawlerTargets.builder()
                .s3Targets(targetList)
                .build();

            CreateCrawlerRequest crawlerRequest = CreateCrawlerRequest.builder()
                .databaseName(dbName)
                .name(crawlerName)
                .description("Created by the AWS Glue Java API")
                .targets(targets)
                .role(iam)
                .schedule(cron)
                .build();

            glueClient.createCrawler(crawlerRequest);
            System.out.println(crawlerName + " was successfully created");

        } catch (GlueException e) {
            throw e;
        }
    }
```

- Para obtener información sobre la API, consulte CreateCrawler en la Referencia de la API de AWS SDK for Java 2.x.

JavaScript

SDK para JavaScript (v3)

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
const createCrawler = (name, role, dbName, tablePrefix, s3TargetPath) => {
  const client = new GlueClient({});
```

```
  const command = new CreateCrawlerCommand({
    Name: name,
    Role: role,
    DatabaseName: dbName,
    TablePrefix: tablePrefix,
    Targets: {
      S3Targets: [{ Path: s3TargetPath }],
    },
  });

  return client.send(command);
};
```

- Para obtener información sobre la API, consulte CreateCrawler en la Referencia de la API de AWS SDK para JavaScript.

Kotlin

SDK para Kotlin

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
suspend fun createGlueCrawler(
    iam: String?,
    s3Path: String?,
    cron: String?,
    dbName: String?,
    crawlerName: String,
) {
    val s3Target =
        S3Target {
            path = s3Path
        }

    // Add the S3Target to a list.
    val targetList = mutableListOf<S3Target>()
```

```
    targetList.add(s3Target)

    val targetOb =
        CrawlerTargets {
            s3Targets = targetList
        }

    val request =
        CreateCrawlerRequest {
            databaseName = dbName
            name = crawlerName
            description = "Created by the AWS Glue Kotlin API"
            targets = targetOb
            role = iam
            schedule = cron
        }

    GlueClient.fromEnvironment { region = "us-west-2" }.use { glueClient ->
        glueClient.createCrawler(request)
        println("$crawlerName was successfully created")
    }
}
```

- Para obtener información sobre la API, consulte CreateCrawler en la Referencia de la API de AWS SDK para Kotlin.

PHP

SDK para PHP

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
        $crawlerName = "example-crawler-test-" . $uniqid;

        $role = $iamService->getRole("AWSGlueServiceRole-DocExample");
```

```
        $path = 's3://crawler-public-us-east-1/flight/2016/csv';
        $glueService->createCrawler($crawlerName, $role['Role']['Arn'],
$databaseName, $path);

    public function createCrawler($crawlerName, $role, $databaseName, $path):
Result
    {
        return $this->customWaiter(function () use ($crawlerName, $role,
$databaseName, $path) {
            return $this->glueClient->createCrawler([
                'Name' => $crawlerName,
                'Role' => $role,
                'DatabaseName' => $databaseName,
                'Targets' => [
                    'S3Targets' =>
                        [[
                            'Path' => $path,
                        ]]
                ],
            ]);
        });
    }
```

- Para obtener información sobre la API, consulte CreateCrawler en la Referencia de la API de AWS SDK para PHP.

Python

SDK para Python (Boto3)

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""

    def __init__(self, glue_client):
```

```
        """
        :param glue_client: A Boto3 Glue client.
        """
        self.glue_client = glue_client


    def create_crawler(self, name, role_arn, db_name, db_prefix, s3_target):
        """
        Creates a crawler that can crawl the specified target and populate a
        database in your AWS Glue Data Catalog with metadata that describes the
data
        in the target.

        :param name: The name of the crawler.
        :param role_arn: The Amazon Resource Name (ARN) of an AWS Identity and
Access
                         Management (IAM) role that grants permission to let AWS
Glue
                         access the resources it needs.
        :param db_name: The name to give the database that is created by the
crawler.
        :param db_prefix: The prefix to give any database tables that are created
by
                          the crawler.
        :param s3_target: The URL to an S3 bucket that contains data that is
                          the target of the crawler.
        """
        try:
            self.glue_client.create_crawler(
                Name=name,
                Role=role_arn,
                DatabaseName=db_name,
                TablePrefix=db_prefix,
                Targets={"S3Targets": [{"Path": s3_target}]},
            )
        except ClientError as err:
            logger.error(
                "Couldn't create crawler. Here's why: %s: %s",
                err.response["Error"]["Code"],
                err.response["Error"]["Message"],
            )
            raise
```

- Para obtener información sobre la API, consulte CreateCrawler en la Referencia de la API de AWS SDK para Python (Boto3).

Ruby

SDK para Ruby

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
# The `GlueWrapper` class serves as a wrapper around the AWS Glue API, providing
 a simplified interface for common operations.
# It encapsulates the functionality of the AWS SDK for Glue and provides methods
 for interacting with Glue crawlers, databases, tables, jobs, and S3 resources.
# The class initializes with a Glue client and a logger, allowing it to make API
 calls and log any errors or informational messages.
class GlueWrapper
  def initialize(glue_client, logger)
    @glue_client = glue_client
    @logger = logger
  end

  # Creates a new crawler with the specified configuration.
  #
  # @param name [String] The name of the crawler.
  # @param role_arn [String] The ARN of the IAM role to be used by the crawler.
  # @param db_name [String] The name of the database where the crawler stores its
 metadata.
  # @param db_prefix [String] The prefix to be added to the names of tables that
 the crawler creates.
  # @param s3_target [String] The S3 path that the crawler will crawl.
  # @return [void]
  def create_crawler(name, role_arn, db_name, _db_prefix, s3_target)
    @glue_client.create_crawler(
      name: name,
```

```
      role: role_arn,
      database_name: db_name,
      targets: {
        s3_targets: [
          {
            path: s3_target
          }
        ]
      }
    )
  rescue Aws::Glue::Errors::GlueException => e
    @logger.error("Glue could not create crawler: \n#{e.message}")
    raise
  end
```

- Para obtener información sobre la API, consulte CreateCrawler en la Referencia de la API de AWS SDK para Ruby.

Rust

SDK para Rust

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
        let create_crawler = glue
            .create_crawler()
            .name(self.crawler())
            .database_name(self.database())
            .role(self.iam_role.expose_secret())
            .targets(
                CrawlerTargets::builder()
                    .s3_targets(S3Target::builder().path(CRAWLER_TARGET).build())
                    .build(),
            )
            .send()
            .await;
```

```
        match create_crawler {
            Err(err) => {
                let glue_err: aws_sdk_glue::Error = err.into();
                match glue_err {
                    aws_sdk_glue::Error::AlreadyExistsException(_) => {
                        info!("Using existing crawler");
                        Ok(())
                    }
                    _ => Err(GlueMvpError::GlueSdk(glue_err)),
                }
            }
            Ok(_) => Ok(()),
        }?;
```

- Para obtener información sobre la API, consulte CreateCrawler en la Referencia de la API de AWS SDK para Rust.

Swift

SDK para Swift

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
import AWSClientRuntime
import AWSGlue

    /// Create a new AWS Glue crawler.
    ///
    /// - Parameters:
    ///   - glueClient: An AWS Glue client to use for the crawler.
    ///   - crawlerName: A name for the new crawler.
    ///   - iamRole: The name of an Amazon IAM role for the crawler to use.
    ///   - s3Path: The path of an Amazon S3 folder to use as a target location.
    ///   - cronSchedule: A `cron` schedule indicating when to run the crawler.
    ///   - databaseName: The name of an AWS Glue database to operate on.
```

```
    ///
    /// - Returns: `true` if the crawler is created successfully, otherwise
`false`.
    func createCrawler(glueClient: GlueClient, crawlerName: String, iamRole:
String,
                       s3Path: String, cronSchedule: String, databaseName:
String) async -> Bool {
        let s3Target = GlueClientTypes.S3Target(path: s3url)
        let targetList = GlueClientTypes.CrawlerTargets(s3Targets: [s3Target])

        do {
            _ = try await glueClient.createCrawler(
                input: CreateCrawlerInput(
                    databaseName: databaseName,
                    description: "Created by the AWS SDK for Swift Scenario
Example for AWS Glue.",
                    name: crawlerName,
                    role: iamRole,
                    schedule: cronSchedule,
                    tablePrefix: tablePrefix,
                    targets: targetList
                )
            )
        } catch _ as AlreadyExistsException {
            print("*** A crawler named \"\(crawlerName)\" already exists.")
            return false
        } catch _ as OperationTimeoutException {
            print("*** The attempt to create the AWS Glue crawler timed out.")
            return false
        } catch {
            print("*** An unexpected error occurred creating the AWS Glue
crawler: \(error.localizedDescription)")
            return false
        }

        return true
    }
```

- Para obtener detalles sobre la API, consulte CreateCrawler en la Referencia de la API de AWS SDK para Swift.

Para obtener una lista completa de las guías para desarrolladores de AWS SDK y ejemplos de código, consulte Cómo utilizar este servicio con un AWS SDK. En este tema también se incluye información sobre cómo comenzar a utilizar el SDK y detalles sobre sus versiones anteriores.

Uso de **`CreateJob`** con un SDK de AWS o la CLI

Los ejemplos de códigos que se muestran a continuación muestran cómo se utiliza `CreateJob`.

Los ejemplos de acciones son extractos de código de programas más grandes y deben ejecutarse en contexto. Puede ver esta acción en contexto en el siguiente ejemplo de código:

- Conceptos básicos

.NET

SDK para .NET

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
   /// <summary>
   /// Create an AWS Glue job.
   /// </summary>
   /// <param name="jobName">The name of the job.</param>
   /// <param name="roleName">The name of the IAM role to be assumed by
   /// the job.</param>
   /// <param name="description">A description of the job.</param>
   /// <param name="scriptUrl">The URL to the script.</param>
   /// <returns>A Boolean value indicating the success of the action.</returns>
   public async Task<bool> CreateJobAsync(string dbName, string tableName,
string bucketUrl, string jobName, string roleName, string description, string
scriptUrl)
   {
       var command = new JobCommand
       {
           PythonVersion = "3",
           Name = "glueetl",
           ScriptLocation = scriptUrl,
```

```
        };

        var arguments = new Dictionary<string, string>
        {
            { "--input_database", dbName },
            { "--input_table", tableName },
            { "--output_bucket_url", bucketUrl }
        };

        var request = new CreateJobRequest
        {
            Command = command,
            DefaultArguments = arguments,
            Description = description,
            GlueVersion = "3.0",
            Name = jobName,
            NumberOfWorkers = 10,
            Role = roleName,
            WorkerType = "G.1X"
        };

        var response = await _amazonGlue.CreateJobAsync(request);
        return response.HttpStatusCode == HttpStatusCode.OK;
    }
```

- Para obtener información sobre la API, consulte CreateJob en la Referencia de la API de AWS SDK para .NET.

C++

SDK para C++

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
        Aws::Client::ClientConfiguration clientConfig;
```

```
        // Optional: Set to the AWS Region in which the bucket was created
(overrides config file).
        // clientConfig.region = "us-east-1";

    Aws::Glue::GlueClient client(clientConfig);

        Aws::Glue::Model::CreateJobRequest request;
        request.SetName(JOB_NAME);
        request.SetRole(roleArn);
        request.SetGlueVersion(GLUE_VERSION);

        Aws::Glue::Model::JobCommand command;
        command.SetName(JOB_COMMAND_NAME);
        command.SetPythonVersion(JOB_PYTHON_VERSION);
        command.SetScriptLocation(
                Aws::String("s3://") + bucketName + "/" + PYTHON_SCRIPT);
        request.SetCommand(command);

        Aws::Glue::Model::CreateJobOutcome outcome = client.CreateJob(request);

        if (outcome.IsSuccess()) {
            std::cout << "Successfully created the job." << std::endl;
        }
        else {
            std::cerr << "Error creating the job. " <<
outcome.GetError().GetMessage()
                      << std::endl;
            deleteAssets(CRAWLER_NAME, CRAWLER_DATABASE_NAME, "", bucketName,
                         clientConfig);
            return false;
        }
```

- Para obtener información sobre la API, consulte CreateJob en la Referencia de la API de AWS SDK para C++.

CLI

AWS CLI

Creación de un trabajo a fin de transformar datos

El siguiente ejemplo de `create-job` crea un trabajo de streaming que ejecuta un script almacenado en S3.

```
aws glue create-job \
    --name my-testing-job \
    --role AWSGlueServiceRoleDefault \
    --command '{ \
        "Name": "gluestreaming", \
        "ScriptLocation": "s3://amzn-s3-demo-bucket/folder/" \
    }' \
    --region us-east-1 \
    --output json \
    --default-arguments '{ \
        "--job-language":"scala", \
        "--class":"GlueApp" \
    }' \
    --profile my-profile \
    --endpoint https://glue.us-east-1.amazonaws.com
```

Contenido de `test_script.scala`:

```
import com.amazonaws.services.glue.ChoiceOption
import com.amazonaws.services.glue.GlueContext
import com.amazonaws.services.glue.MappingSpec
import com.amazonaws.services.glue.ResolveSpec
import com.amazonaws.services.glue.errors.CallSite
import com.amazonaws.services.glue.util.GlueArgParser
import com.amazonaws.services.glue.util.Job
import com.amazonaws.services.glue.util.JsonOptions
import org.apache.spark.SparkContext
import scala.collection.JavaConverters._

object GlueApp {
    def main(sysArgs: Array[String]) {
        val spark: SparkContext = new SparkContext()
        val glueContext: GlueContext = new GlueContext(spark)
        // @params: [JOB_NAME]
        val args = GlueArgParser.getResolvedOptions(sysArgs,
 Seq("JOB_NAME").toArray)
        Job.init(args("JOB_NAME"), glueContext, args.asJava)
        // @type: DataSource
        // @args: [database = "tempdb", table_name = "s3-source",
 transformation_ctx = "datasource0"]
```

```
        // @return: datasource0
        // @inputs: []
        val datasource0 = glueContext.getCatalogSource(database = "tempdb",
 tableName = "s3-source", redshiftTmpDir = "", transformationContext =
 "datasource0").getDynamicFrame()
        // @type: ApplyMapping
        // @args: [mapping = [("sensorid", "int", "sensorid", "int"),
 ("currenttemperature", "int", "currenttemperature", "int"), ("status", "string",
 "status", "string")], transformation_ctx = "applymapping1"]
        // @return: applymapping1
        // @inputs: [frame = datasource0]
        val applymapping1 = datasource0.applyMapping(mappings = Seq(("sensorid",
 "int", "sensorid", "int"), ("currenttemperature", "int", "currenttemperature",
 "int"), ("status", "string", "status", "string")), caseSensitive = false,
 transformationContext = "applymapping1")
        // @type: SelectFields
        // @args: [paths = ["sensorid", "currenttemperature", "status"],
 transformation_ctx = "selectfields2"]
        // @return: selectfields2
        // @inputs: [frame = applymapping1]
        val selectfields2 = applymapping1.selectFields(paths = Seq("sensorid",
 "currenttemperature", "status"), transformationContext = "selectfields2")
        // @type: ResolveChoice
        // @args: [choice = "MATCH_CATALOG", database = "tempdb", table_name =
 "my-s3-sink", transformation_ctx = "resolvechoice3"]
        // @return: resolvechoice3
        // @inputs: [frame = selectfields2]
        val resolvechoice3 = selectfields2.resolveChoice(choiceOption =
 Some(ChoiceOption("MATCH_CATALOG")), database = Some("tempdb"), tableName =
 Some("my-s3-sink"), transformationContext = "resolvechoice3")
        // @type: DataSink
        // @args: [database = "tempdb", table_name = "my-s3-sink",
 transformation_ctx = "datasink4"]
        // @return: datasink4
        // @inputs: [frame = resolvechoice3]
        val datasink4 = glueContext.getCatalogSink(database = "tempdb",
 tableName = "my-s3-sink", redshiftTmpDir = "", transformationContext =
 "datasink4").writeDynamicFrame(resolvechoice3)
        Job.commit()
    }
}
```

Salida:

```
{
    "Name": "my-testing-job"
}
```

Para obtener más información, consulte Creación de trabajos en AWS Glue en la Guía para desarrolladores de AWS Glue.

- Para obtener más información sobre la API, consulte CreateJob en la Referencia de comandos de la AWS CLI.

Java

SDK para Java 2.x

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
   /**
    * Creates a new AWS Glue job.
    *
    * @param glueClient     the AWS Glue client to use for the operation
    * @param jobName        the name of the job to create
    * @param iam            the IAM role to associate with the job
    * @param scriptLocation the location of the script to be used by the job
    * @throws GlueException if there is an error creating the job
    */
   public static void createJob(GlueClient glueClient, String jobName, String
iam, String scriptLocation) {
       try {
           JobCommand command = JobCommand.builder()
               .pythonVersion("3")
               .name("glueetl")
               .scriptLocation(scriptLocation)
               .build();

           CreateJobRequest jobRequest = CreateJobRequest.builder()
               .description("A Job created by using the AWS SDK for Java V2")
```

```
                .glueVersion("2.0")
                .workerType(WorkerType.G_1_X)
                .numberOfWorkers(10)
                .name(jobName)
                .role(iam)
                .command(command)
                .build();

            glueClient.createJob(jobRequest);
            System.out.println(jobName + " was successfully created.");

        } catch (GlueException e) {
            throw e;
        }
    }
```

- Para obtener información sobre la API, consulte CreateJob en la Referencia de la API de AWS SDK for Java 2.x.

JavaScript

SDK para JavaScript (v3)

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
const createJob = (name, role, scriptBucketName, scriptKey) => {
  const client = new GlueClient({});

  const command = new CreateJobCommand({
    Name: name,
    Role: role,
    Command: {
      Name: "glueetl",
      PythonVersion: "3",
      ScriptLocation: `s3://${scriptBucketName}/${scriptKey}`,
    },
```

```
    GlueVersion: "3.0",
  });

  return client.send(command);
};
```

- Para obtener información sobre la API, consulte CreateJob en la Referencia de la API de AWS SDK para JavaScript.

PHP

SDK para PHP

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
        $role = $iamService->getRole("AWSGlueServiceRole-DocExample");

        $jobName = 'test-job-' . $uniqid;

        $scriptLocation = "s3://$bucketName/run_job.py";
        $job = $glueService->createJob($jobName, $role['Role']['Arn'],
$scriptLocation);

    public function createJob($jobName, $role, $scriptLocation, $pythonVersion =
'3', $glueVersion = '3.0'): Result
    {
        return $this->glueClient->createJob([
            'Name' => $jobName,
            'Role' => $role,
            'Command' => [
                'Name' => 'glueetl',
                'ScriptLocation' => $scriptLocation,
                'PythonVersion' => $pythonVersion,
            ],
            'GlueVersion' => $glueVersion,
        ]);
```

```
    }
```

- Para obtener información sobre la API, consulte CreateJob en la Referencia de la API de AWS SDK para PHP.

PowerShell

Herramientas para PowerShell V4

Ejemplo 1: en este ejemplo se muestra cómo crear un trabajo nuevo en AWS Glue. El valor del nombre del comando siempre será **`glueetl`**. AWS Glue es compatible con la ejecución de scripts de trabajos escritos en Python o Scala. En este ejemplo, el script del trabajo (MyTestGlueJob.py) está escrito en Python. Los parámetros de Python se especifican en la variable de **`$DefArgs`** y luego se transfieren al comando de PowerShell en el parámetro de **`DefaultArguments`**, el cual admite una tabla hash. Los parámetros en la variable **`$JobParams`** provienen de la API CreateJob, la cual está documentada en la sección Trabajos (https://docs.aws.amazon.com/glue/latest/dg/aws-glue-api-jobs-job.html) de la referencia de API de AWS Glue.

```
$Command = New-Object Amazon.Glue.Model.JobCommand
$Command.Name = 'glueetl'
$Command.ScriptLocation = 's3://amzn-s3-demo-source-bucket/admin/
MyTestGlueJob.py'
$Command

$Source = "source_test_table"
$Target = "target_test_table"
$Connections = $Source, $Target

$DefArgs = @{
     '--TempDir' = 's3://amzn-s3-demo-bucket/admin'
     '--job-bookmark-option' = 'job-bookmark-disable'
     '--job-language' = 'python'
     }
$DefArgs

$ExecutionProp = New-Object Amazon.Glue.Model.ExecutionProperty
$ExecutionProp.MaxConcurrentRuns = 1
$ExecutionProp
```

```
$JobParams = @{
    "AllocatedCapacity"    = "5"
    "Command"              = $Command
    "Connections_Connection" = $Connections
    "DefaultArguments"  = $DefArgs
    "Description"       = "This is a test"
    "ExecutionProperty" = $ExecutionProp
    "MaxRetries"        = "1"
    "Name"              = "MyOregonTestGlueJob"
    "Role"              = "Amazon-GlueServiceRoleForSSM"
    "Timeout"           = "20"
     }

New-GlueJob @JobParams
```

- Para obtener información sobre la API, consulte CreateJob en la Referencia de Cmdlet de Herramientas de AWS para PowerShell (V4).

Herramientas para PowerShell V5

Ejemplo 1: en este ejemplo se muestra cómo crear un trabajo nuevo en AWS Glue. El valor del nombre del comando siempre será **`glueetl`**. AWS Glue es compatible con la ejecución de scripts de trabajos escritos en Python o Scala. En este ejemplo, el script del trabajo (MyTestGlueJob.py) está escrito en Python. Los parámetros de Python se especifican en la variable de **`$DefArgs`** y luego se transfieren al comando de PowerShell en el parámetro de **`DefaultArguments`**, el cual admite una tabla hash. Los parámetros en la variable **`$JobParams`** provienen de la API CreateJob, la cual está documentada en la sección Trabajos (https://docs.aws.amazon.com/glue/latest/dg/aws-glue-api-jobs-job.html) de la referencia de API de AWS Glue.

```
$Command = New-Object Amazon.Glue.Model.JobCommand
$Command.Name = 'glueetl'
$Command.ScriptLocation = 's3://amzn-s3-demo-source-bucket/admin/
MyTestGlueJob.py'
$Command

$Source = "source_test_table"
$Target = "target_test_table"
$Connections = $Source, $Target

$DefArgs = @{
     '--TempDir' = 's3://amzn-s3-demo-bucket/admin'
```

```
     '--job-bookmark-option' = 'job-bookmark-disable'
     '--job-language' = 'python'
     }
$DefArgs

$ExecutionProp = New-Object Amazon.Glue.Model.ExecutionProperty
$ExecutionProp.MaxConcurrentRuns = 1
$ExecutionProp

$JobParams = @{
    "AllocatedCapacity"    = "5"
    "Command"              = $Command
    "Connections_Connection" = $Connections
    "DefaultArguments"  = $DefArgs
    "Description"       = "This is a test"
    "ExecutionProperty" = $ExecutionProp
    "MaxRetries"        = "1"
    "Name"              = "MyOregonTestGlueJob"
    "Role"              = "Amazon-GlueServiceRoleForSSM"
    "Timeout"           = "20"
     }

New-GlueJob @JobParams
```

- Para obtener información sobre la API, consulte CreateJob en la Referencia de Cmdlet de Herramientas de AWS para PowerShell (V5).

Python

SDK para Python (Boto3)

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""

    def __init__(self, glue_client):
```

```
        """
        :param glue_client: A Boto3 Glue client.
        """
        self.glue_client = glue_client


    def create_job(self, name, description, role_arn, script_location):
        """
        Creates a job definition for an extract, transform, and load (ETL) job
that can
        be run by AWS Glue.

        :param name: The name of the job definition.
        :param description: The description of the job definition.
        :param role_arn: The ARN of an IAM role that grants AWS Glue the
permissions
                         it requires to run the job.
        :param script_location: The Amazon S3 URL of a Python ETL script that is
run as
                                part of the job. The script defines how the data
is
                                transformed.
        """
        try:
            self.glue_client.create_job(
                Name=name,
                Description=description,
                Role=role_arn,
                Command={
                    "Name": "glueetl",
                    "ScriptLocation": script_location,
                    "PythonVersion": "3",
                },
                GlueVersion="3.0",
            )
        except ClientError as err:
            logger.error(
                "Couldn't create job %s. Here's why: %s: %s",
                name,
                err.response["Error"]["Code"],
                err.response["Error"]["Message"],
            )
            raise
```

- Para obtener información sobre la API, consulte CreateJob en la Referencia de la API de AWS SDK para Python (Boto3).

Ruby

SDK para Ruby

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
# The `GlueWrapper` class serves as a wrapper around the AWS Glue API, providing
 a simplified interface for common operations.
# It encapsulates the functionality of the AWS SDK for Glue and provides methods
 for interacting with Glue crawlers, databases, tables, jobs, and S3 resources.
# The class initializes with a Glue client and a logger, allowing it to make API
 calls and log any errors or informational messages.
class GlueWrapper
  def initialize(glue_client, logger)
    @glue_client = glue_client
    @logger = logger
  end

  # Creates a new job with the specified configuration.
  #
  # @param name [String] The name of the job.
  # @param description [String] The description of the job.
  # @param role_arn [String] The ARN of the IAM role to be used by the job.
  # @param script_location [String] The location of the ETL script for the job.
  # @return [void]
  def create_job(name, description, role_arn, script_location)
    @glue_client.create_job(
      name: name,
      description: description,
      role: role_arn,
      command: {
```

```
        name: 'glueetl',
        script_location: script_location,
        python_version: '3'
      },
      glue_version: '3.0'
    )
  rescue Aws::Glue::Errors::GlueException => e
    @logger.error("Glue could not create job #{name}: \n#{e.message}")
    raise
  end
```

- Para obtener información sobre la API, consulte CreateJob en la Referencia de la API de AWS SDK para Ruby.

Rust

SDK para Rust

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
        let create_job = glue
            .create_job()
            .name(self.job())
            .role(self.iam_role.expose_secret())
            .command(
                JobCommand::builder()
                    .name("glueetl")
                    .python_version("3")
                    .script_location(format!("s3://{}/job.py", self.bucket()))
                    .build(),
            )
            .glue_version("3.0")
            .send()
            .await
            .map_err(GlueMvpError::from_glue_sdk)?;
```

```
        let job_name = create_job.name().ok_or_else(|| {
            GlueMvpError::Unknown("Did not get job name after creating
job".into())
        })?;
```

- Para obtener información sobre la API, consulte CreateJob en la Referencia de la API de AWS SDK para Rust.

Swift

SDK para Swift

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
import AWSClientRuntime
import AWSGlue

    /// Create a new AWS Glue job.
    ///
    /// - Parameters:
    ///   - glueClient: The AWS Glue client to use.
    ///   - jobName: The name to give the new job.
    ///   - role: The IAM role for the job to use when accessing AWS services.
    ///   - scriptLocation: The AWS S3 URI of the script to be run by the job.
    ///
    /// - Returns: `true` if the job is created successfully, otherwise `false`.
    func createJob(glueClient: GlueClient, name jobName: String, role: String,
                   scriptLocation: String) async -> Bool {
        let command = GlueClientTypes.JobCommand(
            name: "glueetl",
            pythonVersion: "3",
            scriptLocation: scriptLocation
        )

        do {
            _ = try await glueClient.createJob(
```

```
                input: CreateJobInput(
                    command: command,
                    description: "Created by the AWS SDK for Swift Glue basic
scenario example.",
                    glueVersion: "3.0",
                    name: jobName,
                    numberOfWorkers: 10,
                    role: role,
                    workerType: .g1x
                )
            )
        } catch {
            return false
        }
        return true
    }
```

- Para obtener información sobre la API, consulte CreateJob en la Referencia de la API de AWS SDK para Swift.

Para obtener una lista completa de las guías para desarrolladores de AWS SDK y ejemplos de código, consulte Cómo utilizar este servicio con un AWS SDK. En este tema también se incluye información sobre cómo comenzar a utilizar el SDK y detalles sobre sus versiones anteriores.

Cómo utilizar **`DeleteCrawler`** con un AWS SDK

Los ejemplos de códigos que se muestran a continuación muestran cómo se utiliza `DeleteCrawler`.

Los ejemplos de acciones son extractos de código de programas más grandes y deben ejecutarse en contexto. Puede ver esta acción en contexto en el siguiente ejemplo de código:

- Conceptos básicos

.NET

SDK para .NET

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
    /// <summary>
    /// Delete an AWS Glue crawler.
    /// </summary>
    /// <param name="crawlerName">The name of the crawler.</param>
    /// <returns>A Boolean value indicating the success of the action.</returns>
    public async Task<bool> DeleteCrawlerAsync(string crawlerName)
    {
        var response = await _amazonGlue.DeleteCrawlerAsync(new
DeleteCrawlerRequest { Name = crawlerName });
        return response.HttpStatusCode == HttpStatusCode.OK;
    }
```

- Para obtener información sobre la API, consulte DeleteCrawler en la Referencia de la API de AWS SDK para .NET.

C++

SDK para C++

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
        Aws::Client::ClientConfiguration clientConfig;
        // Optional: Set to the AWS Region in which the bucket was created
(overrides config file).
```

```
        // clientConfig.region = "us-east-1";

    Aws::Glue::GlueClient client(clientConfig);

        Aws::Glue::Model::DeleteCrawlerRequest request;
        request.SetName(crawler);

        Aws::Glue::Model::DeleteCrawlerOutcome outcome =
client.DeleteCrawler(request);

        if (outcome.IsSuccess()) {
            std::cout << "Successfully deleted the crawler." << std::endl;
        }
        else {
            std::cerr << "Error deleting the crawler. "
                      << outcome.GetError().GetMessage() << std::endl;
            result = false;
        }
```

- Para obtener información sobre la API, consulte DeleteCrawler en la Referencia de la API de AWS SDK para C++.

Java

SDK para Java 2.x

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
    /**
     * Deletes a specific AWS Glue crawler.
     *
     * @param glueClient  the AWS Glue client object
     * @param crawlerName the name of the crawler to be deleted
     * @throws GlueException if an error occurs during the deletion process
     */
```

```
    public static void deleteSpecificCrawler(GlueClient glueClient, String
 crawlerName) {
        try {
            DeleteCrawlerRequest deleteCrawlerRequest =
 DeleteCrawlerRequest.builder()
                .name(crawlerName)
                .build();

            glueClient.deleteCrawler(deleteCrawlerRequest);
            System.out.println(crawlerName + " was deleted");

        } catch (GlueException e) {
            throw e;
        }
    }
```

- Para obtener información sobre la API, consulte DeleteCrawler en la Referencia de la API de AWS SDK for Java 2.x.

JavaScript

SDK para JavaScript (v3)

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
const deleteCrawler = (crawlerName) => {
  const client = new GlueClient({});

  const command = new DeleteCrawlerCommand({
    Name: crawlerName,
  });

  return client.send(command);
};
```

- Para obtener información sobre la API, consulte DeleteCrawler en la Referencia de la API de AWS SDK para JavaScript.

PHP

SDK para PHP

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
        echo "Delete the crawler.\n";
        $glueClient->deleteCrawler([
            'Name' => $crawlerName,
        ]);

    public function deleteCrawler($crawlerName)
    {
        return $this->glueClient->deleteCrawler([
            'Name' => $crawlerName,
        ]);
    }
```

- Para obtener información sobre la API, consulte DeleteCrawler en la Referencia de la API de AWS SDK para PHP.

Python

SDK para Python (Boto3)

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""

    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 Glue client.
        """
        self.glue_client = glue_client


    def delete_crawler(self, name):
        """
        Deletes a crawler.

        :param name: The name of the crawler to delete.
        """
        try:
            self.glue_client.delete_crawler(Name=name)
        except ClientError as err:
            logger.error(
                "Couldn't delete crawler %s. Here's why: %s: %s",
                name,
                err.response["Error"]["Code"],
                err.response["Error"]["Message"],
            )
            raise
```

- Para obtener información sobre la API, consulte DeleteCrawler en la Referencia de la API de AWS SDK para Python (Boto3).

Ruby

SDK para Ruby

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
# The `GlueWrapper` class serves as a wrapper around the AWS Glue API, providing
 a simplified interface for common operations.
# It encapsulates the functionality of the AWS SDK for Glue and provides methods
 for interacting with Glue crawlers, databases, tables, jobs, and S3 resources.
# The class initializes with a Glue client and a logger, allowing it to make API
 calls and log any errors or informational messages.
class GlueWrapper
  def initialize(glue_client, logger)
    @glue_client = glue_client
    @logger = logger
  end

  # Deletes a crawler with the specified name.
  #
  # @param name [String] The name of the crawler to delete.
  # @return [void]
  def delete_crawler(name)
    @glue_client.delete_crawler(name: name)
  rescue Aws::Glue::Errors::ServiceError => e
    @logger.error("Glue could not delete crawler #{name}: \n#{e.message}")
    raise
  end
```

- Para obtener información sobre la API, consulte DeleteCrawler en la Referencia de la API de AWS SDK para Ruby.

Rust

SDK para Rust

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
        glue.delete_crawler()
            .name(self.crawler())
            .send()
```

```
            .await
            .map_err(GlueMvpError::from_glue_sdk)?;
```

- Para obtener información sobre la API, consulte DeleteCrawler en la Referencia de la API de AWS SDK para Rust.

Swift

SDK para Swift

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
import AWSClientRuntime
import AWSGlue

    /// Delete an AWS Glue crawler.
    ///
    /// - Parameters:
    ///   - glueClient: The AWS Glue client to use.
    ///   - name: The name of the crawler to delete.
    ///
    /// - Returns: `true` if successful, otherwise `false`.
    func deleteCrawler(glueClient: GlueClient, name: String) async -> Bool {
        do {
            _ = try await glueClient.deleteCrawler(
                input: DeleteCrawlerInput(name: name)
            )
        } catch {
            return false
        }
        return true
    }
```

- Para obtener información acerca de la API, consulte DeleteCrawler en la Referencia de la API de AWS SDK para Swift.

Para obtener una lista completa de las guías para desarrolladores de AWS SDK y ejemplos de código, consulte Cómo utilizar este servicio con un AWS SDK. En este tema también se incluye información sobre cómo comenzar a utilizar el SDK y detalles sobre sus versiones anteriores.

Cómo utilizar **`DeleteDatabase`** con un AWS SDK

Los ejemplos de códigos que se muestran a continuación muestran cómo se utiliza `DeleteDatabase`.

Los ejemplos de acciones son extractos de código de programas más grandes y deben ejecutarse en contexto. Puede ver esta acción en contexto en el siguiente ejemplo de código:

- Conceptos básicos

.NET

SDK para .NET

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
    /// <summary>
    /// Delete the AWS Glue database.
    /// </summary>
    /// <param name="dbName">The name of the database.</param>
    /// <returns>A Boolean value indicating the success of the action.</returns>
    public async Task<bool> DeleteDatabaseAsync(string dbName)
    {
        var response = await _amazonGlue.DeleteDatabaseAsync(new
DeleteDatabaseRequest { Name = dbName });
        return response.HttpStatusCode == HttpStatusCode.OK;
    }
```

- Para obtener información sobre la API, consulte DeleteDatabase en la Referencia de la API de AWS SDK para .NET.

C++

SDK para C++

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
        Aws::Client::ClientConfiguration clientConfig;
        // Optional: Set to the AWS Region in which the bucket was created
(overrides config file).
        // clientConfig.region = "us-east-1";

    Aws::Glue::GlueClient client(clientConfig);

        Aws::Glue::Model::DeleteDatabaseRequest request;
        request.SetName(database);

        Aws::Glue::Model::DeleteDatabaseOutcome outcome = client.DeleteDatabase(
                request);

        if (outcome.IsSuccess()) {
            std::cout << "Successfully deleted the database." << std::endl;
        }
        else {
            std::cerr << "Error deleting database. " <<
outcome.GetError().GetMessage()
                      << std::endl;
            result = false;
        }
```

- Para obtener información sobre la API, consulte DeleteDatabase en la Referencia de la API de AWS SDK para C++.

Java

SDK para Java 2.x

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
    /**
     * Deletes a AWS Glue Database.
     *
     * @param glueClient   An instance of the AWS Glue client used to interact
with the AWS Glue service.
     * @param databaseName The name of the database to be deleted.
     * @throws GlueException If an error occurs while deleting the database.
     */
    public static void deleteDatabase(GlueClient glueClient, String databaseName)
{
        try {
            DeleteDatabaseRequest request = DeleteDatabaseRequest.builder()
                .name(databaseName)
                .build();

            glueClient.deleteDatabase(request);
            System.out.println(databaseName + " was successfully deleted");

        } catch (GlueException e) {
            throw e;
        }
    }
```

- Para obtener información sobre la API, consulte DeleteDatabase en la Referencia de la API de AWS SDK for Java 2.x.

JavaScript

SDK para JavaScript (v3)

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
const deleteDatabase = (databaseName) => {
  const client = new GlueClient({});

  const command = new DeleteDatabaseCommand({
    Name: databaseName,
  });

  return client.send(command);
};
```

- Para obtener información sobre la API, consulte DeleteDatabase en la Referencia de la API de AWS SDK para JavaScript.

PHP

SDK para PHP

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
        echo "Delete the databases.\n";
        $glueClient->deleteDatabase([
            'Name' => $databaseName,
        ]);

    public function deleteDatabase($databaseName)
```

```
    {
        return $this->glueClient->deleteDatabase([
            'Name' => $databaseName,
        ]);
    }
```

- Para obtener información sobre la API, consulte DeleteDatabase en la Referencia de la API de AWS SDK para PHP.

Python

SDK para Python (Boto3)

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""

    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 Glue client.
        """
        self.glue_client = glue_client


    def delete_database(self, name):
        """
        Deletes a metadata database from your Data Catalog.

        :param name: The name of the database to delete.
        """
        try:
            self.glue_client.delete_database(Name=name)
        except ClientError as err:
            logger.error(
                "Couldn't delete database %s. Here's why: %s: %s",
```

```
                name,
                err.response["Error"]["Code"],
                err.response["Error"]["Message"],
            )
            raise
```

- Para obtener información sobre la API, consulte DeleteDatabase en la Referencia de la API de AWS SDK para Python (Boto3).

Ruby

SDK para Ruby

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
# The `GlueWrapper` class serves as a wrapper around the AWS Glue API, providing
 a simplified interface for common operations.
# It encapsulates the functionality of the AWS SDK for Glue and provides methods
 for interacting with Glue crawlers, databases, tables, jobs, and S3 resources.
# The class initializes with a Glue client and a logger, allowing it to make API
 calls and log any errors or informational messages.
class GlueWrapper
  def initialize(glue_client, logger)
    @glue_client = glue_client
    @logger = logger
  end

  # Removes a specified database from a Data Catalog.
  #
  # @param database_name [String] The name of the database to delete.
  # @return [void]
  def delete_database(database_name)
    @glue_client.delete_database(name: database_name)
  rescue Aws::Glue::Errors::ServiceError => e
```

```
    @logger.error("Glue could not delete database: \n#{e.message}")
  end
```

- Para obtener información sobre la API, consulte DeleteDatabase en la Referencia de la API de AWS SDK para Ruby.

Rust

SDK para Rust

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
        glue.delete_database()
            .name(self.database())
            .send()
            .await
            .map_err(GlueMvpError::from_glue_sdk)?;
```

- Para obtener información sobre la API, consulte DeleteDatabase en la Referencia de la API de AWS SDK para Rust.

Swift

SDK para Swift

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
import AWSClientRuntime
import AWSGlue
```

```
    /// Delete the specified database.
    ///
    /// - Parameters:
    ///   - glueClient: The AWS Glue client to use.
    ///   - databaseName: The name of the database to delete.
    ///   - deleteTables: A Bool indicating whether or not to delete the
    ///     tables in the database before attempting to delete the database.
    ///
    /// - Returns: `true` if the database (and optionally its tables) are
    ///   deleted, otherwise `false`.
    func deleteDatabase(glueClient: GlueClient, name databaseName: String,
                        withTables deleteTables: Bool = false) async -> Bool {
        if deleteTables {
            var tableNames: [String] = []

            // Get a list of the names of all of the tables in the database.

            let tableList = await self.getTablesInDatabase(glueClient:
glueClient, databaseName: databaseName)
            for table in tableList {
                guard let name = table.name else {
                    continue
                }
                tableNames.append(name)
            }

            // Delete the tables. If there's only one table, use
            // `deleteTable()`, otherwise, use `batchDeleteTable()`. You can
            // use `batchDeleteTable()` for a single table, but this
            // demonstrates the use of `deleteTable()`.

            if tableNames.count == 1 {
                do {
                    print("    Deleting table...")
                    _ = try await glueClient.deleteTable(
                        input: DeleteTableInput(
                            databaseName: databaseName,
                            name: tableNames[0]
                        )
                    )
                } catch {
                    print("*** Unable to delete the table.")
                }
```

```
            } else {
                do {
                    print("    Deleting tables...")
                    _ = try await glueClient.batchDeleteTable(
                        input: BatchDeleteTableInput(
                            databaseName: databaseName,
                            tablesToDelete: tableNames
                        )
                    )
                } catch {
                    print("*** Unable to delete the tables.")
                }
            }
        }

        // Delete the database itself.

        do {
            print("    Deleting the database itself...")
            _ = try await glueClient.deleteDatabase(
                input: DeleteDatabaseInput(name: databaseName)
            )
        } catch {
            print("*** Unable to delete the database.")
            return false
        }
        return true
    }
```

- Para obtener información acerca de la API, consulte DeleteDatabase en la Referencia de la API del AWS SDK para Swift.

Para obtener una lista completa de las guías para desarrolladores de AWS SDK y ejemplos de código, consulte Cómo utilizar este servicio con un AWS SDK. En este tema también se incluye información sobre cómo comenzar a utilizar el SDK y detalles sobre sus versiones anteriores.

Uso de **`DeleteJob`** con un SDK de AWS o la CLI

Los ejemplos de códigos que se muestran a continuación muestran cómo se utiliza `DeleteJob`.

Los ejemplos de acciones son extractos de código de programas más grandes y deben ejecutarse en contexto. Puede ver esta acción en contexto en el siguiente ejemplo de código:

- Conceptos básicos

.NET

SDK para .NET

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
    /// <summary>
    /// Delete an AWS Glue job.
    /// </summary>
    /// <param name="jobName">The name of the job.</param>
    /// <returns>A Boolean value indicating the success of the action.</returns>
    public async Task<bool> DeleteJobAsync(string jobName)
    {
        var response = await _amazonGlue.DeleteJobAsync(new DeleteJobRequest
{ JobName = jobName });
        return response.HttpStatusCode == HttpStatusCode.OK;
    }
```

- Para obtener información sobre la API, consulte DeleteJob en la Referencia de la API de AWS SDK para .NET.

C++

SDK para C++

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
        Aws::Client::ClientConfiguration clientConfig;
        // Optional: Set to the AWS Region in which the bucket was created
(overrides config file).
        // clientConfig.region = "us-east-1";

    Aws::Glue::GlueClient client(clientConfig);

        Aws::Glue::Model::DeleteJobRequest request;
        request.SetJobName(job);

        Aws::Glue::Model::DeleteJobOutcome outcome = client.DeleteJob(request);


        if (outcome.IsSuccess()) {
            std::cout << "Successfully deleted the job." << std::endl;
        }
        else {
            std::cerr << "Error deleting the job. " <<
outcome.GetError().GetMessage()
                      << std::endl;
            result = false;
        }
```

- Para obtener información sobre la API, consulte DeleteJob en la Referencia de la API de AWS SDK para C++.

CLI

AWS CLI

Eliminación de un trabajo

En el siguiente ejemplo de `delete-job`, se elimina un trabajo que ya no necesite.

```
aws glue delete-job \
    --job-name my-testing-job
```

Salida:

```
{
    "JobName": "my-testing-job"
}
```

Para obtener más información, consulte Uso de trabajos en la consola de AWS Glue en la Guía para desarrolladores de AWS Glue.

- Para obtener más información sobre la API, consulte DeleteJob en la Referencia de comandos de la AWS CLI.

Java

SDK para Java 2.x

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
    /**
     * Deletes a Glue job.
     *
     * @param glueClient the Glue client to use for the operation
     * @param jobName    the name of the job to be deleted
     * @throws GlueException if there is an error deleting the job
     */
```

```
    public static void deleteJob(GlueClient glueClient, String jobName) {
        try {
            DeleteJobRequest jobRequest = DeleteJobRequest.builder()
                .jobName(jobName)
                .build();

            glueClient.deleteJob(jobRequest);
            System.out.println(jobName + " was successfully deleted");

        } catch (GlueException e) {
            throw e;
        }
    }
```

- Para obtener información sobre la API, consulte DeleteJob en la Referencia de la API de AWS SDK for Java 2.x.

JavaScript

SDK para JavaScript (v3)

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
const deleteJob = (jobName) => {
  const client = new GlueClient({});

  const command = new DeleteJobCommand({
    JobName: jobName,
  });

  return client.send(command);
};
```

- Para obtener información sobre la API, consulte DeleteJob en la Referencia de la API de AWS SDK para JavaScript.

PHP

SDK para PHP

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
        echo "Delete the job.\n";
        $glueClient->deleteJob([
            'JobName' => $job['Name'],
        ]);

    public function deleteJob($jobName)
    {
        return $this->glueClient->deleteJob([
            'JobName' => $jobName,
        ]);
    }
```

- Para obtener información sobre la API, consulte DeleteJob en la Referencia de la API de AWS SDK para PHP.

Python

SDK para Python (Boto3)

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""
```

```
    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 Glue client.
        """
        self.glue_client = glue_client


    def delete_job(self, job_name):
        """
        Deletes a job definition. This also deletes data about all runs that are
        associated with this job definition.

        :param job_name: The name of the job definition to delete.
        """
        try:
            self.glue_client.delete_job(JobName=job_name)
        except ClientError as err:
            logger.error(
                "Couldn't delete job %s. Here's why: %s: %s",
                job_name,
                err.response["Error"]["Code"],
                err.response["Error"]["Message"],
            )
            raise
```

- Para obtener información sobre la API, consulte DeleteJob en la Referencia de la API de AWS SDK para Python (Boto3).

Ruby

SDK para Ruby

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
# The `GlueWrapper` class serves as a wrapper around the AWS Glue API, providing
 a simplified interface for common operations.
# It encapsulates the functionality of the AWS SDK for Glue and provides methods
 for interacting with Glue crawlers, databases, tables, jobs, and S3 resources.
# The class initializes with a Glue client and a logger, allowing it to make API
 calls and log any errors or informational messages.
class GlueWrapper
  def initialize(glue_client, logger)
    @glue_client = glue_client
    @logger = logger
  end

  # Deletes a job with the specified name.
  #
  # @param job_name [String] The name of the job to delete.
  # @return [void]
  def delete_job(job_name)
    @glue_client.delete_job(job_name: job_name)
  rescue Aws::Glue::Errors::ServiceError => e
    @logger.error("Glue could not delete job: \n#{e.message}")
  end
```

- Para obtener información sobre la API, consulte DeleteJob en la Referencia de la API de AWS SDK para Ruby.

Rust

SDK para Rust

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
        glue.delete_job()
            .job_name(self.job())
            .send()
            .await
            .map_err(GlueMvpError::from_glue_sdk)?;
```

- Para obtener información sobre la API, consulte DeleteJob en la Referencia de la API de AWS SDK para Rust.

Swift

SDK para Swift

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
import AWSClientRuntime
import AWSGlue

    /// Delete an AWS Glue job.
    ///
    /// - Parameters:
    ///   - glueClient: The AWS Glue client to use.
    ///   - jobName: The name of the job to delete.
    ///
    /// - Returns: `true` if the job is successfully deleted, otherwise `false`.
    func deleteJob(glueClient: GlueClient, name jobName: String) async -> Bool {
        do {
            _ = try await glueClient.deleteJob(
                input: DeleteJobInput(jobName: jobName)
            )
        } catch {
            return false
        }
        return true
    }
```

- Para obtener información acerca de la API, consulte DeleteJob en la Referencia de la API del AWS SDK para Swift.

Para obtener una lista completa de las guías para desarrolladores de AWS SDK y ejemplos de código, consulte Cómo utilizar este servicio con un AWS SDK. En este tema también se incluye información sobre cómo comenzar a utilizar el SDK y detalles sobre sus versiones anteriores.

Cómo utilizar **`DeleteTable`** con un AWS SDK

Los siguientes ejemplos de código muestran cómo utilizar `DeleteTable`.

Los ejemplos de acciones son extractos de código de programas más grandes y deben ejecutarse en contexto. Puede ver esta acción en contexto en el siguiente ejemplo de código:

- Conceptos básicos

.NET

SDK para .NET

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
    /// <summary>
    /// Delete a table from an AWS Glue database.
    /// </summary>
    /// <param name="tableName">The table to delete.</param>
    /// <returns>A Boolean value indicating the success of the action.</returns>
    public async Task<bool> DeleteTableAsync(string dbName, string tableName)
    {
        var response = await _amazonGlue.DeleteTableAsync(new DeleteTableRequest
{ Name = tableName, DatabaseName = dbName });
        return response.HttpStatusCode == HttpStatusCode.OK;
    }
```

- Para obtener información sobre la API, consulte DeleteTable en la referencia de la API de AWS SDK para .NET.

JavaScript

SDK para JavaScript (v3)

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
const deleteTable = (databaseName, tableName) => {
  const client = new GlueClient({});

  const command = new DeleteTableCommand({
    DatabaseName: databaseName,
    Name: tableName,
  });

  return client.send(command);
};
```

- Para obtener información sobre la API, consulte DeleteTable en la referencia de la API de AWS SDK para JavaScript.

PHP

SDK para PHP

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
        echo "Delete the tables.\n";
        foreach ($tables['TableList'] as $table) {
            $glueService->deleteTable($table['Name'], $databaseName);
        }
```

```
    public function deleteTable($tableName, $databaseName)
    {
        return $this->glueClient->deleteTable([
            'DatabaseName' => $databaseName,
            'Name' => $tableName,
        ]);
    }
```

- Para obtener información sobre la API, consulte DeleteTable en la referencia de la API de AWS SDK para PHP.

Python

SDK para Python (Boto3)

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""

    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 Glue client.
        """
        self.glue_client = glue_client


    def delete_table(self, db_name, table_name):
        """
        Deletes a table from a metadata database.

        :param db_name: The name of the database that contains the table.
        :param table_name: The name of the table to delete.
        """
        try:
            self.glue_client.delete_table(DatabaseName=db_name, Name=table_name)
```

```
        except ClientError as err:
            logger.error(
                "Couldn't delete table %s. Here's why: %s: %s",
                table_name,
                err.response["Error"]["Code"],
                err.response["Error"]["Message"],
            )
            raise
```

- Para obtener información sobre la API, consulte DeleteTable en la referencia de la API de AWS SDK para Python (Boto3).

Ruby

SDK para Ruby

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
# The `GlueWrapper` class serves as a wrapper around the AWS Glue API, providing
 a simplified interface for common operations.
# It encapsulates the functionality of the AWS SDK for Glue and provides methods
 for interacting with Glue crawlers, databases, tables, jobs, and S3 resources.
# The class initializes with a Glue client and a logger, allowing it to make API
 calls and log any errors or informational messages.
class GlueWrapper
  def initialize(glue_client, logger)
    @glue_client = glue_client
    @logger = logger
  end

  # Deletes a table with the specified name.
  #
  # @param database_name [String] The name of the catalog database in which the
 table resides.
```

```
  # @param table_name [String] The name of the table to be deleted.
  # @return [void]
  def delete_table(database_name, table_name)
    @glue_client.delete_table(database_name: database_name, name: table_name)
  rescue Aws::Glue::Errors::ServiceError => e
    @logger.error("Glue could not delete job: \n#{e.message}")
  end
```

- Para obtener información sobre la API, consulte DeleteTable en la referencia de la API de AWS SDK para Ruby.

Rust

SDK para Rust

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
        for t in &self.tables {
            glue.delete_table()
                .name(t.name())
                .database_name(self.database())
                .send()
                .await
                .map_err(GlueMvpError::from_glue_sdk)?;
        }
```

- Para obtener información sobre la API, consulte DeleteTable en la referencia de la API de AWS SDK para Rust.

Swift

SDK para Swift

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
import AWSClientRuntime
import AWSGlue

                do {
                    print("    Deleting table...")
                    _ = try await glueClient.deleteTable(
                        input: DeleteTableInput(
                            databaseName: databaseName,
                            name: tableNames[0]
                        )
                    )
                } catch {
                    print("*** Unable to delete the table.")
                }
```

- Para obtener información acerca de la API, consulte DeleteTable en la Referencia de la API del SDK de AWS para Swift.

Para obtener una lista completa de las guías para desarrolladores de AWS SDK y ejemplos de código, consulte Cómo utilizar este servicio con un AWS SDK. En este tema también se incluye información sobre cómo comenzar a utilizar el SDK y detalles sobre sus versiones anteriores.

Cómo utilizar **`GetCrawler`** con un AWS SDK

Los ejemplos de códigos que se muestran a continuación muestran cómo se utiliza `GetCrawler`.

Los ejemplos de acciones son extractos de código de programas más grandes y deben ejecutarse en contexto. Puede ver esta acción en contexto en el siguiente ejemplo de código:

- Conceptos básicos

.NET

SDK para .NET

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
    /// <summary>
    /// Get information about an AWS Glue crawler.
    /// </summary>
    /// <param name="crawlerName">The name of the crawler.</param>
    /// <returns>A Crawler object describing the crawler.</returns>
    public async Task<Crawler?> GetCrawlerAsync(string crawlerName)
    {
        var crawlerRequest = new GetCrawlerRequest
        {
            Name = crawlerName,
        };

        var response = await _amazonGlue.GetCrawlerAsync(crawlerRequest);
        if (response.HttpStatusCode == System.Net.HttpStatusCode.OK)
        {
            var databaseName = response.Crawler.DatabaseName;
            Console.WriteLine($"{crawlerName} has the database {databaseName}");
            return response.Crawler;
        }

        Console.WriteLine($"No information regarding {crawlerName} could be
found.");
        return null;
    }
```

- Para obtener información sobre la API, consulte GetCrawler en la Referencia de la API de AWS SDK para .NET.

C++

SDK para C++

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
       Aws::Client::ClientConfiguration clientConfig;
       // Optional: Set to the AWS Region in which the bucket was created
(overrides config file).
       // clientConfig.region = "us-east-1";

   Aws::Glue::GlueClient client(clientConfig);

       Aws::Glue::Model::GetCrawlerRequest request;
       request.SetName(CRAWLER_NAME);

       Aws::Glue::Model::GetCrawlerOutcome outcome = client.GetCrawler(request);

       if (outcome.IsSuccess()) {
           Aws::Glue::Model::CrawlerState crawlerState =
outcome.GetResult().GetCrawler().GetState();
           std::cout << "Retrieved crawler with state " <<

Aws::Glue::Model::CrawlerStateMapper::GetNameForCrawlerState(
                               crawlerState)
                    << "." << std::endl;
       }
       else {
           std::cerr << "Error retrieving a crawler.  "
                     << outcome.GetError().GetMessage() << std::endl;
           deleteAssets(CRAWLER_NAME, CRAWLER_DATABASE_NAME, "", bucketName,
                        clientConfig);
           return false;
       }
```

- Para obtener información sobre la API, consulte GetCrawler en la Referencia de la API de AWS SDK para C++.

Java

SDK para Java 2.x

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
   /**
    * Retrieves a specific crawler from the AWS Glue service and waits for it to
be in the "READY" state.
    *
    * @param glueClient  the AWS Glue client used to interact with the Glue
service
    * @param crawlerName the name of the crawler to be retrieved
    */
   public static void getSpecificCrawler(GlueClient glueClient, String
crawlerName) throws InterruptedException {
       try {
           GetCrawlerRequest crawlerRequest = GetCrawlerRequest.builder()
               .name(crawlerName)
               .build();

           boolean ready = false;
           while (!ready) {
               GetCrawlerResponse response =
glueClient.getCrawler(crawlerRequest);
               String status = response.crawler().stateAsString();
               if (status.compareTo("READY") == 0) {
                   ready = true;
               }
               Thread.sleep(3000);
           }

           System.out.println("The crawler is now ready");

       } catch (GlueException | InterruptedException e) {
           throw e;
       }
   }
```

- Para obtener información sobre la API, consulte GetCrawler en la Referencia de la API de AWS SDK for Java 2.x.

JavaScript

SDK para JavaScript (v3)

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
const getCrawler = (name) => {
  const client = new GlueClient({});

  const command = new GetCrawlerCommand({
    Name: name,
  });

  return client.send(command);
};
```

- Para obtener información sobre la API, consulte GetCrawler en la Referencia de la API de AWS SDK para JavaScript.

Kotlin

SDK para Kotlin

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
suspend fun getSpecificCrawler(crawlerName: String?) {
    val request =
        GetCrawlerRequest {
            name = crawlerName
        }
    GlueClient.fromEnvironment { region = "us-east-1" }.use { glueClient ->
        val response = glueClient.getCrawler(request)
        val role = response.crawler?.role
        println("The role associated with this crawler is $role")
    }
}
```

- Para obtener información sobre la API, consulte GetCrawler en la Referencia de la API de AWS SDK para Kotlin.

PHP

SDK para PHP

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
        echo "Waiting for crawler";
        do {
            $crawler = $glueService->getCrawler($crawlerName);
            echo ".";
            sleep(10);
        } while ($crawler['Crawler']['State'] != "READY");
        echo "\n";

    public function getCrawler($crawlerName)
    {
        return $this->customWaiter(function () use ($crawlerName) {
            return $this->glueClient->getCrawler([
                'Name' => $crawlerName,
            ]);
        });
```

```
    }
```

- Para obtener información sobre la API, consulte GetCrawler en la Referencia de la API de AWS SDK para PHP.

Python

SDK para Python (Boto3)

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""

    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 Glue client.
        """
        self.glue_client = glue_client


    def get_crawler(self, name):
        """
        Gets information about a crawler.

        :param name: The name of the crawler to look up.
        :return: Data about the crawler.
        """
        crawler = None
        try:
            response = self.glue_client.get_crawler(Name=name)
            crawler = response["Crawler"]
        except ClientError as err:
            if err.response["Error"]["Code"] == "EntityNotFoundException":
                logger.info("Crawler %s doesn't exist.", name)
            else:
```

```
                logger.error(
                    "Couldn't get crawler %s. Here's why: %s: %s",
                    name,
                    err.response["Error"]["Code"],
                    err.response["Error"]["Message"],
                )
                raise
        return crawler
```

- Para obtener información sobre la API, consulte GetCrawler en la Referencia de la API de AWS SDK para Python (Boto3).

Ruby

SDK para Ruby

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
# The `GlueWrapper` class serves as a wrapper around the AWS Glue API, providing
 a simplified interface for common operations.
# It encapsulates the functionality of the AWS SDK for Glue and provides methods
 for interacting with Glue crawlers, databases, tables, jobs, and S3 resources.
# The class initializes with a Glue client and a logger, allowing it to make API
 calls and log any errors or informational messages.
class GlueWrapper
  def initialize(glue_client, logger)
    @glue_client = glue_client
    @logger = logger
  end

  # Retrieves information about a specific crawler.
  #
  # @param name [String] The name of the crawler to retrieve information about.
```

```
  # @return [Aws::Glue::Types::Crawler, nil] The crawler object if found, or nil
if not found.
 def get_crawler(name)
   @glue_client.get_crawler(name: name)
 rescue Aws::Glue::Errors::EntityNotFoundException
   @logger.info("Crawler #{name} doesn't exist.")
   false
 rescue Aws::Glue::Errors::GlueException => e
   @logger.error("Glue could not get crawler #{name}: \n#{e.message}")
   raise
 end
```

- Para obtener información sobre la API, consulte GetCrawler en la Referencia de la API de AWS SDK para Ruby.

Rust

SDK para Rust

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
            let tmp_crawler = glue
                .get_crawler()
                .name(self.crawler())
                .send()
                .await
                .map_err(GlueMvpError::from_glue_sdk)?;
```

- Para obtener información sobre la API, consulte GetCrawler en la Referencia de la API de AWS SDK para Rust.

Swift

SDK para Swift

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
import AWSClientRuntime
import AWSGlue

    /// Get the state of the specified AWS Glue crawler.
    ///
    /// - Parameters:
    ///   - glueClient: The AWS Glue client to use.
    ///   - name: The name of the crawler whose state should be returned.
    ///
    /// - Returns: A `GlueClientTypes.CrawlerState` value describing the
    ///   state of the crawler.
    func getCrawlerState(glueClient: GlueClient, name: String) async ->
 GlueClientTypes.CrawlerState {
        do {
            let output = try await glueClient.getCrawler(
                input: GetCrawlerInput(name: name)
            )

            // If the crawler or its state is `nil`, report that the crawler
            // is stopping. This may not be what you want for your
            // application but it works for this one!

            guard let crawler = output.crawler else {
                return GlueClientTypes.CrawlerState.stopping
            }
            guard let state = crawler.state else {
                return GlueClientTypes.CrawlerState.stopping
            }
            return state
        } catch {
            return GlueClientTypes.CrawlerState.stopping
        }
```

```
    }
```

- Para obtener detalles sobre la API, consulte GetCrawler en la Referencia de la API del AWS SDK para Swift.

Para obtener una lista completa de las guías para desarrolladores de AWS SDK y ejemplos de código, consulte Cómo utilizar este servicio con un AWS SDK. En este tema también se incluye información sobre cómo comenzar a utilizar el SDK y detalles sobre sus versiones anteriores.

Cómo utilizar **`GetDatabase`** con un AWS SDK

Los ejemplos de códigos que se muestran a continuación muestran cómo se utiliza `GetDatabase`.

Los ejemplos de acciones son extractos de código de programas más grandes y deben ejecutarse en contexto. Puede ver esta acción en contexto en el siguiente ejemplo de código:

- Conceptos básicos

.NET

SDK para .NET

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
    /// <summary>
    /// Get information about an AWS Glue database.
    /// </summary>
    /// <param name="dbName">The name of the database.</param>
    /// <returns>A Database object containing information about the database.</
returns>
    public async Task<Database> GetDatabaseAsync(string dbName)
    {
        var databasesRequest = new GetDatabaseRequest
        {
            Name = dbName,
```

```
        };

        var response = await _amazonGlue.GetDatabaseAsync(databasesRequest);
        return response.Database;
    }
```

- Para obtener información sobre la API, consulte GetDatabase en la Referencia de la API de AWS SDK para .NET.

C++

SDK para C++

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
       Aws::Client::ClientConfiguration clientConfig;
       // Optional: Set to the AWS Region in which the bucket was created
(overrides config file).
       // clientConfig.region = "us-east-1";

   Aws::Glue::GlueClient client(clientConfig);

       Aws::Glue::Model::GetDatabaseRequest request;
       request.SetName(CRAWLER_DATABASE_NAME);

       Aws::Glue::Model::GetDatabaseOutcome outcome =
client.GetDatabase(request);

       if (outcome.IsSuccess()) {
           const Aws::Glue::Model::Database &database =
outcome.GetResult().GetDatabase();

           std::cout << "Successfully retrieve the database\n" <<
                     database.Jsonize().View().WriteReadable() << "'." <<
std::endl;
```

```
        }
        else {
            std::cerr << "Error getting the database.  "
                      << outcome.GetError().GetMessage() << std::endl;
            deleteAssets(CRAWLER_NAME, CRAWLER_DATABASE_NAME, "", bucketName,
                         clientConfig);
            return false;
        }
```

- Para obtener información sobre la API, consulte GetDatabase en la Referencia de la API de AWS SDK para C++.

Java

SDK para Java 2.x

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
   /**
    * Retrieves the specific database from the AWS Glue service.
    *
    * @param glueClient   an instance of the AWS Glue client used to interact
with the service
    * @param databaseName the name of the database to retrieve
    * @throws GlueException if there is an error retrieving the database from
the AWS Glue service
    */
   public static void getSpecificDatabase(GlueClient glueClient, String
databaseName) {
       try {
           GetDatabaseRequest databasesRequest = GetDatabaseRequest.builder()
               .name(databaseName)
               .build();

           GetDatabaseResponse response =
glueClient.getDatabase(databasesRequest);
```

```
            Instant createDate = response.database().createTime();

            // Convert the Instant to readable date.
            DateTimeFormatter formatter =
 DateTimeFormatter.ofLocalizedDateTime(FormatStyle.SHORT)
                .withLocale(Locale.US)
                .withZone(ZoneId.systemDefault());

            formatter.format(createDate);
            System.out.println("The create date of the database is " +
 createDate);

        } catch (GlueException e) {
            throw e;
        }
    }
```

- Para obtener información sobre la API, consulte GetDatabase en la Referencia de la API de AWS SDK for Java 2.x.

JavaScript

SDK para JavaScript (v3)

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
const getDatabase = (name) => {
  const client = new GlueClient({});

  const command = new GetDatabaseCommand({
    Name: name,
  });

  return client.send(command);
};
```

- Para obtener información sobre la API, consulte GetDatabase en la Referencia de la API de AWS SDK para JavaScript.

Kotlin

SDK para Kotlin

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
suspend fun getSpecificDatabase(databaseName: String?) {
    val request =
        GetDatabaseRequest {
            name = databaseName
        }

    GlueClient.fromEnvironment { region = "us-east-1" }.use { glueClient ->
        val response = glueClient.getDatabase(request)
        val dbDesc = response.database?.description
        println("The database description is $dbDesc")
    }
}
```

- Para obtener información sobre la API, consulte GetDatabase en la Referencia de la API de AWS SDK para Kotlin.

PHP

SDK para PHP

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
        $databaseName = "doc-example-database-$uniqid";

        $database = $glueService->getDatabase($databaseName);
        echo "Found a database named " . $database['Database']['Name'] . "\n";

    public function getDatabase(string $databaseName): Result
    {
        return $this->customWaiter(function () use ($databaseName) {
            return $this->glueClient->getDatabase([
                'Name' => $databaseName,
            ]);
        });
    }
```

- Para obtener información sobre la API, consulte GetDatabase en la Referencia de la API de AWS SDK para PHP.

Python

SDK para Python (Boto3)

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""

    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 Glue client.
        """
        self.glue_client = glue_client


    def get_database(self, name):
        """
        Gets information about a database in your Data Catalog.
```

```
        :param name: The name of the database to look up.
        :return: Information about the database.
        """
        try:
            response = self.glue_client.get_database(Name=name)
        except ClientError as err:
            logger.error(
                "Couldn't get database %s. Here's why: %s: %s",
                name,
                err.response["Error"]["Code"],
                err.response["Error"]["Message"],
            )
            raise
        else:
            return response["Database"]
```

- Para obtener información sobre la API, consulte GetDatabase en la Referencia de la API de AWS SDK para Python (Boto3).

Ruby

SDK para Ruby

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
# The `GlueWrapper` class serves as a wrapper around the AWS Glue API, providing
 a simplified interface for common operations.
# It encapsulates the functionality of the AWS SDK for Glue and provides methods
 for interacting with Glue crawlers, databases, tables, jobs, and S3 resources.
# The class initializes with a Glue client and a logger, allowing it to make API
 calls and log any errors or informational messages.
class GlueWrapper
  def initialize(glue_client, logger)
```

```
    @glue_client = glue_client
    @logger = logger
  end

  # Retrieves information about a specific database.
  #
  # @param name [String] The name of the database to retrieve information about.
  # @return [Aws::Glue::Types::Database, nil] The database object if found, or
nil if not found.
  def get_database(name)
    response = @glue_client.get_database(name: name)
    response.database
  rescue Aws::Glue::Errors::GlueException => e
    @logger.error("Glue could not get database #{name}: \n#{e.message}")
    raise
  end
```

- Para obtener información sobre la API, consulte GetDatabase en la Referencia de la API de AWS SDK para Ruby.

Rust

SDK para Rust

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
        let database = glue
            .get_database()
            .name(self.database())
            .send()
            .await
            .map_err(GlueMvpError::from_glue_sdk)?
            .to_owned();
        let database = database
            .database()
```

```
            .ok_or_else(|| GlueMvpError::Unknown("Could not find
database".into()))?;
```

- Para obtener información sobre la API, consulte GetDatabase en la Referencia de la API de AWS SDK para Rust.

Swift

SDK para Swift

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
import AWSClientRuntime
import AWSGlue

    /// Get the AWS Glue database with the specified name.
    ///
    /// - Parameters:
    ///   - glueClient: The AWS Glue client to use.
    ///   - name: The name of the database to return.
    ///
    /// - Returns: The `GlueClientTypes.Database` object describing the
    ///   specified database, or `nil` if an error occurs or the database
    ///   isn't found.
    func getDatabase(glueClient: GlueClient, name: String) async ->
GlueClientTypes.Database? {
        do {
            let output = try await glueClient.getDatabase(
                input: GetDatabaseInput(name: name)
            )

            return output.database
        } catch {
            return nil
        }
    }
```

- Para obtener información sobre la API, consulte GetDatabase en la Referencia de la API de AWS SDK para Swift.

Para obtener una lista completa de las guías para desarrolladores de AWS SDK y ejemplos de código, consulte Cómo utilizar este servicio con un AWS SDK. En este tema también se incluye información sobre cómo comenzar a utilizar el SDK y detalles sobre sus versiones anteriores.

Uso de **`GetDatabases`** con un SDK de AWS o la CLI

Los ejemplos de códigos que se muestran a continuación muestran cómo se utiliza `GetDatabases`.

Los ejemplos de acciones son extractos de código de programas más grandes y deben ejecutarse en contexto. Puede ver esta acción en contexto en el siguiente ejemplo de código:

- Conceptos básicos

CLI

AWS CLI

Enumeración de las definiciones de algunas o todas las bases de datos del Catálogo de datos de AWS Glue

El siguiente ejemplo de `get-databases` devuelve información sobre las bases de datos del Catálogo de datos.

```
aws glue get-databases
```

Salida:

```
{
    "DatabaseList": [
        {
            "Name": "default",
            "Description": "Default Hive database",
            "LocationUri": "file:/spark-warehouse",
            "CreateTime": 1602084052.0,
            "CreateTableDefaultPermissions": [
                {
```

```
                    "Principal": {
                        "DataLakePrincipalIdentifier": "IAM_ALLOWED_PRINCIPALS"
                    },
                    "Permissions": [
                        "ALL"
                    ]
                }
            ],
            "CatalogId": "111122223333"
        },
        {
            "Name": "flights-db",
            "CreateTime": 1587072847.0,
            "CreateTableDefaultPermissions": [
                {
                    "Principal": {
                        "DataLakePrincipalIdentifier": "IAM_ALLOWED_PRINCIPALS"
                    },
                    "Permissions": [
                        "ALL"
                    ]
                }
            ],
            "CatalogId": "111122223333"
        },
        {
            "Name": "legislators",
            "CreateTime": 1601415625.0,
            "CreateTableDefaultPermissions": [
                {
                    "Principal": {
                        "DataLakePrincipalIdentifier": "IAM_ALLOWED_PRINCIPALS"
                    },
                    "Permissions": [
                        "ALL"
                    ]
                }
            ],
            "CatalogId": "111122223333"
        },
        {
            "Name": "tempdb",
            "CreateTime": 1601498566.0,
            "CreateTableDefaultPermissions": [
```

```
                {
                    "Principal": {
                        "DataLakePrincipalIdentifier": "IAM_ALLOWED_PRINCIPALS"
                    },
                    "Permissions": [
                        "ALL"
                    ]
                }
            ],
            "CatalogId": "111122223333"
        }
    ]
}
```

Para obtener más información, consulte Definición de una base de datos en su Catálogo de datos en la Guía para desarrolladores de AWS Glue.

- Para obtener más información sobre la API, consulte GetDatabases en la Referencia de comandos de la AWS CLI.

JavaScript

SDK para JavaScript (v3)

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
const getDatabases = () => {
  const client = new GlueClient({});

  const command = new GetDatabasesCommand({});

  return client.send(command);
};
```

- Para obtener información acerca de la API, consulte GetDatabases en la Referencia de la API de AWS SDK para JavaScript.

Para obtener una lista completa de las guías para desarrolladores de AWS SDK y ejemplos de código, consulte Cómo utilizar este servicio con un AWS SDK. En este tema también se incluye información sobre cómo comenzar a utilizar el SDK y detalles sobre sus versiones anteriores.

Uso de **`GetJob`** con un SDK de AWS o la CLI

Los ejemplos de códigos que se muestran a continuación muestran cómo se utiliza `GetJob`.

Los ejemplos de acciones son extractos de código de programas más grandes y deben ejecutarse en contexto. Puede ver esta acción en contexto en el siguiente ejemplo de código:

- Conceptos básicos

CLI

AWS CLI

Recuperación de información sobre un trabajo

El siguiente ejemplo de `get-job` recupera información sobre un trabajo.

```
aws glue get-job \
    --job-name my-testing-job
```

Salida:

```
{
    "Job": {
        "Name": "my-testing-job",
        "Role": "Glue_DefaultRole",
        "CreatedOn": 1602805698.167,
        "LastModifiedOn": 1602805698.167,
        "ExecutionProperty": {
            "MaxConcurrentRuns": 1
        },
        "Command": {
            "Name": "gluestreaming",
            "ScriptLocation": "s3://janetst-bucket-01/Scripts/test_script.scala",
            "PythonVersion": "2"
        },
        "DefaultArguments": {
```

```
            "--class": "GlueApp",
            "--job-language": "scala"
        },
        "MaxRetries": 0,
        "AllocatedCapacity": 10,
        "MaxCapacity": 10.0,
        "GlueVersion": "1.0"
    }
}
```

Para obtener más información, consulte Trabajos en la Guía para desarrolladores de AWS Glue.

- Para obtener más información sobre la API, consulte GetJob en la Referencia de comandos de la AWS CLI.

JavaScript

SDK para JavaScript (v3)

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
const getJob = (jobName) => {
  const client = new GlueClient({});

  const command = new GetJobCommand({
    JobName: jobName,
  });

  return client.send(command);
};
```

- Para obtener información acerca de la API, consulte GetJob en la Referencia de la API de AWS SDK para JavaScript.

Para obtener una lista completa de las guías para desarrolladores de AWS SDK y ejemplos de código, consulte Cómo utilizar este servicio con un AWS SDK. En este tema también se incluye información sobre cómo comenzar a utilizar el SDK y detalles sobre sus versiones anteriores.

Uso de **`GetJobRun`** con un SDK de AWS o la CLI

Los ejemplos de códigos que se muestran a continuación muestran cómo se utiliza `GetJobRun`.

Los ejemplos de acciones son extractos de código de programas más grandes y deben ejecutarse en contexto. Puede ver esta acción en contexto en el siguiente ejemplo de código:

- Conceptos básicos

.NET

SDK para .NET

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
    /// <summary>
    /// Get information about a specific AWS Glue job run.
    /// </summary>
    /// <param name="jobName">The name of the job.</param>
    /// <param name="jobRunId">The Id of the job run.</param>
    /// <returns>A JobRun object with information about the job run.</returns>
    public async Task<JobRun> GetJobRunAsync(string jobName, string jobRunId)
    {
        var response = await _amazonGlue.GetJobRunAsync(new GetJobRunRequest
{ JobName = jobName, RunId = jobRunId });
        return response.JobRun;
    }
```

- Para obtener información sobre la API, consulte GetJobRun en la Referencia de la API de AWS SDK para .NET.

C++

SDK para C++

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
        Aws::Client::ClientConfiguration clientConfig;
        // Optional: Set to the AWS Region in which the bucket was created
(overrides config file).
        // clientConfig.region = "us-east-1";

    Aws::Glue::GlueClient client(clientConfig);

        Aws::Glue::Model::GetJobRunRequest jobRunRequest;
        jobRunRequest.SetJobName(jobName);
        jobRunRequest.SetRunId(jobRunID);

        Aws::Glue::Model::GetJobRunOutcome jobRunOutcome = client.GetJobRun(
                jobRunRequest);

        if (jobRunOutcome.IsSuccess()) {
            std::cout << "Displaying the job run JSON description." << std::endl;
            std::cout
                    <<
jobRunOutcome.GetResult().GetJobRun().Jsonize().View().WriteReadable()
                    << std::endl;
        }
        else {
            std::cerr << "Error get a job run. "
                      << jobRunOutcome.GetError().GetMessage()
                      << std::endl;
        }
```

- Para obtener información sobre la API, consulte GetJobRun en la Referencia de la API de AWS SDK para C++.

CLI

AWS CLI

Obtención de información sobre una ejecución de trabajo

El siguiente ejemplo de `get-job-run` recupera información sobre una ejecución de trabajo.

```
aws glue get-job-run \
    --job-name "Combine legistators data" \
    --run-id jr_012e176506505074d94d761755e5c62538ee1aad6f17d39f527e9140cf0c9a5e
```

Salida:

```
{
    "JobRun": {
        "Id":
 "jr_012e176506505074d94d761755e5c62538ee1aad6f17d39f527e9140cf0c9a5e",
        "Attempt": 0,
        "JobName": "Combine legistators data",
        "StartedOn": 1602873931.255,
        "LastModifiedOn": 1602874075.985,
        "CompletedOn": 1602874075.985,
        "JobRunState": "SUCCEEDED",
        "Arguments": {
            "--enable-continuous-cloudwatch-log": "true",
            "--enable-metrics": "",
            "--enable-spark-ui": "true",
            "--job-bookmark-option": "job-bookmark-enable",
            "--spark-event-logs-path": "s3://aws-glue-assets-111122223333-us-
east-1/sparkHistoryLogs/"
        },
        "PredecessorRuns": [],
        "AllocatedCapacity": 10,
        "ExecutionTime": 117,
        "Timeout": 2880,
        "MaxCapacity": 10.0,
        "WorkerType": "G.1X",
        "NumberOfWorkers": 10,
        "LogGroupName": "/aws-glue/jobs",
        "GlueVersion": "2.0"
    }
}
```

Para obtener más información, consulte Ejecuciones de trabajo en la Guía para desarrolladores de AWS Glue.

- Para obtener más información sobre la API, consulte GetJobRuns en la Referencia de comandos de la AWS CLI.

JavaScript

SDK para JavaScript (v3)

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
const getJobRun = (jobName, jobRunId) => {
  const client = new GlueClient({});
  const command = new GetJobRunCommand({
    JobName: jobName,
    RunId: jobRunId,
  });

  return client.send(command);
};
```

- Para obtener información sobre la API, consulte GetJobRun en la Referencia de la API de AWS SDK para JavaScript.

PHP

SDK para PHP

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
        $jobName = 'test-job-' . $uniqid;

        $outputBucketUrl = "s3://$bucketName";
        $runId = $glueService->startJobRun($jobName, $databaseName, $tables,
$outputBucketUrl)['JobRunId'];

        echo "waiting for job";
        do {
            $jobRun = $glueService->getJobRun($jobName, $runId);
            echo ".";
            sleep(10);
        } while (!array_intersect([$jobRun['JobRun']['JobRunState']],
['SUCCEEDED', 'STOPPED', 'FAILED', 'TIMEOUT']));
        echo "\n";

    public function getJobRun($jobName, $runId, $predecessorsIncluded = false):
Result
    {
        return $this->glueClient->getJobRun([
            'JobName' => $jobName,
            'RunId' => $runId,
            'PredecessorsIncluded' => $predecessorsIncluded,
        ]);
    }
```

- Para obtener información sobre la API, consulte GetJobRun en la Referencia de la API de AWS SDK para PHP.

Python

SDK para Python (Boto3)

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""
```

```
    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 Glue client.
        """
        self.glue_client = glue_client


    def get_job_run(self, name, run_id):
        """
        Gets information about a single job run.

        :param name: The name of the job definition for the run.
        :param run_id: The ID of the run.
        :return: Information about the run.
        """
        try:
            response = self.glue_client.get_job_run(JobName=name, RunId=run_id)
        except ClientError as err:
            logger.error(
                "Couldn't get job run %s/%s. Here's why: %s: %s",
                name,
                run_id,
                err.response["Error"]["Code"],
                err.response["Error"]["Message"],
            )
            raise
        else:
            return response["JobRun"]
```

- Para obtener información sobre la API, consulte GetJobRun en la Referencia de la API de AWS SDK para Python (Boto3).

Ruby

SDK para Ruby

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
# The `GlueWrapper` class serves as a wrapper around the AWS Glue API, providing
 a simplified interface for common operations.
# It encapsulates the functionality of the AWS SDK for Glue and provides methods
 for interacting with Glue crawlers, databases, tables, jobs, and S3 resources.
# The class initializes with a Glue client and a logger, allowing it to make API
 calls and log any errors or informational messages.
class GlueWrapper
  def initialize(glue_client, logger)
    @glue_client = glue_client
    @logger = logger
  end

  # Retrieves data for a specific job run.
  #
  # @param job_name [String] The name of the job run to retrieve data for.
  # @return [Glue::Types::GetJobRunResponse]
  def get_job_run(job_name, run_id)
    @glue_client.get_job_run(job_name: job_name, run_id: run_id)
  rescue Aws::Glue::Errors::GlueException => e
    @logger.error("Glue could not get job runs: \n#{e.message}")
  end
```

- Para obtener información sobre la API, consulte GetJobRun en la Referencia de la API de AWS SDK para Ruby.

Rust

SDK para Rust

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
        let get_job_run = || async {
            Ok::<JobRun, GlueMvpError>(
                glue.get_job_run()
                    .job_name(self.job())
                    .run_id(job_run_id.to_string())
                    .send()
                    .await
                    .map_err(GlueMvpError::from_glue_sdk)?
                    .job_run()
                    .ok_or_else(|| GlueMvpError::Unknown("Failed to get
job_run".into()))?
                    .to_owned(),
            )
        };

        let mut job_run = get_job_run().await?;
        let mut state =
job_run.job_run_state().unwrap_or(&unknown_state).to_owned();

        while matches!(
            state,
            JobRunState::Starting | JobRunState::Stopping | JobRunState::Running
        ) {
            info!(?state, "Waiting for job to finish");
            tokio::time::sleep(self.wait_delay).await;

            job_run = get_job_run().await?;
            state = job_run.job_run_state().unwrap_or(&unknown_state).to_owned();
        }
```

- Para obtener información sobre la API, consulte GetJobRun en la Referencia de la API de AWS SDK para Rust.

Swift

SDK para Swift

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
import AWSClientRuntime
import AWSGlue

    /// Get information about a specific AWS Glue job run.
    ///
    /// - Parameters:
    ///   - glueClient: The AWS Glue client to use.
    ///   - jobName: The name of the job to return job run data for.
    ///   - id: The run ID of the specific job run to return.
    ///
    /// - Returns: A `GlueClientTypes.JobRun` object describing the state of
    ///   the job run, or `nil` if an error occurs.
    func getJobRun(glueClient: GlueClient, name jobName: String, id: String)
 async -> GlueClientTypes.JobRun? {
        do {
            let output = try await glueClient.getJobRun(
                input: GetJobRunInput(
                    jobName: jobName,
                    runId: id
                )
            )

            return output.jobRun
        } catch {
            return nil
        }
    }
```

- Para obtener información sobre la API, consulte GetJobRun en la Referencia de la API de AWS SDK para Swift.

Para obtener una lista completa de las guías para desarrolladores de AWS SDK y ejemplos de código, consulte Cómo utilizar este servicio con un AWS SDK. En este tema también se incluye información sobre cómo comenzar a utilizar el SDK y detalles sobre sus versiones anteriores.

Uso de **`GetJobRuns`** con un SDK de AWS o la CLI

Los ejemplos de códigos que se muestran a continuación muestran cómo se utiliza `GetJobRuns`.

Los ejemplos de acciones son extractos de código de programas más grandes y deben ejecutarse en contexto. Puede ver esta acción en contexto en el siguiente ejemplo de código:

- Conceptos básicos

.NET

SDK para .NET

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
/// <summary>
/// Get information about all AWS Glue runs of a specific job.
/// </summary>
/// <param name="jobName">The name of the job.</param>
/// <returns>A list of JobRun objects.</returns>
public async Task<List<JobRun>> GetJobRunsAsync(string jobName)
{
    var jobRuns = new List<JobRun>();

    var request = new GetJobRunsRequest
    {
        JobName = jobName,
    };
```

```
        // No need to loop to get all the log groups--the SDK does it for us
behind the scenes
        var paginatorForJobRuns =
            _amazonGlue.Paginators.GetJobRuns(request);

        await foreach (var response in paginatorForJobRuns.Responses)
        {
            response.JobRuns.ForEach(jobRun =>
            {
                jobRuns.Add(jobRun);
            });
        }

        return jobRuns;
    }
```

- Para obtener información sobre la API, consulte GetJobRuns en la Referencia de la API de AWS SDK para .NET.

C++

SDK para C++

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
        Aws::Client::ClientConfiguration clientConfig;
        // Optional: Set to the AWS Region in which the bucket was created
(overrides config file).
        // clientConfig.region = "us-east-1";

    Aws::Glue::GlueClient client(clientConfig);

        Aws::Glue::Model::GetJobRunsRequest getJobRunsRequest;
        getJobRunsRequest.SetJobName(jobName);
```

```
        Aws::String nextToken; // Used for pagination.
        std::vector<Aws::Glue::Model::JobRun> allJobRuns;
        do {
            if (!nextToken.empty()) {
                getJobRunsRequest.SetNextToken(nextToken);
            }
            Aws::Glue::Model::GetJobRunsOutcome jobRunsOutcome =
client.GetJobRuns(
                    getJobRunsRequest);

            if (jobRunsOutcome.IsSuccess()) {
                const std::vector<Aws::Glue::Model::JobRun> &jobRuns =
jobRunsOutcome.GetResult().GetJobRuns();
                allJobRuns.insert(allJobRuns.end(), jobRuns.begin(),
jobRuns.end());

                nextToken = jobRunsOutcome.GetResult().GetNextToken();
            }
            else {
                std::cerr << "Error getting job runs. "
                          << jobRunsOutcome.GetError().GetMessage()
                          << std::endl;
                break;
            }
        } while (!nextToken.empty());
```

- Para obtener información sobre la API, consulte GetJobRuns en la Referencia de la API de AWS SDK para C++.

CLI

AWS CLI

Obtención de información sobre todas las ejecuciones de trabajo para un trabajo

El siguiente ejemplo de `get-job-runs` recupera información acerca de las ejecuciones de flujo de trabajo para una tarea.

```
aws glue get-job-runs \
    --job-name "my-testing-job"
```

Salida:

```
{
    "JobRuns": [
        {
            "Id":
 "jr_012e176506505074d94d761755e5c62538ee1aad6f17d39f527e9140cf0c9a5e",
            "Attempt": 0,
            "JobName": "my-testing-job",
            "StartedOn": 1602873931.255,
            "LastModifiedOn": 1602874075.985,
            "CompletedOn": 1602874075.985,
            "JobRunState": "SUCCEEDED",
            "Arguments": {
                "--enable-continuous-cloudwatch-log": "true",
                "--enable-metrics": "",
                "--enable-spark-ui": "true",
                "--job-bookmark-option": "job-bookmark-enable",
                "--spark-event-logs-path": "s3://aws-glue-assets-111122223333-us-
east-1/sparkHistoryLogs/"
            },
            "PredecessorRuns": [],
            "AllocatedCapacity": 10,
            "ExecutionTime": 117,
            "Timeout": 2880,
            "MaxCapacity": 10.0,
            "WorkerType": "G.1X",
            "NumberOfWorkers": 10,
            "LogGroupName": "/aws-glue/jobs",
            "GlueVersion": "2.0"
        },
        {
            "Id":
 "jr_03cc19ddab11c4e244d3f735567de74ff93b0b3ef468a713ffe73e53d1aec08f_attempt_2",
            "Attempt": 2,
            "PreviousRunId":
 "jr_03cc19ddab11c4e244d3f735567de74ff93b0b3ef468a713ffe73e53d1aec08f_attempt_1",
            "JobName": "my-testing-job",
            "StartedOn": 1602811168.496,
            "LastModifiedOn": 1602811282.39,
            "CompletedOn": 1602811282.39,
            "JobRunState": "FAILED",
            "ErrorMessage": "An error occurred while calling
 o122.pyWriteDynamicFrame.
```

```
                Access Denied (Service: Amazon S3; Status Code: 403; Error Code:
 AccessDenied;
                Request ID: 021AAB703DB20A2D;
                S3 Extended Request ID: teZk24Y09TkXzBvMPG502L5VJBhe9DJuWA9/
TXtuGOqfByajkfL/Tlqt5JBGdEGpigAqzdMDM/U=)",
            "PredecessorRuns": [],
            "AllocatedCapacity": 10,
            "ExecutionTime": 110,
            "Timeout": 2880,
            "MaxCapacity": 10.0,
            "WorkerType": "G.1X",
            "NumberOfWorkers": 10,
            "LogGroupName": "/aws-glue/jobs",
            "GlueVersion": "2.0"
        },
        {
            "Id":
 "jr_03cc19ddab11c4e244d3f735567de74ff93b0b3ef468a713ffe73e53d1aec08f_attempt_1",
            "Attempt": 1,
            "PreviousRunId":
 "jr_03cc19ddab11c4e244d3f735567de74ff93b0b3ef468a713ffe73e53d1aec08f",
            "JobName": "my-testing-job",
            "StartedOn": 1602811020.518,
            "LastModifiedOn": 1602811138.364,
            "CompletedOn": 1602811138.364,
            "JobRunState": "FAILED",
            "ErrorMessage": "An error occurred while calling
 o122.pyWriteDynamicFrame.
                Access Denied (Service: Amazon S3; Status Code: 403; Error Code:
 AccessDenied;
                Request ID: 2671D37856AE7ABB;
                S3 Extended Request ID: RLJCJw20brV
+PpC6GpORahyF2fp9flB5SSb2bTGPnUSPVizLXRl1PN3QZldb+v1o9qRVktNYbW8=)",
            "PredecessorRuns": [],
            "AllocatedCapacity": 10,
            "ExecutionTime": 113,
            "Timeout": 2880,
            "MaxCapacity": 10.0,
            "WorkerType": "G.1X",
            "NumberOfWorkers": 10,
            "LogGroupName": "/aws-glue/jobs",
            "GlueVersion": "2.0"
        }
    ]
```

```
}
```

Para obtener más información, consulte Ejecuciones de trabajo en la Guía para desarrolladores de AWS Glue.

- Para obtener detalles de la API, consulte GetJobRuns en la Referencia de comandos de AWS CLI.

Java

SDK para Java 2.x

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
   /**
    * Retrieves the job runs for a given Glue job and prints the status of the
job runs.
    *
    * @param glueClient the Glue client used to make API calls
    * @param jobName    the name of the Glue job to retrieve the job runs for
    */
   public static void getJobRuns(GlueClient glueClient, String jobName) {
       try {
           GetJobRunsRequest runsRequest = GetJobRunsRequest.builder()
               .jobName(jobName)
               .maxResults(20)
               .build();

           boolean jobDone = false;
           while (!jobDone) {
               GetJobRunsResponse response = glueClient.getJobRuns(runsRequest);
               List<JobRun> jobRuns = response.jobRuns();
               for (JobRun jobRun : jobRuns) {
                   String jobState = jobRun.jobRunState().name();
                   if (jobState.compareTo("SUCCEEDED") == 0) {
                       System.out.println(jobName + " has succeeded");
                       jobDone = true;
```

```
                    } else if (jobState.compareTo("STOPPED") == 0) {
                        System.out.println("Job run has stopped");
                        jobDone = true;

                    } else if (jobState.compareTo("FAILED") == 0) {
                        System.out.println("Job run has failed");
                        jobDone = true;

                    } else if (jobState.compareTo("TIMEOUT") == 0) {
                        System.out.println("Job run has timed out");
                        jobDone = true;

                    } else {
                        System.out.println("*** Job run state is " +
jobRun.jobRunState().name());
                        System.out.println("Job run Id is " + jobRun.id());
                        System.out.println("The Glue version is " +
jobRun.glueVersion());
                    }
                    TimeUnit.SECONDS.sleep(5);
                }
            }

        } catch (GlueException e) {
            throw e;
        } catch (InterruptedException e) {
            throw new RuntimeException(e);
        }
    }
```

- Para obtener información sobre la API, consulte GetJobRuns en la Referencia de la API de AWS SDK for Java 2.x.

JavaScript

SDK para JavaScript (v3)

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
const getJobRuns = (jobName) => {
  const client = new GlueClient({});
  const command = new GetJobRunsCommand({
    JobName: jobName,
  });

  return client.send(command);
};
```

- Para obtener información sobre la API, consulte GetJobRuns en la Referencia de la API de AWS SDK para JavaScript.

PHP

SDK para PHP

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
        $jobName = 'test-job-' . $uniqid;

        $jobRuns = $glueService->getJobRuns($jobName);

    public function getJobRuns($jobName, $maxResults = 0, $nextToken = ''):
 Result
    {
```

```
        $arguments = ['JobName' => $jobName];
        if ($maxResults) {
            $arguments['MaxResults'] = $maxResults;
        }
        if ($nextToken) {
            $arguments['NextToken'] = $nextToken;
        }
        return $this->glueClient->getJobRuns($arguments);
    }
```

- Para obtener información sobre la API, consulte GetJobRuns en la Referencia de la API de AWS SDK para PHP.

Python

SDK para Python (Boto3)

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""

    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 Glue client.
        """
        self.glue_client = glue_client


    def get_job_runs(self, job_name):
        """
        Gets information about runs that have been performed for a specific job
        definition.

        :param job_name: The name of the job definition to look up.
        :return: The list of job runs.
```

```
        """
        try:
            response = self.glue_client.get_job_runs(JobName=job_name)
        except ClientError as err:
            logger.error(
                "Couldn't get job runs for %s. Here's why: %s: %s",
                job_name,
                err.response["Error"]["Code"],
                err.response["Error"]["Message"],
            )
            raise
        else:
            return response["JobRuns"]
```

- Para obtener información sobre la API, consulte GetJobRuns en la Referencia de la API de AWS SDK para Python (Boto3).

Ruby

SDK para Ruby

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
# The `GlueWrapper` class serves as a wrapper around the AWS Glue API, providing
 a simplified interface for common operations.
# It encapsulates the functionality of the AWS SDK for Glue and provides methods
 for interacting with Glue crawlers, databases, tables, jobs, and S3 resources.
# The class initializes with a Glue client and a logger, allowing it to make API
 calls and log any errors or informational messages.
class GlueWrapper
  def initialize(glue_client, logger)
    @glue_client = glue_client
    @logger = logger
  end
```

```
  # Retrieves a list of job runs for the specified job.
  #
  # @param job_name [String] The name of the job to retrieve job runs for.
  # @return [Array<Aws::Glue::Types::JobRun>]
  def get_job_runs(job_name)
    response = @glue_client.get_job_runs(job_name: job_name)
    response.job_runs
  rescue Aws::Glue::Errors::GlueException => e
    @logger.error("Glue could not get job runs: \n#{e.message}")
  end
```

- Para obtener información sobre la API, consulte GetJobRuns en la Referencia de la API de AWS SDK para Ruby.

Swift

SDK para Swift

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
import AWSClientRuntime
import AWSGlue

    /// Return a list of the job runs for the specified job.
    ///
    /// - Parameters:
    ///   - glueClient: The AWS Glue client to use.
    ///   - jobName: The name of the job for which to return its job runs.
    ///   - maxResults: The maximum number of job runs to return (default:
    ///     1000).
    ///
    /// - Returns: An array of `GlueClientTypes.JobRun` objects describing
    ///   each job run.
    func getJobRuns(glueClient: GlueClient, name jobName: String, maxResults:
 Int? = nil) async -> [GlueClientTypes.JobRun] {
```

```
        do {
            let output = try await glueClient.getJobRuns(
                input: GetJobRunsInput(
                    jobName: jobName,
                    maxResults: maxResults
                )
            )

            guard let jobRuns = output.jobRuns else {
                print("*** No job runs found.")
                return []
            }

            return jobRuns
        } catch is EntityNotFoundException {
            print("*** The specified job name, \(jobName), doesn't exist.")
            return []
        } catch {
            print("*** Unexpected error getting job runs:")
            dump(error)
            return []
        }
    }
```

- Para obtener información sobre la API, consulte GetJobRuns en la Referencia de la API de AWS SDK para Swift.

Para obtener una lista completa de las guías para desarrolladores de AWS SDK y ejemplos de código, consulte Cómo utilizar este servicio con un AWS SDK. En este tema también se incluye información sobre cómo comenzar a utilizar el SDK y detalles sobre sus versiones anteriores.

Uso de **`GetTables`** con un SDK de AWS o la CLI

Los ejemplos de códigos que se muestran a continuación muestran cómo se utiliza `GetTables`.

Los ejemplos de acciones son extractos de código de programas más grandes y deben ejecutarse en contexto. Puede ver esta acción en contexto en el siguiente ejemplo de código:

- Conceptos básicos

.NET

SDK para .NET

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
/// <summary>
/// Get a list of tables for an AWS Glue database.
/// </summary>
/// <param name="dbName">The name of the database.</param>
/// <returns>A list of Table objects.</returns>
public async Task<List<Table>> GetTablesAsync(string dbName)
{
    var request = new GetTablesRequest { DatabaseName = dbName };
    var tables = new List<Table>();

    // Get a paginator for listing the tables.
    var tablePaginator = _amazonGlue.Paginators.GetTables(request);

    await foreach (var response in tablePaginator.Responses)
    {
        tables.AddRange(response.TableList);
    }

    return tables;
}
```

- Para obtener información sobre la API, consulte GetTables en la Referencia de la API de AWS SDK para .NET.

C++

SDK para C++

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
       Aws::Client::ClientConfiguration clientConfig;
       // Optional: Set to the AWS Region in which the bucket was created
(overrides config file).
       // clientConfig.region = "us-east-1";

   Aws::Glue::GlueClient client(clientConfig);

       Aws::Glue::Model::GetTablesRequest request;
       request.SetDatabaseName(CRAWLER_DATABASE_NAME);
       std::vector<Aws::Glue::Model::Table> all_tables;
       Aws::String nextToken; // Used for pagination.
       do {
           Aws::Glue::Model::GetTablesOutcome outcome =
client.GetTables(request);

           if (outcome.IsSuccess()) {
               const std::vector<Aws::Glue::Model::Table> &tables =
outcome.GetResult().GetTableList();
               all_tables.insert(all_tables.end(), tables.begin(),
tables.end());
               nextToken = outcome.GetResult().GetNextToken();
           }
           else {
               std::cerr << "Error getting the tables. "
                         << outcome.GetError().GetMessage()
                         << std::endl;
               deleteAssets(CRAWLER_NAME, CRAWLER_DATABASE_NAME, "", bucketName,
                            clientConfig);
               return false;
           }
       } while (!nextToken.empty());
```

```
        std::cout << "The database contains " << all_tables.size()
                  << (all_tables.size() == 1 ?
                      " table." : "tables.") << std::endl;
        std::cout << "Here is a list of the tables in the database.";
        for (size_t index = 0; index < all_tables.size(); ++index) {
            std::cout << "    " << index + 1 << ":  " <<
all_tables[index].GetName()
                      << std::endl;
        }

        if (!all_tables.empty()) {
            int tableIndex = askQuestionForIntRange(
                    "Enter an index to display the database detail ",
                    1, static_cast<int>(all_tables.size()));
            std::cout << all_tables[tableIndex -
1].Jsonize().View().WriteReadable()
                      << std::endl;

            tableName = all_tables[tableIndex - 1].GetName();
        }
```

- Para obtener información sobre la API, consulte GetTables en la Referencia de la API de AWS SDK para C++.

CLI

AWS CLI

Enumeración de las definiciones de algunas o todas las tablas de la base de datos especificada

El siguiente ejemplo de `get-tables` devuelve información sobre las tablas de la base de datos especificada.

```
aws glue get-tables --database-name 'tempdb'
```

Salida:

```
{
    "TableList": [
        {
```

```
            "Name": "my-s3-sink",
            "DatabaseName": "tempdb",
            "CreateTime": 1602730539.0,
            "UpdateTime": 1602730539.0,
            "Retention": 0,
            "StorageDescriptor": {
                "Columns": [
                    {
                        "Name": "sensorid",
                        "Type": "int"
                    },
                    {
                        "Name": "currenttemperature",
                        "Type": "int"
                    },
                    {
                        "Name": "status",
                        "Type": "string"
                    }
                ],
                "Location": "s3://janetst-bucket-01/test-s3-output/",
                "Compressed": false,
                "NumberOfBuckets": 0,
                "SerdeInfo": {
                    "SerializationLibrary": "org.openx.data.jsonserde.JsonSerDe"
                },
                "SortColumns": [],
                "StoredAsSubDirectories": false
            },
            "Parameters": {
                "classification": "json"
            },
            "CreatedBy": "arn:aws:iam::007436865787:user/JRSTERN",
            "IsRegisteredWithLakeFormation": false,
            "CatalogId": "007436865787"
        },
        {
            "Name": "s3-source",
            "DatabaseName": "tempdb",
            "CreateTime": 1602730658.0,
            "UpdateTime": 1602730658.0,
            "Retention": 0,
            "StorageDescriptor": {
                "Columns": [
```

```
                    {
                        "Name": "sensorid",
                        "Type": "int"
                    },
                    {
                        "Name": "currenttemperature",
                        "Type": "int"
                    },
                    {
                        "Name": "status",
                        "Type": "string"
                    }
                ],
                "Location": "s3://janetst-bucket-01/",
                "Compressed": false,
                "NumberOfBuckets": 0,
                "SortColumns": [],
                "StoredAsSubDirectories": false
            },
            "Parameters": {
                "classification": "json"
            },
            "CreatedBy": "arn:aws:iam::007436865787:user/JRSTERN",
            "IsRegisteredWithLakeFormation": false,
            "CatalogId": "007436865787"
        },
        {
            "Name": "test-kinesis-input",
            "DatabaseName": "tempdb",
            "CreateTime": 1601507001.0,
            "UpdateTime": 1601507001.0,
            "Retention": 0,
            "StorageDescriptor": {
                "Columns": [
                    {
                        "Name": "sensorid",
                        "Type": "int"
                    },
                    {
                        "Name": "currenttemperature",
                        "Type": "int"
                    },
                    {
                        "Name": "status",
```

```
                        "Type": "string"
                    }
                ],
                "Location": "my-testing-stream",
                "Compressed": false,
                "NumberOfBuckets": 0,
                "SerdeInfo": {
                    "SerializationLibrary": "org.openx.data.jsonserde.JsonSerDe"
                },
                "SortColumns": [],
                "Parameters": {
                    "kinesisUrl": "https://kinesis.us-east-1.amazonaws.com",
                    "streamName": "my-testing-stream",
                    "typeOfData": "kinesis"
                },
                "StoredAsSubDirectories": false
            },
            "Parameters": {
                "classification": "json"
            },
            "CreatedBy": "arn:aws:iam::007436865787:user/JRSTERN",
            "IsRegisteredWithLakeFormation": false,
            "CatalogId": "007436865787"
        }
    ]
}
```

Para obtener más información, consulte Definición de tablas en el Catálogo de datos de AWS Glue en la Guía para desarrolladores de AWS Glue.

- Para obtener más información sobre la API, consulte GetTables en la Referencia de comandos de laAWS CLI.

Java

SDK para Java 2.x

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
   /**
    * Retrieves the names of the tables in the specified Glue database.
    *
    * @param glueClient the Glue client to use for the operation
    * @param dbName     the name of the Glue database to retrieve the table
names from
    * @return the name of the first table retrieved, or an empty string if no
tables were found
    */
   public static String getGlueTables(GlueClient glueClient, String dbName) {
       String myTableName = "";
       try {
           GetTablesRequest tableRequest = GetTablesRequest.builder()
               .databaseName(dbName)
               .build();

           GetTablesResponse response = glueClient.getTables(tableRequest);
           List<Table> tables = response.tableList();
           if (tables.isEmpty()) {
               System.out.println("No tables were returned");
           } else {
               for (Table table : tables) {
                   myTableName = table.name();
                   System.out.println("Table name is: " + myTableName);
               }
           }

       } catch (GlueException e) {
           throw e;
       }
       return myTableName;
   }
```

- Para obtener información sobre la API, consulte GetTables en la Referencia de la API de AWS SDK for Java 2.x.

JavaScript

SDK para JavaScript (v3)

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
const getTables = (databaseName) => {
  const client = new GlueClient({});

  const command = new GetTablesCommand({
    DatabaseName: databaseName,
  });

  return client.send(command);
};
```

- Para obtener información sobre la API, consulte GetTables en la Referencia de la API de AWS SDK para JavaScript.

PHP

SDK para PHP

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
        $databaseName = "doc-example-database-$uniqid";

        $tables = $glueService->getTables($databaseName);

    public function getTables($databaseName): Result
    {
```

```
        return $this->glueClient->getTables([
            'DatabaseName' => $databaseName,
        ]);
    }
```

- Para obtener información sobre la API, consulte GetTables en la Referencia de la API de AWS SDK para PHP.

Python

SDK para Python (Boto3)

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""

    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 Glue client.
        """
        self.glue_client = glue_client


    def get_tables(self, db_name):
        """
        Gets a list of tables in a Data Catalog database.

        :param db_name: The name of the database to query.
        :return: The list of tables in the database.
        """
        try:
            response = self.glue_client.get_tables(DatabaseName=db_name)
        except ClientError as err:
            logger.error(
                "Couldn't get tables %s. Here's why: %s: %s",
```

```
                db_name,
                err.response["Error"]["Code"],
                err.response["Error"]["Message"],
            )
            raise
        else:
            return response["TableList"]
```

- Para obtener información sobre la API, consulte GetTables en la Referencia de la API de AWS SDK para Python (Boto3).

Ruby

SDK para Ruby

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
# The `GlueWrapper` class serves as a wrapper around the AWS Glue API, providing
 a simplified interface for common operations.
# It encapsulates the functionality of the AWS SDK for Glue and provides methods
 for interacting with Glue crawlers, databases, tables, jobs, and S3 resources.
# The class initializes with a Glue client and a logger, allowing it to make API
 calls and log any errors or informational messages.
class GlueWrapper
  def initialize(glue_client, logger)
    @glue_client = glue_client
    @logger = logger
  end

  # Retrieves a list of tables in the specified database.
  #
  # @param db_name [String] The name of the database to retrieve tables from.
  # @return [Array<Aws::Glue::Types::Table>]
  def get_tables(db_name)
```

```
  response = @glue_client.get_tables(database_name: db_name)
  response.table_list
rescue Aws::Glue::Errors::GlueException => e
  @logger.error("Glue could not get tables #{db_name}: \n#{e.message}")
  raise
end
```

- Para obtener información sobre la API, consulte GetTables en la Referencia de la API de AWS SDK para Ruby.

Rust

SDK para Rust

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
        let tables = glue
            .get_tables()
            .database_name(self.database())
            .send()
            .await
            .map_err(GlueMvpError::from_glue_sdk)?;

        let tables = tables.table_list();
```

- Para obtener información sobre la API, consulte GetTables en la Referencia de la API de AWS SDK para Rust.

Swift

SDK para Swift

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
import AWSClientRuntime
import AWSGlue

    /// Returns a list of the tables in the specified database.
    ///
    /// - Parameters:
    ///   - glueClient: The AWS Glue client to use.
    ///   - databaseName: The name of the database whose tables are to be
    ///     returned.
    ///
    /// - Returns: An array of `GlueClientTypes.Table` objects, each
    ///   describing one table in the named database. An empty array indicates
    ///   that there are either no tables in the database, or an error
    ///   occurred before any tables could be found.
    func getTablesInDatabase(glueClient: GlueClient, databaseName: String) async
 -> [GlueClientTypes.Table] {
        var tables: [GlueClientTypes.Table] = []
        var nextToken: String?

        repeat {
            do {
                let output = try await glueClient.getTables(
                    input: GetTablesInput(
                        databaseName: databaseName,
                        nextToken: nextToken
                    )
                )

                guard let tableList = output.tableList else {
                    return tables
                }
```

```
                tables = tables + tableList
                nextToken = output.nextToken
            } catch {
                return tables
            }
        } while nextToken != nil

        return tables
    }
```

- Para obtener información sobre la API, consulte GetTables en la Referencia de la API de AWS SDK para Swift.

Para obtener una lista completa de las guías para desarrolladores de AWS SDK y ejemplos de código, consulte Cómo utilizar este servicio con un AWS SDK. En este tema también se incluye información sobre cómo comenzar a utilizar el SDK y detalles sobre sus versiones anteriores.

Cómo utilizar **`ListJobs`** con un AWS SDK

Los ejemplos de códigos que se muestran a continuación muestran cómo se utiliza `ListJobs`.

Los ejemplos de acciones son extractos de código de programas más grandes y deben ejecutarse en contexto. Puede ver esta acción en contexto en el siguiente ejemplo de código:

- Conceptos básicos

.NET

SDK para .NET

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
    /// <summary>
    /// List AWS Glue jobs using a paginator.
    /// </summary>
```

```
    /// <returns>A list of AWS Glue job names.</returns>
    public async Task<List<string>> ListJobsAsync()
    {
        var jobNames = new List<string>();

        var listJobsPaginator = _amazonGlue.Paginators.ListJobs(new
ListJobsRequest { MaxResults = 10 });
        await foreach (var response in listJobsPaginator.Responses)
        {
            jobNames.AddRange(response.JobNames);
        }

        return jobNames;
    }
```

- Para obtener información sobre la API, consulte ListJobs en la Referencia de la API de AWS SDK para .NET.

C++

SDK para C++

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
        Aws::Client::ClientConfiguration clientConfig;
        // Optional: Set to the AWS Region in which the bucket was created
(overrides config file).
        // clientConfig.region = "us-east-1";

    Aws::Glue::GlueClient client(clientConfig);

        Aws::Glue::Model::ListJobsRequest listJobsRequest;

        Aws::String nextToken;
        std::vector<Aws::String> allJobNames;
```

```
        do {
            if (!nextToken.empty()) {
                listJobsRequest.SetNextToken(nextToken);
            }
            Aws::Glue::Model::ListJobsOutcome listRunsOutcome = client.ListJobs(
                    listJobsRequest);

            if (listRunsOutcome.IsSuccess()) {
                const std::vector<Aws::String> &jobNames =
listRunsOutcome.GetResult().GetJobNames();
                allJobNames.insert(allJobNames.end(), jobNames.begin(),
jobNames.end());
                nextToken = listRunsOutcome.GetResult().GetNextToken();
            }
            else {
                std::cerr << "Error listing jobs. "
                          << listRunsOutcome.GetError().GetMessage()
                          << std::endl;
            }
        } while (!nextToken.empty());
```

- Para obtener información sobre la API, consulte ListJobs en la Referencia de la API de AWS SDK para C++.

JavaScript

SDK para JavaScript (v3)

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
const listJobs = () => {
  const client = new GlueClient({});

  const command = new ListJobsCommand({});
```

```
  return client.send(command);
};
```

- Para obtener información sobre la API, consulte ListJobs en la Referencia de la API de AWS SDK para JavaScript.

PHP

SDK para PHP

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
        $jobs = $glueService->listJobs();
        echo "Current jobs:\n";
        foreach ($jobs['JobNames'] as $jobsName) {
            echo "{$jobsName}\n";
        }

    public function listJobs($maxResults = null, $nextToken = null, $tags = []):
Result
    {
        $arguments = [];
        if ($maxResults) {
            $arguments['MaxResults'] = $maxResults;
        }
        if ($nextToken) {
            $arguments['NextToken'] = $nextToken;
        }
        if (!empty($tags)) {
            $arguments['Tags'] = $tags;
        }
        return $this->glueClient->listJobs($arguments);
    }
```

- Para obtener información sobre la API, consulte ListJobs en la Referencia de la API de AWS SDK para PHP.

Python

SDK para Python (Boto3)

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""

    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 Glue client.
        """
        self.glue_client = glue_client


    def list_jobs(self):
        """
        Lists the names of job definitions in your account.

        :return: The list of job definition names.
        """
        try:
            response = self.glue_client.list_jobs()
        except ClientError as err:
            logger.error(
                "Couldn't list jobs. Here's why: %s: %s",
                err.response["Error"]["Code"],
                err.response["Error"]["Message"],
            )
            raise
        else:
            return response["JobNames"]
```

- Para obtener información sobre la API, consulte ListJobs en la Referencia de la API de AWS SDK para Python (Boto3).

Ruby

SDK para Ruby

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
# The `GlueWrapper` class serves as a wrapper around the AWS Glue API, providing
 a simplified interface for common operations.
# It encapsulates the functionality of the AWS SDK for Glue and provides methods
 for interacting with Glue crawlers, databases, tables, jobs, and S3 resources.
# The class initializes with a Glue client and a logger, allowing it to make API
 calls and log any errors or informational messages.
class GlueWrapper
  def initialize(glue_client, logger)
    @glue_client = glue_client
    @logger = logger
  end

  # Retrieves a list of jobs in AWS Glue.
  #
  # @return [Aws::Glue::Types::ListJobsResponse]
  def list_jobs
    @glue_client.list_jobs
  rescue Aws::Glue::Errors::GlueException => e
    @logger.error("Glue could not list jobs: \n#{e.message}")
    raise
  end
```

- Para obtener información sobre la API, consulte ListJobs en la Referencia de la API de AWS SDK para Ruby.

Rust

SDK para Rust

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
        let mut list_jobs = glue.list_jobs().into_paginator().send();
        while let Some(list_jobs_output) = list_jobs.next().await {
            match list_jobs_output {
                Ok(list_jobs) => {
                    let names = list_jobs.job_names();
                    info!(?names, "Found these jobs")
                }
                Err(err) => return Err(GlueMvpError::from_glue_sdk(err)),
            }
        }
```

- Para obtener información sobre la API, consulte ListJobs en la Referencia de la API de AWS SDK para Rust.

Swift

SDK para Swift

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
import AWSClientRuntime
import AWSGlue

    /// Return a list of the AWS Glue jobs listed on the user's account.
```

```
    ///
    /// - Parameters:
    ///   - glueClient: The AWS Glue client to use.
    ///   - maxJobs: The maximum number of jobs to return (default: 100).
    ///
    /// - Returns: An array of strings listing the names of all available AWS
    ///   Glue jobs.
    func listJobs(glueClient: GlueClient, maxJobs: Int = 100) async -> [String] {
        var jobList: [String] = []
        var nextToken: String?

        repeat {
            do {
                let output = try await glueClient.listJobs(
                    input: ListJobsInput(
                        maxResults: maxJobs,
                        nextToken: nextToken
                    )
                )

                guard let jobs = output.jobNames else {
                    return jobList
                }

                jobList = jobList + jobs
                nextToken = output.nextToken
            } catch {
                return jobList
            }
        } while (nextToken != nil)

        return jobList
    }
```

- Para obtener información sobre la API, consulte ListJobs en la Referencia de la API de AWS SDK para Swift.

Para obtener una lista completa de las guías para desarrolladores de AWS SDK y ejemplos de código, consulte Cómo utilizar este servicio con un AWS SDK. En este tema también se incluye información sobre cómo comenzar a utilizar el SDK y detalles sobre sus versiones anteriores.

Uso de `StartCrawler` con un SDK de AWS o la CLI

Los ejemplos de códigos que se muestran a continuación muestran cómo se utiliza `StartCrawler`.

Los ejemplos de acciones son extractos de código de programas más grandes y deben ejecutarse en contexto. Puede ver esta acción en contexto en el siguiente ejemplo de código:

- Conceptos básicos

.NET

SDK para .NET

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
/// <summary>
/// Start an AWS Glue crawler.
/// </summary>
/// <param name="crawlerName">The name of the crawler.</param>
/// <returns>A Boolean value indicating the success of the action.</returns>
public async Task<bool> StartCrawlerAsync(string crawlerName)
{
    var crawlerRequest = new StartCrawlerRequest
    {
        Name = crawlerName,
    };

    var response = await _amazonGlue.StartCrawlerAsync(crawlerRequest);

    return response.HttpStatusCode == System.Net.HttpStatusCode.OK;
}
```

- Para obtener información sobre la API, consulte StartCrawler en la Referencia de la API de AWS SDK para .NET.

C++

SDK para C++

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
       Aws::Client::ClientConfiguration clientConfig;
       // Optional: Set to the AWS Region in which the bucket was created
(overrides config file).
       // clientConfig.region = "us-east-1";

   Aws::Glue::GlueClient client(clientConfig);

       Aws::Glue::Model::StartCrawlerRequest request;
       request.SetName(CRAWLER_NAME);

       Aws::Glue::Model::StartCrawlerOutcome outcome =
client.StartCrawler(request);


       if (outcome.IsSuccess() || (Aws::Glue::GlueErrors::CRAWLER_RUNNING ==
                                   outcome.GetError().GetErrorType())) {
           if (!outcome.IsSuccess()) {
               std::cout << "Crawler was already started." << std::endl;
           }
           else {
               std::cout << "Successfully started crawler." << std::endl;
           }

           std::cout << "This may take a while to run." << std::endl;

           Aws::Glue::Model::CrawlerState crawlerState =
Aws::Glue::Model::CrawlerState::NOT_SET;
           int iterations = 0;
           while (Aws::Glue::Model::CrawlerState::READY != crawlerState) {
               std::this_thread::sleep_for(std::chrono::seconds(1));
               ++iterations;
               if ((iterations % 10) == 0) { // Log status every 10 seconds.
```

```
                    std::cout << "Crawler status " <<

Aws::Glue::Model::CrawlerStateMapper::GetNameForCrawlerState(
                                      crawlerState)
                              << ". After " << iterations
                              << " seconds elapsed."
                              << std::endl;
                }
                Aws::Glue::Model::GetCrawlerRequest getCrawlerRequest;
                getCrawlerRequest.SetName(CRAWLER_NAME);

                Aws::Glue::Model::GetCrawlerOutcome getCrawlerOutcome =
client.GetCrawler(
                        getCrawlerRequest);

                if (getCrawlerOutcome.IsSuccess()) {
                    crawlerState =
getCrawlerOutcome.GetResult().GetCrawler().GetState();
                }
                else {
                    std::cerr << "Error getting crawler.  "
                              << getCrawlerOutcome.GetError().GetMessage() <<
std::endl;
                    break;
                }
            }

            if (Aws::Glue::Model::CrawlerState::READY == crawlerState) {
                std::cout << "Crawler finished running after " << iterations
                          << " seconds."
                          << std::endl;
            }
        }
        else {
            std::cerr << "Error starting a crawler.  "
                      << outcome.GetError().GetMessage()
                      << std::endl;

            deleteAssets(CRAWLER_NAME, CRAWLER_DATABASE_NAME, "", bucketName,
                         clientConfig);
            return false;
        }
```

- Para obtener información sobre la API, consulte StartCrawler en la Referencia de la API de AWS SDK para C++.

CLI

AWS CLI

Inicio de un rastreador

El siguiente ejemplo de `start-crawler` inicia un rastreador.

```
aws glue start-crawler --name my-crawler
```

Salida:

```
None
```

Para obtener más información, consulte Definición de rastreadores en la Guía para desarrolladores de AWS Glue.

- Para obtener más información sobre la API, consulte StartCrawler en la Referencia de comandos de la AWS CLI.

Java

SDK para Java 2.x

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
    /**
     * Starts a specific AWS Glue crawler.
     *
     * @param glueClient  the AWS Glue client to use for the crawler operation
     * @param crawlerName the name of the crawler to start
     * @throws GlueException if there is an error starting the crawler
```

```
     */
    public static void startSpecificCrawler(GlueClient glueClient, String
 crawlerName) {
        try {
            StartCrawlerRequest crawlerRequest = StartCrawlerRequest.builder()
                .name(crawlerName)
                .build();

            glueClient.startCrawler(crawlerRequest);
            System.out.println(crawlerName + " was successfully started!");

        } catch (GlueException e) {
            throw e;
        }
    }
```

- Para obtener información sobre la API, consulte StartCrawler en la Referencia de la API de AWS SDK for Java 2.x.

JavaScript

SDK para JavaScript (v3)

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
const startCrawler = (name) => {
  const client = new GlueClient({});

  const command = new StartCrawlerCommand({
    Name: name,
  });

  return client.send(command);
};
```

- Para obtener información sobre la API, consulte StartCrawler en la Referencia de la API de AWS SDK para JavaScript.

Kotlin

SDK para Kotlin

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
suspend fun startSpecificCrawler(crawlerName: String?) {
    val request =
        StartCrawlerRequest {
            name = crawlerName
        }

    GlueClient.fromEnvironment { region = "us-west-2" }.use { glueClient ->
        glueClient.startCrawler(request)
        println("$crawlerName was successfully started.")
    }
}
```

- Para obtener información sobre la API, consulte StartCrawler en la Referencia de la API de AWS SDK para Kotlin.

PHP

SDK para PHP

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
        $crawlerName = "example-crawler-test-" . $uniqid;

        $databaseName = "doc-example-database-$uniqid";

        $glueService->startCrawler($crawlerName);

    public function startCrawler($crawlerName): Result
    {
        return $this->glueClient->startCrawler([
            'Name' => $crawlerName,
        ]);
    }
```

- Para obtener información sobre la API, consulte StartCrawler en la Referencia de la API de AWS SDK para PHP.

Python

SDK para Python (Boto3)

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""

    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 Glue client.
        """
        self.glue_client = glue_client


    def start_crawler(self, name):
        """
        Starts a crawler. The crawler crawls its configured target and creates
        metadata that describes the data it finds in the target data source.
```

```
        :param name: The name of the crawler to start.
        """
        try:
            self.glue_client.start_crawler(Name=name)
        except ClientError as err:
            logger.error(
                "Couldn't start crawler %s. Here's why: %s: %s",
                name,
                err.response["Error"]["Code"],
                err.response["Error"]["Message"],
            )
            raise
```

- Para obtener información sobre la API, consulte StartCrawler en la Referencia de la API de AWS SDK para Python (Boto3).

Ruby

SDK para Ruby

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
# The `GlueWrapper` class serves as a wrapper around the AWS Glue API, providing
 a simplified interface for common operations.
# It encapsulates the functionality of the AWS SDK for Glue and provides methods
 for interacting with Glue crawlers, databases, tables, jobs, and S3 resources.
# The class initializes with a Glue client and a logger, allowing it to make API
 calls and log any errors or informational messages.
class GlueWrapper
  def initialize(glue_client, logger)
    @glue_client = glue_client
    @logger = logger
  end
```

```
  # Starts a crawler with the specified name.
  #
  # @param name [String] The name of the crawler to start.
  # @return [void]
  def start_crawler(name)
    @glue_client.start_crawler(name: name)
  rescue Aws::Glue::Errors::ServiceError => e
    @logger.error("Glue could not start crawler #{name}: \n#{e.message}")
    raise
  end
```

- Para obtener información sobre la API, consulte StartCrawler en la Referencia de la API de AWS SDK para Ruby.

Rust

SDK para Rust

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
        let start_crawler =
glue.start_crawler().name(self.crawler()).send().await;

        match start_crawler {
            Ok(_) => Ok(()),
            Err(err) => {
                let glue_err: aws_sdk_glue::Error = err.into();
                match glue_err {
                    aws_sdk_glue::Error::CrawlerRunningException(_) => Ok(()),
                    _ => Err(GlueMvpError::GlueSdk(glue_err)),
                }
            }
        }?;
```

- Para obtener información sobre la API, consulte StartCrawler en la Referencia de la API de AWS SDK para Rust.

Swift

SDK para Swift

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
import AWSClientRuntime
import AWSGlue

    /// Start running an AWS Glue crawler.
    ///
    /// - Parameters:
    ///   - glueClient: The AWS Glue client to use when starting the crawler.
    ///   - name: The name of the crawler to start running.
    ///
    /// - Returns: `true` if the crawler is started successfully, otherwise
 `false`.
    func startCrawler(glueClient: GlueClient, name: String) async -> Bool {
        do {
            _ = try await glueClient.startCrawler(
                input: StartCrawlerInput(name: name)
            )
        } catch {
            print("*** An unexpected error occurred starting the crawler.")
            return false
        }

        return true
    }
```

- Para obtener información sobre la API, consulte StartCrawler en la Referencia de la API de AWS SDK para Swift.

Para obtener una lista completa de las guías para desarrolladores de AWS SDK y ejemplos de código, consulte Cómo utilizar este servicio con un AWS SDK. En este tema también se incluye información sobre cómo comenzar a utilizar el SDK y detalles sobre sus versiones anteriores.

Uso de **`StartJobRun`** con un SDK de AWS o la CLI

Los ejemplos de códigos que se muestran a continuación muestran cómo se utiliza `StartJobRun`.

Los ejemplos de acciones son extractos de código de programas más grandes y deben ejecutarse en contexto. Puede ver esta acción en contexto en el siguiente ejemplo de código:

- Conceptos básicos

.NET

SDK para .NET

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
/// <summary>
/// Start an AWS Glue job run.
/// </summary>
/// <param name="jobName">The name of the job.</param>
/// <returns>A string representing the job run Id.</returns>
public async Task<string> StartJobRunAsync(
    string jobName,
    string inputDatabase,
    string inputTable,
    string bucketName)
{
    var request = new StartJobRunRequest
    {
        JobName = jobName,
        Arguments = new Dictionary<string, string>
        {
            {"--input_database", inputDatabase},
            {"--input_table", inputTable},
```

```
                {"--output_bucket_url", $"s3://{bucketName}/"}
            }
        };

        var response = await _amazonGlue.StartJobRunAsync(request);
        return response.JobRunId;
    }
```

- Para obtener información sobre la API, consulte StartJobRun en la Referencia de la API de AWS SDK para .NET.

C++

SDK para C++

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
        Aws::Client::ClientConfiguration clientConfig;
        // Optional: Set to the AWS Region in which the bucket was created
(overrides config file).
        // clientConfig.region = "us-east-1";

    Aws::Glue::GlueClient client(clientConfig);

        Aws::Glue::Model::StartJobRunRequest request;
        request.SetJobName(JOB_NAME);

        Aws::Map<Aws::String, Aws::String> arguments;
        arguments["--input_database"] = CRAWLER_DATABASE_NAME;
        arguments["--input_table"] = tableName;
        arguments["--output_bucket_url"] = Aws::String("s3://") + bucketName +
"/";
        request.SetArguments(arguments);
```

```
        Aws::Glue::Model::StartJobRunOutcome outcome =
client.StartJobRun(request);

        if (outcome.IsSuccess()) {
            std::cout << "Successfully started the job." << std::endl;

            Aws::String jobRunId = outcome.GetResult().GetJobRunId();

            int iterator = 0;
            bool done = false;
            while (!done) {
                ++iterator;
                std::this_thread::sleep_for(std::chrono::seconds(1));
                Aws::Glue::Model::GetJobRunRequest jobRunRequest;
                jobRunRequest.SetJobName(JOB_NAME);
                jobRunRequest.SetRunId(jobRunId);

                Aws::Glue::Model::GetJobRunOutcome jobRunOutcome =
client.GetJobRun(
                        jobRunRequest);

                if (jobRunOutcome.IsSuccess()) {
                    const Aws::Glue::Model::JobRun &jobRun =
jobRunOutcome.GetResult().GetJobRun();
                    Aws::Glue::Model::JobRunState jobRunState =
jobRun.GetJobRunState();

                    if ((jobRunState == Aws::Glue::Model::JobRunState::STOPPED)
||
                        (jobRunState == Aws::Glue::Model::JobRunState::FAILED) ||
                        (jobRunState == Aws::Glue::Model::JobRunState::TIMEOUT))
{
                        std::cerr << "Error running job. "
                                  << jobRun.GetErrorMessage()
                                  << std::endl;
                        deleteAssets(CRAWLER_NAME, CRAWLER_DATABASE_NAME,
JOB_NAME,
                                     bucketName,
                                     clientConfig);
                        return false;
                    }
                    else if (jobRunState ==
                             Aws::Glue::Model::JobRunState::SUCCEEDED) {
                        std::cout << "Job run succeeded after  " << iterator <<
```

```
                                  " seconds elapsed." << std::endl;
                      done = true;
                  }
                  else if ((iterator % 10) == 0) { // Log status every 10
seconds.
                      std::cout << "Job run status " <<

Aws::Glue::Model::JobRunStateMapper::GetNameForJobRunState(
                                          jobRunState) <<
                                  ". " << iterator <<
                                  " seconds elapsed." << std::endl;
                  }
              }
              else {
                  std::cerr << "Error retrieving job run state. "
                            << jobRunOutcome.GetError().GetMessage()
                            << std::endl;
                  deleteAssets(CRAWLER_NAME, CRAWLER_DATABASE_NAME, JOB_NAME,
                               bucketName, clientConfig);
                  return false;
              }
          }
      }
      else {
          std::cerr << "Error starting a job. " <<
outcome.GetError().GetMessage()
                    << std::endl;
          deleteAssets(CRAWLER_NAME, CRAWLER_DATABASE_NAME, JOB_NAME,
bucketName,
                       clientConfig);
          return false;
      }
```

- Para obtener información sobre la API, consulte StartJobRun en la Referencia de la API de AWS SDK para C++.

CLI

AWS CLI

Inicio de la ejecución de un trabajo

El siguiente ejemplo de `start-job-run` inicia un trabajo.

```
aws glue start-job-run \
    --job-name my-job
```

Salida:

```
{
    "JobRunId":
 "jr_22208b1f44eb5376a60569d4b21dd20fcb8621e1a366b4e7b2494af764b82ded"
}
```

Para obtener más información, consulte Creación de trabajos en la Guía para desarrolladores de AWS Glue.

- Para obtener información sobre la API, consulte StartJobRun en la Referencia de comandos de la AWS CLI.

Java

SDK para Java 2.x

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
   /**
    * Starts a job run in AWS Glue.
    *
    * @param glueClient    the AWS Glue client to use for the job run
    * @param jobName       the name of the Glue job to run
    * @param inputDatabase the name of the input database
    * @param inputTable    the name of the input table
    * @param outBucket     the URL of the output S3 bucket
    * @throws GlueException if there is an error starting the job run
    */
   public static void startJob(GlueClient glueClient, String jobName, String
inputDatabase, String inputTable,
```

```
                                String outBucket) {
        try {
            Map<String, String> myMap = new HashMap<>();
            myMap.put("--input_database", inputDatabase);
            myMap.put("--input_table", inputTable);
            myMap.put("--output_bucket_url", outBucket);

            StartJobRunRequest runRequest = StartJobRunRequest.builder()
                .workerType(WorkerType.G_1_X)
                .numberOfWorkers(10)
                .arguments(myMap)
                .jobName(jobName)
                .build();

            StartJobRunResponse response = glueClient.startJobRun(runRequest);
            System.out.println("The request Id of the job is " +
 response.responseMetadata().requestId());

        } catch (GlueException e) {
            throw e;
        }
    }
```

- Para obtener información sobre la API, consulte StartJobRun en la Referencia de la API de AWS SDK for Java 2.x.

JavaScript

SDK para JavaScript (v3)

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
const startJobRun = (jobName, dbName, tableName, bucketName) => {
  const client = new GlueClient({});

  const command = new StartJobRunCommand({
```

```
    JobName: jobName,
    Arguments: {
      "--input_database": dbName,
      "--input_table": tableName,
      "--output_bucket_url": `s3://${bucketName}/`,
    },
  });

  return client.send(command);
};
```

- Para obtener información sobre la API, consulte StartJobRun en la Referencia de la API de AWS SDK para JavaScript.

PHP

SDK para PHP

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
        $jobName = 'test-job-' . $uniqid;

        $databaseName = "doc-example-database-$uniqid";

        $tables = $glueService->getTables($databaseName);

        $outputBucketUrl = "s3://$bucketName";
        $runId = $glueService->startJobRun($jobName, $databaseName, $tables,
$outputBucketUrl)['JobRunId'];

    public function startJobRun($jobName, $databaseName, $tables,
$outputBucketUrl): Result
    {
        return $this->glueClient->startJobRun([
            'JobName' => $jobName,
            'Arguments' => [
```

```
                'input_database' => $databaseName,
                'input_table' => $tables['TableList'][0]['Name'],
                'output_bucket_url' => $outputBucketUrl,
                '--input_database' => $databaseName,
                '--input_table' => $tables['TableList'][0]['Name'],
                '--output_bucket_url' => $outputBucketUrl,
            ],
        ]);
    }
```

- Para obtener información sobre la API, consulte StartJobRun en la Referencia de la API de AWS SDK para PHP.

Python

SDK para Python (Boto3)

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
class GlueWrapper:
    """Encapsulates AWS Glue actions."""

    def __init__(self, glue_client):
        """
        :param glue_client: A Boto3 Glue client.
        """
        self.glue_client = glue_client


    def start_job_run(self, name, input_database, input_table,
 output_bucket_name):
        """
        Starts a job run. A job run extracts data from the source, transforms it,
        and loads it to the output bucket.

        :param name: The name of the job definition.
```

```
        :param input_database: The name of the metadata database that contains
tables
                              that describe the source data. This is typically
created
                              by a crawler.
        :param input_table: The name of the table in the metadata database that
                            describes the source data.
        :param output_bucket_name: The S3 bucket where the output is written.
        :return: The ID of the job run.
        """
        try:
            # The custom Arguments that are passed to this function are used by
the
            # Python ETL script to determine the location of input and output
data.
            response = self.glue_client.start_job_run(
                JobName=name,
                Arguments={
                    "--input_database": input_database,
                    "--input_table": input_table,
                    "--output_bucket_url": f"s3://{output_bucket_name}/",
                },
            )
        except ClientError as err:
            logger.error(
                "Couldn't start job run %s. Here's why: %s: %s",
                name,
                err.response["Error"]["Code"],
                err.response["Error"]["Message"],
            )
            raise
        else:
            return response["JobRunId"]
```

- Para obtener información sobre la API, consulte StartJobRun en la Referencia de la API de AWS SDK para Python (Boto3).

Ruby

SDK para Ruby

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
# The `GlueWrapper` class serves as a wrapper around the AWS Glue API, providing
 a simplified interface for common operations.
# It encapsulates the functionality of the AWS SDK for Glue and provides methods
 for interacting with Glue crawlers, databases, tables, jobs, and S3 resources.
# The class initializes with a Glue client and a logger, allowing it to make API
 calls and log any errors or informational messages.
class GlueWrapper
  def initialize(glue_client, logger)
    @glue_client = glue_client
    @logger = logger
  end

  # Starts a job run for the specified job.
  #
  # @param name [String] The name of the job to start the run for.
  # @param input_database [String] The name of the input database for the job.
  # @param input_table [String] The name of the input table for the job.
  # @param output_bucket_name [String] The name of the output S3 bucket for the
 job.
  # @return [String] The ID of the started job run.
  def start_job_run(name, input_database, input_table, output_bucket_name)
    response = @glue_client.start_job_run(
      job_name: name,
      arguments: {
        '--input_database': input_database,
        '--input_table': input_table,
        '--output_bucket_url': "s3://#{output_bucket_name}/"
      }
    )
    response.job_run_id
  rescue Aws::Glue::Errors::GlueException => e
```

```
    @logger.error("Glue could not start job run #{name}: \n#{e.message}")
    raise
  end
```

- Para obtener información sobre la API, consulte StartJobRun en la Referencia de la API de AWS SDK para Ruby.

Rust

SDK para Rust

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
        let job_run_output = glue
            .start_job_run()
            .job_name(self.job())
            .arguments("--input_database", self.database())
            .arguments(
                "--input_table",
                self.tables
                    .first()
                    .ok_or_else(|| GlueMvpError::Unknown("Missing crawler
table".into()))?
                    .name(),
            )
            .arguments("--output_bucket_url", self.bucket())
            .send()
            .await
            .map_err(GlueMvpError::from_glue_sdk)?;

        let job = job_run_output
            .job_run_id()
            .ok_or_else(|| GlueMvpError::Unknown("Missing run id from just
started job".into()))?
            .to_string();
```

- Para obtener información sobre la API, consulte StartJobRun en la Referencia de la API de AWS SDK para Rust.

Swift

SDK para Swift

> **Note**
>
> Hay más en GitHub. Busque el ejemplo completo y aprenda a configurar y ejecutar en el Repositorio de ejemplos de código de AWS.

```
import AWSClientRuntime
import AWSGlue

    /// Start an AWS Glue job run.
    ///
    /// - Parameters:
    ///   - glueClient: The AWS Glue client to use.
    ///   - jobName: The name of the job to run.
    ///   - databaseName: The name of the AWS Glue database to run the job
 against.
    ///   - tableName: The name of the table in the database to run the job
 against.
    ///   - outputURL: The AWS S3 URI of the bucket location into which to
    ///     write the resulting output.
    ///
    /// - Returns: `true` if the job run is started successfully, otherwise
 `false`.
    func startJobRun(glueClient: GlueClient, name jobName: String, databaseName:
 String,
                     tableName: String, outputURL: String) async -> String? {
        do {
            let output = try await glueClient.startJobRun(
                input: StartJobRunInput(
                    arguments: [
                        "--input_database": databaseName,
                        "--input_table": tableName,
                        "--output_bucket_url": outputURL
                    ],
```

```
                jobName: jobName,
                numberOfWorkers: 10,
                workerType: .g1x
            )
        )

        guard let id = output.jobRunId else {
            return nil
        }

        return id
    } catch {
        return nil
    }
}
```

- Para obtener información sobre la API, consulte StartJobRun en la Referencia de la API de AWS SDK para Swift.

Para obtener una lista completa de las guías para desarrolladores de AWS SDK y ejemplos de código, consulte Cómo utilizar este servicio con un AWS SDK. En este tema también se incluye información sobre cómo comenzar a utilizar el SDK y detalles sobre sus versiones anteriores.

Seguridad en AWS Glue

La seguridad en la nube de AWS es la máxima prioridad. Como cliente de AWS, se beneficia de una arquitectura de red y un centro de datos que se han diseñado para satisfacer los requisitos de seguridad de las organizaciones más exigentes.

La seguridad es una responsabilidad compartida entre AWS y el usuario. El modelo de responsabilidad compartida la describe como seguridad de la nube y seguridad en la nube:

- Seguridad de la nube: AWS es responsable de proteger la infraestructura que ejecuta los servicios de AWS en la nube de AWS. AWS también proporciona servicios que puedes utilizar de forma segura. Auditores externos prueban y verifican periódicamente la eficacia de nuestra seguridad en el marco de los programas de conformidad de AWS. Para obtener más información sobre los programas de conformidad que se aplican a AWS Glue, consulte Servicios de AWS en el ámbito del programa de conformidad.
- Seguridad en la nube: su responsabilidad se determina según el servicio de AWS que utilice. También es responsable de otros factores, incluida la confidencialidad de los datos, los requisitos de la empresa y la legislación y la normativa aplicables.

Esta documentación le ayuda a comprender cómo aplicar el modelo de responsabilidad compartida a la hora de utilizar AWS Glue. Los siguientes temas le mostrarán cómo configurar AWS Glue para satisfacer sus objetivos de seguridad y de conformidad. También puede aprender a utilizar otros servicios de AWS que lo ayuden a monitorizar y proteger los recursos de AWS Glue.

Temas

- Protección de los datos en AWS Glue
- Administración de identidades y accesos para AWS Glue
- Modelos de control de acceso de AWS Lake Formation
- Uso de Concesiones de acceso a Amazon S3 con AWS Glue
- Propagación de identidades de confianza con AWS Glue ETL
- Registro y monitorización en AWS Glue
- Validación de conformidad en AWS Glue
- Resiliencia en AWS Glue
- Seguridad de la infraestructura en AWS Glue

Protección de los datos en AWS Glue

AWS Glue ofrece varias características que están diseñadas para ayudar a proteger sus datos.

Temas

- Cifrado de datos en reposo
- Cifrado de datos en tránsito
- Conformidad con FIPS
- Administración de claves
- Dependencia de AWS Glue en otros servicios de AWS
- Puntos de conexión de desarrollo

Cifrado de datos en reposo

AWS Glue admite el cifrado de datos en reposo para Creación de trabajos de ETL visual y Desarrollo de scripts usando puntos de conexión de desarrollo. Puede configurar trabajos de extracción, transformación y carga (ETL) y puntos de enlace de desarrollo para utilizar claves de AWS Key Management Service (AWS KMS) para escribir datos cifrados en reposo. También puede cifrar los metadatos almacenados en AWS Glue Data Catalog con claves que administre con AWS KMS. Además, puede usar las claves de AWS KMS para cifrar marcadores de trabajo y los registros que generan los rastreadores y los trabajos de ETL.

Puede cifrar objetos de metadatos en su AWS Glue Data Catalog además de los datos escritos en Amazon Simple Storage Service (Amazon S3) y Amazon CloudWatch Logs por trabajos, rastreadores y puntos de enlace de desarrollo. Cuando cree trabajos, rastreadores y puntos de enlace de desarrollo en AWS Glue, puede proporcionar valores de cifrado al asociar una configuración de seguridad. Las configuraciones de seguridad contienen claves de cifrado del servidor administradas por Amazon S3 (SSE-S3) o claves maestras de cliente (CMK) almacenadas en AWS KMS (SSE-KMS). Puede crear configuraciones de seguridad a través de la consola de AWS Glue.

También puede habilitar el cifrado de todo el Catálogo de datos en su cuenta. Para ello, especifique las CMK almacenadas en AWS KMS.

> **Important**
>
> AWS Glue solo es compatible con las claves simétricas administradas por el cliente. Para obtener más información, consulte Claves administradas por el cliente (CMK) en la Guía para desarrolladores de AWS Key Management Service.

Si el cifrado está activado, al agregar objetos del Catálogo de datos, ejecutar rastreadores, ejecutar trabajos o iniciar puntos de enlace de desarrollo, se utilizan claves SSE-S3 o SSE-KMS para escribir datos en reposo. Además, puede configurar AWS Glue para que solo acceda a almacenamiento de datos de Java Database Connectivity (JDBC) a través de un protocolo de seguridad de la capa de transporte (TLS) de confianza.

En AWS Glue, puede controlar la configuración de cifrado en los siguientes lugares:

- La configuración del Catálogo de datos.
- Las configuraciones de seguridad que cree.
- Configuración del cifrado del lado del servidor (SSE-S3 o SSE-KMS) que se transfiere como parámetro a su trabajo de ETL (extracción, transformación y carga) de AWS Glue.

Para obtener más información acerca de cómo configurar el cifrado, consulte Configuración del cifrado en AWS Glue.

Temas

- Cifrado del Catálogo de datos
- Cifrado de las contraseñas de conexión
- Cifrado de datos escritos por AWS Glue

Cifrado del Catálogo de datos

El cifrado AWS Glue Data Catalog permite una seguridad mejorada para los datos confidenciales. AWS Glue se integra con AWS Key Management Service (AWS KMS) para cifrar los metadatos almacenados en el Catálogo de datos. Las configuraciones de cifrado para los recursos en el Catálogo de datos se pueden activar o desactivar a través de la consola de AWS Glue o el AWS CLI.

Si el cifrado está activado en el Catálogo de datos, se cifrarán todos los objetos nuevos que se creen. Si el cifrado está desactivado, no se cifrarán los objetos nuevos que se creen, pero los objetos que ya estén cifrados permanecerán cifrados.

Se puede cifrar el Catálogo de datos en su totalidad con las claves de cifrado administradas por AWS o con las claves de cifrado administradas por el cliente. Para obtener más información sobre los tipos y los estados de las claves, consulte Conceptos de AWS Key Management Service en la Guía para desarrolladores de AWS Key Management Service.

> **Note**
>
> Cuando utiliza el catálogo de datos cifrado con un rastreador, debe mantener la configuración de cifrado. La eliminación de la configuración de cifrado después de que un rastreador haya procesado un catálogo cifrado produce errores. Si necesita eliminar la configuración de cifrado, cree un rastreador nuevo en lugar de modificar el existente.

Claves administradas de AWS

Las claves administradas de AWS son claves KMS que aparecen en su cuenta y que un servicio de AWS integrado con AWS KMS crea, administra y utiliza en su nombre. Las claves administradas de AWS en su cuenta se pueden visualizar, junto con sus políticas de claves, y en los registros de AWS CloudTrail se puede auditar su utilización. Sin embargo, estas claves no se pueden administrar ni cambiar sus permisos.

El cifrado en reposo se integra de manera automática con AWS KMS para administrar las claves administradas de AWS para AWS Glue y que se utilizan para cifrar los metadatos. Si no existe una clave administrada por AWS cuando se active el cifrado de los metadatos, AWS KMS creará una nueva de manera automática.

Para obtener más información, consulte Claves administradas de AWS.

Claves administradas por el cliente

Las claves administradas por el cliente son claves KMS de su Cuenta de AWS, que usted ha creado, posee y administra. Usted tiene el control total sobre estas claves de KMS. Puede hacer lo siguiente:

- Establecer y mantener las políticas de claves, las políticas de IAM y las subvenciones
- Habilitar y deshabilitar las claves
- Rotar su material de cifrado

- Agregar etiquetas.
- Crear alias que hagan referencia a las claves
- Programar la eliminación de las claves

Para obtener más información sobre la administración de los permisos de una clave administrada por el cliente, consulte Claves administradas por el cliente.

> **Important**
>
> AWS Glue solo es compatible con las claves simétricas administradas por el cliente. La lista de claves de KMS solo muestra las claves simétricas. Sin embargo, si selecciona Seleccionar un ARN de clave de KMS, la consola le deja escribir un ARN para cualquier tipo de clave. Asegúrese de introducir sólo ARN para claves simétricas.
> Para crear una clave simétrica administrada por el cliente, siga las instrucciones para la creación de claves simétricas administradas por el cliente en la Guía para desarrolladores de AWS Key Management Service.

Al activar el cifrado del Catálogo de datos en reposo, se cifran con claves MKS los tipos de recursos que se mencionan a continuación:

- Bases de datos
- Tablas
- Particiones
- Versiones de tablas
- Estadísticas de las columnas
- Funciones definidas por el usuario
- Vistas del Catálogo de datos

AWS GlueContexto de cifrado de

Un contexto de cifrado es un conjunto de pares de valor de clave opcional que pueden contener información contextual adicional sobre los datos. AWS KMS utiliza el contexto de cifrado como información autenticada adicional para permitir el cifrado autenticado. Cuando se incluye un contexto de cifrado en una solicitud para cifrar datos, AWS KMS vincula el contexto de cifrado a los datos cifrados. Para cifrar los datos, se incluye el mismo contexto de cifrado en la solicitud. AWS Glue

utiliza el mismo contexto de cifrado en todas las operaciones de cifrado de AWS KMS, en las cuales `glue_catalog_id` es la clave y el valor es `catalogId`.

```
"encryptionContext": {
    "glue_catalog_id": "111122223333"
}
```

Al utilizar una clave administrada por AWS o una clave simétrica administrada por el cliente para cifrar el Catálogo de datos, también se puede utilizar un contexto de cifrado en los documentos de la auditoría y en los registros para identificar la clave que se utiliza. El contexto de cifrado también aparece en los registros que generan los registros de AWS CloudTrail o de Amazon CloudWatch.

Habilitación del cifrado

El cifrado de los objetos de AWS Glue Data Catalog se puede activar en Configuraciones del Catálogo de datos en la consola de AWS Glue o con la AWS CLI.

Console

Para habilitar el cifrado mediante la consola

1. Inicie sesión en la Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. Seleccione Catálogo de datos en el panel de navegación.
3. En la página Configuraciones del Catálogo de datos, seleccione la casilla Cifrado de metadatos y luego seleccione una clave de AWS KMS.

   Al activar el cifrado, y si no se especificó una clave administrada por el cliente, las configuraciones de cifrado utilizan una clave de KMS administrada por AWS.
4. (Opcional) Al utilizar una clave administrada por el cliente para cifrar el Catálogo de datos, el Catálogo ofrece una opción para registrar un rol de IAM para cifrar y descifrar los recursos. Debe conceder permisos de rol de IAM para que los asuma AWS Glue en su nombre. Esto incluye los permisos de AWS KMS para cifrar y descifrar datos.

   Al crear un recurso nuevo en el Catálogo de datos, AWS Glue asume el rol de IAM que se brindó para cifrar los datos. De forma similar, cuando un cliente accede al recurso, AWS Glue asume el rol de IAM para cifrar los datos. Si se registra un rol de IAM con los permisos necesarios, la entidad principal que realiza la llamada ya no necesita permisos para acceder a la clave y descifrar los datos.

> **Important**
>
> Las operaciones de KMS se pueden delegar a un rol de IAM solo cuando se utiliza una clave administrada por el cliente para cifrar los recursos del Catálogo de datos. La característica de delegación de roles de KMS no es compatible con la utilización de claves administradas de AWS para el cifrado de los recursos del Catálogo de datos en este momento.

> **Warning**
>
> Al activar un rol de IAM para delegar las operaciones de KMS, ya no podrá acceder a los recursos del Catálogo de datos cifrados anteriormente con una clave administrada de AWS.

a. Para habilitar un rol de IAM que AWS Glue pueda asumir para cifrar y descifrar los datos en su nombre, seleccione la opción Delegar operaciones de KMS a un rol de IAM.

b. Luego, seleccione un rol de IAM.

   Para crear un rol de IAM;, consulte Crear un rol de IAM para AWS Glue.

   El rol de IAM asumido por AWS Glue para acceder al Catálogo de datos debe contar con los permisos para cifrar y descifrar los metadatos en el Catálogo de datos. Puede crear un rol de IAM y adjuntar las políticas integradas que me enumeran a continuación:

   - La política que figura a continuación se puede agregar para incluir los permisos de AWS KMS para cifrar y descifrar el Catálogo de datos.

     JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "kms:Decrypt",
        "kms:Encrypt",
```

```
        "kms:GenerateDataKey"
      ],
      "Resource": "arn:aws:kms:us-east-1:111122223333:key/<key-id>"
    }
  ]
}
```

- Luego, agregue al rol la política a continuación para que el servicio de AWS Glue asuma el rol de IAM.

  JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Sid": "",
      "Effect": "Allow",
      "Principal": {
        "Service": "glue.amazonaws.com"
      },
      "Action": "sts:AssumeRole"
    }
  ]
}
```

- Luego, agregue el permiso de `iam:PassRole` al rol de IAM.

  JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "iam:PassRole"
      ],
      "Resource": [
        "arn:aws:iam::111122223333:role/<encryption-role-name>"
      ]
    }
  ]
```

```
}
```

Al activar el cifrado, y si no se especificó un rol de IAM para que AWS Glue asuma, la entidad principal que acceda al Catálogo de datos debe contar con los permisos para realizar las operaciones de API que se enumeran a continuación:

- `kms:Decrypt`
- `kms:Encrypt`
- `kms:GenerateDataKey`

AWS CLI

Para habilitar el cifrado mediante el SDK o AWS CLI

- Use la operación de la API `PutDataCatalogEncryptionSettings`. Si no se especifica ninguna clave, AWS Glue utiliza una clave de cifrado administrada por AWS para la cuenta del cliente para cifrar el Catálogo de datos.

```
aws glue put-data-catalog-encryption-settings \
  --data-catalog-encryption-settings '{
      "EncryptionAtRest": {
      "CatalogEncryptionMode": "SSE-KMS-WITH-SERVICE-ROLE",
      "SseAwsKmsKeyId": "arn:aws:kms:<region>:<account-id>:key/<key-id>",
      "CatalogEncryptionServiceRole":"arn:aws:iam::<account-
id>:role/<encryption-role-name>"
    }

  }'
```

Al activar el cifrado, se cifran todos los objetos que se creen en el Catálogo de datos. Si elimina la configuración, ya no se cifrarán los objetos que se creen en el Catálogo de datos. Puede seguir accediendo a los objetos que ya están cifrados en el Catálogo de datos con los permisos de KMS requeridos.

> **Important**
>
> La clave AWS KMS debe permanecer disponible en el almacén de claves AWS KMS para todos los objetos que se cifran con ella en el Catálogo de datos. Si elimina la clave, los objetos ya no se podrán descifrar. Es posible que en determinados casos le interese esta opción para evitar el acceso a los metadatos del Catálogo de datos.

Monitoreo de las claves de KMS para AWS Glue

Al utilizar las claves de KMS para los recursos del Catálogo de datos, se pueden utilizar los Registros de AWS CloudTrail o de Amazon CloudWatch para rastrear las solicitudes que envía AWS Glue a AWS KMS. AWS CloudTrail monitorea y registra las operaciones de KMS a las cuales AWS Glue llama para acceder a los datos cifrados con las claves de KMS.

Los ejemplos que se muestran a continuación son eventos de AWS CloudTrail para las operaciones de `Decrypt` y `GenerateDataKey`.

Decrypt

```
{
    "eventVersion": "1.08",
    "userIdentity": {
        "type": "AssumedRole",
        "principalId": "AROAXPHTESTANDEXAMPLE:Sampleuser01",
        "arn": "arn:aws:sts::111122223333:assumed-role/Admin/Sampleuser01",
        "accountId": "111122223333",
        "accessKeyId": "AKIAIOSFODNN7EXAMPLE",
        "sessionContext": {
            "sessionIssuer": {
                "type": "Role",
                "principalId": "AROAXPHTESTANDEXAMPLE",
                "arn": "arn:aws:iam::111122223333:role/Admin",
                "accountId": "111122223333",
                "userName": "Admin"
            },
            "webIdFederationData": {},
            "attributes": {
                "creationDate": "2024-01-10T14:33:56Z",
                "mfaAuthenticated": "false"
```

```
            }
        },
        "invokedBy": "glue.amazonaws.com"
    },
    "eventTime": "2024-01-10T15:18:11Z",
    "eventSource": "kms.amazonaws.com",
    "eventName": "Decrypt",
    "awsRegion": "eu-west-2",
    "sourceIPAddress": "glue.amazonaws.com",
    "userAgent": "glue.amazonaws.com",
    "requestParameters": {
        "encryptionContext": {
            "glue_catalog_id": "111122223333"
        },
        "encryptionAlgorithm": "SYMMETRIC_DEFAULT"
    },
    "responseElements": null,
    "requestID": "43b019aa-34b8-4798-9b98-ee968b2d63df",
    "eventID": "d7614763-d3fe-4f84-a1e1-3ca4d2a5bbd5",
    "readOnly": true,
    "resources": [
        {
            "accountId": "111122223333",
            "type": "AWS::KMS::Key",
            "ARN": "arn:aws:kms:<region>:111122223333:key/<key-id>"
        }
    ],
    "eventType": "AwsApiCall",
    "managementEvent": true,
    "recipientAccountId": "111122223333",
    "eventCategory": "Management",
    "sessionCredentialFromConsole": "true"
}
```

GenerateDataKey

```
{
    "eventVersion": "1.08",
    "userIdentity": {
        "type": "AssumedRole",
        "principalId":
 "AROAXPHTESTANDEXAMPLE:V_00_GLUE_KMS_GENERATE_DATA_KEY_111122223333",
```

```
        "arn": "arn:aws:sts::111122223333:assumed-role/Admin/
V_00_GLUE_KMS_GENERATE_DATA_KEY_111122223333",
        "accountId": "111122223333",
        "accessKeyId": "AKIAIOSFODNN7EXAMPLE",
        "sessionContext": {
            "sessionIssuer": {
                "type": "Role",
                "principalId": "AROAXPHTESTANDEXAMPLE",
                "arn": "arn:aws:iam::111122223333:role/Admin",
                "accountId": "AKIAIOSFODNN7EXAMPLE",
                "userName": "Admin"
            },
            "webIdFederationData": {},
            "attributes": {
                "creationDate": "2024-01-05T21:15:47Z",
                "mfaAuthenticated": "false"
            }
        },
        "invokedBy": "glue.amazonaws.com"
    },
    "eventTime": "2024-01-05T21:15:47Z",
    "eventSource": "kms.amazonaws.com",
    "eventName": "GenerateDataKey",
    "awsRegion": "eu-west-2",
    "sourceIPAddress": "glue.amazonaws.com",
    "userAgent": "glue.amazonaws.com",
    "requestParameters": {
        "keyId": "arn:aws:kms:eu-west-2:AKIAIOSFODNN7EXAMPLE:key/
AKIAIOSFODNN7EXAMPLE",
        "encryptionContext": {
            "glue_catalog_id": "111122223333"
        },
        "keySpec": "AES_256"
    },
    "responseElements": null,
    "requestID": "64d1783a-4b62-44ba-b0ab-388b50188070",
    "eventID": "1c73689b-2ef2-443b-aed7-8c126585ca5e",
    "readOnly": true,
    "resources": [
        {
            "accountId": "111122223333",
            "type": "AWS::KMS::Key",
            "ARN": "arn:aws:kms:eu-west-2:111122223333:key/AKIAIOSFODNN7EXAMPLE"
        }
```

```
    ],
    "eventType": "AwsApiCall",
    "managementEvent": true,
    "recipientAccountId": "111122223333",
    "eventCategory": "Management"
}
```

Cifrado de las contraseñas de conexión

Puede recuperar las contraseñas de conexión en AWS Glue Data Catalog mediante las operaciones de la API `GetConnection` y `GetConnections`. Estas contraseñas se almacenan en la conexión del Catálogo de datos y se utilizan cuando AWS Glue se conecta a un almacén de datos de Java Database Connectivity (JDBC). Cuando se creó o actualizó la conexión, una opción en la configuración del Catálogo de datos determinó si la contraseña estaba cifrada, y en caso afirmativo, qué clave AWS Key Management Service (AWS KMS) se especificó.

En la consola de AWS Glue, puede habilitar esta opción en la página Data catalog settings (Configuración del Catálogo de datos).

Para cifrar las contraseñas de conexión

1. Inicie sesión en Consola de administración de AWS y abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. Seleccione Settings (Configuración) en el panel de navegación.
3. En la página Data catalog settings (Configuración del Catálogo de datos), seleccione Encrypt connection passwords (Cifrar contraseñas de conexión) y elija una clave AWS KMS.

> **Important**
>
> AWS Glue solo soporta claves maestras de cliente (CMK) simétricas. La lista de AWS KMS key (Clave KMS) muestra únicamente claves simétricas. Sin embargo, si selecciona Choose a AWS KMS key ARN (Elegir un ARN de clave KMS), la consola le

permite introducir un ARN para cualquier tipo de clave. Asegúrese de introducir sólo ARN para claves simétricas.

Para obtener más información, consulte Configuración del Catálogo de datos .

Cifrado de datos escritos por AWS Glue

Una configuración de seguridad es un conjunto de propiedades de seguridad que AWS Glue puede usar. Puede utilizar una configuración de seguridad para cifrar los datos en reposo. En las siguientes situaciones se muestran algunas de las maneras en las que puede utilizar una configuración de seguridad.

- Asocie una configuración de seguridad a un rastreador de AWS Glue para escribir registros cifrados de Amazon CloudWatch Logs. Para obtener más información sobre cómo asociar las configuraciones de seguridad a los rastreadores, consulte the section called “Establecimiento de la configuración de seguridad”.
- Asocie una configuración de seguridad a un trabajo de extracción, transformación y carga (ETL) para escribir destinos de Amazon Simple Storage Service (Amazon S3) cifrados y registros de CloudWatch Logs cifrados.
- Asocie una configuración de seguridad a un trabajo de ETL para escribir sus marcadores de trabajo como datos de Amazon S3 cifrados.
- Asocie una configuración de seguridad a un punto de enlace de desarrollo para escribir destinos de Amazon S3 cifrados.

Important

En la actualidad, una configuración de seguridad reemplaza cualquier configuración de cifrado del lado del servidor (SSE-S3) que se haya pasado como un parámetro de flujo de trabajo de ETL. Por lo tanto, si un flujo de trabajo tiene asociados una configuración de seguridad y un parámetro de SSE-S3, este último se ignorará.

Para obtener más información acerca de las configuraciones de seguridad, consulte Administración de las configuraciones de seguridad en la consola de AWS Glue.

Temas

- Configuración de AWS Glue para utilizar configuraciones de seguridad
- Creación de una ruta a AWS KMS para rastreadores y trabajos de VPC
- Administración de las configuraciones de seguridad en la consola de AWS Glue

Configuración de AWS Glue para utilizar configuraciones de seguridad

Siga estos pasos para configurar el entorno de AWS Glue para utilizar configuraciones de seguridad.

1. Cree o actualice las claves de AWS Key Management Service (AWS KMS) para conceder permisos de AWS KMS a los roles de IAM que se transfieren a los rastreadores y los trabajos de AWS Glue para cifrar registros de CloudWatch Logs. Para obtener más información, consulte Cifrado de datos de registro en CloudWatch Logs con AWS KMS en la Guía del usuario de Amazon CloudWatch Logs.

   En el siguiente ejemplo, *"role1"*, *"role2"* y *"role3"* son roles de IAM que se transfieren a los rastreadores y los trabajos.

   ```
   {
          "Effect": "Allow",
          "Principal": { "Service": "logs.region.amazonaws.com",
          "AWS": [
                   "role1",
                   "role2",
                   "role3"
                ] },
                      "Action": [
                             "kms:Encrypt*",
                             "kms:Decrypt*",
                             "kms:ReEncrypt*",
                             "kms:GenerateDataKey*",
                             "kms:Describe*"
                      ],
                      "Resource": "*"
   }
   ```

   La instrucción `Service`, que se muestra como `"Service": "logs.region.amazonaws.com"`, es necesaria si utiliza la clave para cifrar CloudWatch Logs.

2. Asegúrese de que la clave AWS KMS es `ENABLED` antes de utilizarla.

> **Note**
>
> Si utiliza Iceberg como marco de lago de datos, las tablas sw Iceberg tienen sus propios mecanismos para habilitar el cifrado del lado del servidor. Debe habilitar esta configuración además de las configuraciones de seguridad de AWS Glue. Para habilitar el cifrado del lado del servidor en las tablas de Iceberg, consulte las instrucciones de la documentación de Iceberg.

Creación de una ruta a AWS KMS para rastreadores y trabajos de VPC

Puede conectarse directamente a AWS KMS a través de un punto de enlace privado en su nube virtual privada (VPC) en lugar de conectarse a través de Internet. Cuando se utiliza un punto de enlace de la VPC, la comunicación entre la VPC y AWS KMS se realiza en su totalidad dentro de la red de AWS.

Puede crear un punto de enlace de la VPC de AWS KMS dentro de una VPC. Sin este paso, sus trabajos o rastreadores podrían generar un error con `kms timeout` en trabajos o con `internal service exception` en rastreadores. Para obtener instrucciones detalladas, consulte Conexión a AWS KMS a través de un punto de enlace de la VPC en la Guía para desarrolladores de AWS Key Management Service.

Cuando siga estas instrucciones, en la consola de VPC, debe hacer lo siguiente:

- Seleccione Enable Private DNS name (Habilitar nombre de DNS privado).
- Elija el Security group (Grupo de seguridad) (con regla de autorreferencia) que utilice para su trabajo o rastreador que accede a Java Database Connectivity (JDBC). Para obtener más información acerca de las conexiones de AWS Glue, consulte Conexión a datos.

Cuando agregue una configuración de seguridad a un rastreador o a un trabajo que accede a almacenes de datos de JDBC, AWS Glue debe tener una ruta al punto de enlace de la AWS KMS. Puede proporcionar la ruta con una gateway de conversión de las direcciones de red (NAT) o con un punto de enlace de las VPC de AWS KMS. Para crear una gateway NAT, consulte Gateways NAT en la Guía del usuario de Amazon VPC.

Administración de las configuraciones de seguridad en la consola de AWS Glue

> **Warning**
>
> Las configuraciones de seguridad de AWS Glue actualmente no son compatibles con los trabajos de Ray.

Una configuración de seguridad en AWS Glue contiene las propiedades que se necesitan cuando se escriben datos cifrados. Las configuraciones de seguridad se crean en la consola de AWS Glue para proporcionar las propiedades de cifrado que utilizan los rastreadores, los flujos de trabajo y los puntos de enlace de desarrollo.

Para ver una lista de todas las configuraciones de seguridad que ha creado, abra la consola de AWS Glue en https://console.aws.amazon.com/glue/ y elija Security configurations (Configuraciones de seguridad) en el panel de navegación.

En la lista Security configurations (Configuraciones de seguridad), se muestran las siguientes propiedades para cada configuración:

Nombre

Nombre único proporcionado al crear la configuración. El nombre puede contener letras (A-Z), números (0-9), guiones (-) o guiones bajos (_) y tener un máximo de 255 caracteres.

Habilite el cifrado de Amazon S3

Si está activado, el modo de cifrado de Amazon Simple Storage Service (Amazon S3), como `SSE-KMS` o `SSE-S3`, está habilitado para el almacenamiento de metadatos en el catálogo de datos.

Habilite el cifrado de registros de Amazon CloudWatch

Si está activado, el modo de cifrado de Amazon S3, como `SSE-KMS`, se habilita al escribir registros en Amazon CloudWatch.

Configuración avanzada: habilitar el cifrado de marcadores de trabajo

Si está activado, el modo de cifrado de Amazon S3, como `CSE-KMS`, se habilita cuando se marcan los trabajos.

Puede agregar o eliminar configuraciones en la sección Security configurations (Configuraciones de seguridad) en la consola. Para consultar más detalles sobre una configuración seleccione el nombre de la configuración en la lista. Los detalles incluirán la información que definió al crear la configuración.

Agregado de una configuración de seguridad

Para agregar una configuración de seguridad a través de la consola de AWS Glue, en la página Security configurations (Configuraciones de seguridad), seleccione Add security configuration (Agregar configuración de seguridad).

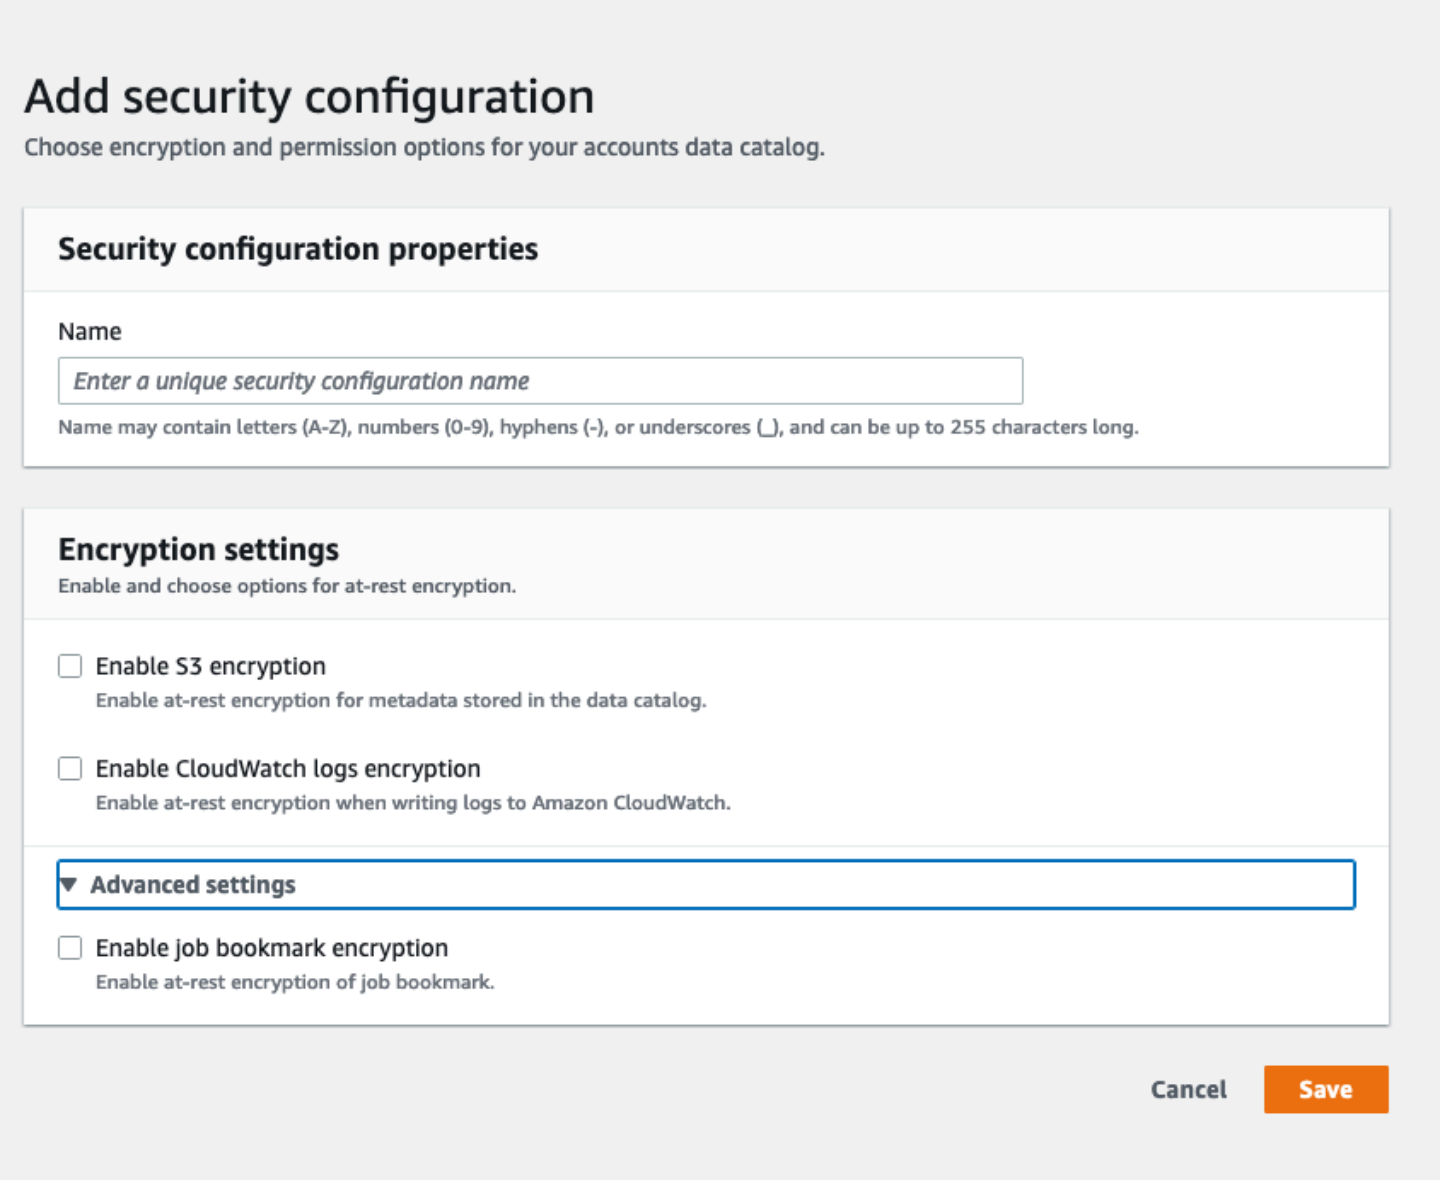

Propiedades de configuración de seguridad

Introduzca un nombre de configuración de seguridad único. El nombre puede contener letras (A-Z), números (0-9), guiones (-) o guiones bajos (_) y tener un máximo de 255 caracteres.

Configuración de cifrado

Puede habilitar el cifrado en reposo para los metadatos almacenados en el Data Catalog de Amazon S3 y los registros en Amazon CloudWatch. Para configurar el cifrado de datos y metadatos con claves de AWS Key Management Service (AWS KMS) en la consola de AWS Glue, agregue una política al usuario de la consola. Esta política debe especificar los recursos permitidos como los nombres de recurso de Amazon (ARN) de las claves que se utilizan para cifrar almacenes de datos de Amazon S3, tal y como se muestra en el siguiente ejemplo.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": {
    "Effect": "Allow",
    "Action": [
      "kms:GenerateDataKey",
      "kms:Decrypt",
      "kms:Encrypt"
    ],
    "Resource": "arn:aws:kms:us-east-1:111122223333:key/key-id"
  }
}
```

Important

Cuando una configuración de seguridad se asocia a un rastreador o trabajo, el rol de IAM que se transfiere debe tener permisos de AWS KMS. Para obtener más información, consulte Cifrado de datos escritos por AWS Glue.

Cuando se define una conexión, puede proporcionar valores para las siguientes propiedades:

Habilitar el cifrado de S3

Al escribir los datos de Amazon S3, puede utilizar el cifrado en el lado del servidor con claves administradas de Amazon S3 (SSE-S3) o el cifrado del lado del servidor con claves administradas de AWS KMS (SSE-KMS). Este campo es opcional. Para habilitar el acceso a Amazon S3, elija una clave AWS KMS, o elija Enter a key ARN (Ingresar un ARN de clave) y proporcione el ARN de la clave. Escriba el ARN con la forma `arn:aws:kms:`*`region`*`:`*`account-id`*`:key/`*`key-id`*. También puede proporcionar el ARN como un alias de clave, como `arn:aws:kms:`*`region`*`:`*`account-id`*`:alias/`*`alias-name`*.

Si habilita la interfaz de usuario de Spark para su trabajo, el archivo de registro de la interfaz de usuario de Spark cargado en Amazon S3 se aplicará con el mismo cifrado.

> **Important**
>
> AWS Glue solo soporta claves maestras de cliente (CMK) simétricas. La lista de AWS KMS key (Clave KMS) muestra únicamente claves simétricas. Sin embargo, si selecciona Choose a AWS KMS key ARN (Elegir un ARN de clave KMS), la consola le permite introducir un ARN para cualquier tipo de clave. Asegúrese de introducir sólo ARN para claves simétricas.

Habilitar el cifrado de registros de CloudWatch

Se utiliza el cifrado del lado del servidor (SSE-KMS) para cifrar registros de CloudWatch Logs. Este campo es opcional. Para habilitarlo, elija una clave AWS KMS o elija Enter a key ARN (Ingresar un ARN de clave) y proporcione el ARN para la clave. Escriba el ARN con la forma `arn:aws:kms:`*`region`*`:`*`account-id`*`:key/`*`key-id`*. También puede proporcionar el ARN como un alias de clave, como `arn:aws:kms:`*`region`*`:`*`account-id`*`:alias/`*`alias-name`*.

Configuración avanzada: cifrado de marcadores de trabajo

El cifrado del lado del cliente (CSE-KMS) se utiliza para cifrar marcadores de trabajos. Este campo es opcional. Los datos del marcador se cifran antes de enviarlos a Amazon S3 para su almacenamiento. Para habilitarlo, elija una clave AWS KMS o elija Enter a key ARN (Ingresar un ARN de clave) y proporcione el ARN para la clave. Escriba el ARN con la forma `arn:aws:kms:`*`region`*`:`*`account-id`*`:key/`*`key-id`*. También puede proporcionar el ARN como un alias de clave, como `arn:aws:kms:`*`region`*`:`*`account-id`*`:alias/`*`alias-name`*.

Para obtener más información, consulte los siguientes temas en la Guía del usuario de Amazon Simple Storage Service:

- Para obtener más información acerca de `SSE-S3`, consulte Protección de los datos con el cifrado del lado del servidor con claves de cifrado administradas por Amazon S3 (SSE-S3).
- Para obtener más información sobre `SSE-KMS`, consulte Protección de los datos con el cifrado del lado del servidor con AWS KMS keys.
- Para obtener más información sobre `CSE-KMS`, consulte Cómo usar una clave KMS almacenada en AWS KMS.

Cifrado de datos en tránsito

AWS ofrece cifrado de seguridad de la capa de transporte (TLS) para los datos en movimiento. Puede establecer la configuración de cifrado para rastreadores, trabajos de ETL y puntos de enlace de desarrollo mediante configuraciones de seguridad en AWS Glue. Puede habilitar el cifrado AWS Glue Data Catalog a través de la configuración del Catálogo de datos.

A partir del 4 de septiembre de 2018, se soporta AWS KMS (traiga su propia clave y cifrado del lado del servidor) para ETL de AWS Glue y la AWS Glue Data Catalog.

Conformidad con FIPS

Si necesita módulos criptográficos validados FIPS 140-2 al acceder a AWS a través de una interfaz de línea de comandos o una API, utilice un punto de conexión de FIPS. Para obtener más información sobre los puntos de conexión de FIPS disponibles, consulte Estándar de procesamiento de la información federal (FIPS) 140-2.

Administración de claves

Puede utilizar AWS Identity and Access Management (IAM) con AWS Glue para definir usuarios, recursos de AWS, grupos, roles y políticas detalladas en relación con el acceso, la denegación, etc.

Puede definir el acceso a los metadatos con ambas políticas basadas en recursos e identidades en función de las necesidades de su organización. Las políticas basadas en recursos enumeran las entidades principales a las que se le permite o deniega el acceso a sus recursos, lo que le permite configurar políticas como el acceso entre cuentas. Las políticas de identidades se asocian a los usuarios, grupos y roles dentro de IAM, de manera específica.

Para obtener un ejemplo paso a paso, consulte Restricción de acceso a AWS Glue Data Catalog con premisos de IAM a nivel de recursos y políticas con base en recursos en el blog de Big Data de AWS.

La parte de acceso detallado de la política se define en la cláusula `Resource`. Esta parte define tanto el objeto de AWS Glue Data Catalog en el que se puede realizar la acción como los objetos resultantes devueltos por esa operación.

Un punto de enlace de desarrollo es un entorno que puede utilizar para desarrollar y probar los scripts de AWS Glue. Puede agregar, eliminar o rotar la clave SSH de un punto de enlace de desarrollo.

A partir del 4 de septiembre de 2018, se soporta AWS KMS (traiga su propia clave y cifrado del lado del servidor) para ETL de AWS Glue y la AWS Glue Data Catalog.

Dependencia de AWS Glue en otros servicios de AWS

Para que un usuario pueda trabajar con la consola de AWS Glue, debe tener un conjunto mínimo de permisos que le permitan trabajar con los recursos de AWS Glue en su cuenta de AWS. Además de estos permisos de AWS Glue, la consola requiere permisos de los servicios a continuación:

- Permisos de Amazon CloudWatch Logs para mostrar registros.
- Permisos de AWS Identity and Access Management (IAM) para enumerar y transferir roles.
- Permisos CloudFormation para trabajar con pilas.
- Permisos de Amazon Elastic Compute Cloud (Amazon EC2) para enumerar las nubes privadas virtuales (VPC), subredes, grupos de seguridad, instancias y otros objetos (para configurar elementos de Amazon EC2 como VPC cuando se ejecutan trabajos y rastreadores, y se crean puntos de enlace de desarrollo).
- Permisos de Amazon Simple Storage Service (Amazon S3) para enumerar buckets y objetos, y recuperar y guardar scripts.
- Permisos necesarios de Amazon Redshift para trabajar con clústeres.
- Permisos de Amazon Relational Database Service (Amazon RDS) para enumerar instancias.

Puntos de conexión de desarrollo

Un punto de enlace de desarrollo es un entorno que puede utilizar para desarrollar y probar los scripts de AWS Glue. Puede usar AWS Glue para crear, editar y eliminar puntos de enlace de

desarrollo. Puede enumerar todos los puntos conexión de desarrollo creados. Puede agregar, eliminar o rotar la clave SSH de un punto de enlace de desarrollo. También puede crear blocs de notas que usen el punto de enlace de desarrollo.

Puede proporcionar valores de configuración para aprovisionar los entornos de desarrollo. Estos valores indican a AWS Glue cómo configurar la red para que pueda obtener acceso a su punto de enlace de desarrollo de forma segura y que su punto de enlace pueda obtener acceso a sus almacenes de datos. A continuación, puede crear un bloc de notas que se conecte al punto de enlace de desarrollo. Puede utilizar el bloc de notas para crear y probar su script de ETL.

Use un rol de AWS Identity and Access Management (IAM) con permisos similares al rol de IAM que utiliza para ejecutar trabajos de ETL de AWS Glue. Utilice una nube privada virtual (VPC), una subred, y un grupo de seguridad para crear un punto de enlace de desarrollo que se pueda conectar a sus recursos de datos de forma segura. Puede generar un par de claves SSH para conectarse al entorno de desarrollo mediante SSH.

Puede crear puntos de enlace de desarrollo para datos de Amazon S3 y dentro de una VPC que puede utilizar para acceder a conjuntos de datos a través de JDBC.

Puede instalar un cliente de cuaderno de Jupyter en su equipo local y utilizarlo para depurar y probar scripts ETL en un punto de conexión de desarrollo. O bien, puede usar un cuaderno de Sagemaker para crear scripts de ETL en JupyterLab en AWS. Consulte Uso de un cuaderno de SageMaker con su punto de conexión de desarrollo.

AWS Glue etiqueta las instancias de Amazon EC2 con un nombre prefijado con `aws-glue-dev-endpoint`.

Puede configurar un servidor de cuadernos en un punto de conexión de desarrollo para ejecutar PySpark con extensiones de AWS Glue.

Administración de identidades y accesos para AWS Glue

AWS Identity and Access Management (IAM) es un Servicio de AWS que ayuda a los gestionadores a controlar de forma segura el acceso a los recursos de AWS. Los administradores de IAM controlan quién está autenticado (ha iniciado sesión) y autorizado (tiene permisos) para utilizar recursos de AWS Glue. IAM es un servicio de Servicio de AWS que se puede utilizar sin cargo adicional.

> **Note**
>
> Puede conceder acceso a sus datos en el Catálogo de datos de AWS Glue mediante métodos de AWS Glue o concesiones de AWS Lake Formation. Puede utilizar las políticas de AWS Identity and Access Management (IAM) para controlar de manera precisa el acceso con métodos de AWS Glue. Lake Formation utiliza un modelo de permisos `GRANT/REVOKE` más simple que es similar a los comandos `GRANT/REVOKE` en un sistema de base de datos relacional.
>
> Esta sección incluye información sobre cómo usar los métodos de AWS Glue. Para obtener más información sobre cómo utilizar las concesiones de Lake Formation, consulte Concesión de permisos de Lake Formation en la Guía para desarrolladores de AWS Lake Formation.

Temas

- Público
- Autenticación con identidades
- Administración de acceso mediante políticas
- Funcionamiento de AWS Glue con IAM
- Configuración de permisos de IAM para AWS Glue
- Ejemplos de políticas de control de acceso de AWS Glue
- Concesión de políticas administradas de AWS para AWS Glue
- Otorgamiento de políticas con un alcance dinámico para la ejecución de trabajos
- Especificación de ARN del recurso de AWS Glue
- Concesión de acceso entre cuentas
- Solución de problemas de identidad y acceso en AWS Glue

Público

La forma en que utiliza AWS Identity and Access Management (IAM) varía en función del rol:

- Usuario del servicio: solicite permisos al administrador si no puede acceder a las características (consulte Solución de problemas de identidad y acceso en AWS Glue)
- Administrador del servicio: determine el acceso de los usuarios y envíe las solicitudes de permiso (consulte Funcionamiento de AWS Glue con IAM)

- Administrador de IAM: escriba políticas para administrar el acceso (consulte Ejemplos de políticas basadas en identidades para AWS Glue)

Autenticación con identidades

La autenticación es la manera de iniciar sesión en AWS mediante credenciales de identidad. Debe estar autenticado como Usuario raíz de la cuenta de AWS, un usuario de IAM o asumiendo un rol de IAM.

Puede iniciar sesión como una identidad federada con las credenciales de un origen de identidad, como AWS IAM Identity Center (IAM Identity Center), la autenticación de inicio de sesión único o las credenciales de Google/Facebook. Para obtener más información sobre el inicio de sesión, consulte Cómo iniciar sesión en la Cuenta de AWS en la Guía del usuario de AWS Sign-In.

Para el acceso programático, AWS proporciona un SDK y una CLI para firmar criptográficamente las solicitudes. Para obtener más información, consulte AWS Signature Version 4 para solicitudes de API en la Guía del usuario de IAM.

Usuario raíz de la Cuenta de AWS

Cuando se crea una Cuenta de AWS, se comienza con una identidad de inicio de sesión llamada Cuenta de AWS del usuario raíz que tiene acceso completo a todos los Servicios de AWS y recursos. Recomendamos encarecidamente que no utilice el usuario raíz para las tareas diarias. Para ver las tareas que requieren credenciales de usuario raíz, consulte Tareas que requieren credenciales de usuario raíz en la Guía del usuario de IAM.

Identidad federada

Como práctica recomendada, exija a los usuarios humanos que utilicen la federación con un proveedor de identidades para acceder a Servicios de AWS con credenciales temporales.

Una identidad federada es un usuario del directorio empresarial, proveedor de identidades web o Directory Service que accede a Servicios de AWS mediante credenciales de un origen de identidad. Las identidades federadas asumen roles que proporcionan credenciales temporales.

Para una administración de acceso centralizada, le recomendamos AWS IAM Identity Center. Para obtener más información, consulte ¿Qué es el Centro de identidades de IAM? en la Guía del usuario de AWS IAM Identity Center.

Usuarios y grupos de IAM

Un usuario de IAM es una identidad con permisos específicos para una sola persona o aplicación. Recomendamos el uso de credenciales temporales en lugar de usuarios de IAM con credenciales a largo plazo. Para obtener más información, consulte Solicitar que los usuarios humanos utilicen la federación con un proveedor de identidades para acceder a AWS mediante credenciales temporales en la Guía del usuario de IAM.

Un grupo de IAM especifica un conjunto de usuarios de IAM y facilita la administración de los permisos para grupos grandes de usuarios. Para obtener más información, consulte Casos de uso para usuarios de IAM en la Guía del usuario de IAM.

Roles de IAM

Un rol de IAM es una identidad con permisos específicos que proporciona credenciales temporales. Puede asumir un rol cambiando de un usuario a un rol de IAM (consola) o llamando a una operación de la API de la AWS CLI o AWS. Para obtener más información, consulte Métodos para asumir un rol en la Guía del usuario de IAM.

Los roles de IAM son útiles para el acceso de usuarios federados, los permisos de usuario de IAM temporales, el acceso entre cuentas, el acceso entre servicios y las aplicaciones que se ejecutan en Amazon EC2. Para obtener más información, consulte Acceso a recursos entre cuentas en IAM en la Guía del usuario de IAM.

Administración de acceso mediante políticas

Para controlar el acceso en AWS, se crean políticas y se adjuntan a identidades o recursos de AWS. Una política define permisos cuando se asocia con una identidad o recurso. AWS evalúa estas políticas cuando una entidad principal realiza una solicitud. La mayoría de las políticas se almacenan en AWS como documentos JSON. Para obtener más información sobre los documentos de política JSON, consulte Información general de políticas JSON en la Guía del usuario de IAM.

Mediante políticas, los administradores especifican quién tiene acceso a qué definiendo qué entidad principal puede realizar acciones sobre qué recursos y en qué condiciones.

De forma predeterminada, los usuarios y los roles no tienen permisos. Un administrador de IAM crea políticas de IAM y las agrega a los roles, que luego los usuarios pueden asumir. Las políticas de IAM definen permisos independientemente del método utilizado para realizar la operación.

Políticas basadas en identidades

Las políticas basadas en identidad son documentos JSON de políticas de permisos que asocia a una identidad (usuario, grupo o rol). Estas políticas controlan qué acciones pueden realizar las identidades, en qué recursos y en qué condiciones. Para obtener más información sobre cómo crear una política basada en identidad, consulte Creación de políticas de IAM en la Guía del usuario de IAM.

Las políticas basadas en la identidad pueden ser políticas integradas (incrustadas directamente en una sola identidad) o políticas administradas (políticas independientes asociadas a varias identidades). Para obtener información sobre cómo elegir entre políticas administradas e insertadas, consulte Elegir entre políticas administradas y políticas insertadas en la Guía del usuario de IAM.

Políticas basadas en recursos

Las políticas basadas en recursos son documentos de políticas JSON que se asocian a un recurso. Los ejemplos incluyen las políticas de confianza de roles de IAM y las políticas de bucket de Amazon S3. En los servicios que admiten políticas basadas en recursos, los administradores de servicios pueden utilizarlos para controlar el acceso a un recurso específico. Debe especificar una entidad principal en una política en función de recursos.

Las políticas basadas en recursos son políticas insertadas que se encuentran en ese servicio. No se puede utilizar políticas de IAM administradas por AWS en una política basada en recursos.

Otros tipos de políticas

AWS admite tipos de políticas adicionales que pueden establecer el máximo de permisos concedidos por los tipos de políticas más comunes:

- Límites de permisos: establecen los permisos máximos que una política basada en la identidad puede conceder a una entidad de IAM. Para obtener más información, consulte Límites de permisos para las entidades de IAM en la Guía del usuario de IAM.
- Políticas de control de servicios (SCP): especifican los permisos máximos para una organización o unidad organizativa en AWS Organizations. Para obtener más información, consulte Políticas de control de servicios en la Guía del usuario de AWS Organizations.
- Políticas de control de recursos (RCP): establecen los permisos máximos disponibles para los recursos de las cuentas. Para obtener más información, consulte Políticas de control de recursos (RCP) en la Guía del usuario de AWS Organizations.

- Políticas de sesión: políticas avanzadas que se pasan como parámetro cuando se crea una sesión temporal para un rol o un usuario federado. Para más información, consulte Políticas de sesión en la Guía del usuario de IAM.

Varios tipos de políticas

Cuando se aplican varios tipos de políticas a una solicitud, los permisos resultantes son más complicados de entender. Para obtener información acerca de cómo AWS decide si permitir o no una solicitud cuando hay varios tipos de políticas implicados, consulte Lógica de evaluación de políticas en la Guía del usuario de IAM.

Funcionamiento de AWS Glue con IAM

Antes de utilizar IAM para administrar el acceso a AWS Glue, conozca qué características de IAM se pueden utilizar con AWS Glue.

Características de IAM que puede utilizar con AWS Glue

Característica de IAM	Compatibilidad de AWS Glue
Políticas basadas en identidades	Sí
Políticas basadas en recursos	Parcial
Acciones de políticas	Sí
Recursos de políticas	Sí
Claves de condición de política (específicas del servicio)	Sí
ACL	No
ABAC (etiquetas en políticas)	Parcial
Credenciales temporales	Sí
Permisos de entidades principales	No

Característica de IAM	Compatibilidad de AWS Glue
Roles de servicio	Sí
Roles vinculados al servicio	No

Para obtener una perspectiva general sobre cómo funcionan AWS Glue y otros servicios de AWS con la mayoría de las características de IAM, consulte Servicios de AWS que funcionan con IAM en la Guía del usuario de IAM.

Políticas basadas en identidades de AWS Glue

Compatibilidad con las políticas basadas en identidad: sí

Las políticas basadas en identidad son documentos de políticas de permisos JSON que puede asociar a una identidad, como un usuario de IAM, un grupo de usuarios o un rol. Estas políticas controlan qué acciones pueden realizar los usuarios y los roles, en qué recursos y en qué condiciones. Para obtener más información sobre cómo crear una política basada en identidad, consulte Creación de políticas de IAM en la Guía del usuario de IAM.

Con las políticas basadas en identidades de IAM, puede especificar las acciones y los recursos permitidos o denegados, así como las condiciones en las que se permiten o deniegan las acciones. Para obtener más información sobre los elementos que puede utilizar en una política de JSON, consulte Referencia de los elementos de las políticas de JSON de IAM en la Guía del usuario de IAM.

AWS Glue admite políticas basadas en identidad (políticas de IAM) para todas las operaciones de AWS Glue. Al asociar una política, puede conceder permisos para crear o modificar un recurso de AWS Glue, como una tabla en AWS Glue Data Catalog, o para acceder a él.

Ejemplos de políticas basadas en identidades para AWS Glue

Para ver ejemplos de políticas basadas en identidades de AWS Glue, consulte Ejemplos de políticas basadas en identidades para AWS Glue.

Políticas basadas en recursos de AWS Glue

Compatibilidad con las políticas basadas en recursos: parcial

Las políticas basadas en recursos son documentos de política JSON que se asocian a un recurso. Los ejemplos de políticas basadas en recursos son las políticas de confianza de roles de IAM y las políticas de bucket de Amazon S3. En los servicios que admiten políticas basadas en recursos, los administradores de servicios pueden utilizarlos para controlar el acceso a un recurso específico. Para el recurso al que se asocia la política, la política define qué acciones puede realizar una entidad principal especificada en ese recurso y en qué condiciones. Debe especificar una entidad principal en una política en función de recursos. Las entidades principales pueden incluir cuentas, usuarios, roles, usuarios federados o Servicios de AWS.

Para habilitar el acceso entre cuentas, puedes especificar toda una cuenta o entidades de IAM de otra cuenta como la entidad principal de una política en función de recursos. Para obtener más información, consulte Acceso a recursos entre cuentas en IAM en la Guía del usuario de IAM.

> **Note**
>
> Solo puede usar una política de recursos de AWS Glue para administrar los permisos de los recursos del Catálogo de datos. No se puede adjuntar a otros recursos de AWS Glue como trabajos, disparadores, puntos de enlace de desarrollo, rastreadores o clasificadores.
> Solo se permite una política de recursos por catálogo y su tamaño se limita a 10 KB.

En AWS Glue, una política de recursos se asocia a un catálogo, que es un contenedor virtual para todos los tipos de recursos del Catálogo de datos mencionados antes. Cada cuenta de AWS posee un único catálogo en una región de AWS, cuyo ID de catálogo es el mismo que el ID de cuenta de AWS. No puede eliminar ni modificar un catálogo.

Una política de recursos se evalúa para todas las llamadas a la API en el catálogo donde el principal del intermediario se incluye en el bloque `"Principal"` del documento de política.

Para ver ejemplos de políticas basadas en recursos de AWS Glue, consulte Ejemplos de políticas basadas en recursos para AWS Glue.

Acciones de política para AWS Glue

Compatibilidad con las acciones de políticas: sí

Los administradores pueden utilizar las políticas JSON de AWS para especificar quién tiene acceso a qué. Es decir, qué entidad principal puede realizar acciones en qué recursos y en qué condiciones.

El elemento `Action` de una política JSON describe las acciones que puede utilizar para conceder o denegar el acceso en una política. Incluya acciones en una política para conceder permisos y así llevar a cabo la operación asociada.

Para ver una lista de las acciones de AWS Glue, consulte Acciones definidas por AWS Glue en la Referencia de autorizaciones de servicio.

Las acciones de políticas de AWS Glue utilizan el siguiente prefijo antes de la acción:

```
glue
```

Para especificar varias acciones en una única instrucción, sepárelas con comas.

```
"Action": [
      "glue:action1",
      "glue:action2"
         ]
```

Puede utilizar caracteres comodín (*) para especificar varias acciones . Por ejemplo, para especificar todas las acciones que comiencen con la palabra `Get`, incluya la siguiente acción:

```
"Action": "glue:Get*"
```

Para ver ejemplos de políticas, consulte Ejemplos de políticas de control de acceso de AWS Glue.

Recursos de políticas para AWS Glue

Compatibilidad con los recursos de políticas: sí

Los administradores pueden utilizar las políticas JSON de AWS para especificar quién tiene acceso a qué. Es decir, qué entidad principal puede realizar acciones en qué recursos y en qué condiciones.

El elemento `Resource` de la política JSON especifica el objeto u objetos a los que se aplica la acción. Como práctica recomendada, especifique un recurso utilizando el Nombre de recurso de Amazon (ARN). Para las acciones que no admiten permisos por recurso, utilice un carácter comodín (*) para indicar que la instrucción se aplica a todos los recursos.

```
"Resource": "*"
```

Para obtener más información sobre cómo controlar el acceso a los recursos de AWS Glue con los ARN, consulte Especificación de ARN del recurso de AWS Glue.

Para ver una lista de los tipos de recursos de AWS Glue y sus ARN, consulte Recursos definidos por AWS Glue en la Referencia de autorizaciones de servicio. Para averiguar cuáles son las acciones que puede usar para especificar el ARN de cada recurso, consulte Acciones definidas por AWS Glue.

Claves de condición de política para AWS Glue

Compatibilidad con claves de condición de políticas específicas del servicio: sí

Los administradores pueden utilizar las políticas JSON de AWS para especificar quién tiene acceso a qué. Es decir, qué entidad principal puede realizar acciones en qué recursos y en qué condiciones.

El elemento `Condition` especifica cuándo se ejecutan las instrucciones en función de criterios definidos. Puedes crear expresiones condicionales que utilizan operadores de condición, tales como igual o menor que, para que la condición de la política coincida con los valores de la solicitud. Para ver todas las claves de condición globales de AWS, consulte Claves de contexto de condición globales de AWS en la Guía del usuario de IAM.

Para ver una lista de las claves de condición de AWS Glue, consulte Claves de condición para AWS Glue en la Referencia de autorizaciones de servicio. Para averiguar qué acciones y recursos puede usar con una clave de condición, consulte Acciones definidas por AWS Glue.

Para ver ejemplos de políticas, consulte Controlar la configuración mediante claves de condición o claves de contexto.

ACL en AWS Glue

Compatibilidad con ACL: no

Las listas de control de acceso (ACL) controlan qué entidades principales (miembros de cuentas, usuarios o roles) tienen permisos para acceder a un recurso. Las ACL son similares a las políticas basadas en recursos, aunque no utilizan el formato de documento de políticas JSON.

ABAC con AWS Glue

Compatibilidad con ABAC (etiquetas en las políticas): parcial

El control de acceso basado en atributos (ABAC) es una estrategia de autorización que define permisos en función de atributos denominados etiquetas. Puede asociar etiquetas a entidades de IAM y recursos de AWS y, a continuación, diseñar políticas de ABAC para permitir operaciones cuando la etiqueta de la entidad principal coincida con la etiqueta del recurso.

Para controlar el acceso en función de etiquetas, debe proporcionar información de las etiquetas en el elemento de condición de una política utilizando las claves de condición `aws:ResourceTag/key-name`, `aws:RequestTag/key-name` o `aws:TagKeys`.

Si un servicio admite las tres claves de condición para cada tipo de recurso, el valor es Sí para el servicio. Si un servicio admite las tres claves de condición solo para algunos tipos de recursos, el valor es Parcial.

Para obtener más información sobre ABAC, consulte Definición de permisos con la autorización de ABAC en la Guía del usuario de IAM. Para ver un tutorial con los pasos para configurar ABAC, consulte Uso del control de acceso basado en atributos (ABAC) en la Guía del usuario de IAM.

> **Important**
>
> Las claves de contexto de condición se aplican únicamente a las acciones de API de AWS Glue que se realizan en los rastreadores, los trabajos, los desencadenadores y los puntos de conexión de desarrollo. Para obtener más información sobre las operaciones de API que se ven afectadas, consulte Claves de condición para AWS Glue.
> Las operaciones de API del Catálogo de datos de AWS Glue no admiten actualmente las claves de contexto de condiciones globales `aws:referer` y `aws:UserAgent`.

Para consultar un ejemplo de política basada en la identidad para limitar el acceso a un recurso en función de las etiquetas de ese recurso, consulte Conceder acceso mediante etiquetas.

Uso de credenciales temporales con AWS Glue

Compatibilidad con credenciales temporales: sí

Las credenciales temporales proporcionan acceso a corto plazo a los recursos de AWS y se crean automáticamente cuando se utiliza la federación o se cambia de rol. AWS recomienda que genere de forma dinámica credenciales temporales en lugar de usar claves de acceso a largo plazo. Para obtener más información, consulte Credenciales de seguridad temporales en IAM y Servicios de AWS que funcionan con IAM en la Guía del usuario de IAM.

Permisos de entidades principales entre servicios para AWS Glue

Compatibilidad con sesiones de acceso directo (FAS): no

Las sesiones de acceso directo (FAS) utilizan los permisos de la entidad principal para llamar a un Servicio de AWS, combinados con el Servicio de AWS solicitante para realizar solicitudes a servicios posteriores. Para obtener información detallada sobre las políticas al momento de realizar solicitudes de FAS, consulte Reenviar las sesiones de acceso.

Roles de servicio para AWS Glue

Compatibilidad con roles de servicio: sí

Un rol de servicio es un rol de IAM que asume un servicio para realizar acciones en su nombre. Un administrador de IAM puede crear, modificar y eliminar un rol de servicio desde IAM. Para obtener más información, consulte Creación de un rol para delegar permisos a un Servicio de AWS en la Guía del usuario de IAM.

> **Warning**
>
> Cambiar los permisos de un rol de servicio podría interrumpir la funcionalidad de AWS Glue. Edite los roles de servicio solo cuando AWS Glue proporcione orientación para hacerlo.

Para obtener instrucciones detalladas sobre cómo crear un rol de servicio para AWS Glue, consulte Paso 1: Crear una política de IAM para el servicio AWS Glue y Paso 2: creación de un rol de IAM para AWS Glue.

Roles vinculados a servicios para AWS Glue

Compatibilidad con roles vinculados al servicio: no

Un rol vinculado a servicios es un tipo de rol de servicio que está vinculado a un Servicio de AWS. El servicio puedes asumir el rol para realizar una acción en su nombre. Los roles vinculados a servicios aparecen en la Cuenta de AWS y son propiedad del servicio. Un administrador de IAM puedes ver, pero no editar, los permisos de los roles vinculados a servicios.

Para más información sobre cómo crear o administrar roles vinculados a servicios, consulta Servicios de AWS que funcionan con IAM. Busque un servicio en la tabla que incluya `Yes` en la columna Rol

vinculado a un servicio. Seleccione el vínculo Sí para ver la documentación acerca del rol vinculado a servicios para ese servicio.

Configuración de permisos de IAM para AWS Glue

AWS Identity and Access Management (IAM) se utiliza para definir políticas y roles que AWS Glue utiliza para acceder a recursos. Los siguientes pasos lo guiarán a través de varias opciones para configurar los permisos para AWS Glue. Según las necesidades de su negocio, es posible que tenga que añadir o reducir el acceso a los recursos.

> **Note**
>
> Para empezar a utilizar los permisos de IAM básicos para AWS Glue en su lugar, consulte Configuración de permisos de IAM para AWS Glue.

1. Crear una política de IAM para el servicio AWS Glue: cree una política de servicio que le permita acceder a los recursos de AWS Glue.
2. Crear un rol de IAM para AWS Glue: cree un rol de IAM y adjunte la política de servicio de AWS Glue y una política para los recursos de Amazon Simple Storage Service (Amazon S3) utilizados por AWS Glue.
3. Adjuntar una política a los usuarios o los grupos que acceden a AWS Glue: adjunte políticas a todo usuario o grupo que inicie sesión en la consola de AWS Glue.
4. Crear una política de IAM para los blocs de notas: cree una política de servidor de blocs de notas para utilizarla en la creación de servidores de blocs de notas en los puntos de conexión de desarrollo.
5. Crear un rol de IAM para los blocs de notas: cree un rol de IAM y adjunte la política de servidor de blocs de notas.
6. Crear una política de IAM para los cuadernos de IA de Amazon SageMaker: cree una política de IAM para utilizarla al crear cuadernos de IA de Amazon SageMaker en puntos de conexión de desarrollo.
7. Crear un rol de IAM para los cuadernos de IA de Amazon SageMaker: cree un rol de IAM y adjunte la política para otorgar permisos al crear cuadernos de IA de Amazon SageMaker en puntos de conexión de desarrollo.

Paso 1: Crear una política de IAM para el servicio AWS Glue

Para cualquier operación que obtenga acceso a datos que estén en otro recurso de AWS, como el acceso a sus objetos en Amazon S3, AWS Glue necesita permiso para obtener acceso al recurso en su nombre. Estos permisos los concede utilizando AWS Identity and Access Management (IAM).

> **Note**
>
> Puede omitir este paso si utiliza la política administrada de AWS, **`AWSGlueServiceRole`**.

En este paso, crea una política que es similar a `AWSGlueServiceRole`. Puede encontrar la versión más actualizada de `AWSGlueServiceRole` en la consola de IAM.

Para crear una política de IAM para AWS Glue

Esta política concede permiso para que algunas acciones de Amazon S3 administren recursos de su cuenta que AWS Glue necesita cuando asume el rol con esta política. Algunos de los recursos especificados en esta política hacen referencia a nombres predeterminados que AWS Glue utiliza para buckets de Amazon S3, scripts de ETL de Amazon S3, CloudWatch Logs y recursos de Amazon EC2. De forma predeterminada y para mayor simplicidad, AWS Glue escribe algunos objetos de Amazon S3 en buckets de su cuenta con el prefijo `aws-glue-*`.

1. Inicie sesión en Consola de administración de AWS y abra la consola IAM en https://console.aws.amazon.com/iam/.
2. En el panel de navegación izquierdo, elija Políticas.
3. Elija Crear política.
4. En la pantalla Create Policy (Crear política) vaya a una pestaña para editar JSON. Cree un documento de política con las instrucciones JSON siguientes y, a continuación, elija Review policy (Revisar política).

   > **Note**
   >
   > Agregue todos los permisos necesarios para los recursos de Amazon S3. Es posible que le interese que la sección de recursos de su política de acceso abarque solo los recursos necesarios.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:*",
        "s3:GetBucketLocation",
        "s3:ListBucket",
        "s3:ListAllMyBuckets",
        "s3:GetBucketAcl",
        "ec2:DescribeVpcEndpoints",
        "ec2:DescribeRouteTables",
        "ec2:CreateNetworkInterface",
        "ec2:DeleteNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DescribeSecurityGroups",
        "ec2:DescribeSubnets",
        "ec2:DescribeVpcAttribute",
        "iam:ListRolePolicies",
        "iam:GetRole",
        "iam:GetRolePolicy",
        "cloudwatch:PutMetricData"
      ],
      "Resource": [
        "*"
      ]
    },
    {
      "Effect": "Allow",
      "Action": [
        "s3:CreateBucket",
        "s3:PutBucketPublicAccessBlock"
      ],
      "Resource": [
        "arn:aws:s3:::aws-glue-*"
      ]
    },
    {
```

```
      "Effect": "Allow",
      "Action": [
        "s3:GetObject",
        "s3:PutObject",
        "s3:DeleteObject"
      ],
      "Resource": [
        "arn:aws:s3:::aws-glue-*/*",
        "arn:aws:s3:::*/*aws-glue-*/*"
      ]
    },
    {
      "Effect": "Allow",
      "Action": [
        "s3:GetObject"
      ],
      "Resource": [
        "arn:aws:s3:::crawler-public*",
        "arn:aws:s3:::aws-glue-*"
      ]
    },
    {
      "Effect": "Allow",
      "Action": [
        "logs:CreateLogGroup",
        "logs:CreateLogStream",
        "logs:PutLogEvents",
        "logs:AssociateKmsKey"
      ],
      "Resource": [
        "arn:aws:logs:*:*:log-group:/aws-glue/*"
      ]
    },
    {
      "Effect": "Allow",
      "Action": [
        "ec2:CreateTags",
        "ec2:DeleteTags"
      ],
      "Condition": {
        "ForAllValues:StringEquals": {
          "aws:TagKeys": [
            "aws-glue-service-resource"
          ]
```

```
        }
      },
      "Resource": [
        "arn:aws:ec2:*:*:network-interface/*",
        "arn:aws:ec2:*:*:security-group/*",
        "arn:aws:ec2:*:*:instance/*"
      ]
    }
  ]
}
```

En la siguiente tabla se describen los permisos que esta política concede.

Acción	Recurso	Descripción
`"glue:*"`	`"*"`	Concede permiso para ejecutar todas las operaciones de la API de AWS Glue.
`"s3:GetBucketLocation", "s3:ListBucket", "s3:ListAllMyBuckets", "s3:GetBucketAcl",`	`"*"`	Permite crear listados de buckets de Amazon S3 a partir de rastreadores, trabajos, puntos de enlace de desarrollo y servidores de blocs de notas.

Acción	Recurso	Descripción
`"ec2:DescribeVpcEndpoints", "ec2:DescribeRouteTables", "ec2:CreateNetworkInterface", "ec2:DeleteNetworkInterface", "ec2:DescribeNetworkInterfaces", "ec2:DescribeSecurityGroups", "ec2:DescribeSubnets", "ec2:DescribeVpcAttribute",`	`"*"`	Permite configurar elementos de red de Amazon EC2, como nubes privadas virtuales (VPC), cuando se ejecutan trabajos, rastreadores y puntos de enlace de desarrollo.
`"iam:ListRolePolicies", "iam:GetRole", "iam:GetRolePolicy"`	`"*"`	Permite crear listados de roles de IAM a partir de rastreadores, trabajos, puntos de enlace de desarrollo y servidores de blocs de notas.
`"cloudwatch:PutMetricData"`	`"*"`	Permite escribir métricas de CloudWatch para trabajos.

Acción	Recurso	Descripción
`"s3:CreateBucket", "s3:PutBucketPublicAccessBlock"`	`"arn:aws:s3:::aws-glue-*"`	Permite la creación de buckets de Amazon S3 en su cuenta a partir de trabajos y servidores de blocs de notas. Convención de denominación: utiliza carpetas de Amazon S3 denominadas aws-glue-. Habilita AWS Glue para crear buckets que bloqueen el acceso público.
`"s3:GetObject", "s3:PutObject", "s3:DeleteObject"`	`"arn:aws:s3:::aws-glue-*/*", "arn:aws:s3:::*/*aws-glue-*/*"`	Permite obtener, colocar y eliminar objetos de Amazon S3 en su cuenta al almacenar objetos como scripts de ETL y ubicaciones de servidores de blocs de notas. Convención de denominación: concede permiso a buckets o carpetas de Amazon S3 cuyos nombres tienen el prefijo aws-glue-.

Acción	Recurso	Descripción
`"s3:GetObject"`	`"arn:aws:s3:::crawler-public*", "arn:aws:s3:::aws-glue-*"`	Permite conseguir objetos de Amazon S3 que utilizan los ejemplos y tutoriales de los rastreadores y los trabajos. Convención de denominación: los nombres de bucket de Amazon S3 comienzan con crawler-public y aws-glue-.
`"logs:CreateLogGroup", "logs:CreateLogStream", "logs:PutLogEvents"`	`"arn:aws:logs:*:*:log-group:/aws-glue/*"`	Permite escribir registros en CloudWatch Logs. Convención de denominación: AWS Glue escribe registros en grupos de registros cuyos nombres comienzan por aws-glue.
`"ec2:CreateTags", "ec2:DeleteTags"`	`"arn:aws:ec2:*:*:network-interface/*", "arn:aws:ec2:*:*:security-group/*", "arn:aws:ec2:*:*:instance/*"`	Permite el etiquetado de recursos de Amazon EC2; creados para puntos de enlace de desarrollo. Convención de denominación: AWS Glue etiqueta interfaces de red de Amazon EC2, grupos de seguridad e instancias con aws-glue-service-resource.

5. En la pantalla Review Policy (Revisar política), escriba su Policy Name (Nombre de política); por ejemplo, GlueServiceRolePolicy. Escriba una descripción opcional y, cuando quede satisfecho con la política, elija Create Policy (Crear política).

Paso 2: creación de un rol de IAM para AWS Glue

Tiene que conceder sus permisos de rol de IAM que AWS Glue pueda asumir cuando llame a otros servicios en su nombre. Esto incluye el acceso a Amazon S3 para todos los orígenes, los destinos, los scripts y los directorios temporales que utilice con AWS Glue. Los rastreadores, los trabajos y los puntos de enlace de desarrollo necesitan permiso.

Estos permisos los concede utilizando AWS Identity and Access Management (IAM). Agregue una política al rol de IAM que transfiera a AWS Glue.

Para crear un rol de IAM para AWS Glue

1. Inicie sesión en Consola de administración de AWS y abra la consola IAM en https://console.aws.amazon.com/iam/.
2. En el panel de navegación izquierdo, elija Roles.
3. Elija Crear rol.
4. Elija Servicio de AWS como tipo de entidad de confianza. Luego, para el servicio o caso de uso, busque y elija AWS Glue. Elija Siguiente.
5. En la página Agregar permisos, elija las políticas que contienen los permisos necesarios; por ejemplo, la política administrada por AWS, `AWSGlueServiceRole`, para permisos de AWS Glue generales y la política administrada de AWS, AmazonS3FullAccess, para obtener acceso a los recursos de Amazon S3. A continuación, elija Siguiente.

   > **Note**
   >
   > Asegúrese de que una de las políticas de este rol conceda permisos a sus orígenes y destinos de Amazon S3. Es posible que le interese proporcionar su propia política para obtener acceso a determinados recursos de Amazon S3. Los orígenes de datos requieren permisos `s3:ListBucket` y `s3:GetObject`. Los destinos de datos requieren permisos `s3:ListBucket`, `s3:PutObject` y `s3:DeleteObject`. Para obtener más información acerca de la creación de una política de Amazon S3 para sus recursos, consulte Especificación de recursos en una política. Para ver un ejemplo de política de Amazon S3, consulte Cómo escribir políticas de IAM: cómo conceder acceso a un bucket de Amazon S3.
   >
   > Si tiene previsto obtener acceso a orígenes y destinos de Amazon S3 cifrados con SSE-KMS, asocie una política que permita a los rastreadores, trabajos y puntos de enlace de desarrollo de AWS Glue descifrar los datos. Para obtener más información, consulte

Proteger los datos utilizando cifrado del lado del servidor con claves administradas por AWS KMS (SSE-KMS).
A continuación se muestra un ejemplo.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "kms:Decrypt"
      ],
      "Resource": [
        "arn:aws:kms:*:111122223333:key/key-id"
      ]
    }
  ]
}
```

6. Asigne un nombre a su función y añada una descripción (opcional) y, a continuación, revise la política de confianza y los permisos. En Role Name (Nombre del rol), escriba un nombre para el rol, por ejemplo, `AWSGlueServiceRoleDefault`. Cree el rol con el nombre prefijado con la cadena `AWSGlueServiceRole` para permitir que se transfiera el rol desde usuarios de la consola al servicio. Las políticas proporcionadas por AWS Glue esperan que los roles de servicio de IAM comiencen con `AWSGlueServiceRole`. De lo contrario, deberá agregar una política para permitir a sus usuarios que el permiso `iam:PassRole` para roles de IAM coincida con la convención de denominación. Seleccione Crear rol.

> **Note**
>
> Cuando se crea un cuaderno con un rol, ese rol se pasa a las sesiones interactivas para que se pueda utilizar el mismo rol en ambos lugares. Como tal, el permiso `iam:PassRole` debe formar parte de la política del rol.
> Cree una nueva política para el rol mediante el siguiente ejemplo. Reemplace el número de cuenta por el suyo y por el nombre del rol.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": "iam:PassRole",
      "Resource": "arn:aws:iam::090000000210:role/<role_name>"
    }
  ]
}
```

7. Añada etiquetas a su rol (opcional). Las etiquetas son pares clave-valor que puede añadir a los recursos AWS para ayudar a identificar, organizar o buscar recursos. A continuación, elija Create role (Crear rol).

Paso 3: Adjuntar una política a los usuarios o los grupos que accedan a AWS Glue

El administrador debe asignar permisos a cualquier usuario, grupo o rol mediante la consola de AWS Glue o la AWS Command Line Interface (AWS CLI). Estos permisos los concede con AWS Identity and Access Management (IAM), mediante políticas. En este paso, se describe la asignación de permisos a usuarios o grupos.

Cuando termine este paso, el usuario o el grupo tendrán las siguientes políticas adjuntas:

- Política administrada de AWS, `AWSGlueConsoleFullAccess`, o política personalizada GlueConsoleAccessPolicy
- **`AWSGlueConsoleSageMakerNotebookFullAccess`**
- **`CloudWatchLogsReadOnlyAccess`**
- **`AWSCloudFormationReadOnlyAccess`**
- **`AmazonAthenaFullAccess`**

Para adjuntar una política insertada e integrarla a un usuario o un grupo

Puede adjuntar una política administrada de AWS o una política insertada a un usuario o un grupo para obtener acceso a la consola de AWS Glue. Algunos de los recursos especificados en esta política hacen referencia a nombres predeterminados que AWS Glue utiliza para buckets de Amazon S3, scripts de ETL de Amazon S3, CloudWatch Logs, CloudFormation y recursos de Amazon EC2. De forma predeterminada y para mayor simplicidad, AWS Glue escribe algunos objetos de Amazon S3 en buckets de su cuenta con el prefijo `aws-glue-*`.

> **Note**
>
> Puede omitir este paso si utiliza la política administrada de AWS **`AWSGlueConsoleFullAccess`**.

> **Important**
>
> AWS Glue necesita permiso para asumir un rol que se utiliza para realizar flujo de trabajo en su nombre. Para ello, debe agregar los permisos **`iam:PassRole`** a los usuarios o los grupos de AWS Glue. Esta política concede permiso a roles que comienzan por `AWSGlueServiceRole` para roles de servicio de AWS Glue y `AWSGlueServiceNotebookRole` para roles que son necesarios cuando crea un servidor de blocs de notas. También puede crear su propia política para permisos `iam:PassRole` que sigue su convención de denominación.
>
> Según las mejores prácticas de seguridad, se recomienda restringir el acceso mediante políticas más estrictas para limitar aún más el acceso al bucket de Amazon S3 y grupos de registros de Amazon CloudWatch. Para ver un ejemplo de política de Amazon S3, consulte Cómo escribir políticas de IAM: cómo conceder acceso a un bucket de Amazon S3.

En este paso, crea una política que es similar a `AWSGlueConsoleFullAccess`. Puede encontrar la versión más actualizada de `AWSGlueConsoleFullAccess` en la consola de IAM.

1. Inicie sesión en Consola de administración de AWS y abra la consola IAM en https://console.aws.amazon.com/iam/.
2. En el panel de navegación, elija Usuarios o Grupos de usuarios.
3. En la lista, seleccione el nombre del usuario o del grupo en el que integrará una política.

4. Elija la pestaña Permissions (Permisos) y, si es necesario, expanda la sección Permissions Policies (Políticas de permisos).
5. Elija el enlace Add Inline policy (Añadir política en línea).
6. En la pantalla Create Policy (Crear política) vaya a una pestaña para editar JSON. Cree un documento de política con las instrucciones JSON siguientes y, a continuación, elija Review policy (Revisar política).

   JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:*",
        "redshift:DescribeClusters",
        "redshift:DescribeClusterSubnetGroups",
        "iam:ListRoles",
        "iam:ListUsers",
        "iam:ListGroups",
        "iam:ListRolePolicies",
        "iam:GetRole",
        "iam:GetRolePolicy",
        "iam:ListAttachedRolePolicies",
        "ec2:DescribeSecurityGroups",
        "ec2:DescribeSubnets",
        "ec2:DescribeVpcs",
        "ec2:DescribeVpcEndpoints",
        "ec2:DescribeRouteTables",
        "ec2:DescribeVpcAttribute",
        "ec2:DescribeKeyPairs",
        "ec2:DescribeInstances",
        "rds:DescribeDBInstances",
        "rds:DescribeDBClusters",
        "rds:DescribeDBSubnetGroups",
        "s3:ListAllMyBuckets",
        "s3:ListBucket",
        "s3:GetBucketAcl",
        "s3:GetBucketLocation",
        "cloudformation:DescribeStacks",
```

```
        "cloudformation:GetTemplateSummary",
        "dynamodb:ListTables",
        "kms:ListAliases",
        "kms:DescribeKey",
        "cloudwatch:GetMetricData",
        "cloudwatch:ListDashboards"
      ],
      "Resource": [
        "*"
      ]
    },
    {
      "Effect": "Allow",
      "Action": [
        "s3:GetObject",
        "s3:PutObject"
      ],
      "Resource": [
        "arn:aws:s3:::*/*aws-glue-*/*",
        "arn:aws:s3:::aws-glue-*"
      ]
    },
    {
      "Effect": "Allow",
      "Action": [
        "tag:GetResources"
      ],
      "Resource": [
        "*"
      ]
    },
    {
      "Effect": "Allow",
      "Action": [
        "s3:CreateBucket",
        "s3:PutBucketPublicAccessBlock"
      ],
      "Resource": [
        "arn:aws:s3:::aws-glue-*"
      ]
    },
    {
      "Effect": "Allow",
      "Action": [
```

```
        "logs:GetLogEvents"
      ],
      "Resource": [
        "arn:aws:logs:*:*:/aws-glue/*"
      ]
    },
    {
      "Effect": "Allow",
      "Action": [
        "cloudformation:CreateStack",
        "cloudformation:DeleteStack"
      ],
      "Resource": "arn:aws:cloudformation:*:*:stack/aws-glue*/*"
    },
    {
      "Effect": "Allow",
      "Action": [
        "ec2:RunInstances"
      ],
      "Resource": [
        "arn:aws:ec2:*:*:instance/*",
        "arn:aws:ec2:*:*:key-pair/*",
        "arn:aws:ec2:*:*:image/*",
        "arn:aws:ec2:*:*:security-group/*",
        "arn:aws:ec2:*:*:network-interface/*",
        "arn:aws:ec2:*:*:subnet/*",
        "arn:aws:ec2:*:*:volume/*"
      ]
    },
    {
      "Action": [
        "iam:PassRole"
      ],
      "Effect": "Allow",
      "Resource": "arn:aws:iam::*:role/AWSGlueServiceRole*",
      "Condition": {
        "StringLike": {
          "iam:PassedToService": [
            "glue.amazonaws.com"
          ]
        }
      }
    },
    {
```

```
      "Action": [
        "iam:PassRole"
      ],
      "Effect": "Allow",
      "Resource": "arn:aws:iam::*:role/AWSGlueServiceNotebookRole*",
      "Condition": {
        "StringLike": {
          "iam:PassedToService": [
            "ec2.amazonaws.com"
          ]
        }
      }
    },
    {
      "Action": [
        "iam:PassRole"
      ],
      "Effect": "Allow",
      "Resource": [
        "arn:aws:iam::*:role/service-role/AWSGlueServiceRole*"
      ],
      "Condition": {
        "StringLike": {
          "iam:PassedToService": [
            "glue.amazonaws.com"
          ]
        }
      }
    }
  ]
}
```

En la siguiente tabla se describen los permisos que esta política concede.

Acción	Recurso	Descripción
`"glue:*"`	`"*"`	Concede permiso para ejecutar todas las operaciones de la API de AWS Glue. Si ya había creado la política sin la acción `"glue:*"`, debe añadir el siguiente permiso individual a la política: • "glue:ListCrawlers" • "glue:BatchGetCrawlers" • "glue:ListTriggers" • "glue:BatchGetTriggers" • "glue:ListDevEndpoints" • "glue:BatchGetDevEndpoints" • "glue:ListJobs" • "glue:BatchGetJobs"
`"redshift:DescribeClusters", "redshift:DescribeClusterSubnetGroups"`	`"*"`	Permite la creación de conexiones con Amazon Redshift.

Acción	Recurso	Descripción
`"iam:ListRoles", "iam:ListRolePolicies", "iam:GetRole", "iam:GetRolePolicy", "iam:ListAttachedRolePolicies"`	`"*"`	Permite crear listados de roles de IAM cuando se trabaja con rastreadores, trabajos, puntos de enlace de desarrollo y servidores de blocs de notas.
`"ec2:DescribeSecurityGroups", "ec2:DescribeSubnets", "ec2:DescribeVpcs", "ec2:DescribeVpcEndpoints", "ec2:DescribeRouteTables", "ec2:DescribeVpcAttribute", "ec2:DescribeKeyPairs", "ec2:DescribeInstances"`	`"*"`	Permite configurar elementos de red de Amazon EC2, como VPC, al ejecutar trabajos, rastreadores y puntos de enlace de desarrollo.
`"rds:DescribeDBInstances"`	`"*"`	Permite la creación de conexiones con Amazon RDS.
`"s3:ListAllMyBuckets", "s3:ListBucket", "s3:GetBucketAcl", "s3:GetBucketLocation"`	`"*"`	Permite crear listados de buckets de Amazon S3 cuando se trabaja con rastreadores, trabajos, puntos de enlace de desarrollo y servidores de blocs de notas.
`"dynamodb:ListTables"`	`"*"`	Permite crear listados de tablas de DynamoDB.

Acción	Recurso	Descripción
`"kms:ListAliases", "kms:DescribeKey"`	`"*"`	Permite trabajar con claves de KMS.
`"cloudwatch:GetMetricData", "cloudwatch:ListDashboards"`	`"*"`	Permite trabajar con métricas de CloudWatch.
`"s3:GetObject", "s3:PutObject"`	`"arn:aws:s3::: aws-glue-*/*", "arn:aws:s3::: */*aws-glue-*/*", "arn:aws:s3::: aws-glue-*"`	Permite obtener y colocar objetos de Amazon S3 en su cuenta al almacenar objetos como scripts de ETL y ubicaciones de servidores de blocs de notas. Convención de denominación: concede permiso a buckets o carpetas de Amazon S3 cuyos nombres tienen el prefijo aws-glue-.
`"tag:GetResources"`	`"*"`	Permite recuperar etiquetas de AWS.

Acción	Recurso	Descripción
`"s3:CreateBucket", "s3:PutBucketPublicAccessBlock"`	`"arn:aws:s3::: aws-glue-*"`	Permite crear un bucket de Amazon S3 en la cuenta para almacenar objetos, como scripts de ETL y ubicaciones de servidores de blocs de notas. Convención de denominación: concede permiso a buckets de Amazon S3 cuyos nombres tienen el prefijo aws-glue-. Habilita AWS Glue para crear buckets que bloqueen el acceso público.
`"logs:GetLogEvents"`	`"arn:aws:logs:*:*: / aws-glue/*"`	Permite la recuperación de CloudWatch Logs. Convención de denominación: AWS Glue escribe registros en grupos de registros cuyos nombres comienzan por aws-glue-.

Acción	Recurso	Descripción
`"cloudformation:CreateStack", "cloudformation:DeleteStack"`	`"arn:aws:cloudformation:*:*:stack/aws-glue*/*"`	Permite administrar pilas de CloudFormation cuando trabaja con servidores de blocs de notas. Convención de denominación: AWS Glue crea pilas cuyos nombres comienzan por aws-glue.
`"ec2:RunInstances"`	`"arn:aws:ec2:*:*:instance/*", "arn:aws:ec2:*:*:key-pair/*", "arn:aws:ec2:*:*:image/*", "arn:aws:ec2:*:*:security-group/*", "arn:aws:ec2:*:*:network-interface/*", "arn:aws:ec2:*:*:subnet/*", "arn:aws:ec2:*:*:volume/*"`	Permite la ejecución de puntos de enlace de desarrollo y servidores de blocs de notas.
`"iam:PassRole"`	`"arn:aws:iam::*:role/ AWSGlueServiceRole*"`	Permite que AWS Glue asuma el permiso `PassRole` para roles que comienzan con `AWSGlueServiceRole` .

Acción	Recurso	Descripción
`"iam:PassRole"`	`"arn:aws:iam::*:role/ AWSGlueServiceNotebookRole*"`	Permite que Amazon EC2 asuma el permiso `PassRole` para roles que comienzan con `AWSGlueServiceNotebookRole` .
`"iam:PassRole"`	`"arn:aws:iam::*:role/service-role/AWSGlueServiceRole*"`	Permite que AWS Glue asuma el permiso `PassRole` para roles que comienzan con `service-role/AWSGlueServiceRole` .

7. En la pantalla Review Policy (Revisar política), escriba un nombre para la política; por ejemplo, GlueConsoleAccessPolicy. Cuando esté satisfecho con la política, elija Crear política. Asegúrese de que no aparece ningún error en un cuadro rojo en la parte superior de la pantalla. Corrija todos los errores notificados.

> **Note**
>
> Si la opción Use autoformatting está seleccionada, la política se vuelve a formatear cada vez que abra una política o elija la opción Validate Policy.

Para asociar la política administrada AWSGlueConsoleFullAccess

Puede asociar la política `AWSGlueConsoleFullAccess` para proporcionar permisos que el usuario de la consola de AWS Glue necesita.

> **Note**
>
> Puede omitir este paso si ha creado su propia política para el acceso a la consola de AWS Glue.

1. Inicie sesión en la Consola de administración de AWS y abra la consola de IAM en https://console.aws.amazon.com/iam/.
2. En el panel de navegación, seleccione Políticas.
3. En la lista de políticas, seleccione la casilla de verificación situada junto a AWSGlueConsoleFullAccess. Puede utilizar el menú Filtro y el cuadro de búsqueda para filtrar la lista de políticas.
4. Seleccione Policy actions (Acciones de la política) y, a continuación, Attach (Adjuntar).
5. Seleccione el usuario al que asociará la política. Puede utilizar el menú Filtro y el cuadro de búsqueda para filtrar la lista entidades principales. Después de seleccionar el usuario al que asociará la política, seleccione Attach policy (Asociar política).

Asocie la política administrada, **`AWSGlueConsoleSageMakerNotebookFullAccess`**

Puede asociar la política `AWSGlueConsoleSageMakerNotebookFullAccess` a un usuario para administrar blocs de notas de IA de SageMaker creados en la consola de AWS Glue. Además de otros permisos de la consola de AWS Glue necesarios, esta política concede acceso a los recursos que se necesitan para administrar blocs de notas de IA de SageMaker.

1. Inicie sesión en la Consola de administración de AWS y abra la consola de IAM en https://console.aws.amazon.com/iam/.
2. En el panel de navegación, seleccione Políticas.
3. En la lista de políticas, seleccione la casilla de verificación situada junto a AWSGlueConsoleSageMakerNotebookFullAccess. Puede utilizar el menú Filtro y el cuadro de búsqueda para filtrar la lista de políticas.
4. Seleccione Policy actions (Acciones de la política) y, a continuación, Attach (Adjuntar).
5. Seleccione el usuario al que asociará la política. Puede utilizar el menú Filtro y el cuadro de búsqueda para filtrar la lista entidades principales. Después de seleccionar el usuario al que asociará la política, seleccione Attach policy (Asociar política).

Para asociar la política administrada CloudWatchLogsReadOnlyAccess

Puede asociar la política CloudWatchLogsReadOnlyAccess a un usuario para ver los registros que AWS Glue crea en la consola de CloudWatch Logs.

1. Inicie sesión en la Consola de administración de AWS y abra la consola de IAM en https://console.aws.amazon.com/iam/.

2. En el panel de navegación, seleccione Políticas.
3. En la lista de políticas, seleccione la casilla de verificación situada junto a la política CloudWatchLogsReadOnlyAccess. Puede utilizar el menú Filtro y el cuadro de búsqueda para filtrar la lista de políticas.
4. Seleccione Policy actions (Acciones de la política) y, a continuación, Attach (Adjuntar).
5. Seleccione el usuario al que asociará la política. Puede utilizar el menú Filtro y el cuadro de búsqueda para filtrar la lista entidades principales. Después de seleccionar el usuario al que asociará la política, seleccione Attach policy (Asociar política).

Para asociar la política administrada AWSCloudFormationReadOnlyAccess

Puede asociar la política AWSCloudFormationReadOnlyAccess a un usuario para ver las pilas de CloudFormation que AWS Glue utiliza en la consola de CloudFormation.

1. Inicie sesión en la Consola de administración de AWS y abra la consola de IAM en https://console.aws.amazon.com/iam/.
2. En el panel de navegación, seleccione Políticas.
3. En la lista de políticas, seleccione la casilla de verificación situada junto a AWSCloudFormationReadOnlyAccess. Puede utilizar el menú Filtro y el cuadro de búsqueda para filtrar la lista de políticas.
4. Seleccione Policy actions (Acciones de la política) y, a continuación, Attach (Adjuntar).
5. Seleccione el usuario al que asociará la política. Puede utilizar el menú Filtro y el cuadro de búsqueda para filtrar la lista entidades principales. Después de seleccionar el usuario al que asociará la política, seleccione Attach policy (Asociar política).

Para asociar la política administrada AmazonAthenaFullAccess

Puede asociar la política AmazonAthenaFullAccess a un usuario para ver datos de Amazon S3 en la consola de Athena.

1. Inicie sesión en la Consola de administración de AWS y abra la consola de IAM en https://console.aws.amazon.com/iam/.
2. En el panel de navegación, seleccione Políticas.
3. En la lista de políticas, seleccione la casilla de verificación situada junto a AmazonAthenaFullAccess. Puede utilizar el menú Filtro y el cuadro de búsqueda para filtrar la lista de políticas.

4. Seleccione Policy actions (Acciones de la política) y, a continuación, Attach (Adjuntar).
5. Seleccione el usuario al que asociará la política. Puede utilizar el menú Filtro y el cuadro de búsqueda para filtrar la lista entidades principales. Después de seleccionar el usuario al que asociará la política, seleccione Attach policy (Asociar política).

Paso 4: Crear una política de IAM para servidores de blocs de notas

Si pretende utilizar blocs de notas con puntos de enlace de desarrollo, debe especificar permisos al crear el servidor de bloc de notas. Estos permisos los concede utilizando AWS Identity and Access Management (IAM).

Esta política concede permiso para que algunas acciones de Amazon S3 administren recursos de su cuenta que AWS Glue necesita cuando asume el rol con esta política. Algunos de los recursos que se especifican en esta política hacen referencia a nombres predeterminados que AWS Glue utiliza para buckets de Amazon S3, scripts de ETL de Amazon S3 y recursos de Amazon EC2. De forma predeterminada y para mayor simplicidad, AWS Glue escribe algunos objetos de Amazon S3 en buckets de su cuenta con el prefijo `aws-glue-*`.

> **Note**
>
> Puede omitir este paso si utiliza la política administrada de AWS, **`AWSGlueServiceNotebookRole`**.

En este paso, crea una política que es similar a `AWSGlueServiceNotebookRole`. Puede encontrar la versión más actualizada de `AWSGlueServiceNotebookRole` en la consola de IAM.

Para crear una política de IAM para blocs de notas

1. Inicie sesión en la Consola de administración de AWS y abra la consola de IAM en https://console.aws.amazon.com/iam/.
2. En el panel de navegación izquierdo, elija Políticas.
3. Elija Crear política.
4. En la pantalla Create Policy (Crear política) vaya a una pestaña para editar JSON. Cree un documento de política con las instrucciones JSON siguientes y, a continuación, elija Review policy (Revisar política).

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:CreateDatabase",
        "glue:CreatePartition",
        "glue:CreateTable",
        "glue:DeleteDatabase",
        "glue:DeletePartition",
        "glue:DeleteTable",
        "glue:GetDatabase",
        "glue:GetDatabases",
        "glue:GetPartition",
        "glue:GetPartitions",
        "glue:GetTable",
        "glue:GetTableVersions",
        "glue:GetTables",
        "glue:UpdateDatabase",
        "glue:UpdatePartition",
        "glue:UpdateTable",
        "glue:GetJobBookmark",
        "glue:ResetJobBookmark",
        "glue:CreateConnection",
        "glue:CreateJob",
        "glue:DeleteConnection",
        "glue:DeleteJob",
        "glue:GetConnection",
        "glue:GetConnections",
        "glue:GetDevEndpoint",
        "glue:GetDevEndpoints",
        "glue:GetJob",
        "glue:GetJobs",
        "glue:UpdateJob",
        "glue:BatchDeleteConnection",
        "glue:UpdateConnection",
        "glue:GetUserDefinedFunction",
        "glue:UpdateUserDefinedFunction",
        "glue:GetUserDefinedFunctions",
```

```
        "glue:DeleteUserDefinedFunction",
        "glue:CreateUserDefinedFunction",
        "glue:BatchGetPartition",
        "glue:BatchDeletePartition",
        "glue:BatchCreatePartition",
        "glue:BatchDeleteTable",
        "glue:UpdateDevEndpoint",
        "s3:GetBucketLocation",
        "s3:ListBucket",
        "s3:ListAllMyBuckets",
        "s3:GetBucketAcl"
      ],
      "Resource": [
        "*"
      ]
    },
    {
      "Effect": "Allow",
      "Action": [
        "s3:GetObject"
      ],
      "Resource": [
        "arn:aws:s3:::crawler-public*",
        "arn:aws:s3:::aws-glue*"
      ]
    },
    {
      "Effect": "Allow",
      "Action": [
        "s3:PutObject",
        "s3:DeleteObject"
      ],
      "Resource": [
        "arn:aws:s3:::aws-glue*"
      ]
    },
    {
      "Effect": "Allow",
      "Action": [
        "ec2:CreateTags",
        "ec2:DeleteTags"
      ],
      "Condition": {
        "ForAllValues:StringEquals": {
```

```
          "aws:TagKeys": [
            "aws-glue-service-resource"
          ]
        }
      },
      "Resource": [
        "arn:aws:ec2:*:*:network-interface/*",
        "arn:aws:ec2:*:*:security-group/*",
        "arn:aws:ec2:*:*:instance/*"
      ]
    }
  ]
}
```

En la siguiente tabla se describen los permisos que esta política concede.

Acción	Recurso	Descripción
`"glue:*"`	`"*"`	Concede permiso para ejecutar todas las operaciones de la API de AWS Glue.
`"s3:GetBucketLocation", "s3:ListBucket", "s3:ListAllMyBuckets", "s3:GetBucketAcl"`	`"*"`	Permite crear listados de los buckets de Amazon S3 a partir de servidores de blocs de notas.

Acción	Recurso	Descripción
`"s3:GetObject"`	`"arn:aws:s3:::crawler-public*", "arn:aws:s3:::aws-glue-*"`	Permite obtener objetos de Amazon S3 que utilizan los ejemplos y tutoriales de los blocs de notas. Convención de denominación: los nombres de bucket de Amazon S3 comienzan con crawler-public y aws-glue-.
`"s3:PutObject", "s3:DeleteObject"`	`"arn:aws:s3:::aws-glue*"`	Permite colocar y eliminar objetos de Amazon S3 en su cuenta desde blocs de notas. Convención de denominación: utiliza carpetas de Amazon S3 denominadas aws-glue.
`"ec2:CreateTags", "ec2:DeleteTags"`	`"arn:aws:ec2:*:*:network-interface/*", "arn:aws:ec2:*:*:security-group/*", "arn:aws:ec2:*:*:instance/*"`	Permite el etiquetado de recursos de Amazon EC2 creados para servidores de blocs de notas. Convención de denominación: AWS Glue etiqueta instancias Amazon EC2 con aws-glue-service-resource.

5. En la pantalla Review Policy (Revisar política), escriba su Policy Name (Nombre de política); por ejemplo, GlueServiceNotebookPolicyDefault. Escriba una descripción opcional y, cuando quede satisfecho con la política, elija Create Policy (Crear política).

Paso 5: Crear un rol de IAM para servidores de blocs de notas

Si pretende utilizar blocs de notas con puntos de enlace de desarrollo, debe conceder los permisos de rol de IAM. Estos permisos los concede al utilizar IAM de AWS Identity and Access Management, mediante un rol de IAM.

> **Note**
>
> Cuando se crea un rol de IAM utilizando la consola de IAM, esta crea automáticamente un perfil de instancia y le da el mismo nombre que el rol al que corresponde.

Para crear un rol de IAM para blocs de notas

1. Inicie sesión en Consola de administración de AWS y abra la consola IAM en https://console.aws.amazon.com/iam/.
2. En el panel de navegación izquierdo, elija Roles.
3. Seleccione Crear rol.
4. Para el tipo de rol, elija Servicio de AWS, encuentre y elija EC2 y seleccione el caso de uso de EC2; por último, elija Siguiente: Permisos.
5. En la página Adjuntar política de permisos, elija las políticas que contienen los permisos necesarios; por ejemplo, AWSGlueServiceNotebookRole, para permisos de AWS Glue generales, y la política administrada por AWS, AmazonS3FullAccess, para obtener acceso a recursos de Amazon S3. A continuación, seleccione Next: Review.

   > **Note**
   >
   > Asegúrese de que una de las políticas de este rol conceda permisos a sus orígenes y destinos de Amazon S3. También confirme que su política le permite obtener acceso completo a la ubicación en la que almacena su bloc de notas cuando crea un servidor de blocs de notas. Es posible que le interese proporcionar su propia política para obtener acceso a determinados recursos de Amazon S3. Para obtener más información acerca de la creación de una política de Amazon S3 para sus recursos, consulte Especificación de recursos en una política.
   > Si tiene previsto obtener acceso a orígenes y destinos de Amazon S3 cifrados con SSE-KMS, asocie una política que permita a los blocs de notas descifrar los datos. Para

obtener más información, consulte Proteger los datos utilizando cifrado del lado del servidor con claves administradas por AWS KMS (SSE-KMS).
A continuación se muestra un ejemplo.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "kms:Decrypt"
      ],
      "Resource": [
        "arn:aws:kms:*:111122223333:key/key-id"
      ]
    }
  ]
}
```

6. Escriba un nombre para el rol en Nombre de rol. Cree el rol con el nombre prefijado con la cadena `AWSGlueServiceNotebookRole` para permitir que se transfiera el rol desde usuarios de la consola al servidor de blocs de notas. Las políticas proporcionadas por AWS Glue esperan que los roles de servicio de IAM comiencen con `AWSGlueServiceNotebookRole`. De lo contrario, deberá agregar una política a sus usuarios para permitir que el permiso `iam:PassRole` para roles de IAM coincida con su convención de denominación. Por ejemplo, escriba . `AWSGlueServiceNotebookRoleDefault`. A continuación, elija Crear rol.

Paso 6: Crear una política de IAM para cuadernos de IA de SageMaker

Si pretende utilizar cuadernos de IA de SageMaker con puntos de conexión de desarrollo, debe especificar los permisos al crear el cuaderno. Estos permisos los concede utilizando AWS Identity and Access Management (IAM).

Creación de una política de IAM para cuadernos de IA de SageMaker

1. Inicie sesión en Consola de administración de AWS y abra la consola IAM en https://console.aws.amazon.com/iam/.

2. En el panel de navegación izquierdo, elija Políticas.
3. Elija Crear política.
4. En la página Create Policy (Crear política) vaya a una pestaña para editar JSON. Cree un documento de política con las siguientes instrucciones JSON. Modifique el *nombre-del-bucket*, el *código-de-región* y el *identificador-de-cuenta* del entorno.

   JSON

```
{
    "Version":"2012-10-17",
    "Statement": [
        {
            "Action": [
                "s3:ListBucket"
            ],
            "Effect": "Allow",
            "Resource": [
                "arn:aws:s3:::amzn-s3-demo-bucket"
            ]
        },
        {
            "Action": [
                "s3:GetObject"
            ],
            "Effect": "Allow",
            "Resource": [
                "arn:aws:s3:::amzn-s3-demo-bucket*"
            ]
        },
        {
            "Action": [
                "logs:CreateLogStream",
                "logs:DescribeLogStreams",
                "logs:PutLogEvents",
                "logs:CreateLogGroup"
            ],
            "Effect": "Allow",
            "Resource": [
                "arn:aws:logs:us-east-1:111122223333:log-group:/aws/
sagemaker/*",
```

```
                "arn:aws:logs:us-east-1:111122223333:log-group:/aws/
sagemaker/*:log-stream:aws-glue-*"
            ]
        },
        {
            "Action": [
                "glue:UpdateDevEndpoint",
                "glue:GetDevEndpoint",
                "glue:GetDevEndpoints"
            ],
            "Effect": "Allow",
            "Resource": [
                "arn:aws:glue:us-east-1:111122223333:devEndpoint/*"
            ]
        },
        {
            "Action": [
                "sagemaker:ListTags"
            ],
            "Effect": "Allow",
            "Resource": [
                "arn:aws:sagemaker:us-east-1:111122223333:notebook-instance/
*"
            ]
        }
    ]
}
```

A continuación, elija Review policy (Revisar política).

En la siguiente tabla se describen los permisos que esta política concede.

Acción	Recurso	Descripción
`"s3:ListBucket*"`	`"arn:aws:s3::: bucket-name "`	Concede permisos para enumerar los buckets de Amazon S3.

Acción	Recurso	Descripción
`"s3:GetObject"`	`"arn:aws:s3::: bucket-name *"`	Concede permiso para obtener objetos de Amazon S3 que se utilizan en cuadernos de IA de SageMaker.
`"logs:CreateLogStream", "logs:DescribeLogStreams", "logs:PutLogEvents", "logs:CreateLogGroup"`	`"arn:aws:logs: region-code :account-id :log-group:/aws/sagemaker/*", "arn:aws:logs: region-code :account-id :log-group:/aws/sagemaker/*:log-stream:aws-glue-*"`	Concede permiso para escribir registros en Amazon CloudWatch Logs desde blocs de notas. Convención de denominación: escribe en grupos de registros cuyos nombres comienzan por aws-glue.
`"glue:UpdateDevEndpoint", "glue:GetDevEndpoint", "glue:GetDevEndpoints"`	`"arn:aws:glue: region-code :account-id :devEndpoint/*"`	Concede permiso para utilizar un punto de conexión de desarrollo desde cuadernos de IA de SageMaker.
`"sagemaker:ListTags"`	`"arn:aws:sagemaker : region-code :account-id :notebook-instance /*"`	Concede permiso para devolver etiquetas de un recurso de IA de SageMaker. La etiqueta `aws-glue-dev-endpoint` es necesaria en el cuaderno de IA de SageMaker para conectar este cuaderno a un punto de conexión de desarrollo.

5. En la pantalla Review Policy (Revisar política), escriba su Policy Name (Nombre de política); por ejemplo, `AWSGlueSageMakerNotebook`. Escriba una descripción opcional y, cuando quede satisfecho con la política, elija Create Policy (Crear política).

Paso 7: Crear un rol de IAM para cuadernos de IA de SageMaker

Si pretende utilizar cuadernos de IA de SageMaker con puntos de conexión de desarrollo, debe conceder los permisos del rol de IAM. Estos permisos los concede al utilizar AWS Identity and Access Management (IAM), mediante un rol de IAM.

Creación de un rol de IAM para cuadernos de IA de SageMaker

1. Inicie sesión en Consola de administración de AWS y abra la consola IAM en https://console.aws.amazon.com/iam/.
2. En el panel de navegación izquierdo, elija Roles.
3. Seleccione Crear rol.
4. Para el tipo de rol, elija Servicio de AWS, busque y elija SageMaker y seleccione el caso de uso SageMaker: ejecución. A continuación, elija Siguiente: Permisos).
5. En la página Attach permissions policy (Asociar la política de permisos), elija las políticas que contengan los permisos necesarios; por ejemplo, AmazonSageMakerFullAccess. Elija Siguiente: Revisar.

   Si tiene previsto obtener acceso a orígenes y destinos de Amazon S3 que se cifran con SSE-KMS, asocie una política que permita a los blocs de notas descifrar los datos, como se muestra en el siguiente ejemplo. Para obtener más información, consulte Proteger los datos utilizando cifrado del lado del servidor con claves administradas por AWS KMS (SSE-KMS).

   JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "kms:Decrypt"
      ],
      "Resource": [
        "arn:aws:kms:*:111122223333:key/key-id"
      ]
    }
  ]
```

```
}
```

6. Escriba un nombre para el rol en Nombre de rol. Para permitir que se transfiera el rol desde usuarios de la consola a la IA de SageMaker, use un nombre que tenga como prefijo la cadena `AWSGlueServiceSageMakerNotebookRole`. Las políticas proporcionadas por AWS Glue esperan que los roles de IAM comiencen con `AWSGlueServiceSageMakerNotebookRole`. De lo contrario, deberá agregar una política a sus usuarios para permitir que el permiso `iam:PassRole` para roles de IAM coincida con su convención de denominación.

   Por ejemplo, ingrese `AWSGlueServiceSageMakerNotebookRole-Default`, y luego elija Create role (Crear rol).

7. Después de crear el rol, asocie la política que permite los permisos adicionales necesarios para crear cuadernos de IA de SageMaker desde AWS Glue.

   Abra el rol que acaba de crear, `AWSGlueServiceSageMakerNotebookRole-Default`, y elija Attach policies (Asociar políticas). Asocie la política que creó, denominada `AWSGlueSageMakerNotebook`, al rol.

Ejemplos de políticas de control de acceso de AWS Glue

En esta sección se incluyen ejemplos de las políticas de control de acceso basadas en identidad (IAM) y las políticas de recursos de AWS Glue.

Contenido

- Ejemplos de políticas basadas en identidades para AWS Glue
  - Prácticas recomendadas sobre las políticas
  - Los permisos de nivel de recursos solo se aplican a objetos específicos de AWS Glue.
  - Uso de la consola de AWS Glue
  - Cómo permitir a los usuarios consultar sus propios permisos
  - Conceder permiso de solo lectura a una tabla
  - Filtrar tablas por permiso GetTables
  - Conceder acceso completo a una tabla y todas las particiones
  - Controlar el acceso mediante prefijo de nombre y denegación explícita
  - Conceder acceso mediante etiquetas
  - Denegar acceso mediante etiquetas

- Usar etiquetas con las operaciones de API List y Batch
- Controlar la configuración mediante claves de condición o claves de contexto
  - Políticas que controlan la configuración mediante claves de condición
  - Políticas que controlan la configuración mediante claves de contexto
- Cómo denegar a una identidad la capacidad de crear sesiones de vista previa de datos
- Ejemplos de políticas basadas en recursos para AWS Glue
  - Consideraciones para el uso de políticas basadas en recursos con AWS Glue
  - Uso de una política de recursos para controlar el acceso en la misma cuenta

Ejemplos de políticas basadas en identidades para AWS Glue

De forma predeterminada, los usuarios y los roles no tienen permiso para crear ni para modificar recursos de AWS Glue. Un administrador de IAM puede crear políticas de IAM para conceder permisos a los usuarios para realizar acciones en los recursos que necesitan.

Para obtener información acerca de cómo crear una política basada en identidades de IAM mediante el uso de estos documentos de políticas JSON de ejemplo, consulte Creación de políticas de IAM (consola) en la Guía del usuario de IAM.

Para obtener más información sobre las acciones y los tipos de recursos definidos por AWS Glue, incluido el formato de los ARN para cada tipo de recurso, consulte Acciones, recursos y claves de condición para AWS Glue en la Referencia de autorizaciones de servicio.

> **Note**
>
> Todos los ejemplos que se proporcionan en esta sección utilizan la región `us-west-2`. Puede reemplazarla por la región de AWS que desee usar.

Temas

- Prácticas recomendadas sobre las políticas
- Los permisos de nivel de recursos solo se aplican a objetos específicos de AWS Glue.
- Uso de la consola de AWS Glue
- Cómo permitir a los usuarios consultar sus propios permisos
- Conceder permiso de solo lectura a una tabla

- Filtrar tablas por permiso GetTables
- Conceder acceso completo a una tabla y todas las particiones
- Controlar el acceso mediante prefijo de nombre y denegación explícita
- Conceder acceso mediante etiquetas
- Denegar acceso mediante etiquetas
- Usar etiquetas con las operaciones de API List y Batch
- Controlar la configuración mediante claves de condición o claves de contexto
- Cómo denegar a una identidad la capacidad de crear sesiones de vista previa de datos

Prácticas recomendadas sobre las políticas

Las políticas basadas en identidades determinan si alguien puede crear o eliminar los recursos de AWS Glue en la cuenta y también si pueden acceder a ellos. Estas acciones pueden generar costos adicionales para su Cuenta de AWS. Siga estas directrices y recomendaciones al crear o editar políticas basadas en identidades:

- Comience a utilizar las políticas administradas de AWS y avance hacia permisos de privilegios mínimos. Para empezar a conceder permisos a los usuarios y cargas de trabajo, utilice las políticas administradas de AWS que otorgan permisos para muchos casos de uso comunes. Están disponibles en su Cuenta de AWS. Se recomienda definir políticas administradas por el cliente de AWS específicas para sus casos de uso a fin de reducir aún más los permisos. Con el fin de obtener más información, consulte las políticas administradas por AWS o las políticas administradas por AWS para funciones de tarea en la Guía de usuario de IAM.
- Aplique permisos de privilegio mínimo: cuando establezca permisos con políticas de IAM, conceda solo los permisos necesarios para realizar una tarea. Para ello, debe definir las acciones que se pueden llevar a cabo en determinados recursos en condiciones específicas, también conocidos como permisos de privilegios mínimos. Con el fin de obtener más información sobre el uso de IAM para aplicar permisos, consulte Políticas y permisos en IAM en la Guía del usuario de IAM.
- Utilice condiciones en las políticas de IAM para restringir aún más el acceso: puede agregar una condición a sus políticas para limitar el acceso a las acciones y los recursos. Por ejemplo, puedes escribir una condición de políticas para especificar que todas las solicitudes deben enviarse utilizando SSL. También puede usar condiciones para conceder acceso a acciones de servicios si se emplean a través de un Servicio de AWS determinado como, por ejemplo, CloudFormation. Para obtener más información, consulte Elementos de la política de JSON de IAM: Condición en la Guía del usuario de IAM.

- Utiliza el analizador de acceso de IAM para validar las políticas de IAM con el fin de garantizar la seguridad y funcionalidad de los permisos: el analizador de acceso de IAM valida políticas nuevas y existentes para que respeten el lenguaje (JSON) de las políticas de IAM y las prácticas recomendadas de IAM. El analizador de acceso de IAM proporciona más de 100 verificaciones de políticas y recomendaciones procesables para ayudar a crear políticas seguras y funcionales. Para más información, consulte Validación de políticas con el Analizador de acceso de IAM en la Guía del usuario de IAM.
- Solicite la autenticación multifactor (MFA): si se encuentra en una situación en la que necesite usuarios raíz o de IAM en su Cuenta de AWS, active la MFA para obtener una mayor seguridad. Para exigir la MFA cuando se invoquen las operaciones de la API, añada condiciones de MFA a sus políticas. Para más información, consulte Acceso seguro a la API con MFA en la Guía del usuario de IAM.

Para obtener más información sobre las prácticas recomendadas de IAM, consulte Prácticas recomendadas de seguridad en IAM en la Guía del usuario de IAM.

Los permisos de nivel de recursos solo se aplican a objetos específicos de AWS Glue.

Solo puede definir un control detallado para los objetos específicos de AWS Glue. Por lo tanto, debe escribir la política de IAM de sus clientes de modo que las operaciones API que permiten utilizar nombres de recursos de Amazon (Amazon Resource Names, ARN) con la instrucción `Resource` no se mezclen con las operaciones API que no permiten el uso de ARN.

Por ejemplo, la siguiente política de IAM permite operaciones de la API para `GetClassifier` y `GetJobRun`. Define el `Resource` como * porque AWS Glue no permite ARN para clasificadores y ejecuciones de trabajo. Dado que se permite utilizar ARN con determinadas operaciones API, como `GetDatabase` y `GetTable`, se pueden especificar ARN en la segunda mitad de la política.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:GetClassifier*",
        "glue:GetJobRun*"
```

```
      ],
      "Resource": "*"
    },
    {
      "Effect": "Allow",
      "Action": [
        "glue:Get*"
      ],
      "Resource": [
        "arn:aws:glue:us-east-1:111122223333:catalog",
        "arn:aws:glue:us-east-1:111122223333:database/default",
        "arn:aws:glue:us-east-1:111122223333:table/default/e*1*",
        "arn:aws:glue:us-east-1:111122223333:connection/connection2"
      ]
    }
  ]
}
```

Para ver una lista de objetos de AWS Glue que permiten el uso de ARN, consulte Especificación de ARN del recurso de AWS Glue.

Uso de la consola de AWS Glue

Para acceder a la consola de AWS Glue, debe tener un conjunto mínimo de permisos. Estos permisos deben permitirle enumerar y consultar detalles sobre los recursos de AWS Glue en su Cuenta de AWS. Si crea una política basada en identidades que sea más restrictiva que el mínimo de permisos necesarios, la consola no funcionará del modo esperado para las entidades (usuarios o roles) que tengan esa política.

No es necesario conceder permisos mínimos para la consola a los usuarios que solo realizan llamadas a la AWS CLI o a la API de AWS. En su lugar, permita el acceso únicamente a las acciones que coincidan con la operación de API que intentan realizar.

Para asegurarse de que los usuarios y los roles puedan seguir utilizando la consola de AWS Glue, también asocie a las entidades la política administrada por AWS *ConsoleAccess* o *ReadOnly* de AWS Glue. Para obtener más información, consulte Adición de permisos a un usuario en la Guía del usuario de IAM:

Para que un usuario pueda trabajar con la consola de AWS Glue, debe tener un conjunto mínimo de permisos que le permitan trabajar con los recursos de AWS Glue en su cuenta de AWS. Además de estos permisos de AWS Glue, la consola requiere permisos de los servicios a continuación:

- Permisos de Amazon CloudWatch Logs para mostrar registros.
- AWS Identity and Access ManagementPermisos de (IAM) para enumerar y transferir roles.
- AWS CloudFormationPermisos para trabajar con pilas.
- Permisos de Amazon Elastic Compute Cloud (Amazon EC2) para enumerar VPC, subredes, grupos de seguridad, instancias y otros objetos.
- Permisos de Amazon Simple Storage Service (Amazon S3) para enumerar buckets y objetos, y recuperar y guardar scripts.
- Permisos necesarios de Amazon Redshift para trabajar con clústeres.
- Permisos de Amazon Relational Database Service (Amazon RDS) para enumerar instancias.

Para obtener más información sobre los permisos que necesitan los usuarios para ver y trabajar con la consola de AWS Glue, consulte Paso 3: Adjuntar una política a los usuarios o los grupos que accedan a AWS Glue.

Si crea una política de IAM que sea más restrictiva que el mínimo de permisos necesarios, la consola no funcionará del modo esperado para los usuarios con esa política de IAM. Para asegurarse de que esos usuarios puedan seguir usando la consola de AWS Glue, asocie también la política administrada `AWSGlueConsoleFullAccess`, según se explica en Políticas administradas (predefinidas) por AWS para AWS Glue.

Cómo permitir a los usuarios consultar sus propios permisos

En este ejemplo, se muestra cómo podría crear una política que permita a los usuarios de IAM ver las políticas administradas e insertadas que se asocian a la identidad de sus usuarios. Esta política incluye permisos para llevar a cabo esta acción en la consola o mediante programación con la AWS CLI o la API de AWS.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "ViewOwnUserInfo",
            "Effect": "Allow",
            "Action": [
                "iam:GetUserPolicy",
                "iam:ListGroupsForUser",
                "iam:ListAttachedUserPolicies",
                "iam:ListUserPolicies",
```

```
                "iam:GetUser"
            ],
            "Resource": ["arn:aws:iam::*:user/${aws:username}"]
        },
        {
            "Sid": "NavigateInConsole",
            "Effect": "Allow",
            "Action": [
                "iam:GetGroupPolicy",
                "iam:GetPolicyVersion",
                "iam:GetPolicy",
                "iam:ListAttachedGroupPolicies",
                "iam:ListGroupPolicies",
                "iam:ListPolicyVersions",
                "iam:ListPolicies",
                "iam:ListUsers"
            ],
            "Resource": "*"
        }
    ]
}
```

Conceder permiso de solo lectura a una tabla

La siguiente política concede permiso de solo lectura a una tabla `books` en la base de datos `db1`. Para obtener más información sobre nombres de recursos de Amazon (Amazon Resource Names, ARN), consulte ARN de Data Catalog.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Sid": "GetTablesActionOnBooks",
      "Effect": "Allow",
      "Action": [
        "glue:GetTables",
        "glue:GetTable"
      ],
      "Resource": [
        "arn:aws:glue:us-east-1:111122223333:catalog",
```

```
        "arn:aws:glue:us-east-1:111122223333:database/db1",
        "arn:aws:glue:us-east-1:111122223333:table/db1/books"
      ]
    }
  ]
}
```

Esta política concede permisos de solo lectura a una tabla denominada `books` en la base de datos denominada `db1`. Para conceder un permiso `Get` a una tabla, también se requiere permiso para el catálogo y los recursos de la base de datos.

La siguiente política concede los permisos mínimos necesarios crear una tabla `tbl` en la base de datos `db1`:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:CreateTable"
      ],
      "Resource": [
        "arn:aws:glue:us-east-1:111122223333:table/db1/tbl1",
        "arn:aws:glue:us-east-1:111122223333:database/db1",
        "arn:aws:glue:us-east-1:111122223333:catalog"
      ]
    }
  ]
}
```

Filtrar tablas por permiso GetTables

Supongamos que hay tres tablas: `customers`, `stores` y `store_sales` en base de datos `db1`. La siguiente política concede permiso `GetTables` a `stores` y `store_sales`, pero no a `customers`. Cuando llama a `GetTables` con esta política, el resultado contiene únicamente las dos tablas autorizadas (la tabla `customers` no se devuelve).

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Sid": "GetTablesExample",
      "Effect": "Allow",
      "Action": [
        "glue:GetTables"
      ],
      "Resource": [
        "arn:aws:glue:us-east-1:111122223333:catalog",
        "arn:aws:glue:us-east-1:111122223333:database/db1",
        "arn:aws:glue:us-east-1:111122223333:table/db1/store_sales",
        "arn:aws:glue:us-east-1:111122223333:table/db1/stores"
      ]
    }
  ]
}
```

Puede simplificar la política anterior mediante `store*` para hacer coincidir los nombres de las tablas que comienzan por `store`.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Sid": "GetTablesExample2",
      "Effect": "Allow",
      "Action": [
        "glue:GetTables"
      ],
      "Resource": [
        "arn:aws:glue:us-east-1:111122223333:catalog",
        "arn:aws:glue:us-east-1:111122223333:database/db1",
        "arn:aws:glue:us-east-1:111122223333:table/db1/store*"
      ]
```

```
    }
  ]
}
```

Del mismo modo, utilizando `/db1/*` para que coincida con todas las tablas de `db1`, la siguiente política concede a `GetTables` acceso a todas las tablas de `db1`.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Sid": "GetTablesReturnAll",
      "Effect": "Allow",
      "Action": [
        "glue:GetTables"
      ],
      "Resource": [
        "arn:aws:glue:us-east-1:111122223333:catalog",
        "arn:aws:glue:us-east-1:111122223333:database/db1",
        "arn:aws:glue:us-east-1:111122223333:table/db1/*"
      ]
    }
  ]
}
```

Si no se proporciona un ARN de tabla, se lleva a cabo correctamente una llamada a `GetTables`, pero devuelve una lista vacía.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Sid": "GetTablesEmptyResults",
      "Effect": "Allow",
      "Action": [
```

```
        "glue:GetTables"
      ],
      "Resource": [
        "arn:aws:glue:us-east-1:111122223333:catalog",
        "arn:aws:glue:us-east-1:111122223333:database/db1"
      ]
    }
  ]
}
```

Si el ARN de base de datos no se encuentra en la política, se produce un error con una llamada a `GetTables` con `AccessDeniedException`.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Sid": "GetTablesAccessDeny",
      "Effect": "Allow",
      "Action": [
        "glue:GetTables"
      ],
      "Resource": [
        "arn:aws:glue:us-east-1:111122223333:catalog",
        "arn:aws:glue:us-east-1:111122223333:table/db1/*"
      ]
    }
  ]
}
```

Conceder acceso completo a una tabla y todas las particiones

La siguiente política concede todos los permisos a una tabla denominada `books` en la base de datos db1. Esto incluye permisos de lectura y escritura en la propia tabla, en las versiones archivadas de ella y en todas sus particiones.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Sid": "FullAccessOnTable",
      "Effect": "Allow",
      "Action": [
        "glue:CreateTable",
        "glue:GetTable",
        "glue:GetTables",
        "glue:UpdateTable",
        "glue:DeleteTable",
        "glue:BatchDeleteTable",
        "glue:GetTableVersion",
        "glue:GetTableVersions",
        "glue:DeleteTableVersion",
        "glue:BatchDeleteTableVersion",
        "glue:CreatePartition",
        "glue:BatchCreatePartition",
        "glue:GetPartition",
        "glue:GetPartitions",
        "glue:BatchGetPartition",
        "glue:UpdatePartition",
        "glue:DeletePartition",
        "glue:BatchDeletePartition"
      ],
      "Resource": [
        "arn:aws:glue:us-east-1:111122223333:catalog",
        "arn:aws:glue:us-east-1:111122223333:database/db1",
        "arn:aws:glue:us-east-1:111122223333:table/db1/books"
      ]
    }
  ]
}
```

La política anterior se puede simplificar en la práctica.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Sid": "FullAccessOnTable",
      "Effect": "Allow",
      "Action": [
        "glue:*Table*",
        "glue:*Partition*"
      ],
      "Resource": [
        "arn:aws:glue:us-east-1:111122223333:catalog",
        "arn:aws:glue:us-east-1:111122223333:database/db1",
        "arn:aws:glue:us-east-1:111122223333:table/db1/books"
      ]
    }
  ]
}
```

Tenga en cuenta que la granularidad mínima del control de acceso detallado se encuentra en el nivel de tabla. Esto significa que no puede conceder a un usuario acceso a algunas particiones de una tabla pero no a otras, o a algunas columnas de la tabla pero no a otras. Un usuario tiene acceso a toda una tabla o a nada de ella.

Controlar el acceso mediante prefijo de nombre y denegación explícita

En este ejemplo, supongamos que las bases de datos y las tablas de su AWS Glue Data Catalog están organizadas con prefijos de nombre. Las bases de datos en la fase de desarrollo tienen el prefijo de nombre `dev-` y las que están en fase de producción tienen el prefijo de nombre `prod-`. Utilice la siguiente política para conceder a los desarrolladores acceso completo a todas las bases de datos, tablas, UDF, etc., que tengan el prefijo `dev-`. Sin embargo, debe conceder acceso de solo lectura a todo lo que incluya el prefijo `prod-`.

JSON

```
{
  "Version":"2012-10-17",
```

```
"Statement": [
  {
    "Sid": "DevAndProdFullAccess",
    "Effect": "Allow",
    "Action": [
      "glue:*Database*",
      "glue:*Table*",
      "glue:*Partition*",
      "glue:*UserDefinedFunction*",
      "glue:*Connection*"
    ],
    "Resource": [
      "arn:aws:glue:us-east-1:111122223333:catalog",
      "arn:aws:glue:us-east-1:111122223333:database/dev-*",
      "arn:aws:glue:us-east-1:111122223333:database/prod-*",
      "arn:aws:glue:us-east-1:111122223333:table/dev-*/*",
      "arn:aws:glue:us-east-1:111122223333:table/*/dev-*",
      "arn:aws:glue:us-east-1:111122223333:table/prod-*/*",
      "arn:aws:glue:us-east-1:111122223333:table/*/prod-*",
      "arn:aws:glue:us-east-1:111122223333:userDefinedFunction/dev-*/*",
      "arn:aws:glue:us-east-1:111122223333:userDefinedFunction/*/dev-*",
      "arn:aws:glue:us-east-1:111122223333:userDefinedFunction/prod-*/*",
      "arn:aws:glue:us-east-1:111122223333:userDefinedFunction/*/prod-*",
      "arn:aws:glue:us-east-1:111122223333:connection/dev-*",
      "arn:aws:glue:us-east-1:111122223333:connection/prod-*"
    ]
  },
  {
    "Sid": "ProdWriteDeny",
    "Effect": "Deny",
    "Action": [
      "glue:*Create*",
      "glue:*Update*",
      "glue:*Delete*"
    ],
    "Resource": [
      "arn:aws:glue:us-east-1:111122223333:database/prod-*",
      "arn:aws:glue:us-east-1:111122223333:table/prod-*/*",
      "arn:aws:glue:us-east-1:111122223333:table/*/prod-*",
      "arn:aws:glue:us-east-1:111122223333:userDefinedFunction/prod-*/*",
      "arn:aws:glue:us-east-1:111122223333:userDefinedFunction/*/prod-*",
      "arn:aws:glue:us-east-1:111122223333:connection/prod-*"
    ]
  }
```

```
  ]
}
```

La segunda instrucción de la política anterior utiliza explícito `deny`. Puede utilizar `deny` explícito para sobrescribir los permisos `allow` que se conceden al principal. Esto le permite bloquear el acceso a los recursos de vital importancia y evitar que otra política conceda accidentalmente acceso a ellos.

En el ejemplo anterior, aunque la primera instrucción concede acceso completo a los recursos de `prod-`, la segunda instrucción revoca explícitamente el acceso de escritura a ellos, lo que deja acceso de solo lectura a los recursos de `prod-`.

Conceder acceso mediante etiquetas

Por ejemplo, supongamos que desea limitar el acceso de un usuario específico de la cuenta denominado `t2` a un desencadenador `Tom`. Todos los demás usuarios, entre los que se incluye `Sam`, tienen acceso para desencadenar `t1`. Los desencadenadores `t1` y `t2` tienen las siguientes propiedades.

```
aws glue get-triggers
{
    "Triggers": [
        {
            "State": "CREATED",
            "Type": "SCHEDULED",
            "Name": "t1",
            "Actions": [
                {
                    "JobName": "j1"
                }
            ],
            "Schedule": "cron(0 0/1 * * ? *)"
        },
        {
            "State": "CREATED",
            "Type": "SCHEDULED",
            "Name": "t2",
            "Actions": [
                {
                    "JobName": "j1"
                }
            ],
```

```
            "Schedule": "cron(0 0/1 * * ? *)"
        }
    ]
}
```

El administrador de AWS Glue asoció un valor de etiqueta `Tom` (`aws:ResourceTag/Name": "Tom"`) al desencadenador `t2`. El administrador de AWS Glue también le proporcionó a Tom una política de IAM con una declaración de condición basada en la etiqueta. Por tanto, Tom solamente puede utilizar una operación de AWS Glue que actúe sobre los recursos con el valor de etiqueta `Tom`.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": "glue:*",
      "Resource": "*",
      "Condition": {
        "StringEquals": {
          "aws:ResourceTag/Name": "Tom"
        }
      }
    }
  ]
}
```

Cuando Tom intenta obtener acceso al desencadenador `t1`, recibe un mensaje de acceso denegado. Sin embargo, puede recuperar correctamente el desencadenador `t2`.

```
aws glue get-trigger --name t1

An error occurred (AccessDeniedException) when calling the GetTrigger operation:
 User: Tom is not authorized to perform: glue:GetTrigger on resource: arn:aws:glue:us-
east-1:123456789012:trigger/t1

aws glue get-trigger --name t2
{
    "Trigger": {
```

```
        "State": "CREATED",
        "Type": "SCHEDULED",
        "Name": "t2",
        "Actions": [
            {
                "JobName": "j1"
            }
        ],
        "Schedule": "cron(0 0/1 * * ? *)"
    }
}
```

Tom no puede usar la operación de API `GetTriggers` plural para mostrar los desencadenadores, ya que esta operación no admite el filtrado de etiquetas.

Para proporcionar a Tom acceso a `GetTriggers`, el administrador de AWS Glue crea una política que estructura los permisos en dos secciones. Una sección permite que Tom tenga acceso a todos los desencadenadores con la operación API `GetTriggers`. La segunda sección permite que Tom tenga acceso a las operaciones API etiquetadas con el valor `Tom`. Con esta política, Tom puede utilizar `GetTriggers` y `GetTrigger` para obtener acceso al desencadenador `t2`.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": "glue:GetTriggers",
      "Resource": "*"
    },
    {
      "Effect": "Allow",
      "Action": "glue:*",
      "Resource": "*",
      "Condition": {
        "StringEquals": {
          "aws:ResourceTag/Name": "Tom"
        }
      }
    }
  ]
```

```
}
```

Denegar acceso mediante etiquetas

Otra estrategia para la política de recursos consiste en denegar el acceso a los recursos explícitamente.

> **Important**
>
> Las políticas de denegación explícita no funcionan con las operaciones de API plurales, como `GetTriggers`.

En la siguiente política de ejemplo, se permiten todas las operaciones de trabajo de AWS Glue. Sin embargo, la segunda declaración `Effect` niega explícitamente el acceso a los trabajos etiquetados con la clave `Team` y el valor `Special`.

Cuando un administrador asocia la siguiente política a una identidad, esta puede acceder a todos los trabajos, excepto los que están etiquetados con la clave `Team` y el valor `Special`.

Usar etiquetas con las operaciones de API List y Batch

Un tercer enfoque para elaborar una política de recursos consiste en permitir el acceso a los recursos utilizando una operación API `List` que muestre los recursos de un valor de etiqueta. A continuación, se utilizará la operación API `Batch` correspondiente, que permitirá obtener acceso a los detalles de recursos específicos. Con este enfoque, el administrador no necesita permitir el acceso las operaciones API `GetCrawlers`, `GetDevEndpoints`, `GetJobs` o `GetTriggers` plurales. En su lugar, puede proporcionar la capacidad para mostrar los recursos con las siguientes operaciones API:

- `ListCrawlers`
- `ListDevEndpoints`
- `ListJobs`
- `ListTriggers`

También puede proporcionar la posibilidad de obtener detalles sobre recursos específicos con las siguientes operaciones API:

- `BatchGetCrawlers`
- `BatchGetDevEndpoints`
- `BatchGetJobs`
- `BatchGetTriggers`

Como administrador, para utilizar este enfoque, puede realizar el siguiente procedimiento:

1. Añadir etiquetas a los rastreadores, puntos de enlace de desarrollo, trabajos y desencadenadores.
2. Denegar a los usuarios el acceso a las operaciones API `Get`, como `GetCrawlers`, `GetDevEndponts`, `GetJobs` y `GetTriggers`.
3. Para que los usuarios puedan saber a qué recursos etiquetados tienen acceso, proporcióneles acceso a las operaciones API `List`, como `ListCrawlers`, `ListDevEndponts`, `ListJobs` y `ListTriggers`.
4. Denegar a los usuarios el acceso a las API de etiquetado de AWS Glue, como `TagResource` y `UntagResource`.
5. Permitir el acceso de los usuarios a los detalles de los recursos con operaciones API `BatchGet`, como `BatchGetCrawlers`, `BatchGetDevEndponts`, `BatchGetJobs` y `BatchGetTriggers`.

Por ejemplo, cuando llame a la operación `ListCrawlers`, proporcione un valor de etiqueta que coincida con el nombre de usuario. El resultado es una lista de rastreadores que coincide con los valores de etiquetas proporcionados. Proporcione la lista de nombres a `BatchGetCrawlers` para obtener información sobre cada uno de los rastreadores con la etiqueta especificada.

Por ejemplo, si Tom solo puede recuperar información sobre los desencadenadores con la etiqueta `Tom`, el administrador puede agregar etiquetas a los desencadenadores de `Tom`, denegar a todos los usuarios el acceso a la operación de API `GetTriggers` y permitir a todos los usuarios el acceso a `ListTriggers` y `BatchGetTriggers`.

A continuación, se muestra la política de recursos que al administrador de AWS Glue concede a Tom. En la primera sección de la política, todas las operaciones API de AWS Glue están denegadas para `GetTriggers`. En la segunda sección de la política, la operación API `ListTriggers` está permitida en todos los recursos. Sin embargo, en la tercera sección, los recursos con la etiqueta `Tom` tienen permitido el acceso mediante `BatchGetTriggers`.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Deny",
      "Action": "glue:GetTriggers",
      "Resource": "*"
    },
    {
      "Effect": "Allow",
      "Action": [
        "glue:ListTriggers"
      ],
      "Resource": [
        "*"
      ]
    },
    {
      "Effect": "Allow",
      "Action": [
        "glue:BatchGetTriggers"
      ],
      "Resource": [
        "*"
      ],
      "Condition": {
        "StringEquals": {
          "aws:ResourceTag/Name": "Tom"
        }
      }
    }
  ]
}
```

Si utilizamos los mismos desencadenadores que en el ejemplo anterior, Tom tendrá acceso al desencadenador `t2`, pero no al desencadenador `t1`. En el siguiente ejemplo, se muestran los resultados cuando Tom intenta obtener acceso a `t1` y `t2` con `BatchGetTriggers`.

```
aws glue batch-get-triggers --trigger-names t2
```

```
{
    "Triggers": {
        "State": "CREATED",
        "Type": "SCHEDULED",
        "Name": "t2",
        "Actions": [
            {
                "JobName": "j2"
            }
        ],
        "Schedule": "cron(0 0/1 * * ? *)"
    }
}

aws glue batch-get-triggers  --trigger-names t1

An error occurred (AccessDeniedException) when calling the BatchGetTriggers operation:
 No access to any requested resource.
```

En el siguiente ejemplo, se muestran los resultados cuando Tom intenta obtener acceso a los desencadenadores `t2` y `t3` (que no existe) en la misma llamada a `BatchGetTriggers`. Tenga en cuenta que, como Tom tiene acceso al desencadenador `t2` y dicho desencadenador existe, solo se devuelve `t2`. Aunque Tom tenga autorización para obtener acceso al desencadenador `t3`, el desencadenador `t3` no existe, por lo que, al devolver la respuesta, `t3` estará incluido en una lista de `"TriggersNotFound": []`.

```
aws glue batch-get-triggers --trigger-names t2 t3
{
    "Triggers": {
        "State": "CREATED",
        "Type": "SCHEDULED",
        "Name": "t2",
        "Actions": [
            {
                "JobName": "j2"
            }
        ],
        "TriggersNotFound": ["t3"],
        "Schedule": "cron(0 0/1 * * ? *)"
    }
}
```

Controlar la configuración mediante claves de condición o claves de contexto

Puede utilizar claves de condición o claves de contexto al conceder permisos para crear y actualizar trabajos. En estas secciones, se analizan las claves:

- Políticas que controlan la configuración mediante claves de condición
- Políticas que controlan la configuración mediante claves de contexto

Políticas que controlan la configuración mediante claves de condición

AWS Glue proporciona tres claves de condición de IAM: `glue:VpcIds`, `glue:SubnetIds` y `glue:SecurityGroupIds`. Puede utilizar claves de condición en políticas de IAM al conceder permisos para crear y actualizar trabajos. Puede utilizar esta configuración para asegurarse de que no se creen trabajos ni sesiones (ni se actualicen) para ejecutarse fuera del entorno de VPC deseado. La información de configuración de la VPC no es una entrada directa de la solicitud `CreateJob`, sino que se infiere del campo “conexiones” del trabajo que apunta a una conexión de AWS Glue.

Ejemplo de uso

Cree una conexión de tipo de red de AWS Glue denominada “traffic-monitored-connection” con el ID de la VPC deseado: “vpc-id1234”, SubnetIds y SecurityGroupIds.

Especifique la condición de las claves de condición para las acciones `CreateJob` y `UpdateJob` en la política de IAM.

```
{
  "Effect": "Allow",
  "Action": [
    "glue:CreateJob",
    "glue:UpdateJob"
  ],
  "Resource": [
    "*"
  ],
  "Condition": {
    "ForAnyValue:StringLike": {
      "glue:VpcIds": [
        "vpc-id1234"
      ]
    }
```

```
  }
}
```

Puede establecer una política de IAM similar para prohibir la creación de un trabajo de AWS Glue sin especificar información de conexión.

Restricción de sesiones en las VPC

Para hacer que las sesiones creadas se ejecuten en una VPC específica, debe restringir el permiso del rol al agregar un efecto `Deny` a la acción `glue:CreateSession` con la condición de que glue:vpc-id no sea igual a vpc-<123>. Por ejemplo:

```
"Effect": "Deny",
"Action": [
    "glue:CreateSession"
 ],
"Condition": {
    "StringNotEquals" : {"glue:VpcIds" : ["vpc-123"]}
}
```

También puede hacer que las sesiones creadas se ejecuten en una VPC al agregar un `Deny` efecto en la `glue:CreateSession` acción con la condición de que `glue:vpc-id` sea nulo. Por ejemplo:

```
{
    "Effect": "Deny",
    "Action": [
        "glue:CreateSession"
    ],
      "Condition": {
        "Null": {"glue:VpcIds": true}
    }
},
{
    "Effect": "Allow",
    "Action": [
        "glue:CreateSession"
    ],
    "Resource": ["*"]
}
```

Políticas que controlan la configuración mediante claves de contexto

AWS Glue proporciona una clave de contexto (`glue:CredentialIssuingService=glue.amazonaws.com`) a cada sesión de rol que AWS Glue pone a disposición del punto de conexión del trabajo y del desarrollador. Esto le permite implementar controles de seguridad para las acciones llevadas a cabo por scripts de AWS Glue. AWS Glue proporciona otra clave de contexto (`glue:RoleAssumedBy=glue.amazonaws.com`) a cada sesión de rol en la que AWS Glue realice una llamada a otro servicio de AWS en nombre del cliente (no mediante un punto de conexión del trabajo o el desarrollador, sino directamente mediante el servicio de AWS Glue).

Ejemplo de uso

Especifique el permiso condicional en una política de IAM y asócielo al rol que utilizará un trabajo de AWS Glue. Esto garantiza que se permitan o denieguen determinadas acciones en función de si la sesión de rol se utiliza para el entorno de tiempo de ejecución de un trabajo de AWS Glue.

```
{
    "Effect": "Allow",
    "Action": "s3:GetObject",
    "Resource": "arn:aws:s3:::amzn-s3-demo-bucket/*",
    "Condition": {
        "StringEquals": {
            "glue:CredentialIssuingService": "glue.amazonaws.com"
        }
    }
}
```

Cómo denegar a una identidad la capacidad de crear sesiones de vista previa de datos

En esta sección, se incluye un ejemplo de política de IAM que se usa para denegar a una identidad la capacidad de crear sesiones de vista previa de datos. Adjunte esta política a la identidad, que es independiente del rol que se usa en la sesión de vista previa de datos durante su ejecución.

```
{
    "Sid": "DatapreviewDeny",
    "Effect": "Deny",
     "Action": [
           "glue:CreateSession"
     ],
     "Resource": [
          "arn:aws:glue:*:*:session/glue-studio-datapreview*"
```

```
        ]
}
```

Ejemplos de políticas basadas en recursos para AWS Glue

Esta sección contiene ejemplos de políticas basadas en recursos, incluidas las políticas que conceden acceso entre cuentas.

Los ejemplos utilizan la AWS Command Line Interface (AWS CLI) para interactuar con las operaciones de API del servicio AWS Glue. Puede realizar las mismas operaciones en la consola de AWS Glue o mediante uno de los SDK de AWS.

> **Important**
>
> Al cambiar una política de recursos de AWS Glue, puede revocar accidentalmente permisos de los usuarios existentes de AWS Glue en su cuenta y causar interrupciones inesperadas. Pruebe estos ejemplos únicamente en las cuentas de desarrollo o prueba y asegúrese de que no rompen ningún flujo de trabajo existente antes de realizar los cambios.

Temas

- Consideraciones para el uso de políticas basadas en recursos con AWS Glue
- Uso de una política de recursos para controlar el acceso en la misma cuenta

Consideraciones para el uso de políticas basadas en recursos con AWS Glue

> **Note**
>
> Tanto las políticas de IAM como una política de recursos de AWS Glue tardan unos segundos en propagarse. Después de asociar una nueva política, es posible que observe que la política anterior sigue en vigor hasta que la nueva política se haya propagado por el sistema.

Puede utilizar un documento de política escrito en formato JSON para crear o modificar una política de recursos. La sintaxis de la política es la misma que para una política de IAM basada en identidades (consulte Referencia de políticas JSON de IAM), con las siguientes excepciones:

- Un bloque "Principal" o "NotPrincipal" es obligatorio para cada instrucción de política.
- "Principal" o "NotPrincipal" deben identificar a las entidades principales válidas. Los patrones de comodín (como arn:aws:iam::*account-id*:user/*) no están permitidos.
- El bloque "Resource" en la política requiere que todos los ARN de recursos se correspondan con la siguiente sintaxis de expresiones regulares (donde el primer %s es la *región* y el segundo %s es el *ID de cuenta*):

  ```
  *arn:aws:glue:%s:%s:(\*|[a-zA-Z\*]+\/?.*)
  ```

  Por ejemplo, arn:aws:glue:us-west-2:*account-id*:* y arn:aws:glue:us-west-2:*account-id*:database/default están permitidos, pero * no está permitido.
- A diferencia de las políticas basadas en identidades, una política de recursos de AWS Glue solo debe contener nombres de recursos de Amazon (ARN) que pertenecen al catálogo al que se asocia dicha política. Estos ARN siempre empiezan por arn:aws:glue:.
- Una política no puede impedir que la identidad que la cree genere o modifique otras políticas.
- Un documento JSON de política de recursos no puede superar los 10 KB de tamaño.

Uso de una política de recursos para controlar el acceso en la misma cuenta

En este ejemplo, un usuario administrador en la cuenta A crea una política de recursos que concede al usuario de IAM, Alice, de la cuenta A un acceso completo al catálogo. Alice no tiene ninguna política de IAM asociada.

Para ello, el usuario administrador ejecuta el siguiente comando de la AWS CLI.

```
# Run as admin of Account A
$ aws glue put-resource-policy --profile administrator-name --region us-west-2 --
policy-in-json '{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Principal": {
        "AWS": [
          "arn:aws:iam::account-A-id:user/Alice"
        ]
      },
      "Effect": "Allow",
      "Action": [
```

```
        "glue:*"
      ],
      "Resource": [
        "arn:aws:glue:us-west-2:account-A-id:*"
      ]
    }
  ]
}'
```

En lugar de especificar el documento de política JSON como parte de su comando de AWS CLI, puede guardar un documento de política en un archivo y hacer referencia a la ruta del archivo en el comando de AWS CLI, con el prefijo `file://`. A continuación, se muestra un ejemplo de cómo podría hacerlo.

```
$ echo '{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Principal": {
        "AWS": [
          "arn:aws:iam::account-A-id:user/Alice"
        ]
      },
      "Effect": "Allow",
      "Action": [
        "glue:*"
      ],
      "Resource": [
        "arn:aws:glue:us-west-2:account-A-id:*"
      ]
    }
  ]
}' > /temp/policy.json

$ aws glue put-resource-policy --profile admin1 \
    --region us-west-2 --policy-in-json file:///temp/policy.json
```

Después de que esta política de recurso se haya propagado, Alice puede acceder a todos los recursos de AWS Glue de la cuenta A; de la siguiente manera.

```
# Run as user Alice
$ aws glue create-database --profile alice --region us-west-2 --database-input '{
```

```
    "Name": "new_database",
    "Description": "A new database created by Alice",
    "LocationUri": "s3://amzn-s3-demo-bucket"
}'

$ aws glue get-table --profile alice --region us-west-2 --database-name "default" --
table-name "tbl1"}
```

En respuesta a la llamada `get-table` de Alice, el servicio de AWS Glue devuelve lo siguiente.

```
{
  "Table": {
    "Name": "tbl1",
    "PartitionKeys": [],
    "StorageDescriptor": {
        ......
    },
    ......
  }
}
```

Concesión de políticas administradas de AWS para AWS Glue

Una política administrada por AWS es una política independiente que AWS crea y administra. Las políticas administradas por AWS se diseñan para ofrecer permisos para muchos casos de uso comunes, por lo que puede empezar a asignar permisos a los usuarios, grupos y roles.

Considere que es posible que las políticas administradas de AWS no concedan permisos de privilegio mínimo para los casos de uso concretos, ya que están disponibles para que las utilicen todos los clientes de AWS. Se recomienda definir políticas administradas por el cliente específicas para sus casos de uso a fin de reducir aún más los permisos.

No puede cambiar los permisos definidos en las políticas administradas de AWS. Si AWS actualiza los permisos definidos en una política administrada de AWS, la actualización afecta a todas las identidades de entidades principales (usuarios, grupos y roles) a las que está adjunta la política. Lo más probable es que AWS actualice una política administrada de AWS cuando se lance un nuevo Servicio de AWS o las operaciones de la API nuevas estén disponibles para los servicios existentes.

Para obtener más información, consulte Políticas administradas por AWS en la Guía del usuario de IAM.

Políticas administradas (predefinidas) por AWS para AWS Glue

AWS aborda muchos casos de uso comunes dando políticas de IAM independientes creadas y administradas por AWS. Estas políticas administradas por AWS conceden los permisos necesarios para casos de uso comunes, lo que le evita tener que investigar los permisos necesarios. Para obtener más información, consulte Políticas administradas por AWS en la Guía del usuario de IAM.

Las siguientes políticas administradas de AWS, que puede asociar a las identidades de su cuenta, son específicas de AWS Glue y se agrupan según los escenarios de caso de uso:

- AWSGlueConsoleFullAccess: concede acceso total a los recursos de AWS Glue cuando una identidad a la que está asociada la política utiliza laConsola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Por lo general, esta política se asocia a los usuarios de la consola de AWS Glue.
- AWSGlueServiceRole: da acceso a recursos que precisan diversos procesos de AWS Glue para ejecutarse en su nombre. Entre estos recursos se incluyen AWS Glue, Amazon S3, IAM, CloudWatch Logs y Amazon EC2. Si aplica la convención de nomenclatura en los recursos especificados en esta política, los procesos de AWS Glue tienen los permisos necesarios. Normalmente, esta política se asocia a los roles que se especifican a la hora de definir rastreadores, trabajos y puntos de conexión de desarrollo.
- AwsGlueSessionUserRestrictedServiceRole: da acceso completo a todos los recursos de AWS Glue, a excepción de las sesiones. Permite a los usuarios crear y utilizar solo las sesiones interactivas que están asociadas al usuario. Esta política incluye otros permisos que AWS Glue necesita para administrar recursos de AWS Glue en otros servicios de AWS. La política también permite agregar etiquetas a recursos de AWS Glue en otros servicios de AWS.

  > **Note**
  >
  > Para obtener todos los beneficios de seguridad, no conceda esta política a un usuario al que se le haya asignado la política `AWSGlueServiceRole`, `AWSGlueConsoleFullAccess` o `AWSGlueConsoleSageMakerNotebookFullAccess`.

- AwsGlueSessionUserRestrictedPolicy: proporciona acceso para crear sesiones interactivas de AWS Glue mediante la operación de la API `CreateSession` solo si se proporcionan un “propietario” de la clave de etiqueta y un valor que coincida con el ID de usuario de AWS del asignado. Esta política de identidad está asociada al usuario de IAM que invoca a la operación de la API `CreateSession`. Esta política también permite al asignado interactuar con los recursos

de sesión interactiva de AWS Glue creados con una etiqueta de “propietario” y un valor que coincide con su ID de usuario de AWS. Esta política deniega el permiso para cambiar o eliminar las etiquetas de “propietario” de un recurso de sesión de AWS Glue luego de que se crea la sesión.

> **Note**
>
> Para obtener los beneficios de seguridad completos, no conceda esta política a un usuario al que se le haya asignado la política `AWSGlueServiceRole`, `AWSGlueConsoleFullAccess` o `AWSGlueConsoleSageMakerNotebookFullAccess`.

- AwsGlueSessionUserRestrictedNotebookServiceRole: proporciona suficiente acceso a la sesión del cuaderno de AWS Glue Studio para interactuar con recursos de sesión interactivos de AWS Glue específicos. Estos son recursos se crean con el valor de etiqueta de “propietario” que coincide con el ID de usuario de AWS de la entidad principal (usuario o rol de IAM) que crea el cuaderno. Para obtener más información sobre estas etiquetas, consulte el gráfico Valores clave de la entidad principal en la Guía del usuario de IAM.

  Esta política de rol de servicio se asocia al rol que se especifica con un comando mágico dentro del cuaderno o que se transfiere como un rol a la operación de la API `CreateSession`. Esta política también permite a la entidad principal crear una sesión interactiva de AWS Glue desde la interfaz del cuaderno de AWS Glue Studio solo si una clave de etiqueta de “propietario” y un valor coinciden con el ID de usuario de AWS de la entidad principal. Esta política deniega el permiso para cambiar o eliminar las etiquetas de “propietario” de un recurso de sesión de AWS Glue luego de que se crea la sesión. Esta política también incluye permisos para escribir y leer desde los buckets de Amazon S3, escribir registros de CloudWatch, y crear y eliminar etiquetas para los recursos de Amazon EC2 que utiliza AWS Glue.

  > **Note**
  >
  > Para obtener todos los beneficios de seguridad, no conceda esta política a un rol al que se le haya asignado la política `AWSGlueServiceRole`, `AWSGlueConsoleFullAccess` o `AWSGlueConsoleSageMakerNotebookFullAccess`.

- AwsGlueSessionUserRestrictedNotebookPolicy: proporciona acceso para crear una sesión interactiva de AWS Glue desde la interfaz del cuaderno de AWS Glue Studio solo si hay una clave de etiqueta de “propietario” y un valor que coinciden con el ID de usuario de AWS de la entidad

principal (usuario o rol de IAM) que crea el cuaderno. Para obtener más información sobre estas etiquetas, consulte el gráfico Valores clave de la entidad principal en la Guía del usuario de IAM.

Esta política se adjunta a la entidad principal (usuario o rol de IAM) que crea sesiones a partir de la interfaz del cuaderno de AWS Glue Studio. Esta política también permite un acceso suficiente al cuaderno de AWS Glue Studio para interactuar con recursos de sesión interactivos de AWS Glue específicos. Se trata de recursos que se crean con el valor de la etiqueta “propietario” que coincide con el ID de usuario de AWS de la entidad principal. Esta política deniega el permiso para cambiar o eliminar las etiquetas de “propietario” de un recurso de sesión de AWS Glue luego de que se crea la sesión.

- AWSGlueServiceNotebookRole: concede acceso a sesiones de AWS Glue iniciadas en un cuaderno de AWS Glue Studio. Esta política permite enumerar y obtener información de sesión de todas las sesiones, pero solo permite a los usuarios crear y utilizar las sesiones etiquetadas con su ID de usuario de AWS. Esta política deniega el permiso para cambiar o eliminar etiquetas de “propietario” de recursos de sesión de AWS Glue etiquetados con sus ID de AWS.

  Asigne esta política al usuario de AWS que crea trabajos con la interfaz del bloc de notas en AWS Glue Studio.

- AWSGlueConsoleSageMakerNotebookFullAccess: concede acceso completo a los recursos de AWS Glue e IA de SageMaker cuando la identidad a la que la política está asociada utiliza la Consola de administración de AWS. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Por lo general, esta política se asocia a los usuarios de la consola de AWS Glue que administran los cuadernos de IA de SageMaker.

- AWSGlueSchemaRegistryFullAccess: concede acceso completo a recursos de Schema Registry de AWS Glue cuando la identidad a la que la política está asociada utiliza la Consola de administración de AWS o la AWS CLI. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Por lo general, esta política se asocia a los usuarios de la consola de AWS Glue o la AWS CLI que administran Schema Registry de AWS Glue.

- AWSGlueSchemaRegistryReadonlyAccess: concede acceso de solo lectura a recursos de Schema Registry de AWS Glue cuando una identidad a la que la política está asociada utiliza la Consola de administración de AWS o la AWS CLI. Si sigue la convención de nomenclatura para los recursos especificados en esta política, los usuarios dispondrán de todas las funciones de la consola. Por lo general, esta política se asocia a los usuarios de la consola de AWS Glue o la AWS CLI que utilizan Schema Registry de AWS Glue.

> **Note**
>
> Para consultar estas políticas de permisos, inicie sesión en la consola de IAM y busque las políticas específicas.

También puede crear sus propias políticas de IAM personalizadas para conceder permisos a las acciones y recursos de AWS Glue. Puede asociar estas políticas personalizadas a los grupos o usuarios de IAM que requieran esos permisos.

Para crear una conexión con una configuración de VPC mientras se utiliza un rol de IAM personalizado, este debe tener las siguientes acciones de acceso a la VPC:

- secretsmanager:GetSecretValue
- secretsmanager:PutSecretValue
- secretsmanager:DescribeSecret
- ec2:CreateNetworkInterface
- ec2:DeleteNetworkInterface
- ec2:DescribeNetworkInterfaces
- ec2:DescribeSubnets

AWS Glue se actualiza a las políticas administradas de AWS

Es posible consultar los detalles sobre las actualizaciones de AWS las políticas administradas de para AWS Glue debido a que este servicio comenzó a realizar el seguimiento de estos cambios. Para obtener alertas automáticas sobre cambios en esta página, suscríbase a la fuente RSS en la página de historial de documentos de AWS Glue.

Cambio	Descripción	Fecha
AWSGlueSessionUser RestrictedNotebookPolicy: actualización menor de una política ya existente.	Agregue el permiso de acción `glue:TagResource` en la clave de la etiqueta de propietario. Necesario para admitir tag-on-create para las	30 de agosto de 2024

Cambio	Descripción	Fecha
	sesiones con clave de etiqueta de propietario.	
AWSGlueSessionUserRestrictedNotebookServiceRole: actualización menor de una política existente.	Agregue el permiso de acción `glue:TagResource` en la clave de la etiqueta de propietario. Necesario para admitir tag-on-create para las sesiones con clave de etiqueta de propietario.	30 de agosto de 2024
AWSGlueSessionUserRestrictedPolicy: actualización menor de una política existente.	Agregue el permiso de acción `glue:TagResource` en la clave de la etiqueta de propietario. Necesario para admitir tag-on-create para las sesiones con clave de etiqueta de propietario.	5 de agosto de 2024
AWSGlueSessionUserRestrictedServiceRole: actualización menor de una política existente.	Agregue el permiso de acción `glue:TagResource` en la clave de la etiqueta de propietario. Necesario para admitir tag-on-create para las sesiones con clave de etiqueta de propietario.	5 de agosto de 2024
AWSGlueSessionUserRestrictedPolicy: actualización menor de una política existente.	Agregar `glue:StartCompletion` y `glue:GetCompletion` a la política. Es necesaria para la integración de datos de Amazon Q en AWS Glue.	30 de abril de 2024

Cambio	Descripción	Fecha
AWSGlueSessionUserRestrictedNotebookServiceRole: actualización menor de una política existente.	Agregar `glue:StartCompletion` y `glue:GetCompletion` a la política. Es necesaria para la integración de datos de Amazon Q en AWS Glue.	30 de abril de 2024
AWSGlueSessionUserRestrictedServiceRole: actualización menor de una política existente.	Agregar `glue:StartCompletion` y `glue:GetCompletion` a la política. Es necesaria para la integración de datos de Amazon Q en AWS Glue.	30 de abril de 2024
AWSGlueServiceNotebookRole: actualización menor de una política ya existente.	Agregar `glue:StartCompletion` y `glue:GetCompletion` a la política. Es necesaria para la integración de datos de Amazon Q en AWS Glue.	30 de enero de 2024
AWSGlueSessionUserRestrictedNotebookPolicy: actualización menor de una política ya existente.	Agregar `glue:StartCompletion` y `glue:GetCompletion` a la política. Es necesaria para la integración de datos de Amazon Q en AWS Glue.	29 de noviembre de 2023
AWSGlueServiceNotebookRole: actualización menor de una política ya existente.	Agregar `codewhisperer:GenerateRecommendations` a la política. Obligatorio para una nueva característica en la que AWS Glue genera recomendaciones de CodeWhisperer.	9 de octubre de 2023

Cambio	Descripción	Fecha
AWSGlueServiceRole: actualización menor de una política ya existente.	Reducir el alcance de los permisos de CloudWatch para reflejar mejor el registro de AWS Glue.	4 de agosto de 2023
AWSGlueConsoleFullAccess: actualización menor de una política ya existente.	Agregar una lista de recetas de `databrew` y describir los permisos a la política. Se requiere para proporcionar acceso administrativo completo a las nuevas características en las que AWS Glue puede acceder a las recetas.	9 de mayo de 2023
AWSGlueConsoleFullAccess: actualización menor de una política existente.	Agregar `cloudformation:ListStacks` a la política. Conserva las capacidades existentes tras los cambios en los requisitos de autorización de CloudFormation.	28 de marzo de 2023

Cambio	Descripción	Fecha
Se agregaron nuevas políticas administradas para la característica de sesiones interactivas: • AwsGlueSessionUser RestrictedServiceRole • AwsGlueSessionUser RestrictedPolicy • AwsGlueSessionUser RestrictedNotebook ServiceRole • AwsGlueSessionUser RestrictedNotebookPolicy	Estas políticas se diseñaron para proporcionar seguridad adicional para las sesiones interactivas y los cuadernos en AWS Glue Studio. Las políticas restringen el acceso a la operación de la API `CreateSession` para que solo el propietario tenga acceso.	30 de noviembre de 2021

Cambio	Descripción	Fecha
AWSGlueConsoleSageMakerNotebookFullAccess: actualización de una política existente.	Se eliminó un ARN de recurso redundante (`arn:aws:s3:::aws-glue-*/*`) para la acción que concede permisos de lectura/escritura en los buckets de Amazon S3 que AWS Glue utiliza para almacenar scripts y archivos temporales. Se corrigió un problema de sintaxis al cambiar `"StringEquals"` a `"ForAnyValue:StringLike"`, y se movieron las líneas `"Effect": "Allow"` para que precedan a la línea `"Action":` en las instancias en la que no funcionaban.	15 de julio de 2021
AWSGlueConsoleFullAccess: actualización de una política existente.	Se eliminó un ARN de recurso redundante (`arn:aws:s3:::aws-glue-*/*`) para la acción que concede permisos de lectura/escritura en los buckets de Amazon S3 que AWS Glue utiliza para almacenar scripts y archivos temporales.	15 de julio de 2021
AWS Glue comenzó el seguimiento de los cambios.	AWS Glue comenzó el seguimiento de los cambios de las políticas administradas de AWS.	10 de junio de 2021

Otorgamiento de políticas con un alcance dinámico para la ejecución de trabajos

AWS Glue ofrece una capacidad nueva y poderosa: políticas de sesión dinámicas para la ejecución de trabajos. Esta característica le permite especificar permisos personalizados y detallados para cada ejecución de trabajo sin necesidad de crear varios roles de IAM.

Cuando inicia un trabajo de Glue con la API `StartJobRun`, puede incluir una política de sesión en línea. Esta política modifica temporalmente los permisos del rol de ejecución del trabajo durante la ejecución de ese trabajo específico. Es similar al uso de credenciales temporales con la API `AssumeRole` en otros servicios de AWS.

- Seguridad mejorada: puede limitar los permisos de trabajo al mínimo necesario para cada ejecución.
- Administración simplificada: elimina la necesidad de crear y mantener numerosos roles de IAM para diferentes escenarios.
- Flexibilidad: puede ajustar los permisos dinámicamente en función de los parámetros de tiempo de ejecución o de las necesidades específicas del inquilino.
- Escalabilidad: este método destaca en entornos de varios inquilinos donde es necesario aislar los recursos entre inquilinos.

Ejemplos para el otorgamiento del uso de políticas con alcance dinámico:

En los siguientes ejemplos, se muestra cómo otorgar acceso de lectura y escritura a los trabajos solo a una ruta de bucket de Amazon S3 específica, donde la ruta se determina dinámicamente mediante el ID de ejecución del trabajo. Esto ilustra cómo implementar permisos detallados y específicos de ejecución para cada ejecución de trabajo.

Desde la CLI

```
aws glue start-job-run \
    --job-name "your-job-name" \
    --execution-role-session-policy '{
        "Version": "2012-10-17",
        "Statement": [
            {
                "Effect": "Allow",
                "Action": [
                    "s3:GetObject",
```

```
                "s3:PutObject"
            ],
            "Resource": [
                "arn:aws:s3:::specific-bucket/${JobRunId}/*"
            ]
        }
    ]
}'
```

Especificación de ARN del recurso de AWS Glue

En AWS Glue, puede controlar el acceso a los recursos a través de una política de AWS Identity and Access Management (IAM). En las políticas se emplean nombres de recurso de Amazon (ARN) para identificar los recursos a los que se aplican las políticas. No todos los recursos de AWS Glue admiten ARN.

Temas

- ARN de Data Catalog
- ARN para objetos que no están en el catálogo en AWS Glue
- Control de acceso para operaciones API singulares que no estén en el catálogo de AWS Glue
- Control de acceso para operaciones API que no están en el catálogo de AWS Glue que recuperan varios elementos
- Control de acceso para operaciones de API BatchGet que no están en el catálogo de AWS Glue

ARN de Data Catalog

Los recursos de Data Catalog tienen una estructura jerárquica, con `catalog` como la raíz.

```
arn:aws:glue:region:account-id:catalog
```

Cada cuenta de AWS tiene un único Data Catalog en una región de AWS con el ID de cuenta de 12 dígitos como el ID de catálogo. Los recursos tienen ARN únicos asociados a ellos, tal y como se muestra en la siguiente tabla.

Tipo de recurso	Formato de ARN
Catálogo	`arn:aws:glue: region:account-id :catalog`

Tipo de recurso	Formato de ARN
	Por ejemplo: .: `arn:aws:glue:us-east-1:123456789012:catalog`
Database	`arn:aws:glue:` *`region`*`:`*`account-id`* `:database/` *`database name`* Por ejemplo: .: `arn:aws:glue:us-east-1:123456789012:database/db1`
Tabla	`arn:aws:glue:` *`region`*`:`*`account-id`* `:table/`*`database name`*`/`*`table name`* Por ejemplo: .: `arn:aws:glue:us-east-1:123456789012:table/db1/tbl1`
Catálogo federado de tablas de S3 (todos los buckets de tabla)	`arn:aws:glue:` *`region`*`:`*`account-id`* `:catalog/s3tablescatalog` Por ejemplo: .: `arn:aws:glue:us-east-1:123456789012:catalog/s3tablescatalog`
Catálogo federado de buckets de tabla de S3 (catálogo secundario)	`arn:aws:glue:` *`region`*`:`*`account-id`* `:catalog/s3tablescatalog/` *`bucket name`* Por ejemplo: .: `arn:aws:glue:us-east-1:123456789012:catalog/s3tablescatalog/amzn-s3-demo-bucket1`
Base de datos federada de tablas de S3	`arn:aws:glue:` *`region`*`:`*`account-id`* `:database/s3tablescatalog/` *`child catalog name`*`/`*`database name`* Por ejemplo: .: `arn:aws:glue:us-east-1:123456789012:database/s3tablescatalog/amzn-s3-demo-bucket1/nsdb1`

Tipo de recurso	Formato de ARN
Tabla federada de S3	`arn:aws:glue:` *`region`*`:`*`account-id`* `:table/s3tablescatalog/` *`child catalog name`*`/`*`database name`*`/`*`table name`* Por ejemplo: .: `arn:aws:glue:us-east-1:123456789012:table/s3tablescatalog/amzn-s3-demo-bucket1/nsdb1/s3tbl1`
Catálogo federado de tablas de S3 (un único bucket de tabla registrado en Lake Formation)	`arn:aws:glue:` *`region`*`:`*`account-id`* `:catalog/`*`nombre del catálogo`* Por ejemplo: .: `arn:aws:glue:us-east-1:123456789012:catalog/amzn-s3-demo-bucket1`
Base de datos federada de tablas de S3	`arn:aws:glue:` *`region`*`:`*`account-id`* `:catalog/`*`nombre del catálogo`*`/`*`nombre de la base de datos`* Por ejemplo: .: `arn:aws:glue:us-east-1:123456789012:database/amzn-s3-demo-bucket1/nsdb1`
Tabla federada de S3	`arn:aws:glue:` *`region`*`:`*`account-id`* `:catalog/`*`nombre del catálogo`*`/`*`nombre de la base de datos`*`/`*`nombre de la tabla`* Por ejemplo: .: `arn:aws:glue:us-east-1:123456789012:table/amzn-s3-demo-bucket1/`*`nsdb1`*`/s3tbl1`
Catálogo federado o gestionado (catálogo de nivel superior en un catálogo múltiple)	`arn:aws:glue:` *`region`*`:`*`account-id`* `:catalog/` *`top-level catalog name`* Por ejemplo: .: `arn:aws:glue:us-east-1:123456789012:catalog/nscatalog` El formato ARN de un catálogo gestionado sigue la misma estructura.

Tipo de recurso	Formato de ARN
Catálogo federado de varios niveles (catálogo secundario en un catálogo de varios niveles)	`arn:aws:glue:` *`region`*`:`*`account-id`* `:catalog/` *`top-level catalog name`*`/`*`child catalog name`* Por ejemplo: .: `arn:aws:glue:us-east-1:123456789012:catalog/nscatalog/dbcatalog`
Base de datos federada	`arn:aws:glue:` *`region`*`:`*`account-id`* `:database/` *`name space catalog name`*`/`*`child catalog name`*`/`*`database name`* Por ejemplo: .: `arn:aws:glue:us-east-1:123456789012:database/nscatalog/dbcatalog/schemadb`
Tabla federada	`arn:aws:glue:` *`region`*`:`*`account-id`* `:table/`*`name space catalog name`*`/`*`child catalog name`*`/`*`database name`*`/`*`table name`* Por ejemplo: .: `arn:aws:glue:us-east-1:123456789012:table/nscatalog/dbcatalog/schemadb/rstbl1`
Contenedor de enlaces de catálogos	`arn:aws:glue:` *`region`*`:`*`account-id`* `:catalog/`*`nombre del contenedor de enlaces`* Por ejemplo: `arn:aws:glue:glue:us-east-1:123456789012:catalog` /linkcontainer-example
Database	`arn:aws:glue:` *`region`*`:`*`account-id`* `:catalog/`*`nombre del contenedor de enlaces`* /*`nombre de la base de datos`* Por ejemplo: `arn:aws:glue:glue:us-east-1:123456789012:database` /linkcontainer-example/link-db
Función definida por el usuario	`arn:aws:glue:` *`region`*`:`*`account-id`* `:userDefinedFunction/` *`database name`*`/`*`user-defined function name`* Por ejemplo: .: `arn:aws:glue:us-east-1:123456789012:userDefinedFunction/db1/func1`

Tipo de recurso	Formato de ARN
Connection	`arn:aws:glue:` *`region`*`:`*`account-id`* `:connection/` *`connection name`* Por ejemplo: .: `arn:aws:glue:us-east-1:123456789012:connection/connection1`
Sesiones interactivas	`arn:aws:glue:` *`region`*`:`*`account-id`* `:session/` *`interactive session id`* Por ejemplo: .: `arn:aws:glue:us-east-1:123456789012:session/a1b2c3d4-5678-90ab-cdef-EXAMPLE11111`

Para habilitar el control de acceso detallado, puede utilizar estos ARN en sus políticas de IAM y las políticas de recursos para conceder y denegar el acceso a recursos específicos. Los comodines están permitidos en las políticas. Por ejemplo, el siguiente ARN coincide con todas las tablas de la base de datos `default`.

```
arn:aws:glue:us-east-1:123456789012:table/default/*
```

Important

Todas las operaciones realizadas en un recurso de Data Catalog requieren permiso en el recurso y todos los antecesores de dicho recurso. Por ejemplo, para crear una partición de una tabla se requiere el permiso en la tabla, la base de datos y el catálogo donde se encuentra la tabla. El siguiente ejemplo muestra el permiso necesario para crear particiones en la tabla `PrivateTable` en la base de datos `PrivateDatabase` de Data Catalog.

```
{
   "Sid": "GrantCreatePartitions",
   "Effect": "Allow",
   "Action": [
       "glue:BatchCreatePartitions"
   ],
   "Resource": [
       "arn:aws:glue:us-east-1:123456789012:table/PrivateDatabase/PrivateTable",
       "arn:aws:glue:us-east-1:123456789012:database/PrivateDatabase",
       "arn:aws:glue:us-east-1:123456789012:catalog"
```

```
    ]
}
```

Además de permiso en el recurso y todos sus antecesores, todas las operaciones de eliminación requieren permiso en todos los elementos secundarios de dicho recurso. Por ejemplo, para eliminar una base de datos, se requiere permiso en todas las tablas y funciones definidas por el usuario en la base de datos, así como en la base de datos y el catálogo donde se encuentra la base de datos. El siguiente ejemplo muestra el permiso necesario para eliminar la base de datos `PrivateDatabase` del Data Catalog.

```
{
   "Sid": "GrantDeleteDatabase",
   "Effect": "Allow",
   "Action": [
       "glue:DeleteDatabase"
   ],
   "Resource": [
       "arn:aws:glue:us-east-1:123456789012:table/PrivateDatabase/*",
       "arn:aws:glue:us-east-1:123456789012:userDefinedFunction/PrivateDatabase/
*",
       "arn:aws:glue:us-east-1:123456789012:database/PrivateDatabase",
       "arn:aws:glue:us-east-1:123456789012:catalog"
   ]
}
```

En resumen, las acciones en los recursos de Data Catalog siguen estas reglas de permisos:

- Las acciones en el catálogo requieren permiso solo en el catálogo.
- Las acciones en una base de datos requieren permiso en la base de datos y el catálogo.
- Eliminar acciones en una base de datos requiere permiso en la base de datos y el catálogo, además de todas las tablas y funciones definidas por el usuario en la base de datos.
- Las acciones en una tabla, partición o versión de tabla requieren el permiso en la tabla, base de datos y catálogo.
- Las acciones en una función definida por el usuario requieren el permiso en la función definida por el usuario, la base de datos y el catálogo.
- Las acciones en una conexión requieren permiso en la conexión y el catálogo.

ARN para objetos que no están en el catálogo en AWS Glue

Algunos recursos de AWS Glue permiten permisos de nivel de recursos para controlar el acceso mediante un ARN. Puede utilizar estos ARN en sus políticas de IAM para habilitar el control de acceso detallado. En la siguiente tabla se enumeran los recursos que puede contener ARN de recursos.

Tipo de recurso	Formato de ARN
Rastreador	`arn:aws:glue:` *`region`*`:`*`account-id`* `:crawler/` *`crawler-name`* Por ejemplo: .: `arn:aws:glue:us-east-1:123456789012:crawler/mycrawler`
Trabajo	`arn:aws:glue:` *`region`*`:`*`account-id`* `:job/`*`job-name`* Por ejemplo: .: `arn:aws:glue:us-east-1:123456789012:job/testjob`
Desencadenador	`arn:aws:glue:` *`region`*`:`*`account-id`* `:trigger/` *`trigger-name`* Por ejemplo: .: `arn:aws:glue:us-east-1:123456789012:trigger/sampletrigger`
Punto de enlace de desarrollo	`arn:aws:glue:` *`region`*`:`*`account-id`* `:devEndpoint/` *`development-endpoint-name`* Por ejemplo: .: `arn:aws:glue:us-east-1:123456789012:devEndpoint/temporarydevendpoint`
Transformación de machine learning	`arn:aws:glue:` *`region`*`:`*`account-id`* `:mlTransform/` *`transform-id`* Por ejemplo: .: `arn:aws:glue:us-east-1:123456789012:mlTransform/tfm-1234567890`

Control de acceso para operaciones API singulares que no estén en el catálogo de AWS Glue

Las operaciones de API singulares que no estén en el catálogo de AWS Glue actúan sobre un solo elemento (punto de conexión de desarrollo). Algunos ejemplos son `GetDevEndpoint`, `CreateUpdateDevEndpoint` y `UpdateDevEndpoint`. Para estas operaciones, una política debe poner el nombre de la API en el bloque `"action"` y el ARN del recurso en el bloque `"resource"`.

Supongamos que desea permitir a un usuario llamar a la operación `GetDevEndpoint`. La siguiente política concede los permisos mínimos necesarios a un punto de enlace llamado `myDevEndpoint-1`.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Sid": "MinimumPermissions",
      "Effect": "Allow",
      "Action": "glue:GetDevEndpoint",
      "Resource": "arn:aws:glue:us-east-1:111122223333:devEndpoint/
myDevEndpoint-1"
    }
  ]
}
```

La siguiente política permite a `UpdateDevEndpoint` el acceso a los recursos que coinciden con `myDevEndpoint-` con un asterisco (*).

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Sid": "PermissionWithWildcard",
      "Effect": "Allow",
      "Action": "glue:UpdateDevEndpoint",
```

```
      "Resource": "arn:aws:glue:us-east-1:111122223333:devEndpoint/myDevEndpoint-
*"
    }
  ]
}
```

Puede combinar los dos políticas tal y como se muestra en el siguiente ejemplo. Puede que vea `EntityNotFoundException` para cualquier punto de enlace de desarrollo cuyo nombre empiece por `A`. Sin embargo, se devuelve un error de acceso denegado cuando intenta acceder a otros puntos de enlace de desarrollo.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Sid": "CombinedPermissions",
      "Effect": "Allow",
      "Action": [
        "glue:UpdateDevEndpoint",
        "glue:GetDevEndpoint"
      ],
      "Resource": "arn:aws:glue:us-east-1:111122223333:devEndpoint/A*"
    }
  ]
}
```

Control de acceso para operaciones API que no están en el catálogo de AWS Glue que recuperan varios elementos

Algunas operaciones API de AWS Glue recupera varios elementos (como varios puntos de enlace de desarrollo); por ejemplo, `GetDevEndpoints`. Para esta operación, solo puede especificar un recurso de asterisco (*) y no ARN específicos.

Por ejemplo, para incluir `GetDevEndpoints` en la política, el ámbito del recurso debe establecer en el carácter comodín (*). Las operaciones singulares (`GetDevEndpoint`, `CreateDevEndpoint` y `DeleteDevendpoint`) también se asignan a todos los recursos (*) en el ejemplo.

```
{
            "Sid": "PluralAPIIncluded",
            "Effect": "Allow",
            "Action": [
                "glue:GetDevEndpoints",
                "glue:GetDevEndpoint",
                "glue:CreateDevEndpoint",
                "glue:UpdateDevEndpoint"
            ],
            "Resource": [
                "*"
            ]
}
```

Control de acceso para operaciones de API BatchGet que no están en el catálogo de AWS Glue

Algunas operaciones API de AWS Glue recupera varios elementos (como varios puntos de enlace de desarrollo); por ejemplo, `BatchGetDevEndpoints`. En esta operación, puede especificar un ARN para limitar el ámbito de los recursos a los que se puede obtener acceso.

Por ejemplo, para permitir el acceso a un punto de enlace de desarrollo específico, incluya `BatchGetDevEndpoints` en la política con el ARN del recurso.

```
{
            "Sid": "BatchGetAPIIncluded",
            "Effect": "Allow",
            "Action": [
                "glue:BatchGetDevEndpoints"
            ],
            "Resource": [
                "arn:aws:glue:us-east-1:123456789012:devEndpoint/de1"
            ]
}
```

Con esta política, puede obtener acceso correctamente al punto de enlace de desarrollo llamado `de1`. Sin embargo, si intenta obtener acceso al punto de enlace de desarrollo llamado `de2`, se devolverá un error.

```
An error occurred (AccessDeniedException) when calling the BatchGetDevEndpoints
 operation: No access to any requested resource.
```

> **Important**
>
> Si desea conocer otros enfoques alternativos para configurar las políticas de IAM, como el uso de las operaciones API `List` y `BatchGet`, consulte Ejemplos de políticas basadas en identidades para AWS Glue.

Concesión de acceso entre cuentas

Al conceder acceso a recursos de Data Catalog entre cuentas, los trabajos de extracción, transformación y carga (ETL) pueden consultar y combinar datos de diferentes cuentas.

Temas

- Métodos para conceder acceso entre cuentas en AWS Glue
- Agregar o actualizar la política de recursos de Data Catalog
- Realización de una llamada a la API entre cuentas
- Realización de una llamada a ETL entre cuentas
- Registro entre cuentas de CloudTrail
- Propiedad de recursos entre cuentas y facturación
- Limitaciones de acceso entre cuentas

Métodos para conceder acceso entre cuentas en AWS Glue

Puede conceder acceso a sus datos a cuentas de AWS externas mediante los métodos de AWS Glue o mediante el uso de concesiones entre cuentas de AWS Lake Formation. Los métodos de AWS Glue utilizan políticas de AWS Identity and Access Management (IAM) para lograr un control preciso de acceso. Lake Formation utiliza un modelo de permisos `GRANT/REVOKE` similares a los comandos de `GRANT/REVOKE` en un sistema de base de datos relacional.

En esta sección, se describe el uso de los métodos de AWS Glue. Para obtener más información sobre cómo utilizar concesiones entre cuentas de Lake Formation, consulte Concesión de permisos de Lake Formation en la Guía para desarrolladores de AWS Lake Formation.

Hay dos métodos de AWS Glue para conceder acceso entre cuentas a un recurso:

- Uso de una política de recursos de Data Catalog
- Uso de un rol de IAM

Concesión de acceso entre cuentas con una política de recursos

Los siguientes son los pasos generales para conceder acceso entre cuentas mediante una política de recursos de Data Catalog:

1. Un administrador (u otra identidad autorizada) en la cuenta A asocia una política de recursos a Data Catalog en la cuenta A. Esta política concede a la cuenta B permisos específicos entre cuentas para realizar operaciones en un recurso en el catálogo de la cuenta A.
2. Un administrador de la cuenta B asocia una política de IAM a una identidad de IAM en la cuenta B que delega los permisos recibidos de la cuenta A.

   La identidad de la cuenta B ahora tiene acceso al recurso especificado en la cuenta A.

   La identidad necesita permiso de ambos, el propietario de los recursos (cuenta A) y su cuenta principal (cuenta B), para poder obtener acceso al recurso.

Conceder acceso entre cuentas mediante un rol de IAM

Los siguientes son los pasos generales para conceder acceso entre cuentas mediante un rol de IAM:

1. Un administrador (u otra identidad autorizada) en la cuenta que posee el recurso (cuenta A) crea un rol de IAM.
2. El administrador de la cuenta A asocia una política al rol que concede permisos entre cuentas para acceder al recurso en cuestión.
3. El administrador de la cuenta A asocia al rol una política de confianza que identifica una identidad de IAM en una cuenta diferente (cuenta B) como la entidad principal que puede asumir el rol.

   La entidad principal de la política de confianza también puede ser una entidad principal de un servicio de AWS, si desea conceder permisos a un servicio de AWS para que asuma el rol.
4. Un administrador de la cuenta B ahora delega los permisos a una o varias identidades de IAM de la cuenta B para que puedan asumir ese rol. De esta forma, ofrece a las identidades de la cuenta B acceso al recurso de la cuenta A.

Para obtener más información sobre el uso de IAM para delegar permisos, consulte Access management (Administración de accesos) en la Guía del usuario de IAM. Para obtener más información acerca de los usuarios, los grupos, los roles y los permisos, consulte Identidades (usuarios, grupos y roles) en la Guía del usuario de IAM.

Si desea obtener una comparación de estos dos enfoques, consulte Cómo los roles de IAM difieren de las políticas basadas en recursos en la Guía del usuario de IAM. AWS Glue es compatible con ambas opciones, con la restricción de que una política de recursos puede conceder acceso únicamente a los recursos de Catálogo de datos.

Por ejemplo, para conceder al rol `Dev` de la cuenta B acceso a la base de datos `db1` en la cuenta A, asocie la siguiente política de recursos al catálogo de la cuenta A.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:GetDatabase"
      ],
      "Principal": {
        "AWS": [
          "arn:aws:iam::111122223333:role/Dev"
        ]
      },
      "Resource": [
        "arn:aws:glue:us-east-1:111122223333:catalog",
        "arn:aws:glue:us-east-1:111122223333:database/db1"
      ]
    }
  ]
}
```

Además, la cuenta B tendría que asociar la siguiente política de IAM al rol `Dev` para obtener acceso a db1 en la cuenta A.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:GetDatabase"
      ],
      "Resource": [
        "arn:aws:glue:us-east-1:111122223333:catalog",
        "arn:aws:glue:us-east-1:111122223333:database/db1"
      ]
    }
  ]
}
```

Agregar o actualizar la política de recursos de Data Catalog

Puede agregar o actualizar la política de recursos de Data Catalog de AWS Glue mediante la consola, la API o AWS Command Line Interface (AWS CLI).

> **Important**
>
> Si ya ha otorgado permisos entre cuentas desde su cuenta con AWS Lake Formation, agregar o actualizar la política de recursos de Data Catalog requiere un paso adicional. Para obtener más información, consulte Administrar los permisos entre cuentas utilizando AWS Glue y Lake Formation en la Guía para desarrolladores de AWS Lake Formation.
> Para determinar si existen concesiones entre cuentas de Lake Formation, utilice la operación de API `glue:GetResourcePolicies` o la AWS CLI. Si `glue:GetResourcePolicies` devuelve una política que no sea de Catálogo de datos, se cuenta con concesiones de Lake Formation. Para obtener más información, consulte Visualización de todas las concesiones entre cuentas mediante la operación de API GetResourcePolicies en la Guía para desarrolladores de AWS Lake Formation.

Agregar o actualizar la política de recursos de Data Catalog (consola)

1. Abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.

   Inicie sesión como usuario administrativo de AWS Identity and Access Management (IAM) con permiso `glue:PutResourcePolicy`.
2. En el panel de navegación, seleccione Configuración.
3. En la página Data catalog settings (Configuración de Data Catalog), en Permissions (Permisos), pegue una política de recursos en el área de texto. A continuación, elija Guardar.

   Si la consola muestra una alerta que indica que los permisos de la política se agregarán a los permisos concedidos mediante Lake Formation, elija Proceed (Proceder).

Agregar o actualizar la política de recursos de Data Catalog (AWS CLI)

- Envíe un comando `aws glue put-resource-policy`. Si ya existen concesiones de Lake Formation, asegúrese de incluir la opción `--enable-hybrid` con el valor `'TRUE'`.

  Para obtener ejemplos de uso de este comando, consulte Ejemplos de políticas basadas en recursos para AWS Glue.

Realización de una llamada a la API entre cuentas

Todas las operaciones de AWS Glue Data Catalog tienen un campo `CatalogId`. Si se han concedido los permisos necesarios para permitir el acceso entre cuentas, un intermediario puede realizar llamadas a la API de Data Catalog entre cuentas. El intermediario realiza este procedimiento pasando el ID de cuenta de AWS de destino en `CatalogId` de manera que acceda al recurso en esa cuenta de destino.

Si no se proporciona ningún valor `CatalogId`, AWS Glue utiliza el propio ID de cuenta del intermediario de forma predeterminada y la llamada no será entre cuentas.

Realización de una llamada a ETL entre cuentas

Algunas API de AWS Glue PySpark y Scala tienen un campo de ID de catálogo. Si se han concedido todos los permisos necesarios para habilitar el acceso entre cuentas, un trabajo de ETL puede realizar llamadas de PySpark y Scala a las operaciones de la API entre cuentas, mediante la transferencia del ID de la cuenta de AWS de destino en el campo de ID de catálogo, con el fin de obtener acceso a los recursos de Data Catalog de una cuenta de destino.

Si no se proporciona ningún valor de ID de catálogo, AWS Glue utiliza el propio ID de cuenta del intermediario de forma predeterminada y la llamada no será entre cuentas.

Para API de PySpark que admiten `catalog_id`, consulte Clase GlueContext. Para API de Scala que admiten `catalogId`, consulte API GlueContext Scala de AWS Glue.

El siguiente ejemplo muestra los permisos que requiere al beneficiario para ejecutar un trabajo de ETL. En este ejemplo, *`grantee-account-id`* es el `catalog-id` del cliente que ejecuta el trabajo y *`grantor-account-id`* es el propietario del recurso. En este ejemplo se concede permiso a todos los recursos de catálogo de la cuenta del concedente. Para limitar el alcance de recursos concedidos, puede proporcionar ARN específicas para el catálogo, la base de datos, la tabla y la conexión.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:GetConnection",
        "glue:GetDatabase",
        "glue:GetTable",
        "glue:GetPartition"
      ],
      "Principal": {
        "AWS": [
          "arn:aws:iam::111122223333:root"
        ]
      },
      "Resource": [
        "arn:aws:glue:us-east-1:111122223333:*"
      ]
    }
  ]
}
```

> **Note**
>
> Si una tabla de la cuenta del concedente apunta a una ubicación de Amazon S3, es decir, también en la cuenta del concedente, el rol de IAM que se utiliza para ejecutar un trabajo de ETL en la cuenta del beneficiario debe tener permiso para enumerar y obtener los objetos de la cuenta del concedente.

Dado que el cliente de la cuenta A ya tiene permiso para crear y ejecutar trabajos de ETL, a continuación se muestran los pasos básicos para configurar un trabajo de ETL para el acceso entre cuentas:

1. Permita el acceso a los datos entre cuentas (omitir este paso si el acceso entre cuentas de Amazon S3 ya está configurado).
   a. Actualice la política de bucket de Amazon S3 en la cuenta B para permitir el acceso entre cuentas desde la cuenta A.
   b. Actualizar la política de IAM de la cuenta A para permitir el acceso al bucket en la cuenta B.
2. Permita acceso entre cuentas al Data Catalog.
   a. Cree o actualice la política de recursos asociada al Data Catalog en la cuenta B para permitir el acceso desde la cuenta A.
   b. Actualice la política de IAM de la cuenta A para permitir el acceso a Data Catalog en la cuenta B.

Registro entre cuentas de CloudTrail

Cuando un trabajo del servicio ETL (extracción, transformación y carga) de AWS Glue tiene acceso a los datos subyacentes de una tabla de Data Catalog compartida mediante concesiones entre cuentas de AWS Lake Formation, existe una conducta de registro adicional de AWS CloudTrail.

A los efectos de este análisis, la cuenta de AWS que compartió la tabla es la cuenta del propietario y la cuenta con la que se compartió la tabla es la cuenta del destinatario. Cuando un trabajo de ETL en la cuenta del destinatario accede a los datos en la tabla de la cuenta del propietario, el evento CloudTrail de acceso a datos que se agrega a los registros de la cuenta del destinatario se copia en los registros de CloudTrail de la cuenta del propietario. Esto es para que las cuentas del propietario puedan realizar un seguimiento de los accesos a datos de las distintas cuentas de destinatarios.

De forma predeterminada, los eventos de CloudTrail no incluyen un identificador principal inteligible (ARN principal). Un administrador en la cuenta del destinatario puede optar por incluir el ARN principal en los registros.

Para obtener más información, consulte Registro entre cuentas de CloudTrail en la Guía para desarrolladores de AWS Lake Formation.

Véase también

- the section called “Registro y monitoreo”

Propiedad de recursos entre cuentas y facturación

Cuando un usuario de una cuenta de AWS (cuenta A) crea un nuevo recurso como una base de datos en una cuenta diferente (cuenta B), dicho recurso pertenece a la cuenta B, la cuenta en la que se creó. Un administrador de la cuenta B obtiene automáticamente permisos completos para obtener acceso al nuevo recurso, como leer, escribir y conceder permisos de acceso a una tercera cuenta. El usuario de la cuenta A puede obtener acceso al recurso que acaba de crear solo si tienen los permisos adecuados concedidos por la cuenta B.

Los costos de almacenamiento y otros costos que guardan relación directa con el nuevo recurso se facturan a la cuenta B, el propietario de los recursos. El costo de las solicitudes de ese usuario que creó el recurso se factura a la cuenta del solicitante, la cuenta A.

Para obtener más información acerca de la facturación y los precios de AWS Glue, consulte Cómo funcionan los precios de AWS.

Limitaciones de acceso entre cuentas

AWS GlueEl acceso entre cuentas de tiene las siguientes limitaciones:

- No se permite el acceso entre cuentas a AWS Glue si ha creado bases de datos y tablas con Amazon Athena o Amazon Redshift Spectrum antes de tener la compatibilidad de una región con AWS Glue y la cuenta del propietario de los recursos no ha migrado el catálogo de datos de Amazon Athena a AWS Glue. Puede encontrar el estado de migración actual utilizando GetCatalogImportStatus (get_catalog_import_status). Para obtener más información sobre cómo migrar un catálogo de Athena a AWS Glue, consulte Actualización a AWS Glue Data Catalog paso a paso en la Guía del usuario de Amazon Athena.

- El acceso entre cuentas solo se soporta para los recursos de Data Catalog, como bases de datos, tablas, funciones definidas por el usuario y conexiones.
- El acceso entre cuentas a Data Catalog de Athena exige que registre el catálogo como un recurso `DataCatalog` de Athena. Para obtener instrucciones, consulte Registro de un AWS Glue Data Catalog desde otra cuenta en la Guía del usuario de Amazon Athena.

Solución de problemas de identidad y acceso en AWS Glue

Utilice la siguiente información para diagnosticar y solucionar los problemas comunes que podrían surgir cuando trabaje con AWS Glue e IAM.

Temas

- No tengo autorización para realizar una acción en AWS Glue
- No tengo autorización para realizar la operación iam:PassRole
- Quiero permitir que personas externas a mi Cuenta de AWS puedan acceder a mis recursos de AWS Glue

No tengo autorización para realizar una acción en AWS Glue

Si recibe un error que indica que no tiene autorización para realizar una acción, las políticas se deben actualizar para permitirle realizar la acción.

En el siguiente ejemplo, el error se produce cuando el usuario de IAM `mateojackson` intenta utilizar la consola para consultar los detalles acerca de un recurso ficticio *`my-example-widget`*, pero no tiene los permisos ficticios `glue:`*`GetWidget`*.

```
User: arn:aws:iam::123456789012:user/mateojackson is not authorized to perform:
 glue:GetWidget on resource: my-example-widget
```

En este caso, la política del usuario `mateojackson` debe actualizarse para permitir el acceso al recurso *`my-example-widget`* mediante la acción `glue:`*`GetWidget`*.

Si necesita ayuda, póngase en contacto con su gestionador de AWS. El gestionador es la persona que le proporcionó las credenciales de inicio de sesión.

No tengo autorización para realizar la operación iam:PassRole

Si recibe un error que indica que no tiene autorización para realizar la acción `iam:PassRole`, las políticas deben actualizarse para que pueda transmitir un rol a AWS Glue.

Algunos Servicios de AWS le permiten transferir un rol existente a dicho servicio en lugar de crear un nuevo rol de servicio o uno vinculado al servicio. Para ello, debe tener permisos para transferir el rol al servicio.

En el siguiente ejemplo, el error se produce cuando un usuario de IAM denominado `marymajor` intenta utilizar la consola para realizar una acción en AWS Glue. Sin embargo, la acción requiere que el servicio cuente con permisos que otorguen un rol de servicio. Mary no tiene permisos para transferir el rol al servicio.

```
User: arn:aws:iam::123456789012:user/marymajor is not authorized to perform:
 iam:PassRole
```

En este caso, las políticas de Mary se deben actualizar para permitirle realizar la acción `iam:PassRole`.

Si necesita ayuda, póngase en contacto con su gestionador de AWS. El gestionador es la persona que le proporcionó las credenciales de inicio de sesión.

Quiero permitir que personas externas a mi Cuenta de AWS puedan acceder a mis recursos de AWS Glue

Puede crear un rol que los usuarios de otras cuentas o las personas externas a la organización puedan utilizar para acceder a sus recursos. Puede especificar una persona de confianza para que asuma el rol. En el caso de los servicios que admitan las políticas basadas en recursos o las listas de control de acceso (ACL), puede utilizar dichas políticas para conceder a las personas acceso a sus recursos.

Para obtener más información, consulte lo siguiente:

- Para averiguar si AWS Glue admite estas características, consulte Funcionamiento de AWS Glue con IAM.
- Para obtener información acerca de cómo proporcionar acceso a los recursos de las Cuenta de AWS de su propiedad, consulte Proporcionar acceso a un usuario de IAM a otra Cuentas de AWS de la que es propietario en la Guía del usuario de IAM.

- Para obtener información acerca de cómo proporcionar acceso a tus recursos a Cuentas de AWS de terceros, consulta Proporcionar acceso a Cuentas de AWS que son propiedad de terceros en la Guía del usuario de IAM.
- Para obtener información sobre cómo proporcionar acceso mediante una federación de identidades, consulta Proporcionar acceso a usuarios autenticados externamente (identidad federada) en la Guía del usuario de IAM.
- Para conocer sobre la diferencia entre las políticas basadas en roles y en recursos para el acceso entre cuentas, consulte Acceso a recursos entre cuentas en IAM en la Guía del usuario de IAM.

Modelos de control de acceso de AWS Lake Formation

AWS Glue 5.0 admite dos modelos para acceder a los datos a través de AWS Lake Formation:

Temas

- Uso de AWS Glue con AWS Lake Formation para acceso completo a la tabla
- Uso de AWS Glue con AWS Lake Formation para obtener un control de acceso detallado

Uso de AWS Glue con AWS Lake Formation para acceso completo a la tabla

Introducción al acceso completo a la tabla

AWS Glue 5.0 admite el control de acceso completo a la tabla (FTA) en Apache Spark según las políticas definidas en AWS Lake Formation. Esta característica permite realizar operaciones de lectura y escritura desde los trabajos de Spark en AWS Glue sobre tablas registradas en AWS Lake Formation, siempre que el rol del trabajo tenga acceso completo a la tabla. FTA es ideal para casos de uso que deben cumplir con normativas de seguridad a nivel de tabla y es compatible con las capacidades de Spark, incluidos los conjuntos de datos distribuidos resilientes (RDD), bibliotecas personalizadas y funciones definidas por el usuario (UDF) sobre tablas de AWS Lake Formation.

Cuando un trabajo de Spark en AWS Glue se configura para acceso completo a la tabla (FTA), se utilizan las credenciales de AWS Lake Formation para leer o escribir datos en Amazon S3 correspondientes a tablas registradas en AWS Lake Formation, mientras que se emplean las credenciales del rol de tiempo de ejecución del trabajo para acceder a tablas no registradas en AWS Lake Formation. Esta funcionalidad permite realizar operaciones del lenguaje de manipulación de

datos (DML), como CREAR, MODIFICAR, ELIMINAR, ACTUALIZAR e INSERTAR CON FUSIÓN, sobre tablas de Apache Hive y Iceberg.

> **Note**
>
> Revise sus requisitos y determine si el control de acceso detallado (FGAC) o el acceso completo a las tablas (FTA) se ajusta mejor a sus necesidades. Solo se puede habilitar un método de permisos de AWS Lake Formation para un trabajo de AWS Glue dado. Un trabajo no puede utilizar simultáneamente el acceso completo a las tablas (FTA) y el control de acceso detallado (FGAC).

Cómo funciona el acceso completo a la tabla (FTA) en AWS Glue

AWS Lake Formation ofrece dos enfoques para controlar el acceso a los datos: el control de acceso detallado (FGAC) y el acceso completo a la tabla (FTA). FGAC proporciona seguridad avanzada mediante filtrado a nivel de columna, fila y celda, lo que lo convierte en la opción ideal para escenarios que requieren permisos detallados. FTA resulta ideal en escenarios simples de control de acceso que requieren permisos a nivel de tabla. Facilita la implementación al no requerir la habilitación del modo de acceso detallado, mejora el rendimiento y reduce los costos al prescindir del controlador y los ejecutores del sistema, y permite tanto operaciones de lectura como de escritura (incluidos los comandos CREAR, MODIFICAR, ELIMINAR, ACTUALIZAR e INSERTAR CON FUSIÓN).

En AWS Glue 4.0, el acceso a datos basado en AWS Lake Formation funcionaba a través de la clase GlueContext, la clase utilitaria proporcionada por AWS Glue. En AWS Glue 5.0, el acceso a datos basado en AWS Lake Formation se ofrece de forma nativa mediante Spark SQL y Spark DataFrames, y también se admite a través de la clase GlueContext.

Implementación del acceso completo a la tabla

Paso 1: habilitación del acceso completo a la tabla en AWS Lake Formation

Para utilizar el modo de acceso completo a la tabla (FTA), debe permitir que motores de consulta de terceros accedan a los datos sin la validación de etiquetas de sesión de IAM en AWS Lake Formation. Para habilitarlo, siga los pasos descritos en Integración de aplicaciones para acceso completo a la tabla .

Paso 2: configuración de los permisos de IAM para el rol en tiempo de ejecución del trabajo

Para acceder a los datos subyacentes, ya sea para lectura o escritura, además de los permisos de AWS Lake Formation, el rol en tiempo de ejecución del trabajo necesita el permiso de IAM `lakeformation:GetDataAccess`. Con este permiso, AWS Lake Formation concede la solicitud de credenciales temporales para acceder a los datos.

A continuación se muestra un ejemplo de política para otorgar permisos de IAM que permiten acceder a un script en Amazon S3, cargar registros en Amazon S3, utilizar las API de AWS Glue y acceder a AWS Lake Formation.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Sid": "ScriptAccess",
      "Effect": "Allow",
      "Action": [
        "s3:GetObject"
      ],
      "Resource": [
        "arn:aws:s3:::amzn-s3-demo-bucket/scripts/*"
      ]
    },
    {
      "Sid": "LoggingAccess",
      "Effect": "Allow",
      "Action": [
        "s3:PutObject"
      ],
      "Resource": [
        "arn:aws:s3:::amzn-s3-demo-bucket/logs/*"
      ]
    },
    {
      "Sid": "GlueCatalogAccess",
      "Effect": "Allow",
      "Action": [
        "glue:GetDatabase",
        "glue:GetDatabases",
```

```
        "glue:GetTable",
        "glue:GetTables",
        "glue:GetPartition",
        "glue:GetPartitions",
        "glue:CreateTable",
        "glue:UpdateTable"
      ],
      "Resource": [
        "arn:aws:glue:us-east-1:111122223333:catalog",
        "arn:aws:glue:us-east-1:111122223333:database/default",
        "arn:aws:glue:us-east-1:111122223333:table/default/*"
      ]
    },
    {
      "Sid": "LakeFormationAccess",
      "Effect": "Allow",
      "Action": [
        "lakeformation:GetDataAccess"
      ],
      "Resource": "*"
    }
  ]
}
```

Paso 2.1: configuración de los permisos de AWS Lake Formation

Los trabajos de AWS Glue Spark que leen datos desde Amazon S3 requieren el permiso SELECCIONAR de AWS Lake Formation.

Los trabajos de AWS Glue Spark que escriben o eliminan datos en Amazon S3 requieren el permiso TODOS de AWS Lake Formation.

Los trabajos de AWS Glue Spark que interactúan con el Catálogo de datos de AWS Glue requieren los permisos Describir, Modificar y Descartar, según corresponda.

Paso 3: inicialización de una sesión de Spark para el acceso completo a la tabla mediante AWS Lake Formation

Para acceder a tablas registradas en AWS Lake Formation, es necesario establecer las siguientes configuraciones durante la inicialización de Spark, con el fin de configurar Spark para que utilice credenciales de AWS Lake Formation.

Para acceder a tablas registradas en AWS Lake Formation, debe configurar explícitamente la sesión de Spark para que utilice credenciales de AWS Lake Formation. Agregue las siguientes configuraciones al inicializar la sesión de Spark:

```
from pyspark.sql import SparkSession

# Initialize Spark session with Lake Formation configurations
spark = SparkSession.builder \
    .appName("Lake Formation Full Table Access") \
    .config("spark.sql.catalog.glue_catalog",
 "org.apache.spark.sql.catalog.hive.GlueCatalog") \
    .config("spark.sql.catalog.glue_catalog.glue.lakeformation-enabled", "true") \
    .config("spark.sql.defaultCatalog", "glue_catalog") \
    .getOrCreate()
```

Configuraciones clave:

- `spark.sql.catalog.glue_catalog`: registra un catálogo llamado “glue_catalog” que utiliza la implementación GlueCatalog
- `spark.sql.catalog.glue_catalog.glue.lakeformation-enabled`: habilita explícitamente la integración con AWS Lake Formation para este catálogo
- El nombre del catálogo (por ejemplo, “glue_catalog”) se puede personalizar, pero se debe mantener coherente en ambas configuraciones

Hive

```
--conf spark.hadoop.fs.s3.credentialsResolverClass=com.amazonaws.AWS
 Glue.accesscontrol.AWSLakeFormationCredentialResolver
--conf spark.hadoop.fs.s3.useDirectoryHeaderAsFolderObject=true
--conf spark.hadoop.fs.s3.folderObject.autoAction.disabled=true
--conf spark.sql.catalog.skipLocationValidationOnCreateTable.enabled=true
--conf spark.sql.catalog.createDirectoryAfterTable.enabled=true
--conf spark.sql.catalog.dropDirectoryBeforeTable.enabled=true
```

Iceberg

```
--conf spark.hadoop.fs.s3.credentialsResolverClass=com.amazonaws.AWS
 Glue.accesscontrol.AWSLakeFormationCredentialResolver
--conf spark.hadoop.fs.s3.useDirectoryHeaderAsFolderObject=true
--conf spark.hadoop.fs.s3.folderObject.autoAction.disabled=true
--conf spark.sql.catalog.skipLocationValidationOnCreateTable.enabled=true
--conf spark.sql.catalog.createDirectoryAfterTable.enabled=true
--conf spark.sql.catalog.dropDirectoryBeforeTable.enabled=true
--conf spark.sql.catalog.<catalog>.AWS Glue.lakeformation-enabled=true
```

- `spark.hadoop.fs.s3.credentialsResolverClass=com.amazonaws.AWS Glue.accesscontrol.AWSLakeFormationCredentialResolver`: configure el sistema de archivos EMR (EMRFS) para que utilice las credenciales de S3 de AWS Lake Formation al acceder a tablas registradas en AWS Lake Formation. Si la tabla no está registrada, utilice las credenciales del rol en tiempo de ejecución del trabajo.
- `spark.hadoop.fs.s3.useDirectoryHeaderAsFolderObject=true` y `spark.hadoop.fs.s3.folderObject.autoAction.disabled=true`: configure EMRFS para que utilice el encabezado de tipo de contenido application/x-directory en lugar del sufijo $folder$ al crear carpetas en S3. Esto es necesario al leer tablas de AWS Lake Formation, ya que las credenciales de AWS Lake Formation no permiten leer carpetas de tablas que utilicen el sufijo $folder$.
- `spark.sql.catalog.skipLocationValidationOnCreateTable.enabled=true`: configure Spark para omitir la validación de que la ubicación de la tabla esté vacía antes de crearla. Esto es necesario para tablas registradas en AWS Lake Formation, ya que las credenciales de AWS Lake Formation para verificar que la ubicación esté vacía solo están disponibles después de crear la tabla en el Catálogo de datos de AWS Glue. Sin esta configuración, las credenciales del rol en tiempo de ejecución del trabajo validarán si la ubicación de la tabla está vacía.
- `spark.sql.catalog.createDirectoryAfterTable.enabled=true`: configure Spark para crear la carpeta en Amazon S3 después de crear la tabla en el repositorio de metadatos de Hive. Esto es necesario para tablas registradas en AWS Lake Formation, ya que las credenciales de AWS Lake Formation para crear la carpeta en Amazon S3 solo están disponibles después de crear la tabla en el Catálogo de datos de AWS Glue.
- `spark.sql.catalog.dropDirectoryBeforeTable.enabled=true`: configure Spark para descartar la carpeta en Amazon S3 antes de eliminar la tabla del repositorio de metadatos de Hive. Esto es necesario para tablas registradas en AWS Lake Formation, ya que las credenciales de

AWS Lake Formation para descartar la carpeta de S3 no están disponibles después de eliminar la tabla del Catálogo de datos de AWS Glue.

- `spark.sql.catalog.<catalog>.AWS Glue.lakeformation-enabled=true`: configure el catálogo de Iceberg para que utilice las credenciales de Amazon S3 de AWS Lake Formation al acceder a tablas registradas en AWS Lake Formation. Si la tabla no está registrada, utilice las credenciales predeterminadas del entorno.

Patrones de uso

Uso de FTA con DataFrames

Para quienes estén familiarizados con Spark, se pueden usar DataFrames con el acceso completo a tablas de AWS Lake Formation.

AWS Glue 5.0 incorpora compatibilidad nativa de Spark con el acceso completo a tablas de Lake Formation, lo que simplifica el trabajo con tablas protegidas. Esta función permite a los trabajos de Spark de AWS Glue 5.0 AWS Glue leer y escribir datos directamente cuando se concede el acceso completo a la tabla, eliminando las limitaciones que anteriormente restringían determinadas operaciones de extracción, transformación y carga (ETL). Ahora puede aprovechar las capacidades avanzadas de Spark, como los conjuntos de datos distribuidos resilientes (RDD), bibliotecas personalizadas y funciones definidas por el usuario (UDF), con tablas de AWS Lake Formation.

FTA con Spark nativo en AWS Glue 5.0

AWS Glue 5.0 admite el control de acceso completo a tablas (FTA) en Apache Spark, basado en las políticas definidas en AWS Lake Formation. Este nivel de control resulta ideal para casos de uso que deben cumplir con regulaciones de seguridad a nivel de tabla.

Ejemplo de tabla de Apache Iceberg

```
from pyspark.sql import SparkSession

catalog_name = "spark_catalog"
aws_region = "us-east-1"
aws_account_id = "123456789012"
warehouse_path = "s3://amzn-s3-demo-bucket/warehouse/"

spark = SparkSession.builder \
```

```
 .config("spark.sql.extensions","org.apache.iceberg.spark.extensions.IcebergSparkSessionExtensi
 \
    .config(f"spark.sql.catalog.{catalog_name}",
 "org.apache.iceberg.spark.SparkSessionCatalog") \
    .config(f"spark.sql.catalog.{catalog_name}.warehouse", f"{warehouse_path}") \
    .config(f"spark.sql.catalog.{catalog_name}.client.region",f"{aws_region}") \
    .config(f"spark.sql.catalog.{catalog_name}.glue.account-id",f"{aws_account_id}") \
    .config(f"spark.sql.catalog.{catalog_name}.glue.lakeformation-enabled","true") \
    .config(f"spark.sql.catalog.dropDirectoryBeforeTable.enabled", "true") \
    .config(f"spark.sql.catalog.{catalog_name}.catalog-impl",
 "org.apache.iceberg.aws.glue.GlueCatalog") \
    .config(f"spark.sql.catalog.{catalog_name}.io-impl",
 "org.apache.iceberg.aws.s3.S3FileIO") \
    .config("spark.sql.defaultCatalog", catalog_name) \  # Add this line
    .getOrCreate()

database_name = "your_database"
table_name = "your_table"

df = spark.sql(f"select * from {database_name}.{table_name}")
df.show()
```

Permisos de IAM necesarios

El rol de ejecución del trabajo de AWS Glue debe contar con:

```
{
    "Action": "lakeformation:GetDataAccess",
    "Resource": "*",
    "Effect": "Allow"
}
```

Además, debe incluir los permisos apropiados de acceso a S3 para las ubicaciones de los datos.

Configuración de Lake Formation

Antes de usar FTA con Spark nativo en AWS Glue 5.0:

1. Permita que los motores de consulta de terceros accedan a los datos sin validación de etiquetas de sesión IAM en AWS Lake Formation.
2. Conceda los permisos adecuados sobre las tablas al rol de ejecución de trabajos de AWS Glue mediante la consola de AWS Lake Formation.

3. Configure la sesión de Spark con los parámetros requeridos que se muestran en el ejemplo anterior

Uso de FTA con DynamicFrames

Los DynamicFrames nativos de AWS Glue se pueden usar con FTA de AWS Lake Formation para optimizar las operaciones de ETL. El acceso completo a tablas (FTA) ofrece un modelo de seguridad que otorga permisos a nivel de tabla, lo que permite procesar datos más rápidamente en comparación con el control de acceso detallado (FGAC), ya que evita la sobrecarga de las verificaciones de permisos a nivel de fila y columna. Este enfoque resulta útil cuando necesita procesar tablas completas y los permisos a nivel de tabla cumplen con los requisitos de seguridad.

En AWS Glue 4.0, el uso de DynamicFrames con FTA requería una configuración específica de GlueContext. Aunque el código existente de DynamicFrame con FTA en AWS Glue 4.0 seguirá funcionando en AWS Glue 5.0, la nueva versión también ofrece compatibilidad con FTA de forma nativa en Spark, lo que brinda mayor flexibilidad. Para nuevos desarrollos, considere usar el enfoque nativo de Spark descrito en la sección de DataFrames, especialmente si necesita capacidades adicionales como conjuntos de datos distribuidos resilientes (RDD), bibliotecas personalizadas y funciones definidas por el usuario (UDF) con tablas de AWS Lake Formation.

Permisos necesarios

El rol de IAM que ejecuta el trabajo de Glue debe contar con lo siguiente:

- `lakeformation:GetDataAccess`Permiso
- Permisos adecuados sobre las tablas de Lake Formation, concedidos a través de la consola de Lake Formation

Ejemplo de implementación con DynamicFrame en AWS Glue 5.0

```
from awsglue.context import GlueContext
from pyspark.context import SparkContext

# Initialize Glue context
sc = SparkContext()
glueContext = GlueContext(sc)

# Configure catalog for Iceberg tables
catalog_name = "glue_catalog"
```

```
aws_region = "us-east-1"
aws_account_id = "123456789012"
warehouse_path = "s3://amzn-s3-demo-bucket/warehouse/"

spark = glueContext.spark_session
spark.conf.set(f"spark.sql.catalog.{catalog_name}",
 "org.apache.iceberg.spark.SparkCatalog")
spark.conf.set(f"spark.sql.catalog.{catalog_name}.warehouse", f"{warehouse_path}")
spark.conf.set(f"spark.sql.catalog.{catalog_name}.catalog-impl",
 "org.apache.iceberg.aws.glue.GlueCatalog")
spark.conf.set(f"spark.sql.catalog.{catalog_name}.io-impl",
 "org.apache.iceberg.aws.s3.S3FileIO")
spark.conf.set(f"spark.sql.catalog.{catalog_name}.glue.lakeformation-enabled","true")
spark.conf.set(f"spark.sql.catalog.{catalog_name}.client.region",f"{aws_region}")
spark.conf.set(f"spark.sql.catalog.{catalog_name}.glue.id", f"{aws_account_id}")

# Read Lake Formation-protected table with DynamicFrame
df = glueContext.create_data_frame.from_catalog(
    database="your_database",
    table_name="your_table"
)
```

Configuración adicional

Configuración del modo de acceso completo a tablas en blocs de notas de AWS Glue Studio

Para acceder a tablas registradas en AWS Lake Formation desde sesiones interactivas de Spark en blocs de notas de AWS Glue Studio, debe usar el modo de permisos de compatibilidad. Use el comando mágico `%%configure` para configurar Spark antes de iniciar la sesión interactiva. Esta configuración debe ser el primer comando en el bloc de notas, ya que no se podrá aplicar una vez iniciada la sesión. Elija la configuración según el tipo de tabla:

Para tablas de Hive

```
%%configure
--conf
 spark.hadoop.fs.s3.credentialsResolverClass=com.amazonaws.glue.accesscontrol.AWSLakeFormationC
--conf spark.hadoop.fs.s3.useDirectoryHeaderAsFolderObject=true
--conf spark.hadoop.fs.s3.folderObject.autoAction.disabled=true
--conf spark.sql.catalog.skipLocationValidationOnCreateTable.enabled=true
--conf spark.sql.catalog.createDirectoryAfterTable.enabled=true
--conf spark.sql.catalog.dropDirectoryBeforeTable.enabled=true
```

Para tablas de Iceberg

```
%%configure
--conf
 spark.hadoop.fs.s3.credentialsResolverClass=com.amazonaws.glue.accesscontrol.AWSLakeFormationC
--conf spark.hadoop.fs.s3.useDirectoryHeaderAsFolderObject=true
--conf spark.hadoop.fs.s3.folderObject.autoAction.disabled=true
--conf spark.sql.catalog.skipLocationValidationOnCreateTable.enabled=true
--conf spark.sql.catalog.createDirectoryAfterTable.enabled=true
--conf spark.sql.catalog.dropDirectoryBeforeTable.enabled=true
--conf spark.sql.catalog.glue_catalog.glue.lakeformation-enabled=true
--conf spark.sql.catalog.glue_catalog.warehouse=s3://example-s3-bucket_DATA_LOCATION
--conf spark.sql.catalog.glue_catalog.catalog-
impl=org.apache.iceberg.aws.glue.GlueCatalog
--conf spark.sql.catalog.glue_catalog.io-impl=org.apache.iceberg.aws.s3.S3FileIO
--conf spark.sql.catalog.glue_catalog.glue.account-id=ACCOUNT_ID
--conf spark.sql.catalog.glue_catalog.glue.region=REGION
```

Reemplace los marcadores de posición:

- S3_DATA_LOCATION: *s3://amzn-s3-demo-bucket*
- REGIÓN: *Región de AWS (por ejemplo, us-east-1)*
- ACCOUNT_ID: *El ID de cuenta de AWS*

> **Note**
>
> Debe establecer estas configuraciones antes de ejecutar cualquier operación de Spark en el bloc de notas.

Operaciones admitidas

Estas operaciones usarán credenciales de AWS Lake Formation para acceder a los datos de las tablas.

> **Note**
>
> Al habilitar AWS Lake Formation:

- Para FTA: habilite la configuración de Spark `spark.sql.catalog.{catalog_name}.glue.lakeformation-enabled`

- CREATE TABLE
- ALTER TABLE
- INSERT INTO
- INSERT OVERWRITE
- SELECT
- UPDATE
- MERGE INTO
- DELETE FROM
- ANALIZAR TABLA
- REPARAR TABLA
- DROP TABLE
- Consultas de orígenes de datos de Spark
- Escrituras de orígenes de datos de Spark

> **Note**
>
> Las operaciones no mencionadas anteriormente aún usan permisos de IAM para acceder a los datos de las tablas.

Migración de AWS Glue 4.0 a AWS Glue 5.0 con FTA

Al migrar de FTA con GlueContext en AWS Glue 4.0 a FTA nativo de Spark en AWS Glue 5.0:

1. Permita que los motores de consultas de terceros accedan a los datos sin la validación de etiquetas de sesión de IAM en AWS Lake Formation. Realice un seguimiento de Paso 1: habilitación del acceso completo a la tabla en AWS Lake Formation.
2. No es necesario cambiar el rol de tiempo de ejecución del trabajo. Sin embargo, verifique que el rol de ejecución del trabajo de AWS Glue tenga el permiso de IAM lakeformation:GetDataAccess.

3. Modifique las configuraciones de la sesión de Spark en el script. Verifique que las siguientes configuraciones de Spark estén incluidas:

```
--conf spark.sql.catalog.spark_catalog=org.apache.iceberg.spark.SparkSessionCatalog
--conf spark.sql.catalog.spark_catalog.warehouse=s3://<bucket-name>/warehouse/
--conf spark.sql.catalog.spark_catalog.client.region=<REGION>
--conf spark.sql.catalog.spark_catalog.glue.account-id=ACCOUNT_ID
--conf spark.sql.catalog.spark_catalog.glue.lakeformation-enabled=true
--conf spark.sql.catalog.dropDirectoryBeforeTable.enabled=true
```

4. Actualice el script para reemplazar los DataFrames de GlueContext por DataFrames nativos de Spark.
5. Actualice el trabajo de AWS Glue de modo que utilice AWS Glue 5.0

Condiciones y limitaciones

- Si una tabla de Hive se crea mediante un trabajo que no tiene habilitado el acceso completo a la tabla y no se insertan registros, las lecturas o escrituras posteriores desde un trabajo con acceso completo a la tabla fallarán. Esto se debe a que AWS Glue Spark, cuando no tiene habilitado el acceso completo a la tabla, agrega el sufijo $folder$ al nombre de la carpeta de la tabla. Para resolver esto, puede optar por una de las siguientes acciones:
  - Insertar al menos una fila en la tabla desde un trabajo que no tenga FTA habilitado.
  - Configure el trabajo que no tiene FTA habilitado para evitar el uso del sufijo $folder$ en el nombre de la carpeta en S3. Esto se logra al configurar `spark.hadoop.fs.s3.useDirectoryHeaderAsFolderObject=true` en Spark.
  - Cree una carpeta de Amazon S3 en la ubicación de la tabla `s3://path/to/table/table_name` mediante la consola de Amazon S3 o la CLI de Amazon S3.
- El acceso completo a la tabla (FTA) funciona exclusivamente con el sistema de archivos de EMR (EMRFS). El sistema de archivos de S3A no es compatible.
- El acceso completo a tablas (FTA) es compatible con tablas de Hive e Iceberg. Aún no se ha agregado compatibilidad con tablas Hudi y Delta.
- Los trabajos que hagan referencia a tablas con reglas de control de acceso detallado (FGAC) de AWS Lake Formation o con vistas del Catálogo de datos de AWS Glue generarán errores. Para consultar una tabla con reglas de FGAC o una vista del Catálogo de datos de AWS Glue, debe usar el modo FGAC. Para habilitar el modo FGAC, siga los pasos que se indican en la

documentación de AWS: Cómo utilizar AWS Glue con AWS Lake Formation para el control de acceso detallado.

- El acceso completo a tablas no ofrece compatibilidad con Spark Streaming.
- No se puede usar simultáneamente con FGAC.

Uso de AWS Glue con AWS Lake Formation para obtener un control de acceso detallado

Descripción general

Con la versión 5.0 de AWS Glue y posteriores, puede aprovechar AWS Lake Formation para aplicar controles de acceso detallados en las tablas del catálogo de datos respaldadas por S3. Esta capacidad le permite configurar los controles de acceso a nivel de tabla, fila, columna y celda para las consultas de read en sus trabajos de Apache Spark de AWS Glue. Consulte las siguientes secciones para obtener más información sobre Lake Formation y cómo usarlo con AWS Glue.

El control de acceso a nivel de tabla basado en `GlueContext` con permisos de AWS Lake Formation admitido en Glue 4.0 y las versiones anteriores no se admite en Glue 5.0. En Glue 5.0 se utiliza el nuevo control de acceso detallado (FGAC) nativo de Spark. Tenga en cuenta la siguiente información:

- Si necesita un control de acceso detallado (FGAC) para el control de acceso de filas, columnas o celdas, tendrá que migrar desde `GlueContext`/Glue DynamicFrame en Glue 4.0 y antes al marco de datos de Spark en Glue 5.0. Para ver ejemplos, consulte Migración de GlueContext/Glue DynamicFrame a Spark DataFrame
- Si necesita control de acceso completo a tablas (FTA), puede aprovechar el FTA con DynamicFrames en AWS Glue 5.0. También puede migrar al enfoque nativo de Spark para aprovechar capacidades adicionales, como conjuntos de datos distribuidos resilientes (RDD), bibliotecas personalizadas y funciones definidas por el usuario (UDF) con tablas de AWS Lake Formation. Para ver ejemplos, consulte Migración de AWS Glue 4.0 a AWS Glue 5.0.
- Si no necesita el FGAC, no es necesario migrar al marco de datos de Spark y características `GlueContext` como los marcadores de trabajo o los predicados desplegables seguirán funcionando.
- Los trabajos con FGAC requieren un mínimo de 4 trabajadores: un controlador del usuario, un controlador del sistema, un ejecutor del sistema y un ejecutor del usuario en espera.

El uso de AWS Glue con AWS Lake Formation conlleva cargos adicionales.

Cómo funciona AWS Glue con AWS Lake Formation

El uso de AWS Glue con Lake Formation le permite implementar una capa de permisos en cada trabajo de Spark para aplicar el control de permisos de Lake Formation cuando AWS Glue ejecuta trabajos. AWS Glue utiliza los perfiles de recursos de Spark para crear dos perfiles para ejecutar los trabajos de forma eficaz. El perfil de usuario ejecuta el código proporcionado por el usuario, mientras que el perfil del sistema implementa las políticas de Lake Formation. Para obtener más información, consulte Qué es AWS Lake Formation y Consideraciones y limitaciones.

A continuación, se ofrece una descripción general de alto nivel sobre cómo AWS Glue obtiene acceso a los datos protegidos por las políticas de seguridad de Lake Formation.

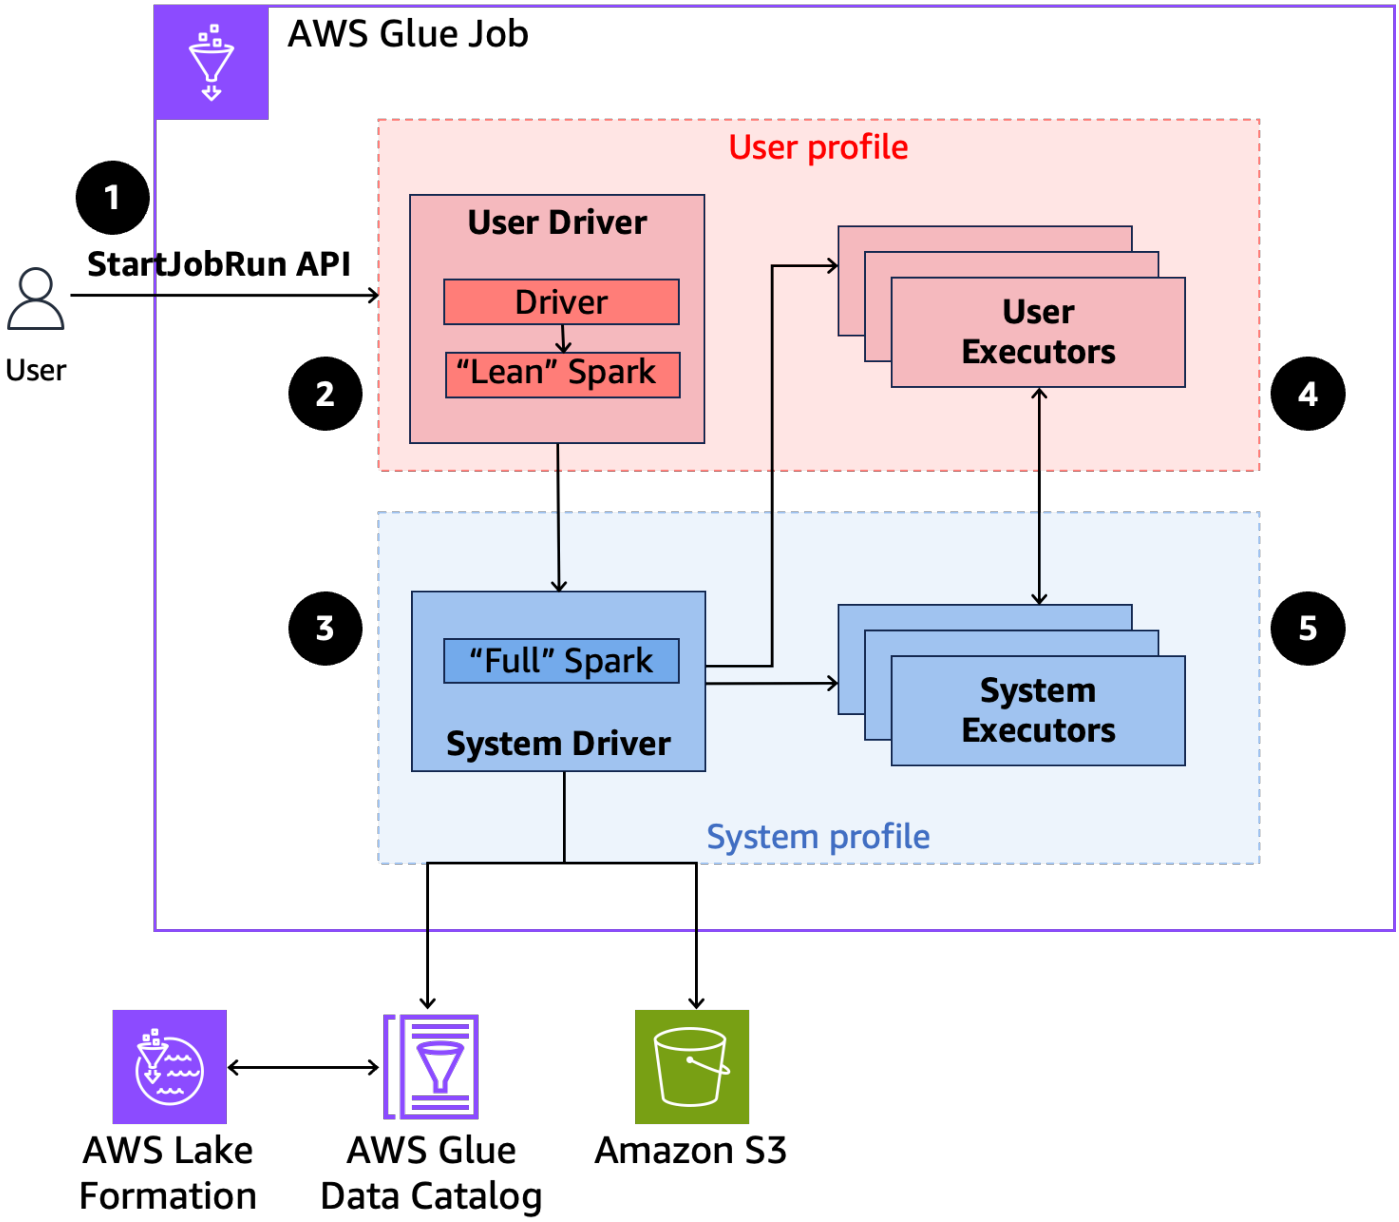

1. Un usuario llama a la API `StartJobRun` en un trabajo de AWS Glue habilitado para AWS Lake Formation.
2. AWS Glue envía el trabajo a un controlador de usuarios y lo ejecuta en el perfil de usuario. El controlador de usuario ejecuta una versión sencilla de Spark que no permite lanzar tareas, solicitar ejecutores ni acceder a S3 ni al catálogo de Glue. Crea un plan de trabajo.
3. AWS Glue configura un segundo controlador denominado controlador del sistema y lo ejecuta en el perfil del sistema (con una identidad privilegiada). AWS Glue configura un canal TLS cifrado entre los dos controladores para la comunicación. El controlador de usuario utiliza el canal para enviar los planes de trabajo al controlador del sistema. El controlador del sistema no ejecuta el

código enviado por el usuario. Ejecuta Spark a pleno rendimiento y se comunica con S3 y con el catálogo de datos para acceder a los datos. Solicita ejecutores y compila el plan de trabajo en una secuencia de etapas de ejecución.

4. A continuación, AWS Glue ejecuta las etapas en los ejecutores con el controlador de usuario o el controlador del sistema. En cualquier etapa, el código de usuario se ejecuta exclusivamente en los ejecutores de perfiles de usuario.
5. Las etapas que leen datos de las tablas del catálogo de datos protegidas por AWS Lake Formation o aquellas que aplican filtros de seguridad se delegan a los ejecutores del sistema.

Requisito mínimo de trabajadores

Un trabajo habilitado para Lake Formation en AWS Glue requiere un mínimo de 4 trabajadores: un controlador del usuario, un controlador del sistema, un ejecutor del sistema y un ejecutor del usuario en espera. Esto representa un aumento con respecto al mínimo de 2 trabajadores requerido para los trabajos estándar de AWS Glue.

Cada trabajo habilitado para Lake Formation en AWS Glue utiliza dos controladores de Spark, uno para el perfil del usuario y otro para el perfil del sistema. Del mismo modo, los ejecutores también se dividen en dos perfiles:

- Ejecutores del sistema: gestionan las tareas en las que se aplican los filtros de datos de Lake Formation.
- Ejecutores del usuario: el controlador del sistema los solicita según sea necesario.

Como los trabajos de Spark son de naturaleza perezosa, AWS Glue reserva el 10 % del total de trabajadores (mínimo 1), una vez deducidos los dos controladores, para los ejecutores del usuario.

Todos los trabajos habilitados para Lake Formation tienen habilitado el escalado automático, lo que significa que los ejecutores del usuario solo se iniciarán cuando sea necesario.

Para ver un ejemplo de configuración, consulte Consideraciones y limitaciones.

Permisos de IAM del rol de tiempo de ejecución de trabajos

Los permisos de Lake Formation controlan el acceso a los recursos de Catálogo de datos de AWS Glue, a las ubicaciones de Amazon S3 y a los datos subyacentes en esas ubicaciones. Los permisos de IAM controlan el acceso a las API y los recursos de Lake Formation y AWS Glue. Aunque es

posible que tenga el permiso de Lake Formation para acceder a una tabla del catálogo de datos (SELECT), la operación fallará si no tiene el permiso de IAM en la operativa de la API `glue:Get*`.

El siguiente es un ejemplo de política sobre cómo proporcionar permisos de IAM para acceder a un script en S3, cargar registros en S3, permisos de la API de Glue de AWS y permiso para acceder a Lake Formation.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Sid": "ScriptAccess",
      "Effect": "Allow",
      "Action": [
        "s3:GetObject",
        "s3:ListBucket"
      ],
      "Resource": [
        "arn:aws:s3:::*.amzn-s3-demo-bucket/scripts",
        "arn:aws:s3:::*.amzn-s3-demo-bucket/*"
      ]
    },
    {
      "Sid": "LoggingAccess",
      "Effect": "Allow",
      "Action": [
        "s3:PutObject"
      ],
      "Resource": [
        "arn:aws:s3:::amzn-s3-demo-bucket/logs/*"
      ]
    },
    {
      "Sid": "GlueCatalogAccess",
      "Effect": "Allow",
      "Action": [
        "glue:Get*",
        "glue:Create*",
        "glue:Update*"
      ],
```

```
      "Resource": [
        "*"
      ]
    },
    {
      "Sid": "LakeFormationAccess",
      "Effect": "Allow",
      "Action": [
        "lakeformation:GetDataAccess"
      ],
      "Resource": [
        "*"
      ]
    }
  ]
}
```

Configuración de permisos de Lake Formation para roles de tiempo de ejecución de trabajos

Primero, registre la ubicación de su tabla de Hive con Lake Formation. A continuación, cree los permisos para el rol de tiempo de ejecución de su trabajo en la tabla que desee. Para obtener más detalles acerca de Lake Formation, consulte Qué esAWS Lake Formation en la AWS Lake Formation Guía para desarrolladores.

Después de configurar los permisos de Lake Formation, puede enviar trabajos de Spark en AWS Glue.

Envío de la ejecución de un trabajo

Cuando termine de configurar los permisos de Lake Formation, podrá enviar trabajos a Spark en AWS Glue. Para ejecutar trabajos de Iceberg, necesita proporcionar las siguientes configuraciones de Spark. Para configurar contenido mediante los parámetros de trabajo de Glue, introduzca el siguiente parámetro:

- Clave:

```
--conf
```

- Valor:

```
spark.sql.catalog.spark_catalog=org.apache.iceberg.spark.SparkSessionCatalog
       --conf spark.sql.catalog.spark_catalog.warehouse=<S3_DATA_LOCATION>
       --conf spark.sql.catalog.spark_catalog.glue.account-id=<ACCOUNT_ID>
       --conf spark.sql.catalog.spark_catalog.client.region=<REGION>
       --conf spark.sql.catalog.spark_catalog.glue.endpoint=https://
glue.<REGION>.amazonaws.com
```

Uso de una sesión interactiva

Cuando termine de configurar los permisos de AWS Lake Formation, podrá usar sesiones interactivas en AWS Glue. Debe proporcionar las siguientes configuraciones de Spark mediante la magia de `%%configure` antes de ejecutar el código.

```
%%configure
{
    "--enable-lakeformation-fine-grained-access": "true",
    "--conf":
 "spark.sql.catalog.spark_catalog=org.apache.iceberg.spark.SparkSessionCatalog
 --conf spark.sql.catalog.spark_catalog.warehouse=<S3_DATA_LOCATION> --conf
 spark.sql.catalog.spark_catalog.catalog-impl=org.apache.iceberg.aws.glue.GlueCatalog
 --conf spark.sql.catalog.spark_catalog.io-impl=org.apache.iceberg.aws.s3.S3FileIO --
conf
 spark.sql.extensions=org.apache.iceberg.spark.extensions.IcebergSparkSessionExtensions
 --conf spark.sql.catalog.spark_catalog.client.region=<REGION> --conf
 spark.sql.catalog.spark_catalog.glue.account-id=<ACCOUNT_ID> --conf
 spark.sql.catalog.spark_catalog.glue.endpoint=https://glue.<REGION>.amazonaws.com"
}
```

FGAC para AWS Glue 5.0 Notebook o sesiones interactivas

Para habilitar el Control de Acceso Detallado (FGAC) en AWS Glue, debe especificar las configuraciones de Spark requeridas para Lake Formation como parte de la magia %%configure antes de crear la primera celda.

Especificarla más tarde mediante las llamadas `SparkSession.builder().conf("").get()` o `SparkSession.builder().conf("").create()` no será suficiente. Este es un cambio con respecto al comportamiento de AWS Glue 4.0.

Compatibilidad con el formato de tabla abierta

La versión 5.0 o posterior de AWS Glue incluye compatibilidad con los controles de acceso detallado basados en Lake Formation. AWS Glue admite los tipos de tablas Hive e Iceberg. La tabla siguiente describe todas las operaciones compatibles.

Operaciones	Hive	Iceberg
Comandos DDL	Solo con permisos de roles de IAM	Solo con permisos de roles de IAM
Consultas incrementales	No aplicable	Totalmente compatible
Consultas de viaje en el tiempo	No es aplicable a este formato de tabla	Totalmente compatible
Tabla de metadatos	No es aplicable a este formato de tabla	Es compatible, pero algunas tablas están ocultas. Consulte consideraciones y limitaciones para obtener más información.
`DML INSERT`	Solo con permisos de IAM	Solo con permisos de IAM
ACTUALIZACIÓN DE DML	No es aplicable a este formato de tabla	Solo con permisos de IAM
`DML DELETE`	No es aplicable a este formato de tabla	Solo con permisos de IAM
Operaciones de lectura	Totalmente compatible	Totalmente compatible
Procedimientos almacenados	No aplicable	Se admite con las excepciones de `register_table` y `migrate`. Consulte consideraciones y limitaciones para obtener más información.

Migración de GlueContext/Glue DynamicFrame a Spark DataFrame

Los siguientes son ejemplos en Python y Scala de migración de `GlueContext`/Glue `DynamicFrame` en Glue 4.0 a Spark `DataFrame` en Glue 5.0.

Python

Antes:

```
escaped_table_name= '`<dbname>`.`<table_name>`'

additional_options = {
  "query": f'select * from {escaped_table_name} WHERE column1 = 1 AND column7 = 7'
}

# DynamicFrame example
dataset = glueContext.create_data_frame_from_catalog(
    database="<dbname>",
    table_name=escaped_table_name,
    additional_options=additional_options)
```

Después:

```
table_identifier= '`<catalogname>`.`<dbname>`.`<table_name>`"' #catalogname is optional

# DataFrame example
dataset = spark.sql(f'select * from {table_identifier} WHERE column1 = 1 AND column7 =
 7')
```

Scala

Antes:

```
val escapedTableName = "`<dbname>`.`<table_name>`"

val additionalOptions = JsonOptions(Map(
    "query" -> s"select * from $escapedTableName WHERE column1 = 1 AND column7 = 7"
    )
)

# DynamicFrame example
```

```
val datasource0 = glueContext.getCatalogSource(
    database="<dbname>",
    tableName=escapedTableName,
    additionalOptions=additionalOptions).getDataFrame()
```

Después:

```
val tableIdentifier = "`<catalogname>`.`<dbname>`.`<table_name>`" //catalogname is
 optional

# DataFrame example
val datasource0 = spark.sql(s"select * from $tableIdentifier WHERE column1 = 1 AND
 column7 = 7")
```

Consideraciones y limitaciones

Tenga en cuenta las siguientes consideraciones y limitaciones cuando utilice Lake Formation con AWS Glue.

AWS Glue con Lake Formation está disponible en todas las regiones compatibles, excepto GovCloud de AWS (Este de EE. UU.) y GovCloud de AWS (Oeste de EE. UU.).

- AWS Glue admite un control de acceso detallado a través de Lake Formation solo para las tablas de Apache Hive y Apache Iceberg. Los formatos de Apache Hive incluyen Parquet, ORC y CSV.
- Solo puede utilizar Lake Formation con trabajos de Spark.
- AWS Glue con Lake Formation solo admite una única sesión de Spark durante un trabajo.
- Cuando Lake Formation está activado, AWS Glue necesita un mayor número de trabajadores porque requiere un controlador del sistema, ejecutores del sistema, un controlador de usuario y, opcionalmente, ejecutores de usuario (necesarios cuando su trabajo tiene UDF o `spark.createDataFrame`).
- AWSGlue con Lake Formation solo admite consultas de tablas entre cuentas compartidas a través de enlaces de recursos. El enlace de recursos debe tener el mismo nombre que el recurso de la cuenta de origen.
- Para habilitar el control de acceso detallado para los trabajos de AWS Glue, pase el parámetro de trabajo `--enable-lakeformation-fine-grained-access`.
- Puede configurar sus trabajos de AWS Glue para que funcionen con la jerarquía de varios catálogos de AWS Glue. Para obtener información sobre los parámetros de configuración que

se van a utilizar con la API `StartJobRun` de AWS Glue, consulte Working with AWS Glue multi-catalog hierarchy on EMR Serverless.

- Lo siguiente no es compatible:
  - Conjuntos de datos distribuidos resilientes (RDD)
  - Streaming de Spark
  - Lectura con permisos concedidos de Lake Formation
  - Control de acceso para columnas anidadas
- AWS Glue bloquea las funcionalidades que podrían socavar el aislamiento total del controlador del sistema, incluidas las siguientes:
  - UDT, HiveUDFS y cualquier función definida por el usuario que incluya clases personalizadas
  - Orígenes de datos personalizados
  - Suministro de archivos jar adicionales para la extensión, el conector o el metaalmacén de Spark
  - `ANALYZE TABLE` command
- Para hacer cumplir los controles de acceso, `EXPLAIN PLAN` y las operaciones de DDL, como `DESCRIBE TABLE`, no exponen información restringida.
- AWS Glue restringe el acceso a los registros de Spark del controlador del sistema en las aplicaciones habilitadas para Lake Formation. Dado que el controlador del sistema se ejecuta con más acceso, los eventos y registros que genera el controlador del sistema pueden incluir información confidencial. Para evitar que usuarios o códigos no autorizados accedan a estos datos confidenciales, AWS Glue deshabilitó el acceso a los registros de los controladores del sistema. Para solucionar problemas, póngase en contacto con la asistencia técnica de AWS.
- Si ha registrado una ubicación de tabla en Lake Formation, la ruta de acceso a los datos pasa por las credenciales almacenadas de Lake Formation, independientemente del permiso de IAM para el rol de tiempo de ejecución de trabajos de AWS Glue. Si configura incorrectamente el rol registrado con la ubicación de la tabla, los trabajos enviados que usen el rol con permisos de IAM de S3 para la ubicación de la tabla fallarán.
- Para escribir en una tabla de Lake Formation se utiliza el permiso de IAM en lugar de los permisos concedidos por Lake Formation. Si el rol de tiempo de ejecución de su trabajo tiene los permisos de S3 necesarios, puede usarlo para ejecutar operaciones de escritura.

A continuación, se indican las consideraciones y limitaciones cuando se utiliza Apache Iceberg:

- Solo puede usar Apache Iceberg con el catálogo de sesiones y no con catálogos con nombres arbitrarios.

- Las tablas de Iceberg que están registradas en Lake Formation solo admiten las tablas de metadatos `history`, `metadata_log_entries`, `snapshots`, `files`, `manifests` y `refs`. AWS Glue oculta las columnas que pueden contener datos confidenciales, como `partitions`, `path` y `summaries`. Esta limitación no se aplica a las tablas de Iceberg que no estén registradas en Lake Formation.
- Las tablas que no se registran en Lake Formation admiten todos los procedimientos almacenados de Iceberg. Los procedimientos `register_table` y `migrate` no son compatibles con ninguna tabla.
- Recomendamos utilizar Iceberg DataFrameWriterV2 en lugar de V1.

Ejemplo de asignación de trabajadores

En un trabajo configurado con los siguientes parámetros:

```
--enable-lakeformation-fine-grained-access=true
--number-of-workers=20
```

La asignación de trabajadores sería la siguiente:

- Un trabajador para el controlador del usuario.
- Un trabajador para el controlador del sistema.
- El 10 % de los 18 trabajadores restantes (es decir, 2 trabajadores) están reservados para los ejecutores de usuarios.
- Se asignan hasta 16 trabajadores a los ejecutores del sistema.

Con el escalado automático habilitado, los ejecutores del usuario pueden utilizar cualquier capacidad no asignada de los ejecutores del sistema si es necesario.

Control de la asignación de ejecutores por usuario

Puede ajustar el porcentaje de reservas para los ejecutores del usuario mediante la siguiente configuración:

```
--conf spark.dynamicAllocation.maxExecutorsRatio=<value between 0 and 1>
```

Esta configuración permite controlar con precisión el número de ejecutores del usuario que están reservados en relación con la capacidad total disponible.

Solución de problemas

Consulte las secciones siguientes para obtener soluciones de problemas.

Registro

AWS Glue utiliza los perfiles de recursos de Spark para dividir la ejecución de los trabajos. AWS Glue utiliza el perfil de usuario para ejecutar el código que proporcionó, mientras que el perfil del sistema implementa las políticas de Lake Formation. Puede acceder a los registros de las tareas ejecutadas con el perfil de usuario.

IU Live y servidor de historial de Spark

La IU Live y el servidor de historial de Spark contienen todos los eventos de Spark generados a partir del perfil de usuario, así como los eventos redactados generados a partir del controlador del sistema.

Puede ver todas las tareas tanto del usuario como de los controladores del sistema en la pestaña Ejecutores. Sin embargo, los enlaces de registro solo están disponibles para el perfil de usuario. Además, parte de la información está redactada en la IU Live, como el número de registros de salida.

Error de trabajo: permisos de Lake Formation insuficientes

Asegúrese de que su rol de tiempo de ejecución de trabajos tenga los permisos para ejecutar SELECT y DESCRIBE en la tabla a la que está accediendo.

Error de trabajo en la ejecución de RDD

Actualmente, AWS Glue no admite operaciones de conjuntos de datos distribuidos resilientes (RDD) en trabajos habilitados para Lake Formation.

Imposible acceder a archivos de datos en Amazon S3

Asegúrese de haber registrado la ubicación del lago de datos en Lake Formation.

Excepción de validación de seguridad

AWS Glue ha detectado un error de validación de seguridad. Póngase en contacto con la asistencia técnica de AWS para obtener ayuda.

Uso compartido del catálogo de datos de Glue y tablas entre cuentas de AWS

Puede compartir bases de datos y tablas entre cuentas y seguir utilizando Lake Formation. Para obtener más información, consulte Intercambio de datos entre cuentas de Lake Formation y How do I share AWS Glue Data Catalog and tables cross-account using?.

La siguiente tabla ofrece un resumen sobre cómo elegir entre el control de acceso detallado (FGAC) y el acceso completo a la tabla (FTA), según la carga de trabajo.

Característica	Control de acceso preciso (FGAC)	Acceso completo a la tabla (FTA)
Access Level	Column/row level	Full table
Use Case	Queries and ETL with limited permissions	ETL
Performance Impact	Requires system/user space transitions for access control evaluation, adding latency	Optimized performance

Uso de Concesiones de acceso a Amazon S3 con AWS Glue

Con la versión 5.0 de Glue, Concesiones de acceso a Amazon S3 proporciona una solución de control de acceso escalable que puede utilizar para aumentar el acceso a los datos de Amazon S3 desde AWS Glue. Si cuenta con una configuración de permisos compleja o amplia de datos de S3, puede utilizar Concesiones de acceso a S3 para escalar los permisos de datos de S3 para usuarios y roles.

Utilice Concesiones de acceso a S3 para incrementar el acceso a los datos de Amazon S3, más allá de los permisos que conceden el rol de tiempo de ejecución o los roles de IAM asociados a las identidades con acceso al trabajo de AWS Glue. Para obtener más información, consulte Administración del acceso con S3 Access Grants en la Guía del usuario de Amazon S3.

Cómo funciona AWS Glue con Concesiones de acceso a S3

Las versiones 5.0 y posteriores de AWS Glue proporcionan una integración nativa con Concesiones de acceso a S3. Puede habilitar Concesiones de acceso a S3 en AWS Glue y ejecutar trabajos de Spark. Cuando un trabajo de Spark solicita datos de S3, Amazon S3 proporciona credenciales temporales que se limitan al bucket, al prefijo o al objeto.

A continuación, se ofrece información general de alto nivel sobre cómo AWS Glue obtiene acceso a los datos que administra Concesiones de acceso a S3.

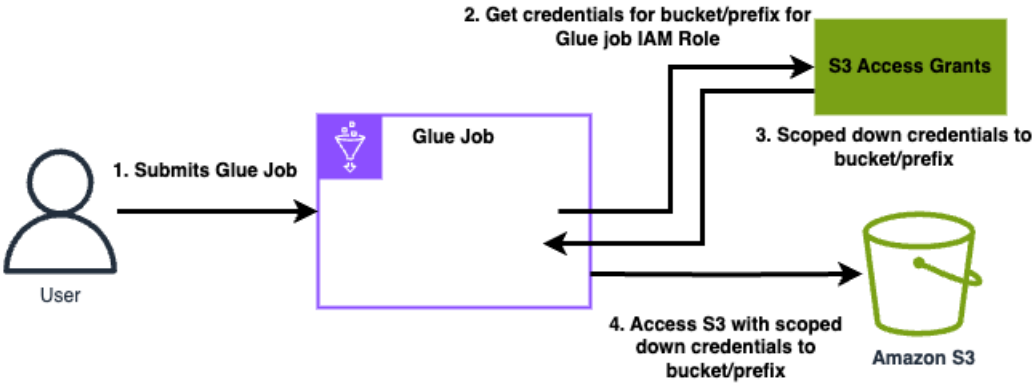

1. Un usuario envía un trabajo de Spark de AWS Glue que utiliza datos almacenados en Amazon S3.
2. AWS Glue solicita a Concesiones de acceso a S3 que venda credenciales temporales para el usuario que da acceso al bucket, al prefijo o al objeto.
3. AWS Glue devuelve credenciales temporales en forma de token de seguridad de AWS (STS) para el usuario. El token tiene el alcance para acceder al bucket, al prefijo o al objeto de S3.
4. AWS Glue utiliza el token de STS para recuperar datos de S3.
5. AWS Gluerecibe los datos de S3 y devuelve los resultados al usuario.

Consideraciones sobre Concesiones de acceso a S3 con AWS Glue

Tenga en cuenta los siguientes comportamientos y limitaciones cuando utilice Concesiones de acceso a S3 con AWS Glue.

Compatibilidad de características

- Concesiones de acceso a S3 es compatible con las versiones 5.0 y posteriores de AWS Glue.
- Recuerde que Spark es el único tipo de trabajo compatible cuando utiliza Concesiones de acceso a S3 con AWS Glue.
- Delta Lake y Hudi son los únicos formatos de tabla abierta compatibles cuando utiliza Concesiones de acceso a S3 con AWS Glue.
- Las siguientes capacidades no son compatibles para su uso con Concesiones de acceso a S3:
  - Tablas de Apache Iceberg
  - Solicitudes a Amazon S3 de la CLI de AWS que utilizan roles de IAM
  - Acceso a S3 mediante el protocolo de código abierto de S3A

Consideraciones sobre el comportamiento

- AWS Glue proporciona una caché de credenciales para garantizar que un usuario no necesite realizar solicitudes repetidas de las mismas credenciales en un trabajo de Spark. Por lo tanto, AWS Glue siempre solicita el privilegio de nivel predeterminado cuando solicita credenciales. Para obtener más información, consulte Solicitud de acceso a datos de S3 en la Guía del usuario de Amazon S3.

Configuración de Concesiones de acceso a S3 con AWS Glue

Requisitos previos

La persona que llama o el administrador ha creado una instancia de Concesiones de acceso a S3.

Configure las políticas de AWS Glue y la configuración de los trabajos

Para configurar Concesiones de acceso a S3 con AWS Glue, debe configurar sus políticas de confianza e IAM y pasar la configuración a través de los parámetros del trabajo.

1. Configure las siguientes políticas de confianza mínima e IAM en el rol que utilice para las concesiones (el rol AWS Glue que ejecuta las sesiones o los trabajos).

   Política de confianza:

```
{
            "Sid": "Stmt1234567891011",
            "Action": [
                "sts:AssumeRole",
                "sts:SetSourceIdentity",
                "sts:SetContext"
            ],
            "Effect": "Allow",
            "Principal": {
                "Service": "access-grants.s3.amazonaws.com"
            },
            "Condition": {
                "StringEquals": {
                    "aws:SourceAccount": "123456789012",
                    "aws:SourceArn": "arn:aws:s3:<region>:123456789012:access-grants/
default"
                }
            }
```

```
        }
```

Política de IAM:

```
{
            "Sid": "S3Grants",
            "Effect": "Allow",
            "Action": [
                "s3:GetDataAccess",
                "s3:GetAccessGrantsInstanceForPrefix"
            ],
            "Resource": "arn:aws:s3:<region>:123456789012:access-grants/default"
        },
        {
            "Sid": "BucketLevelReadPermissions",
            "Effect": "Allow",
            "Action": [
                "s3:ListBucket"
            ],
            "Resource": [
                "arn:aws:s3:::*"
            ],
            "Condition": {
                "StringEquals": {
                    "aws:ResourceAccount": "123456789012"
                },
                "ArnEquals": {
                    "s3:AccessGrantsInstanceArn": [
                        "arn:aws:s3:<region>:123456789012:access-grants/default"
                    ]
                }
            }
        },
        {
            "Sid": "ObjectLevelReadPermissions",
            "Effect": "Allow",
            "Action": [
                "s3:GetObject",
                "s3:GetObjectVersion",
                "s3:GetObjectAcl",
                "s3:GetObjectVersionAcl",
                "s3:ListMultipartUploadParts"
            ],
```

```
            "Resource": [
                "arn:aws:s3:::*"
            ],
            "Condition": {
                "StringEquals": {
                    "aws:ResourceAccount": "123456789012"
                },
                "ArnEquals": {
                    "s3:AccessGrantsInstanceArn": [
                        "arn:aws:s3:<region>:123456789012:access-grants/default"
                    ]
                }
            }
        }
```

2. En el trabajo de AWS Glue, pase la siguiente configuración de Spark a través de los parámetros del trabajo de AWS Glue o `SparkConf`.

```
--conf spark.hadoop.fs.s3.s3AccessGrants.enabled=true \
--conf spark.hadoop.fs.s3.s3AccessGrants.fallbackToIAM=false
```

Propagación de identidades de confianza con AWS Glue ETL

Con IAM Identity Center, puede conectarse a proveedores de identidad (IdP) y administrar de forma centralizada el acceso de usuarios y grupos en todos los servicios de análisis de AWS. Puede integrar proveedores de identidad como Okta, Ping y Microsoft Entra ID (anteriormente Azure Active Directory) con IAM Identity Center para que los usuarios de su organización accedan a los datos mediante una experiencia de inicio de sesión único. IAM Identity Center también permite conectar otros proveedores de identidad de terceros.

Con AWS Glue 5.0 y versiones posteriores, puede propagar las identidades de los usuarios de IAM Identity Center a las sesiones interactivas de AWS Glue. AWS Glue Las sesiones interactivas propagarán aún más la identidad proporcionada a los servicios posteriores, como Concesiones de acceso a Amazon S3, AWS Lake Formation y Amazon Redshift, lo que permitirá el acceso seguro a los datos mediante la identidad del usuario en estos servicios posteriores.

Descripción general

Identity Center es el enfoque recomendado para la autenticación y autorización del personal en AWS para organizaciones de cualquier tamaño y tipo. Con Identity Center, puede crear y administrar

identidades de usuario en AWS o conectar una fuente de identidad existente, entre las que se incluyen Microsoft Active Directory, Okta, Ping Identity, JumpCloud, Google Workspace y Microsoft Entra ID (anteriormente Azure AD).

La propagación de identidades de confianza es una característica de IAM Identity Center que los administradores de los servicios conectados de AWS pueden utilizar para conceder y auditar el acceso a los datos del servicio. El acceso a estos datos se basa en los atributos del usuario, como las asociaciones de grupo. La configuración de la propagación de identidades de confianza requiere la colaboración entre los administradores de los servicios conectados de AWS y los administradores de IAM Identity Center.

Características y ventajas

La integración de las sesiones interactivas de AWS Glue con la propagación de identidades de confianza de IAM Identity Center ofrece las siguientes ventajas:

- La capacidad de aplicar la autorización a nivel de tabla y un control de acceso detallado con las identidades de Identity Center en las tablas de los catálogos de datos de AWS Glue administrados por Lake Formation.
- La capacidad de imponer la autorización con las identidades de Identity Center en los clústeres de Amazon Redshift.
- Permite el seguimiento integral de las acciones de los usuarios para la auditoría.
- La capacidad de imponer la autorización a nivel de prefijo de Amazon S3 con las identidades de Identity Center en los prefijos de Amazon S3 administrados por Concesiones de acceso a Amazon S3.

Casos de uso

Exploración y análisis interactivos de datos

Los ingenieros de datos utilizan sus identidades corporativas para acceder sin problemas a los datos de varias cuentas de AWS y analizarlos. A través de SageMaker Studio, ejecutan sesiones interactivas de Spark mediante AWS Glue ETL y se conectan a varios orígenes de datos, incluidos Amazon S3 y el catálogo de datos de AWS Glue. A medida que los ingenieros exploran los conjuntos de datos, Spark aplica controles de acceso detallados definidos en Lake Formation en función de sus identidades, para garantizar que solo puedan ver los datos autorizados. Todas las consultas y transformaciones de datos se registran con la identidad del usuario, lo que crea un registro

de auditoría claro. Este enfoque simplificado permite la creación rápida de prototipos de nuevos productos de análisis y, al mismo tiempo, mantiene una estricta gobernanza de datos en todos los entornos de cliente.

Preparación de datos e ingeniería de características

Los científicos de datos de varios equipos de investigación colaboran en proyectos complejos mediante una plataforma de datos unificada. Inician sesión en Sagemaker Studio con sus credenciales corporativas y acceden inmediatamente a un enorme lago de datos compartido que abarca varias cuentas de AWS. A medida que comienza la ingeniería de características para los nuevos modelos de machine learning, las sesiones de Spark ejecutadas a través de AWS Glue ETL refuerzan las políticas de seguridad a nivel de columnas y filas de Lake Formation en función de sus identidades propagadas. Los científicos pueden preparar los datos y diseñar características de manera eficiente con herramientas conocidas, mientras que los equipos de cumplimiento tienen la seguridad de que cada interacción de datos se rastrea y audita automáticamente. Este entorno seguro y colaborativo acelera los procesos de investigación y, al mismo tiempo, mantiene los estrictos estándares de protección de datos que se exigen en los sectores regulados.

Funcionamiento

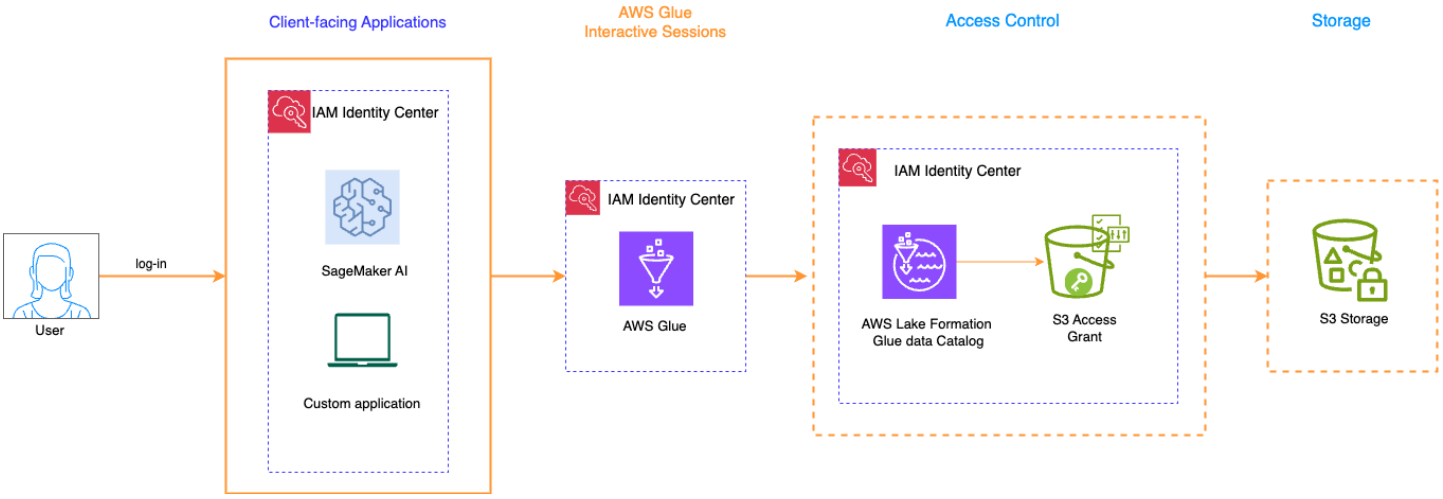

Un usuario inicia sesión en aplicaciones orientadas al cliente (Sagemaker AI o aplicaciones personalizadas) con su identidad corporativa a través de IAM Identity Center. A continuación, esta identidad se propaga en todo el proceso de acceso a los datos.

El usuario autenticado inicia las sesiones interactivas de AWS AWS Glue, que funcionan como motor de cómputo para el procesamiento de datos. Estas sesiones mantienen el contexto de identidad del usuario durante todo el flujo de trabajo.

AWS Lake Formation y el catálogo de datos de AWS Glue trabajan en conjunto para aplicar controles de acceso detallados. Lake Formation aplica políticas de seguridad basadas en la identidad propagada del usuario, mientras que Concesiones de acceso a Amazon S3 proporciona capas de permisos adicionales, lo que garantiza que los usuarios solo puedan acceder a los datos que estén autorizados a ver.

Por último, el sistema se conecta al almacenamiento de Amazon S3, donde residen los datos reales. Todos los accesos se rigen por las políticas de seguridad combinadas, lo que mantiene la gobernanza de datos y permite la exploración y el análisis interactivos de los datos. Esta arquitectura permite un acceso seguro a los datos basado en la identidad en varios servicios de AWS, al tiempo que mantiene una experiencia de usuario perfecta para los científicos e ingenieros de datos que trabajan con grandes conjuntos de datos.

Integraciones

Entorno de desarrollo administrado por AWS

Las siguientes aplicaciones orientadas al cliente administradas por AWS permiten la propagación de identidades de confianza con sesiones interactivas de AWS Glue:

- Sagemaker Unified Studio
- Amazon SageMaker AI

Sagemaker Unified Studio

Siga estos pasos para utilizar la propagación de identidades de confianza con Sagemaker Unified Studio:

1. Configure el proyecto Sagemaker Unified Studio con la propagación de identidades de confianza habilitada como entorno de desarrollo orientado al cliente.
2. Configure Lake Formation para permitir un control de acceso detallado para las tablas de AWS Glue en función del usuario o grupo de IAM Identity Center.
3. Configure Concesiones de acceso a Amazon S3 para permitir el acceso temporal a las ubicaciones de datos subyacentes de Amazon S3.
4. Abra el espacio IDE JupyterLab de Sagemaker Unified Studio y seleccione AWS Glue como cómputo para la ejecución del cuaderno.

Entorno de cuaderno autoalojado administrado por el cliente

Para permitir la propagación de identidades de confianza para los usuarios de aplicaciones desarrolladas a medida, consulte Acceder a los servicios de AWS mediante programación con la propagación de identidades de confianza en el blog de seguridad de AWS.

Cómo empezar con la propagación de identidades de confianza en AWS Glue ETL

Esta sección le ayuda a configurar la aplicación de AWS Glue con sesiones interactivas para integrarla con IAM Identity Center y permitir la propagación de identidades de confianza.

Requisitos previos

- Una instancia de Identity Center en la región de AWS en la que desea crear sesiones interactivas habilitadas por AWS Glue para la propagación de identidades de confianza. Una instancia de Identity Center solo puede existir en una sola región para una cuenta de AWS. Para obtener más información, consulte Activar IAM Identity Center y Aprovisionar los usuarios y grupos de su fuente de identidades en IAM Identity Center.
- Habilite la propagación de identidades de confianza para los servicios posteriores como Lake Formation, Concesiones de acceso a Amazon S3 o el clúster de Amazon Redshift con el que la carga de trabajo interactiva interactúa para acceder a los datos.

Permisos necesarios para conectar AWS Glue ETL con IAM Identity Center

Creación de un rol de IAM

El rol que crea la conexión a IAM Identity Center requiere permisos para crear y modificar la configuración de la aplicación en AWS Glue e IAM Identity Center, como se indica en la siguiente política en línea.

JSON

```
{
    "Version":"2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
```

```
                "glue:CreateGlueIdentityCenterConfiguration",
                "sso:CreateApplication",
                "sso:PutApplicationAssignmentConfiguration",
                "sso:PutApplicationAuthenticationMethod",
                "sso:PutApplicationGrant",
                "sso:PutApplicationAccessScope",
                "sso:ListInstances"
            ],
            "Resource": [
                "*"
            ]
        }
    ]
}
```

Las siguientes políticas en línea contienen los permisos específicos necesarios para ver, actualizar y eliminar las propiedades de la integración de AWS Glue con IAM Identity Center.

Utilice la siguiente política en línea para permitir que un rol de IAM vea una integración de AWS Glue con IAM Identity Center.

JSON

```
{
    "Version":"2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "glue:GetGlueIdentityCenterConfiguration"
            ],
            "Resource": [
                "*"
            ]
        }
    ]
}
```

Utilice la siguiente política en línea para permitir que un rol de IAM actualice una integración de AWS Glue con IAM Identity Center.

JSON

```
{
    "Version":"2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "glue:UpdateGlueIdentityCenterConfiguration",
                "sso:PutApplicationAccessScope",
                "sso:DeleteApplicationAccessScope"
            ],
            "Resource": [
                "*"
            ]
        }
    ]
}
```

Utilice la siguiente política en línea para permitir que un rol de IAM elimine una integración de AWS Glue con IAM Identity Center.

JSON

```
{
    "Version":"2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "glue:DeleteGlueIdentityCenterConfiguration",
                "sso:DeleteApplication"
            ],
            "Resource": [
                "*"
            ]
        }
    ]
}
```

Descripción de los permisos

- `glue:CreateGlueIdentityCenterConfiguration`: otorga permiso para crear una configuración de AWS Glue IdC.
- `glue:GetGlueIdentityCenterConfiguration`: otorga permiso para obtener una configuración de IdC existente.
- `glue:DeleteGlueIdentityCenterConfiguration`: otorga permiso para eliminar una configuración de AWS Glue IdC existente.
- `glue:UpdateGlueIdentityCenterConfiguration`: otorga permiso para actualizar una configuración de AWS Glue IdC existente.
- `sso:CreateApplication`: otorga permiso para crear una aplicación de IAM Identity Center administrada por AWS Glue.
- `sso:DescribeApplication`: otorga permiso para describir una aplicación de IAM Identity Center administrada por AWS Glue.
- `sso:DeleteApplication`: otorga permiso para eliminar una aplicación de IAM Identity Center administrada por AWS Glue.
- `sso:UpdateApplication`: otorga permiso para actualizar una aplicación de IAM Identity Center administrada por AWS Glue.
- `sso:PutApplicationGrant`: otorga permiso para aplicar el intercambio de tokens, IntrospectToken, RefreshToken y RevokeToken en la aplicación de IdC.
- `sso:PutApplicationAuthenticationMethod`: otorga permiso para colocar authenticationMethod en la aplicación de IdC administrada por AWS Glue, lo que permite a la entidad principal del servicio de AWS Glue interactuar con la aplicación de IdC.
- `sso:PutApplicationAccessScope`: otorga permiso para añadir o actualizar la lista de ámbitos de servicio posteriores autorizados en la aplicación de IdC administrada por AWS Glue.
- `sso:DeleteApplicationAccessScope`: otorga permiso para eliminar los ámbitos posteriores si se elimina un ámbito de la aplicación de IdC administrada por AWS Glue.
- `sso:PutApplicationAssignmentConfiguration`: otorga permiso para establecer la configuración “User-assignment-not-required” en la aplicación de IdC.
- `sso:ListInstances`: otorga permiso para enumerar instancias y validar InstanceArn de IdC que especifique en el parámetro de configuración de Identity Center.

Conectar AWS Glue con IAM Identity Center

Cuando se conecta AWS Glue a IAM Identity Center, crea una aplicación de IdC administrada por singleton por cuenta. En el siguiente ejemplo se muestra cómo conectar AWS Glue con IAM Identity Center:

```
aws glue create-glue-identity-center-configuration \
--instance-arn arn:aws:sso:::instance/ssoins-123456789 \
--scopes '["s3:access_grants:read_write", "redshift:connect","lakeformation:query"]'
```

Para actualizar los ámbitos de la aplicación administrada (por lo general se hace para propagarse a más servicios posteriores), puede utilizar lo siguiente:

```
aws glue update-glue-identity-center-configuration \
--scopes '["s3:access_grants:read_write", "redshift:connect","lakeformation:query"]'
```

El parámetro Scopes es opcional y se agregarán todos los ámbitos si no se proporciona. Los valores admitidos son `s3:access_grants:read_write`, `redshift:connect` y `lakeformation:query`.

Para obtener los detalles de la configuración, puede utilizar lo siguiente:

```
aws glue get-glue-identity-center-configuration
```

Puede eliminar la conexión entre AWS Glue e IAM Identity Center mediante el siguiente comando:

```
aws glue delete-glue-identity-center-configuration
```

> **Note**
>
> AWS Glue crea una aplicación de Identity Center administrada por el servicio en su cuenta que el servicio utiliza para la validación y la propagación de identidades a los servicios posteriores. La aplicación Identity Center creada y administrada por AWS Glue se comparte en todas las sesiones de propagación de identidades de confianza de su cuenta. Advertencia: no modifique manualmente la configuración de la aplicación de Identity Center administrada. Cualquier cambio podría afectar a todas las sesiones interactivas de AWS Glue habilitadas para la propagación de identidades de confianza en su cuenta.

Creación de una sesión interactiva de AWS Glue con la propagación de identidades de confianza habilitada

Tras conectar AWS Glue con IAM Identity Center, puede utilizar credenciales de rol con identidad mejorada para crear una sesión interactiva de AWS Glue. No es necesario enviar parámetros adicionales al crear una sesión de AWS Glue 5.0. Dado que AWS Glue está conectada con IAM Identity Center, si AWS Glue detecta credenciales con identidad mejorada, propagará automáticamente la información de identidad a los servicios posteriores, a los que se hace referencia como parte de las instrucciones. Sin embargo, el rol de tiempo de ejecución de la sesión debe tener el permiso `sts:SetContext` que se muestra a continuación.

Permisos del rol de tiempo de ejecución para propagar la identidad

Dado que las sesiones de AWS Glue utilizan credenciales con identidad mejorada para propagar la identidad a los servicios posteriores de AWS, la política de confianza de su rol de tiempo de ejecución debe tener el permiso adicional `sts:SetContext` para permitir la propagación de identidades a los servicios posteriores (Concesiones de acceso a Amazon S3, Lake Formation, Amazon Redshift). Para obtener más información sobre cómo crear un rol de tiempo de ejecución, consulte Configuración de un rol de tiempo de ejecución.

JSON

```
{
  "Version":"2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Principal": {
        "Service": "glue.amazonaws.com"
      },
      "Action": [
        "sts:AssumeRole",
        "sts:SetContext"
      ]
    }
  ]
}
```

Además, el rol de tiempo de ejecución necesitaría permisos para los servicios posteriores de AWS, que la ejecución de flujo de trabajo invocaría para obtener datos mediante la identidad del usuario. Consulte los siguientes enlaces para configurar Concesiones de acceso a Amazon S3 y Lake Formation:

- Uso de Lake Formation con AWS Glue
- Uso de Concesiones de acceso a Amazon S3 con AWS Glue

Consideraciones y limitaciones para la integración de AWS Glue ETL Trusted Identity Propagation

> **Important**
>
> De forma predeterminada, las sesiones no son privadas, lo que significa que un usuario de IdC puede acceder a la sesión de otro usuario de IdC. Puede usar tagOnCreate para configurar las sesiones como privadas. Por ejemplo, la sesión puede etiquetarse con una etiqueta de propietario y su valor como ID de usuario de IDC. En la política, puede utilizar una clave de condición global como `identitystore:UserId` para validar con la etiqueta de propietario en la política de rol de entidad principal o tiempo de ejecución del cliente para todas las operaciones de la API de la sesión, a fin de garantizar que un usuario de IdC no pueda acceder a la sesión de otro usuario de IdC.

Tenga en cuenta estos puntos cuando utilice la propagación de identidades de confianza de IAM Identity Center con la aplicación de AWS Glue:

- La propagación de identidades de confianza a través de Identity Center es compatible con AWS Glue 5.0 y versiones posteriores, y solo con las sesiones interactivas de AWS Glue.
- El catálogo de datos de AWS Glue se incluye en la integración de Lake Formation con Identity Center.
- La propagación de identidades de confianza se limita a las sesiones interactivas de AWS Glue, sin incluir otras entidades de procesamiento de datos como los trabajos, los desencadenadores, los flujos de trabajo y las tareas de aprendizaje automático. Sin embargo, todas las API de AWS Glue registran las identidades de los usuarios en AWS CloudTrail para su auditoría.
- AWS Glue actualmente admite la integración con IAM Identity Center exclusivamente a través de las interfaces de CLI y API, no a través de la consola.

- Una vez que habilite una aplicación en la AWS Glue, asegúrese de crear sesiones 5.0 con credenciales de IdC, pero no cree una sesión 4.0 con credenciales de IdC.
- La propagación de identidades de confianza con AWS Glue es compatible en las siguientes regiones de AWS:
  - af-south-1: África (Ciudad del Cabo)
  - ap-east-1: Asia-Pacífico (Hong Kong)
  - ap-northeast-1 – Asia-Pacífico (Tokio)
  - ap-northeast-2: Asia Pacífico (Seúl)
  - ap-northeast-3: Asia-Pacífico (Osaka)
  - ap-south-1: Asia Pacífico (Mumbai)
  - ap-southeast-1 – Asia-Pacífico (Singapur)
  - ap-southeast-2 – Asia-Pacífico (Sídney)
  - ap-southeast-3: Asia-Pacífico (Yakarta)
  - ca-central-1: Canadá (Central)
  - eu-central-1 – Europa (Fráncfort)
  - eu-north-1: Europa (Estocolmo)
  - eu-south-1: Europa (Milán)
  - eu-west-1 – Europa (Irlanda)
  - eu-west-2: Europa (Londres)
  - eu-west-3: Europa (París)
  - me-south-1: Medio Oriente (Baréin)
  - sa-east-1: América del Sur (São Paulo)
  - us-east-1 – EE. UU. Este (Norte de Virginia)
  - us-east-2 – EE. UU. Este (Ohio)
  - us-west-1: EE. UU. Oeste (Norte de California)
  - us-west-2 – EE. UU. Oeste (Oregón)

Sesiones de usuario en segundo plano para AWS Glue ETL

Las sesiones de usuario en segundo plano permiten que las cargas de trabajo de análisis y machine learning de larga duración continúen incluso después de que el usuario haya cerrado sesión en la interfaz de su cuaderno. Esta capacidad se implementa a través de la característica de

propagación de identidad de confianza de AWS Glue. En la siguiente página se explican las opciones de configuración y los comportamientos de las sesiones de usuario en segundo plano.

> **Note**
>
> Las sesiones de usuario en segundo plano se aplican a las sesiones interactivas de AWS Glue iniciadas a través de interfaces de cuadernos como Sagemaker Unified Studio. La habilitación o deshabilitación de esta característica solo afecta a las sesiones interactivas nuevas; las sesiones activas existentes no se ven afectadas.

Configuración de sesiones de usuario en segundo plano

Las sesiones de usuario en segundo plano deben estar habilitadas en dos niveles para que funcionen correctamente:

1. Nivel de instancia de IAM Identity Center (configurado por los administradores de IdC)
2. Nivel de configuración del centro de identidades de AWS Glue (configurado por los administradores de AWS Glue)

Habilitación de sesiones de usuario en segundo plano para AWS Glue

Para habilitar las sesiones de usuario en segundo plano para AWS Glue, debe establecer el parámetro `userBackgroundSessionsEnabled` en `true` en la configuración del centro de identidades al crear o actualizar la configuración.

Requisitos previos

- El rol de IAM que se utiliza para crear o actualizar la configuración del centro de identidades de AWS Glue debe tener el permiso `sso:PutApplicationSessionConfiguration`. Este permiso permite a AWS Glue habilitar las sesiones en segundo plano de los usuarios en el nivel de la aplicación de IdC administrada por AWS Glue.
- Sus sesiones interactivas de AWS Glue deben usar AWS Glue versión 5.0 o posteriores y deben tener habilitada la función Propagación de identidad de confianza.

Para habilitar las sesiones en segundo plano de los usuarios mediante AWS CLI:

```
aws glue create-glue-identity-center-configuration \
```

```
    --instance-arn "arn:aws:sso:::instance/ssoins-1234567890abcdef" \
    --user-background-sessions-enabled
```

Para actualizar una configuración existente:

```
aws glue update-glue-identity-center-configuration \
    --user-background-sessions-enabled
```

Matriz de configuración

La configuración efectiva de la sesión en segundo plano de los usuarios depende tanto del ajuste de configuración AWS Glue como de los ajustes a nivel de instancia de IAM Identity Center:

¿userBackgroundSession de IAM Identity Center habilitado?	userBackgroundSessionsEnabled de AWS Glue	Comportamiento
Sí	TRUE	Sesiones de usuario en segundo plano habilitadas
Sí	FALSO	La sesión caduca al cerrar sesión del usuario
No	TRUE	La creación de la sesión falla con una excepción
No	FALSO	La sesión caduca al cerrar sesión del usuario

Duración predeterminada de la sesión de usuario en segundo plano

De forma predeterminada, todas las sesiones de usuario en segundo plano tienen un límite de duración de 7 días en IAM Identity Center. Los administradores pueden modificar esta duración en la consola de IAM Identity Center. Esta configuración se aplica a la instancia de IAM Identity Center y afecta a todas las aplicaciones de IAM Identity Center dentro de dicha instancia.

- La duración se puede establecer en cualquier valor, desde 15 minutos hasta 90 días
- Este ajuste se configura en la consola de IAM Identity Center, en Configuración → Autenticación → Configurar (sección Trabajos no interactivos)

> **Note**
>
> De forma predeterminada, las sesiones interactivas de AWS Glue tienen un límite de tiempo de espera de inactividad independiente de 48 horas. Las sesiones finalizarán cuando se agote el tiempo de inactividad de la sesión de AWS Glue o se alcance la duración de la sesión en segundo plano del usuario, lo que ocurra primero.

Impacto de la deshabilitación de las sesiones en segundo plano de los usuarios

Cuando las sesiones en segundo plano de los usuarios están deshabilitadas en el nivel de configuración de AWS Glue:

- Sesiones interactivas existentes: continúan ejecutándose sin interrupciones si se iniciaron con las sesiones en segundo plano de usuarios habilitadas. Estas sesiones seguirán utilizando sus identificadores de sesión en segundo plano hasta que finalicen de forma natural o se detengan explícitamente.
- Nuevas sesiones interactivas: utilizarán el flujo de propagación de identidad de confianza estándar y finalizarán cuando el usuario cierre la sesión o caduque su sesión interactiva (por ejemplo, al cerrar un cuaderno de JupyterLab de Sagemaker Unified Studio).

Cambio de la duración de las sesiones en segundo plano de los usuarios

Cuando se modifica la configuración de duración de las sesiones en segundo plano de los usuarios en IAM Identity Center:

- Sesiones interactivas existentes: continúan ejecutándose con la misma duración de sesión en segundo plano con la que se iniciaron
- Nuevas sesiones interactivas: usarán la nueva duración de la sesión para las sesiones en segundo plano

Consideraciones sobre el tiempo de ejecución

Condiciones de finalización de la sesión

Cuando se utilizan sesiones de usuario en segundo plano, una sesión interactiva de AWS Glue seguirá ejecutándose hasta que se produzca una de las siguientes situaciones:

- La sesión en segundo plano de los usuarios caduque (según la configuración de IdC, hasta 90 días)
- Un administrador revoque manualmente la sesión en segundo plano de los usuarios
- La sesión interactiva de AWS Glue alcanza su tiempo de espera de inactividad (predeterminado: 48 horas después de la última instrucción ejecutada)
- El usuario detiene o reinicia el núcleo del cuaderno de forma explícita

Persistencia de datos

Cuando se utilizan sesiones de usuario en segundo plano:

- Los usuarios no pueden volver a conectarse a la interfaz de su cuaderno para ver los resultados una vez que han cerrado sesión
- Configure sus instrucciones de Spark para escribir los resultados en un almacenamiento persistente (como Amazon S3) antes de que se complete la ejecución

Consecuencias de los costos

- Los trabajos seguirán ejecutándose hasta completarse incluso después de que los usuarios finalicen su sesión de Sagemaker Unified Studio y JupyterLab y se les cobrará por la duración de toda la ejecución.
- Supervise sus sesiones en segundo plano activas para evitar costos innecesarios derivados de sesiones olvidadas o abandonadas

Disponibilidad de características

Las sesiones en segundo plano de los usuarios de AWS Glue están disponibles para:

- Solo sesiones interactivas de AWS Glue (no se admiten trabajos de AWS Glue ni trabajos de transmisión)
- AWS Glue versión 5.0 y posteriores
- Solo configuraciones con la propagación de identidad de confianza habilitada

Registro y monitorización en AWS Glue

Puede automatizar la ejecución de sus trabajos de ETL (extracción, transformación y carga). AWS Glue proporciona métricas de rastreadores y trabajos que se pueden monitorear. Después de configurar AWS Glue Data Catalog con los metadatos necesarios, AWS Glue proporciona estadísticas sobre el estado de su entorno. Puede automatizar la invocación de rastreadores y trabajos con un programa basado en tiempo que esté basado en cron. También puede activar trabajos cuando se desencadena un disparador basado en eventos.

AWS Glue se integra con AWS CloudTrail, un servicio que proporciona un registro de las acciones realizadas por un usuario, un rol o un servicio de AWS en AWS Glue. Si crea un registro de seguimiento, puede habilitar la entrega continua de los eventos de CloudTrail a un bucket de Amazon Simple Storage Service (Amazon S3), Amazon CloudWatch Logs y Amazon CloudWatch Events. Cada entrada de registro o evento contiene información sobre quién generó la solicitud.

Utilice Amazon CloudWatch Events para automatizar los servicios de AWS y responder automáticamente a eventos del sistema, como problemas de disponibilidad de aplicaciones o cambios de recursos. Los eventos de los servicios de AWS se envían a CloudWatch Events casi en tiempo real. Puede crear reglas sencillas para indicar qué eventos resultan de interés, así como qué acciones automatizadas se van a realizar cuando un evento cumple una de las reglas.

Véase también

- Automatizar AWS Glue con EventBridge
- Registro entre cuentas de CloudTrail

Un aspecto importante de la seguridad en la nube es el registro. Se debe configurar el registro de forma que no capture secretos ni material confidencial mientras captura la información necesaria para depurar y proteger la infraestructura en la nube. Asegúrese de familiarizarse con los elementos que se vayan a registrar.

Validación de conformidad en AWS Glue

Para saber si un Servicio de AWS está incluido en el ámbito de programas de conformidad específicos, consulte Servicios de AWS incluidos por programa de conformidad y escoja el

programa de conformidad que le interese. Para obtener información general, consulte Programas de conformidad de AWS.

Puedes descargar los informes de auditoría de terceros utilizando AWS Artifact. Para obtener más información, consulte Descarga de informes en AWS Artifact.

Su responsabilidad de conformidad al utilizar Servicios de AWS se determina en función de la confidencialidad de los datos, los objetivos de conformidad de su empresa, así como de la legislación y los reglamentos aplicables. Para obtener más información sobre la responsabilidad de conformidad al usar Servicios de AWS, consulte la Documentación de seguridad de AWS.

Resiliencia en AWS Glue

La infraestructura global de AWS se compone de regiones de AWS y zonas de disponibilidad de AWS. Las regiones proporcionan varias zonas de disponibilidad físicamente independientes y aisladas que se encuentran conectadas mediante redes con un alto nivel de rendimiento y redundancia, además de baja latencia. Con las zonas de disponibilidad, puede diseñar y utilizar aplicaciones y bases de datos que realizan una conmutación por error automática entre zonas de disponibilidad sin interrupciones. Las zonas de disponibilidad tienen una mayor disponibilidad, tolerancia a errores y escalabilidad que las infraestructuras tradicionales de centros de datos únicos o múltiples.

Para obtener más información sobre las regiones y zonas de disponibilidad de AWS, consulte Infraestructura global de AWS.

Para obtener más información sobre la resiliencia de los trabajos de AWS Glue, consulte Error: comportamiento de conmutación por error entre las VPC en AWS Glue.

Seguridad de la infraestructura en AWS Glue

Al tratarse de un servicio administrado, AWS Glue está protegido por los procedimientos de seguridad de red globales de AWS que se describen en el documento técnico Amazon Web Services: Información general sobre los procesos de seguridad.

Puede utilizar llamadas a la API publicadas en AWS para obtener acceso a AWS Glue a través de la red. Los clientes deben ser compatibles con la seguridad de la capa de transporte (TLS) 1.0 o una versión posterior. Recomendamos TLS 1.2 o una versión posterior. Los clientes también

deben ser compatibles con conjuntos de cifrado con confidencialidad directa total (PFS) tales como Ephemeral Diffie-Hellman (DHE) o Elliptic Curve Ephemeral Diffie-Hellman (ECDHE). La mayoría de los sistemas modernos como Java 7 y posteriores son compatibles con estos modos.

Además, las solicitudes deben estar firmadas mediante un ID de clave de acceso y una clave de acceso secreta que esté asociada a una entidad principal de IAM. También puedes utilizar AWS Security Token Service (AWS STS) para generar credenciales de seguridad temporales para firmar solicitudes.

Temas

- Configuración de puntos de conexión de la VPC de tipo interfaz (AWS PrivateLink) para AWS Glue (AWS PrivateLink)
- Configuración de uso compartido de Amazon VPC

Configuración de puntos de conexión de la VPC de tipo interfaz (AWS PrivateLink) para AWS Glue (AWS PrivateLink)

Puede establecer una conexión privada entre la VPC y AWS Glue mediante la creación de un punto de conexión de VPC de interfaz. Los puntos de conexión de interfaz cuentan con tecnología de AWS PrivateLink que le permite acceder de forma privada a las API de AWS Glue sin una puerta de enlace de Internet, un dispositivo NAT, una conexión de VPN o una conexión de AWS Direct Connect. Las instancias de su VPC no necesitan direcciones IP públicas para comunicar con las API de AWS Glue. El tráfico entre la VPC y AWS Glue no sale de la red de Amazon.

Cada punto de conexión de interfaz está representado por una o más interfaces de red elásticas en las subredes.

Para obtener más información, consulte puntos de conexión de VPC de interfaz (AWS PrivateLink) en la Guía del usuario de Amazon VPC.

Consideraciones para los puntos de conexión de VPC de AWS Glue

Antes de configurar un punto de conexión de VPC de tipo interfaz para AWS Glue, asegúrese de revisar las Propiedades y limitaciones de los puntos de conexión de interfaz en la Guía del usuario de Amazon VPC.

AWS Glue admite realizar llamadas a todas sus acciones de la API desde su VPC.

Creación de un punto de conexión de VPC de interfaz para AWS Glue

Puede crear un punto de conexión de VPC para el servicio de AWS Glue mediante la consola de Amazon VPC o AWS Command Line Interface (AWS CLI). Para obtener más información, consulte Creación de un punto de conexión de interfaz en la Guía del usuario de Amazon VPC.

Cree un punto de conexión de VPC para AWS Glue, mediante el siguiente nombre de servicio:

- com.amazonaws.*region*.glue

Si habilita DNS privado para el punto de conexión, puede realizar solicitudes a la API para AWS Glue usando su nombre de DNS predeterminado para la región, por ejemplo `glue.us-east-1.amazonaws.com`.

Para más información, consulte Acceso a un servicio a través de un punto de conexión de interfaz en la Guía del usuario de Amazon VPC.

Creación de una política de puntos de conexión de VPC para AWS Glue

Puede asociar una política de punto de conexión con su punto de conexión de VPC que controla el acceso a AWS Glue. La política especifica la siguiente información:

- La entidad principal que puede realizar acciones.
- Las acciones que se pueden realizar.
- Los recursos en los que se pueden llevar a cabo las acciones.

Para más información, consulte Control del acceso a los servicios con puntos de enlace de la VPC en la Guía del usuario de Amazon VPC.

Ejemplo: política de punto de conexión de VPC para que AWS Glue permita la creación y actualización de trabajos

A continuación, se muestra un ejemplo de una política de puntos de conexión de AWS Glue. Cuando se asocia con un punto de conexión, esta política concede acceso a las acciones de AWS Glue mostradas para todas las entidades principales en todos los recursos.

```
{
  "Statement": [
```

```
    {
      "Sid": "RestrictPassRole",
      "Effect": "Allow",
      "Action": "iam:PassRole",
      "Resource": "arn:aws:iam::123456789012:role/GlueServiceRole*",
      "Condition": {
        "StringEquals": {
          "iam:PassedToService": "glue.amazonaws.com"
        }
      }
    }
  ]
}
```

Ejemplo: política de punto de conexión de VPC para permitir acceso de solo lectura a Data Catalog

A continuación, se muestra un ejemplo de una política de puntos de conexión de AWS Glue. Cuando se asocia con un punto de conexión, esta política concede acceso a las acciones de AWS Glue mostradas para todas las entidades principales en todos los recursos.

```
{
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:GetDatabase",
        "glue:GetDatabases",
        "glue:GetTable",
        "glue:GetTables",
        "glue:GetTableVersion",
        "glue:GetTableVersions",
        "glue:GetPartition",
        "glue:GetPartitions",
        "glue:BatchGetPartition",
        "glue:SearchTables"
      ],
      "Resource": "*"
    }
  ]
}
```

Configuración de uso compartido de Amazon VPC

AWS Glue soporta las nubes privadas virtuales (VPC) compartidas en Amazon Virtual Private Cloud. El uso compartido de Amazon VPC permite que varias cuentas de AWS creen sus recursos de aplicaciones, como instancias de Amazon EC2 y bases de datos de Amazon Relational Database Service (Amazon RDS), en Amazon VPC compartidas y administradas de forma centralizada. En este modelo, la cuenta propietaria de la VPC (el propietario) comparte una o varias subredes con otras cuentas (los participantes) que pertenecen a la misma organización de AWS Organizations. Después de compartir una subred, los participantes pueden ver, crear, modificar y eliminar los recursos de su aplicación en las subredes compartidas con ellos.

En AWS Glue, para crear una conexión con una subred compartida, debe crear un grupo de seguridad dentro de su cuenta y asociar el grupo de seguridad a la subred compartida.

Para obtener más información, consulte estos temas:

- Trabajar con VPC compartidas en la Guía del usuario de Amazon VPC
- ¿Qué es AWS Organizations? en la Guía del usuario de AWS Organizations

Solución de problemas de AWS Glue

Si surgen problemas a la hora de trabajar con AWS Glue, consulte los temas de esta sección.

Temas

- Recopilación de información sobre la solución de problemas en AWS Glue
- Solución de errores de Spark
- Errores del rastreador cuando usa permisos de Lake Formation
- Solución de problemas AWS Glue de errores de Ray en los registros
- Excepciones de machine learning en AWS Glue
- Cuotas de AWS Glue

Recopilación de información sobre la solución de problemas en AWS Glue

Si detecta errores o comportamientos no esperados en AWS Glue y debe ponerse en contacto con AWS Support, en primer lugar, deberá recopilar la información sobre los nombres, los ID y los registros asociados con el error. Con esta información, Soporte podrán ayudarlo a solucionar los problemas que experimenta.

Junto con su ID de cuenta, recopile la siguiente información para cada uno de estos tipos de errores:

Cuando se produzca un error en un rastreador, recopile la siguiente información:

- Nombre del rastreador

  Los registros de las ejecuciones del rastreador se encuentran en CloudWatch Logs en `/aws-glue/crawlers`.

Cuando se produzca un error en una conexión de prueba, recopile la siguiente información:

- Connection name
- ID de la conexión
- Cadena de la conexión de JDBC con formato `jdbc:protocol://host:port/database-name`.

  Los registros de las conexiones de prueba se encuentra en CloudWatch Logs en `/aws-glue/testconnection`.

Cuando se produzca un error en un flujo de trabajo, recopile la siguiente información:

- Nombre del trabajo
- ID de ejecución del flujo de trabajo con el formato `jr_xxxxx`.

  Los registros de las ejecuciones de trabajo se encuentran en CloudWatch Logs en `/aws-glue/jobs`.

Solución de errores de Spark

Si encuentra errores en AWS Glue, utilice la siguiente información como apoyo para encontrar el origen de los problemas y solucionarlos.

> **Note**
>
> El repositorio GitHub de AWS Glue contiene orientación adicional para solucionar problemas en la sección de preguntas frecuentes deAWS Glue.

Temas

- Error: Resource unavailable (Recurso no disponible)
- Error: Could Not Find S3 Endpoint or NAT Gateway for subnetId in VPC (No se encontró el punto de conexión S3 o puerta de enlace NAT para subnetId en la VPC)
- Error: Inbound Rule in Security Group Required (La regla de entrada del grupo de seguridad es obligatoria)
- Error: Outbound Rule in Security Group Required (La regla de salida del grupo de seguridad es obligatoria)
- Error de trabajo porque el rol transferido debería tener premisos para asumir el rol para el servicio AWS Glue
- Error: DescribeVpcEndpoints action is unauthorized. unable to validate VPC ID vpc-id (La acción DescribeVPCEndpoints no está autorizada. No se puede validar el ID de VPC vpc-id)
- Error: DescribeRouteTables action is unauthorized. unable to validate subnet id: Subnet-id in VPC id: vpc-id (La acción DescribeRouteTables no está autorizada. No se puede validar el ID de subred: Subnet-id en el ID de VPC vpc-id)
- Error: Failed to call ec2:DescribeSubnets (Error al llamar a ec2:DescribeSubnets)

- Error: Failed to call ec2:DescribeSecurityGroups (Error al llamar a ec2:DescribeSecurityGroups)
- Error: Could Not Find Subnet for AZ (No se pudo encontrar la subred de AZ)
- Error: Job run exception when writing to a JDBC target (Excepción de ejecución de flujo de trabajo al escribir en un destino JDBC)
- Error: Amazon S3: The operation is not valid for the object's storage class
- Error: Amazon S3 timeout (Tiempo de espera de Amazon S3)
- Error: Amazon S3 access denied (Acceso denegado a Amazon S3)
- Error: Amazon S3 access key ID does not exist (El ID de clave de acceso de Amazon S3 no existe)
- Se produce un error en la ejecución de trabajo al obtener acceso a Amazon S3 con un URI de s3a://
- Error: Amazon S3 service token expired (Token de servicio de Amazon S3 caducado)
- Error: No private DNS for network interface found (No se encontró un DNS privado para la interfaz de red)
- Error: Development endpoint provisioning failed (Error en el aprovisionamiento del punto de conexión de desarrollo)
- Error: Notebook Server CREATE_FAILED (CREATE_FAILED el servidor del bloc de notas)
- Error: Local notebook fails to start (El bloc de notas local no se inicia)
- Error: Running crawler failed (Error de ejecución del rastreador)
- Error: Partitions were not updated (Las particiones no se han actualizado)
- Error: no se pudo actualizar el marcador de trabajo debido a que la versión no coincide
- Error: A job is reprocessing data when job bookmarks are enabled (Un trabajo está reprocesando datos cuando los marcadores de trabajo están habilitados)
- Error: comportamiento de conmutación por error entre VPC en AWS Glue

Error: Resource unavailable (Recurso no disponible)

Si AWS Glue devuelve un mensaje de recurso no disponible, los mensajes de error o los registros le serán útiles para obtener más información sobre el problema. Las siguientes tareas describen métodos generales para solucionar problemas.

- Por cada conexión o punto de enlace de desarrollo que utilice, compruebe que el clúster no se haya quedado sin interfaces de red elásticas.

Error: Could Not Find S3 Endpoint or NAT Gateway for subnetId in VPC (No se encontró el punto de conexión S3 o puerta de enlace NAT para subnetId en la VPC)

Compruebe el ID de la subred y el ID de la VPC indicados en el mensaje como ayuda para diagnosticar el problema.

- Compruebe que tenga un punto de conexión de VPC de Amazon S3 configurado, elemento obligatorio con AWS Glue. Además, compruebe la gateway de NAT si forma parte de su configuración. Para obtener más información, consulte Puntos de enlace de Amazon VPC para Amazon S3.

Error: Inbound Rule in Security Group Required (La regla de entrada del grupo de seguridad es obligatoria)

Al menos un grupo de seguridad debe abrir todos los puertos de entrada. Para limitar el tráfico, el grupo de seguridad de origen de su regla de entrada puede restringirse al mismo grupo de seguridad.

- En todas las conexiones que utilice, compruebe que el grupo de seguridad tenga una regla de entrada con autorreferencia. Para obtener más información, consulte Configuración del acceso de red a los almacenes de datos.
- Cuando utilice un punto de enlace de desarrollo, compruebe que su grupo de seguridad tenga una regla de entrada con autorreferencia. Para obtener más información, consulte Configuración del acceso de red a los almacenes de datos.

Error: Outbound Rule in Security Group Required (La regla de salida del grupo de seguridad es obligatoria)

Al menos un grupo de seguridad debe abrir todos los puertos de salida. Para limitar el tráfico, el grupo de seguridad de origen de su regla de salida puede restringirse al mismo grupo de seguridad.

- En todas las conexiones que utilice, compruebe que el grupo de seguridad tenga una regla de salida que se haga referencia a sí misma. Para obtener más información, consulte Configuración del acceso de red a los almacenes de datos.

- Cuando utilice un punto de enlace de desarrollo, compruebe que su grupo de seguridad tenga una regla de salida que se haga referencia a sí misma. Para obtener más información, consulte Configuración del acceso de red a los almacenes de datos.

Error de trabajo porque el rol transferido debería tener premisos para asumir el rol para el servicio AWS Glue

El usuario que define un flujo de trabajo debe tener permiso para `iam:PassRole` para AWS Glue.

- Cuando un usuario cree un flujo de trabajo de AWS Glue, compruebe que el rol de usuario contenga una política que tenga `iam:PassRole` para AWS Glue. Para obtener más información, consulte Paso 3: Adjuntar una política a los usuarios o los grupos que accedan a AWS Glue.

Error: DescribeVpcEndpoints action is unauthorized. unable to validate VPC ID vpc-id (La acción DescribeVPCEndpoints no está autorizada. No se puede validar el ID de VPC vpc-id)

- Compruebe que la política que se haya pasado a AWS Glue contenga el permiso `ec2:DescribeVpcEndpoints`.

Error: DescribeRouteTables action is unauthorized. unable to validate subnet id: Subnet-id in VPC id: vpc-id (La acción DescribeRouteTables no está autorizada. No se puede validar el ID de subred: Subnet-id en el ID de VPC vpc-id)

- Compruebe que la política que se haya pasado a AWS Glue contenga el permiso `ec2:DescribeRouteTables`.

Error: Failed to call ec2:DescribeSubnets (Error al llamar a ec2:DescribeSubnets)

- Compruebe que la política que se haya pasado a AWS Glue contenga el permiso `ec2:DescribeSubnets`.

Error: Failed to call ec2:DescribeSecurityGroups (Error al llamar a ec2:DescribeSecurityGroups)

- Compruebe que la política que se haya pasado a AWS Glue contenga el permiso `ec2:DescribeSecurityGroups`.

Error: Could Not Find Subnet for AZ (No se pudo encontrar la subred de AZ)

- Puede que la zona de disponibilidad no esté disponible para AWS Glue. Cree y utilice una nueva subred en una zona de disponibilidad que no sea la que se ha especificado en el mensaje.

Error: Job run exception when writing to a JDBC target (Excepción de ejecución de flujo de trabajo al escribir en un destino JDBC)

Cuando ejecuta un flujo de trabajo que escribe en un destino JDBC, es posible que el flujo de trabajo presente errores en los siguientes casos:

- Si su flujo de trabajo escribe en una tabla de Microsoft SQL Server y la tabla tiene definidas columnas de tipo `Boolean`, la tabla tiene que definirse previamente en la base de datos de SQL Server. Cuando defina el flujo de trabajo en la consola de AWS Glue utilizando un destino de SQL Server con la opción Create tables in your data target (Crear tablas en el destino de los datos), no mapee ninguna columna de origen con ninguna columna de destino que tenga un tipo de datos `Boolean`. Es posible que se produzca un error cuando el flujo de trabajo se ejecute.

  Para evitar el error, ejecute la siguiente operación:

  - Elija una tabla existente con la columna Boolean (booleana).
  - Edite la transformación `ApplyMapping` y mapee la columna Boolean del origen con un número o una cadena del destino.
  - Edite la transformación `ApplyMapping` para eliminar la columna Boolean del origen.
- Si su flujo de trabajo escribe en una tabla de Oracle, es posible que deba ajustar la longitud de los nombres de los objetos de Oracle. En algunas versiones de Oracle, la longitud de identificador máxima está limitada a 30 o 128 bytes. Este límite afecta a los nombres de tablas y de columnas de los almacenes de datos de destino de Oracle.

Para evitar el error, ejecute la siguiente operación:

- Dé un nombre a las tablas de destino de Oracle que esté dentro de los límites de su versión.
- Los nombres de columna predeterminados se generan a partir de los nombres de campos de los datos. Para gestionar el error cuando los nombres de las columnas superan el límite establecido, utilice las transformaciones `ApplyMapping` o `RenameField` para cambiar el nombre de la columna para que esté dentro del límite aceptado.

Error: Amazon S3: The operation is not valid for the object's storage class

Si AWS Glue arroja este error, puede que el trabajo de AWS Glue haya leído datos de las tablas con particiones en los niveles de clase de almacenamiento de Amazon S3.

- Mediante el uso de exclusiones de clase de almacenamiento, puede asegurarse de que sus trabajos de AWS Glue funcionarán en tablas que tengan particiones en estas capas de clase de almacenamiento. Sin exclusiones, los trabajos que leen datos de estos niveles fallan con el siguiente error: `AmazonS3Exception: The operation is not valid for the object's storage class`.

  Para obtener más información, consulte Exclusión de clases de almacenamiento de Amazon S3.

Error: Amazon S3 timeout (Tiempo de espera de Amazon S3)

Si AWS Glue devuelve un error de tiempo de espera de conexión agotado, puede que se deba a que está intentando obtener acceso a un bucket de Amazon S3 ubicado en otra región de AWS.

- Un punto de conexión de VPC de Amazon S3 solo puede dirigir el tráfico a los buckets que se encuentran dentro de una región de AWS. Si necesita conectarse a buckets de otras regiones, puede recurrir a una gateway de NAT para evitar este problema. Para obtener más información, consulte Puerta de enlace NAT.

Error: Amazon S3 access denied (Acceso denegado a Amazon S3)

Si AWS Glue devuelve un error de acceso denegado a un bucket u objeto de Amazon S3, puede deberse a que el rol de IAM proporcionado no tiene una política con permiso para el almacén de datos.

- Un flujo de trabajo de ETL debe tener acceso al almacén de datos de Amazon S3 utilizado como origen o destino. Un rastreador debe tener acceso al almacén de datos de Amazon S3 que rastrea. Para obtener más información, consulte Paso 2: creación de un rol de IAM para AWS Glue.

Error: Amazon S3 access key ID does not exist (El ID de clave de acceso de Amazon S3 no existe)

Si AWS Glue devuelve un error de ID de clave de acceso no existe al ejecutar un flujo de trabajo, puede deberse a uno de los motivos siguientes:

- Un trabajo de ETL utiliza un rol de IAM para obtener acceso a los almacenes de datos. Confirme que el rol de IAM de su trabajo no se haya eliminado antes de iniciar el trabajo.
- Un rol de IAM contiene permisos para obtener acceso a sus almacenes de datos. Confirme que todas las políticas de Amazon S3 asociadas que contengan `s3:ListBucket` sean correctas.

Se produce un error en la ejecución de trabajo al obtener acceso a Amazon S3 con un URI de **`s3a://`**

Si un trabajo devuelve un error similar a Failed to parse XML document with handler class (No se pudo analizar documento XML con la clase de controlador), podría deberse a un error al intentar enumerar centenares de archivos mediante un URI `s3a://`. Obtenga acceso a su almacén de datos mediante un URI `s3://` en su lugar. En el siguiente seguimiento de excepciones se destacan los errores que se buscan:

```
1. com.amazonaws.SdkClientException: Failed to parse XML document with handler class
 com.amazonaws.services.s3.model.transform.XmlResponsesSaxParser$ListBucketHandler
2. at
 com.amazonaws.services.s3.model.transform.XmlResponsesSaxParser.parseXmlInputStream(XmlRespons
3. at
 com.amazonaws.services.s3.model.transform.XmlResponsesSaxParser.parseListBucketObjectsResponse
4. at com.amazonaws.services.s3.model.transform.Unmarshallers
$ListObjectsUnmarshaller.unmarshall(Unmarshallers.java:70)
5. at com.amazonaws.services.s3.model.transform.Unmarshallers
$ListObjectsUnmarshaller.unmarshall(Unmarshallers.java:59)
6. at
 com.amazonaws.services.s3.internal.S3XmlResponseHandler.handle(S3XmlResponseHandler.java:62)
```

```
7. at
 com.amazonaws.services.s3.internal.S3XmlResponseHandler.handle(S3XmlResponseHandler.java:31)
8. at
 com.amazonaws.http.response.AwsResponseHandlerAdapter.handle(AwsResponseHandlerAdapter.java:70
9. at com.amazonaws.http.AmazonHttpClient
$RequestExecutor.handleResponse(AmazonHttpClient.java:1554)
10. at com.amazonaws.http.AmazonHttpClient
$RequestExecutor.executeOneRequest(AmazonHttpClient.java:1272)
11. at com.amazonaws.http.AmazonHttpClient
$RequestExecutor.executeHelper(AmazonHttpClient.java:1056)
12. at com.amazonaws.http.AmazonHttpClient
$RequestExecutor.doExecute(AmazonHttpClient.java:743)
13. at com.amazonaws.http.AmazonHttpClient
$RequestExecutor.executeWithTimer(AmazonHttpClient.java:717)
14. at com.amazonaws.http.AmazonHttpClient
$RequestExecutor.execute(AmazonHttpClient.java:699)
15. at com.amazonaws.http.AmazonHttpClient$RequestExecutor.access
$500(AmazonHttpClient.java:667)
16. at com.amazonaws.http.AmazonHttpClient
$RequestExecutionBuilderImpl.execute(AmazonHttpClient.java:649)
17. at com.amazonaws.http.AmazonHttpClient.execute(AmazonHttpClient.java:513)
18. at com.amazonaws.services.s3.AmazonS3Client.invoke(AmazonS3Client.java:4325)
19. at com.amazonaws.services.s3.AmazonS3Client.invoke(AmazonS3Client.java:4272)
20. at com.amazonaws.services.s3.AmazonS3Client.invoke(AmazonS3Client.java:4266)
21. at com.amazonaws.services.s3.AmazonS3Client.listObjects(AmazonS3Client.java:834)
22. at org.apache.hadoop.fs.s3a.S3AFileSystem.getFileStatus(S3AFileSystem.java:971)
23. at
 org.apache.hadoop.fs.s3a.S3AFileSystem.deleteUnnecessaryFakeDirectories(S3AFileSystem.java:115
24. at org.apache.hadoop.fs.s3a.S3AFileSystem.finishedWrite(S3AFileSystem.java:1144)
25. at org.apache.hadoop.fs.s3a.S3AOutputStream.close(S3AOutputStream.java:142)
26. at org.apache.hadoop.fs.FSDataOutputStream
$PositionCache.close(FSDataOutputStream.java:74)
27. at org.apache.hadoop.fs.FSDataOutputStream.close(FSDataOutputStream.java:108)
28. at org.apache.parquet.hadoop.ParquetFileWriter.end(ParquetFileWriter.java:467)
29. at
 org.apache.parquet.hadoop.InternalParquetRecordWriter.close(InternalParquetRecordWriter.java:1
30. at
 org.apache.parquet.hadoop.ParquetRecordWriter.close(ParquetRecordWriter.java:112)
31. at
 org.apache.spark.sql.execution.datasources.parquet.ParquetOutputWriter.close(ParquetOutputWrit
32. at org.apache.spark.sql.execution.datasources.FileFormatWriter
$SingleDirectoryWriteTask.releaseResources(FileFormatWriter.scala:252)
```

```
33. at org.apache.spark.sql.execution.datasources.FileFormatWriter$$anonfun
$org$apache$spark$sql$execution$datasources$FileFormatWriter$$executeTask
$3.apply(FileFormatWriter.scala:191)
34. at org.apache.spark.sql.execution.datasources.FileFormatWriter$$anonfun
$org$apache$spark$sql$execution$datasources$FileFormatWriter$$executeTask
$3.apply(FileFormatWriter.scala:188)
35. at org.apache.spark.util.Utils
$.tryWithSafeFinallyAndFailureCallbacks(Utils.scala:1341)
36. at org.apache.spark.sql.execution.datasources.FileFormatWriter$.org$apache$spark
$sql$execution$datasources$FileFormatWriter$$executeTask(FileFormatWriter.scala:193)
37. at org.apache.spark.sql.execution.datasources.FileFormatWriter$$anonfun$write$1$
$anonfun$3.apply(FileFormatWriter.scala:129)
38. at org.apache.spark.sql.execution.datasources.FileFormatWriter$$anonfun$write$1$
$anonfun$3.apply(FileFormatWriter.scala:128)
39. at org.apache.spark.scheduler.ResultTask.runTask(ResultTask.scala:87)
40. at org.apache.spark.scheduler.Task.run(Task.scala:99)
41. at org.apache.spark.executor.Executor$TaskRunner.run(Executor.scala:282)
42. at java.util.concurrent.ThreadPoolExecutor.runWorker(ThreadPoolExecutor.java:1149)
43. at java.util.concurrent.ThreadPoolExecutor$Worker.run(ThreadPoolExecutor.java:624)
44. at java.lang.Thread.run(Thread.java:748)
```

Error: Amazon S3 service token expired (Token de servicio de Amazon S3 caducado)

Al transferir datos hacia y desde Amazon Redshift, se utilizan las credenciales temporales de Amazon S3, que caducan después de 1 hora. Si tiene un trabajo de larga duración, se podría producir un error. Para obtener información acerca de cómo configurar sus trabajos de larga duración para mover datos hacia y desde Amazon Redshift, consulte aws-glue-programming-etl-connect-redshift-home.

Error: No private DNS for network interface found (No se encontró un DNS privado para la interfaz de red)

Si un flujo de trabajo genera un error o un punto de enlace de desarrollo no aprovisiona correctamente, podría ser debido a un problema en la configuración de la red.

- Si utiliza el DNS suministrado por Amazon, el valor de `enableDnsHostnames` debe establecerse en true. Para obtener más información, consulte DNS.

Error: Development endpoint provisioning failed (Error en el aprovisionamiento del punto de conexión de desarrollo)

Si AWS Glue no aprovisiona correctamente un punto de enlace de desarrollo, podría ser debido a un problema en la configuración de la red.

- Cuando defina un punto de enlace de desarrollo, la VPC, la subred y los grupos de seguridad se validan para confirmar que cumplan determinados requisitos.
- Si ha proporcionado la clave pública SSH opcional, compruebe que esta sea una clave pública SSH válida.
- Consulte en la consola de la VPC que su VPC utilice la opción DHCP option set (Conjunto de opciones de DHCP) válida. Para obtener más información, consulte Conjuntos de opciones de DHCP.
- Si el clúster permanece en estado PROVISIONING (APROVISIONAMIENTO), póngase en contacto con AWS Support.

Error: Notebook Server CREATE_FAILED (CREATE_FAILED el servidor del bloc de notas)

Si AWS Glue no consigue crear el servidor del bloc de notas de un punto de enlace de desarrollo, podría ser debido a uno de los siguientes problemas:

- AWS Glue transfiere un rol de IAM a Amazon EC2 cuando está configurando el bloc de notas del servidor. El rol de IAM debe tener una relación de confianza con Amazon EC2.
- El rol de IAM debe tener un perfil de instancias con el mismo nombre. Cuando crea el rol para Amazon EC2 con la consola de IAM, se crea automáticamente el perfil de instancias con el mismo nombre. Compruebe si el registro contiene un error de nombre de perfil de instancias `iamInstanceProfile.name` no válido. Para obtener más información, consulte Utilización de perfiles de instancia.
- Compruebe que su rol tenga permiso para obtener acceso a buckets `aws-glue*` en la política que pasa para crear el servidor del bloc de notas.

Error: Local notebook fails to start (El bloc de notas local no se inicia)

Si el bloc de notas local no se inicia y notifica errores del tipo que un directorio o una carpeta no se pueden encontrar, podría ser debido a uno de los siguientes problemas:

- Si usa Microsoft Windows, asegúrese de que la variable de entorno `JAVA_HOME` apunte al directorio de Java correcto. Es posible actualizar Java sin actualizar esta variable; si la variable apunta a una carpeta que ya no existe, los cuadernos de Jupyter no se iniciarán.

Error: Running crawler failed (Error de ejecución del rastreador)

Si AWS Glue no consigue ejecutar correctamente un rastreador para catalogar sus datos, puede ser debido a una de las siguientes razones. En primer lugar compruebe si un error aparece en la lista de rastreadores de la consola de AWS Glue. Compruebe si hay un icono de exclamación junto al nombre del rastreador y pase el ratón por encima del icono para ver si hay mensajes asociados.

- Compruebe los registros del rastreador ejecutado en CloudWatch Logs en `/aws-glue/crawlers`.

Error: Partitions were not updated (Las particiones no se han actualizado)

Si las particiones no se actualizaron en el Data Catalog al ejecutar un trabajo de ETL, estas instrucciones de registro de la clase `DataSink` de CloudWatch Logs pueden resultarle útiles:

- "`Attempting to fast-forward updates to the Catalog - nameSpace:`": muestra qué base de datos, tabla e identificador de catálogo se intenta modificar en este trabajo. Si esta instrucción no está aquí, compruebe si `enableUpdateCatalog` está establecido en true y se ha pasado correctamente como un parámetro `getSink()` o en `additional_options`.
- "`Schema change policy behavior:`": muestra qué valor `updateBehavior` del esquema se ha pasado.
- "`Schemas qualify (schema compare):`": será true o false.
- "`Schemas qualify (case-insensitive compare):`": será true o false.
- Si ambos son falsos y su `updateBehavior` no está establecido en `UPDATE_IN_DATABASE`, entonces el esquema de DynamicFrame tendrá que ser idéntico o contener un subconjunto de las columnas que se muestran en el esquema de la tabla del Data Catalog.

Para obtener más información sobre actualización de particiones, consulte Cómo actualizar el esquema y añadir nuevas particiones al Catálogo de datos mediante trabajos de ETL de AWS Glue.

Error: no se pudo actualizar el marcador de trabajo debido a que la versión no coincide

Es posible que esté intentando aplicar parámetros en trabajos de AWS Glue para aplicar la misma transformación/lógica en distintos conjuntos de datos de Amazon S3. Desea realizar un seguimiento de los archivos procesados en las ubicaciones proporcionadas. Cuando ejecuta el mismo trabajo en el mismo bucket de origen y escribe en el mismo destino o en uno diferente simultáneamente (concurrencia >1), el trabajo falla con este error:

```
py4j.protocol.Py4JJavaError: An error occurred while
 callingz:com.amazonaws.services.glue.util.Job.commit.:com.amazonaws.services.gluejobexecutor.m
 Continuation update failed due to version mismatch. Expected version 2 but found
 version 3
```

Solución: establezca la concurrencia en 1 o no ejecute el trabajo simultáneamente.

Actualmente, los marcadores de AWS Glue no admiten ejecuciones de trabajos simultáneos y las confirmaciones fallarán.

Error: A job is reprocessing data when job bookmarks are enabled (Un trabajo está reprocesando datos cuando los marcadores de trabajo están habilitados)

Es posible que en algunos casos tenga habilitados marcadores de trabajo de AWS Glue, pero su trabajo de ETL está reprocesando los datos que ya se han procesado anteriormente. Compruebe si hay estas causas comunes de este error:

Simultaneidad máxima

Si el número máximo establecido de ejecuciones concurrentes para el trabajo es mayor que el valor predeterminado de 1, esto puede interferir con los marcadores de trabajo. Esto puede suceder cuando los marcadores de trabajo comprueban la hora de la última modificación para verificar los objetos que deben volver a procesarse. Para obtener más información, consulte la discusión de simultaneidad máxima en Configuración de las propiedades de trabajos para trabajos de Spark en AWS Glue.

Objeto de trabajo ausente

Asegúrese de que su script de ejecución de trabajo termina con la siguiente confirmación:

```
job.commit()
```

Al incluir este objeto, AWS Glue registra la marca temporal y la ruta de la ejecución del trabajo. Si ejecuta el trabajo de nuevo con la misma ruta, AWS Glue procesa solo los archivos nuevos. Si no incluye este objeto y los marcadores de trabajo están habilitados, el trabajo vuelve a procesar los archivos ya procesados junto con los nuevos archivos y crea redundancia en el almacén de datos de destino del trabajo.

Parámetro de contexto de transformación ausente

El contexto de transformación es un parámetro opcional en la clase `GlueContext`, pero los marcadores de trabajo no funcionan si no lo incluye. Para solucionar este error, añada el parámetro de contexto de transformación al crear la DynamicFrame, tal y como se muestra a continuación:

```
sample_dynF=create_dynamic_frame_from_catalog(database,
 table_name,transformation_ctx="sample_dynF")
```

Origen de entrada

Si utiliza una base de datos relacional (una conexión JDBC) para la fuente de entrada, los marcadores de trabajo funcionan solamente si las claves de principal de la tabla se encuentran en orden secuencial. Los marcadores de trabajo funcionan en nuevas filas, pero no en filas actualizadas. Esto se debe a que los marcadores de trabajo buscan las claves principales, que ya existen. Esto no se aplica si su origen de entrada es Amazon Simple Storage Service (Amazon S3).

Hora de la última modificación

Para orígenes de entrada de Amazon S3, los marcadores de trabajo comprueban la hora de última modificación de los objetos, en lugar de los nombres de archivo, para verificar qué objetos deben volver a procesarse. Si los datos de origen de entrada se han modificado desde la última ejecución de trabajo, los archivos se vuelven a procesar al ejecutar el trabajo de nuevo.

Error: comportamiento de conmutación por error entre VPC en AWS Glue

El siguiente proceso se utiliza para la conmutación por error de los trabajos de la versión 5.0 de AWS Glue y versiones anteriores.

Resumen: se selecciona una conexión AWS Glue en el momento en que se envía la ejecución de un trabajo. Si la ejecución del trabajo presenta algunos problemas (falta de direcciones IP, conectividad al origen, problema de enrutamiento), la ejecución fallará. Si los reintentos están configurados, AWS Glue lo volverá a intentar con la misma conexión.

1. Para cada intento de ejecución, AWS Glue comprobará el estado de las conexiones en el orden indicado en la configuración del trabajo, hasta que encuentre una que pueda usar. En caso de que se produzca un error en la zona de disponibilidad (AZ), las conexiones procedentes de esa zona no pasarán la comprobación y se omitirán.
2. AWS Glue valida la conexión con lo siguiente:
   - comprueba si el identificador y la subred de Amazon VPC son válidos.
   - comprueba que existe una puerta de enlace NAT o un punto de conexión de VPC de Amazon.
   - comprueba que la subred tiene más de 0 direcciones IP asignadas.
   - comprueba que la AZ esté en buen estado.

   AWS Glue no puede verificar la conectividad en el momento de enviar el trabajo.
3. En el caso de los trabajos que utilizan Amazon VPC, todos los controladores y ejecutores se crearán en la misma zona de disponibilidad con la conexión seleccionada en el momento de enviar el trabajo.
4. Si los reintentos están configurados, AWS Glue lo volverá a intentar con la misma conexión. Esto se debe a que no podemos garantizar que los problemas con esta conexión se prolonguen durante mucho tiempo. Si una zona de disponibilidad falla, el trabajo existente que se ejecuta (según la etapa de ejecución del trabajo) en esa zona puede fallar. Al volver a intentarlo, se debe detectar un error en la zona de disponibilidad y elegir otra zona de disponibilidad para la nueva ejecución.

Errores del rastreador cuando usa permisos de Lake Formation

Utilice la siguiente información para diagnosticar y solucionar varios problemas al configurar el rastreador mediante las credenciales de Lake Formation.

Error: la ubicación de S3: s3://examplepath no está registrada

Para que un rastreador se ejecute con las credenciales de Lake Formation, primero debe configurar los permisos de Lake Formation. Para resolver este error, registre la ubicación de Amazon S3 de

destino con Lake Formation. Para obtener más información, consulte Registro de una ubicación de Amazon S3.

Error: el usuario o rol no está autorizado a realizar: lakeformation:GetDataAccess en el recurso

Añada el permiso `lakeformation:GetDataAccess` del rol de rastreador con la consola de IAM o AWS CLI. Con este permiso, Lake Formation concede la solicitud de credenciales temporales para acceder a los datos. Consulte la política siguiente:

JSON

```
{
  "Version":"2012-10-17",
  "Statement": {
    "Effect": "Allow",
    "Action": [
      "lakeformation:GetDataAccess"
    ],
    "Resource": "*"
  }
}
```

Error: permisos insuficientes para la formación de lagos en (Nombre de la base de datos: exampleDatabase, Nombre de la tabla: exampleTable)

En la consola de Lake Formation (https://console.aws.amazon.com/lakeformation/), conceda permisos de acceso al rol de rastreador (`Create`, `Describe`, `Alter`) en la base de datos, que se especifica como la base de datos de salida. También puede conceder permisos a la tabla. Para obtener más información, consulte Concesión de permisos de base de datos mediante la consola de Lake Formation y el método de recurso con nombre.

Error: permisos de Lake Formation insuficientes en s3://examplepath

1. Rastreo entre cuentas
   a. Inicie sesión en la consola de Lake Formation (https://console.aws.amazon.com/lakeformation/) mediante la cuenta en la que está registrado el bucket de Amazon S3 (cuenta B). Conceda

permisos de Data location (Ubicación de datos) a la cuenta en la que se vaya a ejecutar el rastreador. Esto permitirá al rastreador leer los datos de la ubicación de Amazon S3 de destino.

b. En la cuenta donde esté creado el rastreador (cuenta A), conceda a Data location (ubicación de los datos) permisos en la ubicación de Amazon S3 de destino para el rol de IAM que se usa para la ejecución del rastreador, de modo que el rastreador pueda leer los datos del destino en Lake Formation. Para más información, consulte Concesión de permisos de ubicación de datos (misma cuenta).

2. Rastreo en cuenta (el rastreador y la ubicación de Amazon S3 registrada están en la misma cuenta) - Conceda a Data location (ubicación de los datos) permisos para el rol de IAM que se usa en la ejecución del rastreador en la ubicación de Amazon S3, de modo que el rastreador pueda leer los datos del destino en Lake Formation. Para obtener más información, consulte Concesión de permisos de ubicación de datos (misma cuenta).

Preguntas frecuentes sobre la configuración del rastreador con las credenciales de Lake Formation

1. ¿Cómo configuro un rastreador para que se ejecute con las credenciales de Lake Formation mediante la consola AWS?

   En la consola de AWS Glue (https://console.aws.amazon.com/glue/), al configurar el rastreador, seleccione la opción Use Lake Formation credentials for crawling Amazon S3 data source (Utilizar credenciales de Lake Formation para rastrear un origen de datos de Amazon S3). Para el rastreo entre cuentas, especifique el ID de la Cuenta de AWS donde esté registrada la ubicación de Amazon S3 de destino en Lake Formation. Para realizar el rastreo en cuenta, el campo accountId es opcional.

2. Cómo configuro un rastreador para que se ejecute con las credenciales de Lake Formation mediante AWS CLI?

   Durante la llamada a la API `CreateCrawler`, agregue `LakeFormationConfiguration`:

```
"LakeFormationConfiguration": {
    "UseLakeFormationCredentials": true,
    "AccountId": "111111111111" (AWS account ID where the target Amazon S3 location
 is registered with Lake Formation)
  }
```

3. Cuáles son los objetivos admitidos por un rastreador que utiliza las credenciales de Lake Formation?

   Un rastreador que utilice las credenciales de Lake Formation solo es compatible con Amazon S3 (rastreo dentro y entre cuentas) y para los destinos del catálogo de datos de la cuenta (donde la ubicación subyacente es Amazon S3) y destinos Apache Iceberg.
4. Puedo rastrear varios depósitos de Amazon S3 como parte de un único rastreador con las credenciales de Lake Formation?

   No, para los objetivos de rastreo que utilizan la venta de credenciales de Lake Formation, las ubicaciones subyacentes de Amazon S3 deben pertenecer al mismo bucket. Por ejemplo, los clientes pueden utilizar varias ubicaciones de destino (`s3://bucket1/folder1, s3://bucket1/folder2`) si están debajo del mismo bucket (bucket 1). No se admite la especificación de diferentes buckets (s3://bucket1/carpeta1, s3://bucket2/carpeta2).

Solución de problemas AWS Glue de errores de Ray en los registros

AWS Glue proporciona acceso a los registros emitidos por los procesos de Ray durante la ejecución del trabajo. Si encuentra errores o un comportamiento inesperado en los trabajos de Ray, recopile antes información de los registros para determinar la causa del error. También proporcionamos registros similares para sesiones interactivas. Los registros de sesiones se proporcionan con el prefijo `/aws-glue/ray/sessions`.

Las líneas de registro se envían a CloudWatch en tiempo real, a medida que se ejecuta el trabajo. Las declaraciones de impresión se adjuntan a los registros de CloudWatch una vez finalizada la ejecución. Los registros se conservan durante dos semanas después de ejecutar un trabajo.

Inspección de los registros de trabajos de Ray

Cuando se produce un error en un trabajo, recopile el nombre del trabajo y el identificador de ejecución del trabajo. Puede encontrarlos en la consola de AWS Glue. Vaya a la página del trabajo y, a continuación, vaya a la pestaña Runs (Ejecuciones). Los registros de trabajos de Ray se almacenan en los siguientes grupos de registros dedicados de CloudWatch.

- `/aws-glue/ray/jobs/script-log/`: almacena los registros emitidos por su script principal de Ray.

- `/aws-glue/ray/jobs/ray-monitor-log/`: almacena los registros emitidos por el proceso del escalador automático de Ray. Estos registros se generan para el nodo principal y no para otros nodos de trabajo.
- `/aws-glue/ray/jobs/ray-gcs-logs/`: Almacena los registros emitidos por el proceso GCS (almacenamiento de control global). Estos registros se generan para el nodo principal y no para otros nodos de trabajo.
- `/aws-glue/ray/jobs/ray-process-logs/`: Almacena los registros emitidos por otros procesos de Ray (principalmente el agente del panel de control) que se ejecutan en el nodo principal. Estos registros se generan para el nodo principal y no para otros nodos de trabajo.
- `/aws-glue/ray/jobs/ray-raylet-logs/`: Almacena los registros emitidos por cada proceso de raylet. Estos registros se recopilan en una sola secuencia para cada nodo de trabajo, incluido el nodo principal.
- `/aws-glue/ray/jobs/ray-worker-out-logs/`: Almacena los registros `stdout` de cada proceso de trabajo en el clúster. Estos registros se generan para cada nodo de trabajo, incluido el nodo principal.
- `/aws-glue/ray/jobs/ray-worker-err-logs/`: Almacena los registros `stderr` de cada proceso de trabajo en el clúster. Estos registros se generan para cada nodo de trabajo, incluido el nodo principal.
- `/aws-glue/ray/jobs/ray-runtime-env-log/`: Almacena los registros sobre el proceso de configuración de Ray. Estos registros se generan para cada nodo de trabajo, incluido el nodo principal.

Solución de errores de trabajos de Ray

Para entender la organización de los grupos de registro de Ray y encontrar los grupos de registro que ayudarán a solucionar los errores, es útil disponer de información básica sobre la arquitectura de Ray.

En ETL de AWS Glue, un proceso de trabajo corresponde a una instancia. Al configurar procesos de trabajo para un trabajo de AWS Glue, se establece el tipo y la cantidad de instancias dedicadas al trabajo. Ray utiliza el término proceso de trabajo de diferentes maneras.

Ray usa el nodo principal y el nodo de trabajo para distinguir las responsabilidades de una instancia en un clúster de Ray. Un nodo de trabajo de Ray puede alojar procesos de varios actores que hacen cálculos para lograr el resultado de su cálculo distribuido. Los actores que ejecutan una réplica de una función se denominan réplicas. Los actores de réplica también se pueden denominar procesos

de trabajo. Las réplicas también se pueden ejecutar en el nodo principal, que se conoce como el principal porque ejecuta procesos adicionales para coordinar el clúster.

Cada actor que contribuye al cálculo genera su propio flujo de registro. Esto nos proporciona un poco de información:

- La cantidad de procesos que emiten registros puede ser mayor que la cantidad de procesos de trabajo asignados al trabajo. A menudo, cada núcleo de cada instancia tiene un actor.
- Los nodos principales de Ray emiten registros de inicio y administración de clústeres. Por el contrario, los nodos de trabajo de Ray solo emiten registros del trabajo hecho en ellos.

Para más información acerca de la arquitectura de Ray, consulte Architecture Whitepapers (Documentos técnicos sobre la arquitectura) en la documentación de Ray.

Área del problema: acceso a Amazon S3

Compruebe el mensaje de error de la ejecución del trabajo. Si eso no proporciona suficiente información, compruebe `/aws-glue/ray/jobs/script-log/`.

Área del problema: administración de dependencias de PIP

Compruebe `/aws-glue/ray/jobs/ray-runtime-env-log/`.

Área del problema: inspección de valores intermedios en el proceso principal

Escriba a `stderr` o `stdout` desde su script principal y recupere los registros de `/aws-glue/ray/jobs/script-log/`.

Área del problema: inspección de valores intermedios en un proceso secundario

Escriba a `stderr` o `stdout` desde su función `remote`. A continuación, recupere los registros de `/aws-glue/ray/jobs/ray-worker-out-logs/` o `/aws-glue/ray/jobs/ray-worker-err-logs/`. Es posible que la función se haya ejecutado en cualquier réplica, por lo que es posible que tenga que examinar varios registros para encontrar el resultado deseado.

Área problemática: interpretación de las direcciones IP en los mensajes de error

En determinadas situaciones de error, es posible que su trabajo emita un mensaje de error que contenga una dirección IP. Estas direcciones IP son efímeras y el clúster las utiliza para identificar los nodos y comunicarse entre ellos. Los registros de un nodo se publicarán en un flujo de registros con un sufijo único basado en la dirección IP.

En CloudWatch, puede filtrar los registros para inspeccionar los específicos de esta dirección IP a través de la identificación de este sufijo. Por ejemplo, si utiliza *FAILED_IP* y *JOB_RUN_ID*, puede identificar el sufijo con:

```
filter @logStream like /JOB_RUN_ID/
| filter @message like /IP-/
| parse @message "IP-[*]" as ip
| filter ip like /FAILED_IP/
| fields replace(ip, ":", "_") as uIP
| stats count_distinct by uIP as logStreamSuffix
| display logStreamSuffix
```

Excepciones de machine learning en AWS Glue

En este tema se describen los códigos de error HTTP y las cadenas de las excepciones de AWS Glue relacionadas con el machine learning. Se proporcionan los códigos de error y las cadenas de error de cada actividad de machine learning que pueden producirse al realizar una operación. Además, puede ver si es posible volver a intentar la operación que dio lugar al error.

CancelMLTaskRunActivity

Esta actividad tiene las siguientes excepciones:

- EntityNotFoundException (400)
  - "No se puede encontrar MLTransform en la cuenta [AccountId] con el identificador [transformName]".
  - "No se ha encontrado la ML Task Run para [taskRunId]: en la cuenta [accountId] para transformar [transformName]".

  Reintentar: No.

CreateMLTaskRunActivity

Esta actividad tiene las siguientes excepciones:

- InvalidInputException (400)
  - "Error de servicio interno debido a una entrada inesperada".

- "Se debe especificar un origen de entrada de la tabla de AWS Glue en la transformación".
- "La columna de origen de entrada [columnName] tiene un tipo de datos no válido definido en el catálogo".
- "Se debe proporcionar exactamente una tabla de registro de entrada".
- "Se debe especificar el nombre de la base de datos".
- "Se debe especificar el nombre de la tabla".
- "El esquema no está definido en la transformación".
- "El esquema debe contener la clave principal proporcionada: [primaryKey]".
- "Problema al recuperar el esquema del catálogo de datos: [message]".
- "No se puede establecer capacidad máxima y número de trabajo/tipo al mismo tiempo".
- "Se deben establecer tanto WorkerType como NumberOfWorkers".
- "MaxCapacity debe ser >= [maxCapacity]".
- "NumberOfWorkers debe ser >= [maxCapacity]".
- "Los reintentos máximos no deben ser negativos".
- "No se han establecido los parámetros de búsqueda de coincidencias".
- "Se debe especificar una clave principal en los parámetros de búsqueda de coincidencias".

Reintentar: No.

- AlreadyExistsException (400)
  - "Ya existe una transformación con el nombre [transformName]".

  Reintentar: No.
- IdempotentParameterMismatchException (400)
  - "La solicitud de creación de Idempotent para la transformación [transformName] tenía parámetros que no coincidían".

  Reintentar: No.
- InternalServiceException (500)
  - "Error de dependencia".

  Reintentar: Sí.
- ResourceNumberLimitExceededException (400)
  - "El recuento de Transformaciones ML ([count]) ha excedido el límite de [limit] transformaciones".

Reintentar: Sí, una vez que haya eliminado una transformación para dejar espacio a esta nueva.

DeleteMLTransformActivity

Esta actividad tiene las siguientes excepciones:

- EntityNotFoundException (400)
  - "No se puede encontrar MLTransform en la cuenta [accountId] con el identificador [transformName]"

  Reintentar: No.

GetMLTaskRunActivity

Esta actividad tiene las siguientes excepciones:

- EntityNotFoundException (400)
  - "No se puede encontrar MLTransform en la cuenta [AccountId] con el identificador [transformName]".
  - "No se ha encontrado la ML Task Run para [taskRunId]: en la cuenta [accountId] para transformar [transformName]".

  Reintentar: No.

GetMLTaskRunsActivity

Esta actividad tiene las siguientes excepciones:

- EntityNotFoundException (400)
  - "No se puede encontrar MLTransform en la cuenta [AccountId] con el identificador [transformName]".
  - "No se ha encontrado la ML Task Run para [taskRunId]: en la cuenta [accountId] para transformar [transformName]".

  Reintentar: No.

GetMLTransformActivity

Esta actividad tiene las siguientes excepciones:

- EntityNotFoundException (400)
  - "No se puede encontrar MLTransform en la cuenta [AccountId] con el identificador [transformName]".

  Reintentar: No.

GetMLTransformsActivity

Esta actividad tiene las siguientes excepciones:

- EntityNotFoundException (400)
  - "No se puede encontrar MLTransform en la cuenta [AccountId] con el identificador [transformName]".

  Reintentar: No.
- InvalidInputException (400)
  - "El ID de cuenta no puede estar en blanco".
  - "No se admite clasificación para la columna [column]".
  - "[column] no puede estar en blanco".
  - "Error de servicio interno debido a una entrada inesperada".

  Reintentar: No.

GetSaveLocationForTransformArtifactActivity

Esta actividad tiene las siguientes excepciones:

- EntityNotFoundException (400)
  - "No se puede encontrar MLTransform en la cuenta [AccountId] con el identificador [transformName]".

  Reintentar: No.
- InvalidInputException (400)

- "Tipo de artefacto no admitido [ArtifactType]".
- "Error de servicio interno debido a una entrada inesperada".

Reintentar: No.

GetTaskRunArtifactActivity

Esta actividad tiene las siguientes excepciones:

- EntityNotFoundException (400)
  - "No se puede encontrar MLTransform en la cuenta [AccountId] con el identificador [transformName]".
  - "No se ha encontrado la ML Task Run para [taskRunId]: en la cuenta [accountId] para transformar [transformName]".

  Reintentar: No.
- InvalidInputException (400)
  - "El nombre de archivo '[fileName]' no es válido para la publicación".
  - "No se puede recuperar el artefacto para el tipo de tarea [taskType]".
  - "No se puede recuperar artefacto para [artifactType]".
  - "Error de servicio interno debido a una entrada inesperada".

  Reintentar: No.

PublishMLTransformModelActivity

Esta actividad tiene las siguientes excepciones:

- EntityNotFoundException (400)
  - "No se puede encontrar MLTransform en la cuenta [AccountId] con el identificador [transformName]".
  - "No se puede encontrar un modelo existente con la versión: [version] para el id de cuenta: [accountId] y el id de transformación - [transformId]".

  Reintentar: No.
- InvalidInputException (400)

- "El nombre de archivo '[fileName]' no es válido para la publicación".
- "Signo menos inicial ilegal en cadena sin signo [string]".
- "Dígito incorrecto al final de [string]".
- "El valor de la cadena [string] excede el rango de longitud sin signo".
- "Error de servicio interno debido a una entrada inesperada".

Reintentar: No.

PullLatestMLTransformModelActivity

Esta actividad tiene las siguientes excepciones:

- EntityNotFoundException (400)
  - "No se puede encontrar MLTransform en la cuenta [AccountId] con el identificador [transformName]".

  Reintentar: No.
- InvalidInputException (400)
  - "Error de servicio interno debido a una entrada inesperada".

  Reintentar: No.
- ConcurrentModificationException (400)
  - "No se puede crear la versión del modelo que se quiere capacitar debido a inserciones de carreras con parámetros que no coinciden".
  - "El modelo de transformación ML para el id de transformación [transformId] está obsoleto o está siendo actualizado por otro proceso; vuelva a intentarlo".

  Reintentar: Sí.

PutJobMetadataForMLTransformActivity

Esta actividad tiene las siguientes excepciones:

- EntityNotFoundException (400)
  - "No se puede encontrar MLTransform en la cuenta [AccountId] con el identificador [transformName]".

- "No se ha encontrado la ML Task Run para [taskRunId]: en la cuenta [accountId] para transformar [transformName]".

Reintentar: No.

- InvalidInputException (400)
  - "Error de servicio interno debido a una entrada inesperada".
  - "Tipo de metadatos de trabajo desconocido [jobType]".
  - "Debe proporcionar un ID de ejecución de tarea para actualizar".

Reintentar: No.

StartExportLabelsTaskRunActivity

Esta actividad tiene las siguientes excepciones:

- EntityNotFoundException (400)
  - "No se puede encontrar MLTransform en la cuenta [AccountId] con el identificador [transformName]".
  - "No existe ningún conjunto de etiquetas para transformId [transformID] en el ID de cuenta [accountID]".

Reintentar: No.

- InvalidInputException (400)
  - “[message].”
  - "La ruta S3 proporcionada no está en la misma región que la transformación. Se esperaba región: [región], pero se obtuvo: [región]".

Reintentar: No.

StartImportLabelsTaskRunActivity

Esta actividad tiene las siguientes excepciones:

- EntityNotFoundException (400)
  - "No se puede encontrar MLTransform en la cuenta [AccountId] con el identificador [transformName]".

Reintentar: No.

- InvalidInputException (400)
  - “[message].”
  - "Ruta de archivo de etiqueta no válida".
  - "No se puede acceder al archivo de etiqueta en [labelPath]. [message]".
  - "No se puede utilizar el rol de IAM proporcionado en la transformación. Rol: [role]".
  - "Archivo de etiqueta de tamaño 0 no válido".
  - "La ruta S3 proporcionada no está en la misma región que la transformación. Se esperaba región: [región], pero se obtuvo: [región]".

  Reintentar: No.
- ResourceNumberLimitExceededException (400)
  - "El archivo de etiqueta ha superado el límite de [limit] MB".

  Reintentar: No. Considere dividir su archivo de etiqueta en varios archivos más pequeños.

StartMLEvaluationTaskRunActivity

Esta actividad tiene las siguientes excepciones:

- EntityNotFoundException (400)
  - "No se puede encontrar MLTransform en la cuenta [AccountId] con el identificador [transformName]".

  Reintentar: No.
- InvalidInputException (400)
  - "Se debe proporcionar exactamente una tabla de registro de entrada".
  - "Se debe especificar el nombre de la base de datos".
  - "Se debe especificar el nombre de la tabla".
  - "No se han establecido los parámetros de búsqueda de coincidencias".
  - "Se debe especificar una clave principal en los parámetros de búsqueda de coincidencias".

  Reintentar: No.
- MLTransformNotReadyException (400)

- "Esta operación solo se puede aplicar a una transformación que se encuentra en un estado READY".

Reintentar: No.

- InternalServiceException (500)
  - "Error de dependencia".

Reintentar: Sí.

- ConcurrentRunsExceededException (400)
  - "El recuento de ML Task Runs [count] ha superado el límite de transformación de las ejecuciones de [limit] tareas".
  - "El recuento de ML Task Runs [count] ha superado el límite de ejecuciones de [limit] tareas".

Reintentar: Sí, después de esperar a que finalicen las ejecuciones de tareas.

StartMLLabelingSetGenerationTaskRunActivity

Esta actividad tiene las siguientes excepciones:

- EntityNotFoundException (400)
  - "No se puede encontrar MLTransform en la cuenta [AccountId] con el identificador [transformName]".

Reintentar: No.

- InvalidInputException (400)
  - "Se debe proporcionar exactamente una tabla de registro de entrada".
  - "Se debe especificar el nombre de la base de datos".
  - "Se debe especificar el nombre de la tabla".
  - "No se han establecido los parámetros de búsqueda de coincidencias".
  - "Se debe especificar una clave principal en los parámetros de búsqueda de coincidencias".

Reintentar: No.

- InternalServiceException (500)
  - "Error de dependencia".

Reintentar: Sí.

- ConcurrentRunsExceededException (400)
  - "El recuento de ML Task Runs [count] ha superado el límite de transformación de las ejecuciones de [limit] tareas".

  Reintentar: Sí, después de que se hayan completado las ejecuciones de tareas.

UpdateMLTransformActivity

Esta actividad tiene las siguientes excepciones:

- EntityNotFoundException (400)
  - "No se puede encontrar MLTransform en la cuenta [AccountId] con el identificador [transformName]".

  Reintentar: No.
- InvalidInputException (400)
  - "Ya existe otra transformación con el nombre [transformName]".
  - “[message].”
  - "El nombre de la transformación no puede estar en blanco".
  - "No se puede establecer capacidad máxima y número de trabajo/tipo al mismo tiempo".
  - "Se deben establecer tanto WorkerType como NumberOfWorkers".
  - "MaxCapacity debe ser >= [minMaxCapacity]".
  - "NumberOfWorkers debe ser >= [minNumWorkers]".
  - "Los reintentos máximos no deben ser negativos".
  - "Error de servicio interno debido a una entrada inesperada".
  - "No se han establecido los parámetros de búsqueda de coincidencias".
  - "Se debe especificar una clave principal en los parámetros de búsqueda de coincidencias".

  Reintentar: No.
- AlreadyExistsException (400)
  - "Ya existe una transformación con el nombre [transformName]".

  Reintentar: No.
- IdempotentParameterMismatchException (400)

- "La solicitud de creación de Idempotent para la transformación [transformName] tenía parámetros que no coincidían".

Reintentar: No.

Cuotas de AWS Glue

Puede ponerse en contacto con AWS Supportpara solicitar un aumento de cuota para las service quotas indicadas en el Referencia general de AWS. A menos que se indique lo contrario, cada cuota es específica de la región. Para obtener más información, consulte Puntos de conexión y cuotas de AWS Glue.

Mejora en el rendimiento de AWS Glue

Estrategia básica para ajustar el rendimiento

Para mejorar el rendimiento de AWS Glue, se recomienda que actualice algunos parámetros de AWS Glue relacionados con el rendimiento. Cuando se prepare para ajustar los parámetros, siga las siguientes prácticas recomendadas:

- Determine sus objetivos de rendimiento antes de empezar a identificar los problemas.
- Utilice las métricas para identificar los problemas antes de intentar cambiar los parámetros de ajuste.

Para obtener resultados más consistentes al afinar un trabajo, desarrolle una estrategia básica para su trabajo de ajuste.

Por lo general, el ajuste del rendimiento se realiza en el siguiente flujo de trabajo:

1. Determine los objetivos de rendimiento.
2. Mida las métricas.
3. Identifique los cuellos de botella.
4. Reduzca el impacto de los cuellos de botella.
5. Repita los pasos 2 a 4 hasta alcanzar el objetivo deseado.

Ajuste de las estrategias para el tipo de trabajo

Trabajos de Spark: siga la guía de las Prácticas recomendadas de ajuste del rendimiento de AWS Glue para los trabajos de Apache Spark en las Recomendaciones de AWS.

Otros trabajos: puede ajustar AWS Glue para trabajos de intérprete de comandos de Ray y AWS Glue Python al adaptar las estrategias disponibles en otros entornos de tiempo de ejecución.

Mejora del rendimiento de AWS Glue para los trabajos de Apache Spark

Para mejorar el rendimiento de AWS Glue para Spark, le recomendamos actualizar algunos parámetros relacionados con el rendimiento de AWS Glue y de Spark.

Para obtener más información sobre estrategias específicas para identificar los cuellos de botella mediante métricas y reducir su impacto, consulte las Prácticas recomendadas para el rendimiento al ajustar AWS Glue para los trabajos de Apache Spark en Recomendaciones de AWS. Esta guía presenta los temas principales que se pueden aplicar a Apache Spark en todos los entornos de tiempo de ejecución, como la arquitectura de Spark y los conjuntos de datos distribuidos resilientes. Con estos temas, la guía ayuda para implementar estrategias específicas de ajuste del rendimiento, como la optimización de las combinaciones y la paralelización de las tareas.

Se pueden identificar los cuellos de botella al configurar AWS Glue para que muestre la interfaz de usuario de Spark. Para obtener más información, consulte the section called “Monitorización con la interfaz de usuario de Spark”.

Además, AWS Glue ofrece características de rendimiento que pueden aplicarse al tipo específico de almacén de datos al que se conecta el trabajo. Puede encontrar información de referencia sobre los parámetros de rendimiento para los almacenes de datos en the section called “Parámetros de conexión”.

Optimización de las lecturas con inserción en operaciones de ETL de AWS Glue

El método Pushdown es una técnica de optimización que acerca la lógica de la recuperación de datos al origen de los datos. El origen podría ser una base de datos o un sistema de archivos como Amazon S3. Al ejecutar determinadas operaciones directamente en el origen, puede ahorrar tiempo y potencia de procesamiento al no llevar todos los datos de la red al motor Spark gestionado por Glue AWS.

Otra forma de decir esto es que la presión hacia abajo reduce el escaneo de datos. Para obtener más información sobre el proceso de identificación de cuándo esta técnica es adecuada, consulte Reducir la cantidad de datos escaneados en la guía de Prácticas recomendadas para el ajuste del rendimiento de AWS Glue para trabajos de Apache Spark en las Recomendaciones de AWS.

Predica cómo insertar los archivos almacenados en Amazon S3

Al trabajar con archivos en Amazon S3 organizados por prefijo, puede filtrar las rutas de Amazon S3 de destino mediante la definición de un predicado de inserción. En lugar de leer el conjunto de datos completo y aplicar filtros dentro de un `DynamicFrame`, puede aplicar el filtro directamente a los metadatos de la partición almacenados en el catálogo de datos de Glue AWS. Este enfoque

permite enumerar y leer de forma selectiva solo los datos necesarios. Para obtener más información sobre este proceso, incluida la escritura en un bucket mediante particiones, consulte the section called “Administración de particiones”.

Para lograr la inserción de predicados en Amazon S3, utilice el parámetro `push_down_predicate`. Pensemos en un bucket de Amazon S3 que haya particionado por año, mes y día. Si quiere recuperar los datos de los clientes de junio de 2022, puede indicar a Glue AWS que lea solo las rutas relevantes de Amazon S3. En este caso, el `push_down_predicate` es `year='2022' and month='06'`. Juntándolo todo, la operación de lectura se puede lograr de la siguiente manera:

Python

```
customer_records = glueContext.create_dynamic_frame.from_catalog(
    database = "customer_db",
    table_name = "customer_tbl",
    push_down_predicate = "year='2022' and month='06'"
)
```

Scala

```
val customer_records = glueContext.getCatalogSource(
database="customer_db",
tableName="customer_tbl",
pushDownPredicate="year='2022' and month='06'"
).getDynamicFrame()
```

En el escenario anterior, `push_down_predicate` recupera una lista de todas las particiones del catálogo de datos de Glue AWS y las filtra antes de leer los archivos subyacentes de Amazon S3. Aunque esto ayuda en la mayoría de los casos, cuando se trabaja con conjuntos de datos que tienen millones de particiones, el proceso de enumerar las particiones puede llevar mucho tiempo. Para solucionar este problema, se puede utilizar la depuración de las particiones desde el servidor para mejorar el rendimiento. Para ello, se crea un índice de particiones para los datos en el catálogo de datos de Glue AWS. Para obtener más información sobre los índices de particiones, consulte the section called “Creación de índices de particiones”. A continuación, puede utilizar la opción `catalogPartitionPredicate` para hacer referencia al índice. Para ver un ejemplo de cómo recuperar particiones con `catalogPartitionPredicate`, consulte the section called “Predicados de particiones de catálogo”.

Insertar al trabajar con fuentes JDBC

El lector JDBC de Glue AWS que se utiliza en el archivo `GlueContext` admite la inserción en las bases de datos compatibles al proporcionar consultas SQL personalizadas que se pueden ejecutar directamente en el origen. Esto se puede lograr mediante la configuración del parámetro `sampleQuery`. La consulta de ejemplo puede especificar qué columnas seleccionar, así como proporcionar un predicado de inserción para limitar los datos transferidos al motor Spark.

De forma predeterminada, las consultas de muestra funcionan en un único nodo, lo que puede provocar fallos en el trabajo cuando se manejan grandes volúmenes de datos. Para utilizar esta función para consultar datos a escala, debe configurar la partición de consultas con el valor `enablePartitioningForSampleQuery` a verdadero, lo que distribuirá la consulta a varios nodos en la clave que elija. La partición de consultas también requiere algunos otros parámetros de configuración necesarios. Para obtener más información sobre la partición de consultas, vea the section called “Lectura desde JDBC en paralelo”.

Al configurar `enablePartitioningForSampleQuery`, Glue AWS combinará el predicado de inserción con un predicado de partición al consultar la base de datos. Su `sampleQuery` debe terminar con un `AND` para que Glue AWS agregue condiciones de partición. (Si no proporciona un predicado de inserción, `sampleQuery` debe terminar con un `WHERE`). Consulte un ejemplo a continuación, en el que presionamos un predicado hacia abajo para recuperar solo las `id` filas superiores a 1000. Esto `sampleQuery` solo devolverá las columnas de nombre y ubicación de las filas donde `id` sea mayor que el valor especificado:

Python

```
sample_query = "select name, location from customer_tbl WHERE id>=1000 AND"
customer_records = glueContext.create_dynamic_frame.from_catalog(
    database="customer_db",
    table_name="customer_tbl",
    sample_query = "select name, location from customer_tbl WHERE id>=1000 AND",

    additional_options = {
                           "hashpartitions": 36 ,
                           "hashfield":"id",
                           "enablePartitioningForSampleQuery":True,
                           "sampleQuery":sample_query
                          }
)
```

Scala

```
val additionalOptions = Map(
        "hashpartitions" -> "36",
        "hashfield" -> "id",
        "enablePartitioningForSampleQuery" -> "true",
        "sampleQuery" -> "select name, location from customer_tbl WHERE id >= 1000
 AND"
        )

    val customer_records = glueContext.getCatalogSource(
        database="customer_db",
        tableName="customer_tbl").getDynamicFrame()
```

> **Note**
>
> Si el nombre de `customer_tbl` es diferente en el Catálogo de datos en el almacén de datos subyacente, debe brindar el nombre subyacente de la tabla en sample_query, ya que la solicitud es enviada al almacén de datos subyacente.

También puede realizar consultas en tablas JDBC sin necesidad de integrarlas con el catálogo de datos de Glue AWS. En lugar de proporcionar el nombre de usuario y la contraseña como parámetros del método, puede reutilizar las credenciales de una conexión preexistente y proporcionar `useConnectionProperties` y `connectionName`. En este ejemplo, recuperamos las credenciales de una conexión llamada `my_postgre_connection`.

Python

```
connection_options_dict = {
    "useConnectionProperties": True,
    "connectionName": "my_postgre_connection",
    "dbtable":"customer_tbl",
    "sampleQuery":"select name, location from customer_tbl WHERE id>=1000 AND",
    "enablePartitioningForSampleQuery":True,
    "hashfield":"id",
    "hashpartitions":36
    }
```

```
customer_records = glueContext.create_dynamic_frame.from_options(
    connection_type="postgresql",
    connection_options=connection_options_dict
    )
```

Scala

```
val connectionOptionsJson = """
      {
        "useConnectionProperties": true,
        "connectionName": "my_postgre_connection",
        "dbtable": "customer_tbl",
        "sampleQuery": "select name, location from customer_tbl WHERE id>=1000 AND",
        "enablePartitioningForSampleQuery" : true,
        "hashfield" : "id",
        "hashpartitions" : 36
      }
    """

    val connectionOptions = new JsonOptions(connectionOptionsJson)

    val dyf = glueContext.getSource("postgresql",
 connectionOptions).getDynamicFrame()
```

Notas y limitaciones de cómo insertar en Glue AWS

El concepto Pushdown es aplicable cuando se lee desde orígenes que no son de streaming. AWS Glue admite una variedad de orígenes: la capacidad de insertar depende de la fuente y el conector.

- Cuando se conecte a Snowflake, puede usar la opción `query`. Existe una funcionalidad similar en el conector Redshift de Glue 4.0 AWS y versiones posteriores. Para obtener más información acerca de cómo leer de Snowflake with`query`, consulte the section called “Leer de Snowflake”.
- El lector de ETL de DynamoDB no es compatible con filtros ni predicados de inserción. MongoDB y DocumentDB tampoco admiten este tipo de funcionalidad.
- Al leer datos almacenados en Amazon S3 en formatos de tabla abierta, el método de partición de los archivos en Amazon S3 ya no es suficiente. Para leer y escribir desde particiones que utilizan formatos de tabla abierta, consulte la documentación del formato.
- Los métodos DynamicFrame no realizan la inserción de proyección de Amazon S3. Se leerán todas las columnas de los archivos que pasen el filtro de predicados.

- Cuando se trabaja con conectores `custom.jdbc` en Glue AWS, la capacidad de inserción depende del origen y del conector. Revise la documentación del conector correspondiente para confirmar si es compatible con la inserción en Glue AWS y cómo lo hace.

Utilizar Auto Scaling para AWS Glue

El escalado automático está disponible para trabajos ETL, sesiones interactivas y trabajos de transmisión de AWS Glue con AWS Glue versión 3.0 o posterior.

Con Auto Scaling habilitado, obtendrá los siguientes beneficios:

- AWS Glue agrega automáticamente y elimina empleados del clúster en función del paralelismo en cada etapa o microlote de la ejecución del trabajo.
- Elimina la necesidad de experimentar y decidir el número de empleados que asignará a sus trabajos de ETL de AWS Glue.
- Si elije el número máximo de empleados, AWS Glue elegirá el tamaño correcto de recursos para la carga de trabajo.
- Puede ver cómo cambia el tamaño del clúster durante la ejecución del trabajo si mira las métricas de CloudWatch en la página de detalles de ejecución de trabajo de AWS Glue Studio.

El escalado automático para trabajos de ETL de AWS Glue y streaming permite escalar horizontalmente y reducir horizontalmente bajo demanda los recursos de computación de sus trabajos de AWS Glue. El escalado vertical bajo demanda lo ayuda a asignar solo los recursos informáticos necesarios, en principio, en el inicio de la ejecución de trabajos, así como a aprovisionar los recursos necesarios según la demanda durante el trabajo.

El escalado automático también admite la reducción horizontal dinámica de los recursos de trabajo de AWS Glue durante el transcurso de un trabajo. Durante la ejecución de un trabajo, cuando la aplicación Spark solicite más ejecutores, se agregarán más empleados al clúster. Cuando el ejecutor ha estado inactivo sin tareas de cálculo activas, se eliminarán el ejecutor y el empleado correspondiente.

Los escenarios comunes en los que el escalado automático ayuda con el costo y el uso de sus aplicaciones de Spark incluyen:

- un controlador de Spark que enumera un gran número de archivos en Amazon S3 o lleva a cabo una carga mientras los ejecutores se encuentran inactivos

- etapas en las que Spark se ejecuta con solo unos pocos ejecutores debido al sobreaprovisionamiento
- sesgos de datos o demanda de cálculo desigual en todas las etapas de Spark

Requisitos

El escalado automático solo se encuentra disponible para la versión 3.0 o posterior de AWS Glue. Para utilizar el escalado automático, puede seguir la guía de migración a fin de migrar los trabajos existentes a la versión 3.0 o posterior de AWS Glue, o bien crear trabajos nuevos con la versión 3.0 o posterior de AWS Glue.

El escalado automático se encuentra disponible para trabajos de AWS Glue con los tipos de trabajadores `G.1X`, `G.2X`, `G.4X`, `G.8X`, `G.12X`, `G.16X`, `R.1X`, `R.2X`, `R.4X`, `R.8X` o `G.025X` (solo con trabajos de streaming). Las DPU estándar no son compatibles con el escalado automático.

Habilitar Auto Scaling en AWS Glue Studio

En la página Detalles del trabajo en AWS Glue Studio, elija el tipo como Spark o Spark Streaming y Versión de Glue como **`Glue 3.0`** o posterior. A continuación, se mostrará una casilla de verificación debajo de Tipo de trabajador.

- Seleccione la opción Automatically scale the number of workers (Escalar automáticamente el número de empleados).
- Establezca el Maximum number of workers (Número máximo de empleados) para definir el número máximo de empleados que se pueden asignar a la ejecución de trabajos.

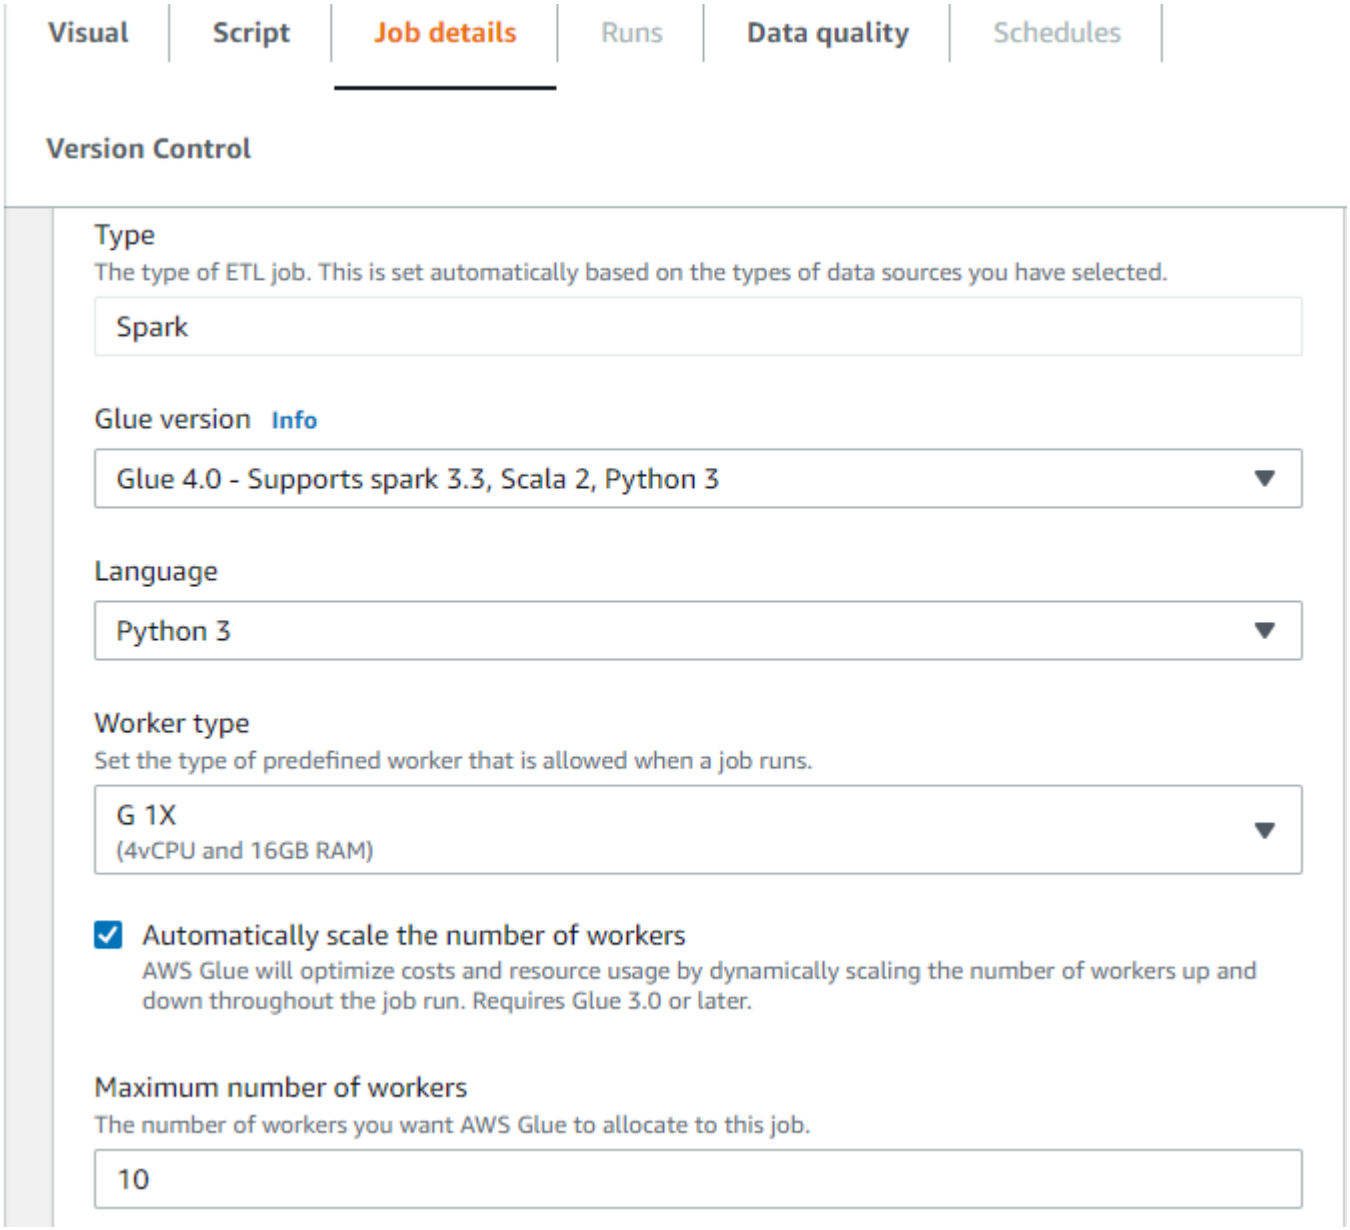

Habilitación de Auto Scaling con AWS CLI o SDK

Para habilitar el escalado automático desde la CLI de AWS para la ejecución de un trabajo, ejecute `start-job-run` con la siguiente configuración:

```
{
    "JobName": "<your job name>",
    "Arguments": {
        "--enable-auto-scaling": "true"
    },
```

```
    "WorkerType": "G.2X", // G.1X, G.2X, G.4X, G.8X, G.12X, G.16X, R.1X, R.2X, R.4X,
 and R.8X are supported for Auto Scaling Jobs
    "NumberOfWorkers": 20, // represents Maximum number of workers
    ...other job run configurations...
}
```

Una vez que haya finalizado la ejecución de un trabajo de ETL, también puede llamar a `get-job-run` para comprobar el uso real de recursos de la ejecución del trabajo en segundos de DPU. Nota: El nuevo campo DPUSeconds solo se mostrará para los trabajos por lotes en AWS Glue 4.0 o posterior con el escalado automático activado. Este campo no es compatible con trabajos de streaming.

```
$ aws glue get-job-run --job-name your-job-name --run-id jr_xx --endpoint https://
glue.us-east-1.amazonaws.com --region us-east-1
{
    "JobRun": {
        ...
        "GlueVersion": "3.0",
        "DPUSeconds": 386.0
    }
}
```

También se pueden configurar ejecuciones de trabajos con Auto Scaling mediante el AWS Glue SDK con la misma configuración.

Habilitación del escalado automático con sesiones interactivas

Para habilitar el escalado automático al crear trabajos de AWS Glue con sesiones interactivas, consulte Configuring AWS Glue interactive sessions.

Sugerencias y consideraciones

Sugerencias y consideraciones para afinar el escalado automático de AWS Glue con precisión:

- En caso de que no sepa el valor inicial del número máximo de trabajadores, puede empezar con el cálculo aproximado que se explica en Estimate AWS Glue DPU. No debe configurar un valor extremadamente alto en el número máximo de trabajadores para un volumen de datos muy bajo.
- El escalado automático para AWS Glue configura `spark.sql.shuffle.partitions` y `spark.default.parallelism` en función del número máximo de DPU (calculada con el

número máximo de trabajadores y el tipo de trabajador) configurado en el trabajo. Si prefiere el valor fijo en esas configuraciones, puede sobrescribir estos parámetros con los siguientes parámetros de trabajo:

- Clave: `--conf`
- Valor: `spark.sql.shuffle.partitions=200 --conf spark.default.parallelism=200`

- Para los trabajos de streaming, de forma predeterminada, AWS Glue no se escala automáticamente dentro de los microlotes y se requieren varios microlotes para iniciar el escalado automático. En caso de que desee habilitar el escalado automático en microlotes, proporcione `--auto-scale-within-microbatch`. Para obtener más información, consulte Job parameter reference.

Monitorear Auto Scaling con las métricas de Amazon CloudWatch.

Las métricas de ejecutor de CloudWatch se encuentran disponibles para sus trabajos de AWS Glue 3.0 o posterior si habilita el escalado automático. Las métricas se pueden utilizar para monitorear la demanda y la utilización optimizada de los ejecutores en sus aplicaciones Spark habilitadas con Auto Scaling. Para obtener más información, consulte Supervisión de AWS Glue con métricas de Amazon CloudWatch.

También puede utilizar las métricas de observabilidad de AWS Glue para obtener información sobre la utilización de los recursos. Por ejemplo, al supervisar `glue.driver.workerUtilization`, puede supervisar la cantidad de recursos que se usó realmente con y sin el escalado automático. Por otro ejemplo, al supervisar `glue.driver.skewness.job` y `glue.driver.skewness.stage`, puede ver cómo están sesgados los datos. Esa información le ayudará a decidir si se habilita el escalado automático y se afinan las configuraciones. Para obtener más información, consulte Supervisión con Monitorización con métricas de observabilidad de AWS Glue.

- glue.driver.ExecutorAllocationManager.executors.numberAllExecutors
- glue.driver.ExecutorAllocationManager.executors.numberMaxNeededExecutors

Para obtener más información sobre estas métricas, consulte Monitorización de la planificación de la capacidad de DPU.

> **Note**
>
> Las métricas de ejecución de CloudWatch no están disponibles para las sesiones interactivas.

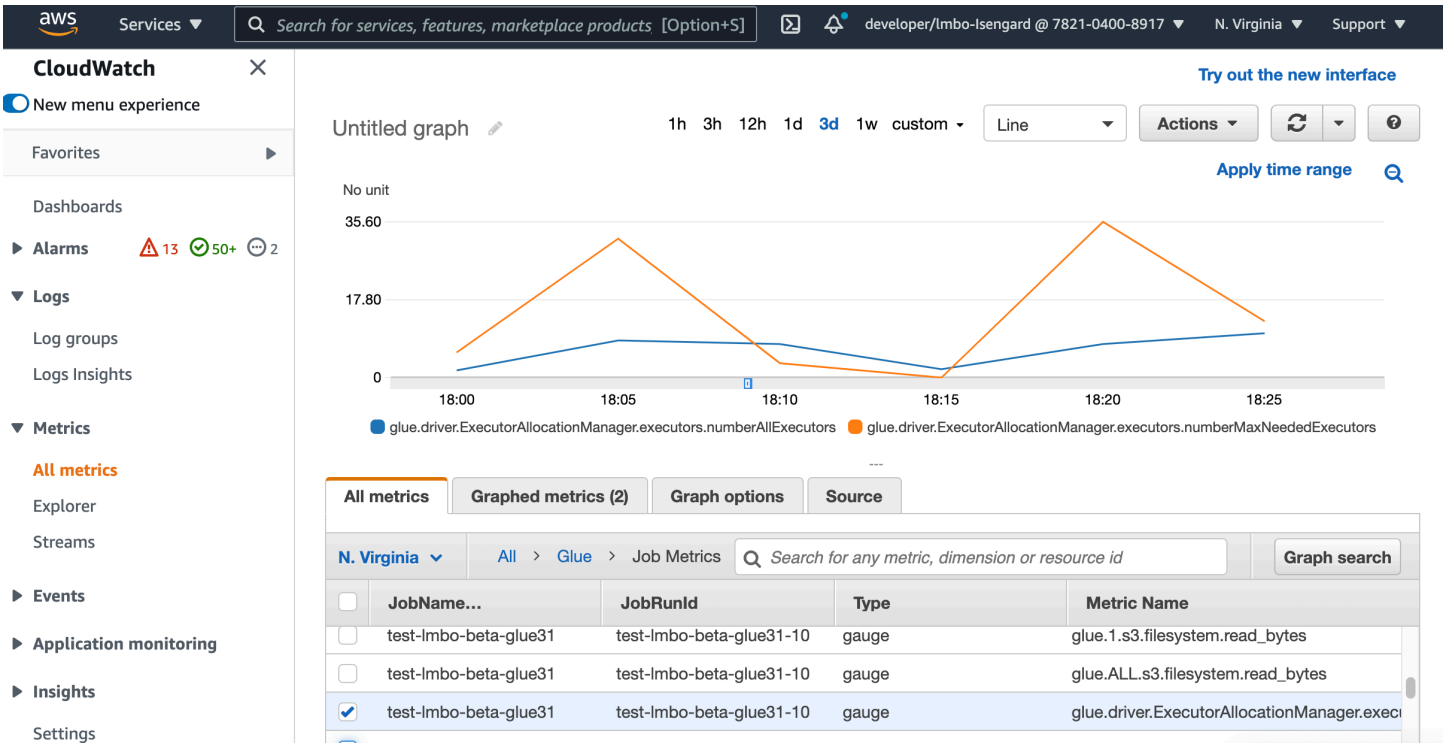

Supervisión del escalado automático con Registros de Amazon CloudWatch

Si usa sesiones interactivas, puede supervisar el número de ejecutores al activar los Registros de Amazon CloudWatch continuos y buscar “executor” en los registros, o bien mediante la interfaz de usuario de Spark. Para ello, utilice el comando mágico `%%configure` para habilitar el registro continuo junto con `enable auto scaling`.

```
%%configure{
    "--enable-continuous-cloudwatch-log": "true",
    "--enable-auto-scaling": "true"
}
```

En los eventos de registro de Amazon CloudWatch, busque “executor” en los registros:

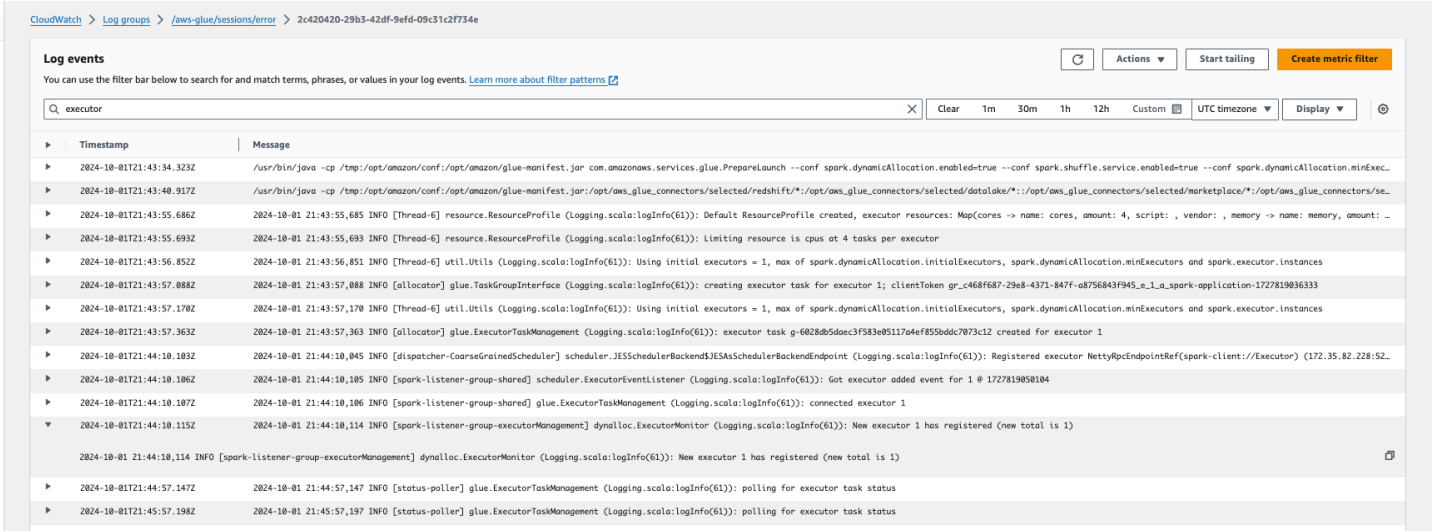

Monitorear Auto Scaling con la IU de Spark

Con Auto Scaling habilitado, también puede supervisar los ejecutores que se agregan y eliminan con escalado vertical y reducción vertical dinámicos en función de la demanda de sus trabajos de AWS Glue mediante la IU de Glue Spark. Para obtener más información, consulte Habilitación de la interfaz de usuario web de Apache Spark para trabajos de AWS Glue.

Cuando usa sesiones interactivas desde el cuaderno de Jupyter, puede ejecutar el siguiente comando mágico para habilitar el escalado automático junto con la interfaz de usuario de Spark:

```
%%configure{
    "--enable-auto-scaling": "true",
    "--enable-continuous-cloudwatch-log": "true"
}
```

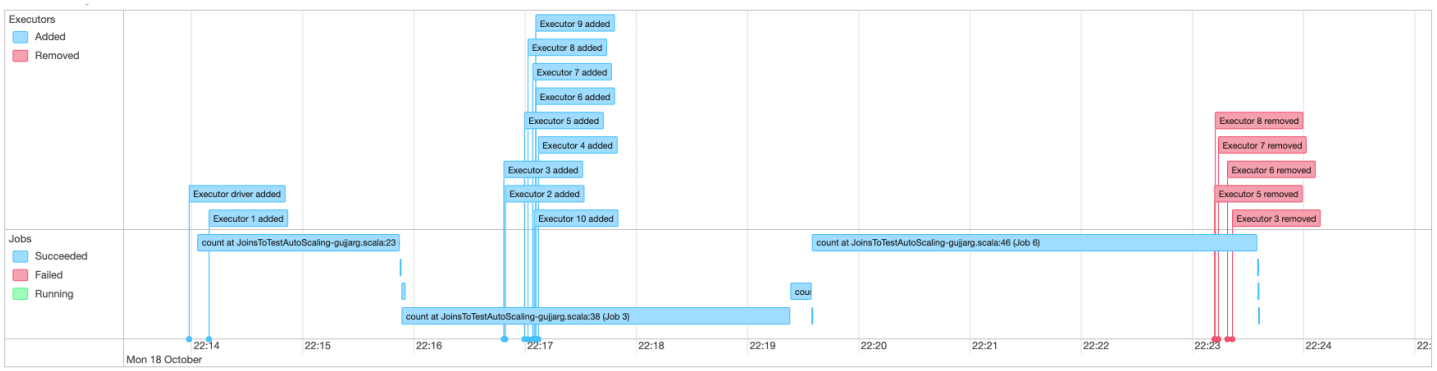

Supervisión del uso de DPU en ejecución de trabajos de Auto Scaling

Puede utilizar la Vista de ejecución de trabajos de AWS Glue Studio para comprobar el uso de DPU de los trabajos de escalado automático.

1. Elija Supervisión en el panel de navegación de AWS Glue Studio. Aparecerá la página Monitoring (Supervisión).
2. Desplácese hacia abajo hasta el gráfico Job runs (Ejecuciones de trabajos).
3. Navegue hasta la ejecución del trabajo que le interese y desplácese hasta la columna DPU hours (Horas de DPU) para comprobar el uso de la ejecución del trabajo en cuestión.

Limitaciones

En la actualidad, el streaming de AWS Glue de Auto Scaling no soporta una unión de DataFrame en streaming con un DataFrame estático creado fuera de `ForEachBatch`. Un DataFrame estático creado dentro de `ForEachBatch` funcionará según lo previsto.

Partición de cargas de trabajo con ejecución limitada

Los errores en las aplicaciones de Spark suelen deberse a scripts de Spark ineficientes, a la ejecución distribuida en memoria de transformaciones a gran escala y a anomalías de los conjuntos de datos. Hay muchas razones que pueden causar problemas de memoria al controlador o al ejecutor, por ejemplo, un sesgo de datos, una lista con demasiados objetos o mezclas aleatorias importantes de datos. Estos problemas suelen aparecer cuando se procesan grandes cantidades de datos pendientes con Spark.

AWS Glue le permite resolver problemas de memoria insuficiente y facilitar el procesamiento de ETL con la partición de carga de trabajo. Si habilita la partición de carga de trabajo, cada ejecución de trabajo de ETL solo selecciona datos no procesados, con un límite superior en el tamaño del conjunto de datos o la cantidad de archivos que se van a procesar con esta ejecución de trabajo. Las ejecuciones de trabajos futuras procesarán los datos restantes. Por ejemplo, si hay 1000 archivos que necesitan ser procesados, puede establecer el número de archivos en 500 y separarlos en dos ejecuciones de trabajos.

La partición de carga de trabajo sólo se admite para orígenes de datos de Amazon S3.

Habilitar la partición de carga de trabajo

Puede habilitar la ejecución limitada mediante la configuración manual de las opciones en el script o mediante el agregado de propiedades a la tabla del catálogo.

Para habilitar la partición de carga de trabajo con ejecución limitada en el script:

1. Para evitar el reprocesamiento de datos, habilite los marcadores de trabajos en el trabajo nuevo o en el trabajo existente. Para obtener más información, consulte Seguimiento de los datos procesados mediante marcadores de trabajo.
2. Modifique el script y establezca el límite delimitado en las opciones adicionales de la API `getSource` de AWS Glue. También debe establecer el contexto de transformación para que el marcador de trabajo almacene el elemento `state`. Por ejemplo:

   Python

   ```
   glueContext.create_dynamic_frame.from_catalog(
       database = "database",
       table_name = "table_name",
       redshift_tmp_dir = "",
       transformation_ctx = "datasource0",
       additional_options = {
           "boundedFiles" : "500", # need to be string
         # "boundedSize" : "1000000000" unit is byte
       }
   )
   ```

   Scala

   ```
   val datasource0 = glueContext.getCatalogSource(
       database = "database", tableName = "table_name", redshiftTmpDir = "",
       transformationContext = "datasource0",
       additionalOptions = JsonOptions(
           Map("boundedFiles" -> "500") // need to be string
         //"boundedSize" -> "1000000000" unit is byte
       )
   ).getDynamicFrame()
   ```

   ```
   val connectionOptions = JsonOptions(
       Map("paths" -> List(baseLocation), "boundedFiles" -> "30")
   ```

```
)
val source = glueContext.getSource("s3", connectionOptions, "datasource0", "")
```

Para habilitar la partición de carga de trabajo con ejecución limitada en la tabla de Data Catalog:

1. Configure los pares clave-valor en el campo `parameters` de la estructura de su tabla en Data Catalog. Para obtener más información, consulte Visualización y edición de los detalles de la tabla.
2. Configure el límite superior para el tamaño del conjunto de datos o la cantidad de archivos procesados:

   - Configure el `boundedSize` al tamaño objetivo del conjunto de datos en bytes. La ejecución del trabajo se detendrá después de alcanzar el tamaño objetivo de la tabla.
   - Configure `boundedFiles` a la cantidad de archivos objetivo. La ejecución del trabajo se detendrá después de procesar la cantidad de archivos objetivo.

> **Note**
>
> Solo debe configurar uno entre `boundedSize` o `boundedFiles`, ya que solo se soporta un único límite.

Configuración de un desencadenador de AWS Glue para ejecutar el trabajo en forma automática

Una vez que haya habilitado la ejecución limitada, puede configurar un desencadenador de AWS Glue para ejecutar el trabajo en forma automática y cargar los datos de forma progresiva en ejecuciones secuenciales. Diríjase a la consola de AWS Glue y cree un desencadenador, configure la hora programada y adjúntelo a su trabajo. Se desencadenará automáticamente la siguiente ejecución del trabajo y se procesará el nuevo lote de datos.

También puede utilizar los flujos de trabajo de AWS Glue u orquestar múltiples trabajos para procesar datos de diferentes particiones en paralelo. Para obtener más información, consulte Desencadenadores de AWS Glue y Flujos de trabajo de AWS Glue.

Para obtener más información sobre los casos de uso y las opciones, consulte el blog Optimizing Spark applications with workload partitioning in AWS Glue (Optimización de aplicaciones de Spark con partición de carga de trabajo en Glue).

Problemas conocidos de AWS Glue

Tenga presente los siguientes problemas conocidos de AWS Glue.

Temas

- Prevención del acceso a datos entre trabajos

Prevención del acceso a datos entre trabajos

Considere la siguiente situación: tiene dos trabajos de AWS Glue Spark en una única cuenta de AWS, cada uno de ellos ejecutándose en un clúster de AWS Glue Spark independiente. Los trabajos utilizan conexiones de AWS Glue para obtener acceso a los recursos de la misma nube virtual privada (VPC). En esta situación, un trabajo que se ejecuta en un clúster podría tener acceso a los datos del trabajo que se ejecuta en el otro clúster.

El siguiente diagrama ilustra un ejemplo de esta situación.

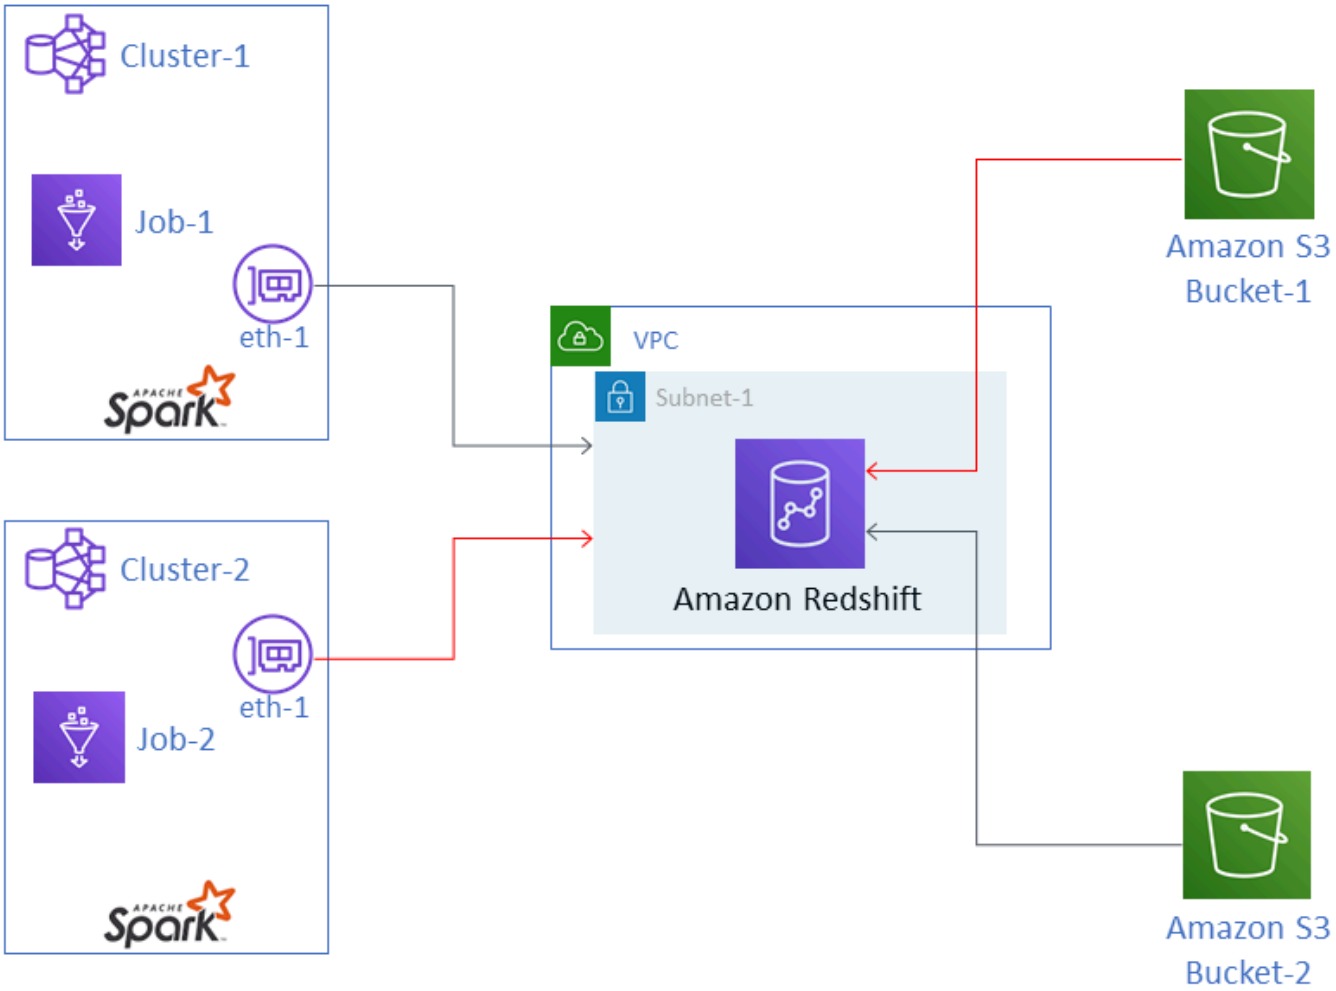

En el diagrama, `Job-1` de AWS Glue se ejecuta en `Cluster-1`, y Job-2 se ejecuta en `Cluster-2`. Ambos trabajos funcionan con la misma instancia de Amazon Redshift, que reside en la `Subnet-1` de una VPC. La `Subnet-1` podría ser una subred pública o privada.

`Job-1` transforma los datos del `Bucket-1` de Amazon Simple Storage Service (Amazon S3) y escribe los datos a Amazon Redshift. `Job-2` hace lo mismo con los datos en el `Bucket-2`. `Job-1` utiliza el rol (IAM) `Role-1` de AWS Identity and Access Management (no se muestra), que otorga acceso al `Bucket-1`. `Job-2` utiliza el `Role-2` (no se muestra), que otorga acceso al `Bucket-2`.

Estos trabajos tienen rutas de red que les permiten comunicarse con los clústeres de los demás y, por lo tanto, obtener acceso a los datos de los demás. Por ejemplo, `Job-2` podría obtener acceso a los datos de `Bucket-1`. En el diagrama, se muestra como la ruta en rojo.

Para evitar esta situación, le recomendamos asociar diferentes configuraciones de seguridad a `Job-1` y `Job-2`. Al asociar las configuraciones de seguridad, el acceso entre trabajos a los datos se bloquea en virtud de los certificados que AWS Glue crea. Las configuraciones de seguridad pueden ser configuraciones ficticias. Es decir, puede crear las configuraciones de seguridad sin habilitar el cifrado de datos de Amazon S3, datos de Amazon CloudWatch o marcadores de trabajos. Las tres opciones de cifrado se pueden deshabilitar.

Para obtener información acerca de las configuraciones de seguridad, consulte the section called "Cifrado de datos escritos por AWS Glue".

Para asociar una configuración de seguridad a un trabajo

1. Abra la consola de AWS Glue en https://console.aws.amazon.com/glue/.
2. En la página Configure the job properties (Configurar propiedades del trabajo) del trabajo, expanda la sección Security configuration, script libraries and job parameters (Seguridad, configuración, bibliotecas de scripts y parámetros de trabajo).
3. Seleccione una configuración de seguridad en la lista.

Historial de documentación para AWS Glue

Cambio	Descripción	Fecha
La calidad de datos de AWS Glue ahora admite el etiquetado de reglas para mejorar los informes.	La calidad de datos de AWS Glue ahora admite el etiquetado de reglas, lo que le permite organizar y analizar los resultados de calidad de los datos de manera más eficaz. Puede consultar los resultados por etiquetas específicas para identificar reglas fallidas dentro de categorías concretas, contar los resultados de las reglas por equipo o dominio y crear informes específicos para distintas partes interesadas. Para obtener más información, consulte Etiquetas.	21 de noviembre de 2025
La calidad de datos de AWS Glue ahora admite consultas de preprocesamiento.	La calidad de datos de AWS Glue ahora admite constantes en DQDL, lo que permite definir valores constantes y hacer referencia a ellos a lo largo de todo el script. Esto ayuda a evitar problemas relacionados con los límites de tamaño de las consultas al trabajar con instrucciones SQL de gran tamaño. Para obtener más información, consulte Constantes.	21 de noviembre de 2025

Compatibilidad con los nuevos tipos de trabajadores G.12X, G.16X y los tipos de trabajadores R con memoria optimizada	Se agregó compatibilidad con los nuevos tipos de trabajadores G.12X, G.16X y los tipos de trabajadores R.1X, R.2X, R.4X y R.8X con memoria optimizada para los trabajos de AWS Glue. Estos nuevos tipos de trabajadores ofrecen opciones adicionales de computación y memoria para diferentes requisitos de cargas de trabajo. Para obtener más información, consulte Adding jobs in AWS Glue.	30 de enero de 2025
Compatibilidad con 14 nuevos conectores nativos de SaaS para AWS Glue	Se agregaron 14 nuevos conectores nativos de SaaS a AWS Glue. Para obtener más información, consulte Adding an AWS Glue connection.	30 de enero de 2025
Compatibilidad con 16 nuevos conectores nativos de SaaS para AWS Glue	Se agregaron otros 16 conectores nativos de SaaS a AWS Glue. Para obtener más información, consulte Adding an AWS Glue connection.	17 de diciembre de 2024

Generación automática de estadísticas de columnas	Calidad de datos de AWS Glue ahora admite tablas de Amazon SageMaker AI LakeHouse y tablas de Iceberg, Delta y HUDI administradas por AWS Lake Formation en Catálogo de datos y ETL. Para obtener más información, consulte Calidad de datos de AWS Glue.	6 de diciembre de 2024
Compatibilidad con integraciones sin ETL	El conjunto de integraciones sin ETL está totalmente administrado por AWS y minimiza la necesidad de crear canalizaciones de datos de ETL. Para obtener más información, consulte Integraciones sin ETL.	3 de diciembre de 2024
Compatibilidad con conexiones reutilizables	Un nuevo esquema de conexiones de AWS Glue proporciona una forma unificada de administrar las conexiones de datos entre servicios AWS y aplicaciones AWS Glue, como Amazon Athena y Amazon SageMaker Unified Studio. Para obtener más información, consulte Conexión a los datos.	3 de diciembre de 2024

Compatibilidad con la versión 5.0 de AWS Glue.	Se agregó información acerca de la compatibilidad con la versión 5.0 de AWS Glue. Las características incluyen una actualización de Apache Spark a la versión 3.52, una actualización de Java a la versión 17, actualizaciones del formato de tabla abierta, control de acceso detallado y nativo de Spark, la integración de SageMaker Lakehouse y la abstracción de almacenamiento de datos, la compatibilidad con SageMaker Unified Studio y mucho más. Para obtener más información, consulte las Notas de la versión de AWS Glue y Migración de trabajos de AWS Glue a la versión 5.0 de AWS Glue.	3 de diciembre de 2024

Conexión a AWS Glue Data Catalog mediante el punto de conexión REST de Iceberg de AWS Glue	El punto de conexión de REST de Iceberg de AWS Glue admite las operaciones de API indicadas en la especificación REST de Apache Iceberg. Si usa un cliente REST de Iceberg, puede conectar la aplicación que se ejecuta en un motor de análisis al catálogo de REST hospedado en el catálogo de datos. Para obtener más información consulte Acceso al catálogo de datos.	3 de diciembre de 2024
Generación automática de estadísticas de columnas	Genere automáticamente estadísticas de columnas para tablas nuevas de AWS Glue Data Catalog. Para obtener más información, consulte Automatic column statistics generation.	3 de diciembre de 2024
Soporte para actualizaciones de IA generativa para Apache Spark en AWS Glue	La función Actualizaciones de Spark en AWS Glue permite que los ingenieros de datos y desarrolladores actualicen y migren sus trabajos actuales de Spark de AWS Glue a las versiones más recientes de Spark mediante la IA generativa. Para obtener más información, consulte Upgrade analysis with AI.	22 de noviembre de 2024

Soporte para resolución de problemas de IA generativa para Apache Spark en AWS Glue	La resolución de problemas mediante IA generativa para trabajos de Apache Spark en AWS Glue ayuda a los ingenieros y científicos de datos a diagnosticar y solucionar problemas en sus aplicaciones de Spark con facilidad. Para obtener más información, consulte Troubleshooting Spark jobs with AI.	22 de noviembre de 2024
Soporte para que optimizadores de Iceberg accedan a los buckets de Amazon S3 en una VPC	AWS Glue Data Catalog admite los optimizadores de tablas de Iceberg para acceder a los buckets de Amazon S3 desde una nube privada virtual (VPC) específica mediante una conexión de red de AWS Glue. Para obtener más información, consulte Optimización de las tablas de Iceberg.	20 de noviembre de 2024
Soporte para nueve nuevos conectores nativos de SaaS para AWS Glue	Se agregaron otros nueve conectores nativos de SaaS para AWS Glue. Para obtener más información, consulte Adding an AWS Glue connection.	19 de noviembre de 2024

Soporte para diez nuevos conectores nativos de SaaS para AWS Glue	Se agregaron otros diez conectores nativos de SaaS para AWS Glue. Para obtener más información, consulte Adding an AWS Glue connection.	15 de noviembre de 2024
Soporte para la puesta en cola de las ejecuciones de trabajos de AWS Glue ETL	Puede activar la puesta en cola de las ejecuciones de trabajos para ejecutarlas más adelante, cuando no puedan ejecutarse inmediatamente debido a las Service Quotas. Para obtener más informaci ón, consulte Configuración de las propiedades de trabajos de Spark en AWS Glue.	3 de septiembre de 2024
Cambios en la política actualizados	Se han documentado los cambios a las políticas AwsGlueSessionUser RestrictedNotebookPolicy y AwsGlueSessionUser RestrictedNotebookServiceRo le necesarios para poder admitir tag-on-create para las sesiones con clave de etiqueta de propietario. Para obtener más información, consulte Actualizaciones de AWS Glue a políticas administradas de AWS.	30 de agosto de 2024

La detección de anomalías y las reglas dinámicas ya están disponibles con carácter general	Calidad de datos de AWS Glue utiliza un algoritmo de machine learning para aprender de las tendencias pasadas y, luego, predecir los valores futuros con el fin de detectar anomalías. Las reglas dinámicas le permiten proporcionar umbrales dinámicos. Para obtener más información, consulte Optimización del rendimiento de consultas para las tablas de Iceberg.	7 de agosto de 2024
Cambios en la política actualizados	Se han documentado los cambios a las políticas AwsGlueSessionUserRestrictedPolicy y AwsGlueSessionUserRestrictedServiceRole necesarios para poder admitir tag-on-create para las sesiones con clave de etiqueta de propietario. Para obtener más información, consulte Actualizaciones de AWS Glue a políticas administradas de AWS.	5 de agosto de 2024

La generación de estadísticas de las columnas de las tablas de Iceberg ya está disponible	AWS Glue permite calcular y actualizar el número de valores distintos (number of distinct values, NDV) para cada columna de las tablas de Iceberg. Para obtener más información, consulte Detección de anomalías en Calidad de datos de AWS Glue y Reglas dinámicas.	9 de julio de 2024
Compatibilidad con perfiles de uso de AWS Glue	Los administradores pueden crear perfiles de uso de AWS Glue para varias clases de usuarios dentro de la cuenta, como desarrolladores, evaluadores y equipos de productos. Esta flexibilidad permite a los administradores aplicar diferentes controles de uso y costos para cada clase de usuarios. Para obtener más información, consulte Configuración de perfiles de uso de AWS Glue.	18 de junio de 2024

Compatibilidad con un conector de Salesforce para AWS Glue para Spark	Se agregó información sobre un nuevo conector de AWS Glue para Salesforce. Esta característica le permite usar AWS Glue para Spark y así poder leer y escribir en Salesforce en AWS Glue versión 4.0 y versiones posteriores. Para obtener más información, consulte Conectarse a Salesforce.	22 de mayo de 2024

Integración de datos de Amazon Q en AWS Glue (GA)	La integración de datos de Amazon Q en AWS Glue es una nueva capacidad de IA generativa de AWS Glue que permite a los ingenieros de datos y a los desarrolladores de ETL crear trabajos de integración de datos usando un lenguaje natural. Los ingenieros y desarrolladores pueden pedir a Q que cree trabajos, solucione problemas y responda preguntas sobre AWS Glue y la integración de datos. Para obtener más información, consulte Integración de datos de Amazon Q en AWS Glue. Esta característica incluye una actualización de las políticas de `AwsGlueSessionUserRestrictedPolicy`, `AwsGlueSessionUserRestrictedNotebookServiceRole` y `AwsGlueSessionUserRestrictedServiceRole` administradas por AWS. Para obtener más información, consulte Actualizaciones de AWS Glue a políticas administradas de AWS.	30 de abril de 2024

Integración de datos de Amazon Q en AWS Glue (vista previa)	La integración de datos de Amazon Q en AWS Glue es una nueva capacidad de IA generativa de AWS Glue que permite a los ingenieros de datos y a los desarrolladores de ETL crear trabajos de integración de datos usando un lenguaje natural. Los ingenieros y desarrolladores pueden pedir a Q que cree trabajos, solucione problemas y responda preguntas sobre AWS Glue y la integración de datos. Para obtener más información, consulte Integración de datos de Amazon Q en AWS Glue. Esta característica incluye una actualización de la política gestionada de `AwsGlueSessionUserRestrictedNotebookPolicy` AWS. Para obtener más información, consulte las actualizaciones de AWS Glue a las políticas administradas de AWS.	30 de enero de 2024

Actualización de la documentación para la transmisión de AWS Glue	Se agregó un nuevo capítulo con contenido nuevo y reorganizado sobre el streaming de AWS Glue. Dicho contenido describe cómo funciona la transmisión con AWS Glue, las características del procesamiento de datos en tiempo real y cómo supervisar los trabajos de transmisión. Para obtener más información, consulte Transmisión de AWS Glue.	27 de diciembre de 2023
Soporte para el uso de una detección de datos confidenciales detallada	La transformación Detectar datos confidenciales ofrece la capacidad de detectar, enmascarar o eliminar entidades definidas por el usuario o predefinidas por AWS Glue. Las acciones detalladas permiten además aplicar una acción específica por entidad. Para obtener más información, consulte Uso de una detección de datos confidenciales detallada.	26 de noviembre de 2023

Soporte para la monitorización de trabajos con métricas de observabilidad de AWS Glue	Use las métricas de observabilidad de AWS Glue para obtener información sobre lo que ocurre dentro de sus trabajos de AWS Glue for Apache Spark y así mejorar la clasificación y el análisis de los problemas. Para obtener más información, consulte Monitoreo con las métricas de observabilidad de AWS Glue.	26 de noviembre de 2023
Soporte para la detección de anomalías en calidad de los datos de AWS Glue	AWS GlueLa detección de anomalías en la calidad de los datos de aplica algoritmos de machine learning (ML) a las estadísticas de datos a lo largo del tiempo para detectar patrones anormales y problemas ocultos de calidad de los datos que son difíciles de detectar con reglas. Para obtener más información, consulte Detección de anomalías de calidad de datos de AWS Glue.	26 de noviembre de 2023

Actualización del comportamiento de registro predeterminado de la interfaz de usuario de Spark	Los trabajos de Spark que generen registros de la interfaz de usuario de Spark ahora se escribirán con un patrón de nombre de archivo diferente, a fin de que sean compatibles con la interfaz de usuario de Spark en la consola de AWS Glue. Esto no modifica el comportamiento de los registros de CloudWatch. Puede volver al comportamiento anterior si actualiza la configuración de su trabajo. Para obtener más información, consulte Monitorización de trabajos mediante la interfaz de usuario web de Apache Spark.	17 de noviembre de 2023

Soporte para nuevas fuentes de datos en AWS Glue para Spark	Las conexiones a Amazon OpenSearch Service, Azure SQL, Azure Cosmos para NoSQL, SAP HANA Teradata Vantage y Vertica ahora se admiten de forma nativa desde AWS Glue. Además, las conexiones a estos orígenes de datos, junto con MongoDB, ahora están disponibles para su uso en el editor visual de AWS Glue Studio. Para obtener más información, consulte Tipos de conexión y opciones para ETL en AWS Glue para Spark para conocer la compatibilidad de AWS Glue para Spark y Añadir una conexión AWS Glue para conocer más sobre su uso en el editor visual de AWS Glue Studio.	17 de noviembre de 2023
Soporte para generar estadísticas de columnas	Puede calcular estadísticas a nivel de columna para tablas AWS Glue Data Catalog en formatos de datos como Parquet, ORC, JSON, ION, CSV y XML sin necesidad de configurar canalizaciones de datos adicionales. Para obtener más información, consulte Trabajar con las estadísticas de las columnas.	16 de noviembre de 2023

Soporte para la compactación de datos para tablas Iceberg	Para mejorar el rendimiento de lectura de los servicios de análisis de AWS, como Amazon Athena, Amazon EMR, y los trabajos de ETL de AWS Glue, el Catálogo de datos proporciona una compactación gestionada (un proceso que compacta objetos pequeños de Amazon S3 para convertirlos en objetos más grandes) para las tablas Iceberg del Catálogo de datos. Para obtener más información, consulte Optimización de las tablas de Iceberg.	13 de noviembre de 2023
Actualizar el comportamiento de espera al ejecutar un trabajo	Las ejecuciones de tareas de intérprete de comandos estándar de Spark y Python ahora pasarán a `WAITING` en determinadas situaciones, al contrario de pasar inmediatamente a `FAILED`. Para obtener más información, consulte Estados de ejecución de trabajos de AWS Glue.	8 de noviembre de 2023

AWS Glue Studio Guía del usuario de AWS Glue consolidada en la guía para desarrolladores de	La guía del usuario de AWS Glue Studio se ha trasladado a la guía para desarrolladores para crear una guía de usuario única y unificada para AWS Glue Studio, la consola de AWS Glue y el acceso de AWS Glue Studio mediante programación.	25 de octubre de 2023
Actualización de la política administrada de AWS AWSGlueServiceNote bookRole	Se agregó información sobre una actualización secundaria a la política administrada de AWS AWSGlueServiceNote bookRole. Para obtener más información, consulte Actualizaciones de AWS Glue a las políticas administradas de AWS	9 de octubre de 2023
AWS Glue Studio admite cinco nuevas transformaciones integradas	AWS Glue Studio admite las siguientes cinco transform aciones integradas nuevas: la coincidencia de registros, la eliminación de filas nulas, la columna Parse JSON, la ruta de extracción de JSON y el extractor de expresiones regulares. Para obtener más información, consulte Edición de nodos de transformación de datos administrados por AWS Glue.	11 de agosto de 2023

Actualización a la política administrada de AWS AWSGlueServiceRole	Se agregó información sobre una actualización menor a la política administrada de AWS AWSGlueServiceRole . Para obtener más informaci ón, consulte Actualizaciones de AWS Glue a las políticas administradas de AWS.	4 de agosto de 2023
Compatibilidad para el rastreo de tablas de Apache Hudi	Se agregó información sobre cómo usar AWS Glue para rastrear tablas en buckets de Amazon S3 y cómo registrar las tablas de Hudi en AWS Glue Data Catalog. Para obtener más información, consulte ¿Qué almacenes de datos puedo rastrear? y Propiedades del rastreador.	21 de julio de 2023
Actualización a la política AWSGlueConsoleFullAccess administrada por AWS	Se agregó información sobre una actualización menor a la política AWSGlueCo nsoleFullAccess administr ada por AWS. Para obtener más información, consulte Actualizaciones de AWS Glue a las políticas administradas de AWS.	14 de julio de 2023

Compatibilidad para el rastreo de tablas de Apache Iceberg	Se agregó información sobre cómo usar AWS Glue para rastrear tablas de Iceberg en buckets de Amazon S3 y cómo registrar las tablas de Iceberg en AWS Glue Data Catalog. Para obtener más información, consulte ¿Qué almacenes de datos puedo rastrear? y Propiedades del rastreador.	7 de julio de 2023
Compatibilidad para AWS Glue para Ray	Se agregó información sobre AWS Glue para Ray, un nuevo motor que puede respaldar trabajos de AWS Glue. Se reorganizó el contenido existente de AWS Glue con Spark para eliminar la ambigüedad.	30 de mayo de 2023

Compatibilidad para Calidad de datos de AWS Glue (GA)	Calidad de datos de AWS Glue se encuentra disponible para el público en general. AWS Glue lo ayuda a evaluar y supervisar la calidad de los datos. Para obtener información sobre cómo utilizar Calidad de los datos de AWS Glue con el Catálogo de datos, consulte Calidad de datos de AWS Glue. Para obtener más información sobre Calidad de datos de AWS Glue para AWS Glue Studio, consulte Evaluación de la calidad de los datos con AWS Glue Studio.	24 de mayo de 2023
Compatibilidad para tipos de trabajos más grandes para trabajos de Apache Spark	Ya se encuentra disponible la asistencia para los tipos de trabajo de `G.4X` y `G.8X` para los trabajos de Apache Spark. Estos tipos de trabajos son adecuados para los trabajos cuyas cargas de trabajo contienen las transformaciones, agregaciones, combinaciones y consultas más exigentes. Para obtener más información, consulte Agregar trabajos en AWS Glue.	8 de mayo de 2023

Compatibilidad para crear índices de particiones cuando se rastrean tablas	Se agregó información sobre cómo los rastreadores admiten la creación de índices de partición para las tablas que detecta el rastreador. Para obtener más información, consulte Establecimiento de opciones de configuración de rastreadores.	24 de abril de 2023
Compatibilidad para métricas de uso de recursos	Se agregó información sobre la visualización del uso de recursos del servicio y la configuración de alarmas en Amazon CloudWatch. Para obtener más información, consulte AWS Glue resource monitoring.	7 de abril de 2023
Actualización a la política AWSGlueConsoleFullAccess administrada por AWS	Se agregó información sobre una actualización menor a la política AWSGlueConsoleFullAccess administrada por AWS. Para obtener más información, consulte Actualizaciones de AWS Glue a las políticas administradas de AWS.	28 de marzo de 2023

Se agregó una guía para utilizar AWS Glue con un SDK de AWS con ejemplos	La Guía para desarroll adores de AWS Glue incluye dos secciones nuevas que proporcionan información para utilizar AWS Glue con un SDK de AWS. Para obtener más información, consulte Uso de AWS Glue con un SDK de AWS y Ejemplos de código para AWS Glue con SDK de AWS.	23 de febrero de 2023
Actualización de la documentación para IAM con AWS Glue	Se reorganizó y se agregó información sobre el uso de IAM con AWS Glue. Para obtener más información, consulte Administración de identidad y acceso para AWS Glue.	15 de febrero de 2023
Soporte para la ejecución de trabajos de ETL de streaming en AWS Glue, versión 4.0	Se agregó información sobre la compatibilidad para ejecutar trabajos de ETL de streaming en la versión 4.0 de Glue y sobre las nuevas opciones para conectarse a un clúster de Kafka o a un clúster de Amazon Managed Streaming para Apache Kafka y Amazon Kinesis Data Streams. Para obtener más información, consulte Agregar trabajos de ETL de streaming en AWS Glue y Tipos de conexión y opciones para ETL en AWS Glue.	8 de febrero de 2023

Compatibilidad con el rastreo de orígenes de datos de MongoDB Atlas	Se agregó información sobre el uso de AWS Glue para rastrear los orígenes de datos de MongoDB Atlas. Para obtener más información, consulte ¿Qué almacenes de datos puedo rastrear?, Propiedades de conexión de MongoDB y MongoDB Atlas y Utilización de la conexión de MongoDB o MongoDB Atlas.	6 de febrero de 2023

Compatibilidad con el rastreo de tablas de Delta Lake mediante un conector nativo de Delta Lake	Se agregó información sobre el uso de AWS Glue para rastrear tablas de Delta Lake mediante un conector nativo de Delta Lake. Esta característica permite usar motores de consulta de AWS para consultar directamente el registro de transacciones de Delta y usar características como viaje en el tiempo y garantías ACID, y sincronizar los metadatos de Delta Lake de los archivos de transacciones de Amazon S3 con el catálogo de datos para habilitar los permisos de columna en sus consultas en Lake Formation. Para obtener más información, consulte Cómo especificar opciones de configuración para un almacén de datos de Delta Lake y Consulta de tablas de Delta Lake.	15 de diciembre de 2022

Compatibilidad con Calidad de datos de AWS Glue (versión preliminar)	Ya está disponible la compatibilidad con Calidad de datos de AWS Glue (versión preliminar). AWS Glue Calidad de datos ayuda a evaluar y supervisar la calidad de los datos cuando utiliza la versión 3.0 de AWS Glue. Para obtener información sobre cómo utilizar Calidad de los datos de AWS Glue con el Catálogo de datos, consulte Calidad de los datos de AWS Glue (versión preliminar). Para obtener más informaci ón sobre Calidad de datos de AWS Glue para AWS Glue Studio, consulte Evaluación de la calidad de los datos con AWS Glue Studio.	30 de noviembre de 2022

Compatibilidad con un nuevo conector de Spark para Amazon Redshift con nuevas características y mejoras de rendimiento	Ya hay compatibilidad con un nuevo conector de Spark para Amazon Redshift con un nuevo controlador de JDBC que se puede utilizar con tareas de ETL de AWS Glue para crear aplicaciones de Apache Spark que lean datos desde Amazon Redshift y escriban en este como parte de las canalizaciones de ingesta y transformación de datos. Para más informaci ón, consulte Movimiento de datos desde y hacia Amazon Redshift.	29 de noviembre de 2022

Compatibilidad con la versión 4.0 de AWS Glue.	Se agregó información acerca de la compatibilidad con la versión 4.0 de AWS Glue. Las características incluyen la compatibilidad nativa para marcos de lagos de datos abiertos con Apache Hudi, Delta Lake y Apache Iceberg, y la compatibilidad nativa con el complemento Cloud Shuffle Storage basado en Amazon S3 (un complemento de Apache Spark) para utilizar Amazon S3 para una capacidad de almacenamiento aleatoria y elástica. Para obtener más información, consulte las Notas de la versión de AWS Glue y Migración de trabajos de AWS Glue a la versión 4.0 de AWS Glue.	28 de noviembre de 2022
AWS Glue Studio ahora ofrece transformaciones visuales personalizadas	Las transformaciones visuales personalizadas permiten a los clientes definir, reutilizar y compartir la lógica de ETL específica de la empresa entre sus equipos. Para obtener más información, consulte Custom visual transforms (Transformaciones visuales personalizadas).	28 de noviembre de 2022

Compatibilidad con el uso del rastreador de AWS Glue para publicar metadatos de los almacenes de datos de JDBC	Ya está disponible la compatibilidad con el uso del rastreador de AWS Glue para publicar metadatos, como comentarios y tipos sin procesar, en el catálogo de datos de los almacenes de datos de JDBC. Para más información, consulte Parámetros establecidos en las tablas del Catálogo de datos por el rastreador, Propiedades del rastreador y Estructura JdbcTarget.	18 de noviembre de 2022
Compatibilidad con el rastreo de almacenes de datos de Snowflake	Ahora hay compatibilidad con el uso de AWS Glue para rastrear tablas y vistas de Snowflake y publicar los metadatos en Catálogo de datos como una entrada de tabla. En el caso de las tablas externas de Snowflake en Amazon S3, el rastreador también rastrea la ubicación de Amazon S3 y el tipo de formato de archivo de la tabla externa y los rellena como parámetros de la tabla. Para más información, consulte ¿Qué almacenes de datos puedo rastrear?, Propiedades de las conexiones de AWS Glue y Parámetros establecidos en las tablas del Catálogo de datos por el rastreador.	18 de noviembre de 2022

Compatibilidad con la mejora de la gestión aleatoria de las aplicaciones de Spark	Ya está disponible la compatibilidad con un nuevo complemento de Cloud Shuffle Storage para Apache Spark. Para más información, consulte Complemento de mezclas aleatorias de Spark para AWS Glue con Amazon S3 y Complemento Cloud Shuffle Storage para Apache Spark.	15 de noviembre de 2022
Se agregó soporte para los destinos del catálogo de datos al acelerar el rastreo de las notificaciones de eventos de Amazon S	Además del soporte existente para destinos de Amazon S3, ahora se ofrece soporte para acelerar los rastreos de los destinos del catálogo de datos mediante notificaciones de eventos de Amazon S3. Para obtener más información, consulte Aceleración de los rastreadores mediante las notificaciones de eventos de Amazon S3.	13 de octubre de 2022
Posibilidad de especificar el número máximo de tablas que puede crear un rastreador	Ahora es posible especificar el número máximo de tablas que el rastreador tiene permitido crear. Para obtener más información, consulte Cómo especificar el número máximo de tablas que el rastreador tiene permitido crear.	6 de septiembre de 2022

Compatibilidad con Python 3.9 de trabajos de intérprete de comandos de Python en AWS Glue	Ahora hay compatibilidad disponible para ejecutar scripts compatibles con Python 3.9 en trabajos de intérprete de comandos de Python en AWS Glue y por elegir el uso de conjuntos de bibliotecas preempaquetadas. Para obtener más información, consulte Trabajos de trabajos de intérprete de comandos de Python en AWS Glue.	11 de agosto de 2022
Compatibilidad para ejecutar trabajos no urgentes o no sensibles al tiempo de AWS Glue sobre capacidad adicional	Ahora hay compatibilidad disponible para la configura ción de ejecuciones de trabajos flexibles para trabajos no urgentes, como trabajos de preproducción, pruebas y cargas de datos únicas. Para obtener más información, consulte Adding jobs in AWS Glue.	9 de agosto de 2022
Soporte para un nuevo tipo de proceso de trabajo para el streaming de trabajos	Ya se encuentra disponibl e el soporte para el tipo de proceso de trabajo `G.025X` para trabajos de streaming de bajo volumen. Para obtener más información, consulte Agregar trabajos en AWS Glue.	14 de julio de 2022

Soporte para el uso de Kafka SASL en conexiones AWS Glue	Ya se encuentra disponible el soporte para el uso de Kafka SASL en conexiones de AWS Glue. Para obtener más información, consulte Propiedades de conexión de AWS Glue Kafka para autenticación de clientes.	5 de julio de 2022
Compatibilidad con Apache Kafka Connector para esquemas Protobuf	La compatibilidad con Apache Kafka Connector ya está disponible para esquemas Protobuf. Para obtener más información, consulte Registro de esquemas de AWS Glue.	9 de junio de 2022
Compatibilidad con Auto Scaling para trabajos de AWS Glue (disponible de manera general)	Se ha agregado información sobre el uso de escalado automático para trabajos en AWS Glue versión 3.0 para escalar dinámicamente los recursos de computación. Para obtener más información, consulte Uso de Auto Scaling para AWS Glue.	14 de abril de 2022
Actualice la documentación de AWS Glue desarrollando y probando scripts de trabajo de AWS Glue	Información reorganizada y agregada sobre los métodos de desarrollo y pruebas disponibles para AWS Glue, incluidas instrucciones para desarrollar con Docker. Para obtener más información, consulte Desarrollo y pruebas de scripts de trabajo de AWS Glue.	14 de marzo de 2022

Agregado de búferes de protocolo (Protobuf) como formato de datos admitido para AWS Glue Schema Registry	Se agregó información acerca de Protobuf como formato de datos admitido (además de AVRO y JSON). Para obtener más información, consulte Registro de esquemas de AWS Glue.	25 de febrero de 2022
Compatibilidad con tablas de rastreo de Delta Lake	Se agregó información sobre el uso de AWS Glue para rastrear tablas de Delta Lake. Para obtener más información, consulte Cómo especificar opciones de configuración para un almacén de datos de Delta Lake.	24 de febrero de 2022
Compatibilidad con Información de trabajos de AWS Glue	Información agregada acerca del uso de información de trabajos de AWS Glue para simplificar la depuración y la optimización de los trabajos de AWS Glue. Para obtener más información, consulte Monitorización con información de trabajos de AWS Glue.	8 de febrero de 2022

Compatibilidad para rastrear tablas del Catálogo de datos respaldadas por Amazon S3 mediante un punto de conexión de VPC	Además de los almacenes de datos de Amazon S3, puede configurar las tablas del Catálogo de datos respaldadas por Amazon S3 para acceder a ellas únicamente a través de un entorno de Amazon Virtual Private Cloud (Amazon VPC), con fines de seguridad, auditoría o control. Para obtener más información, consulte Rastreo de un almacén de datos de Amazon S3 o tablas del Catálogo de datos respaldadas por Amazon S3 mediante un punto de conexión de VPC.	3 de febrero de 2022
Compatibilidad con las tablas regidas por Lake Formation	Se ha agregado información acerca de la compatibilidad de AWS Glue con las tablas regidas por Lake Formation, que admiten transacciones ACID, compactación automática de datos y consultas de viaje en el tiempo. Para obtener más información, consulte la API de AWS Glue y la Guía para desarrolladores de AWS Lake Formation.	30 de noviembre de 2021

Nuevas políticas administradas de AWS agregadas para sesiones interactivas y cuadernos	Las nuevas políticas administradas para IAM han proporcionado seguridad mejorada para utilizar AWS Glue con sesiones interactivas y cuadernos. Para obtener más información, consulte Políticas administradas de AWS para AWS Glue.	30 de noviembre de 2021
Glue Schema Registry ahora es compatible con trabajos de flujos	Puede crear trabajos de streaming que tengan acceso a las tablas que forman parte de Glue Schema Registry. Para obtener más información, consulte AWS Glue Schema Registry y Agregado de trabajos de ETL de streaming en AWS Glue.	15 de noviembre de 2021
Compatibilidad con las nuevas características de machine learning	Se ha agregado información sobre las nuevas características de la transformación de machine learning de búsqueda de coincidencias, incluidas la coincidencia progresiva y la puntuación de coincidencias. Para obtener más información, consulte Búsqueda de coincidencias progresivas y Estimación de la calidad de las coincidencias mediante las puntuaciones de confianza de coincidencias.	31 de octubre de 2021

(Versión preliminar privada) Compatibilidad para trabajos flexibles de AWS Glue	Se agregó información sobre la configuración de trabajos Spark de AWS Glue con una clase de ejecución flexible, adecuada para trabajos insensibles al tiempo cuyos tiempos de inicio y finalización pueden variar. Para obtener más información, consulte Agregar trabajos en AWS Glue.	29 de octubre de 2021
Compatibilidad con la aceleración de los rastreadores mediante las notificaciones de eventos de Amazon S	Se ha agregado información acerca de cómo acelerar los rastreadores mediante las notificaciones de eventos de Amazon S3. Para obtener más información, consulte Aceleración de los rastreadores mediante las notificaciones de eventos de Amazon S3.	15 de octubre de 2021

Opciones de configuración de seguridad adicionales relacionadas con el control de acceso y las VPC	Se ha agregado información acerca de cómo configurar nuevos permisos de control de acceso en AWS Glue y la configuración de VPC. Para obtener más información, consulte Etiquetas de AWS en AWS Glue, Políticas con base en identidad (políticas de IAM) que controlan la configuración mediante claves de condición o claves de contexto y Configuración de todas las llamadas de AWS para pasar por su VPC.	13 de octubre de 2021
Compatibilidad con las políticas de punto de conexión de VPC	Se ha agregado información acerca de la compatibilidad con las políticas de punto de conexión de Virtual Private Cloud (VPC) en AWS Glue. Para obtener más información, consulte AWS Glue y puntos de conexión de VPC de tipo interfaz (AWS PrivateLink).	11 de octubre de 2021
Glue Studio está disponible en China	AWS Glue StudioAhora, está disponible en las regiones de China (Pekín) y Ningxia.	11 de octubre de 2021

AWS Glue Studio ofrece creación de cuadernos para editar trabajos interactivos	Los cuadernos le ayudan a escribir y ejecutar código, visualizar los resultados y compartir información. Por lo general, los científicos de datos utilizan cuadernos para experimentos y tareas de exploración de datos. Para obtener más información, consulte Using Notebooks (Uso de cuadernos).	1 de octubre de 2021
Ahora, se encuentra disponible el acceso directo a orígenes de streaming	Al agregar orígenes de datos al trabajo ETL en el editor visual, puede proporcionar información para acceder a la secuencia de datos en lugar de tener que utilizar una base de datos y una tabla del Data Catalog.	30 de septiembre de 2021
Se ha documentado la política de compatibilidad de versiones de AWS Glue	Se ha agregado información acerca de la política de compatibilidad de versiones de AWS Glue y las fases de fin de vida útil para determinadas versiones de AWS Glue. Para obtener más información, consulte Política de compatibilidad de versiones de AWS Glue.	24 de septiembre de 2021

Los conectores personalizados ahora se pueden utilizar con vistas previas de datos	Al editar el nodo de origen de datos mediante un conector personalizado, puede obtener una vista previa del conjunto de datos al elegir la pestaña Vista previa de Dat. Para obtener más información, consulte Conectores personalizados.	24 de septiembre de 2021
Compatibilidad con sesiones interactivas de AWS Glue (versión preliminar privada)	(Versión preliminar privada). Se ha agregado información acerca de la utilización de sesiones interactivas de AWS Glue para ejecutar cargas de trabajo de Spark en la nube desde cualquier cuaderno de Jupyter. Las sesiones interactivas son el método preferido para desarrollar su código de servicio ETL (extracción, transformación y carga) de AWS Glue cuando utiliza AWS Glue 2.0 o posterior. Para obtener más información, consulte Configuración y ejecución de sesiones interactivas de AWS Glue para el cuaderno de Jupyter.	24 de agosto de 2021

Compatibilidad con la creación de flujos de trabajo a partir de esquemas (disponible de manera general)	Se agregó información acerca de la codificación de casos de uso comunes de extracción, transformación y carga (ETL) en proyectos y la creación de flujos de trabajo a partir de proyectos. Permite a los analistas de datos crear y ejecutar con facilidad procesos de ETL complejos. Para obtener más información, consulte Realización de actividades de ETL complejas mediante proyectos y flujos de trabajo en AWS Glue.	23 de agosto de 2021

Compatibilidad con la versión 3.0 de AWS Glue.	Se agregó información acerca del soporte de la versión 3.0 de AWS Glue que admite la actualización del motor Apache Spark 3.0 para ejecutar trabajos de ETL de Apache Spark, y otras optimizaciones y actualizaciones. Para obtener más información, consulte las Notas de la versión de AWS Glue y Migración de trabajos de AWS Glue a la versión 3.0 de AWS Glue. Otras características de esta versión incluyen el administrador de mezclas aleatorias de AWS Glue, un lector CSV vectorizado de SIMD y predicados de particiones de catálogo. Para obtener más información, consulte Administrador de mezclas aleatorias de AWS Glue Spark con Amazon S3, Opciones de formato para las entradas y salidas de ETL en AWS Glue, y Filtrado del lado del servidor mediante predicados de partición de catálogo.	18 de agosto de 2021
AWS GovCloud (US) Region	AWS Glue Studio ahora está disponible en AWS GovCloud (US) Region	18 de agosto de 2021

Creación de intérprete de comandos de Python disponible en AWS Glue Studio	Al crear un nuevo trabajo, ahora puede elegir crear un trabajo de intérprete de comandos de Python. Para obtener más información, consulte Iniciar el proceso de creación de trabajo y Edición de trabajos de intérprete de comandos de Python en AWS Glue Studio.	13 de agosto de 2021
Compatibilidad con el inicio de un flujo de trabajo con un evento de Amazon EventBridge	Se agregó información acerca de cómo AWS Glue puede ser un consumidor de eventos en una arquitectura basada en eventos. Para obtener más información, consulte Inicio de un flujo de trabajo de AWS Glue con un evento de Amazon EventBridge y Visualización de los eventos de EventBridge que iniciaron un flujo de trabajo.	14 de julio de 2021
Adición de JSON como formato de datos compatible para AWS Glue Schema Registry	Se agregó información acerca de JSON como formato de datos soportado (además de AVRO). Para obtener más información, consulte AWS Glue Schema Registry.	30 de junio de 2021

Creación de trabajos de streaming de AWS Glue sin una tabla del Data Catalog	La función de Python `create_data_frame_from_options` o `getSource` para scripts de Scala soporta la creación de trabajos de ETL de streaming que hacen referencia a los flujos de datos directamente, en lugar de requerir una tabla del Catálogo de datos.	15 de junio de 2021
AWS Glue Las transformaciones de machine learning de AWS Key Management Service ahora son compatibles con las claves de	Puede especificar una configuración de seguridad o clave AWS KMS cuando se configuran transformaciones de machine learning de AWS Glue con la consola, la CLI o las API de AWS Glue. Para obtener más información, consulte Uso de cifrado de datos con transformaciones de machine learning y API de machine learning de AWS Glue.	15 de junio de 2021
Actualización a la política AWSGlueConsoleFullAccess administrada por AWS	Se agregó información sobre una actualización menor a la política AWSGlueConsoleFullAccess administrada por AWS. Para obtener más información, consulte Actualizaciones de AWS Glue a las políticas administradas de AWS.	10 de junio de 2021

Visualice el conjunto de datos del trabajo mientras crea y edita trabajos	Puede utilizar la nueva pestaña Previsualización de datos para un nodo en su diagrama de trabajo para ver una muestra de los datos procesados por ese nodo. Para obtener más informaci ón, consulte Utilizar previsual izaciones de datos en el editor visual de trabajos.	7 de junio de 2021
Compatibilidad con la especific ación de un valor que indique la ubicación de la tabla para la salida del rastreador.	Se agregó información sobre cómo especificar un valor que indica la ubicación de la tabla al configurar la salida del rastreador. Para obtener más información, consulte Cómo especificar la ubicación de la tabla.	4 de junio de 2021
Compatibilidad con el rastreo de una muestra de archivos en un conjunto de datos al rastrear un almacén de datos de Simple Storage Service (Amazon S	Se agregó información sobre cómo rastrear una muestra de archivos al rastrear Amazon S3. Para obtener más información, consulte Propiedades del rastreador.	10 de mayo de 2021

Compatibilidad con el escritor de parquet optimizado de AWS Glue	Se agregó información acerca del uso del escritor de parquet optimizado de AWS Glue para DynamicFrames a fin de crear o actualizar tablas con la clasificación `parquet`. Para obtener más información, consulte Creación de tablas, actualización de esquemas y agregado de nuevas particiones en el Catálogo de datos desde trabajos de ETL de AWS Glue y Opciones de formato para entradas y salidas de ETL en AWS Glue.	4 de mayo de 2021
Compatibilidad con contraseñas de autenticación de cliente de Kafka	Se agregó información acerca de cómo los trabajos de ETL de streaming en AWS Glue soportan la autenticación de certificados de cliente SSL con los productores de flujos de Apache Kafka. Ahora puede proporcionar un certificado personalizado al definir una conexión de AWS Glue a un clúster de Apache Kafka, que AWS Glue usará al autenticarse con él. Para obtener más información, consulte Propiedades de conexión de AWS Glue y API de conexión.	28 de abril de 2021

Compatibilidad con el consumo de datos de Amazon Kinesis Data Streams en otra cuenta en trabajos de ETL de streaming	Se agregó información sobre cómo crear un trabajo de ETL de streaming para consumir datos de Amazon Kinesis Data Streams en otra cuenta. Para obtener más información, consulte Agregado de trabajos de ETL de streaming en AWS Glue.	30 de marzo de 2021
Transformación SQL disponible	Puede usar un nodo de transformación SQL para escribir su propia transformación en forma de consulta SQL. Para obtener más información, consulte Uso de una consulta SQL para transformar datos.	23 de marzo de 2021
Compatibilidad con la creación de flujos de trabajo a partir de esquemas (versión preliminar pública)	(Previsualización pública) se agregó información acerca de la codificación de casos de uso comunes de extracción, transformación y carga (ETL) en proyectos y, a continuación, creación de flujos de trabajo a partir de proyectos. Permite a los analistas de datos crear y ejecutar con facilidad procesos de ETL complejos. Para obtener más información, consulte Realización de actividades de ETL complejas mediante proyectos y flujos de trabajo en AWS Glue ().	22 de marzo de 2021

Los conectores se pueden utilizar para destinos de datos	Ahora, se soporta el uso de un conector personalizado o AWS Marketplace para su destino de datos. Para obtener más información, consulte Creación de trabajos con conectores personalizados.	15 de marzo de 2021
Compatibilidad con las métricas de importancia de columna para transformaciones de machine learning de AWS Glue	Se agregó información sobre la visualización de métricas de importancia de columna cuando se trabaja con transformaciones de machine learning de AWS Glue. Para obtener más información, consulte Trabajar con transformaciones de machine learning en la consola de AWS Glue	5 de febrero de 2021
La programación de trabajos ya se encuentra disponible en AWS Glue Studio	Puede definir programaciones basadas en tiempo para las ejecuciones de trabajo en AWS Glue Studio. Puede utilizar la consola para crear una programación básica o definir una programación más compleja con la sintaxis cron de tipo Unix. Para obtener más información, consulte Programación de ejecuciones de trabajo.	21 de diciembre de 2020

AWS Glue Lanzamiento de conectores personalizados de	AWS Glue Los conectores personalizados de le permiten descubrir y suscribirse a conectores en AWS Marketplace. También introdujimos interfaces de tiempo de ejecución de AWS Glue Spark para conectar conectores creados para Apache Spark Datasource, consulta federada de Athena y API de JDBC. Para obtener más información, consulte Uso de conectores y conexiones con AWS Glue Studio.	21 de diciembre de 2020
Soporte para la ejecución de trabajos de ETL de streaming en AWS Glue, versión 2.0	Se agregó información sobre el soporte para la ejecución de trabajos de ETL de streaming en Glue versión 2.0. Para obtener más información, consulte Agregado de trabajos de ETL de streaming en AWS Glue.	18 de diciembre de 2020

Compatibilidad con particiones de cargas de trabajo con ejecución limitada	Se agregó información acerca de habilitar la partición de carga de trabajo para configurar los límites superiores en el tamaño del conjunto de datos o la cantidad de archivos procesados en ejecuciones de trabajos de ETL. Para obtener más información, consulte Partición de carga de trabajo con ejecución limitada.	23 de noviembre de 2020
Compatibilidad con la administración mejorada de particiones	Se agregó información acerca de cómo usar nuevas API para agregar o eliminar un índice de partición a/desde una tabla existente. Para obtener más información, consulte Trabajar con índices de partición.	23 de noviembre de 2020
Soporte para AWS Glue Schema Registry	Se agregó información acerca del uso de AWS Glue Schema Registry para descubrir, controlar y evolucionar los esquemas de forma centralizada. Para obtener más información, consulte Registro de esquemas de AWS Glue.	19 de noviembre de 2020

Compatibilidad con el formato de entrada Grok en trabajos de ETL de streaming	Se agregó información sobre la aplicación de patrones Grok a orígenes de streaming , como archivos de registro. Para obtener más informaci ón, consulte Aplicación de patrones Grok a orígenes de streaming.	17 de noviembre de 2020
Compatibilidad con el agregado de etiquetas a flujos de trabajo en la consola de AWS Glue	Se agregó información acerca de cómo agregar etiquetas al crear un flujo de trabajo mediante la consola de AWS Glue. Para obtener más información, consulte Creación y desarrollo de un flujo de trabajo mediante la consola de AWS Glue.	27 de octubre de 2020
Compatibilidad con ejecucion es de rastreadores progresiv as	Se agregó información sobre el soporte de ejecuciones de rastreadores progresivos, que rastrean sólo las carpetas de Amazon S3 agregadas desde la última ejecución. Para obtener más información, consulte Rastreos progresivos.	21 de octubre de 2020

Compatibilidad con la detección de esquemas para orígenes de datos de ETL de streaming. Compatibilidad con orígenes de datos de ETL de streaming de Avro y Kafka autoadministrado	Los trabajos de extracción, transformación y carga (ETL) de streaming en AWS Glue ahora pueden detectar automáticamente el esquema de los registros entrantes y controlar los cambios de esquema por registro. Ahora se soportan orígenes de datos Kafka autoadministrados. Los trabajos de ETL de streaming ahora admiten el formato Avro en los orígenes de datos. Para obtener más información, consulte ETL de streaming en AWS Glue, Definición de propiedades de trabajo para un trabajo de ETL de streaming y Notas y restricciones para orígenes de streaming de Avro.	7 de octubre de 2020
Compatibilidad con el rastreo de orígenes de datos de MongoDB y DocumentDB	Se agregó información acerca del soporte para rastrear orígenes de datos de MongoDB y Amazon DocumentDB (con compatibilidad con MongoDB). Para obtener más información, consulte Definición de rastreadores.	5 de octubre de 2020

Compatibilidad con la conformidad con FIPS	Se agregó información acerca de los puntos de enlace de FIPS para clientes que necesitan módulos criptográficos validados según FIPS 140-2 al acceder a los datos mediante AWS Glue. Para obtener más información, consulte Conformidad con FIPS.	23 de septiembre de 2020
AWS Glue Studio proporciona una interfaz visual fácil de usar para crear y monitorear trabajos	Ahora puede usar una interfaz sencilla basada en gráficos para componer trabajos que mueven y transforman datos, y ejecutarlos en AWS Glue. Puede utilizar el panel de ejecución de trabajos en AWS Glue Studio para monitorear la ejecución de ETL y asegurarse de que sus trabajos funcionen de la manera pretendida. Si quiere obtener más información, consulte la Guía del usuario de AWS Glue Studio.	23 de septiembre de 2020
Compatibilidad con la creación de índices de tabla para mejorar el rendimiento de las consultas	Se agregó información sobre la creación de índices de tabla para permitir la recuperación de un subconjunto de particiones de una tabla. Para obtener más información, consulte Trabajar con índices de partición.	9 de septiembre de 2020

Soporte para tiempos de inicio reducidos al ejecutar trabajos de ETL de Apache Spark en AWS Glue, versión 2.0.	Se agregó información acerca del soporte para AWS Glue, versión 2.0, que proporciona una infraestructura mejorada para ejecutar trabajos de ETL de Apache Spark con tiempos de inicio reducidos, cambios en el registro y soporte para especificar módulos adicionales de Python al nivel del trabajo. Para obtener más información, consulte Notas de la versión de AWS Glue y Ejecución de trabajos de ETL de Spark con tiempos de inicio reducidos.	10 de agosto de 2020
Compatibilidad con la limitación de la cantidad de ejecuciones concurrentes de un flujo de trabajo.	Se agregó información acerca de cómo limitar la cantidad de ejecuciones concurrentes del flujo de trabajo para un flujo de trabajo determinado. Para obtener más información, consulte Creación y desarrollo de un flujo de trabajo mediante la consola de AWS Glue.	10 de agosto de 2020

Compatibilidad con el rastreo de un almacén de datos de Simple Storage Service (Amazon S3) mediante un punto de conexión de VPC	Se agregó información acerca de la configuración de su almacén de datos de Amazon S3 para el acceso únicament e a través de un entorno de Amazon Virtual Private Cloud (Amazon VPC), con fines de seguridad, auditoría o control. Para obtener más informaci ón, consulte Rastreo de un almacén de datos de Amazon S3 mediante un punto de enlace de la VPC.	7 de agosto de 2020
Compatibilidad con la reanudación de ejecuciones de flujos de trabajo	Se agregó información acerca de cómo reanudar las ejecuciones de flujo de trabajo que solo se completar on en forma parcial porque uno o más nodos (trabajos o rastreadores) no se completar on correctamente. Para obtener más informaci ón, consulte Reparación y reanudación de una ejecución de flujo de trabajo.	27 de julio de 2020

Compatibilidad con la habilitación de certificados de CA privados en conexiones de Kafka en AWS Glue.	Se agregó información sobre las nuevas opciones de conexión que soportan la habilitación de certificados de CA privados para conexiones Kafka en AWS Glue. Para obtener más información, consulte Tipos y opciones de conexión para ETL en AWS Glue y Parámetros especiales usados por AWS Glue.	20 de julio de 2020
Compatibilidad con la lectura de datos de DynamoDB en otra cuenta	Se agregó información sobre el soporte de AWS Glue para leer datos de la tabla DynamoDB de otra cuenta de AWS. Para obtener más información, consulte Lectura de datos de DynamoDB en otra cuenta.	17 de julio de 2020
Soporte para la conexión de escritura de DynamoDB en AWS Glue, versión 1.0 o posterior	Se agregó información acerca del soporte para el escritor de DynamoDB y opciones de conexión nuevas o actualizadas para que DynamoDB lea o escriba. Para obtener más información, consulte Tipos y opciones de conexión para ETL en AWS Glue.	17 de julio de 2020

Soporte para enlaces de recursos y control de acceso entre cuentas mediante AWS Glue y Lake Formation	Se agregó contenido sobre los nuevos objetos del Catálogo de datos denominados enlaces de recursos y sobre cómo administrar los recursos compartidos del Catálogo de datos entre cuentas con AWS Glue y AWS Lake Formation. Para obtener más información, consulte Concesión de acceso entre cuentas y Enlaces de recursos de tabla.	7 de julio de 2020
Compatibilidad con el muestreo de registros al rastrear almacenes de datos de DynamoDB	Se agregó información acerca de las nuevas propiedad es que puede configurar al rastrear un almacén de datos de DynamoDB. Para obtener más información, consulte Propiedades del rastreador.	12 de junio de 2020
Compatibilidad con la detención de la ejecución de un flujo de trabajo.	Se agregó información sobre cómo detener una ejecución de flujo de trabajo para un flujo de trabajo determinado. Para obtener más información, consulte Detener ejecución de flujo de trabajo.	14 de mayo de 2020

Soporte para trabajos de ETL de Spark Streaming	Se agregó información sobre la creación de trabajos de extracción, transformación y carga (ETL) con origen de datos de streaming. Para obtener más información, consulte Agregado de trabajos de ETL de streaming en AWS Glue.	27 de abril de 2020
Compatibilidad con la creación de tablas, la actualización del esquema y la adición de nuevas particiones en el Catálogo de datos después de ejecutar un trabajo de ETL	Se agregó información acerca de cómo permitir la creación de tablas, la actualización del esquema y la incorporación de nuevas particiones para ver los resultados del trabajo de ETL en el Catálogo de datos. Para obtener más información, consulte Creación de tablas, actualización de esquemas y agregado de nuevas particiones en el Catálogo de datos desde trabajos de ETL de AWS Glue.	2 de abril de 2020

Compatibilidad con la especificación de una versión para el formato de datos de Apache Avro como entrada y salida de ETL en AWS Glue	Se agregó información acerca de cómo especificar una versión para el formato de datos de Apache Avro como una entrada y salida de ETL en AWS Glue. La versión predeterminada es 1.7. Puede utilizar la opción de formato `version` para especificar la versión 1.8 de Avro y habilitar la lectura/escritura lógica. Para obtener más información, consulte Opciones de formato para las entradas y salidas de ETL en AWS Glue.	31 de marzo de 2020
Compatibilidad con el confirmador optimizado para S3 de EMRFS para la escritura de datos de Parquet en Simple Storage Service (Amazon S3	Se agregó información acerca de cómo establecer un nuevo indicador que habilite el confirmador optimizado para S3 de EMRFR de forma que puedan escribirse datos de Parquet en Amazon S3 al crear o actualizar un trabajo de AWS Glue. Para obtener más información, consulte Parámetros especiales utilizados por AWS Glue.	30 de marzo de 2020

Compatibilidad con las transformaciones de machine learning como recurso administrado por las etiquetas de recursos de AWS	Se agregó información sobre el uso de etiquetas de recursos de AWS para administrar y controlar el acceso a las transformaciones de machine learning en AWS Glue. Puede asignar etiquetas de recursos de AWS a trabajos, desencade nadores, puntos de enlace, rastreadores y transform aciones de machine learning en AWS Glue. Para obtener más información, consulte Etiquetas de AWS en AWS Glue.	2 de marzo de 2020
Compatibilidad con argumento s de trabajo que no se pueden invalidar	Se agregó información acerca del soporte de parámetros especiales de trabajos que no se pueden invalidar en desencadenadores o cuando se ejecuta el trabajo. Para obtener más información, consulte Agregado de trabajos en AWS Glue.	12 de febrero de 2020

Compatibilidad con nuevas transformaciones para trabajar con conjuntos de datos en Simple Storage Service (Amazon S3	Se agregó información sobre nuevas transformaciones (Merge, Purge y Transitio n) y exclusiones de clases de almacenamiento de Amazon S3 en aplicacio nes de Apache Spark para trabajar con conjuntos de datos de Amazon S3. Para obtener más información sobre el soporte con estas transformaciones en Python, consulte mergeDynamicFrame y Trabajar con conjuntos de datos en Amazon S3. En el caso de Scala, consulte mergeDynamicFrames y las API GlueContext de AWS Glue Scala.	16 de enero de 2020
Compatibilidad con la actualización del Catálogo de datos con información sobre nuevas particiones desde un trabajo de ETL	Se agregó información acerca de cómo codificar un script de extracción, transformación y carga (ETL) para actualizar AWS Glue Data Catalog con información sobre nuevas particiones. Con esta funcional idad, ya no tendrá que volver a ejecutar el rastreador después de finalizar un trabajo para ver las nuevas particiones. Para obtener más informaci ón, consulte Actualización del Catálogo de datos con nuevas particiones.	15 de enero de 2020

Nuevo tutorial: Uso de un cuaderno de IA de SageMaker	Se agregó un tutorial que muestra cómo utilizar un cuaderno de Amazon SageMaker para ayudar a desarrollar sus scripts de machine learning y ETL. Consulte Tutorial: uso de un cuaderno de Amazon SageMaker con su punto de enlace de desarrollo.	3 de enero de 2020
Compatibilidad con la lectura desde MongoDB y Amazon DocumentDB (con compatibilidad con MongoDB)	Se agregó información sobre nuevos tipos de conexión y opciones de conexión para leer y escribir en MongoDB y Amazon DocumentDB (con compatibilidad con MongoDB). Para obtener más información, consulte Tipos y opciones de conexión para ETL en AWS Glue.	17 de diciembre de 2019

Diversas correcciones y aclaraciones	Se han agregado correcciones y aclaraciones en todo el documento. Se han eliminado entradas del capítulo de problemas conocidos. Se han agregado advertencias para indicar que AWS Glue solo soporta claves maestras de cliente (CMK) simétricas al crear configuraciones de seguridad y especificar la configuración de cifrado del Catálogo de datos. Se agregó una nota que indica que AWS Glue no permite escribir en Amazon DynamoDB.	9 de diciembre de 2019
Compatibilidad con controladores JDBC personalizados	Se agregó información sobre la conexión a orígenes de datos y destinos con controladores JDBC que AWS Glue no soporta de forma nativa, como MySQL versión 8 y Oracle Database versión 18. Para obtener más información, consulte Valores ConnectionType de JDBC.	25 de noviembre de 2019

Compatibilidad con la conexión de cuadernos de IA de SageMaker a diferentes puntos de conexión de desarrollo	Se agregó información acerca de cómo conectar un cuaderno de IA de SageMaker a diferentes puntos de conexión de desarrollo. Se han incluido actualizaciones para describir una nueva acción de la consola que permite cambiar a un nuevo punto de conexión de desarrollo y para explicar la nueva política de IAM de IA de SageMaker. Para obtener más información, consulte Trabajo con cuadernos en la consola de AWS Glue y Creación de una política de IAM para los cuadernos de IA de Amazon SageMaker.	21 de noviembre de 2019
Soporte para la versión de AWS Glue en las transformaciones de machine learning	Se agregó información sobre la definición de la versión de AWS Glue en las transformaciones de machine learning para indicar la versión de AWS Glue con la que son compatibles estas transformaciones. Para obtener más información, consulte Trabajar con transformaciones de machine learning en la consola de AWS Glue.	21 de noviembre de 2019

Compatibilidad con el rebobinado de marcadores de trabajos	Se agregó información sobre el rebobinado de los marcadores de trabajo a cualquier ejecución de trabajo anterior reprocesando los datos solo desde la ejecución del trabajo marcado. Se describen dos nuevas subopciones para la opción `job-bookmark-pause` que le permiten ejecutar un trabajo entre dos marcadores. Para obtener más información, consulte, Seguimiento de los datos procesados mediante marcadores de trabajo y Parámetros especiales usados por AWS Glue.	22 de octubre de 2019
Compatibilidad con certificados JDBC personalizados para conectarse a un almacén de datos	Se agregó información sobre el soporte de AWS Glue con certificados JDBC personalizados para conexiones SSL que tienen orígenes o destinos de datos de AWS Glue. Para obtener más información, consulte Trabajar con conexiones en la consola de AWS Glue.	10 de octubre de 2019

Compatibilidad con archivos wheel de Python	Se agregó información sobre el soporte de AWS Glue con los archivos wheel (junto con los archivos egg) como dependencias para los trabajos de intérprete de comandos de Python. Para obtener más información, consulte Proporcionar su propia biblioteca de Python.	26 de septiembre de 2019
Compatibilidad con el control de versiones de puntos de conexión de desarrollo en AWS Glue	Se ha agregado información sobre la definición de `Glue version` en los puntos de enlace de desarrollo. `Glue version` determina las versiones de Apache Spark y Python compatibles con AWS Glue. Para obtener más información, consulte Añadir un punto de conexión de desarrollo.	19 de septiembre de 2019

Compatibilidad con la supervisión de AWS Glue mediante la interfaz de usuario de Spark	Se ha añadido información sobre el uso de la interfaz de usuario de Apache Spark para monitorizar y depurar trabajos ETL en AWS Glue que se ejecutan en el sistema de trabajos de AWS Glue, así como aplicaciones Spark en puntos de conexión de desarrollo de AWS Glue. Para obtener más información, consulte Monitoreo mediante la interfaz de usuario de AWS Glue Spark.	19 de septiembre de 2019
Se mejoró la compatibilidad con el desarrollo de scripts de ETL locales mediante la biblioteca pública de ETL de AWS Glue	Se ha actualizado el contenido de la biblioteca de ETL de AWS Glue para reflejar que ahora se soporta la versión 1.0 de AWS Glue. Para obtener más información, consulte Desarrollo y prueba de scripts de ETL localmente mediante la biblioteca de ETL de AWS Glue.	18 de septiembre de 2019

Compatibilidad con la exclusión de clases de almacenamiento de Simple Storage Service (Amazon S3) al ejecutar trabajos	Se agregó información sobre la exclusión de clases de almacenamiento de Amazon S3 al ejecutar trabajos de ETL de AWS Glue que leen archivos o particiones desde Amazon S3. Para obtener más información, consulte Exclusión de clases de almacenamiento de Amazon S3.	29 de agosto de 2019
Compatibilidad con el desarrollo de scripts de ETL locales mediante la biblioteca pública de ETL de AWS Glue	Se ha agregado información sobre cómo desarrollar y probar localmente scripts ETL de Python y Scala sin necesidad de una conexión de red. Para obtener más información, consulte Desarrollo y prueba de scripts de ETL localmente mediante la biblioteca de ETL de AWS Glue.	28 de agosto de 2019
Problemas conocidos	Se ha agregado información sobre problemas conocidos en AWS Glue. Para obtener más información, consulte Problemas conocidos de AWS Glue.	28 de agosto de 2019

Compatibilidad con transformaciones de machine learning en AWS Glue	Se ha agregado información sobre las capacidades de machine learning proporcionadas por AWS Glue para crear transformaciones personalizadas. Puede crear estas transformaciones cuando cree un trabajo. Para obtener más información, consulte Transformaciones de machine learning en AWS Glue.	8 de agosto de 2019
Compatibilidad con Amazon Virtual Private Cloud compartida	Se agregó información sobre el soporte de AWS Glue con Amazon Virtual Private Cloud compartida. Para obtener más información, consulte Uso compartido de Amazon VPC.	6 de agosto de 2019
Compatibilidad con el control de versiones en AWS Glue	Se agregó información sobre la definición de `Glue version` en las propiedades del trabajo. La versión de AWS Glue determina las versiones de Apache Spark y Python que soporta AWS Glue. Para obtener más información, consulte Agregar trabajos en AWS Glue.	24 de julio de 2019

Compatibilidad con opciones de configuración adicionales para puntos de conexión de desarrollo	Se ha agregado información sobre las opciones de configuración de los puntos de enlace de desarrollo que tienen cargas de trabajo con uso intensivo de memoria. Puede elegir entre dos nuevas configuraciones que ofrecen más memoria por ejecutor. Para obtener más información, consulte Trabajar con puntos de enlace de desarrollo en la consola de AWS Glue.	24 de julio de 2019
Compatibilidad con la realización de actividades de extracción, transferencia y carga (ETL) mediante flujos de trabajo	Se agregó información sobre el uso de un nuevo elemento denominado flujo de trabajo para diseñar una actividad compleja de extracción, transformación y carga (ETL) de varios trabajos que AWS Glue puede ejecutar como entidad única y realizar su seguimiento. Para obtener más información, consulte Realización de actividades de ETL complejas mediante flujos de trabajo en AWS Glue.	20 de junio de 2019

Compatibilidad con Python 3.6 de trabajos de intérprete de comandos de Python	Se ha añadido información sobre la compatibilidad con Python 3.6 en los trabajos de intérprete de comandos de Python. Puede especific ar Python 2.7 o Python 3.6 como propiedad de trabajo. Para obtener más información, consulte Agregado de trabajos de intérprete de comandos de Python en AWS Glue.	5 de junio de 2019
Compatibilidad con puntos de conexión de nube virtual privada (VPC	Se agregó información acerca de cómo conectarse directame nte a AWS Glue a través de un punto de enlace de interfaz de la VPC. Cuando se utiliza un punto de enlace de interfaz de la VPC, la comunicación entre la VPC y AWS Glue se realiza en su totalidad y de manera segura dentro de la red de AWS. Para obtener más información, consulte Uso de AWS Glue con puntos de enlace de la VPC.	4 de junio de 2019

Compatibilidad con el registro continuo en tiempo real de los trabajos de AWS Glue.	Se agregó información acerca de cómo habilitar y visualizar registros de trabajo de Apache Spark en tiempo real en CloudWatch, incluidos los registros del controlador, cada uno de los registros de trabajo y una barra de progreso de trabajos de Spark. Para obtener más información, consulte la sección Registro continuo de trabajos de AWS Glue.	28 de mayo de 2019
Compatibilidad con tablas existentes del Catálogo de datos como orígenes de rastreador	Se agregó información acerca de la especificación de una lista de tablas existentes del Catálogo de datos como orígenes del rastreador. Los rastreadores pueden detectar los cambios en los esquemas de tabla, actualizar las definiciones de la tabla y habilitar la opción de registrar nuevas particiones como datos nuevos. Para obtener más información, consulte Propiedades del rastreador.	10 de mayo de 2019

Compatibilidad con opciones de configuración adicionales para trabajos con uso intensivo de memoria	Se ha añadido información sobre las opciones de configuración para los trabajos de Apache Spark con cargas de trabajo con uso intensivo de memoria. Puede elegir entre dos nuevas configuraciones que ofrecen más memoria por ejecutor. Para obtener más información, consulte Agregar trabajos en AWS Glue.	5 de abril de 2019
Compatibilidad con clasificadores personalizados de CSV	Se ha añadido información sobre el uso de un clasificador personalizado de CSV para inferir el esquema de distintos tipos de datos CSV. Para obtener más información, consulte Escritura de clasificadores personalizados.	26 de marzo de 2019
Compatibilidad con las etiquetas de recursos de AWS	Se agregó información acerca del uso de etiquetas de recursos de AWS para facilitar la administración y el control de acceso a los recursos de AWS Glue. Puede asignar etiquetas de recursos de AWS a trabajos, desencadenadores, puntos de enlace y rastreadores de AWS Glue. Para obtener más información, consulte Etiquetas de AWS en AWS Glue.	20 de marzo de 2019

Compatibilidad con el Catálogo de datos para trabajos de Spark SQL	Se agregó información sobre la configuración de los trabajos y los puntos de enlace de desarrollo de AWS Glue para utilizar AWS Glue Data Catalog como un metaalmacén de Apache Hive externo. De este modo, los trabajos y los puntos de enlace de desarrollo pueden ejecutar directamente consultas de Apache Spark SQL en las tablas almacenadas en AWS Glue Data Catalog. Para obtener más información, consulte Soporte de AWS Glue Data Catalog para trabajos de Spark SQL.	14 de marzo de 2019
Compatibilidad con trabajos de intérprete de comandos de Python	Se ha añadido información sobre los trabajos de intérprete de comandos de Python y el nuevo campo Capacidad máxima. Para obtener más información, consulte Agregado de trabajos de intérprete de comandos de Python en AWS Glue.	18 de enero de 2019

Compatibilidad con notificaciones cuando se producen cambios en bases de datos y tablas	Se ha añadido información sobre los eventos que se generan para los cambios en las llamadas a la API de base de datos, tabla y partición. Puede configurar acciones en CloudWatch Events para responder a estos eventos. Para obtener más información, consulte Automatización de AWS Glue con CloudWatch Events.	16 de enero de 2019
Compatibilidad con el cifrado de contraseñas de conexión	Se ha añadido información sobre el cifrado de contraseñas usadas en los objetos de conexión. Para obtener más información, consulte Cifrado de contraseñas de conexión.	11 de diciembre de 2018
Compatibilidad con permisos de nivel de recursos y políticas basadas en recursos	Se ha agregado información sobre el uso de permisos de nivel de recursos y políticas basadas en recursos con AWS Glue. Para obtener más información, consulte los temas de Seguridad en AWS Glue.	15 de octubre de 2018
Compatibilidad con cuadernos de IA de SageMaker	Se agregó información sobre el uso de cuadernos de IA de SageMaker con puntos de conexión de desarrollo de AWS Glue. Para obtener más información, consulte Administración de cuadernos.	5 de octubre de 2018

Compatibilidad con cifrado	Información agregada acerca del uso del cifrado con AWS Glue. Para obtener más información, consulte Cifrado en reposo, Cifrado en tránsito y Configuración del cifrado en AWS Glue.	24 de agosto de 2018
Compatibilidad con métricas de trabajos de Apache Spark	Información agregada acerca del uso de las métricas de Apache Spark para lograr una mejor depuración de los trabajos de ETL y una mejor generación de perfiles en estos. Puede hacer fácilment e un seguimiento de métricas de tiempo de ejecución como, por ejemplo, los bytes leídos y escritos, el uso de la memoria y la carga de la CPU del controlador y los ejecutore s, mientras que los datos se mezclan en forma aleatoria entre los ejecutores desde la consola de AWS Glue. Para obtener más informaci ón, consulte Monitoreo de AWS Glue con métricas de CloudWatch, Monitoreo y depuración de trabajos, y Uso de trabajos en la consola de AWS Glue.	13 de julio de 2018

Compatibilidad con DynamoDB como origen de datos	Se agregó información acerca de cómo rastrear y usar DynamoDB como origen de datos de los trabajos de ETL. Para obtener más información, consulte el artículo acerca de cómo catalogar tablas con un rastreador y Parámetros de conexión.	10 de julio de 2018
Actualizaciones para crear un procedimiento de servidor de cuadernos	Se ha incluido información actualizada acerca de cómo crear un servidor de cuadernos en una instancia de Amazon EC2 asociada a un punto de enlace de desarrollo. Para obtener más información, consulte Creación de un servidor de cuadernos asociado a un punto de enlace de desarrollo.	9 de julio de 2018
Actualizaciones ahora disponibles sobre RSS	Ahora puede suscribirse a una fuente RSS para recibir notificaciones sobre actualizaciones de la Guía para desarrolladores de AWS Glue.	25 de junio de 2018
Compatibilidad con notificaciones de retraso de trabajos	Se ha agregado información sobre la configuración de un umbral de retraso cuando se ejecuta un flujo de trabajo. Para obtener más información, consulte Agregar trabajos en AWS Glue.	25 de mayo de 2018

Configurar un rastreador para anexar nuevas columnas	Se ha agregado información sobre una nueva opción de configuración para los rastreadores: MergeNewColumns. Para obtener más información, consulte Configuración de un rastreador.	7 de mayo de 2018
Compatibilidad con el tiempo de espera de los trabajos	Información agregada sobre la configuración de un umbral de tiempo de espera cuando se ejecuta un flujo de trabajo. Para obtener más información, consulte Agregar trabajos en AWS Glue.	10 de abril de 2018
Compatibilidad con trabajos de desencadenador y script de ETL de Scala basados en estados de ejecución adicionales	Se ha agregado información sobre el uso de Scala como lenguaje de programación de ETL. Además, la API de disparador admite ahora la activación al cumplirse algunas de las condiciones (además de todas las condiciones). Además, los trabajos se pueden activar según una ejecución de flujo de trabajo "con error" o "detenida" (además de una ejecución de flujo de trabajo "de éxito").	12 de enero de 2018

Actualizaciones anteriores

En la siguiente tabla, se describen los cambios importantes que se han realizado en cada versión de la Guía para desarrolladores de AWS Glue anteriores a enero de 2018.

Cambio	Descripción	Fecha
Admita orígenes de datos XML y una nueva opción de configuración del rastreador	Se ha agregado información acerca de la clasificación de los orígenes de datos XML y la nueva opción del rastreador para los cambios en la partición.	16 de noviembre de 2017
Nuevas transform aciones, soporte para motores de bases de datos de Amazon RDS adicionales y mejoras de punto de enlace de desarrollo	Se agregó información acerca de las transformaciones de mapeo y filtrado, el soporte para Microsoft SQL Server de Amazon RDS y Oracle de Amazon RDS, y nuevas características de los puntos de enlace de desarrollo.	29 de septiembre de 2017
AWS GlueVersión inicial de	Esta es la versión inicial de la Guía para desarrolladores de AWS Glue.	14 de agosto de 2017

AWSGlosario de

Para ver la terminología más reciente de AWS, consulte el Glosario de AWS en la Referencia de Glosario de AWS.