



Análisis de datos para Big Data en AWS

Prof: Arturo Lorenzo
Hernández.



Arturo Lorenzo Hernández

Arquitecto de Datos en Iskaypet

Estudié Ingeniería Informática en la Universidad de Murcia, España.

Llevo más de 3 años trabajando en el mundo de la ciencia de datos.

Empecé como ingeniero de datos y actualmente desempeño tareas de arquitectura de datos en AWS.



¿Qué vas a conseguir con este curso?

-  Conocer los conceptos principales en Big Data y Análisis de datos
-  Dominar los recursos cloud de AWS para el análisis de datos Big Data
-  Poner en práctica los conocimientos aprendidos con un proyecto real
-  Guía para conseguir trabajo a día de hoy con estas tecnologías



Análisis de datos Big Data en AWS

01.

Fundamentos de
AWS y Big Data

02.

Almacenamiento
de datos en AWS

03.

Ingesta de datos en
S3

04.

Procesamiento de
datos en AWS

05.

Consulta de datos
en AWS

06.

Visualización de
datos y
comunicación de
resultados

07.

Orquestación de
flujos de trabajo

08.

Recomendaciones
finales y próximos
pasos

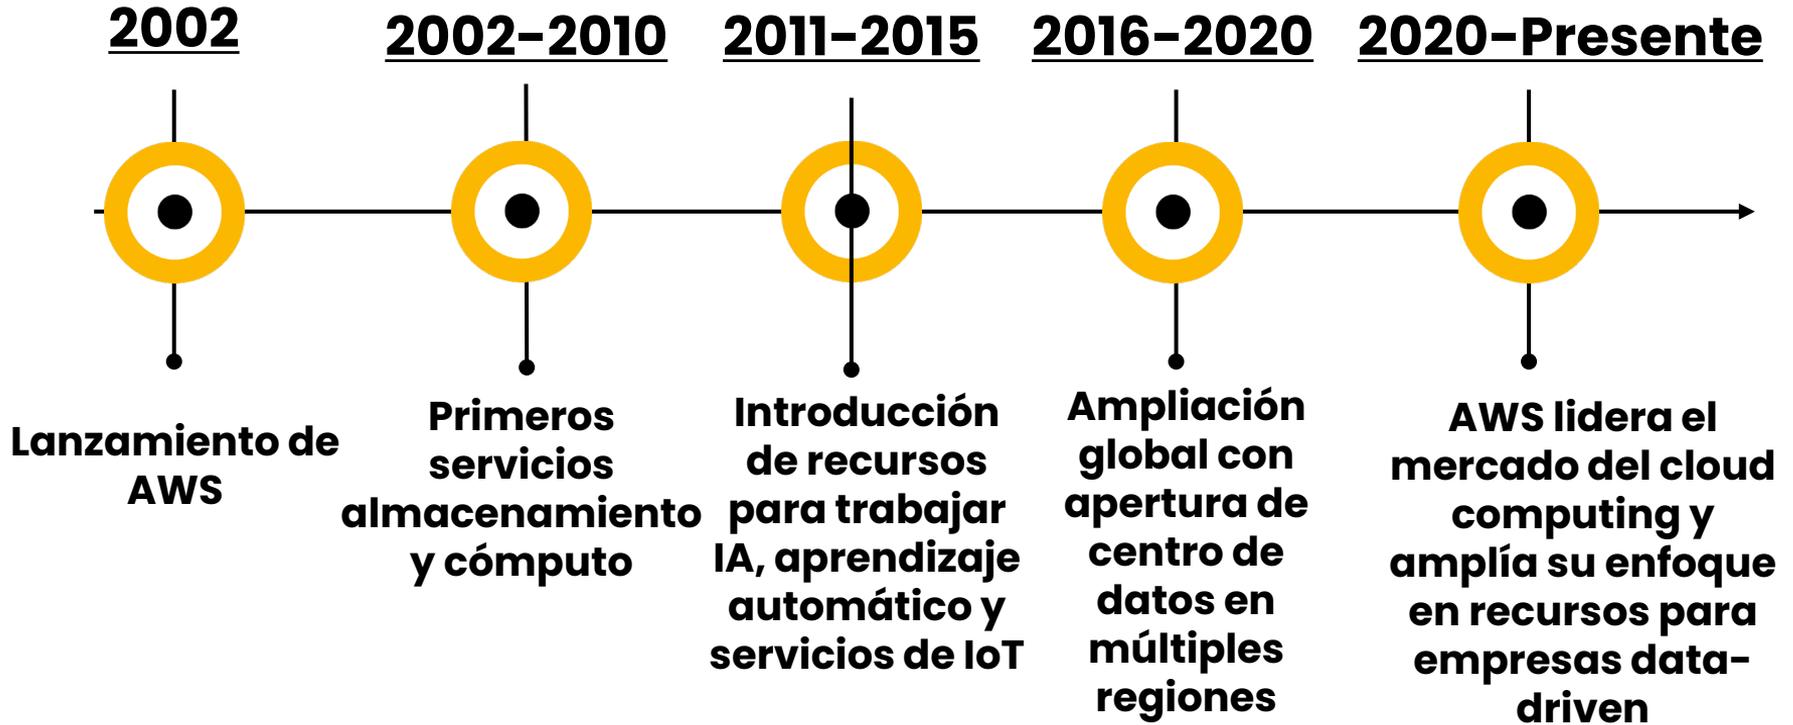
01

Fundamentos de AWS y Big Data

Introducción a AWS



01. Breve historia y evolución de AWS



Categorías de recursos

Computación	<ul style="list-style-type: none">- Amazon EC2- Amazon Lambda- Amazon ECS
Almacenamiento	<ul style="list-style-type: none">- Amazon S3- Amazon EBS
Bases de datos	<ul style="list-style-type: none">- Amazon RDS- Amazon DynamoDB- Amazon Redshift
Analítica	<ul style="list-style-type: none">- Amazon Glue- Amazon EMR- Amazon Kinesis- Amazon Athena
Servicios de mensajería	<ul style="list-style-type: none">- Amazon SNS- Amazon SQS

¿Creamos nuestra primera cuenta en AWS?



Iniciar sesión

Usuario raíz

Propietario de la cuenta que realiza tareas que requieren acceso ilimitado. [Más información](#)

Usuario de IAM

Usuario de una cuenta que realiza tareas diarias. [Más información](#)

Dirección de email del usuario raíz

nombreusuario@ejemplo.com

Siguiente

Al continuar, acepta el [Contrato de cliente de AWS](#) u otro acuerdo para los servicios de AWS y el [Aviso de privacidad](#). Este sitio utiliza cookies esenciales. Consulte nuestro [Aviso de cookies](#) para obtener más información.

¿Es nuevo en AWS?

Crear una cuenta de AWS

© 2024, Amazon Web Services, Inc. o sus empresas afiliadas. Todos los derechos reservados.



Español ▾

01

Fundamentos de AWS y Big Data

¿Cómo se relaciona el
análisis de datos con
AWS?

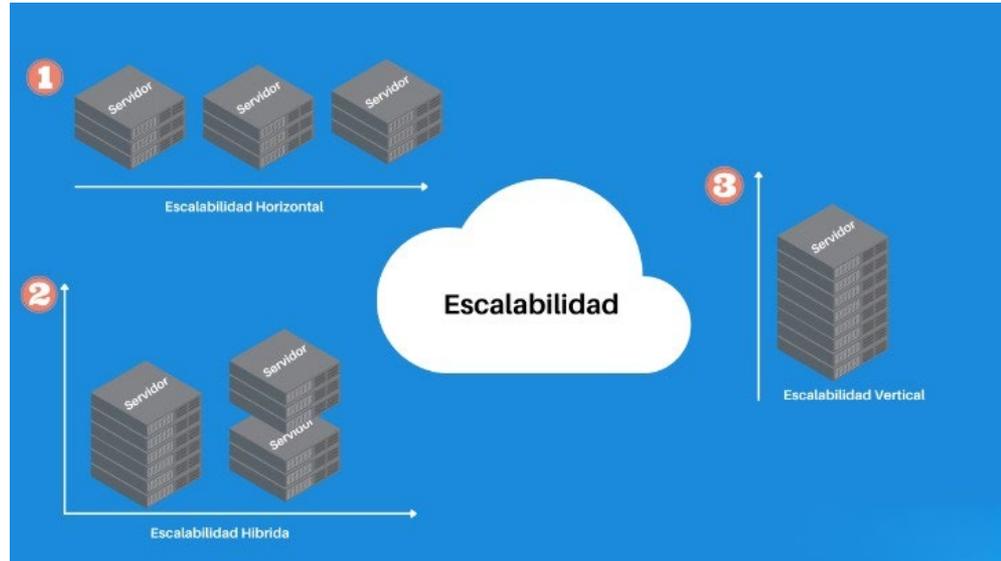


Escalabilidad, elasticidad y pago por uso



Escalabilidad

Puedes aumentar o disminuir el uso de los recursos en la nube con un par de clicks y sin necesidad de comprar infraestructura física.



Escalabilidad, elasticidad y pago por uso



Elasticidad

Los recursos en la nube te permiten que tus servidores escalan de forma automática según la demanda, muy potente cuando no sabes qué uso van a tener tus servidores.



Escalabilidad, elasticidad y pago por uso

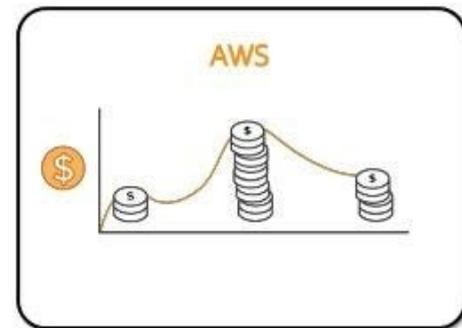
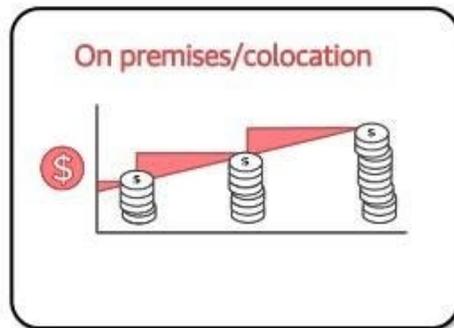


Pay as you go

Only pay for what you use

Pago por uso

Los usuarios solo pagan por los recursos que consumen, si solo quieres tener un servicio encendido un par de días solo vas a pagar por ese consumo.



Recursos top para análisis de datos

Amazon S3



AWS Lambda



AWS Glue



Recursos top para análisis de datos

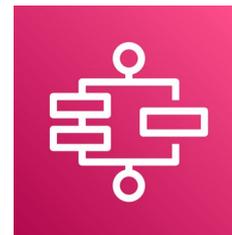
Amazon Athena



Quicksight



Step functions



01

Fundamentos de AWS y Big Data

Análisis de datos en el
contexto de Big Data



- La **cantidad y variedad de formato de datos** han aumentado mucho en los últimos años lo que ha llevado a las empresas a la necesidad de utilizar nuevas técnicas y tecnologías que antes no existían, para poder recopilar, limpiar y analizar los datos de forma masiva.
- Big Data se refiere a **conjuntos de datos extremadamente grandes y complejos** que son difíciles de procesar y analizar utilizando herramientas de gestión de datos tradicionales, por ello se requieren de herramientas avanzadas.

Características principales Big Data (5Vs)



Volumen

Cantidad masiva de datos generados cada segundo desde diversas fuentes.



Velocidad

Rapidez con la que se generan y procesan los datos para cumplir con las demandas.



Valor

Utilidad y relevancia de los datos para la toma de decisiones empresariales.



Variedad

Diversidad de tipos y fuentes de datos, tanto estructurados como no estructurados.



Veracidad

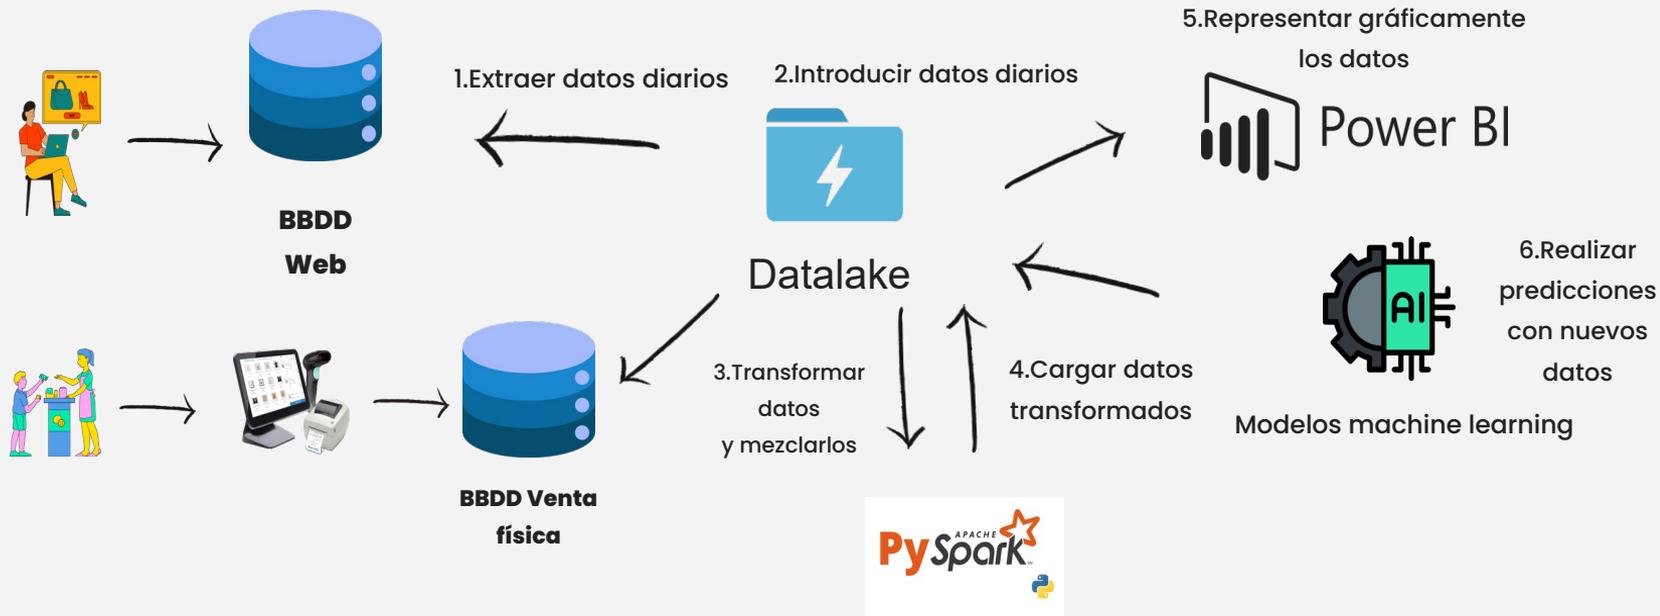
Calidad y precisión de los datos, importante para asegurar resultados fiables.

- AWS ofrece servicios de análisis de datos completos, seguros, escalables y rentables. **Los servicios de análisis de AWS se adaptan a todas las necesidades de análisis de grandes volúmenes de datos:** movimiento de datos, almacenamiento, lagos de datos, análisis de macrodatos, machine learning...
- **El análisis de datos ayuda a las organizaciones a aprovechar sus datos y utilizarlos para identificar nuevas oportunidades.** Eso, a su vez, conduce a movimientos de negocios más inteligentes, operaciones más eficientes, mayores ganancias y clientes más fidelizados.

03. Aplicaciones prácticas del análisis de datos en contextos de Big Data.

- **Optimización de inventarios**
- **Optimización de campañas de marketing digital**
- **Detección de tendencias de mercado bursátil**
- **Optimización de Precios**
- **Reducción del Churn de clientes**
- **Optimización de la cadena de suministro**
- **Personalización de contenidos en medios digitales**
- **Análisis de sentimientos en redes sociales**

Flujo de datos de compra en una empresa



02

Almacenamiento de datos en AWS

Amazon S3:
Almacenamiento
escalable y seguro



- **Amazon S3 (Simple Storage Service) es un servicio de almacenamiento de objetos altamente escalable, duradero y seguro** que permite almacenar y recuperar cualquier cantidad de datos desde cualquier lugar en la web.

- Amazon S3 es como un sistema de ficheros tradicional de cualquier ordenador, permite almacenar *objetos* (ficheros) en *buckets* (directorios) a cualquier escala ya que los datos siguen un patrón de arquitectura distribuida.

Algunas características

- Un bucket debe contener un nombre único de forma global.
- El nombre de un bucket se escribe en minúscula sin barras bajas y debe tener entre 3-63 caracteres.
- Un objeto en S3 contiene una key que se define por la ruta completa en el bucket hacia ese objeto (prefijo + nombre del objeto).
- El máximo de tamaño de un objeto es de 5TB, si se quiere subir un objeto de más peso se tiene que usar la opción de *muti-part upload*

Clases almacenamiento S3

- **S3 Standard:** Uso para datos accedidos frecuentemente, muy poca latencia de recuperación de datos.
- **S3 Standard Infrequent Access:** Uso para datos con menos frecuencia de acceso pero que se necesita un rápido acceso cuando se requieren.
- **S3 Glacier:** Almacenamiento low-cost para archivos de backup o archive.
 - *Glacier Instant Retrieval:* Recuperación de datos en milisegundos, recomendado para acceso a datos de forma trimestral.
 - *Glacier Flexible Retrieval:* Recuperación de datos entre 1 minuto y 12 horas dependiendo de la clase a la que recupere.
 - *Glacier Deep Archive:* Recuperación de datos entre 12 y 48 horas.

Clases almacenamiento S3

- **S3 Intelligent-Tiering:** Uso para datos que no sabes qué tipo de frecuencia de acceso van a tener, los datos se mueven entre clases de forma inteligente.
 - Standard Frequent: Tier por defecto.
 - Standard Infrequent Access: Objetos no recuperados en 30 días.
 - Glacier instant retrieval: Objetos no recuperados en 90 días.
 - Glacier flexible retrieval: Configurable para objetos no recuperados entre 90 y +700 días.
 - Glacier deep archive: Configurable para objetos no recuperados entre 180 y +700 días.

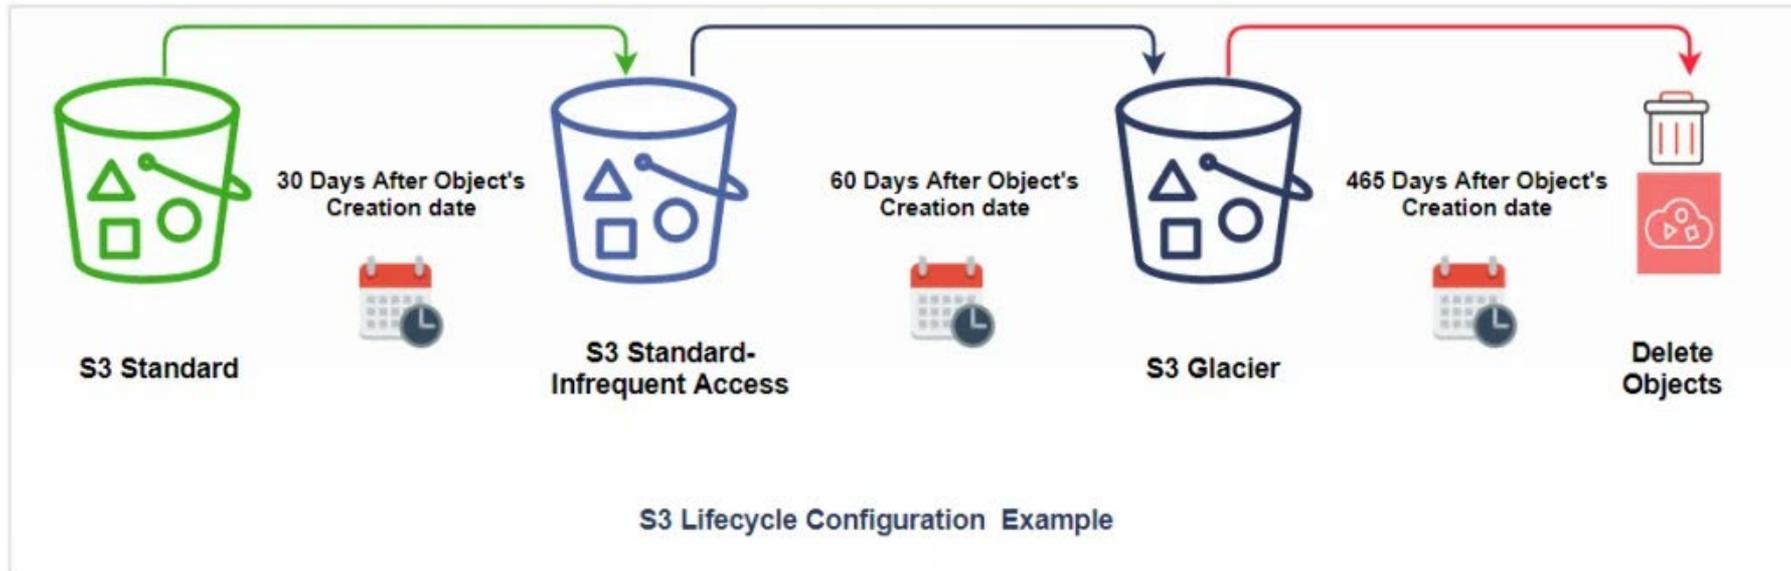
Elegir una clase u otra depende de las necesidades actuales y las diferencias principales es el tiempo de recuperación y el precio de una clase u otra.

Ciclo de vida en S3

- El ciclo de vida en Amazon S3 se refiere a las **políticas de ciclo de vida** (Lifecycle Policies) que **gestionan la transición y expiración de objetos** almacenados en S3 de manera automatizada.
- Estas políticas permiten a los usuarios definir reglas para **trasladar objetos entre diferentes clases de almacenamiento** y eliminar objetos innecesarios, optimizando costos y gestionando eficientemente los datos a lo largo del tiempo.

02. ¿Cómo se gestionan los datos correctamente en S3 con el paso del tiempo?

Ciclo de vida en S3



Versionado de datos en S3

- El versionado en Amazon S3 es una característica que permite mantener **múltiples versiones de un objeto en un bucket**. Esto facilita la protección contra la pérdida accidental de datos y la recuperación de versiones anteriores de objetos.
- Supongamos que tienes un bucket llamado "mis-datos-importantes" y subes un archivo llamado "datos.csv". Si habilitas el versionado y luego cargas una nueva versión de "datos.csv", S3 mantendrá ambas versiones del archivo. **Puedes listar las versiones del objeto y recuperar la versión que necesites.**

02

Almacenamiento de datos en AWS

Casos de uso de servicios de almacenamiento en Big Data



Casos de uso de S3



Backup y almacenamiento



Disaster recovery



Archive



Application hosting



Media hosting



Software delivery



Data lakes y big data analytics



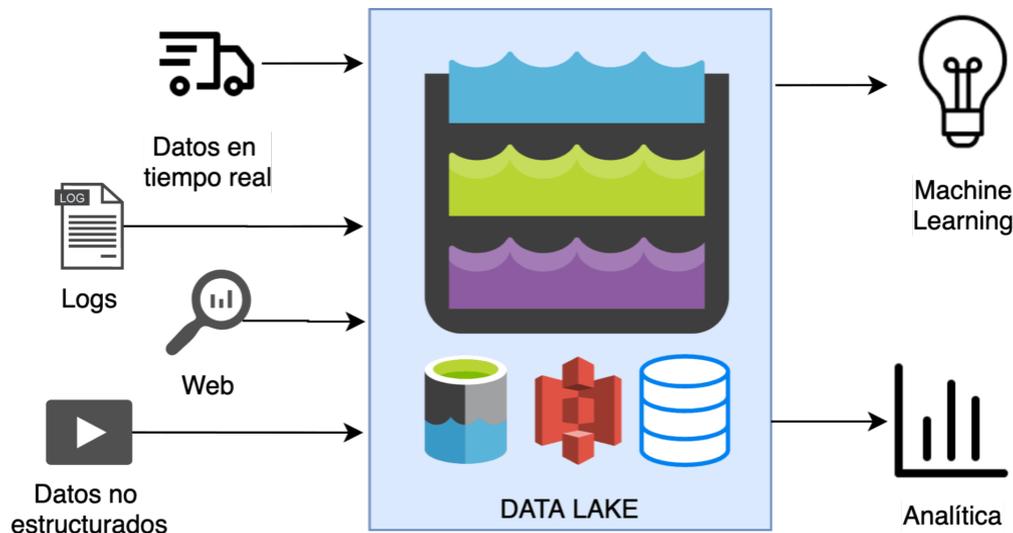
Static website

Datalake para análisis Big Data



Datalake

Un Data Lake es un almacenamiento centralizado que permite guardar todos los datos de una organización sin importar su tipo o formato. Es flexible, escalable y facilita el acceso y análisis de grandes volúmenes de datos, proporcionando una base poderosa para la toma de decisiones basadas en datos.



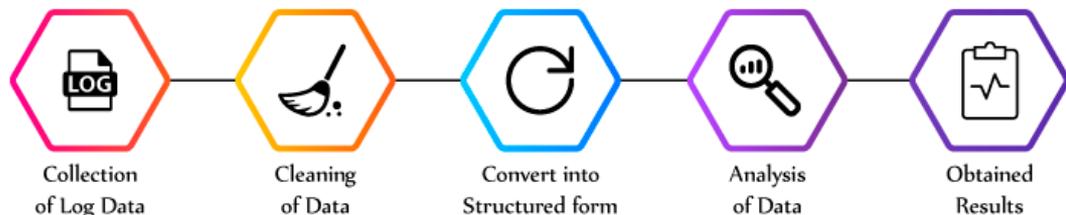


Almacenamiento de logs

Análisis de logs

El análisis de logs es fundamental en Big Data porque proporciona una visión detallada y en tiempo real del estado del sistema, comportamiento del usuario y el rendimiento de las aplicaciones. Esta información es vital para tomar decisiones informadas que beneficien tanto a la operación técnica como a la estrategia de negocio.

Log Analysis



03

Ingesta de datos en S3

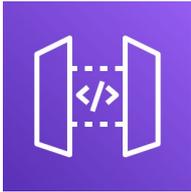
AWS Lambda: Ejecución de código serverless



03. ¿Para qué sirve una función lambda?

- En AWS (Amazon Web Services), una función lambda **es un servicio serverless que te permite ejecutar código sin tener que aprovisionar ni administrar servidores**. Puedes utilizar funciones lambda para ejecutar código en respuesta a eventos como cambios en datos, acciones del usuario o invocaciones de API.
- Estas funciones se pueden configurar para ejecutarse automáticamente en respuesta a eventos específicos, como subida de archivos a un bucket de Amazon S3, inserción de datos en una tabla de Amazon DynamoDB, o invocación de una API Gateway.

Integraciones más usadas con AWS Lambda



API Gateway



Kinesis



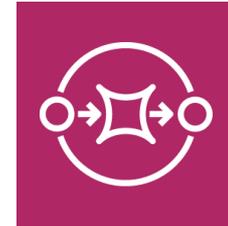
S3



Eventbridge



DynamoDB



**Simple Queue
Service (SQS)**

Algunas características

- El pago se hace por petición y tiempo de cómputo. El servicio es muy barato, casi gratis en la mayoría de casos de uso.
- Se puede programar con muchos lenguajes, como Node.js, Python, Java, C# o Ruby.
- Se puede configurar con una memoria RAM de 128MB - 10GB
- Capacidad de almacenamiento en disco temporal de 512MB - 10GB
- Máximo de ejecuciones concurrentes de 1000 y máximo de tiempo de ejecución de 15 minutos.

03. ¿Qué utilidad tiene una función lambda en el análisis de datos?

- **Preprocesamiento de datos**
- **Ingesta de datos desde distintos orígenes**
- **Transformaciones sencillas de pocos datos**
- **Orquestación de flujo de trabajo**
- **Manejo de metadatos (estados de ejecuciones)**
- **Envíos de correos electrónicos con información analítica (Lambda + Athena + SNS)**
- **Automatización de configuraciones para procesos big data**

03

Ingesta de datos en S3

Casos de uso reales de funciones lambda en análisis de datos



Ingesta de datos en datalake



Repositorio con datos csv



API Pública



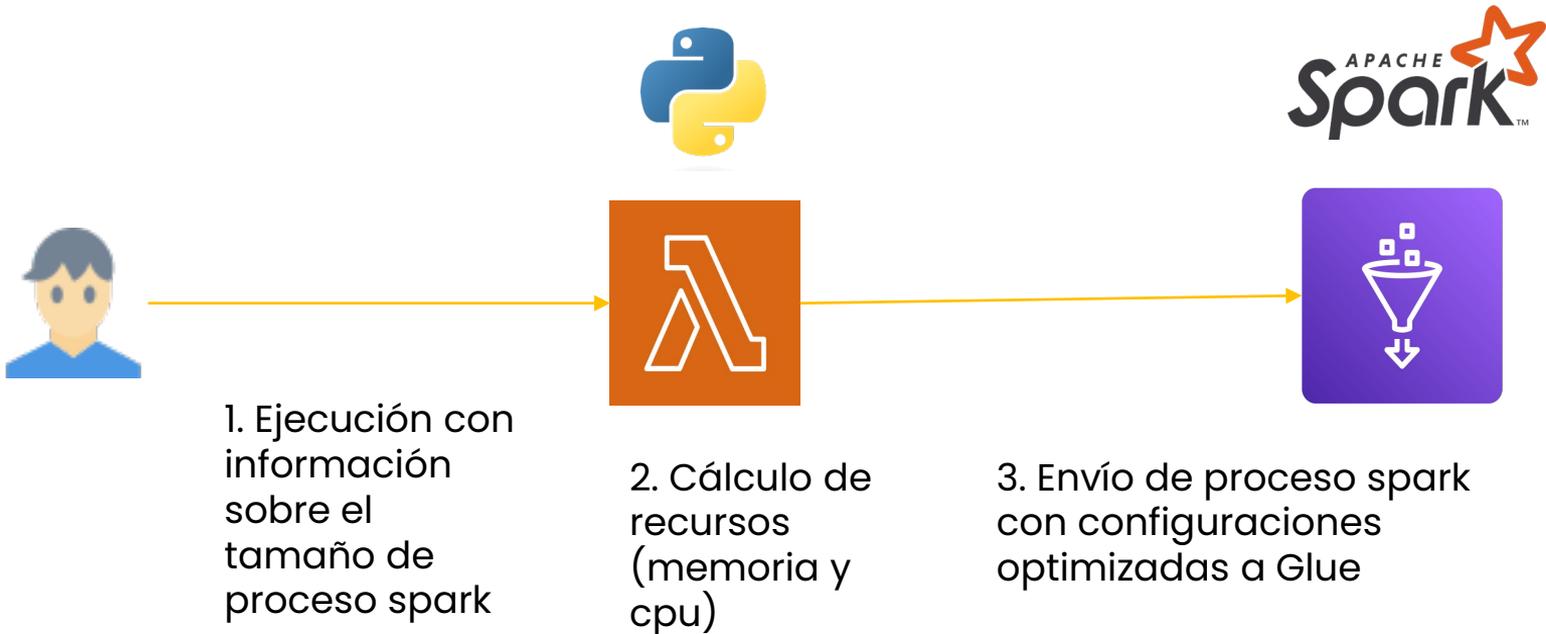
1. Extracción y
preprocesamiento
de datos

2. Escritura
de datos en
S3



Bucket ingesta de
datos

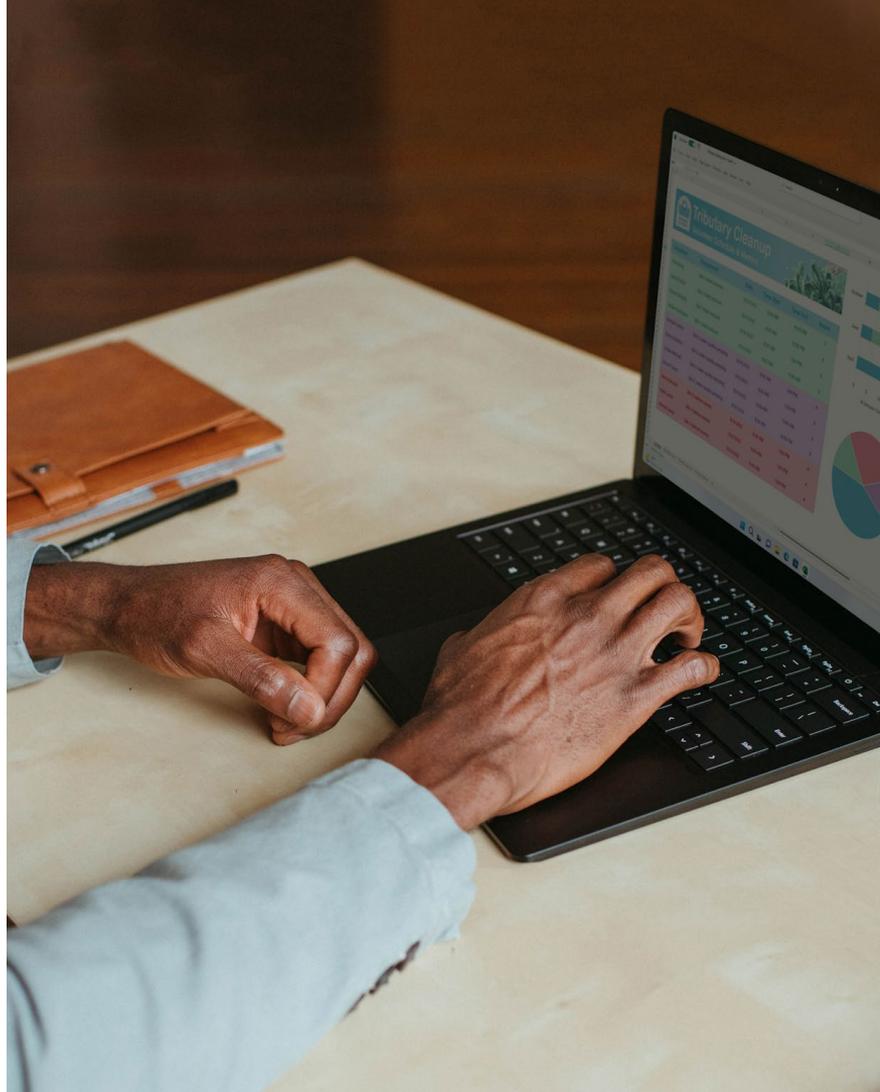
Orquestación de procesos big data



04

PROCESAMIENTO DE DATOS EN AWS

Amazon Glue Notebooks:
Procesamiento distribuido de
datos con PySpark



04. ¿Qué es el procesamiento distribuido de datos y que aporta en Big Data?

- El procesamiento de datos distribuido es una metodología en la cual **las tareas de procesamiento de datos se dividen y se ejecutan en múltiples nodos o máquinas dentro de una red**. Esto se hace para manejar grandes volúmenes de datos de manera más eficiente y rápida.
- La necesidad de esta metodología surge del problema que se tenía al intentar procesar datos con una única máquina, aunque tuviese paralelismo multinúcleo y multihilo, para el procesamiento de gigabytes, terabytes y petabytes se hace una tarea imposible para los tiempos que se requieren.

Un poco de historia:



Los primeros días: Computación centralizada

En las décadas de **1950 a 1970**, el **procesamiento de datos se realizaba principalmente en grandes mainframes**.

Estas máquinas centralizadas eran capaces de manejar grandes cantidades de datos, pero tenían limitaciones en cuanto a escalabilidad y costos.



Surgimiento del procesamiento distribuido

Durante las décadas de **1980 y 1990**, la **aparición de las redes de computadoras marcó el inicio de la transición hacia el procesamiento distribuido**. Se comenzaron a experimentar con clústeres de computadoras, donde varias máquinas trabajaban juntas para completar tareas de procesamiento de datos.

Un poco de historia:



La revolución de Hadoop

Inspirado por el Google File System (GFS), Doug Cutting y Mike Cafarella crearon el framework Hadoop en los 2000s, **esta herramienta utiliza el Hadoop Distributed File System (HDFS) y el modelo de programación MapReduce**, que dividía las tareas en sub-tareas más pequeñas que podían ser procesadas en paralelo por múltiples nodos.



Expansión y diversificación

En la década de 2010, se produjo una expansión y diversificación significativa en las tecnologías de procesamiento de datos. **Apache Spark fue introducido en 2014, ofreciendo procesamiento en memoria que era mucho más rápido que Hadoop y capaz de manejar tanto datos en lotes como en tiempo real.**

Tecnologías más usadas



Características de Spark más top

- Apache Spark es conocido por su **procesamiento en memoria**, realiza operaciones a velocidades mucho más altas que los sistemas tradicionales.
- **Ofrece un modelo de programación unificado** con APIs en Java, Scala, Python y R, facilitando el desarrollo en diversos lenguajes y soportando procesamiento batch, consultas interactivas, análisis en tiempo real y machine learning.
- Spark **se integra fácilmente con Hadoop**, utilizando HDFS y otros componentes del ecosistema Hadoop.
- Los RDDs (Resilient Distributed Datasets) en Spark son **estructuras de datos distribuidas** que permiten el procesamiento paralelo de grandes conjuntos de datos, ofreciendo tolerancia a fallos mediante su capacidad de reconstrucción automática.

Conceptos clave de Spark

Concepto	Descripción
SparkSession	Punto de entrada principal para trabajar con datos estructurados en Spark. Se utiliza para crear DataFrames, leer archivos, configurar opciones de Spark, entre otras tareas.
SparkContext	Contexto principal de Spark que sirve para establecer configuraciones mayormente. Se utiliza para crear RDDs, acceder a configuraciones de Spark, administrar recursos y controlar la ejecución de aplicaciones Spark en un clúster
Driver	El proceso principal de Spark que coordina las operaciones y programa la ejecución del trabajo en el clúster.

Conceptos clave de Spark

Conceptos	Descripción
Executors	Procesos que realizan el trabajo real de procesamiento de datos en el clúster, ejecutando tareas asignadas por el Driver.
Cluster manager	Gestor de clúster que coordina la asignación de recursos y la administración de los nodos en el clúster de Spark
RDD (Resilient Distributed Dataset)	Un conjunto de datos distribuido e inmutable que puede ser procesado en paralelo en un clúster de nodos Spark.

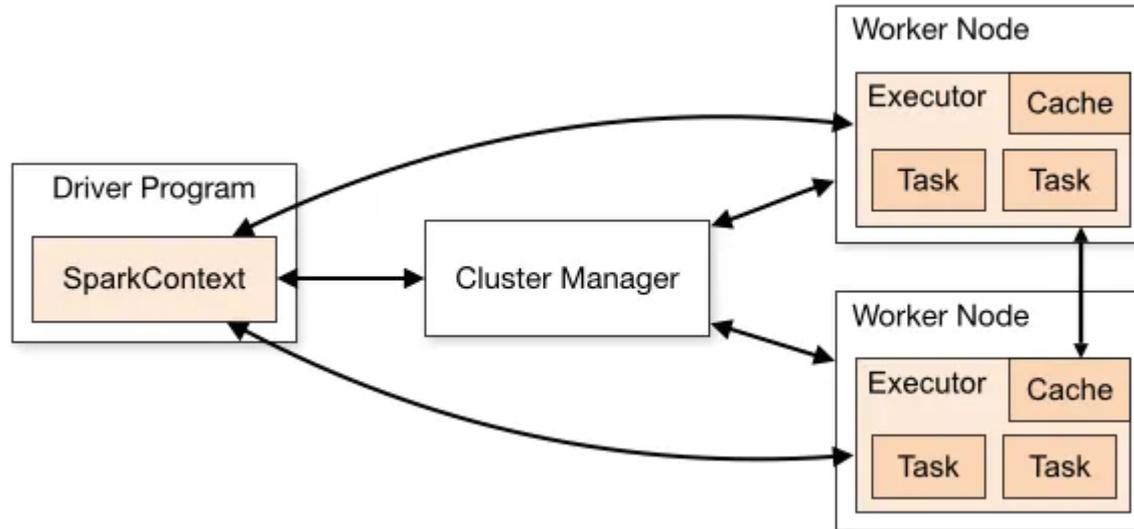
Conceptos clave de Spark

Conceptos	Descripción
DataFrames	Una abstracción de datos distribuida que organiza los datos en columnas con un esquema definido y permite realizar operaciones SQL y análisis de datos
Datasets	Similar a los DataFrames, pero con tipos de datos fuertemente tipados, lo que proporciona más seguridad y optimización de rendimiento.
Transformaciones	Operaciones que transforman un conjunto de datos en otro como 'map', 'filter', 'join', etc...

Conceptos clave de Spark

Conceptos	Descripción
Acciones	Operaciones que inician la ejecución de un plan y devuelven resultados al Driver, como 'collect', 'count', 'write' etc.

Arquitectura de Spark



- Glue Notebooks es una herramienta de Amazon Web Services (AWS) que forma parte de AWS Glue, un **servicio de procesamiento de datos distribuido serverless que facilita la preparación y carga de datos para análisis**.
- AWS Glue Notebooks permite a los usuarios **crear, editar y ejecutar scripts interactivos en Jupyter notebooks**, una popular plataforma de código abierto para la computación interactiva y colaborativa.

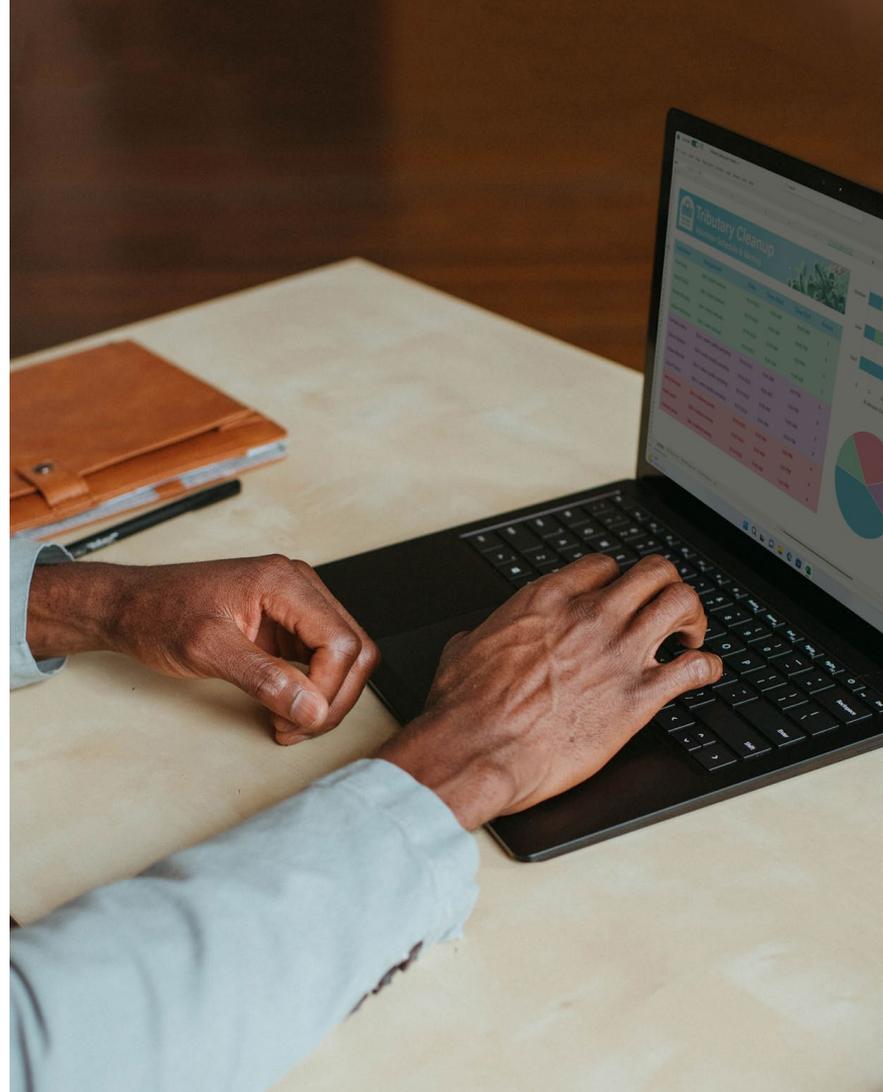
Beneficios de Glue Notebooks

- **Agilidad:** Facilita el desarrollo rápido de soluciones de datos con resultados inmediatos, mejorando la productividad de los equipos.
- **Escalabilidad:** Permite manejar grandes volúmenes de datos sin preocuparse por la infraestructura, adaptándose a las necesidades crecientes.
- **Eficiencia:** Reduce significativamente el tiempo necesario para la preparación y transformación de datos, optimizando los flujos de trabajo.
- **Colaboración:** Proporciona un entorno compartido donde los equipos de datos pueden trabajar juntos de manera efectiva, mejorando la cooperación y la comunicación.

04

PROCESAMIENTO DE DATOS EN AWS

Ejemplos prácticos de procesamiento de datos en AWS.



04. Datos estructurados, semi-estructurados y no estructurados.



Unstructured

PDFs, JPEGs,
MP3, Movies, ...

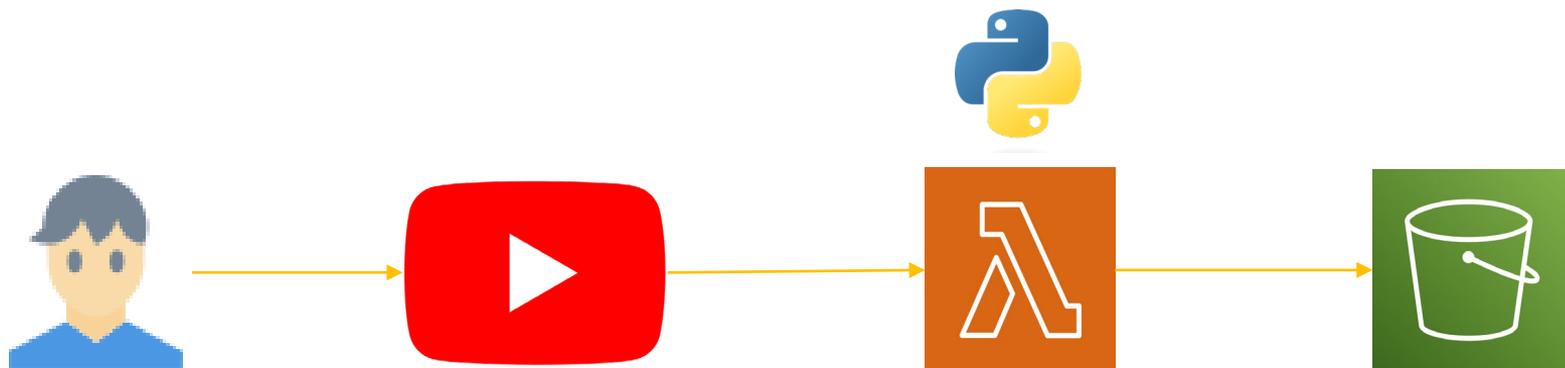
Semi-structured

CSV, JSON, XML,
MongoDB, ...

Structured

Oracle, MSSQL,
MySQL, DB2, ...

PROCESAMIENTO DE IMÁGENES

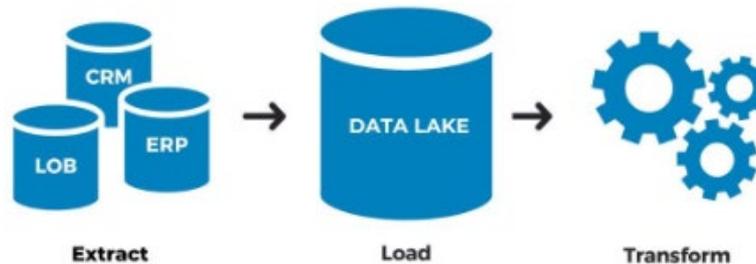
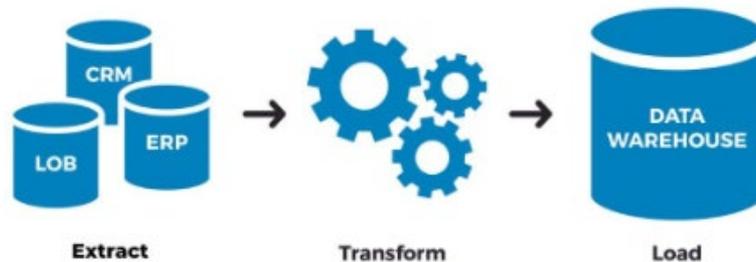


1. Usuario sube vídeo con foto de miniatura

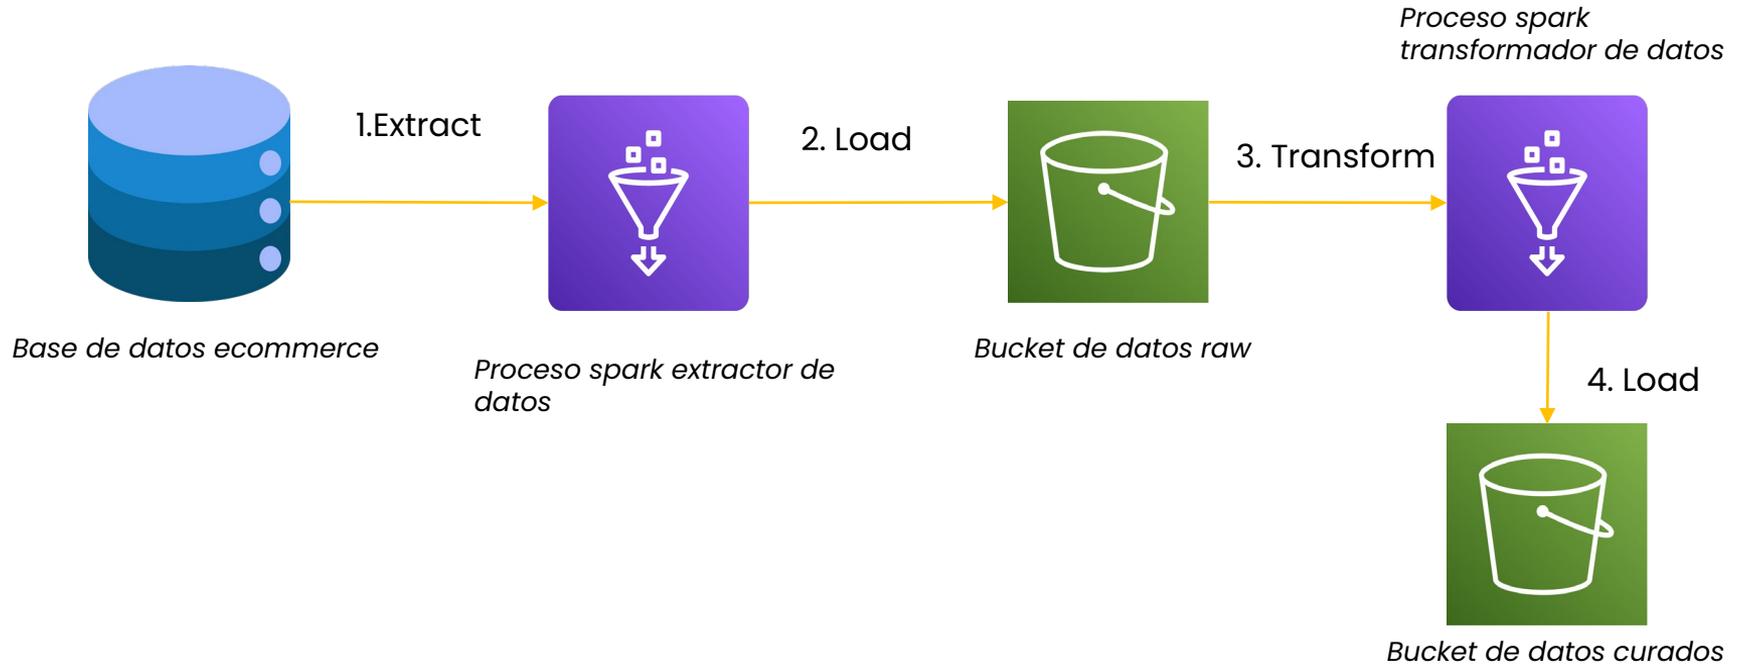
2. Extracción de imagen de miniatura y reducción de dimensión a thumbnail

3. Carga de foto redimensionada en bucket de S3

ETL vs ELT



CASO DE USO ELTL



05

CONSULTA DE DATOS EN AWS

Amazon Glue Data Catalog: Meta Almacén
de esquemas y bases de datos.





Meta almacén de datos

Meta almacén

Un meta almacén de datos, o catálogo de datos, es esencial en Big Data porque organiza y describe los ficheros del datalake.

Facilita la búsqueda y el descubrimiento de datos y el cumplimiento de políticas. Además, ayuda a los equipos a trabajar juntos de manera más eficiente al compartir una visión clara y accesible de los datos.



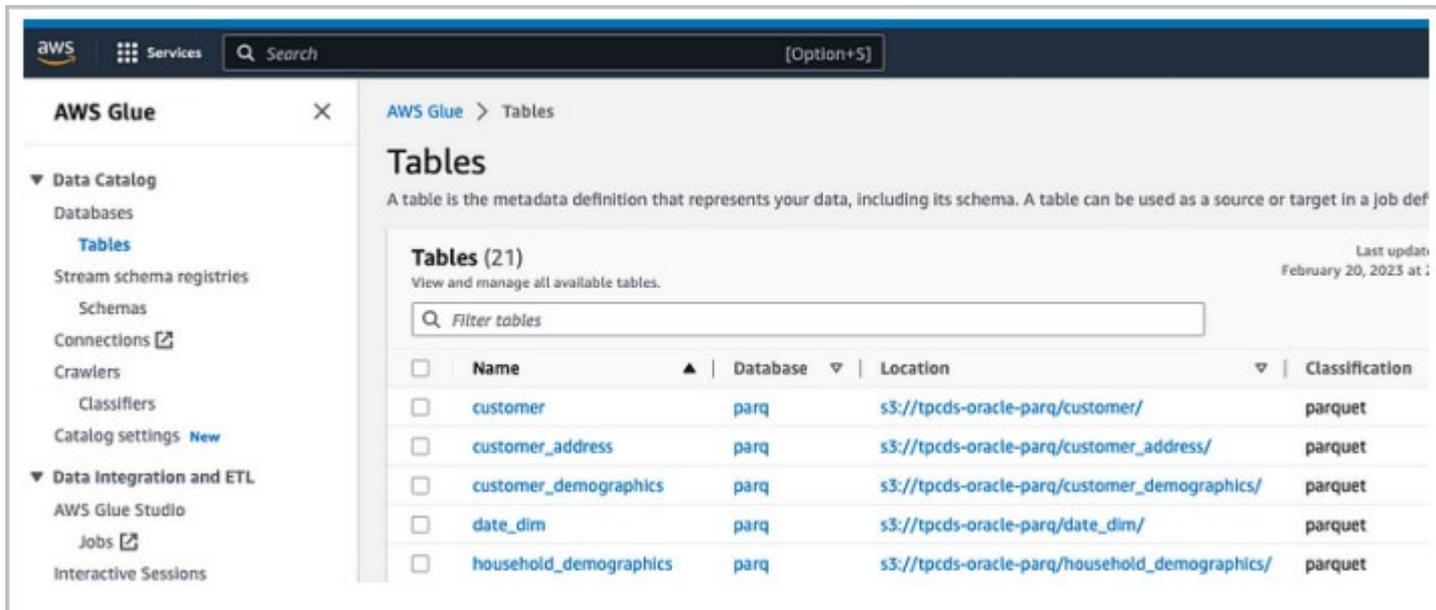
¿Por qué es importante un meta almacén?

La necesidad de un meta almacén en big data surge por varias razones:

- No tenemos el concepto de base de datos, tablas ni esquema.
- Para referirnos a una “tabla” de la única forma que podemos es a través de su ruta de S3.

- Glue Data Catalog es un servicio de AWS que **centraliza y gestiona metadatos de diversas fuentes de datos, la principal es S3**. Permite descubrir y organizar datos, creando una base de metadatos con información sobre ubicaciones, esquemas y versionados de tablas, facilitando así llevar un registro de todos los cambios hechos en cada tabla.
- Además ofrece **integración con otros servicios de AWS como Athena y Redshift** para poder explorar los datos con queries SQL y permitiendo un análisis más amigable.

Ejemplo de tablas en Glue Data Catalog



The screenshot shows the AWS Glue console interface. On the left is a navigation sidebar with categories like 'Data Catalog' and 'Data Integration and ETL'. The main area is titled 'Tables' and contains a search bar, a table with 21 entries, and a description of what a table is. The table lists columns: Name, Database, Location, and Classification. The first five rows are visible, showing tables like 'customer', 'customer_address', 'customer_demographics', 'date_dim', and 'household_demographics', all with a 'parquet' classification.

Tables (21)
View and manage all available tables. Last updated: February 20, 2023 at :

<input type="checkbox"/>	Name ▲	Database ▼	Location ▼	Classification
<input type="checkbox"/>	customer	parq	s3://tpcds-oracle-parq/customer/	parquet
<input type="checkbox"/>	customer_address	parq	s3://tpcds-oracle-parq/customer_address/	parquet
<input type="checkbox"/>	customer_demographics	parq	s3://tpcds-oracle-parq/customer_demographics/	parquet
<input type="checkbox"/>	date_dim	parq	s3://tpcds-oracle-parq/date_dim/	parquet
<input type="checkbox"/>	household_demographics	parq	s3://tpcds-oracle-parq/household_demographics/	parquet

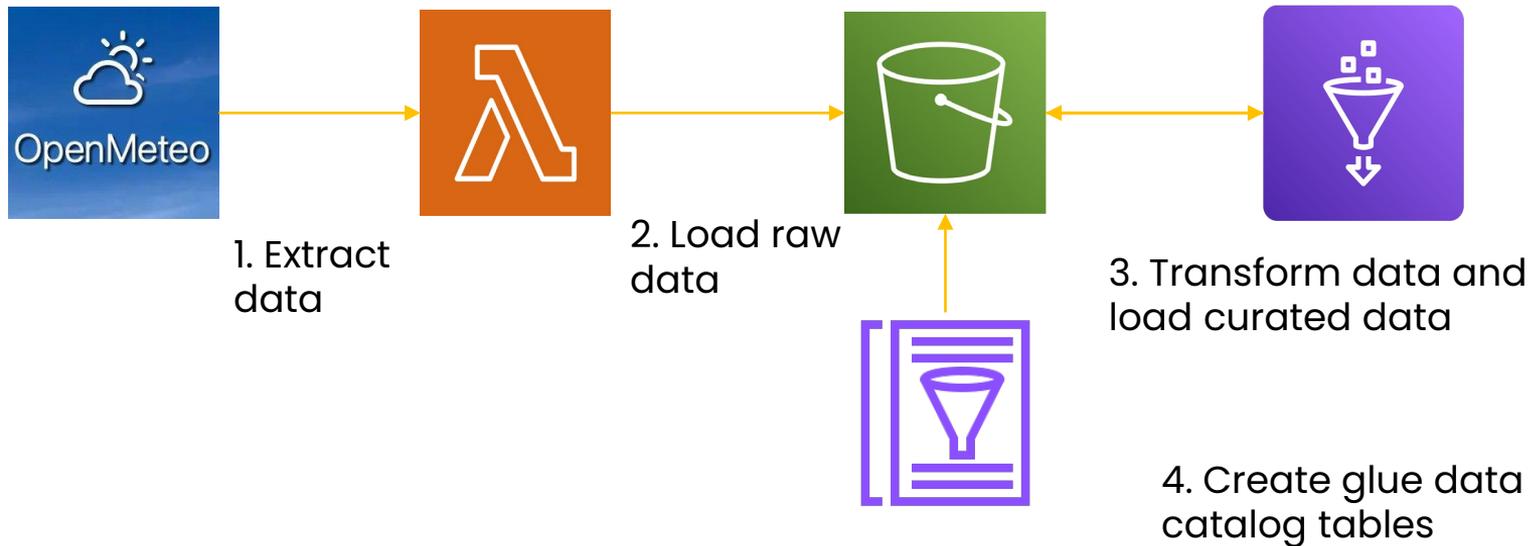
05

CONSULTA DE DATOS EN AWS

Amazon Athena: Consultas ad hoc en
datos almacenados en S3



¿Cómo analizamos los datos transformados?



- Amazon Athena es un **servicio de consulta interactiva que permite analizar datos en Amazon S3** utilizando SQL estándar. Es serverless, por lo que no requiere administrar infraestructura, y cobra solo por las consultas ejecutadas.
- Athena se **integra con AWS Glue Data Catalog para gestionar metadatos y facilitar el análisis de datos** estructurados, semiestructurados y no estructurados. Es ideal para análisis ad-hoc y puede procesar grandes volúmenes de datos rápidamente..

Ejemplo de query en Amazon Athena

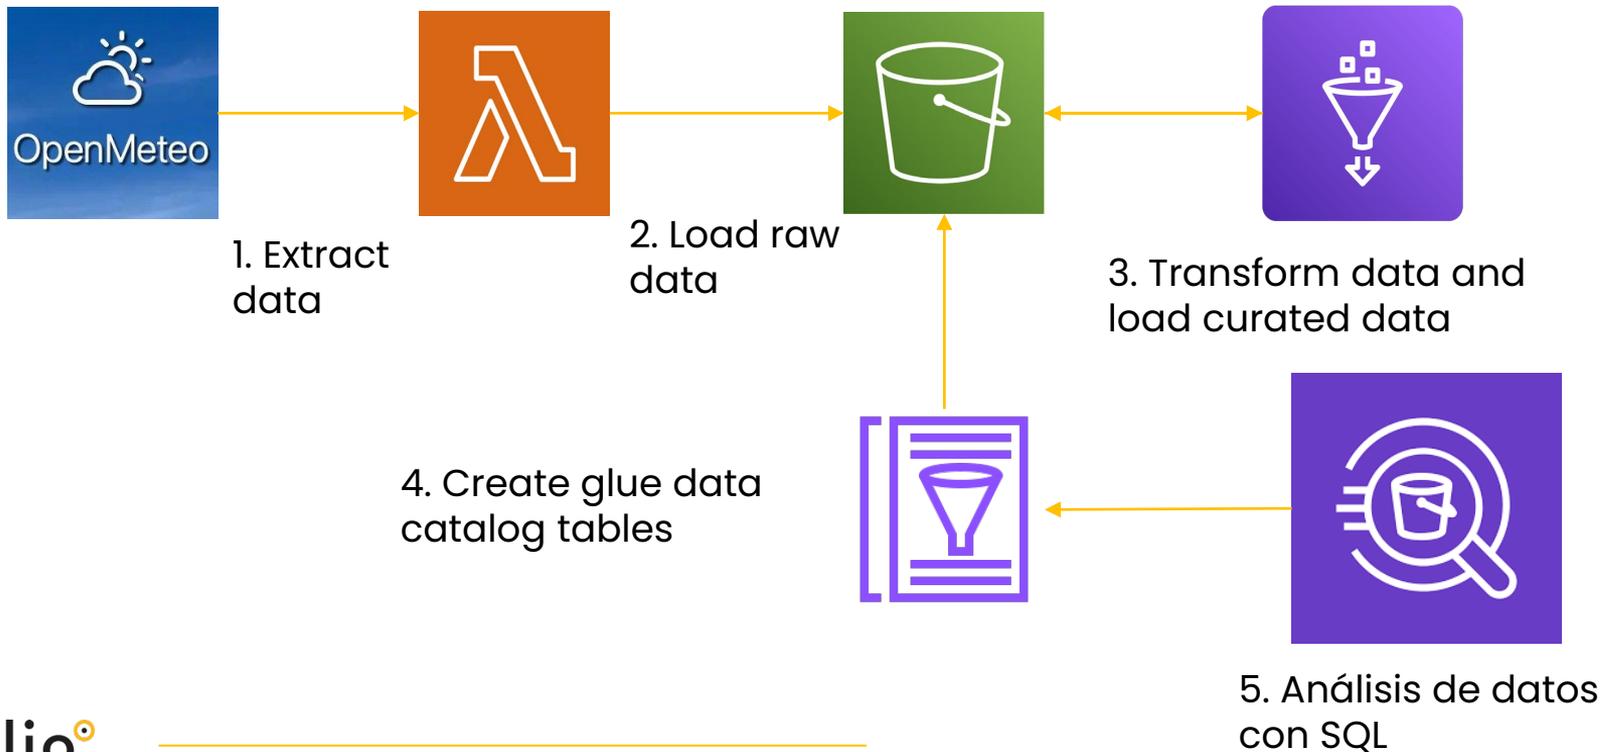
The screenshot displays the Amazon Athena console interface. On the left, the 'Data' sidebar shows the 'Data source' set to 'AwsDataCatalog' and the 'Database' set to 'default'. Under 'Tables and views', three tables are listed: 'customer_dim', 'poblaciones', and 'provincias'. The main query editor shows a SQL query: `1 SELECT * FROM "default"."provincias"`. Below the editor, there are buttons for 'Run again', 'Explain', 'Cancel', 'Clear', and 'Create'. A 'Reuse query results' toggle is set to 'on' with a note 'up to 60 minutes ago'. The 'Query results' tab is active, showing a status of 'Completed' with a green checkmark. Performance metrics are displayed: 'Time in queue: 93 ms', 'Run time: 473 ms', and 'Data scanned: 0.86 KB'. At the bottom, there are buttons for 'Copy' and 'Download results'.

Características de Athena

- Aunque por defecto la fuente de datos de Athena es Glue Data Catalog, también ofrece multitud de conectores hacia otras fuentes.
- Tiene un precio de 5.00\$ por cada TB de datos escaneado.
- Soporta lectura de ficheros parquet, csv, json, orc y avro.
- Permite descarga de resultados de queries en formato csv, guardado de queries y exportación de resultados hacia un bucket de S3.
- El lenguaje de consultas es SQL, está construido sobre el motor de consultas presto.

Podemos encontrar las funciones built-in en este enlace de AWS
<https://docs.aws.amazon.com/athena/latest/ug/functions.html>

¿Cómo analizamos los datos transformados?



06

VISUALIZACIÓN DE DATOS Y COMUNICACIÓN DE RESULTADOS

Amazon QuickSight: Herramienta de reporting

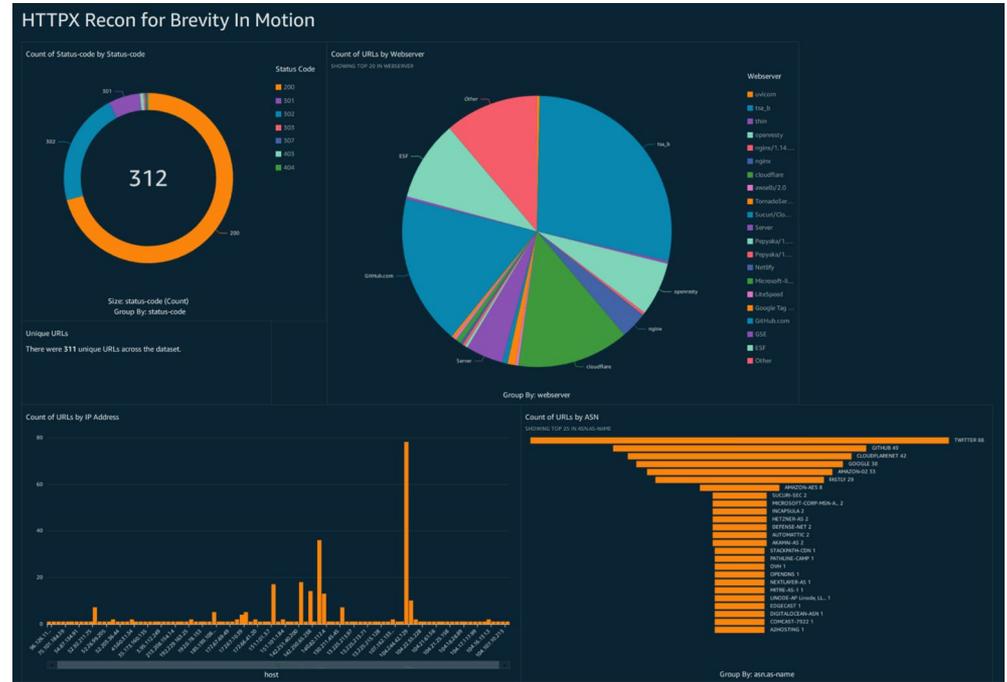


Business Intelligence



Dashboard

Un dashboard es una herramienta visual que muestra datos clave y métricas de rendimiento en un formato fácilmente comprensible. Facilitan la toma de decisiones, mejoran la eficiencia operativa, permiten un seguimiento continuo de objetivos y estrategias, y ayudan a identificar tendencias y problemas rápidamente.



Tipos de gráficos más comunes



Barras

Comparar diferentes categorías o grupos, mostrando cantidades o frecuencias de manera clara



Líneas

Visualizar tendencias a lo largo del tiempo, permitiendo un seguimiento fácil de cambios y patrones



Dispersión

Muestran la relación entre dos variables mediante puntos distribuidos en el gráfico.



Pastel

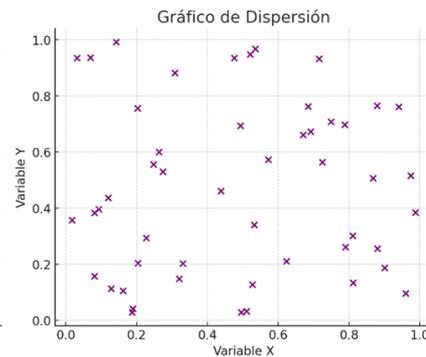
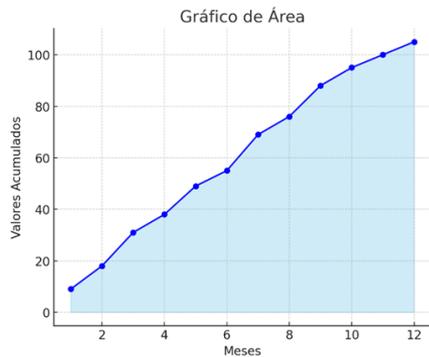
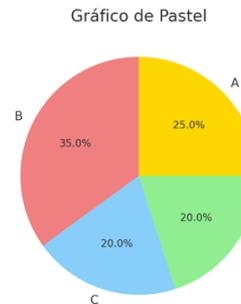
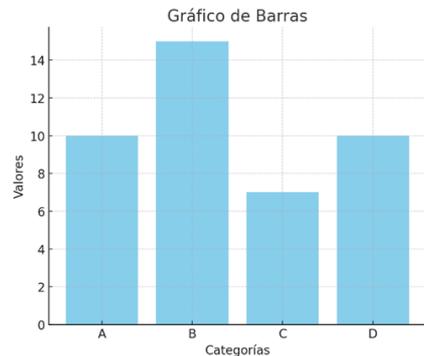
Representan proporciones o partes de un todo, mostrando la contribución de cada categoría a un total



Área

Similares a los gráficos de líneas, pero con áreas sombreadas debajo de las líneas. Utilizados para mostrar acumulaciones

Tipos de gráficos más comunes



06. ¿Cómo funciona Quicksight y que debemos tener en cuenta?

- Amazon QuickSight es un servicio de inteligencia empresarial basado en la nube ofrecido por Amazon Web Services (AWS). **Permite a los usuarios crear y publicar dashboards** que incluyen visualizaciones de datos, gráficos y tablas, accesibles desde cualquier dispositivo.
- Además, QuickSight se integra fácilmente con otros servicios de AWS y diversas fuentes de datos, facilitando la consolidación y análisis de información heterogénea. Su capacidad de autoescalado y su modelo de pago por usuario lo convierten en una opción flexible y económica para empresas de todos los tamaños.

Características de Quicksight

- Existen dos modelos de Quicksight la versión standard con usuarios individuales y la versión enterprise que ofrece grupos de usuarios.
- En la versión enterprise existen dos roles diferentes, autores con un precio de 24\$/mes y los lectores con un precio de 3\$/mes
- Quicksight puede graficar datos de cualquier recurso de almacenamiento de AWS y además de fuentes externas como bases de datos on-premise, Jira, Salesforce, ficheros CSVs.
- Ofrece una herramienta que hace los reportes rápidos y escalables llamada SPICE que ofrece cómputo en memoria de los datos almacenados en Quicksight.

Para crear un usuario en Quicksight tenemos que acceder al recurso desde el portal y **registrarnos con nuestro correo electrónico** asociado a la cuenta de AWS.

Welcome to QuickSight

You are about to access QuickSight in AWS Account 

Email address

By choosing to continue, you will be provisioned as a user in the QuickSight account. Monthly charges for QuickSight usage will apply until you or an administrator revokes access privileges to this account.

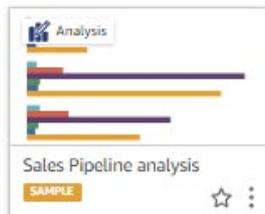
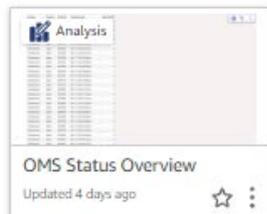
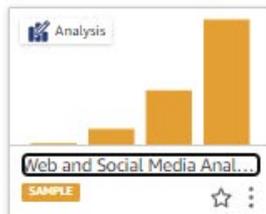
Continue

Conceptos clave de Quicksight

- **Datasets:** Conjuntos de datos importados o conectados que se utilizan para crear visualizaciones y análisis en QuickSight.
- **Analyses:** Entornos interactivos donde los usuarios exploran y visualizan datos utilizando gráficos y tablas
- **Dashboards:** Paneles interactivos y compartibles que presentan visualizaciones y KPIs derivados de los análisis.
- **Security & Permissions:** Configuraciones que controlan el acceso y los permisos de usuarios y grupos para asegurar la protección de los datos y recursos.

Página principal Quicksight

- ★ Favorites
- 🕒 Recent
- 📁 My folders
- 📁 Shared folders
- 📊 Dashboards
- 📊 Analyses**
- 📊 Datasets
- 📊 Topics
- 🗨️ Community



Mejora de performance en Quicksight

SPICE (Super-fast, Parallel, In-memory Calculation Engine) es el motor de análisis en memoria de Amazon QuickSight que permite realizar consultas rápidas y análisis interactivos.

Mejora los reportes al proporcionar tiempos de respuesta más rápidos, capacidad de manejar grandes volúmenes de datos y reducción de carga en las bases de datos fuentes

SPICE Capacity



SPICE Usage (695.8MB)



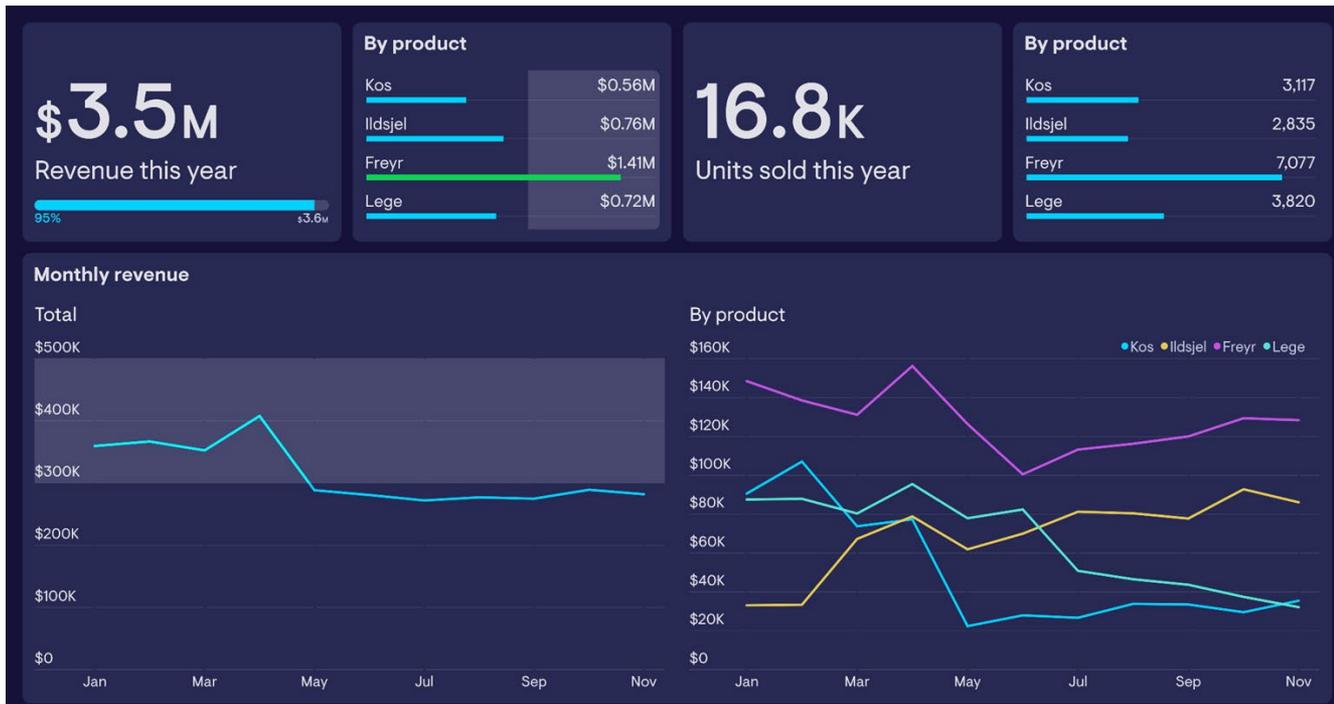
06

VISUALIZACIÓN DE DATOS Y COMUNICACIÓN DE RESULTADOS

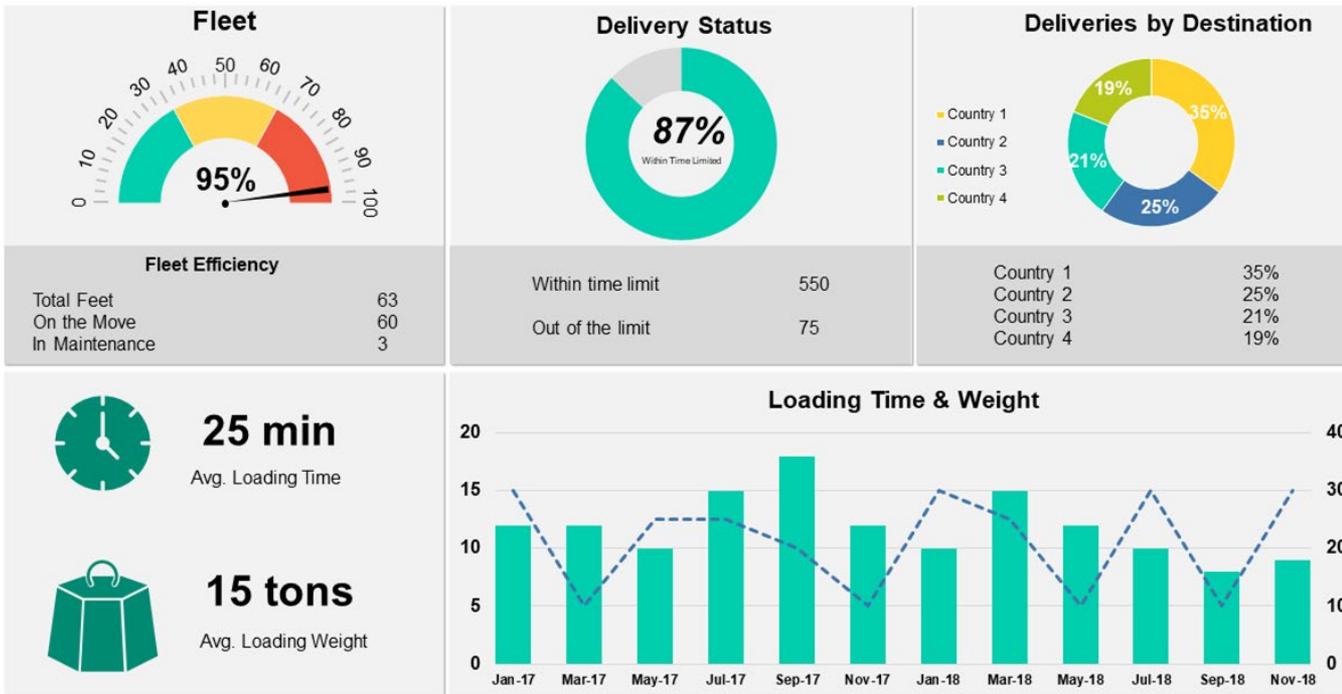
Casos de uso típicos de dashboard en
empresas



Dashboard ventas por producto



Dashboard de entregas de mercancía



Dashboard recruitment en RRHH



07

ORQUESTACIÓN DE FLUJOS DE TRABAJO

AWS Step functions: Orquestación de flujos de trabajo



07. ¿Qué es la orquestación de un flujo de trabajo y cómo step function nos ayuda?

- La orquestación de un flujo de trabajo es la **coordinación y ejecución secuencial de varias tareas** o procesos interrelacionados.
- AWS Step Functions es un servicio que facilita la **orquestación de estos flujos de trabajo al permitir definir, ejecutar y monitorear pasos individuales de manera eficiente.**

Ofrece una manera sencilla de coordinar tareas de los distintos servicios de AWS, lo que simplifica el desarrollo y la automatización de procesos complejos como puede ser el de procesamiento de datos.

07. ¿Qué es la orquestación de un flujo de trabajo y cómo step function nos ayuda?

- **Flujos de trabajo de ETL**
- **Análisis de datos en tiempo real**
- **Generación de informes automatizados**
- **Procesamiento de datos de eventos**
- **Generación de facturas automáticas ecommerce**
- **Gestión de llamadas a microservicios**
- **Preprocesamiento y entrenamiento de datos para modelos de machine learning**

Página principal del servicio Step Functions

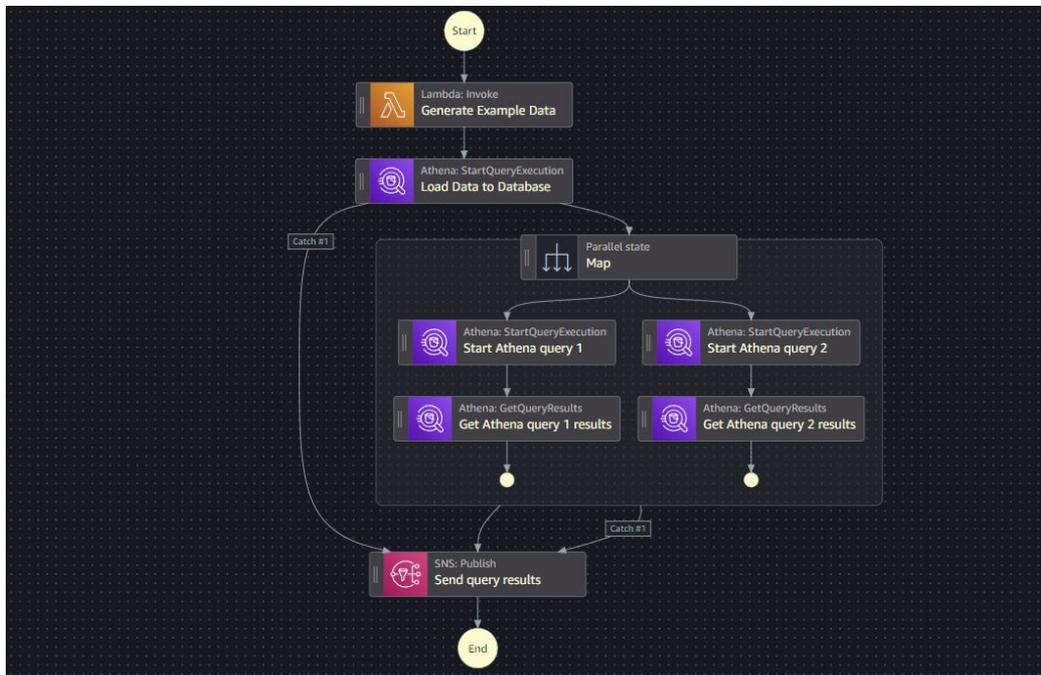
State machines (15) View execution counts View details Edit Copy to new Delete Create state machine

Execution counts are based on the most recent 1000 executions

Search for state machines Any type < 1 > ⊙

Name	Type	Creation date	Status	Total	Running	Succeeded	Failed	Timed out	Aborted
ikp-oms-workload-dev	Standard	Feb 12, 2024, 12:15:05 (UTC+01:00)	Active	270	0	241	27	0	2
ikp-copy-data-environment-dev	Standard	Feb 5, 2024, 13:00:05 (UTC+01:00)	Active	0	0	0	0	0	0
ikp-launch-comerzzia-workload-dev	Standard	Jan 2, 2024, 11:17:13 (UTC+01:00)	Active	87	0	54	17	0	16
ikp-launch-microbatch-workload-dev	Standard	Dec 18, 2023, 12:10:33 (UTC+01:00)	Active	54	0	20	31	0	3
ikp-etl-rgpd-and-nav-aggr-dev	Standard	Nov 21, 2023, 16:46:28 (UTC+01:00)	Active	0	0	0	0	0	0
ikp-etl-navision-dev	Standard	Nov 21, 2023, 16:45:49 (UTC+01:00)	Active	0	0	0	0	0	0
ikp-etl-data-from-salesforce-dev	Standard	Nov 13, 2023, 16:38:56 (UTC+01:00)	Active	0	0	0	0	0	0

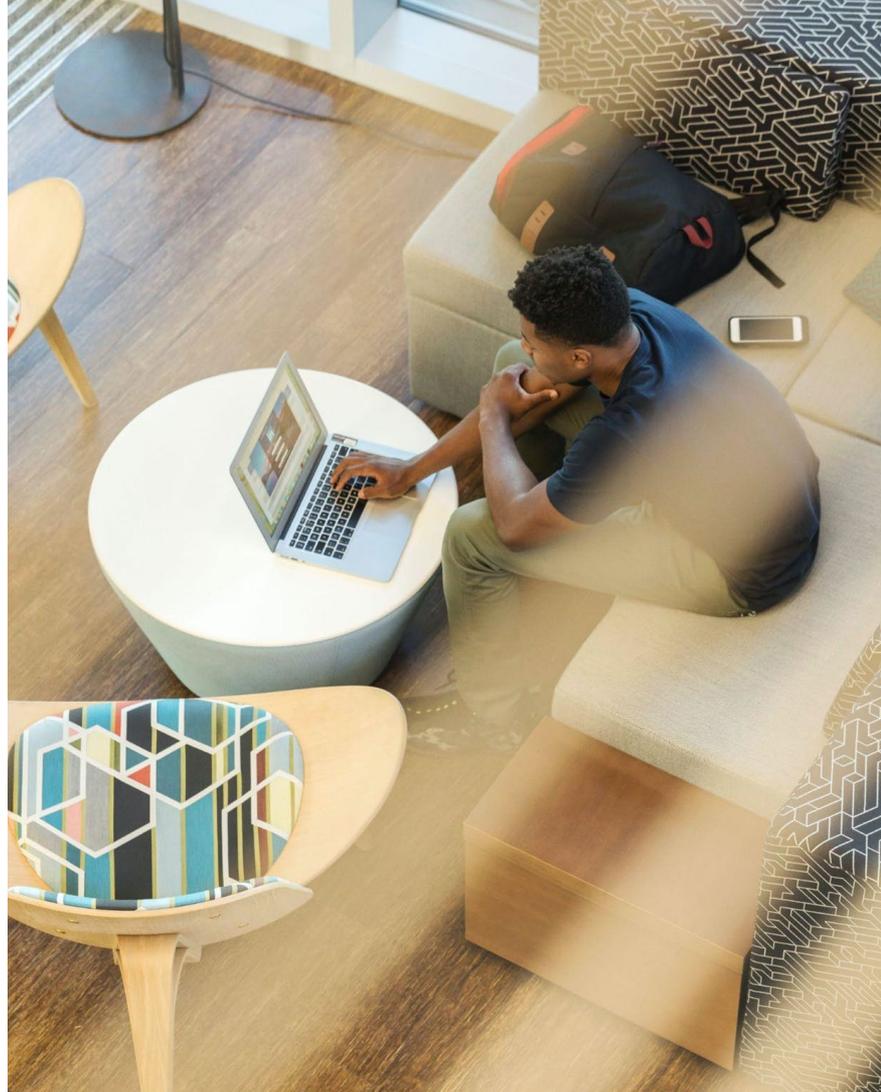
Orquestación de ingesta y consulta de datos



08

RECOMENDACIONES FINALES Y PRÓXIMOS PASOS

Siguientes pasos como analista de datos
en cloud



Roles más comunes en ciencia de datos



**Ingeniero
de datos**



**Arquitecto
de datos**



**Analista
de datos**



**Científico
de datos**



**Ingeniero de
machine
learning**

1. Enfócate en un sólo rol:

Lo más importante para este sector es aprender las tecnologías más demandadas para uno de los roles.

Céntrate en esas tecnologías enfocadas a un puesto de trabajo.

2. LinkedIn:

La plataforma para encontrar trabajo más grande del mundo es LinkedIn, si no tienes un perfil atractivo y no eres activo en la plataforma compartiendo tus logros o pensamientos te va a costar más encontrar un buen trabajo.

3. Piensa en grande:

Intenta siempre conectar las ideas que hay detrás de cada tecnología y qué problema resuelve en las empresas, de esta manera te será mucho más sencillo avanzar en tu carrera y encontrar trabajos cada más interesantes.

4. Síndrome del impostor:

No te abrumes por lo complejo y lo profundo que es el mundo tecnológico, todos empezamos por la base y nos bloqueamos horas y horas con problemas que después nos parecen muy sencillos.

La frustración es parte de la tecnología.

5. La historia importa

La ciencia de datos tiene una historia muy corta por el momento, esto es una ventaja ya que si entendemos como empezaron estas tecnologías nos costará mucho menos entender el presente.

6. Date tiempo

Aprender una nueva profesión lleva tiempo y en este sector no es diferente, es más, cuesta lo suyo.

Rodéate de los mejores profesores y mentores para acortar el proceso lo más rápido posible.

- Para validar tus conocimientos en cloud antes las empresas **es muy recomendable conseguir las certificaciones de pago** que ofrecen las distintas plataformas cloud.
- Cada plataforma cloud tiene sus **caminos de certificaciones dependiendo de que rol vas a desempeñar**, no son las mismas certificaciones para un ingeniero de datos que para un científico de datos o para un desarrollador web. Además estas empresas te ofrecen contenido teórico y práctica gratis para estudiarlas.

Las certificaciones no son muy caras, pero **podemos encontrar muchas veces Vouchers que ofrecen descuentos** sobre todo para la nube de Microsoft, Azure.

Páginas para practicar exámenes gratis

EXAMTOPICS - Expert Verified, Online, Free.



MAIL US
team@examtopics.com

- HOME
- EXAMTOPICS PRO
- POPULAR EXAMS
- VIEW ALL EXAMS
- DOWNLOAD FREE
- NEW COURSES
- CONTACT
- FORUM
- SEARCH

Amazon Forum Discussions

List of all Amazon exams

- ANS-C00: AWS Certified Advanced Networking - Specialty
- AWS Certified Advanced Networking - Specialty ANS-C01: AWS Certified Advanced Networking - Specialty ANS-C01 **Popular**
- AWS Certified Alexa Skill Builder - Specialty: AWS Certified Alexa Skill Builder - Specialty
- AWS Certified Big Data - Specialty: exam
- AWS Certified Cloud Practitioner: AWS Certified Cloud Practitioner (CLF-C01) **Popular**
- AWS Certified Cloud Practitioner CLF-C02: AWS Certified Cloud Practitioner CLF-C02 **Popular**
- AWS Certified Data Analytics - Specialty: AWS Certified Data Analytics - Specialty (DAS-C01) **Popular**
- AWS Certified Database - Specialty: AWS Certified Database - Specialty **Popular**
- AWS Certified Data Engineer - Associate DEA-C01: AWS Certified Data Engineer - Associate DEA-C01 **Popular**
- AWS Certified Developer Associate: AWS Certified Developer Associate **Popular**
- AWS Certified Developer - Associate DVA-C02: AWS Certified Developer - Associate DVA-C02 **Popular**
- AWS Certified DevOps Engineer - Professional DOP-C02: AWS Certified DevOps Engineer - Professional DOP-C02 **Popular**
- AWS Certified Machine Learning - Specialty: AWS Certified Machine Learning - Specialty (MLS-C01) **Popular**
- AWS Certified SAP on AWS - Specialty PAS-C01: AWS Certified SAP on AWS - Specialty PAS-C01
- AWS Certified Security - Specialty: AWS Certified Security - Specialty **Popular**
- AWS Certified Security - Specialty SCS-C02: AWS Certified Security - Specialty SCS-C02 **Popular**
- AWS Certified Solutions Architect - Associate SAA-C02: AWS Certified Solutions Architect - Associate SAA-C02
- AWS Certified Solutions Architect - Associate SAA-C03: AWS Certified Solutions Architect - Associate SAA-C03 **Popular**
- AWS Certified Solutions Architect - Professional: AWS Certified Solutions Architect - Professional **Popular**
- AWS Certified Solutions Architect - Professional SAP-C02: AWS Certified Solutions Architect - Professional SAP-C02 **Popular**

Páginas para practicar exámenes gratis

The screenshot displays the A Cloud Guru website interface. At the top left is the logo for A Cloud Guru, a Pluralsight company. A search bar is located next to it. Navigation icons for Dashboard, Browse, Labs, Playground, and For Business are visible. A green 'Upgrade' button and a user profile icon are on the right. The main content area is divided into two sections. The 'Recommended for you' section, based on user interests and onboarding, features four course cards: 'AWS Certified Solutions Architect - Professional (SAP-C02)' (40.1 hours), 'AWS Certified Security - Specialty (SCS-C02)' (32.2 hours), 'AWS Certified Solutions Architect - Associate (SAA-C03)' (64.7 hours), and 'Introduction to AWS' (5.7 hours, free for novices). The 'Good afternoon!' section welcomes the user back and includes a 'Hands-on Learning' section with a 'Hands-on Labs' button and three options: 'Cloud Sandbox', 'Instant Terminal', and 'Cloud Server'.

Páginas para practicar exámenes gratis



Search for products...

All Courses

Contact Us

MY ACCOUNT

Home / AWS Cloud

AWS Cloud

Showing all 10 results

Sort by popularity



AWS Cloud

AWS Solutions Architect Associate (SAA-C03)



AWS Cloud

AWS Certified Cloud Practitioner (CLF-C02)



AWS Cloud

AWS Certified Developer Associate (DVA-C02)

Camino de certificaciones en AWS

Roles y responsabilidades Rutas de AWS Certification

Arquitectura

Arquitecto de soluciones

Diseñe, desarrolle y administre la infraestructura y los activos en la nube y trabaje con DevOps para migrar las aplicaciones a la nube.



Arquitecto de aplicaciones

Diseñe aspectos importantes de la arquitectura de aplicaciones, como la interfaz de usuario, el middleware y la infraestructura, y garantice sistemas escalables, fiables y administrables en toda la empresa.



Análisis de datos

Ingeniero de datos de la nube

Automatice la recopilación y el procesamiento de datos estructurados o semiestructurados y supervise el rendimiento de la canalización de datos.



Camino de certificaciones en AWS

IA/ML

Ingeniero de machine learning

Investigue, cree y diseñe sistemas de inteligencia artificial (IA) para automatizar los modelos predictivos y diseñe sistemas, modelos y esquemas de machine learning.



Opcional para profesionales de TI y la nube

Caminos de certificaciones en AWS

Desarrollo

Ingeniero de desarrollo de software

Desarrolle, cree y administre software en todas las plataformas y dispositivos.



Opcional para profesionales de TI y la nube

Operaciones

Administrador de sistemas

Instale, actualice y administre los componentes de cómputo y el software e integre los procesos de automatización.



Opcional para profesionales de TI y la nube

Para profundizar

Ingeniero de la nube

Implemente y opere la infraestructura de cómputo en red de una organización e implemente sistemas de seguridad para proteger los datos.



Opcional para profesionales de TI y la nube

Para profundizar

Camino de certificaciones en AWS

DevOps

Ingeniero de pruebas

Integre las prácticas recomendadas de pruebas y calidad para el desarrollo de software, desde el diseño hasta el lanzamiento, durante todo el ciclo de vida del producto.



Opcional para profesionales de TI y la nube

Ingeniero de DevOps en la nube

Diseño, implementación y operaciones de un entorno global de cómputo en la nube híbrida a gran escala, fomentando las canalizaciones automatizadas de CI/CD de DevOps de extremo a extremo.



Opcional para profesionales de TI y la nube

Opcional

Para profundizar

Ingeniero de DevSecOps

Acelere la adopción de la nube empresarial y, al mismo tiempo, permita la entrega rápida y estable de capacidades mediante principios, metodologías y tecnologías de CI/CD



Opcional para profesionales de TI y la nube

Caminos de certificaciones en AWS

Seguridad

Ingeniero de seguridad en la nube

Diseñe una arquitectura de seguridad informática y desarrolle diseños detallados de ciberseguridad. Desarrolle, ejecute y realice un seguimiento del rendimiento de las medidas de seguridad para proteger la información.



Arquitecto de seguridad en la nube

Diseñe e implemente soluciones empresariales en la nube que apliquen la gobernanza para identificar, comunicar y minimizar los riesgos empresariales y técnicos.



Redes

Ingeniero de redes

Diseñe e implemente redes informáticas y de información, como redes de área local (LAN), redes de área amplia (WAN), intranets, extranets, etc.



¡Gracias!

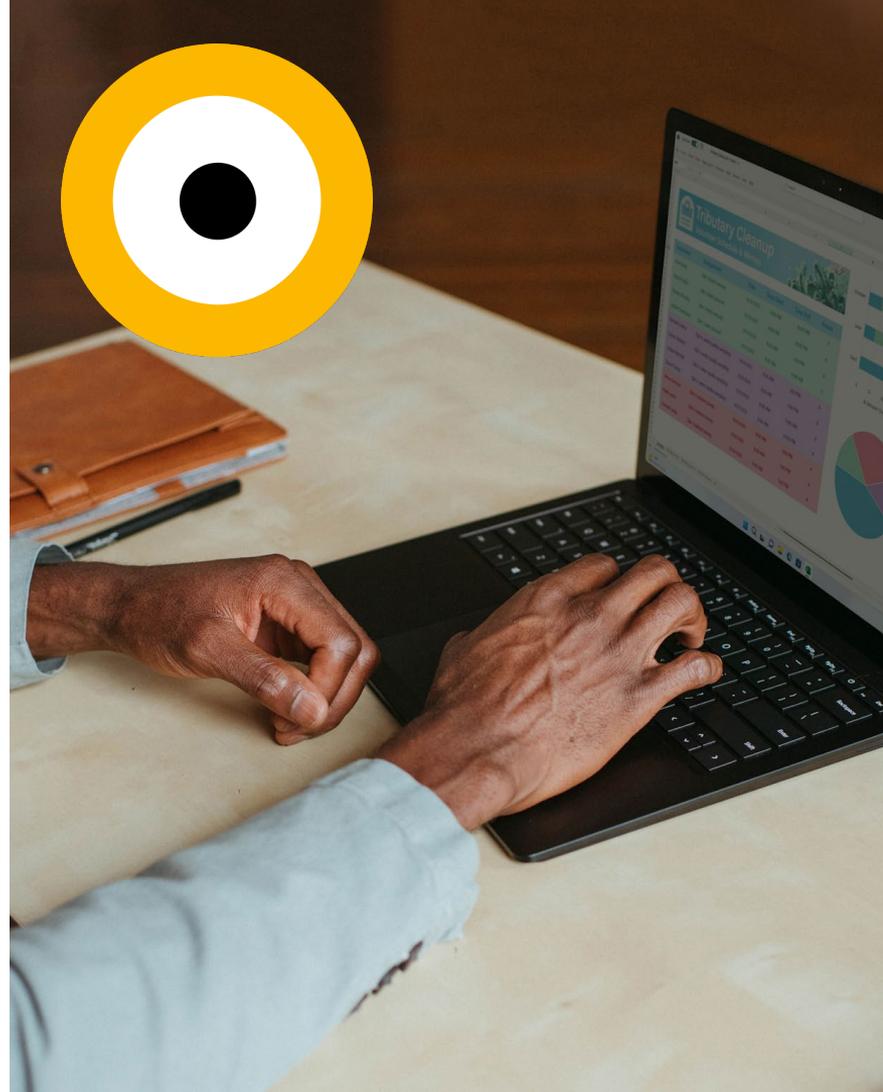
tumail@nucliollearning.com

+34 000 000 000

nucliollearning.com



nuclio^o
learning



nuclio[®]
learning