



Cloudera DataFlow

Universal Data Distribution (UDD)

VinkOS
DATA ENGINEERING | DATA SCIENCE

CLOUDERA

Dobeslao Hernández



Agenda

Universal Data Distribution

1

Cloudera DataFlow

2

Componentes

3

Arquitecturas Modernas

4


Demostración

Cloudera DataFlow

La familia de productos Cloudera DataFlow soporta procesos de ingestión continua, intercambio de información entre aplicaciones con todos los elementos de una plataforma empresarial: seguridad, gobierno, auditoría, linaje...



A DATA-IN-MOTION REFERENCE ARCHITECTURE



Cloudera DataFlow - Casos de Uso

Algunos casos de Uso ...

- **Actividad de sitios web:** seguimiento de visitas, búsquedas, etc. en tiempo real
- **Agregación de eventos y registros:** sobre sistemas distribuidos, mensajes de múltiples fuentes
- **Data Movement:** Optimización de uso de recursos en movimientos de datos entre data centers o entre infraestructura on-premise y nube.
- **Stream Processing:** Combinar múltiples flujos de datos en tiempo real, enriquecer los datos y enviarlos a diferentes destinos en función de reglas definidas
- **Streaming Analytics:** Análisis de patrones en flujos de datos utilizando modelos de machine learning, generando inteligencia accionable.
- **Single view / 360° view of customer:** Ingestar, transformar y combinar datos del cliente provenientes de múltiples fuentes en un punto único de verdad, data lake.
- **Optimize Log Collection & Analysis:** Optimización de soluciones de análisis de logs utilizando Data Flow como la plataforma única para recolectar y entregar múltiples fuentes de datos
- **Capture IoT Data:** Ingestar datos provenientes de sensores de dispositivos IoT y enviarlas para procesamiento y análisis posterior



Agenda

Universal Data Distribution

1

Cloudera DataFlow

2

Componentes

3


Arquitecturas Modernas

4

Demostración


Cloudera DataFlow - Componentes

Los componentes de Cloudera DataFlow incluyen características empresariales para el desarrollo de soluciones ...



Procesos de Ingesta Continua - Arquitectura de caso de uso implementado

Si trasladamos los puntos anteriores a un proceso de datos, lo visualizamos:



En este tipo de procesos, los datos están en flujo constante: Data-in-Motion



Agenda

Universal Data Distribution

1

Cloudera DataFlow

2

Componentes

3


Arquitecturas Modernas

4

Demostración

Procesos de Ingesta Continua ...

¿De qué hablamos cuando decimos Ingesta Continua?



... Pero, ¿Cuáles son los elementos, los componentes que debo considerar para empezar con procesos de ingestá continua?



Procesos de Ingesta Continua - Consideraciones

¿Qué necesitamos saber para implementar un proceso de ingestión continua?

Del entorno

- Tipos de fuentes y destinos en mi arquitectura: APIs, Servicios, Transacciones, Logs
- Frecuencia de generación de registros continua o en microbatch

De los componentes

Componentes principales:

- Transporte: Movimiento de datos de una fuente a un destino
- Retención: Capacidad de retener registros en caso de contingencia para no perder información
- Preparación / Enriquecimiento: Capacidad para realizar operaciones sobre el flujo de datos, antes de persistirlos.

De las herramientas


Características:

- Despliegue on premise / en nube
- Desarrollo escribiendo código (java/python, otros)
- Programación por objetos / Parametrización
- Uso de lenguaje SQL
- Integración con Seguridad, administración de usuarios
- Gobierno / Lineage / Auditoría



Retos de las Arquitecturas Modernas

Una arquitectura moderna incorpora múltiples aplicaciones y sistemas que necesitan interactuar enviando y recibiendo datos con diferentes formatos, frecuencias, estructuras; unidireccional o bidireccional:




RETOS

- La velocidad para mover los datos eficientemente a través de la Organización .
- Las herramientas de “Extracción/Carga” se enfocan en fuentes on premise o en nube, sin considerar que un entorno de real combina on premise, nube, edge, etc y no necesariamente son estructuradas y con esquemas definidos.
- Se requieren ó se desarrollan manualmente múltiples herramientas para la “Extracción/Carga” para mover los datos a través de los diferentes elementos del ecosistema

Se requiere un servicio universal de distribución de datos

Servicio universal de distribución de datos

Un servicio universal de distribución de datos permite conectar a cualquier fuente de datos, en cualquier lugar, procesar y enviar a cualquier destino:



Capacidades

- Soporta ingestión de datos en entornos híbridos, conectándose a cualquier fuente de datos en cualquier lugar en cualquier nube con cualquier estructura
- No excluye donde distribuye los datos, soporta la entrega a cualquier destino: lakehouses, data lakes, servicios
- Soporta casos de uso diversos: Continuous Data Collection, batch, microservicios, event-driven, streaming...
- Soporta los desafíos de integración de datos: formateo de datos, ruteo, filtrado, administración de errores, reintentos/reejecuciones, interacción con múltiples protocolos.
- El desarrollo es por configuración de objetos, no código; con posibilidad de extensiones para incrementar las funcionalidades

Universal Data Distribution

Universal Data Distribution de Cloudera ofrece la primera solución de ingestión de datos construida para datos híbridos.

El volumen de datos que las empresas capturan y almacenan en su infraestructura on-premise, en la nube y en streaming sigue aumentando.

Permite a las empresas tomar el control de sus flujos de datos, desde el origen hasta todos los puntos de consumo, tanto on-premise como en la nube, de una manera universal que es simple, segura, escalable y rentable. Esto es posible gracias a **Cloudera DataFlow**, la primera solución de ingestión de datos creada para un mundo de datos híbridos. A diferencia de las soluciones basadas en asistentes, específicas del sistema de destino, Cloudera DataFlow proporciona una distribución de datos indiscriminada con **más de 450 conectores y procesadores** a través de un ecosistema de servicios de nube híbrida, incluyendo data lakes, lakehouses, y almacenes de datos en la nube con fuentes de datos locales y edge.

Cloudera DataFlow, es una verdadera solución de ingestión de datos híbridos que aborda toda la diversidad de casos de uso de los datos: por lotes, impulsado por eventos, edge, microservicios y continuo/streaming. Con Cloudera DataFlow, el streaming es tratado como se debería, convirtiendo cualquier fuente de datos en un flujo de datos, soportando la escala de streaming y desbloqueando cientos de miles de clientes generadores de datos.



Agenda

Universal Data Distribution

1

Cloudera DataFlow

2

Componentes

3

Arquitectura Conceptual

4

Demostración



Demostración

Universal Data Distribution (UDD)

VinkOS

DATA ENGINEERING | DATA SCIENCE

CLOUDERA


Apache® NiFi™ For Dummies®,
Cloudera Special Edition



VinkOS

DATA ENGINEERING | DATA SCIENCE

CLOUDERA



Gracias, nos vemos pronto.