

Clase 4 IA - BigData

Tipos de datos

- Datos Estructurados: A menudo numeroso etiquetas almacenadas en un marco estructurados de columnas y filas.
- Datos Semiestructurados: Organizados libremente en categorías utilizando etiquetas meta.
- Datos No Estructurados: Información con mucho texto que no está organizada en un marco o modelo claramente definido.

ETL vs ELT

ETL

- Extract: Se obtienen los datos desde diversas fuentes (api, db).
- Transform: Los datos extraídos son procesados y transformados fuera del sistema destino. Se limpian, formatean y estructuran de acuerdo a las reglas de negocio.
- Load: Los datos transformados se cargan en un almacen.

ELT

- Extract: Los datos son extraídos de las fuentes, igual que en ETL
- Load: Los datos sin transformar se cargan directamente en el sistema destino. > Es un concepto alimentado por la nube
- Transform: La transformación ocurre dentro del sistema de destino, aprovechando su capacidad de procesamiento.

Categorías

Bronce

Tener los datos en bruto, por ejemplo, cuando hacemos web-scraping. A veces es json, csv, mas o menos estructurados.




Figure 1: Imagen de referencia

Plata

es el procesamiento de los datos de tipo bronce. simplemnte una pequena modificacion de los datos que los deje listos para hacer una transformacion mas completa.

Oro

Es el dato mas refinado. Esto es luego de hacer agregaciones (porque necesitan mucho computo). Este es el nivel desde donde deberia consumir el sistema

Herramientas que se usan: > Azure, Apache spark.

Webscrapping

Es un procedo mediante el cual extraemos datos de la web de forma medianamente automatizada.

Nota

escribir la diferencia entre **Data Factory** contra **Data Bricks**.