

BENVENUTI!





who

why

what

when

where



who

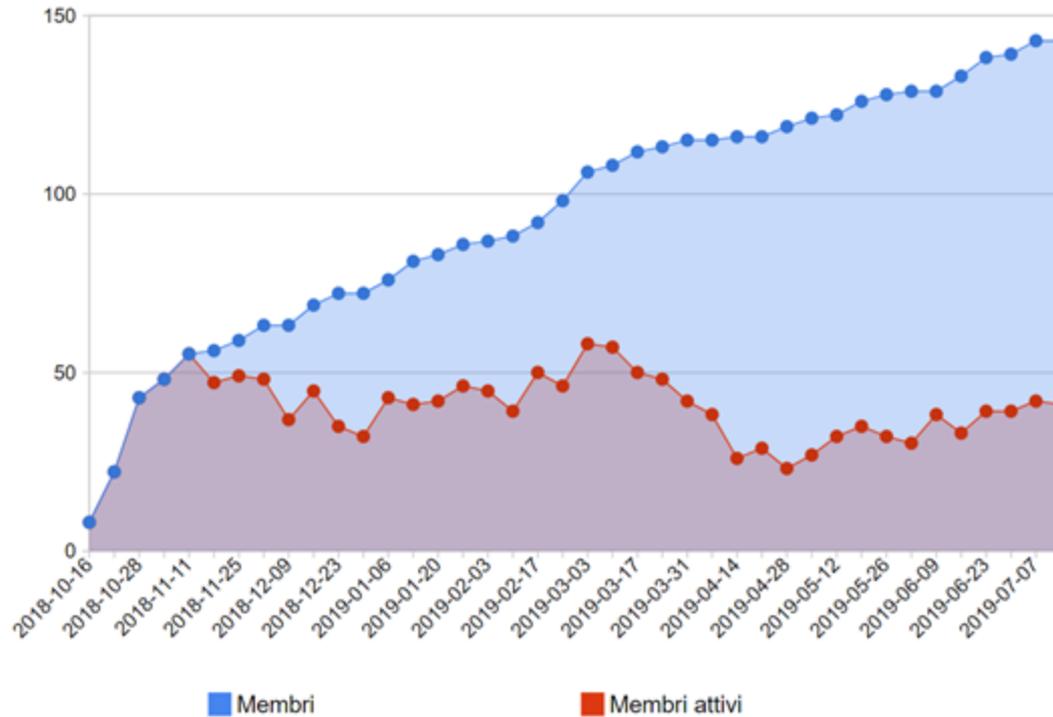


community



who

Totale membri e membri attivi



what

```
for (var oneDay of month) {  
  if (you.Code 📁 || you.Beer 🍺 || you.Tech 📱) {  
    CremaWeb.meetup.join()  
  }  
}
```



what

Organizzazione eventi su
temi Tecnologici

Area di discussione
comune su Web (Discord)

Coinvolgimento diretto o
indiretto dei dipendenti
delle aziende della zona


Riferimento propositivo per
discussioni e eventi
dedicato ad appassionati
del campo IT



why



**when
where**



meetup.com/CremaWeb



per ora grazie a



...aspettando i contributi di chi si vorrà unire...



6 Febbraio 2025

Databricks: I processi ETL al giorno



databricks



Mirko Porcu

Presentiamoci :)



Indice

1. Introduzione
2. Il Data Management e i processi ETL
3. Databricks
4. Use case



1. Introduzione

Nell'era digitale le aziende raccolgono quotidianamente una quantità enorme di dati da **diverse fonti eterogenee**, che sarebbero impossibili da gestire se non attraverso processi specifici di gestione del dato.

La gestione del dato, o **Data Management**, include processi come la **data integration**, la **data quality**, la **data governance** e la **data security**, che permettono alle aziende di ottenere una visione completa e affidabile del proprio business, ad esempio, comprendendo meglio il comportamento dei clienti o le performance di vendita.

Attraverso una corretta gestione dei dati, le aziende possono, ad esempio, individuare nuove opportunità di mercato, ottimizzare le campagne di marketing e migliorare l'efficienza operativa, trasformando i propri dati in una risorsa strategica.



2. Il data management e i processi ETL

il Data Management è l'insieme di processi e tecniche che permettono alle aziende di:

- Raccogliere dati da diverse fonti, interne ed esterne → **Data Integration**
- Organizzare i dati in modo strutturato e accessibile → **Data Governance**
- Assicurare la qualità dei dati, eliminando errori e incongruenze → **Data quality**
- Proteggere i dati da accessi non autorizzati e perdite → **Data Security**
- Utilizzare i dati per analisi, reportistica e decisioni strategiche → **Data Visualization**

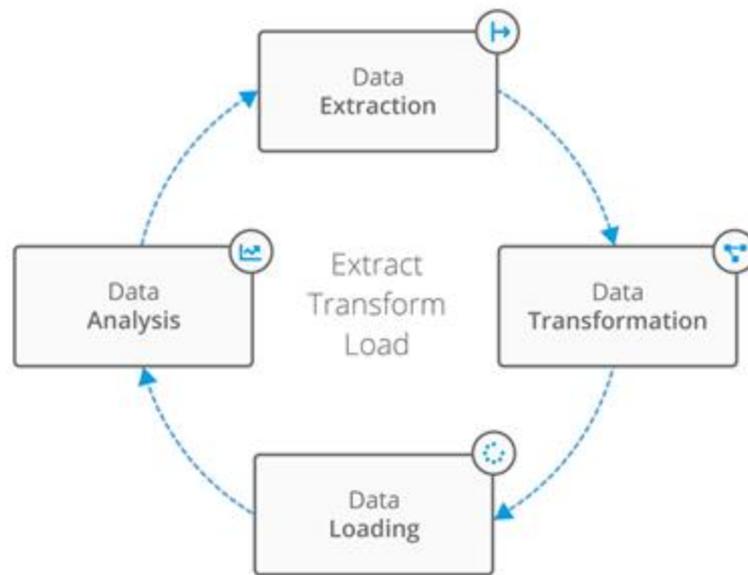


2.1 I processi ETL

Cosa sono i processi ETL?

I processi ETL sono dei processi di trasformazione del dato che si possono suddividere in questi step :

- **Extract:** Raccolta dati grezzi da diverse fonti (database, file, ecc.)
- **Transform:** "Pulizia" e conversione dei dati in un formato utilizzabile (correzione errori, uniformazione formati, aggregazione, ecc.)
- **Load:** Inserimento dei dati trasformati in un sistema di destinazione (data warehouse, data lake, ecc.)



2.1.1 ETL vs ELT

ETL

I dati vengono trasformati prima di essere caricati nel data warehouse.

Utile quando:

- Le risorse del data warehouse sono limitate.
- È necessario un elevato controllo sulla qualità dei dati.
- I dati devono essere conformi a schemi rigidi.

ELT

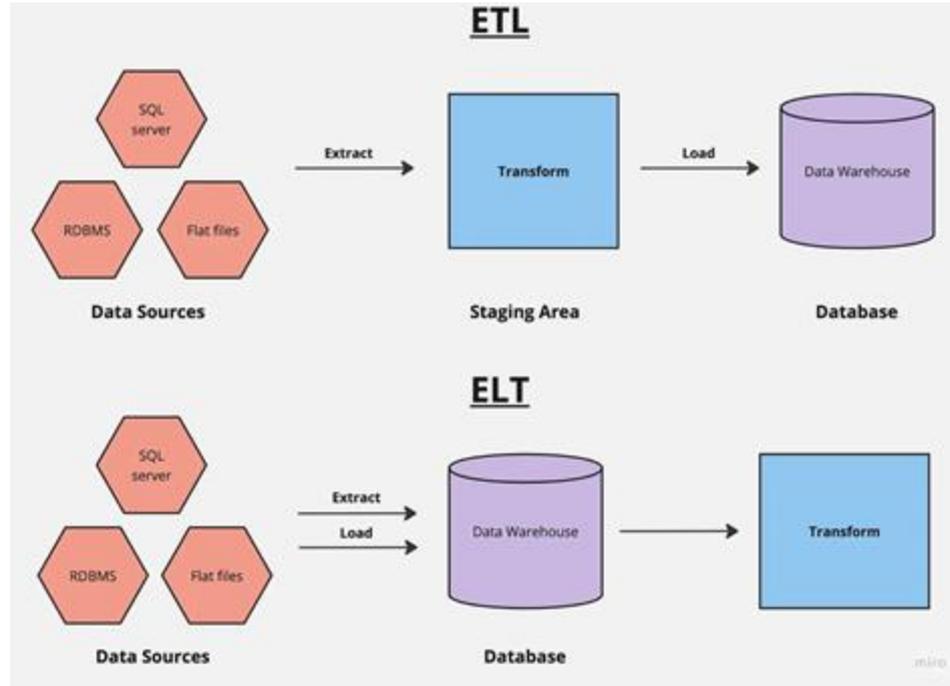
I dati vengono caricati nel data warehouse prima di essere trasformati.

Utile quando:

- Si dispone di un data warehouse scalabile (cloud).
- Si gestiscono grandi volumi di dati non strutturati.
- Si necessita di flessibilità nell'analisi dei dati.



2.1.1 ETL vs ELT



<https://medium.com/@c.chai/main-architecture-types-in-data-engineering-5e2242cace15>



2.1.2 Gestione a Batch e Gestione streaming

L'elaborazione batch e l'elaborazione in streaming sono due approcci fondamentali per l'elaborazione dei dati, ognuno con i suoi pro e contro.

La scelta migliore dipende dalle esigenze specifiche dell'applicazione.



2.1.2.1 Elaborazione Batch

Pro:

- **Efficiente per grandi volumi di dati:** L'elaborazione batch è ideale per elaborare grandi quantità di dati storici, in quanto può essere eseguita in modo efficiente su larga scala.
- **Costo-efficacia:** L'elaborazione batch può essere più conveniente rispetto all'elaborazione in streaming, in quanto può utilizzare risorse di elaborazione meno costose.
- **Semplicità:** L'elaborazione batch è generalmente più semplice da implementare e gestire rispetto all'elaborazione in streaming.

Contro:

- **Latenza elevata:** L'elaborazione batch introduce un ritardo significativo tra l'acquisizione dei dati e la disponibilità dei risultati, il che la rende inadatta per applicazioni in tempo reale.
- **Difficoltà nell'aggiornamento dei dati:** L'aggiornamento dei dati elaborati in batch può essere complesso e richiedere molto tempo.



2.1.2.2 Elaborazione Streaming

Pro:

- **Latenza bassa:** L'elaborazione in streaming consente di elaborare i dati in tempo reale, il che la rende ideale per applicazioni che richiedono risposte immediate, come il monitoraggio delle frodi etc etc.
- **Aggiornamenti in tempo reale:** L'elaborazione in streaming consente di aggiornare continuamente i dati e i risultati, fornendo una visione aggiornata dell'andamento.

Contro:

- **Complessità:** L'elaborazione in streaming è generalmente più complessa da implementare e gestire rispetto all'elaborazione batch.
- **Costo:** L'elaborazione in streaming può essere più costosa rispetto all'elaborazione batch, in quanto richiede risorse di elaborazione dedicate e una maggiore capacità di gestione dei dati.
- **Sfide nella gestione degli errori:** La gestione degli errori nell'elaborazione in streaming può essere più complessa, in quanto i dati vengono elaborati in modo continuo.



3.1 Databricks

Databricks è una piattaforma cloud che unifica **Data Analysis**, **Data Engineering** e **Data Science**. Offre un ambiente collaborativo in cui diversi profili professionali possono lavorare insieme su progetti di dati, sfruttando strumenti e funzionalità per:

- **Data Analysis**: esplorare, analizzare e visualizzare i dati per estrarre informazioni utili al business.
- **Data Engineering**: costruire e gestire pipeline di dati affidabili e scalabili per l'elaborazione di grandi volumi di informazioni.
- **Data Science**: sviluppare, addestrare e distribuire modelli di machine learning per ottenere previsioni e automatizzare processi.

<https://www.databricks.com/>



databricks

3.1 Databricks

Databricks si basa su **Apache Spark**, offre un ambiente collaborativo e scalabile per:

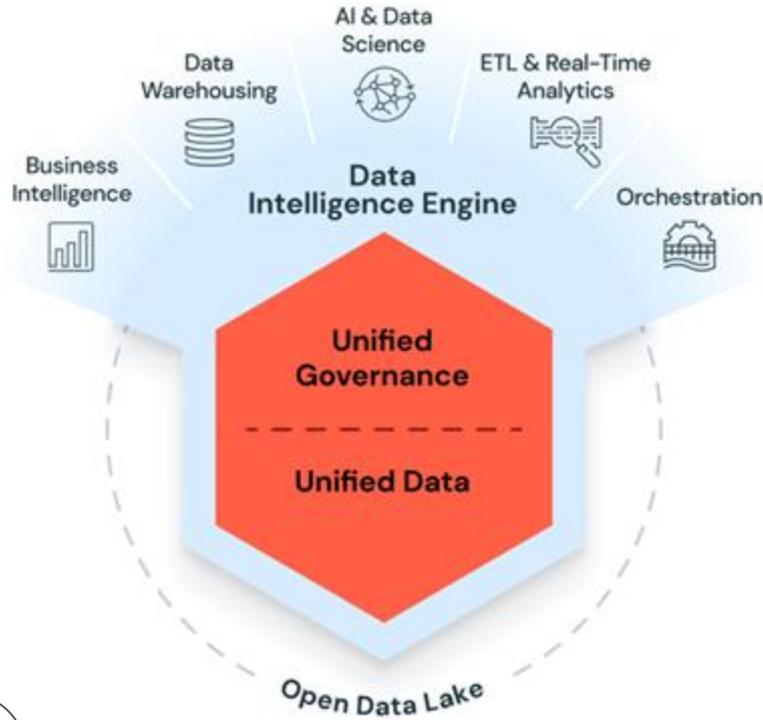
- Analizzare grandi quantità di dati con velocità e flessibilità.
- Costruire pipeline di dati affidabili e automatizzate.
- Sviluppare e distribuire modelli di machine learning.



databricks



3.1 Databricks



3.2 Databricks : Apache Spark



What is Apache Spark™?

Apache Spark™ is a multi-language engine for executing data engineering, data science, and machine learning on single-node machines or clusters.

<https://spark.apache.org/>



3.2 Databricks : Apache Spark



Cos'è Apache Spark?

Un framework open-source per l'elaborazione distribuita di grandi quantità di dati.

Caratteristiche principali:

- **Velocità:** Esegue calcoli in memoria per prestazioni elevate.
- **Scalabilità:** Può essere eseguito su cluster di macchine, da piccole a grandi.
- **Facilità d'uso:** Supporta API in **Java**, **Scala**, **Python** e **R**.
- **Versatilità:** Può essere utilizzato per analisi batch, elaborazione di flussi, machine learning e SQL.

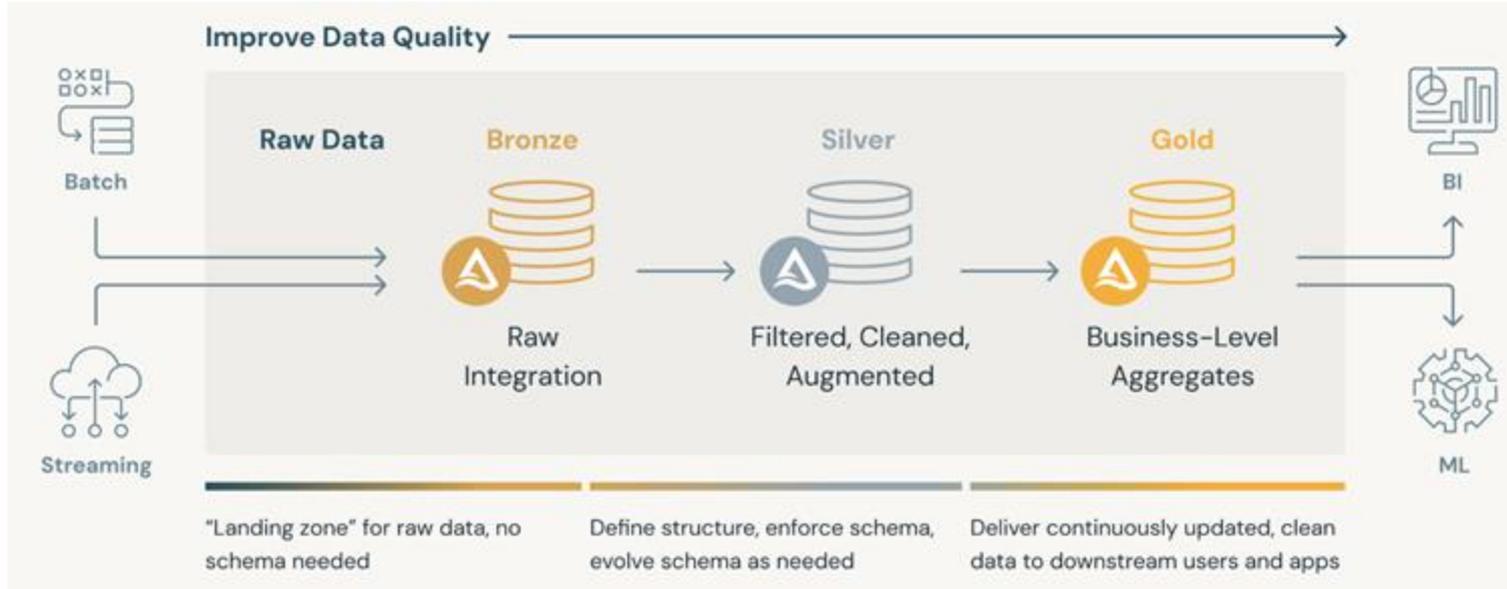


Esempi di architettura per la trasformazione del dato

- L'architettura **Medallion** è un approccio tradizionale che categorizza i dati in tre livelli: bronzo, argento e oro, in base alla qualità e all'affidabilità dei dati.
- Architetture basate su **streaming**: Elaborano i dati in tempo reale, il che è cruciale per applicazioni come il rilevamento delle frodi e l'analisi del sentiment dei clienti.
- Architetture **lambda**: Combinano l'elaborazione batch e in streaming per gestire sia i dati storici che quelli in tempo reale.
- Kappa, Data Vault Architecture & more more others



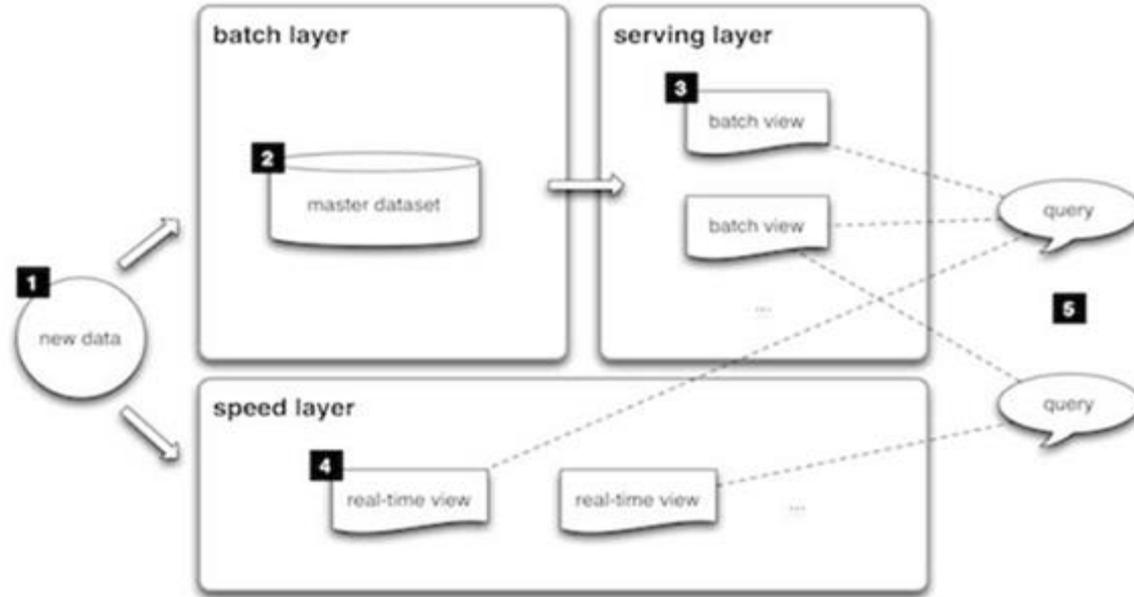
Medallion Architecture



<https://www.databricks.com/glossary/medallion-architecture>



Lambda Architecture



<https://www.databricks.com/it/glossary/lambda-architecture>



4. Use Case

Realizziamo un **processo** per la gestione di transazioni per avere dei KPI di performance che possano permettere di prendere decisioni strategiche importanti per il business.



Grazie



Next event



17/04/2025

