

DATA WAREHOUSE

/

DATA LAKE

# DATA WAREHOUSE

## Définition

- un **Data Warehouse** (entrepôt de données) est une **base de données** créée pour les analyses de données, la prise de décision et les activités de type Business Intelligence
- un Data Warehouse reçoit des données provenant de **sources diverses**
- les informations stockées dans un entrepôt sont **historisées chronologiquement**
- elles offrent une vue d'ensemble de **l'évolution d'une information**
- les **données redondantes** existent donc dans un entrepôt de données et offrent aux utilisateurs **plusieurs vues de la même information**
- exemples : l'évolution des chiffres d'affaires clients sur plusieurs mois ou plusieurs années, l'évolution de l'effectif d'une entreprise ...

# DATA WAREHOUSE

## Définition

- un Data Warehouse est défini par son **sujet**
- exemple : un entrepôt de données est créé spécialement pour analyser les **données de ventes** de l'entreprise et fournit des analyses telles que le palmarès clients, les produits les plus vendus, la répartition géographique des ventes ...
- il est également défini par :
  - le **type de données** qu'il contient
  - les **personnes** qui utilisent l'entrepôt et analysent ses données
- exemple :
  - **type de données** : données financières relatives à des clients et des fournisseurs
  - **personnes** qui utilisent l'entrepôt : le service comptable de l'entreprise

# DATA WAREHOUSE

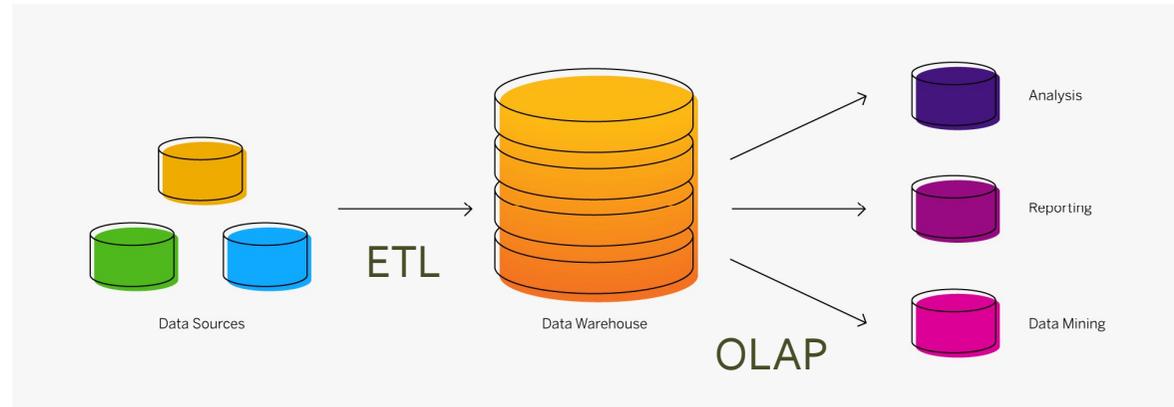
## Définition

- un Data Warehouse est **non-volatile** : une donnée stockée **ne doit plus changer**
- un Data Warehouse est **time-variant** : il permet les analyses sur les **changements survenus au fil du temps** afin de découvrir des **tendances**
- avec ce stockage de **plusieurs versions de la même information**, on cherchera à **prévoir les prochaines valeurs** de cette même information
- exemple : on analyse sur plusieurs années les données de ventes d'un secteur géographique et on essaye de comprendre pourquoi elles ont évolué pour prévoir ce que seront ces mêmes données à l'avenir

# DATA WAREHOUSE

## Outils

## ETL OLAP



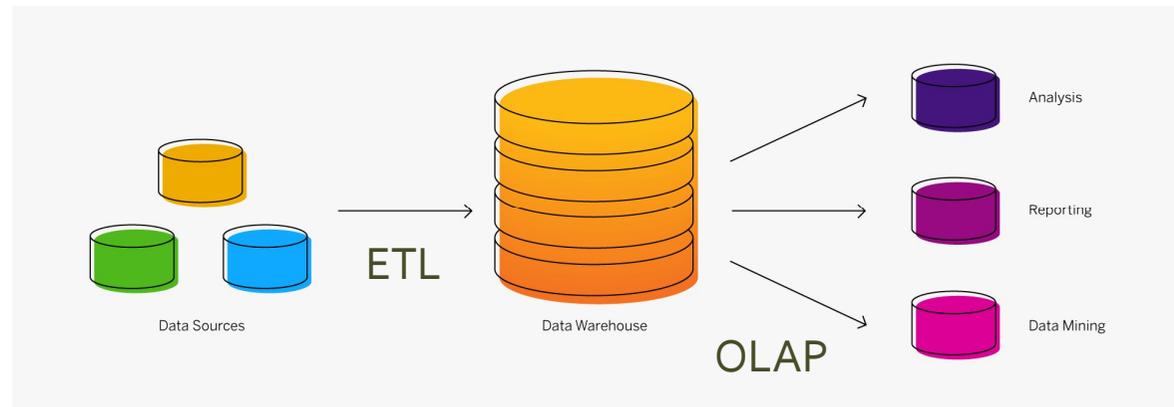
Un **environnement** Data Warehouse intègre :

- un outil d'extraction, de transformation et de chargement des données appelé **ETL** (Extract – Transform – Load) qui **agrège** les informations provenant de **différentes sources** et les **modélise**
- un moteur de **traitement analytique** en ligne appelé **OLAP** (Online Analytical Processing) qui génère des rapports et favorise l'analyse de type Data Mining (extraction de connaissances)

# DATA WAREHOUSE

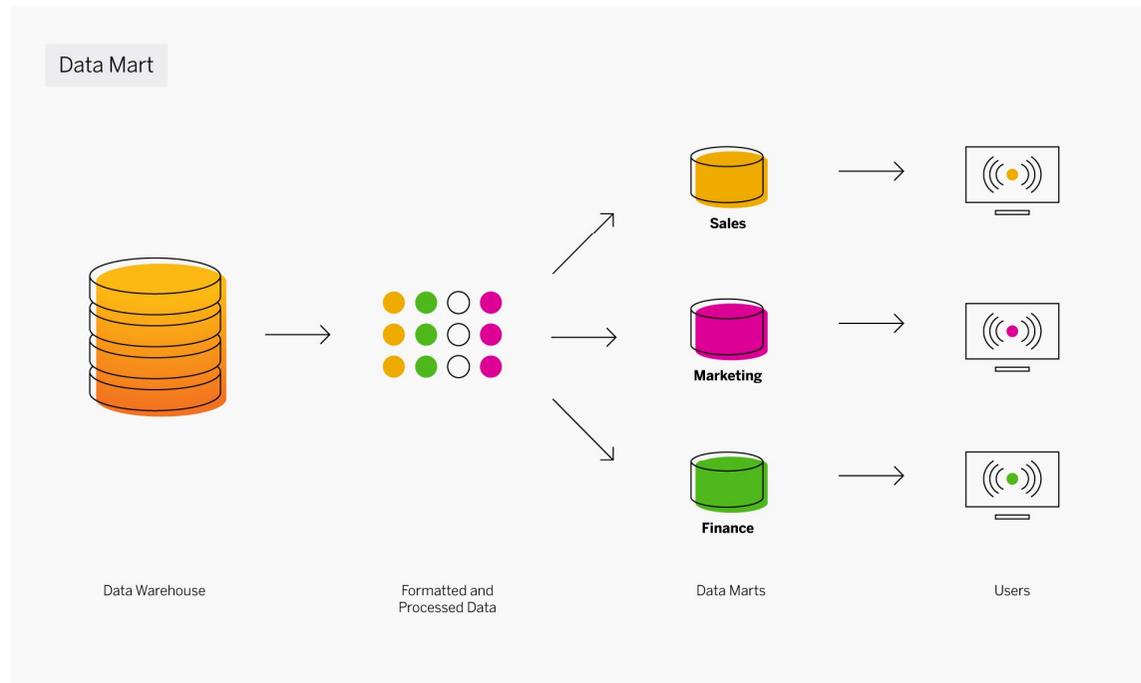
## Outils

## ETL OLAP



- grâce à ces outils on résout notamment les **conflits de noms** et les **incohérences** en termes d'unités de mesure : c'est ce qu'on appelle **l'intégration** des données
- exemple :
  - on a on a amassé beaucoup de données contenant des montants dans de nombreuses devises différentes
  - on va les rendre **homogènes** sur une devise commune

# DATA MART



- un Data Warehouse peut être divisé en magasins → Data Marts
- un Data Mart contient des informations dédiées à un domaine spécifique : ventes, marketing, finance ...
- ces Data Marts sont analysés séparément

# Data Warehouse vs Data Lake

## Les 7 différences

### 1. les données

- un Data Warehouse rassemble une grande quantité de données en provenance de **différentes sources de données**
- la prise de décision se fait à partir de données **déjà rendues cohérentes = données structurées**
- un Data Lake est une banque de stockage servant à contenir une immense quantité de **données brutes dans leur format d'origine jusqu'à ce que l'entreprise en ait besoin**

### 2. la structure des données

- les Data Warehouses ne peuvent accueillir **que des données structurées**
- un Data Lake est capable de stocker tous types de données, **structurées ou non**

# Data Warehouse vs Data Lake

## Les 7 différences

### 3. le traitement des données

- les données d'un Data Warehouse sont traitées et passent par l'étape du « **schema-on-write** » qui leur confère une **structure** (un **modèle**) pour devenir **exploitables**
- les données d'un Data Lake sont stockées sous leur **forme brute et ne sont pas exploitables en l'état**, et elles ne seront traitées (et donc préalablement mises en forme) **qu'en cas de besoin** → c'est ce qu'on appelle le « **schema-on-read** »

### 4. le stockage

- la différence se fait au niveau des **coûts** : un **Data Lake coûte moins cher qu'un Data Warehouse** tant que les données ne sont pas structurées car dans un Data Lake nous n'avons **pas besoin de performance de traitement**, mais **seulement d'un stockage**

# Data Warehouse vs Data Lake

## Les 7 différences

### 5. l'agilité (évolutions)

- comme un Data Warehouse est **structuré**, changer sa structure **prend du temps**
- à l'inverse un Data Lake n'a **pas de structure** donc les Data Scientists peuvent **aisément configurer** et reconfigurer les modèles de données, les requêtes et les applications
- le Data Warehouse est donc **moins agile, moins flexible**

### 6. la sécurité

- le Data Warehouse est historiquement plus ancien que le Data Lake, ce qui lui confère **maturité et fiabilité maximale** de sa protection
- la technologie de stockage d'un Data Lake est plus récente donc moins éprouvée techniquement, **les données sont donc un peu moins sécurisées au sein d'un Data Lake**

# Data Warehouse vs Data Lake

## Les 7 différences

### 7. les utilisateurs

- un Data Warehouse est principalement utilisé par les **responsables d'entreprises** car les données sont **prêtes à l'emploi**
- un Data Lake est plus utilisé par les **Data Scientists** car les données sont brutes et en cas de besoin, nécessitent **l'expertise de traitement et d'interprétation** d'un spécialiste comme un **Data Scientist**



# Data Warehouse vs Data Lake

## Les 7 différences

| Critères                | Data Warehouse                             | Data Lake  |
|-------------------------|--|--|
| Données                 | Données cohérentes                         | Données brutes                                     |
| Structure des données   | Données structurées                        | Tous types de données                              |
| Traitement des données  | Directement exploitables                   | Pas exploitables en l'état                         |
| Stockage                | Stockage + traitement<br>Coûts plus élevés | Simple stockage<br>Coûts moins élevés              |
| Agilité<br>(évolutions) | Changer la structure<br>prend du temps     | Pas de structure donc<br>facilement reconfigurable |
| Sécurité                | Maturité, fiabilité<br>maximale            | Technologies plus récentes<br>Moindre fiabilité    |
| Utilisateurs            | Décideurs                                  | Data Scientists                                    |