




Objectifs du cours Big Data

- **Découvrir la méthodologie map/reduce.**
- **Apprendre à utiliser Hadoop.**
- **Apprendre à rédiger et exécuter des programmes pour Hadoop.**
- **Apprendre à utiliser MongoDB (BD Non-structuré).**
- **Apprendre à utiliser Apache Spark.**

Pré-requis



Pour pouvoir tirer le maximum de ce cours, il faut connaître :

- **Systemes Répartis**
- **Programmation orientée objets (Java)**
- **Bases des Données**
- **Algorithmes parallèles et distribués**

Mode d'évaluation

L'évaluation finale se fait à travers:

- Un **examen final**, qui compte pour **60%** de la note finale.
- **Évaluation continue** à raison de **40%** restant (Contrôle TP, Exposé, Interro).

Plan de Cours

A decorative graphic in the top-left corner consisting of three overlapping squares: a dark red one on top, a lighter red one to the left, and a yellow one on the bottom. A red line extends horizontally from the right side of the yellow square across the top of the slide, and then turns vertically downwards on the left side.

1-introduction au Big Data

2-Systeme Hadoop

3-Apache Spark

4- BD NoSql (Mongo DB)

Plan de TDs

A decorative graphic in the top-left corner consisting of three overlapping squares: a dark red one on top, a lighter red one to the left, and a yellow one on the bottom. A red line extends horizontally from the right side of the yellow square across the top of the slide, and a vertical red line extends downwards from the bottom of the yellow square.

1- Métriques de performance

2- Partie 1: Algorithmique avec MapReduce

2- Partie 2: HDFS

3- NoSQL

Plan de TPs



1- Préparation de l'environnement pour les TPs

2- Analyse de Ventas en utilisant Hadoop

3- Problème du réseau social et des « amis en commun » en utilisant Apache Spark

4- MongoDB – Utilisation et API Java

Exposés sur les technologies de Big Data



- 1- Apache Cassandra**
- 2- Apache Kafka**
- 3- QlikView**
- 4- Qlik Sense**
- 5- Tableau**
- 6- Apache Storm**
- 7- Apache Storm**
- 8- Apache Hive**
- 9- Apache Pig**
- 10 – Presto**
- 11- Apache Flink**
- 12- Apache Sqoop**
- 13- Rapidminer**
- 14- KNIME**
- 15- Elasticsearch**



Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
Centre Universitaire de Mila
Institut des Mathématiques et Informatique
Département de l'Informatique



Big Data

– Chapitre 1 – Introduction au Big Data

s.meghzili@centre-univ-mila.dz



Plan du chapitre 1

- ❖ **Motivations**
- ❖ **Définitions du Big Data**
- ❖ **Données**
- ❖ **Défis du Big Data**
- ❖ **Les 5 Vs du Big Data**
- ❖ **Hiérarchie de la mémoire**

Motivations: Exemple de recherche sur Google

□ Le **nbre** moyenne de requêtes de recherche dans **Google** = **63000** requête par Seconde

➤ **Donc, Combien de requête par année ?**



➤ $63000 * 3600h * 24j * 365\text{année} = 1\ 986\ 768\ 000\ 000$ requête par Seconde

➤ **Donc, Analyser ces données** vous donnera un **vertige**



Définitions du Big Data



Le terme **Big Data** se réfère:

- A une **accumulation** de données très **larges** et très **complexes** pour être traitées par les outils **classiques** de gestion des bases de données.
- Aux solutions **hardware** et **software** développées pour la gestion de données **volumineuses**.
- A la branche de l'informatique qui étudie les solutions de gestion de données **volumineuses**.

Données: Source de données

Plusieurs sources de données:

- **Messages texte** sur les médias sociaux (**Twitter**, **Facebook**)
- **Images** numériques et **vidéos** publiées en ligne (**Youtube**)
- Enregistrements transactionnels ***d'achat en ligne (Amazon)***
- Signaux **GPS** de **téléphones mobiles**
- les informations **climatiques**
- ...

Donc, ces données appelées **Big Data** ou **Données Massives**


Données : Nature des données (0)

Niveau de structuration	Modèle de données	Exemples	Facilité de traitement
Structuré	Système de données relationnel objet/colonne	Base de données d'entreprise...	Facile (indexé)
Semi-structuré	XML, JSON, CSV, logs	API Google, API Twitter, web, logs...	Facile (non indexé)
Non structuré	Texte, image, vidéo	web, e-mails, documents...	Complexe

Défis du Big Data

- ✓ **Réunir** un grand volume de données variées pour trouver de nouvelles idées
- ✓ **Difficulté** pour sauvegarder toutes ces données
 - Systèmes Distribués.
 - Bases de données (**relationnelles/NoSQL**) distribuées.
- ✓ **Difficulté** pour traiter ces données et les utiliser
 - **Parallélisation** du calcul sur les machines.
 - Bases de données **parallèles**.
 - Frameworks de traitement distribué (e.g., **Hadoop MapReduce/Spark**)
- ✓ Les données sont créées **rapidement**

Les 5 Vs du Big Data



Les 5 Vs du Big Data : Volume

- Le terme **volume** fait référence à la grande quantité d'éléments de données dans le big data.
- Exemples:
 - Les services de **streaming** comme **Netflix** ou **YouTube** accueillent des millions d'utilisateurs qui diffusent des vidéos en continu, ce qui génère une énorme quantité de données.
 - **Netflix** doit stocker ce volume colossal de données, les préférences des **utilisateurs**, leur **historique** de recherche et leurs **interactions**.
 - Le volume de données généré aide **Netflix** à utiliser des algorithmes sophistiqués pour **recommander** des émissions et des films

Les 5 Vs du Big Data : Variété

- La nature **hétérogène** des données (structurées, semi-structurées, non structurées).
- Les données **structurées** comprennent des types de données bien définis, tels que des **bases de données** de noms et de chiffres.
- Les données **non structurées**, quant à elles, comprennent des types de données tels que **du texte**, des **sons**, des **images** et des **messages** sur les médias sociaux.
- Les données **semi-structurées** sont un mélange des deux.
 - **Par exemple**, dans le domaine des soins de santé, les données relatives aux patients peuvent inclure des **enregistrements structurés** tels que l'**âge**, le **diagnostic** et l'**historique** des traitements, ainsi que des données **non structurées** telles que des **notes médicales**, des **images** de santé et même des **informations génétiques**.

Les 5 Vs du Big Data : Vélocité (vitesse)

- Elle comprend la **vitesse** de **génération** des données, ainsi que la vitesse à laquelle les professionnels les **collectent** et les **traitent**.
 - **Par exemple**, Système **d'analyse des Sentiments** qui traite les **tweets** afin de trouver l'ambiance générale du candidat politique.
 - **Vélocité**: flot constant de données (**7,500 tweets/second**).

Les 5 Vs du Big Data : Véracité

- Le terme **véracité** fait référence à la **fiabilité** et à la **qualité** des données.
- Avec un tel **volume** de données générées quotidiennement, il est toujours difficile de s'assurer que les données avec lesquelles vous travaillez sont **impartiales** et représentent **correctement** ce qu'elles sont censées représenter.

Les 5 Vs du Big Data : Valeur

- Elle provient des informations et des **modèles** que vous pouvez trouver dans les données.
- Comme les **big data** intègrent des données provenant de sources et de formats **divers**, vous pouvez obtenir des informations sur les paramètres qui vous intéressent, tels que le **comportement des clients**, l'**évolution du marché**, les **performances de l'entreprise**, etc.



Par exemple,

- alors que les **données structurées** peuvent révéler des **tendances** et des **modèles numériques**,
- les données textuelles **non structurées** provenant de sources telles que les messages sur les **médias sociaux** ou les **commentaires** des clients peuvent révéler les **sentiments** et les **opinions** qui déterminent le comportement humain.


Hiérarchie de la mémoire (1)

- Les systèmes réels ont plusieurs niveaux de types de **stockage**:
 - **Hiérarchie supérieure**: stockage **petit** et **rapide** à proximité du processeur
 - **Hiérarchie inférieure**: stockage **grand** et **lent** plus éloigné du Processeur
- Pour le programmeur / compilateur, pas besoin de savoir
 - Le matériel fournit une **abstraction**: la mémoire ressemble à un seul grand tableau,
- Mais les performances **dépendent** du **modèle d'accès** du programme.

Hiérarchie de la mémoire (2)




Hiérarchie de la mémoire (3)



Plus les ensembles de données sont **volumineux**, plus la **latence** est **grande**

Hiérarchie de la mémoire (4)

- Un **cluster** de traitement de données est simplement de nombreux ordinateurs reliés via une connexion **Ethernet**.
- Le stockage est **partagé**
- Localité: les données seront stockées sur l'ordinateur qui les **traitera**



Disciplines du Big Data

- **Informatique distribuée:**

- Paradigme de programmation **Map-Reduce**: «*amener les codes de calcul sur les noeuds de données*» «*traitements large échelle* » sur cluster **Hadoop**, ...

- **Informatique parallèle:**

- Paradigmes du **Calcul à Haute Performance (HPC)**: pour accélérer les algorithmes de « data analytics » ou de « machine learning », sur cluster de calcul intensif, sur GPU, sur superCalculateurs...

- **Bases de Données « NoSQL » : Not Only SQL**

- BdD plus simples mais à très large échelle
- Plusieurs types de BdD NoSQL: stockage distribué, interrogation sur les données.