

Immersion BD et infostructure

Focus sur map-reduce

4 V fondamentaux : volume, vitesse, variabilité et variété

1ère approche nouvelle : pas de schéma, ou variable (V : variability)

Notion de variété : les sources de données sont hétérogènes (web, fb, open data, gouvernement, flux vidéo, sms) (V : variety)

Les données sont en temps réel : chaque seconde sur internet il y a 300 000 tweets, sms,

Les requêtes google dépassent le million, plus d'une heure de vidéo youtube publiée.

Question fondamentale du Big Data : comment les exploiter ?

→ Définir des patrons, des corrélations

ex : temps passé sur fb et temps en forme (humeur)

identification des quartiers à risque d'incendie de New York

- là où y'a des rayonnements de façade, peu de risque (pas de conflit)
- là où il y a des sous-locataires
- Corrélation : immeuble à risque

La corrélation dans big data précède la causalité.

Peta = 1000 tera

Exa = 1 million de tera : 10^{18}

Zetta = 1000 Exa : 10^{24}

IDC 2012 a analysé 1.8 Zetta octets de données produites en 2011 avec 50% de croissance par an

Dans les 3000 premières années de l'humanité : 5 Exa octets de produit.

2012 : 5 Exa tout les 2 jours

2013 : toutes les 10 min

2015 : toutes les 10 secs

→ Data Tsunami : ce grand volume arrive

Pour illustrer : <http://onesecond.designly.com>

Terme yotta : espionnage : surveiller réseaux sociaux, ect

Ambition nsa : gérer big data du yotta : 10^{32}

Google en anglais signifie : 10^{99}

Tsunami data : déluge data :

- Bottom up
- Temps réel

Big data : serveur (cloud), mobilité (portable, tag nfc), réseaux sociaux, analyse

Application des big data : cartographie, océanographie, astronomie, génétique, médecine, épidémie, linguistique, Macro-économie, transport (VAMP), cartographie temps réel (FIRST), Commerce, tourisme (Matrium, reve, imajean + projet city wallet)

Résumé :

Avant big data : recherche scientifique type

Problème : état de l'art

Posé une hypothèse, trouver des impasses, des solutions

Avoir une intuition

Valider par des expériences, simulations, calculs

Avec big data :

Analyse informatique :

Identification de corrélations nouvelles → génératrice d'hypothèse

Emergence de découvertes

Pour pouvoir modéliser et interroger le web il faut un schéma : rdf et un langage de manipulation : sparql

Rdf permet de lier les données ensembles : principe du web sémantique

Rdf est un ensemble de triplet : < sujet, prédicat, objet >

Rdf / XML est une recommandation du W3C

Sparql : langage d'interrogation, ajout, modification et suppression des données RDF

3 approches pour faire du big data :

SQL 2 / SQL 3 (quelques petas octets)

NO SQL

NEW SQL

Echo système bd top down sql

G / P / D -> gestion production distribution

SQL : données structuré (table, objet)

Approche top down

No SQL : donnée non structuré (web par url)

Approche bottom up

BASE :

Basically

Available

Scalabilty

Eventually consistent

CAP Theorem (en choisir 2)

Consistency

Availability

Partitionning

} sql

} nosql

Meilleures approches pour big data : no sql et new sql

4 types de base no sql :

- clé-valeur (suivi par hadoop et cassandra) : table de hachage
- orientées colonne : stockage par colonnes (pas par ligne)
- orientées document (mongodb) : pas de schéma, ensemble de clé valeur
- graphe (pour réseau sociaux : neo4j) : nœuds/liens/propriété, pas d'opérateur ensembliste mais parcours de graph

Map Reduce (à la base dans les calculs distribués):

Map : étape de transformation de données sous la forme d'un couple clé valeur

Reduce : on fusionne les enregistrements par clé pour obtenir le résultat final

4 phrases de map reduce :

splitting : sépare les mots

mapping : on compte l'occurrence des mots

shuffling : on regroupe les valeurs

reduce : fusion des valeurs avec additions

Inconvénient : c'est celui qui a lancé la recherche qui traîne le résultat, trop compliqué d'utiliser une sortie sans en connaître l'entrée

Prendre le meilleur des 2 mondes (approche Stonebraker): faire un système

amphibiens : passerelle entre sqgb(top down) et décisionnel (bottom up)