CentraleSupélec

Big Data : Informatique pour les données et calculs massifs

11 – Exploration et préparation des données

Stéphane Vialle

CentraleSupélec université PARIS-SACLAY — École doctorale Sciences et technologies de l'information et de la communication (STIC) — RISEGrid lorraine — Grand Est

Stephane.Vialle@centralesupelec.fr
http://www.metz.supelec.fr/~vialle

Quelques Pb & Sol avant l'exploitation des données

Pb 1 : Diversité des données
Sources différentes - Types différents - Formats différents

Pb 2 : Qualité variable des données
Exhaustivité insuffisante - Granularité inadaptée - Exactitude ??

Sol : Démarche d'exploration préalable des données
Révélation de la structure - Enquête sur la collecte - Stats. descriptives

Sol : Démarche de préparation des données
Nettoyage - Transformation - Enrichissement

En Big Data : un POC standard est-il démonstratif ?

2

Exploration et préparation des données

1. **Pbs engendrés par la diversités des données**
2. Pbs engendrés par la qualité variable des données
3. Explorer les données par précaution
4. Préparer les données pour de meilleures analyses
5. Un POC standard est-il démonstratif ?

3

Diversité des sources

Données internes : 1ères sources de données

- **Les entreprises débutent souvent leur démarche BigData en analysant leurs données internes** (historiques, archives…):
  - Données de production
  - Données sur les clients (CRM : Customer Relation Management)
  - Transactions d'achats et ventes
  - Processus/Plan de gestion (ERP : Entreprise Resource Planning)

  Objectifs :
  → Améliorer la stratégie de l'entreprise
  → Economiser sur les ressources consommées
  → Anticiper l'avenir avec des modèles prédictifs

- Ensuite l'entreprise se tournera vers des sources de données externes (achat de BdD, accès à des OpenData, Web crawling)

4

Diversité des sources

Données externes : BdD commerciales

- Ventes de jeux de données par des instituts de sondage, de mesure d'audience… par des entreprises spécialisées dans la production et la vente de données
- Vente des données liées à l'activité propre de l'entreprise
  (mais dont la diffusion est sans risque pour elle)

  La vente de ces données peut devenir une source de revenus significative…

  Elle est de plus en plus encouragée…
- Vente « par BdD » ou « à l'unité »

5

Diversité des sources

Données externes : OpenData

Des collectivités, des administrations et parfois des entreprises publient des données libres d'accès (*OpenData*)

Ex : ***data.gouv.fr*** publie des *OpenData* sous l'autorité du gouvernement français
(résultats du recensement, résultats économiques du pays, données sur l'éducation, le logement, la santé, l'agriculture…)

data.gouv.fr — Liberté Égalité Fraternité

- Agriculture et Alimentation
- Culture, Communications
- Comptes, Économie et Emploi
- Éducation, Recherche, Formation
- International, Europe
- Environnement, Énergie, Logement
- Santé et Social
- Société, Droit, Institutions
- Territoires, Transports, Tourisme

→ données du TD MongoDB

Diversité des sources

Données externes : collectées sur le web

Collecte automatique de contenus de sites web par des robots de *crawling* (des logiciels), puis extraction des données pertinentes

Une source d'information intéressante, mais qui pose 2 problèmes :

- Pb 1 : collecte de données très déstructurées
  (pas forcément conçues pour faciliter leur collecte)
- Pb 2 : quels droits d'exploitation ???
  (constitue une *zone grise* de la législation)

7

Diversité des types

Données comportementales d'utilisateurs / de clients

- Les **logs des sites web** : contiennent les historiques de navigation des visiteurs
  → Pour reconstituer les parcours et comportements des visiteurs
  → Pour faire des mesures fines d'attractivité des sites web
  (web analytics)
- Les **données des réseaux sociaux - si elles sont accessibles (!!)**
  → Pour enrichir les profils des utilisateurs/des clients

  Elles sont mises à jour par les utilisateurs eux-mêmes (!!)
  - Données souvent à jour
  - Mise à jour gratuitement

8

Diversité des types

Données comportementales de systèmes / d'installations

- Les **données issues de capteurs et objets connectés** : stockées également dans des logs, ou échantillonnées et historisées.
  → Pour faire de la détection et prédiction de pannes
  → Pour réaliser de la maintenance prédictive
  « Comportement d'installations industrielles »
- Données de capteurs et d'objets connectés pour capter des comportements d'utilisateurs… **délicat !!**

9

Diversité des types

Données géographiques / spatiales

- Les données de localisation permettent d'enrichir d'autres données

  Ex :
  - Carte mentionnant des point d'intérêts
    (restaurants, hôtels…)
  - Données socio-économiques recoupées avec des informations géographiques
    (revenu par habitant et par pays, par ville…)
  - Conséquence sur le trafic routier d'événements de proximité

10

Diversité des formats

Données stockées en fichiers

- Fichiers .txt, .cvs… : des lignes de données ASCII
  Pb : les séparateurs de données et de lignes ne sont pas standardisés
- Fichiers JSON, XML… : des données structurées et complexes
  (hiérarchiques)
  - Souvent sous forme de listes de clé-valeur
  - Contiennent les informations pour les interpréter
    (auto-descriptif)
  - Peuvent être interrogés à travers des API/bibliothèques
    (ex : des classes de *parsing* XML en Java)
- Fichiers « *shapefile* » : des données de nature géométrique
  (points, lignes, polygones…)
  - Proviennent de systèmes d'informations géographiques

11

Diversité des formats

Données stockées en fichiers

- Fichiers multimédias au format binaire : images, vidéos, audio
  - Difficile à exploiter sans une application spécialisée
  - Souvent **étiquetés à partir de leur metadonnées externes**
- Nouveaux formats de stockage Apache :
  - Apache parquet : facilite une lecture par colonne pour les calculs de *data-analytics*
  - Apache Avro : mécanisme de *sérialization* incluant le schéma des données (auto-descriptif)

OpenSource
The Apache Software Foundation

Fichiers binaires plats :
- Très compacts, économiques
- Sans metadonnées incluses
  (besoin de connaître leur schéma pour les relire)

Traditionnels en HPC, mais PAS en BigData

12

Diversité des formats

Données stockées en BdD

- BdD SQL :
  Stockage sous forme de tables relationnelles, liées par des clés, toutes cohérentes, et respectant des contraintes d'intégrité
  (ex : il y a bien un « int » et pas un « double » pour un nombre d'étudiants, cet entier est positif ou nul, …)
  Interrogation par requêtes SQL
- BdD NoSQL :
  Stockage sous formes très variées
  - tables avec un nombre variable de colonnes par ligne,
  - format JSON structuré-hiérarchique,
  - format XML…

  sans cohérence ni intégrité garanties
  Interrogation par API native ou Java ou Python…
  …parfois interrogation dans un langage proche de SQL (ex : Hive)

Diversité des données

Bilan de la diversité des données

- Plusieurs aspects dans la diversité :
  sources, types, formats … et d'autres aspects
- **Faut-il exploiter des données plus variées ?**
  - Permettrait une analyse plus riche / pertinente
  - Va demander plus d'efforts d'ingénierie
  - Va augmenter les coûts de développement

14

Exploration et préparation des données

1. Pbs engendrés par la diversités des données
2. **Pbs engendrés par la qualité variable des données**
3. Explorer les données par précaution
4. Préparer les données pour de meilleures analyses
5. Un POC standard est-il démonstratif ?

15

Qualité variable des données

Données alimentant le modèle

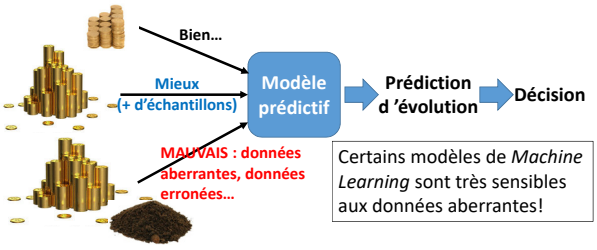

Certains modèles de *Machine Learning* sont très sensibles aux données aberrantes!

Une approche BigData ne permet pas automatiquement d'accepter des données de mauvaise qualité sous prétexte qu'on en prend énormément

Qualité variable des données

Qualité : Exhaustivité

- Rmq : un jeu de données complet n'est pas toujours indispensable.
  - Recherche d'une trace d'intrusion : log complets importants
  - Analyse statistique d'accès à un site : log complets inutiles
- Complétude de la liste des enregistrements
  → Parfois impossible ou inutile
  → Risque de ramener des données erronées, mal collectées
- Complétude de chaque enregistrement
  → que faire d'un enregistrement incomplet ??
  - Le rejeter
  - Le conserver
  - Le compléter avec une valeur moyenne, médiane, précédente …

Voir la *préparation* des données

17

Qualité variable des données

Qualité : Granularité des données

La *granularité* est aussi le *degré de finesse* des données
→ finesse spatiale, temporelle, sociale…

Ex. de besoins en granularité d'un ensemble de mesures :

- assez précises ?
- assez fréquentes dans le temps ?
- couvrant l'ensemble de la zone étudiée ?
- maillant assez finement la zone étudiée ?
- couvrant toutes les catégories sociales de personnes ?

Ex. d'études avec des besoins différents en granularité :

- Des données élémentaires sont nécessaires pour caractériser des individus
- Des données agrégées suffisent pour caractériser des villes

Qualité variable des données

Qualité : Exactitude des données

L'exactitude des données enregistrées représente aussi leur fiabilité

- Les données saisies manuellement par l'utilisateur, ou dictées par téléphone, seront entachées d'erreurs
  → Besoin de vérification dans des annuaires par exemple.
- Les sorties de capteurs peuvent être fausses si un capteur est abimé ou a vieilli
  → Une redondance de la mesure peut permettre de détecter les fausses mesures… mais 2x plus de data !

Vérifier et assurer l'exactitude des mesures est couteux

19

Qualité variable des données

Qualité : Fraicheur des données

La fraicheur des données enregistrées indique si elle sont assez récentes pour l'étude

Ex. sensibles sur la fraicheur :

- données boursières pour décision d'achat ou de vente
- données géographiques pour localiser un produit en mouvement

20

Qualité variable des données

Bilan de la qualité des données :

- Différents critères de qualité des données
- Pas de mesure absolue de la qualité des données
- Sensibilité et besoin très variables selon les données et les traitements
- Il y a un coût à l'augmentation de la qualité des données

Faut-il augmenter la qualité des données ?

→ Décider et agir en fonction des coûts de collecte et d'exploitation

21

Exploration et préparation des données

1. Pbs engendrés par la diversités des données
2. Pbs engendrés par la qualité variable des données
3. **Explorer les données par précaution**
4. Préparer les données pour de meilleures analyses
5. Un POC standard est-il démonstratif ?

22

Objectifs de l'exploration

- La phase d'analyse **démarre** avec l'exploration des données

➢ **Inspecter les données et leur collecte :**

Bonne qualité(s) ?
Allure attendue ?
Existence de biais ?
Existence de valeurs aberrantes ?

➢ afin de **révéler/vérifier la structure des données**

➢ et pouvoir **répondre à la question :**
→ *Le modèle prévu semble-t-il toujours adapté aux données ?*

- Une exploration par **visualisation** est souvent une bonne méthode
  (l'œil humain perçoit très bien des structures au sein d'ensembles de données)

Démarche d'exploration

1 - « Enquêter » sur les données et sur leur collecte

- Saisies manuelle ou automatique ?
- Dans le même but que l'analyse prévue ?
- Collectées en une fois ou en plusieurs étapes ?
  (mêmes conditions pour toutes les étapes ?)
- Référentiels et unités de mesures utilisés ?
- …

} Recherche de metadonnées

On n'a jamais toutes les metadonnées que l'on souhaite !
→ besoin d'**enquêter** ! … peut être long et délicat

Objectifs :

→ Identifier la provenance des données
→ Appréhender la structure des données et leurs formats
→ Détecter les incohérences entre les données
→ Détecter les biais des mesures

24

Démarche d'exploration

2 - Calculer et visualiser des statistiques descriptives

Objectif des statistiques descriptives :

Cerner le centre d'un ensemble de données et sa dispersion autour de ce centre

→moyenne, **médiane**, variance, écart –type, **quantiles**

→**représentation graphique**

Ex. de visualisation pour un ensemble de valeurs numériques

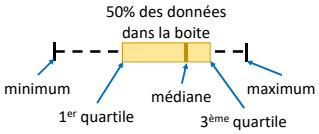

Box plot

25

Démarche d'exploration

2 - Calculer et visualiser des statistiques descriptives

Objectif des statistiques descriptives :

Cerner le centre d'un ensemble de données et sa dispersion autour de ce centre

→moyenne, **médiane**, variance, écart –type, **quantiles**

→**représentation graphique**

Ex. de visualisation pour un ensemble de valeurs numériques

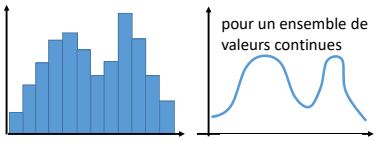

Histogramme

Courbe de densité

Démarche d'exploration

3 - Multiplier les visualisations en cas de données complexes

Rappel des objectifs :

- Avoir une bonne idée des données qui vont alimenter les modèles d'analyse et d'apprentissage
- Détecter les valeurs aberrantes, les biais…

→ En cas de données complexes plusieurs visualisations peuvent être nécessaires

Négliger/sauter cette étape peut mener à faire des analyses longues et couteuses totalement fausses !

Ex : certains algorithmes sont très sensibles aux valeurs aberrantes…

27

Exploration et préparation des données

1. Pbs engendrés par la diversités des données
2. Pbs engendrés par la qualité variable des données
3. Explorer les données par précaution
4. **Préparer les données pour de meilleures analyses**
5. Un POC standard est-il démonstratif ?

28

Objectifs de la préparation

Constituer un jeu de données apte à être analysé :

- de qualité homogène
- avec des structures et des formats bien définis
- exploitable par des algorithmes d'analyse automatique

Corriger les défauts (révélés par l'exploration) **:**

- Traiter les valeurs manquantes et aberrantes
- Redéfinir certaines échelles pour homogénéiser des variabilités
- Utiliser des données externes pour enrichir le jeu initial

3 étapes :

nettoyage → transformation → enrichissement

29

Les 3 étapes de la préparation

nettoyage → transformation → enrichissement

1 - Nettoyage des données

Identifier toutes les données indésirables :

- Erronées / aberrantes
- Trop inexactes (manque de précision)

  Ex : valeurs trop éloignées de la théorie ou des autres, enregistrement d'utilisateurs sans leurs emails…
- Inutiles pour l'analyse voulue … faut-il les supprimer ?

Actions possibles :

- Supprimer une valeur non conforme et garder le reste de l'enregistrement
- Supprimer tout l'enregistrement (toute la ligne)
- Ajouter un flag indiquant si l'enregistrement est conforme ou non (exploitable ou non)
- Remplacer la valeur non conforme par : la médiane, la moyenne, la valeur précédente (cas des données ordonnées)

30

Les 3 étapes de la préparation

nettoyage ⇒ transformation ⇒ enrichissement

2 - Transformation des données

Objectifs :

Manipuler, modifier, créer de nouvelles informations à partir de celles contenues dans les données initiales

Exemples :

- Identifier et Lister les mots les plus fréquents dans des articles à analyser ensuite
- Identifier et Taguer les logs ou événements dont les dates correspondent à des vacances scolaires ou à des jours fériés

Rmq : ce genre de transformations sur de grands ensembles de données se prête bien à des traitements Map-Reduce

31

Les 3 étapes de la préparation

nettoyage ⇒ transformation ⇒ enrichissement

2 - Transformation des données

Opérations de Séparation et Extraction

- Analyse syntaxique d'une chaîne et séparation en une liste d'éléments
- Extraction d'un élément particulier dans une chaîne : nom, email…

Opérations d'Agrégation de valeurs

Remplacement d'un ensemble de données par :

- Le nombre des occurrences d'un terme
- Les termes les plus fréquents
- Une valeur moyenne, médiane, maximale, minimale…

32

Les 3 étapes de la préparation

nettoyage ⇒ transformation ⇒ enrichissement

2 - Transformation des données

Opérations de Modification de valeurs

- Transformation des dates pour s'adapter aux fuseaux horaires, calcul du nombre de jours entre deux dates…
- Remplissage des valeurs manquantes
- Réorganisation des données par catégories pertinentes

Ce denier point empiète sur l'analyse de données !!

33

Les 3 étapes de la préparation

nettoyage ⇒ transformation ⇒ enrichissement

3 - Enrichissement des données

Objectif :

Croiser les données existantes **avec de nouvelles données**, parfois extérieures à l'entreprise

Ex. d'enrichissement géographique :

- Ajouter des info de géocodage (latitude, longitude) à une adresse
- Ajouter une adresse à un géocodage (géocodage inverse)
- Ajouter un géocodage à une adresse IP (démarche approximative)

Ex. d'enrichissement temporel :

- Déterminer si une date d'événement à une adresse donnée, se situe dans les congés scolaires du pays concerné

Ex. d'enrichissement socio-économique :

- Associer des informations juridiques et financières au nom d'une entreprise

34

Les 3 étapes de la préparation

nettoyage ⇒ transformation ⇒ enrichissement

3 - Enrichissement des données

Objectif :

Croiser les données existantes **avec de nouvelles données**, parfois extérieures à l'entreprise

→ **Correspond souvent à une opération de jointure**

- Pour une BdD relationnelle : jointure classique
- Pour une BdD NoSQL :
  - patron Map-Reduce de jointure
  - jointure + restructuration des données

35

Exploration et préparation des données

1. Pbs engendrés par la diversités des données
2. Pbs engendrés par la qualité variable des données
3. Explorer les données par précaution
4. Préparer les données pour de meilleures analyses
5. **Un POC standard est-il démonstratif ?**

36

POC standard

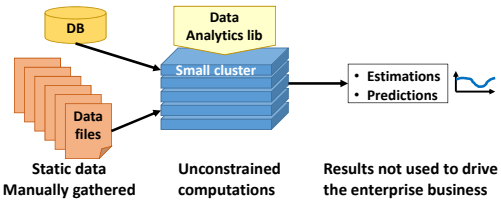

- Système non connecté aux flux de données réels de l'entreprise
- Calculs menés sans contrainte de temps
- Visualisation des résultats par (simplement) quelques courbes …

→ Pas de démarche possible de réflexion/décision sur l'évolution de l'entreprise

→ **POC non démonstrative (de l'apport de l'analyse de données)**

Expérimentation significative

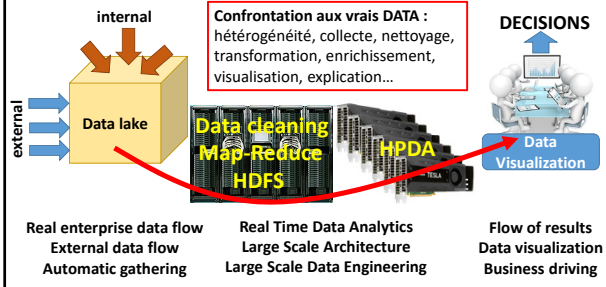

- Le système minimum doit être connecté aux vrais données de l'entreprise, en temps réel
- Les résultats doivent être exploités pour influer sur le business de l'entreprise

Consensus au forum Big Data 2018, Paris

38

Exploration et préparation des données

39