

Des entrepôts à la fouille de données

Jean-Marc Petit
INSA de Lyon

jmpetit@liris.cnrs.fr

Laboratoire d'InfoRmatique en Image et Systèmes d'information

LIRIS UMR 5205 CNRS/INSA de Lyon/Université Claude Bernard Lyon 1/Université Lumière Lyon 2/Ecole Centrale de Lyon
 Université Claude Bernard Lyon 1, bâtiment Nautibus
 43, boulevard du 11 novembre 1918 — F-69621 Villeurbanne cedex
[http://liris.cnrs.fr/](http://liris.cnrs.fr)

Ecole d'été COSI 2007 – Oran – Algérie / mardi 11 septembre 2007

Plan du cours

- Fouille de données : une vision d'ensemble
- Un petit focus sur le passage à l'échelle
- Problèmes d'énumération des motifs intéressants
 - Cadre formel
 - Exemples
 - Algorithmes d'énumération
- Conclusions

Ecole d'été COSI 2007 – Oran, Algérie

que ce cours est/n'est pas

- Est :
 - Positionnement de la fouille de données
 - Un aperçu des enjeux et des techniques
- N'est pas :
 - Un descriptif de méthodes/algorithmes
 - Un aperçu du fonctionnement des systèmes de fouille de données

Ecole d'été COSI 2007 – Oran, Algérie

Bibliographie

- Principale référence
 - « Data Mining: Concepts and Techniques » par Jiawei Han et Micheline Kamber, Morgan Kaufmann Publishers, 550 pages, 2004
- Conférences scientifiques
 - ACM KDD, IEEE ICDM, SIAM DM
 - + conférence DB et Apprentissage
- Sites web dédiés à la fouille de données
 - www.kddnuggets.com

Ecole d'été COSI 2007 – Oran, Algérie


duction à la fouille de données

« Nécessité est mère d'invention »

- **Constat : déluge de données**
 - dans des entrepôts de données (ou data warehouses (DW) ou data marts)
 - dans des bases de données (BD)
 - dans des fichiers
- **Pénurie de connaissances sur ces données**
- **Les techniques de fouille de données peuvent être une solution**

le de données : au delà des ED

More New Information Over Next 2 Years Than in All Previous History



Exemples :

- Téléphone AT&T : BD d'appel téléphonique 20TB, suivi des appels sans fil
- Grande consommation Wal-Mart: BD 70TB
- WEB crawl : 200M de pages et 2000M liens, 7 milliards de clics par jour

ension des requêtes SQL

- **Suite logique des bases de données**
 - requêtes SQL classiques
 - idée simple : accéder efficacement aux données pour faire des analyses
 - requêtes OLAP (OnLine Analytical Processing)
 - Idée simple : améliorer l'analyse des données par agrégations « complexes »
 - Fouille de données (data mining)
 - aller au-delà : construction de modèles d'apprentissage pour la classification, regroupement de données en classes, ...


D vs entrepôt et fouille

- **construit différemment des BD (en général)**
 - **Intégration** de sources de données (multiples, hétérogènes, BD relationnelles, fichiers)
 - Nécessite de nettoyer et d'intégrer ces données (normaliser, conventions de nommage, mesures utilisées, conversion des données)
- **construit pour faciliter l'aide à la décision**
 - exclu des données jugées non pertinentes par rapport à ces objectifs
- **Technologie utilisé ?**
 - Souvent basée sur les SGBDR !

Qu'est-ce que la fouille de données ?

- Mauvais noms, analogie avec la recherche d'or
- Définition informelle : *"Extraction of interesting (non-trivial, implicit, previously unknown and potentially useful) information or patterns from data in large databases"*
- Synonymes :
 - Data mining, KDD pour knowledge discovery in databases, business intelligence, etc.
- Ce que n'est pas la fouille de données ?
 - Systèmes experts
 - Petits programmes statistiques/d'apprentissage
 - Bases de données déductives

Fouille de données



Principales techniques de data mining

- Les techniques "classiques"
 - Association
 - corrélation et causalité
 - Classification et prédiction supervisée
 - arbre de décision,
 - réseaux bayésiens,
 - réseaux de neurones,
 - régression logistique, linéaire, non linéaire
 - Segmentation (Clustering) non supervisée
 - Analyse des cas particuliers (outliers)
- Et beaucoup d'autres ...

Data Mining : un domaine pluridisciplinaire

- Analyse de données, Statistiques, Mathématiques
- Bases de données
 - Accès à des données volumineuses, entrepôts de données
 - Algorithmique en mémoire externe
- Intelligence Artificielle
 - Techniques d'apprentissage "Machine learning"
- Autres domaines :
 - Recherche opérationnelle, optimisation combinatoire
 - Imagerie
 - Visualisation
- Nouveau domaine à part entière ?

Principales applications

- ☰ A qui sert le data mining ?
 - à l'homme, e.g. pour faciliter la prise de décision
 - à des systèmes, e.g. pour s'adapter automatiquement en fonction des données collectées (e.g. systèmes d'exploitation, bases de données).
- ☰ Exemples pour l'aide à la décision
 - Analyse de marchés
 - cible marketing,
 - gestion clientèle,
 - analyse du panier de la ménagère,
 - segmentation de marché
 - Analyse de risques
 - prévision, contrôle qualité,
 - détection de fraudes, ...
- ☰ Domaines d'application : commerce, bio-informatique, WWW ...

Exemples du monde réel

- ☰ Les transactions dans les grandes surfaces
 - Comment mieux disposer les articles dans les rayons pour favoriser les ventes ?
 - Comment concevoir un catalogue ? une page Web ?
- ☰ Les achats sur Amazon.com
- ☰ Les transactions aux péages autoroutes
 - Quels sont les motifs « fréquents » d'utilisation du réseau autoroutier ?

Préparation des données

- ☰ Nettoyage des données
 - valeurs manquantes,
 - valeurs aberrantes,
 - inconsistances
- ☰ Intégration des données
 - fichiers, BD, entrepôts
- ☰ Transformation des données
 - Normalisation
 - Agrégation
 - Réduction des données
 - Représentation plus "petites" des données sans altérer la qualité des résultats analytiques
 - Discretisation des données

Etape critique et laborieuse qui conditionne la suite du processus

Problème de la connaissance extraite ?

- ☰ Problème du volume de la connaissance extraite
 - Par ex, plusieurs millions de règles d'association
- ☰ Mesure d'intérêt de la connaissance extraite
 - Mesure objective
 - basé sur des statistiques
 - support, confiance d'une règle
 - Mesure subjective
 - basé sur l'utilisateur
- ☰ Quand est ce que la connaissance est intéressante ?
 - Quand elle est inattendue
 - Quand elle sert à résoudre le problème de l'analyste

Problème majeur en pratique, pas de solutions à priori

Les systèmes DM (SDM)

Les systèmes supportant le Data Mining

- Analogie avec les SGBD

Industrie

- Côté statistiques
 - SAS : Entreprise Miner
 - SPSS avec Clementine
- Côté bases de données
 - Microsoft : OLE DB for DM
 - IBM : Intelligent Miner
 - Oracle : package ad-hoc, SQL-like data mining

Académie

- DMQL (J. Han, USA)
- Logiciel libre WEKA (Nouvelle Zélande)

Interaction des SDM avec les SGBD

pas de couplage

- déchargement d'une partie de la BD dans un fichier

couplage faible

- récupérer les données ligne à ligne avec SQL et curseurs via un LP

couplage semi-fort

- quelques primitives de DM intégrés dans un SGBD

couplage fort

- intégration totale des techniques de DM dans un SGBD

Positionnement des outils dans ce canevas ?

Plan du cours

Fouille de données : une vision d'ensemble

Un petit focus sur le passage à l'échelle

Problèmes d'énumération des motifs intéressants

- un cadre formel
- Exemples
- Algorithmes d'énumération
- Structure de données pour la gestion d'ensemble d'ensemble

Conclusions

Passage à l'échelle

Fouille de données : activité qui permet de découvrir des connaissances dans les données volumineuses


Verrous ?

- passage à l'échelle des techniques développées en analyse de données, machine learning, statistiques, optimisation combinatoire, ...

Passage à l'échelle ?

Quel verrou technologique sous jacent ?

Modèle de mémoire RAM




Modèle théorique standard de calcul

- Très simple
- Mémoire virtuelle infini
- Coût d'accès en temps constant

Modèle crucial pour le succès de l'informatique


Mémoire hiérarchique



Machines modernes

- Plusieurs niveaux de mémoire
- Niveaux loin du processeur : plus grands et plus lents
- Mouvement des données entre les niveaux
 - Utilisation de "bloc" ou "page"
 - De plus en plus grand

E/S lente




Accès disque ~ 10^6 plus lent
que accès RAM

"The difference in speed between modern CPU and disk technologies is analogous to the difference in speed in sharpening a pencil using a sharpener on one's desk or by taking an airplane to the other side of the world and using a sharpener on someone else's desk." (D. Comer)

Important de stocker et d'accéder aux données de façon à tirer profit des blocs (contiguïté)

Problème de passage à l'échelle

Programmes développés dans le modèle RAM
Fonctionne sur des grands jeux de données
OS déplace les blocs pour nous entre les niveaux !




OS récents utilise des stratégies de pagination et de "prefetching" sophistiquées

- Inefficace si le programme fait des accès aléatoires



problèmes de passage à l'échelle (scalability)



Retour sur le data mining

- Définition personnelle du contour des techniques de data mining

« Toutes les propositions qui adressent le problème du passage à l'échelle pour leur technique »

Plan du cours

- Fouille de données : une vision d'ensemble
- Un petit focus sur le passage à l'échelle
- **Problèmes d'énumération des motifs intéressants**
 - Cadre formel
 - Exemples
 - Algorithmes d'énumération
- Conclusions

Thème large

- **Motifs fréquents pour les règles d'association**
 - Apriori [Sigmod 94] et ses innombrables améliorations
 - Souvent au niveau « structure de données »
 - Nombreuses applications
 - Requiert une discrétisation dans $\{0,1\}$ des données
- **Arbres fréquents dans des forêts ☺**
 - données semi structurées
- **Sous-séquences fréquentes dans une séquence**
- **Contraintes dans les bases de données**
 - Clés via les dépendances fonctionnelles
 - Clés étrangères via les dépendances d'inclusion

Objectifs

- Identifier une ou des classes de problèmes que l'on pourra résoudre efficacement
- Tentative de définir un cadre commun
 - À partir des travaux de Mannila et Toivonen [DMKD'97, ACM TODS'05]
- La plupart des solutions proposées pour ces problèmes sont spécifiques

Cadre théorique

- Focus sur les problèmes d'énumération de motifs intéressants dans les grandes bases de données
- Définition des principaux termes
 - Bases de données d
 - Motifs
 - Motifs intéressants dans d : notion de prédicat
 - Relation d'ordre entre motifs
- Propriété du prédicat
- Cadre ensembliste

Exemple de jeux de données

- BD relationnelle
- Relation binaire ou BD de transactions
- Fichiers textes, documents structurés
- Données semi-structurés

Pas vraiment d'hypothèses fortes, doit décrire les données et les moyens pour y accéder

Exemples de motifs / langages

- Sous ensembles d'un ensemble
- Séquences
- Arbres
- Graphes
- Dépendances fonctionnelles
- Dépendance d'inclusion
- ...

Forme des motifs qui nous intéressent, notion syntaxique

Exemples de prédicats

- X est fréquent dans une BDT
- $X \rightarrow Y$ est satisfaite dans une relation
- Le sous arbre X apparaît plus de n fois dans la collection d'arbres
- Formule mathématique

➔ Permet de définir formellement la notion de « motif intéressant »

Sens des motifs qui nous intéressent, notion sémantique

texte du travail : Notations

Un modèle pour la découverte de connaissance

- [Mannila & Toivonen, DMKD, 1997]
- Cadre théorique, nombreuses applications
 - Motifs fréquents, séquentiels, DF, DI, ...

Cadre :

- Etant donné
 - Une base de données d
 - Un langage fini L (ou un ensemble de motifs)
 - Un prédicat Q défini sur d et un motif X de L

Trouver

$$Th(L, d, Q) = \{X \in L \mid Q(X, d) = VRAI\}$$

Relation d'ordre entre motifs

Permet de structurer l'espace de recherche

- si les motifs sont des ensembles, on retrouve l'inclusion ensembliste
- Sinon, cela dépend des motifs

Permet aussi de rechercher si le problème a de bonnes propriétés, typiquement la **monotonie**

Permet d'éviter l'énumération « brute force » de tous les motifs intéressants

Notations (suite)

Si de plus on suppose :

- Un ordre partiel \leq entre les motifs (relation de spécialisation/généralisation)
- Q (anti-)monotone par rapport à \leq :
 $\forall X, Y \in L \text{ tq } X \leq Y, Q(Y, d) \text{ vrai} \Rightarrow Q(X, d) \text{ vrai}$

Alors le problème peut se ramener à la recherche de :

$$MTh(L, d, Q) = \{X \in Th(L, d, Q) \mid \nexists Y \in Th(L, d, Q), X \leq Y, Y \neq X\}$$

Problèmes « représentables par des ensembles »

Etude de plongement dans un treillis booléen

Idées de base :

- Faire correspondre à chaque motif un certain sous ensemble d'un ensemble
- Préserver l'ordre partiel

Définit ainsi toute une classe de problèmes, qui d'un point de vue théorique, sont « équivalents » à un isomorphisme près.

Opportunité pour faire de l'**optimisation de requêtes!**

Notations (fin)

Si de plus on suppose :

- L est « représentable » par un ensemble si il existe un ensemble E et une fonction $f : L \rightarrow 2^E$ tel que
 - f soit bijective
 - $X \leq Y \Leftrightarrow f(X) \subseteq f(Y)$

Alors, le problème initial peut se ramener à :

$$Bd^+(I) = \{X \in Th(L, d, Q) \mid \forall Y \supset X, Q(Y, d) = FAUX\}$$

$$Bd^-(I) = \{X \notin Th(L, d, Q) \mid \forall Y \subset X, Q(Y, d) = VRAI\}$$

Notions de bordures

- Soit I un ensemble de motifs intéressants de E
- La **bordure positive** de I (les motifs les plus spécifiques de I), noté $Bd^+(I)$, est :
$$Bd^+(I) = \{X \in I \mid \forall Y \supset X, Y \notin I\}$$

- La **bordure négative** de I (les motifs les plus généraux qui ne sont pas dans I), noté $Bd^-(I)$, est :

$$Bd^-(I) = \{X \in (2^E \setminus I) \mid \forall Y \subset X, Y \in I\}$$

- Il existe un lien fort entre les bordures positive et négative
 - Transformation de l'un à l'autre et vice et vers ça
- Objet combinatoire connu :
 - transversaux minimaux d'un hypergraphe

Formulation des problèmes

Grande unité de définition des problèmes

- Même si une grande partie de la difficulté réside dans cette formulation
- “un problème bien posé est à moitié résolu” ☺

Trois formes

- Enumération des éléments I de E
- Enumération des éléments de $Bd^-(I)$
- Enumération des éléments de $Bd^+(I)$

Les problèmes « ensemblistes »

- A la base d'algorithmes de parcours de l'espace de recherche
- Structure de données pour manipuler de grandes collections d'ensembles d'ensemble.


Cadre restrictif néanmoins ...

Possibilité d'appliquer des techniques d'optimisation de requêtes en BD

Application aux motifs fréquents

- Ensemble de propriétés P
- Une ligne t est un sous-ensemble de P, i.e. $t \subseteq P$
- bd : multi-ensemble de lignes
- $Q(X, bd, \alpha)$: « être fréquent » par rapport à un seuil α , i.e. $|\{t \mid t \in bd \text{ et } X \subseteq t\}| \geq \alpha$
 - Si $Q(X, bd, \alpha) = \text{VRAI}$ alors X est un **motif fréquent**
- Propriété :
 - Q est anti-monotone par rapport à \subseteq
- Fonction f : fonction identité


Exemple parcours par niveaux (Apriori)



Algorithmes d'énumération

- Par niveau: connu en fouille de données sous le nom d'Apriori (Agrawal et al 1993, ACM Sigmod)
- Par dualisation (transversaux minimaux)
 - moins connu mais très élégant
 - Idée : passer d'une bordure à l'autre en évitant l'explosion combinatoire des approches par niveaux quand de grands éléments existent

Exemple pour bd+




solution est peut etre là ...

- Bordure positive optimiste** = plus "grands" éléments pas disqualifiés par NI
- On a donc :


$$Bd_{opt}^+(I) = \overline{\text{MinTr}(NI)}$$

- Notion de "saut" dans l'espace de recherche


Intuition




Estimation de l'erreur



Stratégies adaptatives 1/2



Stratégies adaptatives 2/2



Structure de données

- Quelles structures de données pour gérer des ensembles d'ensemble très volumineux ?
- Dépend des opérations à faire sur ces structures
- Pour des algorithmes type Apriori
 - Développement de structure de « trie » développée en recherche d'information (information retrieval)
 - Arbre de préfixe ou dictionnaire
 - Recherche d'un élément en temps constant
 - Et variantes ... Patricia trees,
- Beaucoup de travaux dans la littérature

Conclusion et perspectives

- Fouille de données :
 - guidée par les applications
 - à la croisée de nombreuses branches de l'informatique
 - Constitue ses forces et ses faiblesses
- Beaucoup de business, réel besoin des entreprises
- Difficulté de la validation avec des experts

- A terme : nécessité d'intégration et de rapprochement avec les SGBD => passage à l'échelle