Extraction de motifs : Règles d'association et motifs séquentiels

Pascal Poncelet
LIRMM
Pascal.Poncelet@lirmm.fr
http://www.lirmm. fr/~poncelet

Plan

- Règles d'association
- Motifs séquentiels
- Applications : Web Mining, Text Mining
- Conclusions

« Panier de la ménagère »

- Recherche d'associations
  - recherche de corrélations entre attributs (items)
  - caractéristiques : « panier de la ménagère »
  - de très grandes données
  - limitations : données binaires
- Recherche de motifs séquentiels
  - recherche de corrélations entre attributs (items) mais en prenant en compte le temps entre items => comportement

Recherche de règles d'association

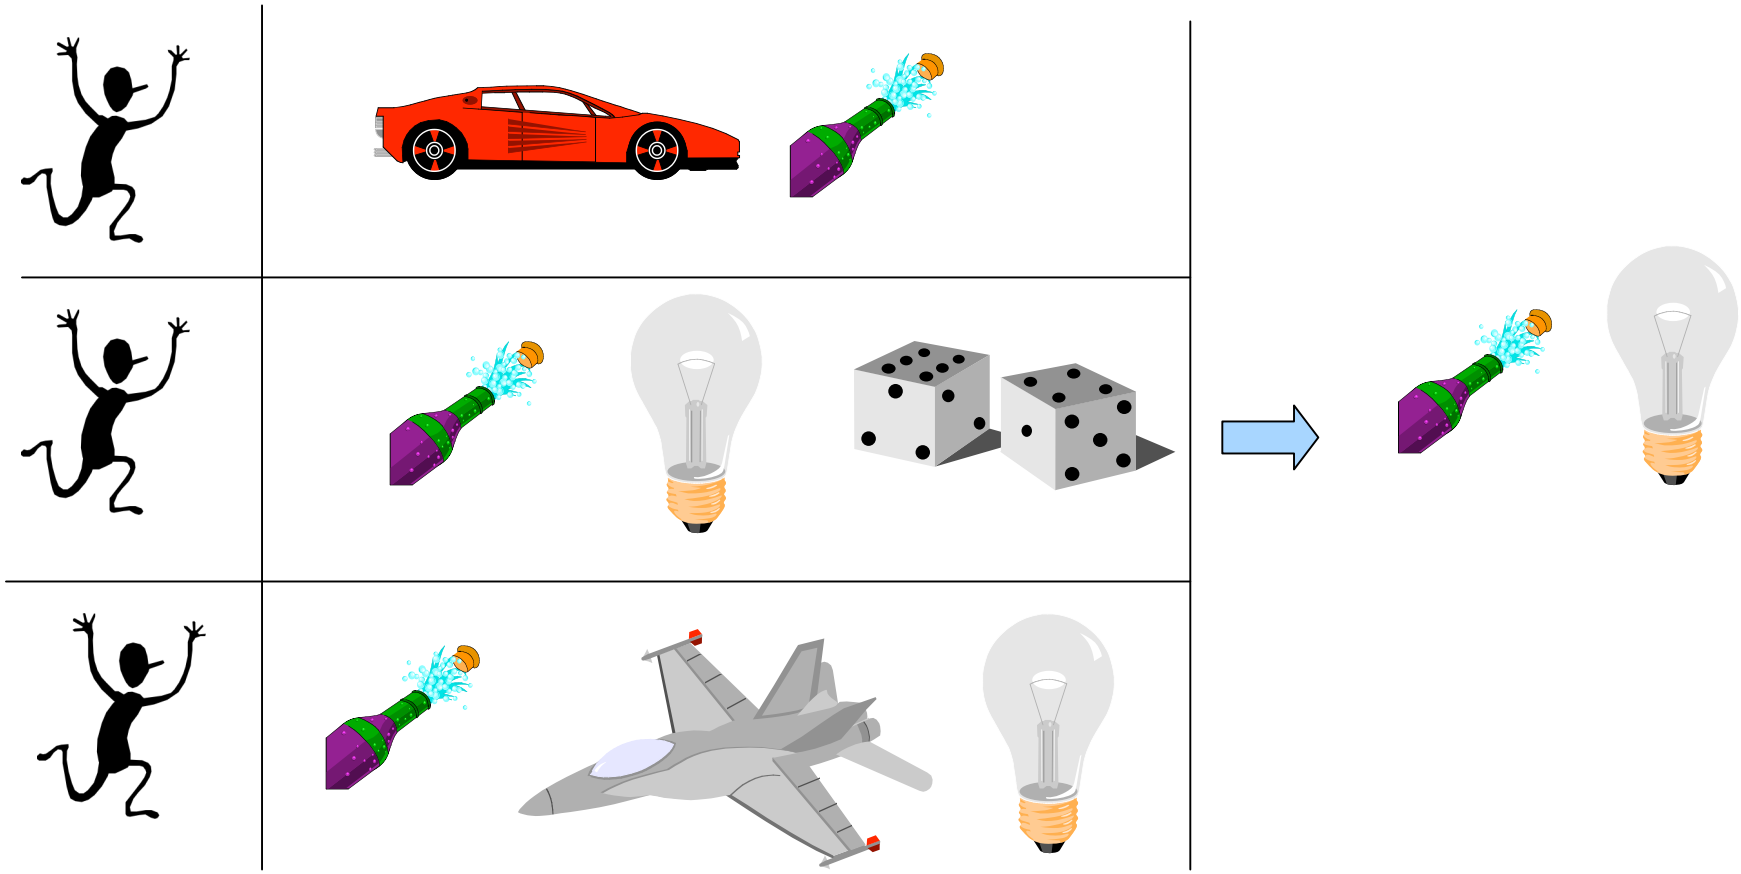

Panier de la ménagère

Localisation

Produits achetés

Identification

Date, heure

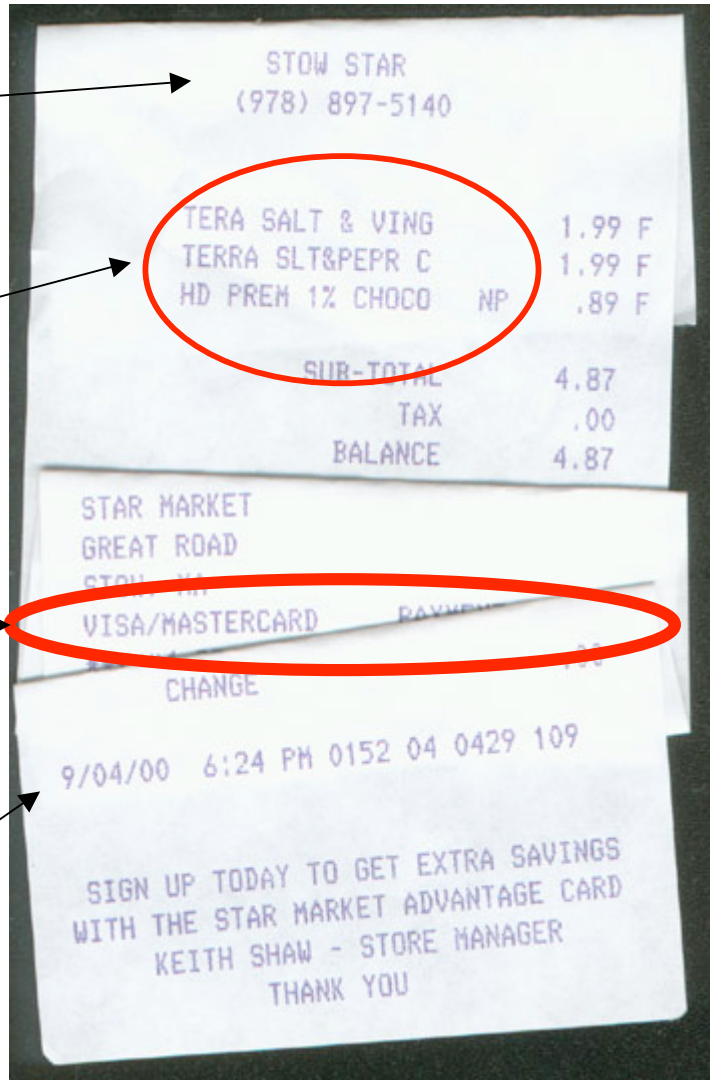

Panier de la ménagère

Localisation

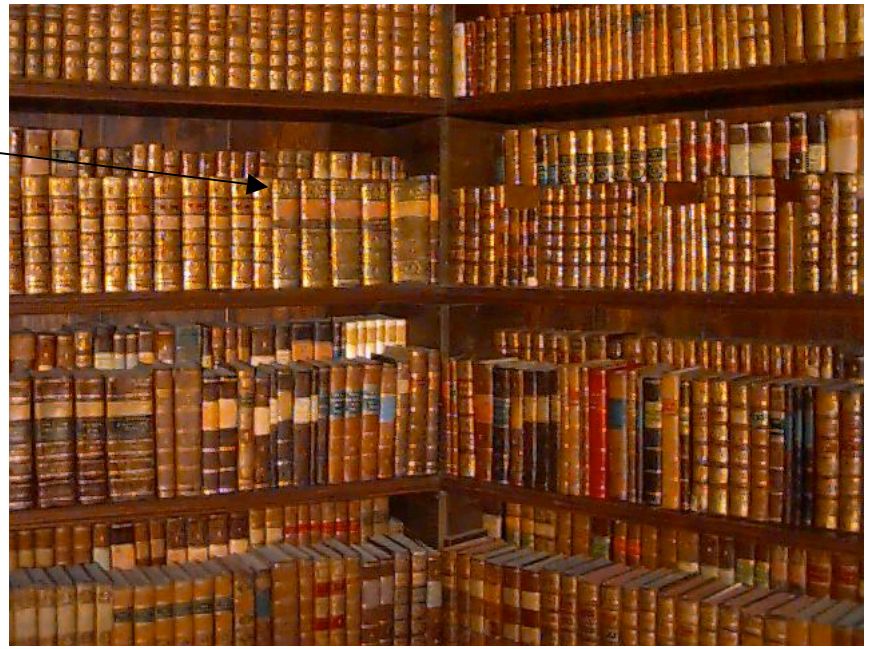

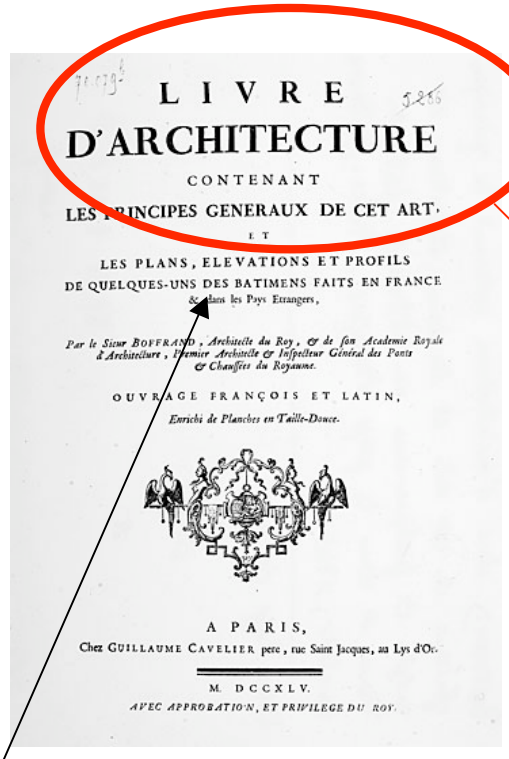

LIVRE
D'ARCHITECTURE
CONTENANT
LES PRINCIPES GENERAUX DE CET ART,
ET
LES PLANS, ELEVATIONS ET PROFILS
DE QUELQUES-UNS DES BATIMENS FAITS EN FRANCE
& dans les Pays Etrangers,

Par le Sieur BOFFRAND, Architecte du Roy, & de son Academie Royale d'Architecture, Premier Architecte & Inspecteur Général des Ponts & Chaussées du Royaume.

OUVRAGE FRANÇOIS ET LATIN,
Enrichi de Planches en Taille-Douce.

A PARIS,
Chez GUILLAUME CAVELIER pere, rue Saint Jacques, au Lys d'Or.

M. DCCXLV.
AVEC APPROBATION, ET PRIVILEGE DU ROY.

Premier paragraphe

« Livre d'architecture contenant les principes généraux … »

Identification

Position # Date

Mots # Produits

Recherche de règles d'association

- Règles de la forme

ANTECEDENT → CONSEQUENT [Support, Confiance]

(support et confiance sont des mesures d'intérêt définies par l'utilisateur)

- Achat (x, « Beurre ») ET Achat (x, « Pain ») → Achat(x, « Lait ») [70%, 80%]
- Achat (x, « Bière ») ET Achat (x, « Gâteaux ») → Achat (x, « Couches ») [30%, 80%]
- Achat (x, « Caviar ») → Achat(x, « Champagne ») [10%, 90%]

La légende

Stories – Beer and Diapers

- Diapers and Beer. Most famous example of market basket analysis for the last few years. If you buy diapers, you tend to buy beer.
  - T. Blischok headed Terradata's Industry Consulting group.
  - K. Heath ran self joins in SQL (1990), trying to find two itemsets that have baby items, which are particularly profitable.
  - Found this pattern in their data of 50 stores/90 day period.
  - Unlikely to be significant, but it's a nice example that explains associations well.

Ronny Kohavi ICML 1998

Interprétation

- R : X → Y (A%, B%)
  - ***Support*** *: portée de la règle*

    Proportion de paniers contenant tous les attributs

    A% des clients ont acheté les 2 articles X et Y

  - ***Confiance*** *:*

    Proportion de paniers contenant le conséquent parmi ceux qui contiennent l'antécédent

    B% des clients qui ont acheté X ont aussi acheté Y

  - Beurre, Pain → Lait [70%, 80%]
  - Bière, Gâteaux → Couches [30%, 80%]
  - Caviar → Champagne [10%, 90%]

Utilisation des règles d'association

Bière, … →Couches

- **Couches** comme conséquent

  déterminer ce qu'il faut faire pour augmenter les ventes

- **Bière** comme antécédent

  quel produit serait affecté si on n'arrête de vendre de la bière

- **Bière** comme antécédent et **Couche** comme conséquent

  quels produits devraient être vendus avec la Bière pour promouvoir la vente de couches

Définitions des ensembles fréquents

- Soit un ensemble I = {I1, I2, ..., Im} d'items, une transaction T est définie comme les sous-ensembles d'items dans I ($\subseteq$ I).
  - I = {Bière, Café, Couche, Gâteaux,Moutarde,Saucisse...}
  - T1 = {Café, Moutarde, Saucisse}
- Une transaction n'a pas de duplicats
- Soit une base de données D un ensemble de n transactions et chaque transaction est nommée par un identifiant (TID).
  - D = {{T1, {Café,Moutarde,Saucisse}},
    {T2, {Bière, Café, Gâteaux}}, ...}

Une base de données

- Une représentation de la base de données D

Client	Pizza	Lait	Sucre	Pommes	Café
1	1	0	0	0	0
2	0	1	1	0	0
3	1	0	0	1	1
4	0	1	0	0	1
5	1	0	1	1	1

- En fait ….

$$M = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 1 & 0 & 0 \\ 1 & 0 & 0 & 1 & 1 \\ 0 & 1 & 0 & 0 & 1 \\ 1 & 0 & 1 & 1 & 1 \end{bmatrix}$$

Définition des ensembles fréquents (cont.)

- Une transaction T **supporte** un ensemble $X \subseteq I$ si elle contient tous les items de X ($X \subseteq T$).
  - T1 supporte {Café, Moutarde,Saucisse}
- Support de X (**Supp(X)**) : fraction de toutes les transactions dans D qui supportent X.
- Si $supp(X) \geq s_{min}$ l'ensemble X est dit **fréquent**.

- Un ensemble d'items (*itemset*) X de cardinalité

k = |X| est appelé un *k-itemset*.

3-itemset : {Café, Moutarde, Saucisse}

Propriétés des ensembles fréquents

- **Propriété 1** : *support pour les sous-ensembles*
  - Si A ⊆ B pour les itemsets A, B alors supp(A) >= supp(B) car toutes les transactions dans D qui supportent B supportent aussi nécessairement A.

  A={Café, Moutarde}, B ={Café, Moutarde, Saucisse}

- **Propriété 2** : *les sous-ensembles d'ensembles fréquents sont fréquents*

- **Propriété 3** : *les sur-ensembles d'ensembles non fréquents sont non fréquents* (anti-monotonie)

Définition des Règles d'association

- Une règle d'association est une implication de la forme

$$R : X \rightarrow Y$$

où X et Y sont des itemsets disjoints : $X, Y \subseteq I$ et $X \cap Y = \varnothing$.

Bière, Gâteaux → Couches

Définition des Règles d'association (cont.)

- Confiance (*confidence*) dans une règle R
- Si une transaction supporte X, elle supporte aussi Y avec une certaine probabilité appelée **confiance** de la règle (conf(R)).

$$conf(R) = p(Y \subseteq T \mid X \subseteq T)$$
$$= p(Y \subseteq T \wedge X \subseteq T) / p(X \subseteq T)$$
$$= support(X \cup Y) / support(X)$$

$$conf(R) = \frac{Supp(Bière, Gâteaux, Couches)}{Supp(Bière, Gâteaux)} \geq \text{confiance ?}$$

Propriétés des règles d'association

- **Propriété 4** : *pas de composition des règles*
  - Si X → Z et Y → Z sont vrais dans D, X U Y → Z n'est pas nécessairement vrai.
  - Considérons le cas où X ∩ Y = Ø et les transactions dans D supportent Z si et seulement si elles supportent X ou Y, alors l 'ensemble X U Y a un support de 0 et donc X U Y → Z a une confiance de O%.

- **Propriété 5** : *décomposition des règles*
  - Si X U Y → Z convient, X → Z et Y → Z peut ne pas être vrai.

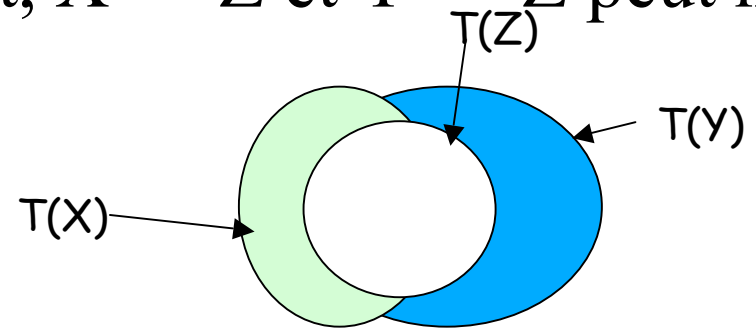

Propriétés des règles d'association

- **Propriété 6** : *pas de transitivité*
  - Si X → Y et Y → Z , nous ne pouvons pas en déduire que X → Z.

- **Propriété 7** : *déduire si une règle convient*
  - Si A → (L-A) ne vérifie pas la confiance alors nous n'avons pas B → (L-B) pour les itemsets L, A, B et B ⊆ A.

En résumé

- Itemsets : A, B ou B, E, F
- Support pour un itemset

  Supp (A,D)=1

  Supp (A,C) = 2
- Itemsets fréquents (minSupp=50%)

  {A,C} est un itemset fréquent
- Pour minSupp = 50% et minConf = 50%, nous avons les règles suivantes :

  A → C [50%, 50%]

  C → A [50%, 100%]

Trans. ID	Items
1	A, D
2	A, C
3	A, B, C
4	A, B, E, F

Schéma algorithmique de base

- La plupart des approches utilise le même schéma algorithmique
- Pour construire les règles d ’association, le support de tous les itemsets fréquents dans la base doit être calculé
- L ’algorithme procède en deux phases :
  - 1) Génération de tous les ensembles fréquents
  - 2) Génération des règles d ’association

Comptage des itemsets

- Une première approche
- I = {A, B,C}
- Génération de tous les cas possibles :

  {∅},{A}, {B}, {C},

  {A,B}, {A,C}, {B,C}

  {A,B,C}
- Comptage du support

Génération des ensembles fréquents

- Le nombre d 'ensemble fréquent potentiel est égal à la taille du produit cartésien de tous les items …. qui croit exponentiellement en fonction du nombre d 'items considérés.
- Approche naïve : recherche exhaustive et test de tous les ensemble du produit cartésien pour savoir s 'ils sont fréquents
- 1000 items => 2^{1000} ensembles à considérer

Vers un algorithme générique

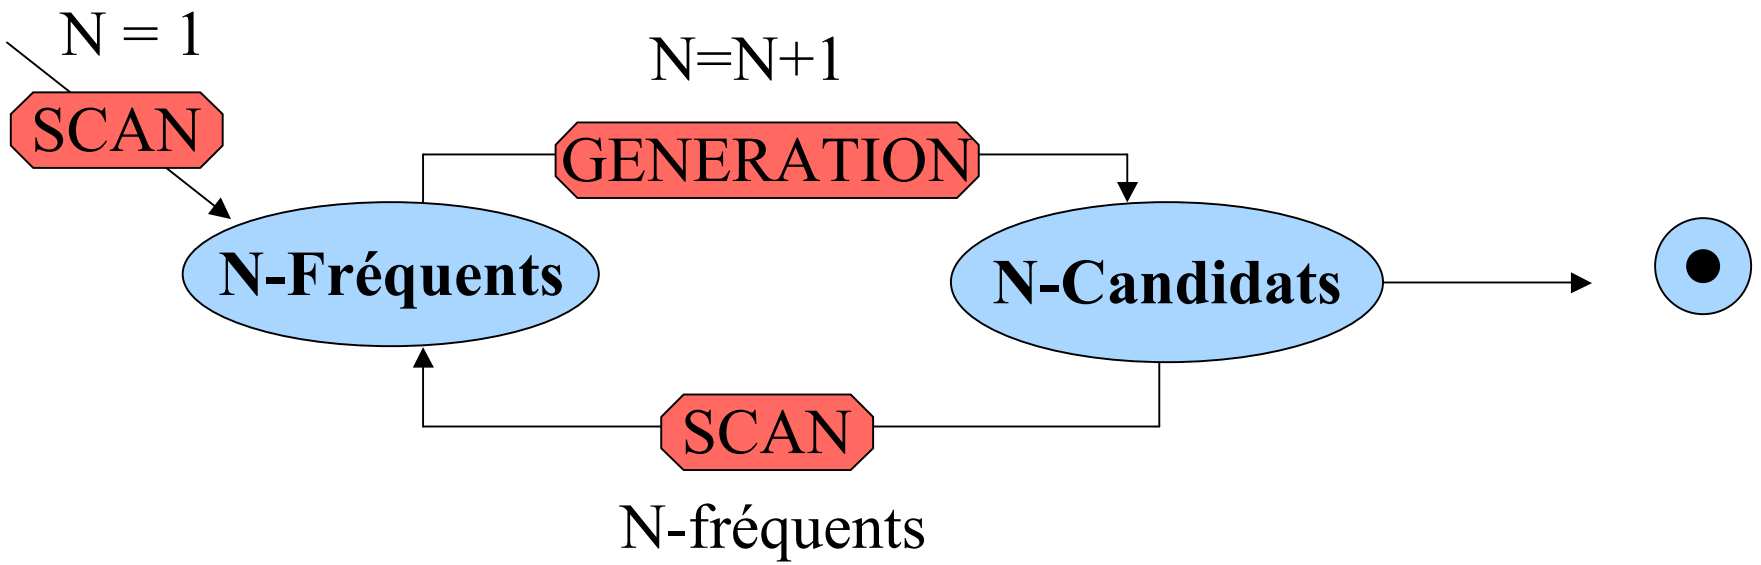

Construction des règles

- Pour chaque ensemble fréquent X, chaque sous-ensemble est choisi comme antécédent de la règle, le reste devenant la partie conséquent.
- Comme X est fréquent, tous les sous-ensembles sont fréquents (Propriété 3) donc leur support est connu. La confiance d'une règle est calculée et une règle est conservée ou pas selon la confiance minimale.
- Amélioration : (Propriété 7) quand une règle échoue, aucun sous ensembles de l 'antécédent n 'est à considérer.

Bref historique

- Problématique initiée en 1993
- CPU vs. I/O
- De nombreux algorithmes ...

AIS - *R. Agrawal, T. Imielinski and A. Swami - ACM SIGMOD 1993*

SETM - *Houtsma and Swami - IBM Technical Record*

APRIORI - *R. Agrawal and R. Srikant - VLDB 1994*

PARTITION - *A. Sarasere, E. Omiecinsky and S. Navathe - VLDB 1995*

SAMPLING - *H. Toivonen - VLDB 1996*

DIC - *S. Brin, R. Motwani, J.Ulman and S. Tsur - ACM SIGMOD 1997*

PrefixSpan - *J. Pei, J. Han, …. - ICDE'01*

SPADE - *M. Zaki - Machine Learning'01*

….2006, 2007

L'algorithme APRIORI

- But : minimiser les candidats
- Principe : générer seulement les candidats pour lesquels tous les sous-ensembles ont été déterminés fréquents

- Génération des candidats réalisée avant et de manière séparée de l'étape de comptage

L'algorithme APRIORI

Input : C_k: itemsets candidats de taille k

Output : L_k : itemsets fréquents de taille k

L_1 = {items fréquents};

for (k = 1; L_k !=∅; k++) do

  C_{k+1} = candidats générés à partir de L_k;

  Pour chaque transaction t de la base de données, incrémenter le compteur de tous les candidats dans C_{k+1} qui sont contenus dans t

  L_{k+1} = candidats dans C_{k+1} avec minSupp

return $\cup_k L_k$;

Détails d'APRIORI

- Comment générer les candidats ?
  - Etape 1: auto-jointure sur L_k
  - Etape 2: élagage
- Comment compter le support des candidats ?

Génération des candidats

- Les items de L_{k-1} sont ordonnés par ordre lexicographique

- Etape 1: auto-jointure sur L_{k-1}

  INSERT INTO C_k

  SELECT $p.item_1, p.item_2, \ldots, p.item_{k-1}, q.item_{k-1}$

  FROM $L_{k-1}\ p, L_{k-1}\ q$

  WHERE $p.item_1=q.item_1, \ldots, p.item_{k-2}=q.item_{k-2}, p.item_{k-1} < q.item_{k-1}$

- Etape 2: élagage

  For each itemset c in C_k do

  For each (k-1)-subsets s of c do if (s is not in L_{k-1}) then delete c from C_k

Génération des candidats : exemple

- L_3={*abc, abd, acd, ace, bcd*}
- Auto-jointure : L_3*L_3
  - *abcd* à partir de *abc* et *abd*
  - *acde* à partir de *acd* et *ace*
- Élagage :
  - *acde* est supprimé car *ade* n'est pas dans L_3
- C_4={*abcd*}

Stockage des candidats

- un arbre (structure de hash-tree)

structure de tous les 3-candidats possibles pour 5 items (A, B, C, D, E)

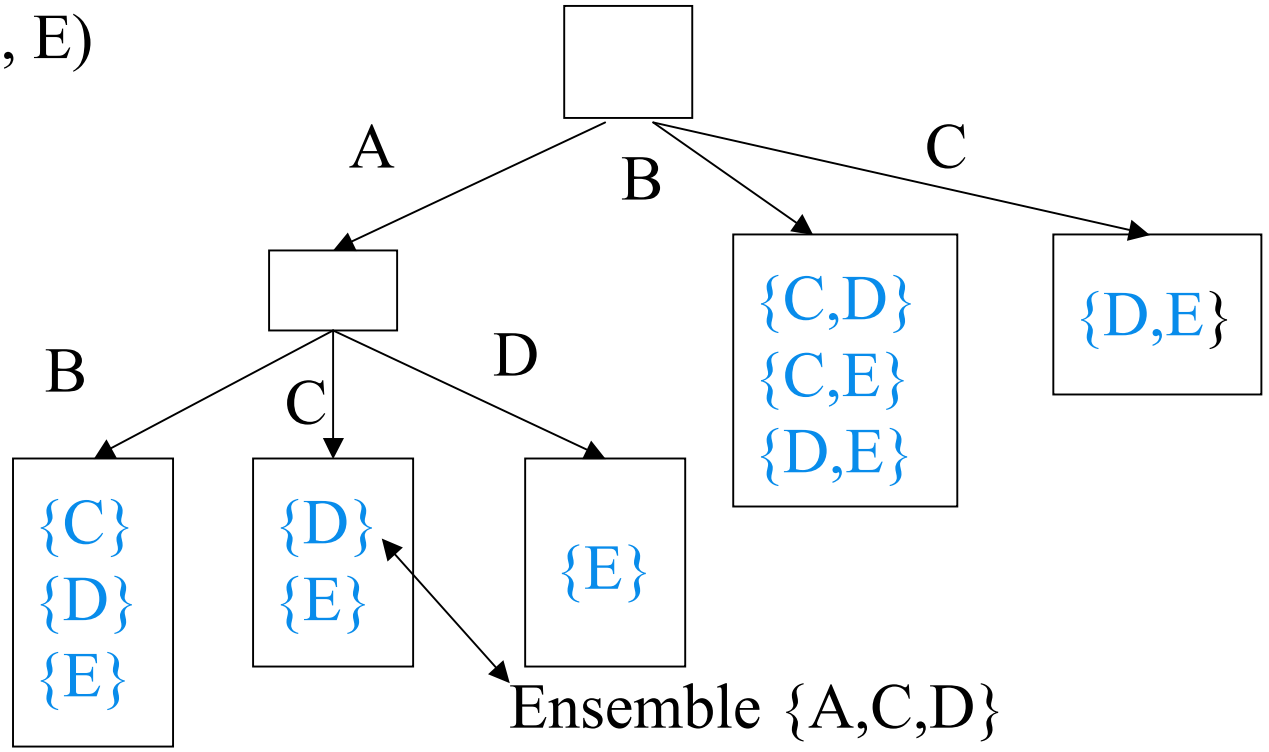

Comptage du support des candidats

- Parcourir la base. Pour chaque tuple extrait t, compter tous les candidats inclus dedans
  - Rechercher toutes les feuilles qui peuvent contenir les candidats
  - Hachage sur chaque item du tuple et descente dans l ’arbre des candidats
- Dans les feuilles de l’arbre vérifier ceux effectivement supportés par t
- Incrémenter leur support

Illustration

CID	Items
1	A B
2	A B C D E F
3	B D G
4	B E G
5	D F G
6	DEG
7	B E
8	B D E F

Support minimal = 1

Illustration

C1	Support
A	2
B	6
C	1
D	5
E	5
F	3
G	4

L1 = {{A},{B},{C},{D},{E},{F},{G}} 1-itemsets fréquents

Illustration

C2	Support	C2	Support
AB	2	CD	1
AC	1	CE	1
AD	1	CF	1
AE	1	**CG**	**0**
AF	1	DE	3
AG	**0**	DF	3
BC	1	DG	3
BD	3	EF	2
BE	4	EG	2
BF	2	FG	1
BG	2		

2-itemsets fréquents{{A,B},{A,C},{A,D},{A,E},{A,F},{B,C},{B,D},{B,E},
{B,F},{B,G}, {C,D},{C,E},{C,F},{D,E},{D,F},{D,G},{E,F},{E,G},{F,G}}

Illustration

C3	Support	C3	Support
ABC	1	BDE	2
ABD	1	BDF	2
ABE	1	BDG	1
ABF	1	BEF	2
ACD	1	BEG	1
ACE	1	**BFG**	**0**
…	…	…	…
BCF	1	**EFG**	**0**

L3 = {{A,B,C},{A,B,D},{A,B,E},{A,B,F},{A,C,D}, … {D,F,G}}

{B,C,G} élagué par Apriori-Gen car {C, G} n ’appartient pas à L2

Illustration

C4	Support	C4	Support
ABCD	1	ACEF	1
ABCE	1	ADEF	1
ABCF	1	BCDE	1
ABDE	1	BCDF	1
ABDF	1	BCEF	1
ABEF	1	BDEF	2
ACDE	1	**BDEG**	**0**
ACDF	1	CDEF	0

L4 = {{A,B,C,D},{A,B,C,E},{A,B,C,F}, … {C,D,E,F}}

{B,D,F,G}, {B,E,F,G} élagués car {B,F,G} n ’appartient pas à L3

{D,E,F,G} élagué car {E,F,G} n ’appartient pas à L3

Illustration

C6	Support
ABCDE F	1

6-itemsets fréquents L6 = {{A,B,C,D,E,F}}

C7 = {∅} => l 'algorithme se termine.

7 balayages pour déterminer tous les itemsets fréquents

Espace de recherche

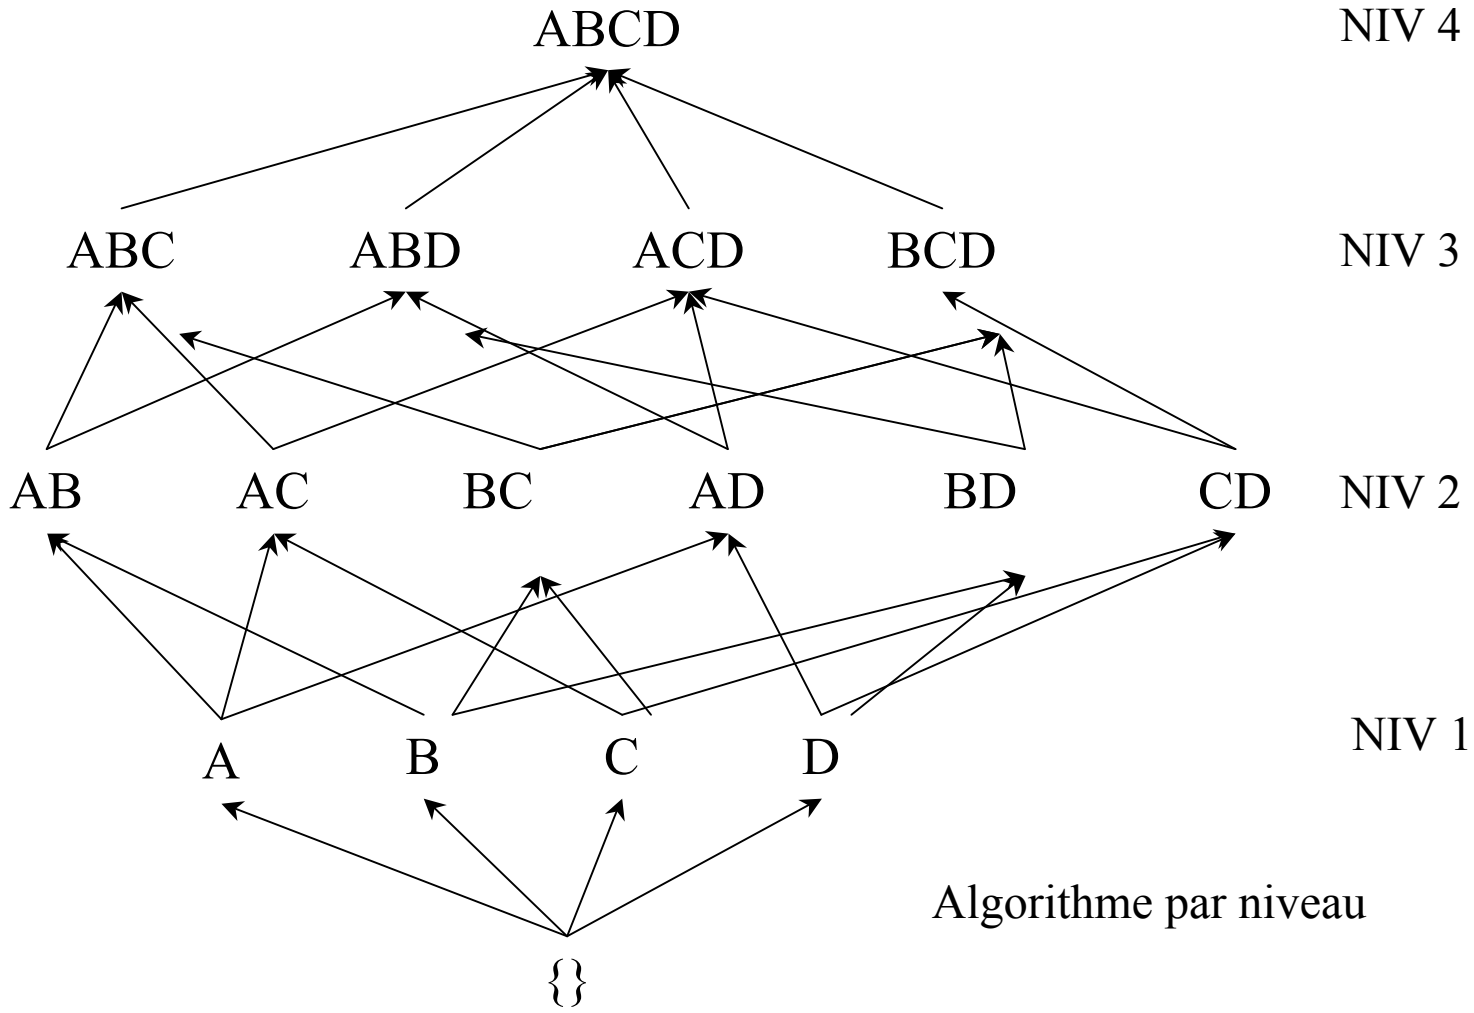

Algorithme par niveau

Partition

- But : Réduire le nombre de passes
- Principe :
  - partitionner la base de manière à ce que chaque partition tienne en mémoire centrale (utilisation d 'Apriori pour chaque partition)
  - 2 passes sur la base

Partition (cont.)

- Phase 1 : Division de la base
  - Traiter les partitions une par une : les itemsets fréquents sont fusionnés pour générer l ’ensemble de tous les itemsets fréquents potentiels
- Phase 2 : le support de ces itemsets est calculé

DIC (Dynamic Itemset Counting)

- But : réduction du nombre de balayage de la base
- Lecture par blocs de M transactions
- Essayer de générer le plus vite possible, i.e. à la fin de M, des (k+1)-itemsets pour les rechercher dans les prochaines M transactions

DIC (Cont.)

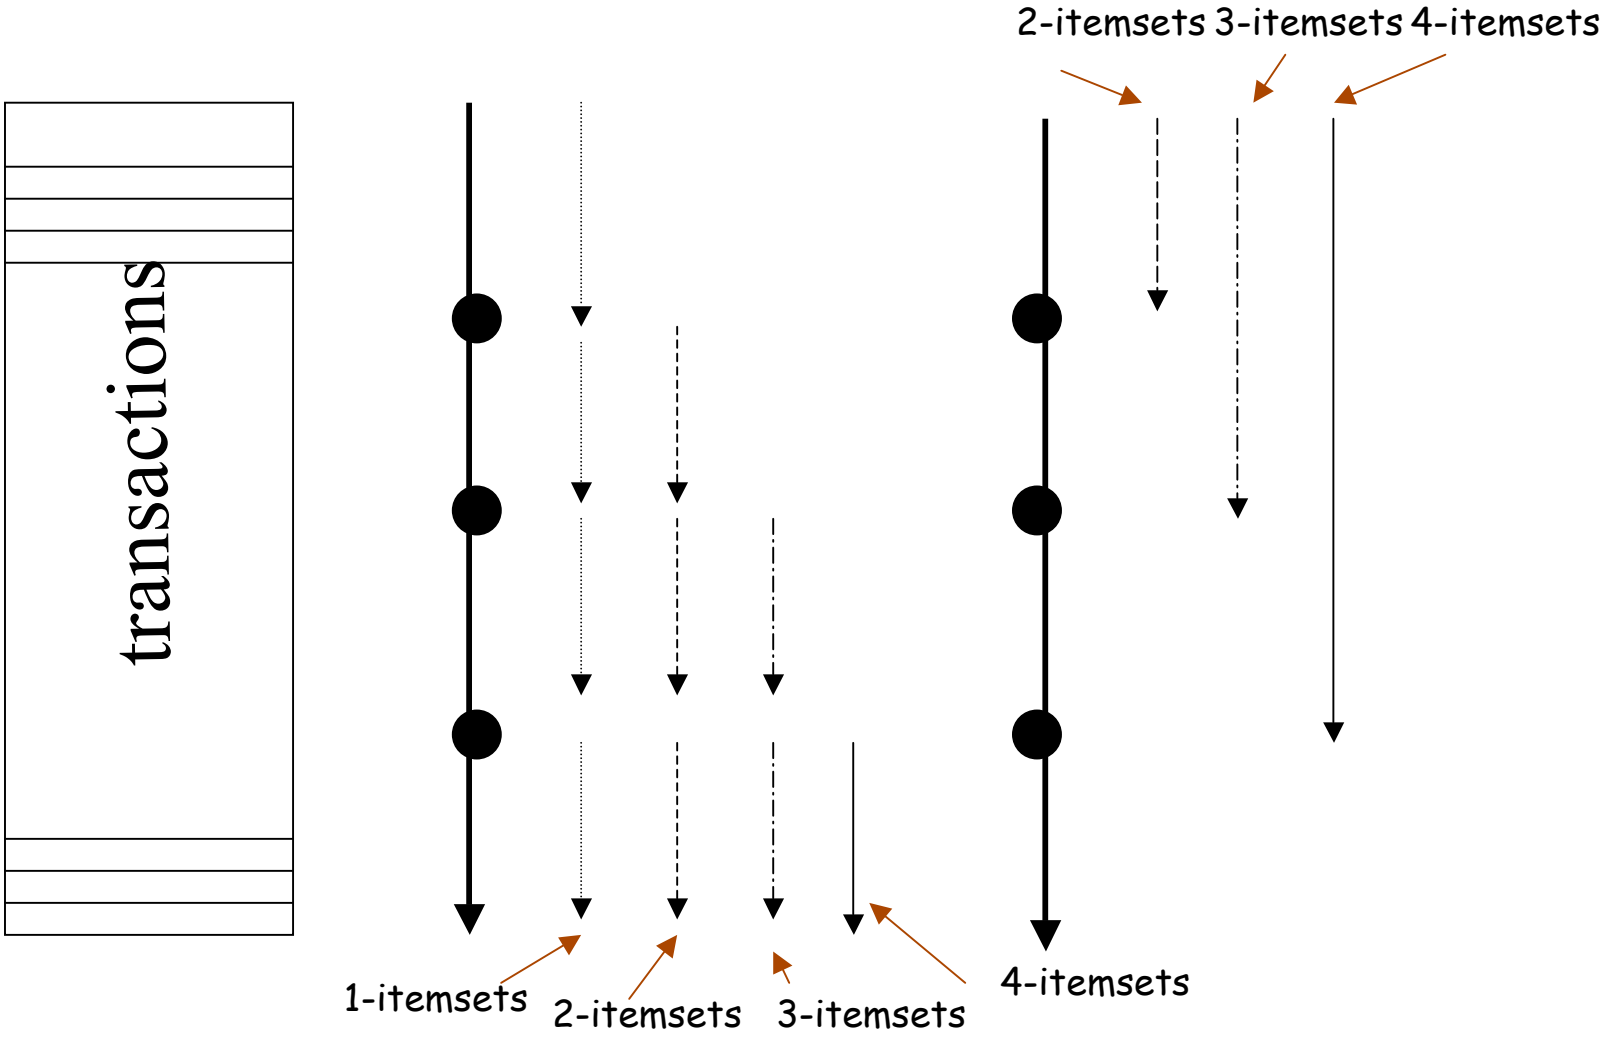
transactions
2-itemsets 3-itemsets 4-itemsets
1-itemsets
2-itemsets
3-itemsets
4-itemsets

Sampling

- Idée : prendre un ensemble aléatoire qui réside en mémoire centrale et rechercher tous les itemsets fréquents
- Très efficace : 1 passe, 2 passes au pire

- Basée sur la bordure négative

Bordure négative

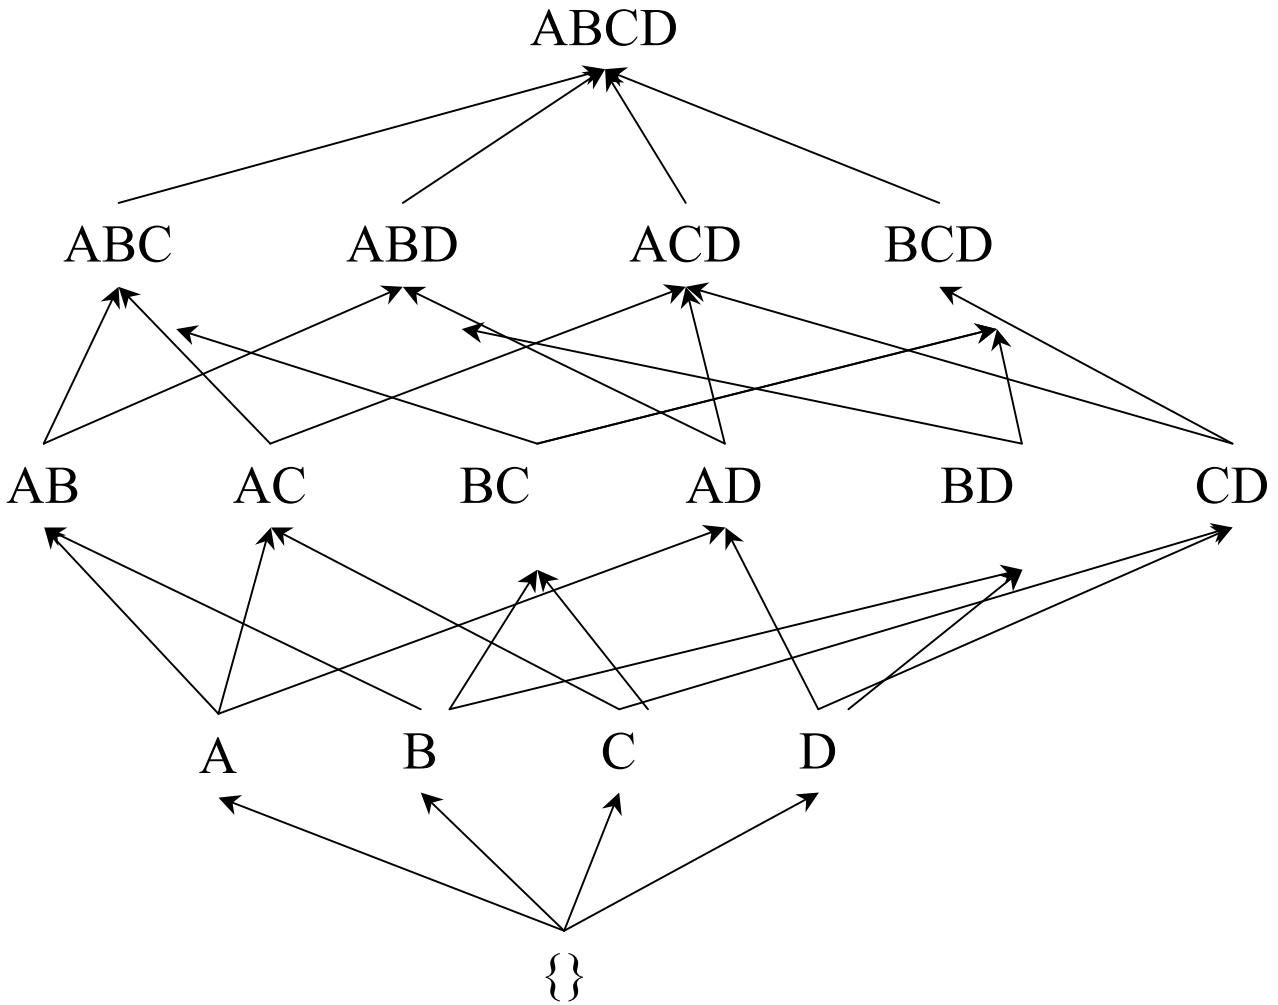

Bordure négative

minSupp = 2

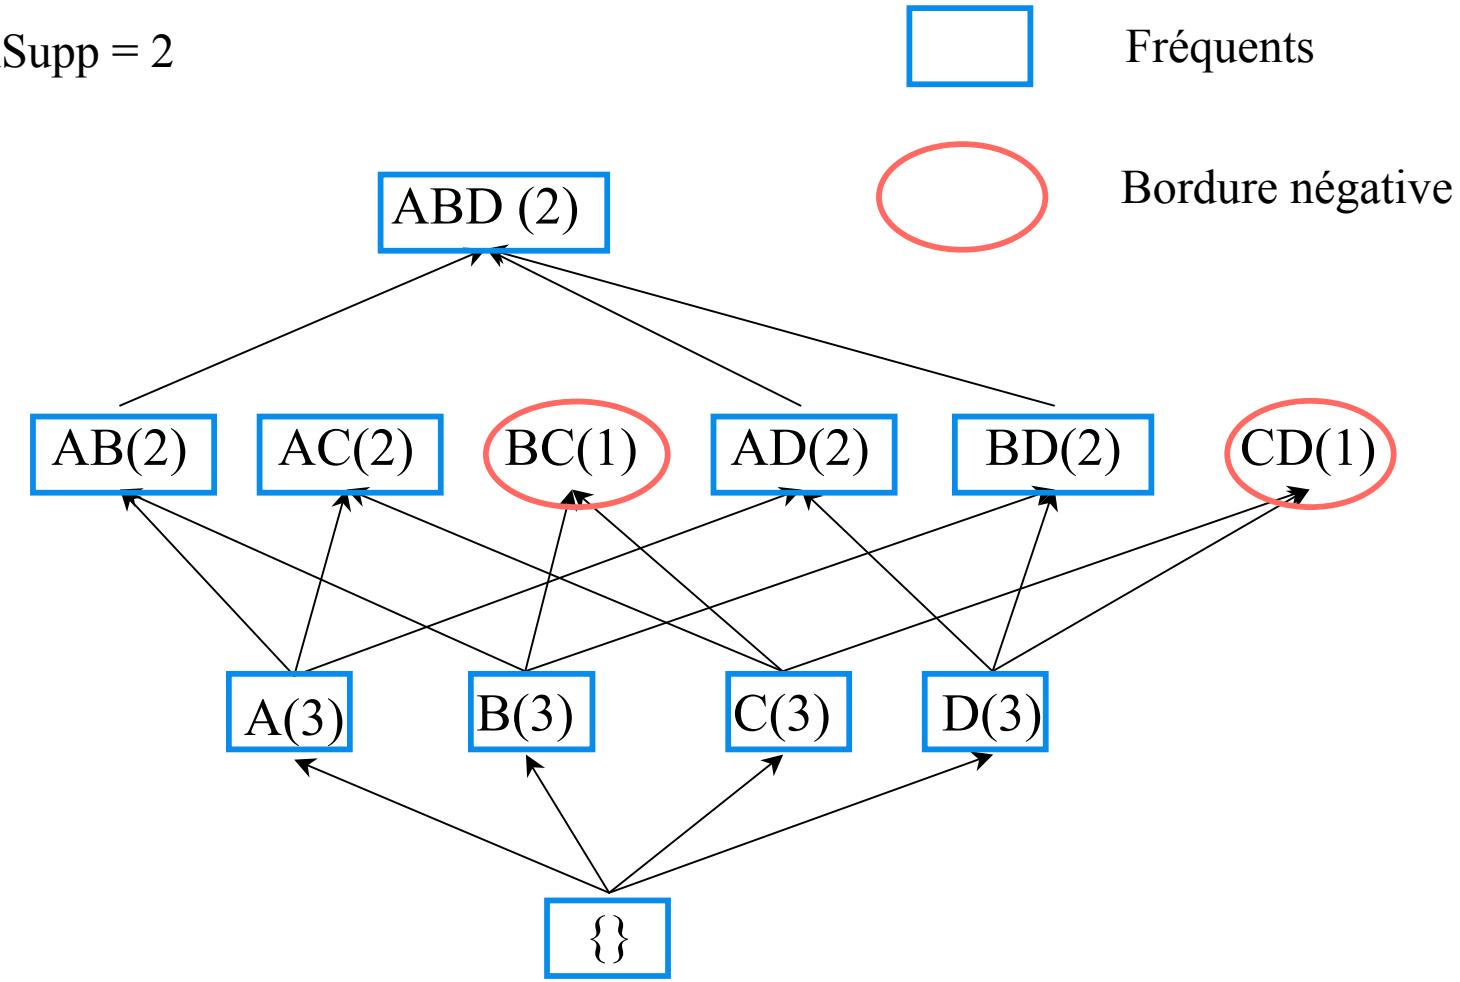

Sampling (cont.)

- Algorithme

  support minimum, petit support minimum, une base et un échantillon de la base

  1 - prendre un échantillon de la base

  2 - Calculer les fréquents avec petit support minimum en mémoire centrale : Fréquents et Bordure

  3 - Evaluer la fréquence des itemsets fréquents et de la bordure négative sur le reste de la base

  4 - Retourner le résultat et les éventuels manques

Sampling (cont.)

- D = 10 millions de tuples - A ... F - support minimum = 2% - Echantillon s de 20 000 tuples petit support minimum = 1,5%

  Pour l'échantillon avec 1,5% :
  F={{A,B,C},{A,C,F},{A,D},{B,D}}
  Bordure négative = BN={{B,F},{C,D},{D,F},{E}}

- Evaluer F et BD sur le reste de la base avec 2%

  1 - on trouve {A,B},{A,C,F} en une passe

  2 - si {B,F} devient fréquent sur D => manque peut être {A,B,F} => ***reporter l 'erreur et effectuer une seconde passe***

MaxMiner : Mining Max-patterns

- But : rechercher les longs itemsets fréquents
- Max-patterns : bordures de motifs fréquents
  - Un sous-ensemble d'un max-pattern est fréquent
  - Un sur-ensemble d'un max-pattern est non fréquent
- Parcours en largeur et en profondeur

MaxMiner : Mining Max-patterns (cont.)

- 1er passage: rechercher les items fréquents
  - A, B, C, D, E
- 2nd passage: rechercher les support pour
  - AB, AC, AD, AE, ABCDE
  - BC, BD, BE, BCDE
  - CD, CE, CDE, DE,
- Comme BCDE est un max-pattern, il n'est pas nécessaire de vérifier BCD, BDE, CDE dans les parcours suivants

Tid	Items
10	A,B,C,D,E
20	B,C,D,E,
30	A,C,D,F

minSupp=2

Génération des candidats

- Depuis 2000 « La base peut tenir en mémoire »
- Constat : génération d 'un trop grand nombre de candidats
  - s 'il y a 10^4 1-itemset => génération de 10^7 candidats 2-itemsets
  - Pour un fréquent de 100, il faut générer plus de 10^{30} candidats au total

- Est-il possible de proposer une méthode qui évite de générer des candidats ?

FP-Tree

1 - Parcours de la base pour rechercher les 1-fréquents

2 - Tri des fréquents dans l 'ordre décroissant

TID	Items	Items triés
1	I1, I2, I5	I2, I1, I5
2	I2, I4	I2, I4
3	I2, I3	I2, I3
4	I1, I2, I4	I2, I1, I4
5	I1, I3	I1, I3
6	I2, I3	I2, I3
7	I1, I3	I1, I3
8	I1, I2, I3, I5	I2, I1, I3, I5
9	I1, I2, I3	I2, I1, I3

L = [I2:7,
I1:6,
I3: 6,
I4 : 2,
I5 : 2]

FP-Tree (cont.)

Parcourir les transactions de la base

Création du FP-Tree :

« faire glisser les transactions dans l'arbre »

- Une branche existe : incrémenter le support
- Créer la branche autrement

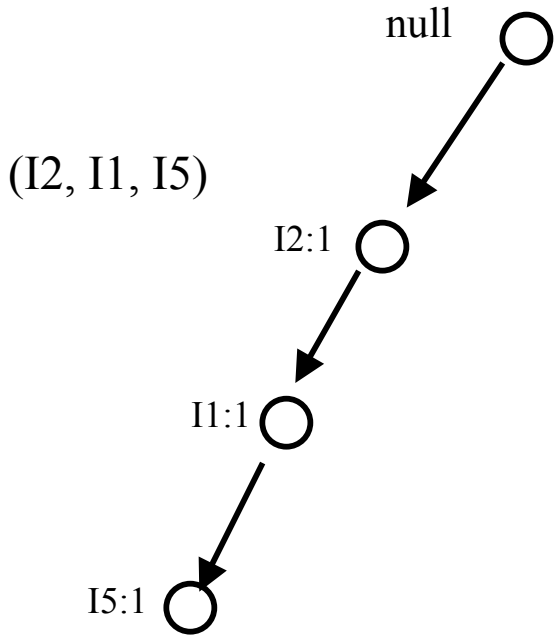

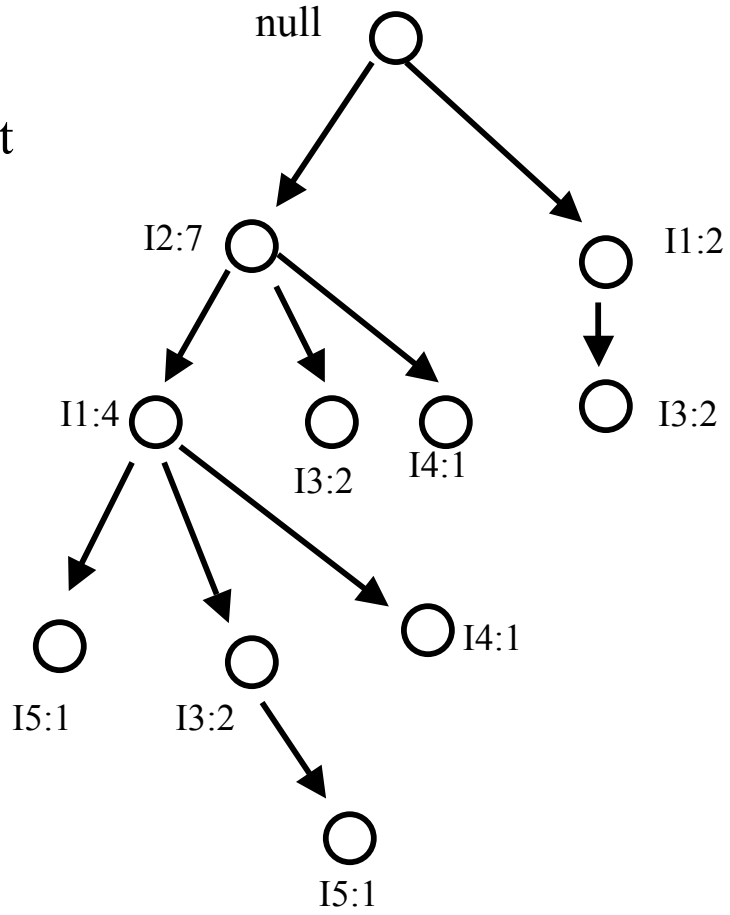

FP-Tree (cont.)

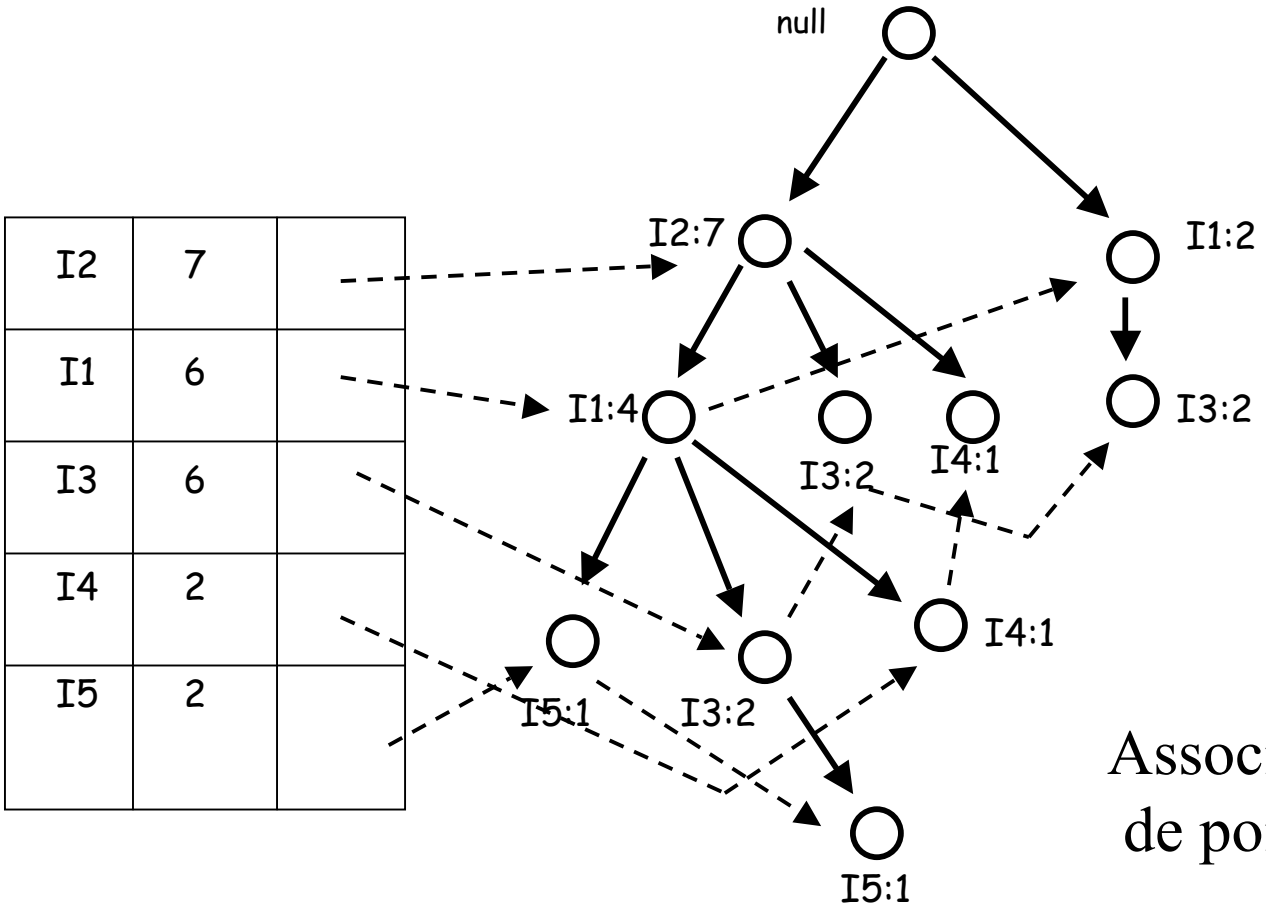

Association d'un tableau de pointeurs trié

FP-Tree (cont.)

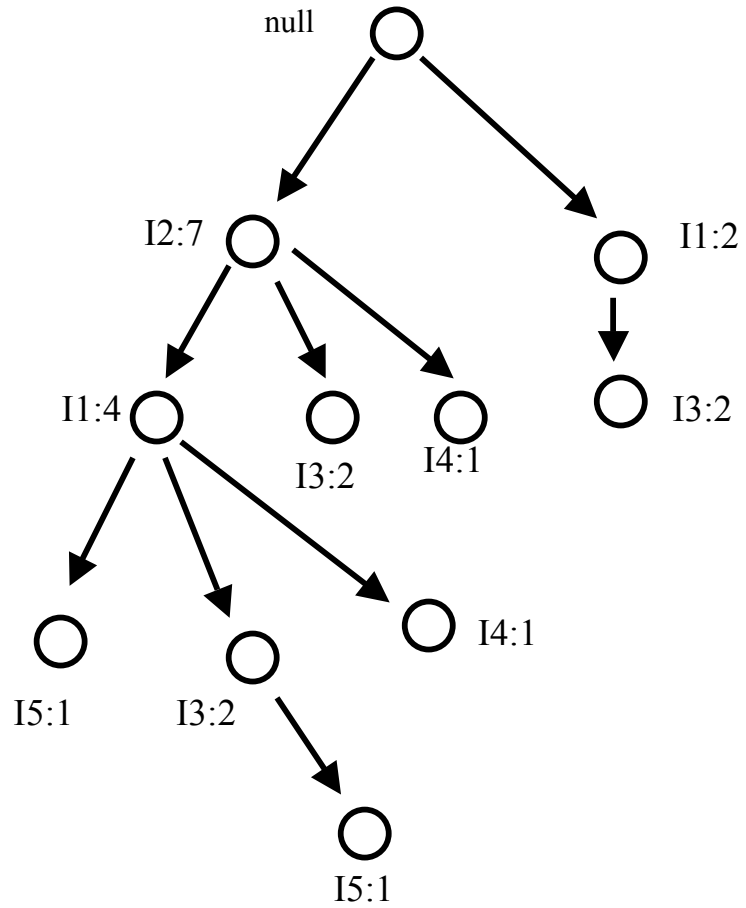

On commence par ceux dont le support est le plus faible

Pour I5

chemins pour I5 <I2 I1 I5:1> et <I2 I1 I3 I5:1>

en considérant I5 comme suffixe on a :

<I2 I1 : 1>

<I2 I1 I3 : 1>

=> <I2 : 2, I1 : 2> (support I3 = 1)

Génération : I2 I5 : 2 I1 I5 : 2 I2 I1 I5 : 2

Pour I4

Avec I4 comme suffixe

<I2 I1 : 1> et <I2 : 1> => fréquent I2 I4 : 2

Pour I3

Avec I3 comme suffixe

<I2 I1 : 2>, <I2 : 2>, <I1 : 2>

=> fréquents : I2 I3 : 4 I1 I3 : 2 I2 I1 I3 : 2

...

Bénéfices de FP-tree

- Préserve l'information complète pour l'extraction d'itemsets
  - Pas de passage supplémentaire sur la base
- Approche Compacte
  - Les items sont triés dans un ordre décroissant de fréquence : plus ils apparaissent fréquemment plus ils seront partagés
  - Ne peut jamais être plus grand que la base d'origine (sans compter les liens, les nœuds et les compteurs)

Cas des données corrélées

$$M = \begin{bmatrix} 1 & 1 & 0 & 1 & 1 \\ 0 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 0 & 1 & 1 & 1 & 1 \\ 1 & 0 & 1 & 1 & 1 \end{bmatrix}$$

- D'autres types d'algorithmes
  - Utilisation du treillis et de ses propriétés
  - Recherche des itemsets fermés fréquents (les itemsets maximaux pour lesquels il n'existe pas de super ensemble avec la même valeur de support)
  - Recherche des générateurs
  - Recherche de représentation condensée (clos, libres, dérivables)
- Close, Close+, Charm …

Quelques conclusions

- De nombreux travaux
  - De nouvelles approches condensées
  - De nouvelles contraintes (réduire l'espace de recherche)
  - Préservation de la vie privée
  - Approches Incrémentales
  - Règles plus générales
  - Définir de nouvelles mesures (lift, implication, …)

Règles d'association incrémentales

- Générer les règles dans une base dynamique
- Problème : les algorithmes considèrent des bases statiques
- Objectifs :
  - Chercher les itemsets fréquents dans D
  - Chercher les itemsets fréquents dans $D \cup \{\Delta D\}$
- Doit être fréquent dans D ou Δ D
- Sauvegarder tous les fréquents, la bordure
- … Data Streams (Flots de Données)

Des règles plus générales

- Les règles négatives

  Expr(Ci) → Expr(Cj) avec AND, OR, NOT

- Les règles sur plusieurs dimensions
- Les règles à attributs variables

  Age ∈[x,y] => Salaire > 45 K€ (5%; 30%)

- Les règles approximatives
- Les règles avec généralisation

  Associée à une taxonomie

Utilité des règles

- La règle utile contenant des informations de qualité qui peuvent être mises en pratique

  ex : *le samedi, les clients des épiceries achètent en même temps de la bière et des couches*

- Résultats connus par quiconque

  ex : *les client des épiceries achètent en même temps du pain et du beurre*

- Résultats inexplicables difficiles à situer et donc à expliquer

  ex : *lors de l'ouverture d'une quincaillerie, parmi les articles les plus vendus on trouve les abattants de toilette*

D'autres mesures

Articles	A	B	C	A, B	A, C	B, C	A, B, C
Fréquences (%)	45	42,5	40	25	20	15	5

- Si on considère les règles à trois articles, elles ont le même support 5%. Le niveau de confiance est alors :

Règle	Confiance
A, B → C	0,20
A, C → B	0,25
B,C → A	0,33

- La règle « B, C → A » possède la plus grande confiance. si B et C apparaissent simultanément dans un achat alors A y apparaît aussi avec une probabilité estimée de 33%.

D’autres mesures (cont.)

Articles	A	B	C	A, B	A, C	B, C	A, B, C
Fréquences (%)	**45**	42,5	40	25	20	15	5

- A apparaît dans 45% des achats. Il vaut donc mieux prédire A sans autre information que de prédire A lorsque B et C apparaissent.
- l'*amélioration* permet de comparer le résultat de la prédiction en utilisant la fréquence du résultat

$$Amélioration = confiance / frequence(résultat)$$

D’autres mesures (cont.)

- Une règle est intéressante lorsque l'amélioration est supérieure à 1. Pour les règles choisies, on trouve :

Règle	Confiance	Freq(résultat)	Amélioration
A, B→ C	0.20	40%	0.50
A,C → B	0.25	42.5%	0.59
B,C → A	0.33	45%	0.74

- Par contre, la règle si « A → B » possède un support de 25%, une confiance de 0.55 et une amélioration de 1.31, cette règle est donc la meilleure.
- En règle générale, la meilleure règle est celle qui contient le moins d'articles.

Visualisation

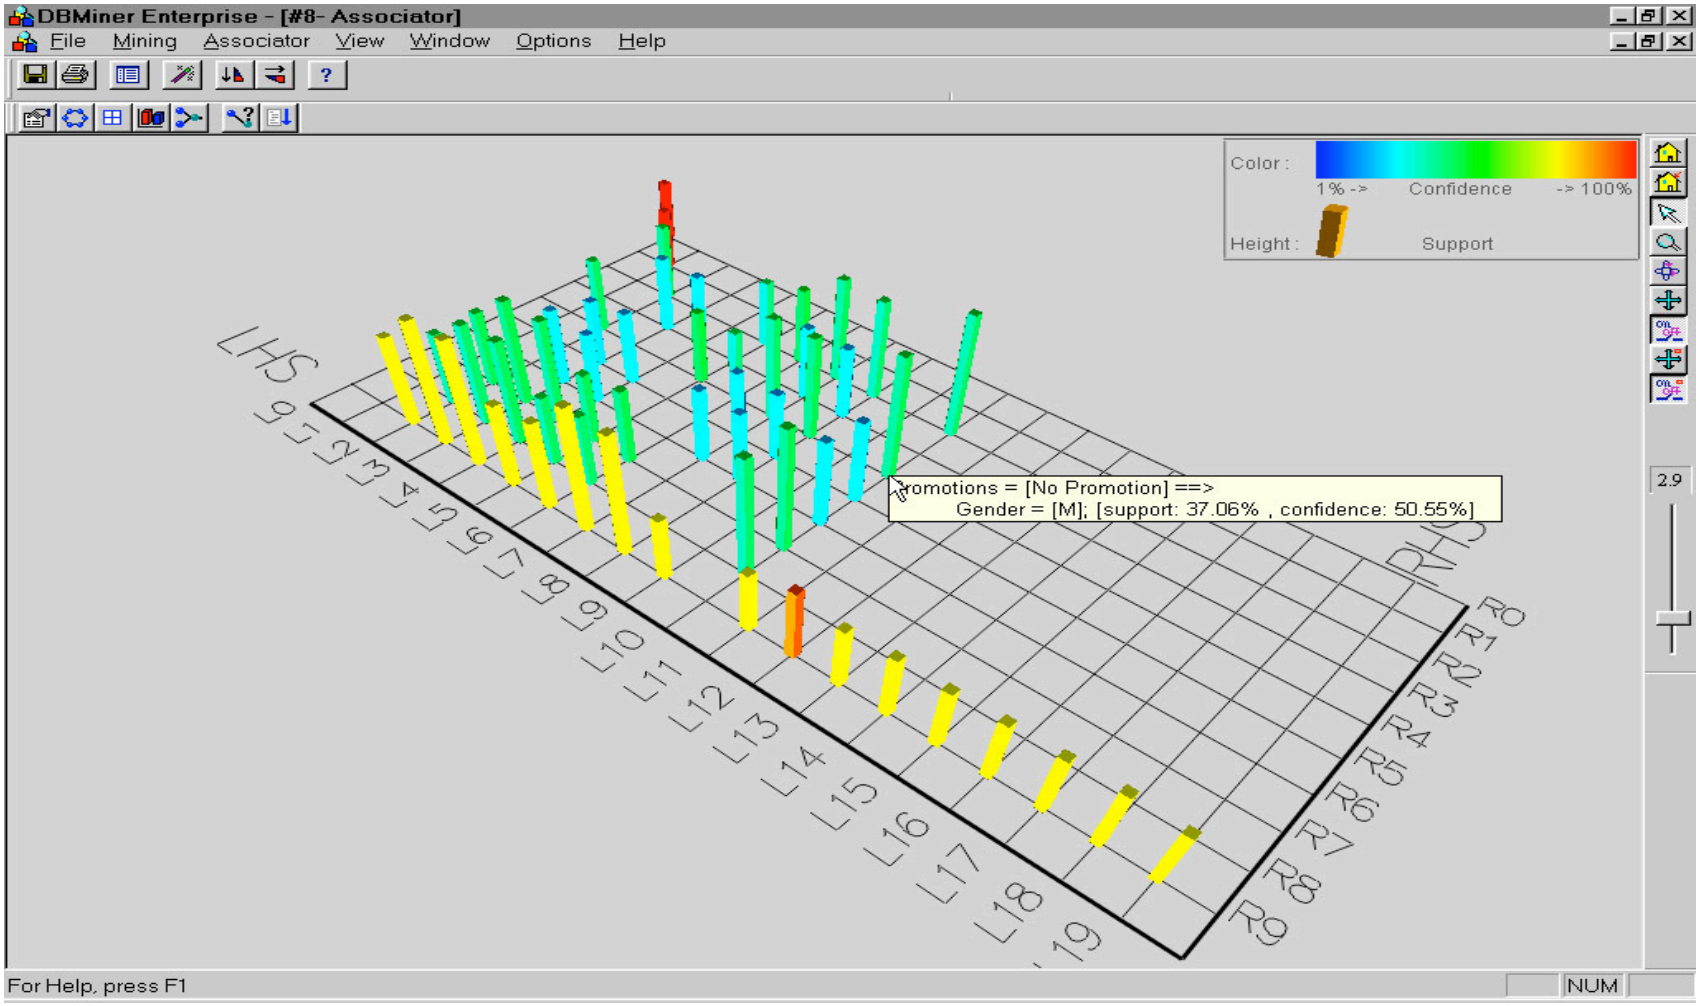

DBMiner (www.dbminer.com)

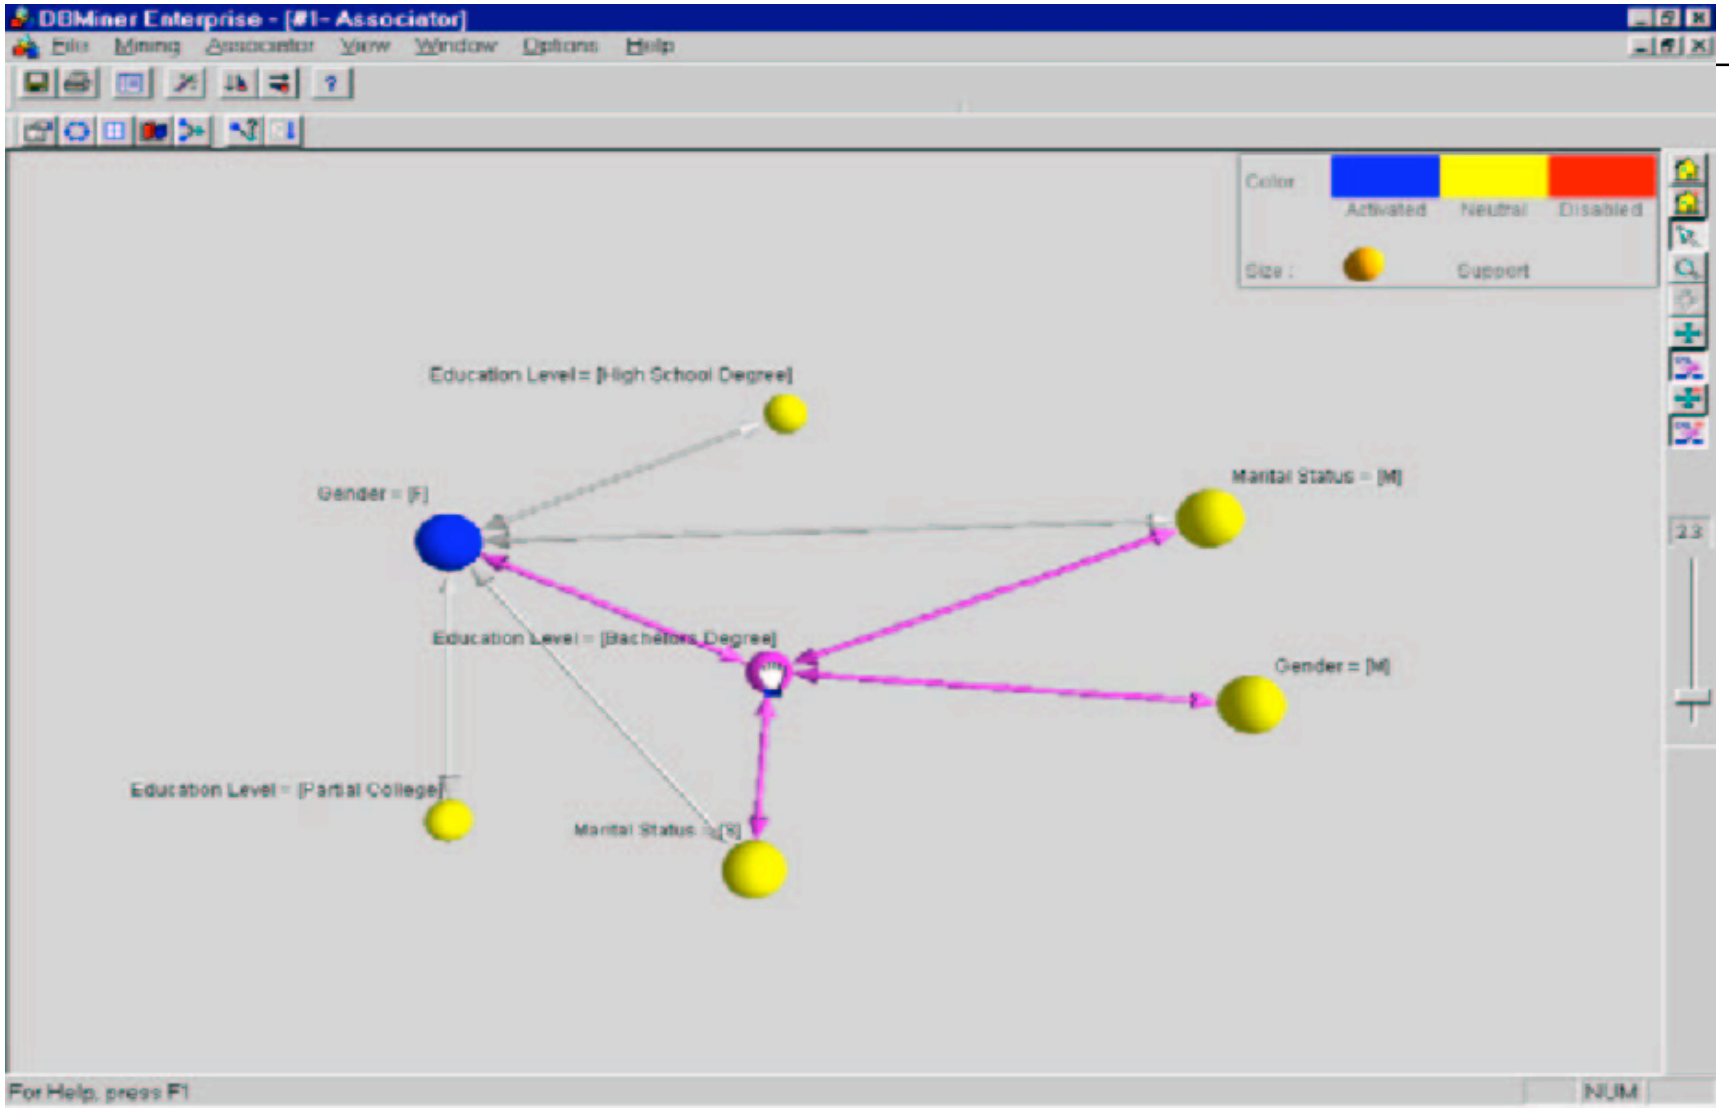

DBMiner (www.dbminer.com)

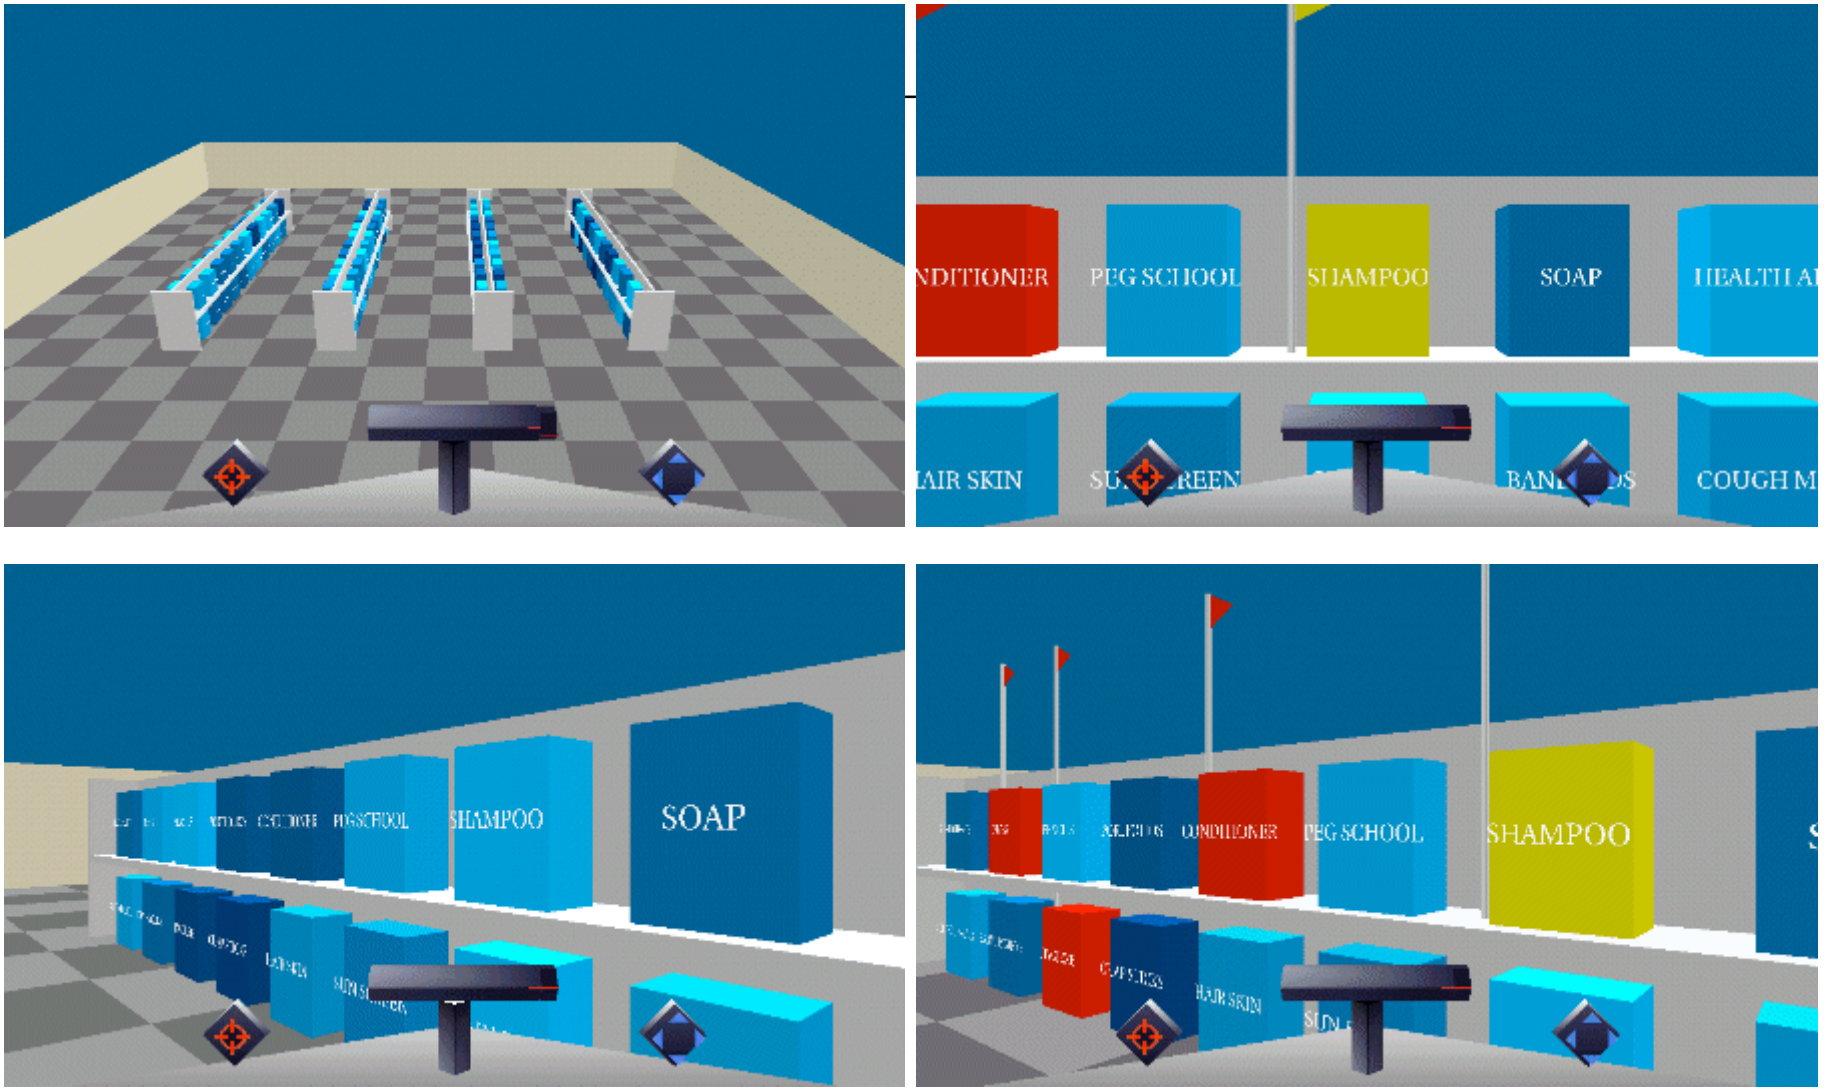

Intelligent Miner (www.ibm.com)

Plan

- Contexte général
- Règles d'association
- Motifs séquentiels
- Applications : Web Mining, Text Mining
- Conclusions

Pourquoi la recherche de séquence ?

- Un important domaine de recherche pour le data mining avec de très nombreuses applications
  - Analyse des achats des clients
  - Analyse de puces ADN
  - Processus
  - Conséquences de catastrophes naturelles
  - Web mining
  - Détection de tendances dans des données textuelles

Recherche de Motifs Séquentiels

- Même problématique mais avec le temps
- Item : « un article »
- Transaction : un client + un itemset + une estampille temporelle $T = [C, (a,b,c)_5]$
- Séquence : liste ordonnée d'itemsets
- Séquence de données : « activité du client »

  Soit T_1, T_2, … T_n, les transactions du client C, la séquence de données de C est :

  $[C, <itemset(T_1)\ itemset(T_2)\ \ldots.\ itemset(T_n)>]$

Recherche de Motifs Séquentiels

- Support minimal : nombre minimum d'occurrences d'un motif séquentiel pour être considéré comme fréquent

- Attention l'occurrence n'est prise en compte qu'une fois dans la séquence

Support (20) dans <(10) (20 30) (40) (20)>=1

Inclusion

- Inclusion : Soient $S_1 = <a_1\ a_2\ \ldots\ a_n>$ et $S_2 = <b_1\ b_2\ \ldots\ b_n>$ $S_1 \subseteq S_2$ ssi

  $i_1 < i_2 < \ldots < i_n$ / $a_1 \subseteq b_{i1}, \ldots. a_n \subseteq b_{in}$

- S1 = <(10) (20 30) (40) (20)>

  S2 = <(20) (40)> $\subseteq$ S1

  S3 = <(20) (30)> n'est pas incluse dans S1

Problématique

- Soit D une base de données de transactions de clients. Soit σ une valeur de support minimal

  Rechercher toutes les séquences S telles que :

  support(S) ≥σ dans D

- 50% des personnes qui achètent du vin et du fromage le lundi achètent aussi du pain le vendredi

  <(French wine, cheese) (bread)>

Illustration

Clients	Date1	Date2	Date3	Date4
C1	10 20 30	20 40 50	10 20 60	10 40
C2	10 20 30	10 20 30		20 30 60
C3	20 30 50		10 40 60	10 20 30
C4	10 30 60	20 40	10 20 60	50

Support = 60% (3 clients) => <(10 30) (20) (20 60)>

Itemsets :Espace de recherche

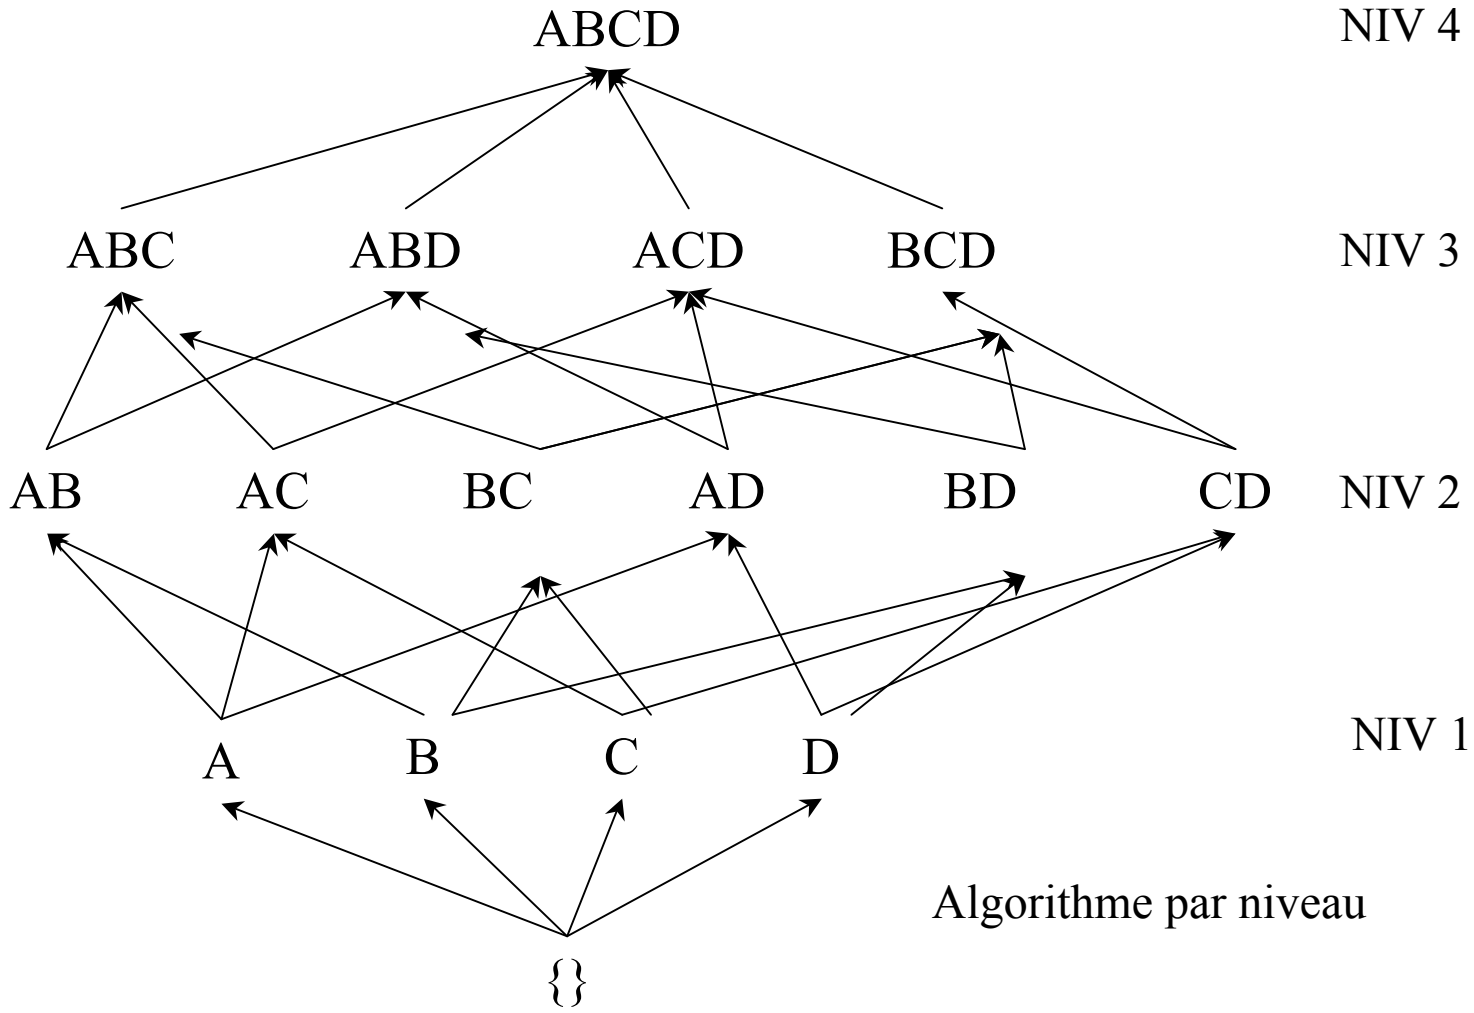

Algorithme par niveau

Motifs Séquentiels : l'espace de recherche

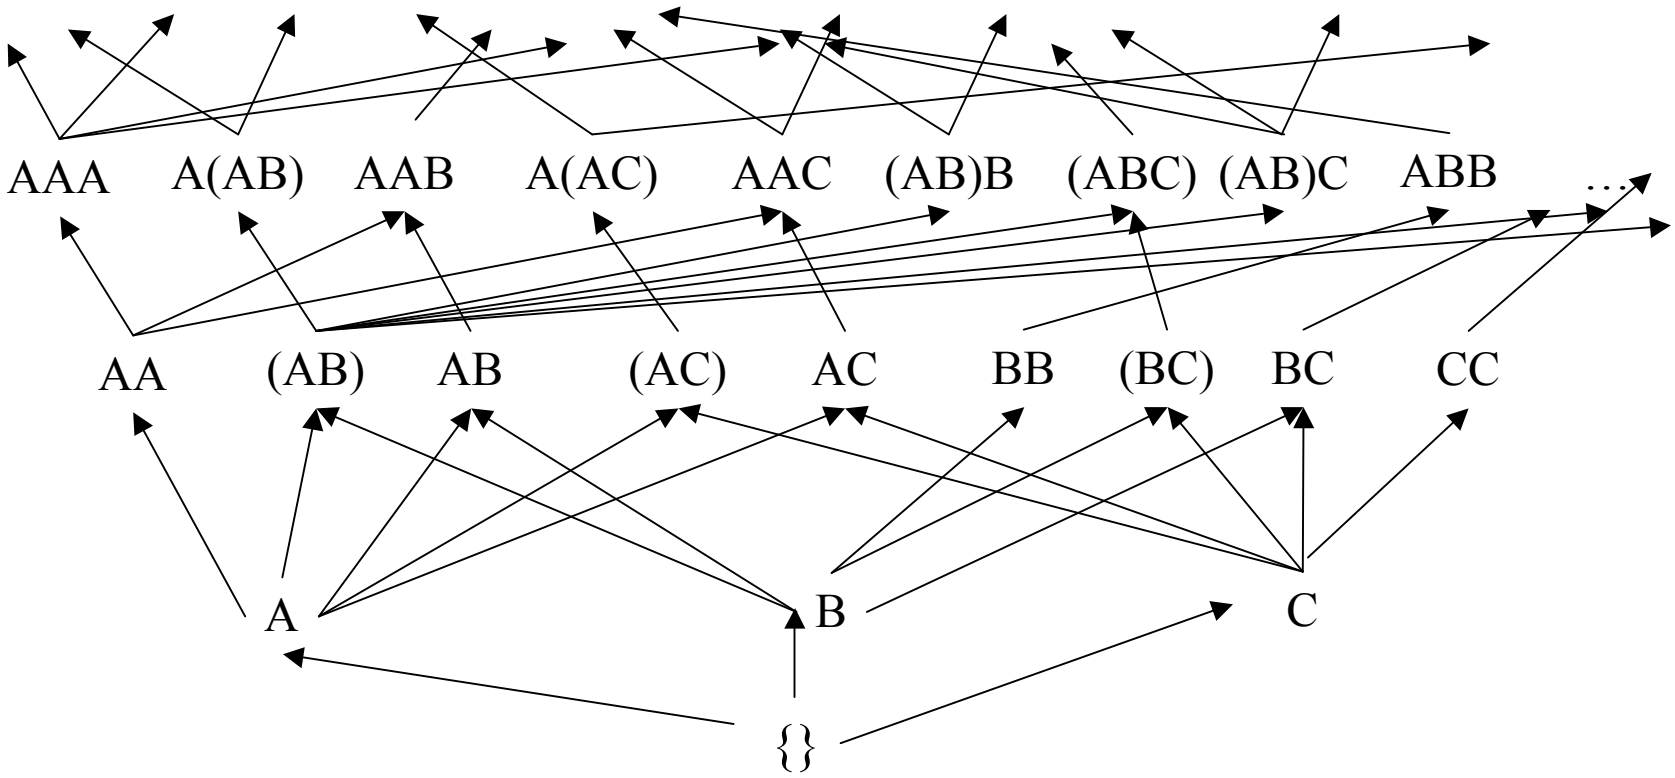

La propriété d'antimonotonie

- Une propriété essentielle (c.f. Apriori [AIS93])
  - Si une séquence n'est pas fréquente, aucune des super-séquences de S n'est fréquente!

Support (<(10) (20 30)>) < minsupp

Support (<(10) (20 30) (40)>)<< minsupp

Vers un algorithme générique

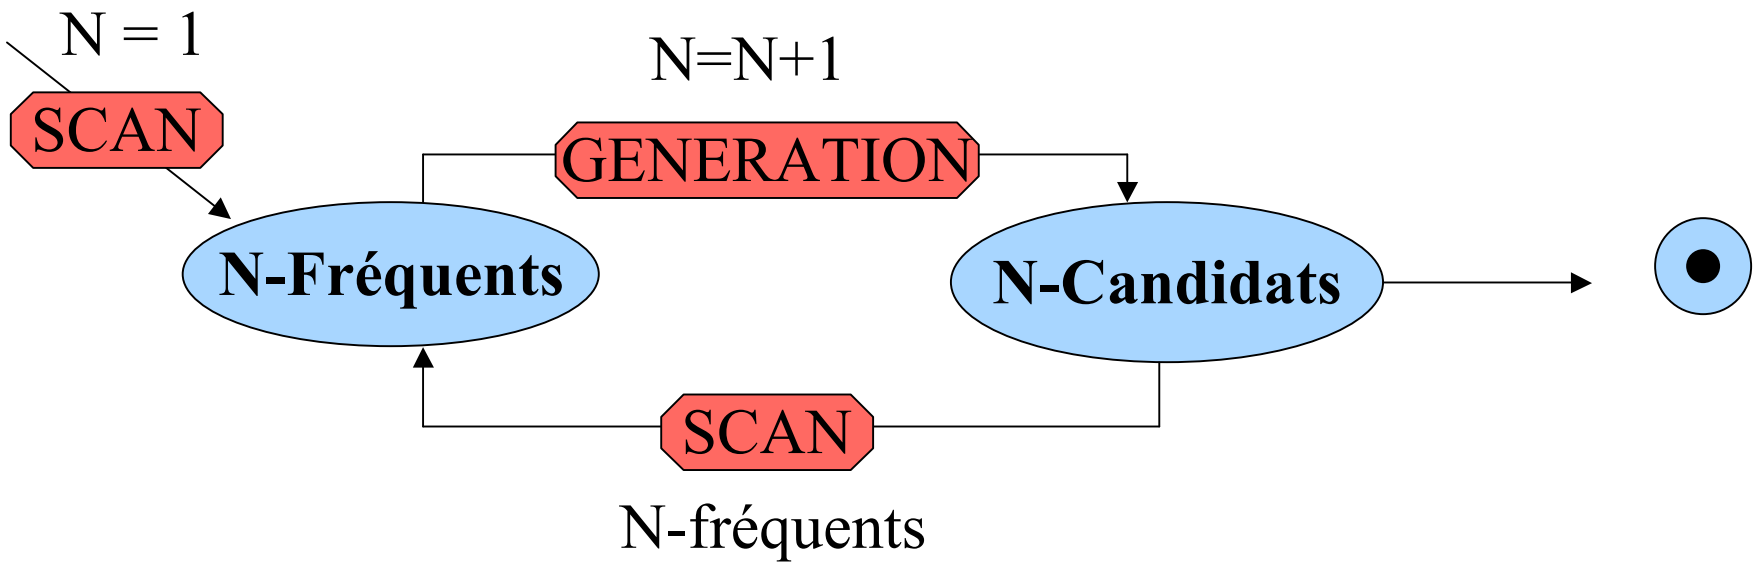

Génération des candidats

- S-Extension : ajout d'une séquence
- I-Extension : ajout d'un itemset

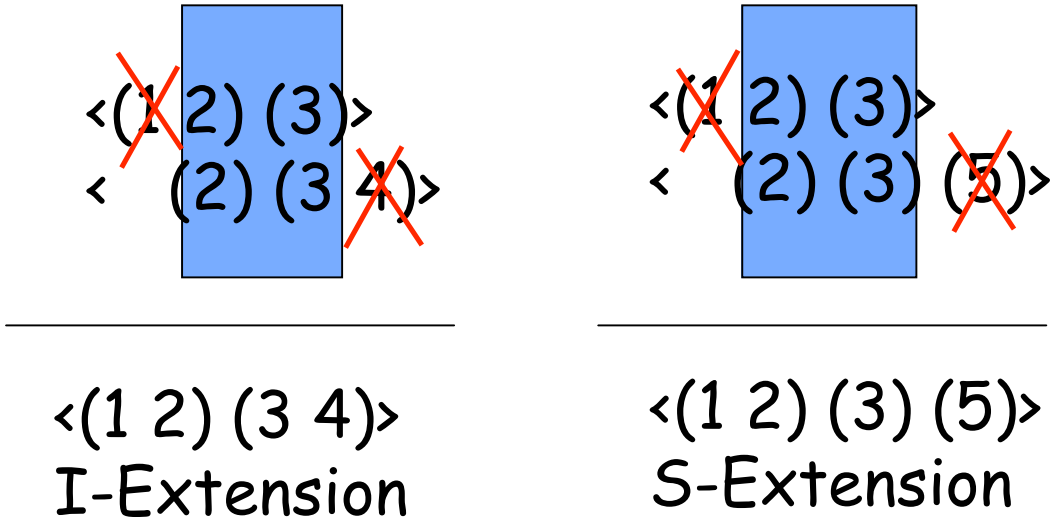

GSP

- A la APRIORI [Srikant, Agrawal, EDBT'96]

L=1

While ($Result_L$!= NULL)

    Candidate Generate

    Prune

    Test

    L=L+1

Recherche des séquences de taille 1

- Candidats initiaux : toutes les séquences réduites à un item
  - <a>, <b>, <c>, <d>, <e>, <f>, <g>, <h>
- Un passage sur la base pour compter le support des candidats

Seq. ID	Séquence
10	<(bd)cb(ac)>
20	<(bf)(ce)b(fg)>
30	<(ah)(bf)abf>
40	<(be)(ce)d>
50	<a(bd)bcb(ade)>

minSupp =2

Cand	Sup
<a>	**3**
<b>	**5**
<c>	**4**
<d>	**3**
<e>	**3**
<f>	**2**
~~<g>~~	1
~~<h>~~	1

Le Processus

5th scan : 1 candidate
1 length-5 seq pattern

<(bd)cba>

4th scan : 8 candidates
6 length-4 seq pat

<abba> <(bd)bc> …

3rd scan : 46 candidates
19 length-3 seq pat.

<abb> <aab> <aba> <baa> <bab> …

2nd scan : 51 candidates
19 length-2 seq pat.

<aa> <ab> … <af> <ba> <bb> … <ff> <(ab)> … <(ef)>

1st scan : 8 candidates
6 length-1 seq pattern

<a> <b> <c> <d> <e> <f> <g> <h>

Génération des candidats de taille 2

S-Extension

	<a>	<b>	<c>	<d>	<e>	<f>
<a>	<aa>	<ab>	<ac>	<ad>	<ae>	<af>
<b>	<ba>	<bb>	<bc>	<bd>	<be>	<bf>
<c>	<ca>	<cb>	<cc>	<cd>	<ce>	<cf>
<d>	<da>	<db>	<dc>	<dd>	<de>	<df>
<e>	<ea>	<eb>	<ec>	<ed>	<ee>	<ef>
<f>	<fa>	<fb>	<fc>	<fd>	<fe>	<ff>

51 2-Candidats

I-Extension

	<a>	<b>	<c>	<d>	<e>	<f>
<a>		<(ab)>	<(ac)>	<(ad)>	<(ae)>	<(af)>
<b>			<(bc)>	<(bd)>	<(be)>	<(bf)>
<c>				<(cd)>	<(ce)>	<(cf)>
<d>					<(de)>	<(df)>
<e>						<(ef)>
<f>						

Sans la propriété d'anti-monotonie
8*8+8*7/2=92 candidats

Comptage des supports des candidats

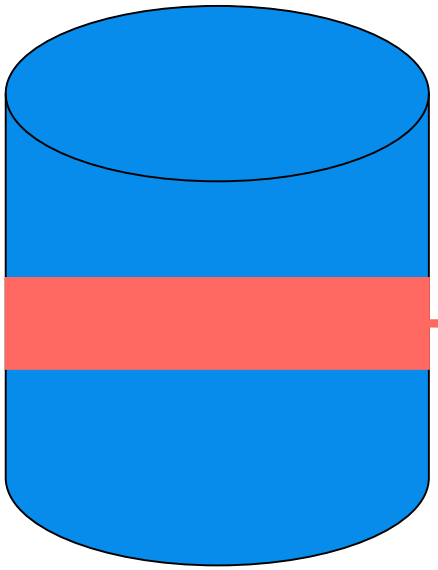

Un tuple
T={cid, <(a) (bc) (d)>}

BASE DE DONNEES

Candidats
Stockés en
Mémoire centrale

C1 C1 ⊆ T ?
C2 C2 ⊆ T ?
C3 C3 ⊆ T ?
C4 C4 ⊆ T ?
C5 C5 ⊆ T ?

Cn Cn ⊆ T ?

MEMOIRE CENTRALE

Stockage des candidats

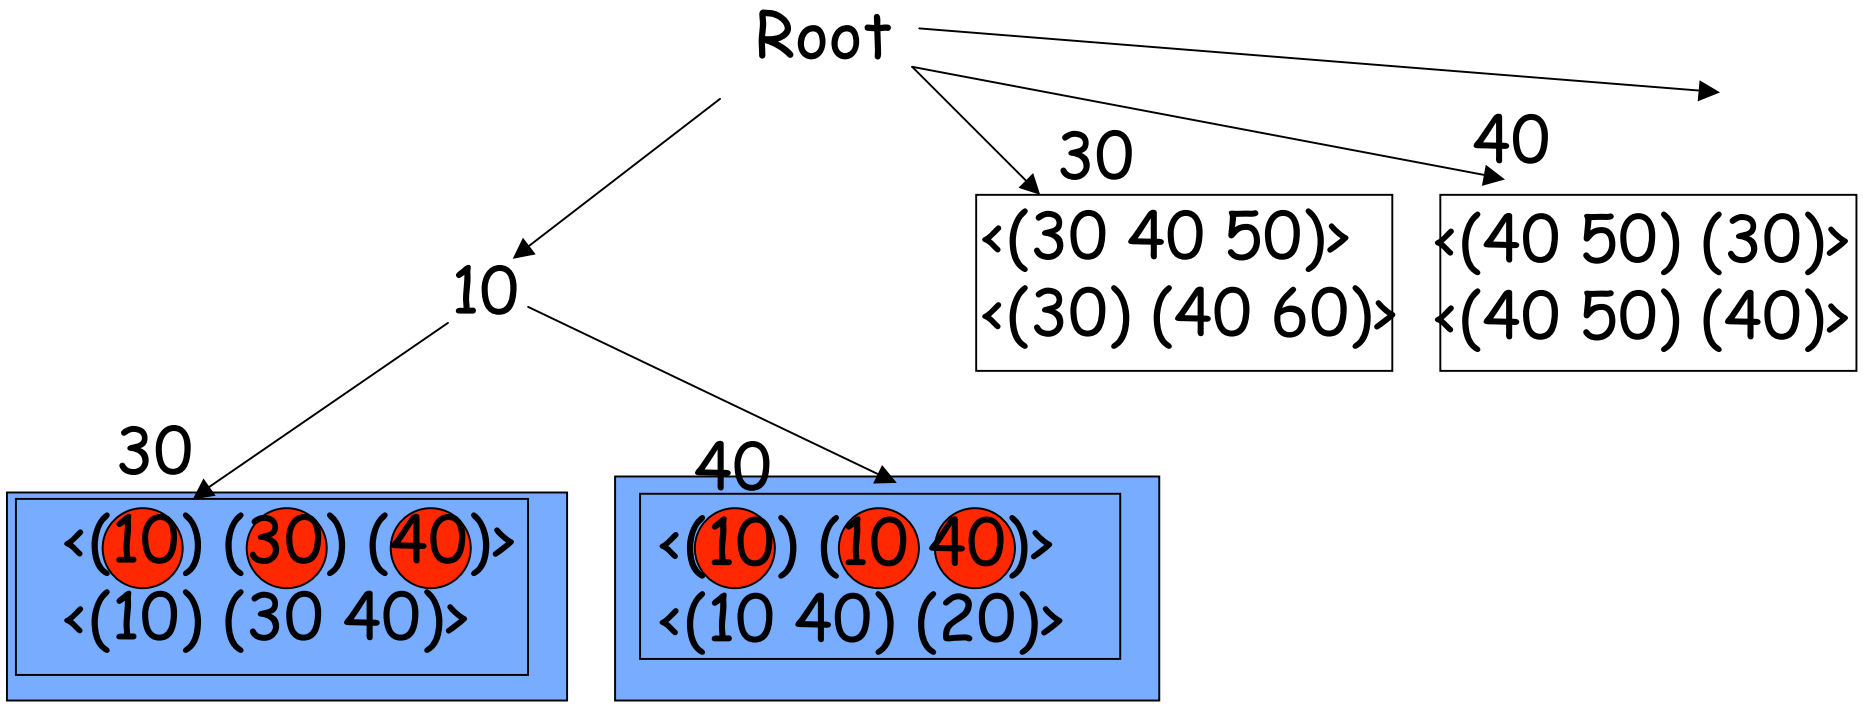

S = <(10) (30) (10 40)>

PSP (Prefix Tree for Sequential Patterns)

- Vers une structure plus efficace : prefix tree

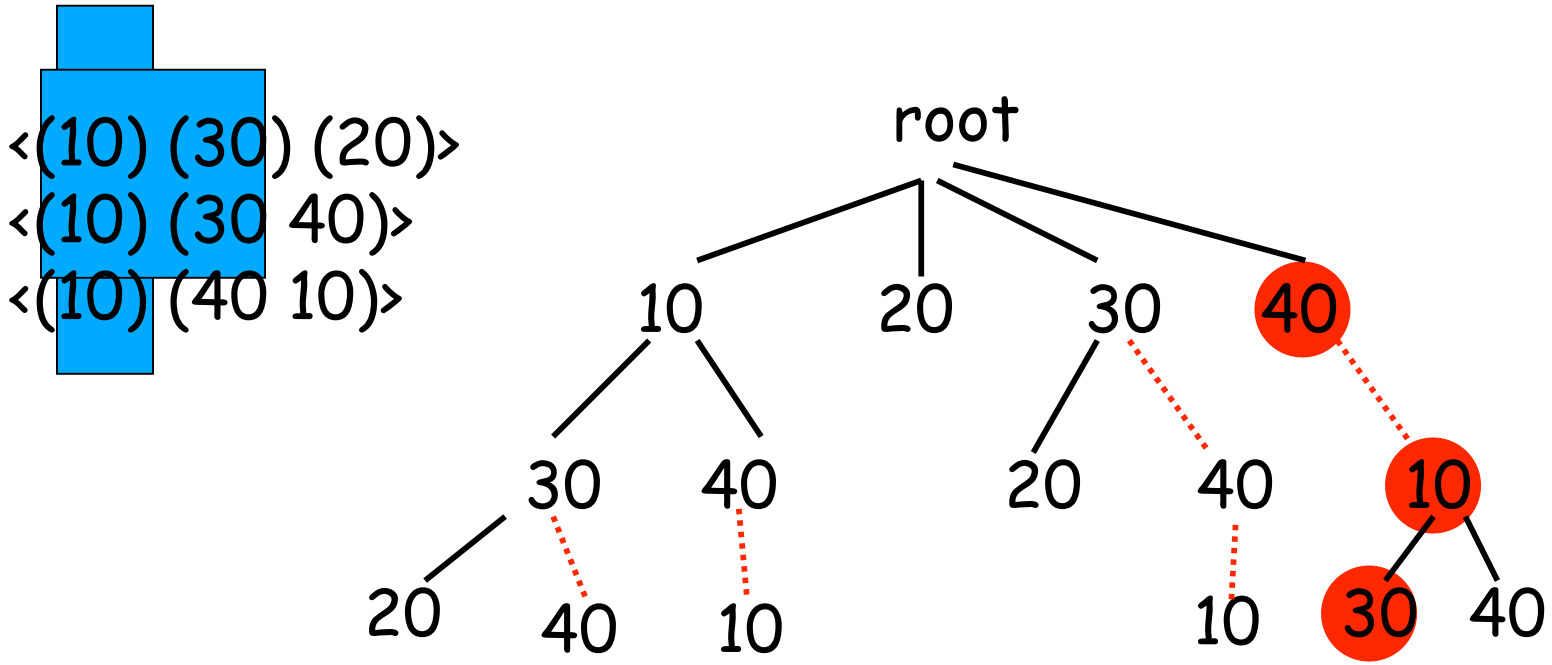

<(30 50 40 10) (30) (20 10)>

PSP (cont.)

- Génération des candidats de taille 2

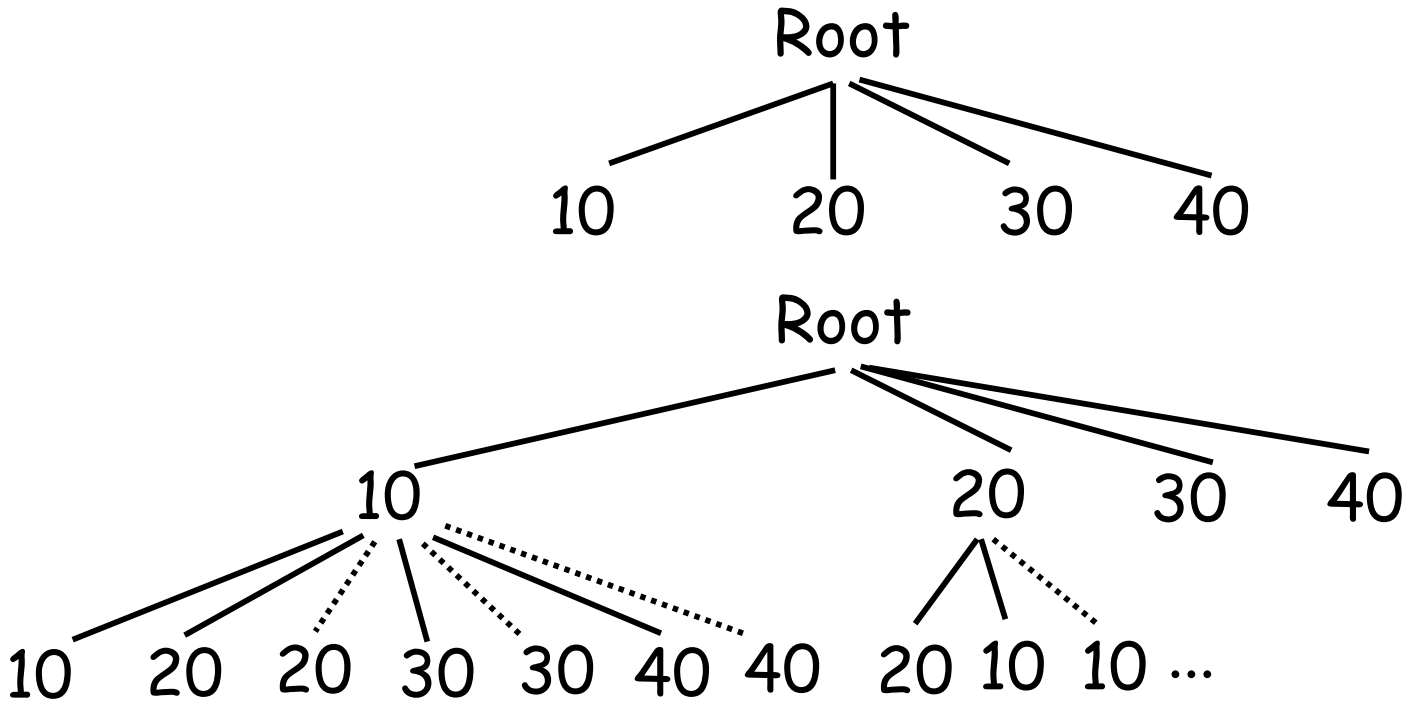

PSP (cont.)

- Génération des candidats de taille > 2

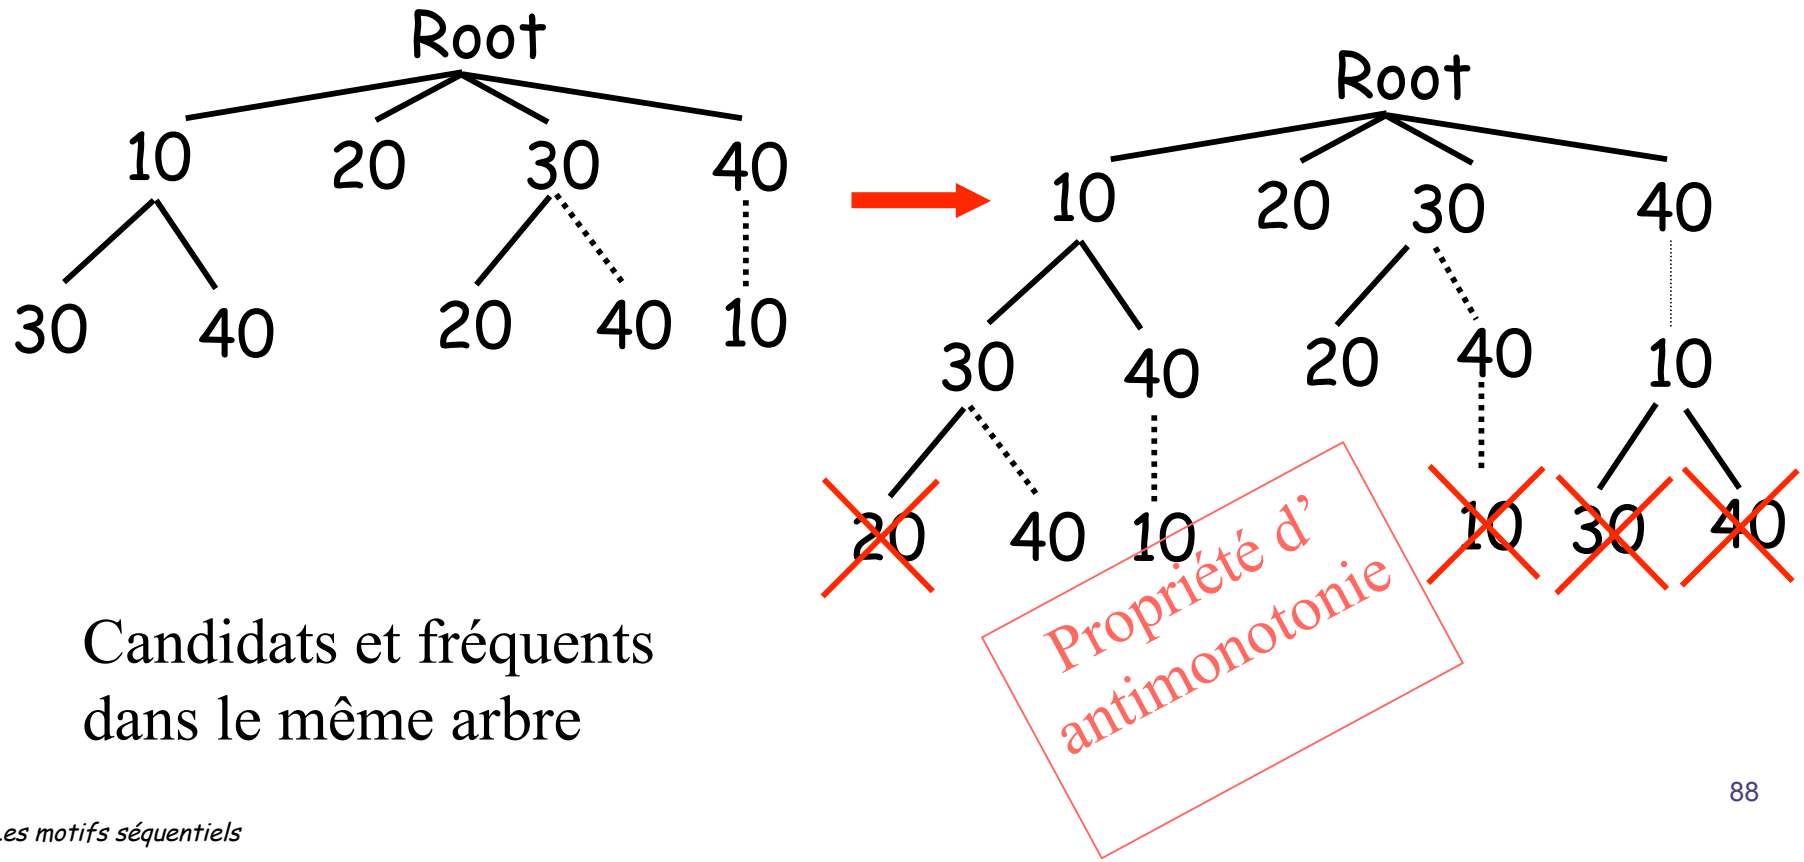

Candidats et fréquents
dans le même arbre

SPAM

- Utilisation de bitmaps pour rechercher les motifs fréquents
- Hypothèse : la base tient toujours en mémoire
- On construit d'un arbre lexicographique contenant toutes les branches possibles – élimination des branches en fonction du support
- Nouvelle représentation des données

SPAM (cont.)

- Représentation verticale des données

$C1 = <(1)_3\ (1)_5>$

		(1)
C1	**T1**	0
	T2	0
	T3	1
	T4	0
	T5	1

- S-Extension
- I-Extension

SPAM (cont.)

- S-Extension : un bitmap transformé + AND
- I-Extension : AND
- Exemple : recherche du candidat (1) (2)

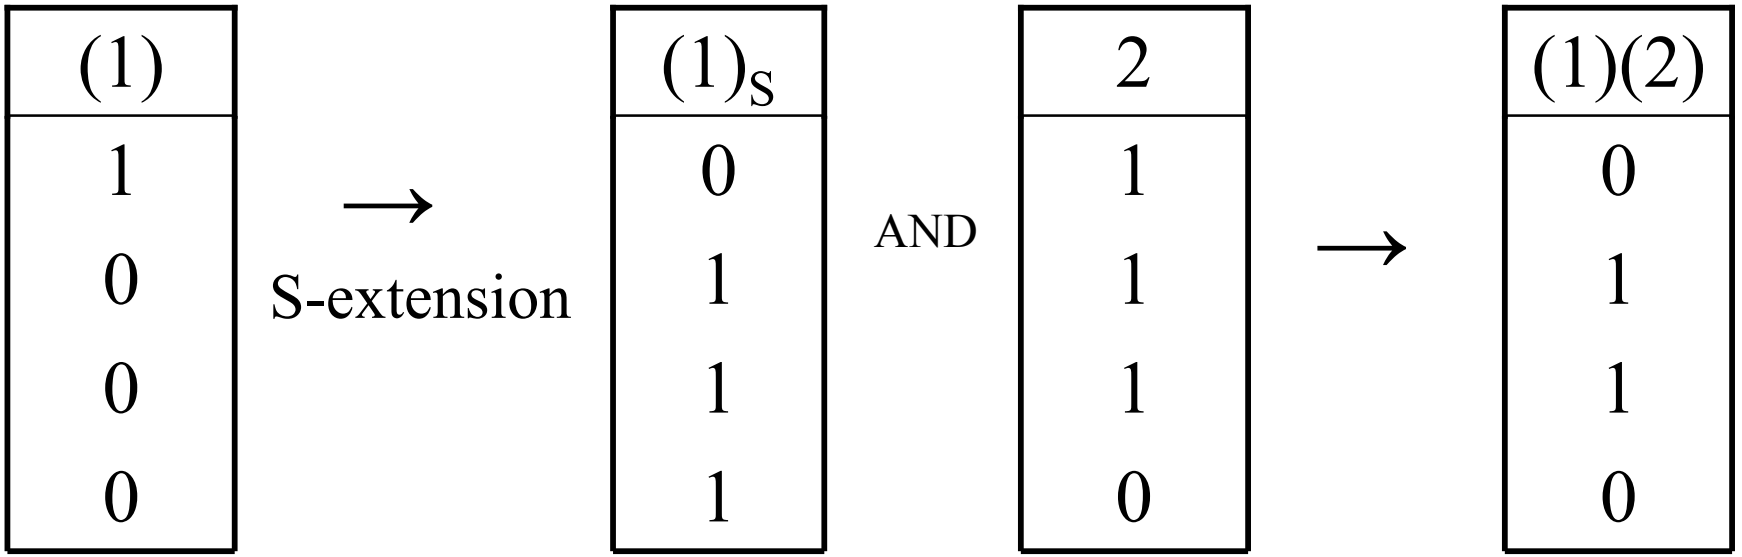

Conclusions

- Depuis 1996 :
- Problème de recherche ouvert
- Données de plus en plus complexes (représentations, …), obtenues de plus en plus rapidement (incrémental, flots de données), avec de nouvelles contraintes (préservation de la vie privée, contraintes de dimensions, temporelles), avec valeurs manquantes, …
- Besoins de nouveaux indicateurs de qualité

Conclusions

- Une URL : KDD Mine ttp://www.kdnuggets.com
- Google, citeseer, …
- Quelques outils

  Intelligent Miner (www.ibm.com)

  Entreprise Miner (SAS Institute)

  MineSet (Silicon Graphics Inc.)

  Clementine (Integral Solutions Ltd, racheté par SPSS)

  DBMiner (www.dbminer.com)
- Le projet Weka (librairie de classes Java)

  http://www.cs.waikato.ac.nz/ml/weka

Conclusions

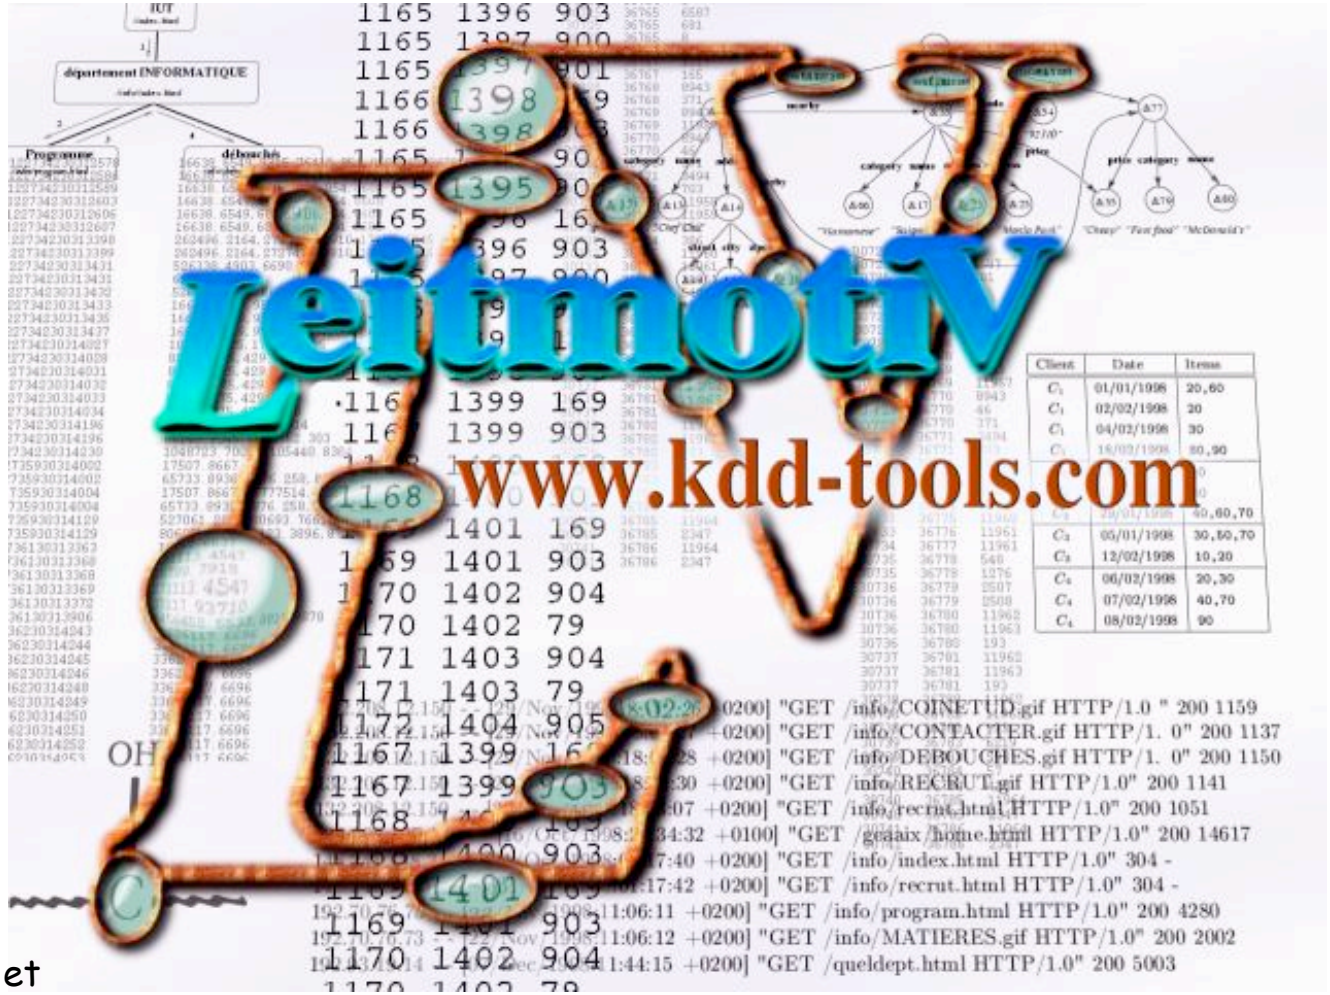

www.lgi2p.ema.fr/~poncelet

Conclusions

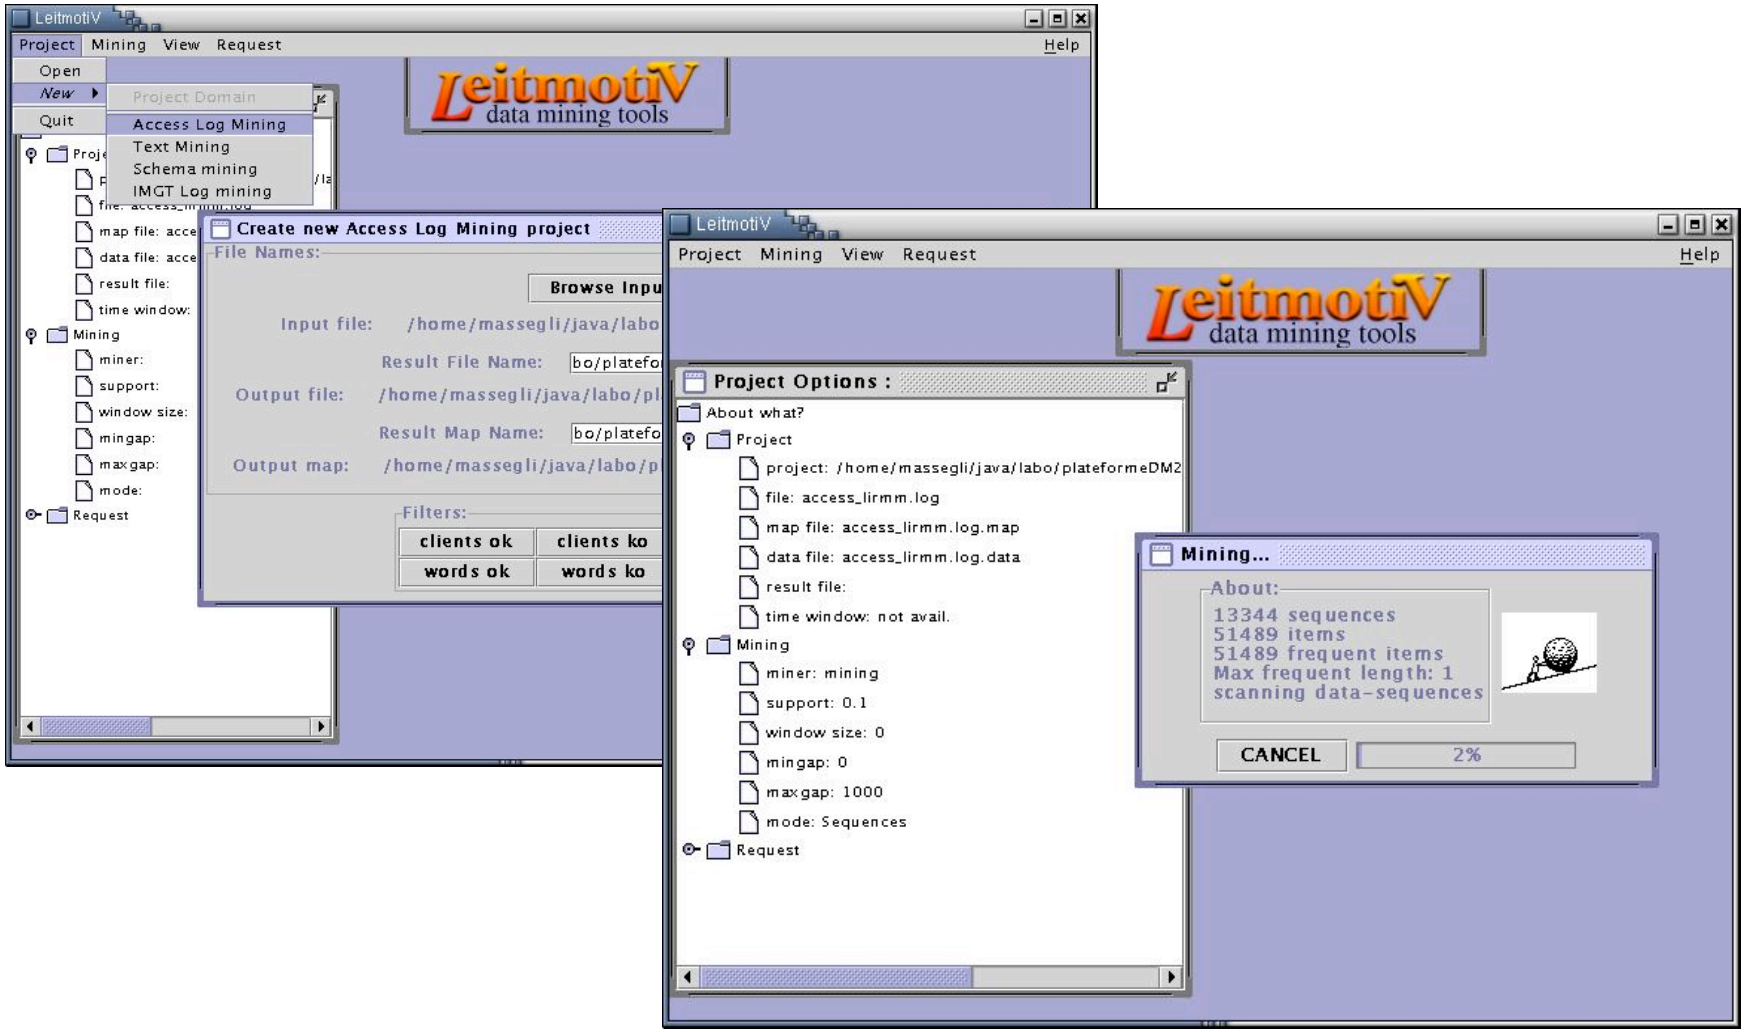

Conclusions

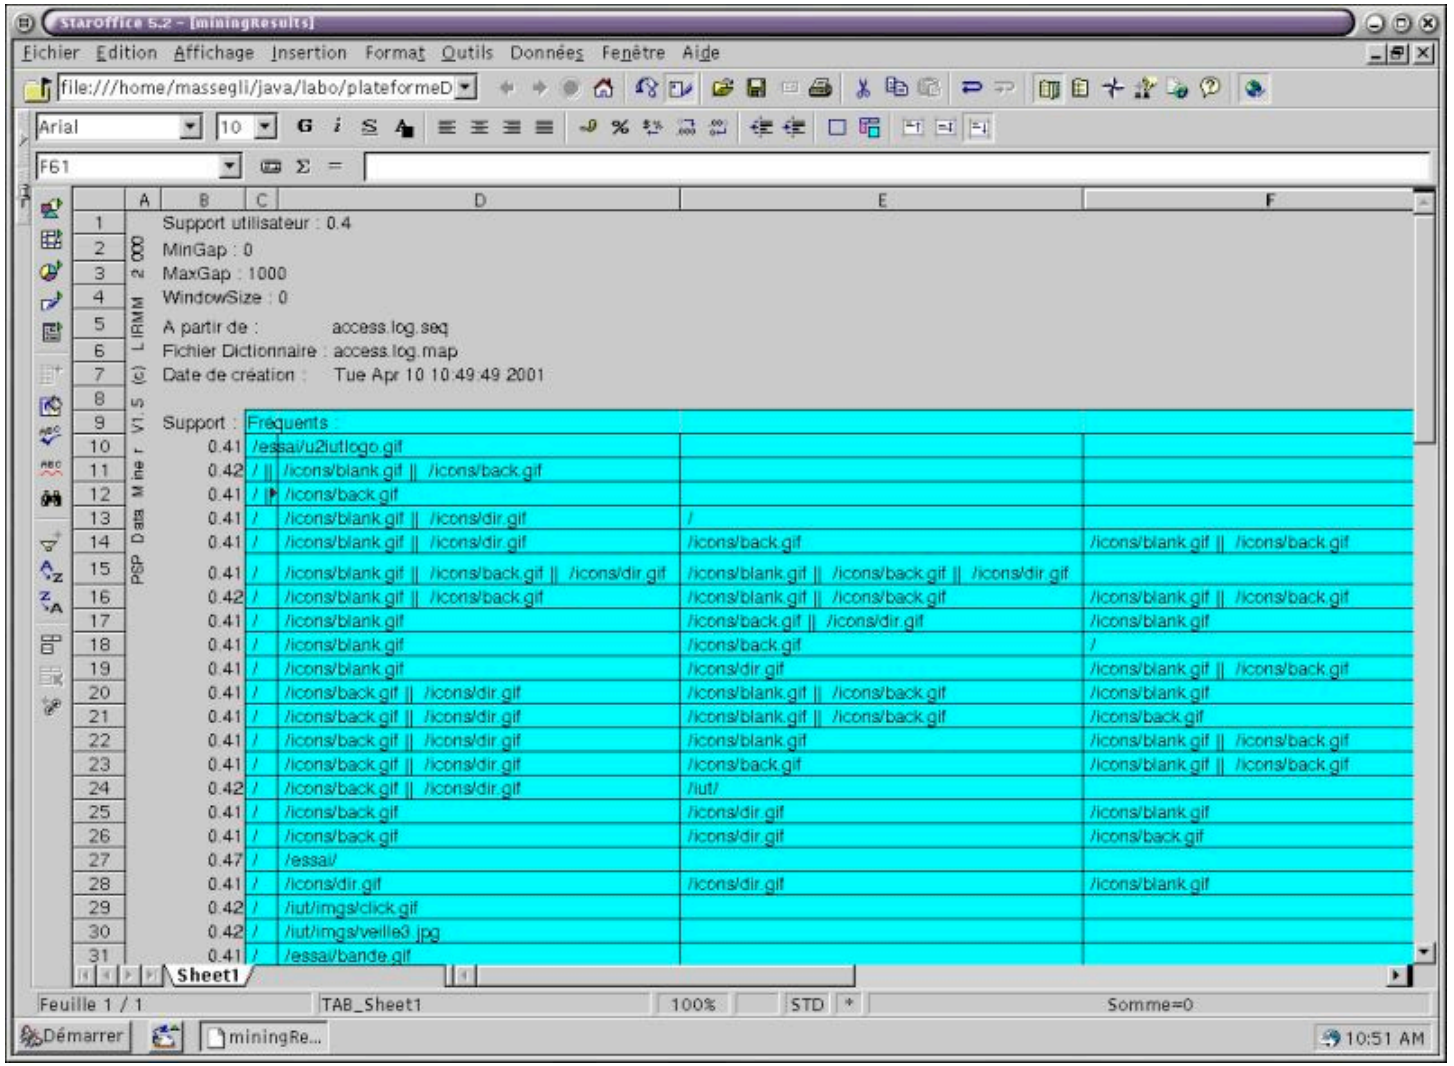

Références

- R. Agrawal, T. Imielinski, and A. Swami. Mining association rules between sets of items in large databases. SIGMOD'93, 207-216, Washington, D.C.
- R. Agrawal and R. Srikant. Fast algorithms for mining association rules. VLDB'94 487-499, Santiago, Chile.
- R. Agrawal and R. Srikant "Mining sequential patterns", In Proc. ICDE'95, Taiwan, March 1995.
- R.J. Bayardo. Efficiently mining long patterns from databases. In *Proc. SIGMOD'98*, WA, June 1998
- S. Brin R. Motwani, J. Ullman, and S. Tsur. Dynamic itemset counting and implication rules for market basket data. In *SIGMOD'97*
- M.N. Garofalakis, R. Rastogi, K. Shim: SPIRIT: Sequential Pattern Mining with Regular Expression Constraints. VLDB 1999: 223-234, Edinburgh, Scotland.
- J. Han, J. Pei, and Y. Yin: "Mining frequent patterns without candidate generation". In Proc. ACM-SIGMOD'2000, pp. 1-12, Dallas, TX, May 2000.
- H. Mannila, H. Toivonen, and A. I. Verkamo. Efficient algorithms for discovering association rules. KDD'94, 181-192, Seattle, WA, July 1994.
- J. Han and M. Kamber, Data Mining: Concepts and Techniques, Morgan Kaufmann, 2000.
- J. Han, J. Pei, B. Mortazavi-Asl, Q. Chen, U. Dayal, M.-C. Hsu, "FreeSpan: Frequent Pattern-Projected Sequential Pattern Mining", In Proc. 2000 Int. Conf. on Knowledge Discovery and Data Mining (KDD'00), Boston, MA, August 2000.
- J. Han, J. Pei, B. Mortazavi-Asl, Q. Chen, U. Dayal, M.-C. Hsu, "FreeSpan: Frequent Pattern-Projected Sequential Pattern Mining", In Proc. 2000 Int. Conf. on Knowledge Discovery and Data Mining (KDD'00), Boston, MA, August 2000.
- J. Han, J. Pei, and Y. Yin: "Mining frequent patterns without candidate generation". In ACM-SIGMOD'2000, Dallas, TX, May 2000.
- V. Kapoor, P. Poncelet, F. Trousset and M. Teisseire. "Privacy Preserving Sequential Pattern Mining in Distributed Databases". Proceedings of the Fifteenth Conference on Information and Knowledge Management (CIKM 2006), Arlington, US, November 2006.

Références

- H. Mannila, H. Toivonen and A.I. Verkamo. Efficient algorithms for discovering association rules. In *Proc. KDD'94*, WA, July 1994
- P.A. Laur, M. Teisseire and P. Poncelet. "AUSMS: An Environment for Frequent Sub-Substructures Extraction in a Semi-Structured Object Collection". Proceedings of the 14th International Conference on Database and Expert Systems Applications (DEXA'03), Prague, Czech Republic, LNCS, pages 38-45, September 03.
- F. Masseglia, P. Poncelet and M. Teisseire. "Peer-to-Peer Usage Mining: a Distributed Mining Approach". Proceedings of the IEEE 20th International Conference on Advanced Information Networking and Applications (AINA 2006), Vienna, Austria, April 2006.
- F. Masseglia, F. Cathala and P. Poncelet. "PSP: Prefix Tree For Sequential Patterns". Proceedings of the 2nd European Symposium on Principles of Data Mining and Knowledge Discovery (PKDD'98), Nantes, France, LNAI, Vol. 1510, pp. 176-184, September 1998.
- F. Masseglia, M. Teisseire et P. Poncelet. "Extraction de motifs séquentiels - Problèmes et Méthodes". Revue Ingénierie des Systèmes d'Information (ISI), Numéro spécial "Extraction et usages multiples de motifs dans les Bases de Données", Vol.9, N. 3-4, 2004, pp.183-210.
- F. Masseglia, M. Teisseire and P. Poncelet. "Pre-Processing Time Constraints for Efficiently Mining Generalized Sequential Patterns". Proceedings of the 11th International Symposium on Temporal Representation and Reasoning (TIME'04), Tatihou, Basse Normandie, France, July 2004
- F. Masseglia, P. Poncelet and M. Teisseire. "Incremental Mining of Sequential Patterns in Large Databases". Data and Knowledge Engineering, Volume 46, Issue 1, pages 97-121, 2003.(PDF)
- F. Masseglia, M. Teisseire and P. Poncelet. "HDM: A Client/Server/Engine Architecture for Real Time Web Usage". Knowledge and Information Systems (KAIS) journal, Vol. 5, N° 4, October 2003.

Références

- C. Raissi and P. Poncelet. "Towards a New Approach for Mining Maximal Frequent Itemsets over Data Stream". Journal of Intelligent Information Systems, Springer (to appear 2006)
- C. Raissi, P. Poncelet and M. Teisseire. "SPEED: Mining Maximal Sequential Patterns over Data Streams". Proceedings of the 3rd IEEE International Conference on Intelligent Systems (IEEE IS 2006), London, UK, September 2006.
- A. Savasere, E. Omiecinski, and S. Navathe. An efficient algorithm for mining association in large databases. In *VLDB'95*
- R. Srikant and R. Agrawal "Mining sequential patterns: Generations and performance improvements", In Proc. EDBT'96, France, March 1996.
- H. Toivonen. Sampling large databases for association rules. In *VLDB'96*
- Wei Wang, Jiong Yang, Philip S. Yu: Mining Patterns in Long Sequential Data with Noise. SIGKDD Explorations 2(2): 28-33 (2000)
- M.J. Zaki. Efficient enumeration of frequent sequences. CIKM'98. Novermber 1998.