

---

## Fouille de Séquences

---

MARC PLANTEVIT

UCB LYON 1 - LIRIS - CNRS



LIRIS



`marc.plantevit@liris.cnrs.fr`

# Outline

- 1 Introduction
- 2 Définitions
- 3 Algorithmes
- 4 Web Usage Mining
- 5 Conclusions

## Règles d'association : rappel

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

## Règles d'association : rappel

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

- Itemsets : A,B ou B,E,F

## Règles d'association : rappel

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

- Itemsets : A,B ou B,E,F
- Support d'un itemset :
  - $support(AD) = 1$
  - $support(AC) = 2$

## Règles d'association : rappel

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

- Itemsets : A,B ou B,E,F
- Support d'un itemset :
  - $support(AD) = 1$
  - $support(AC) = 2$
- Itemsets fréquents ( $minsupp = 50\%$ ) :
  - $\{A, C\}$  et  $\{A, B\}$  sont fréquents

## Règles d'association : rappel

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

- Itemsets : A,B ou B,E,F
- Support d'un itemset :
  - $support(AD) = 1$
  - $support(AC) = 2$
- Itemsets fréquents ( $minsupp = 50\%$ ) :
  - $\{A, C\}$  et  $\{A, B\}$  sont fréquents
- Pour  $minsupp = 50\%$  et  $minconf = 50\%$ , on a les règles suivantes :
  - $A \rightarrow C$  [50%, 50%]
  - $C \rightarrow A$  [50%, 100%]
  - $A \rightarrow B$  et  $B \rightarrow A$ ?

# Association vs. motif séquentiel

## Règles d'association

- **ensemble d'items** qui apparaît fréquemment dans une base de données
- Corrélation entre ces items

## Motifs séquentiels

- **Liste d'ensemble d'items** qui apparaît fréquemment dans une base de données
- L'idée principale est de comprendre les habitudes d'un consommateur, etc.

## Analyse du panier de la ménagère

# Analyse du panier de la ménagère

Localization → STOW STAR  
(978) 897-5140

Items bought → TERA SALT & VING 1.99 F  
TERRA SLT&PEPR C 1.99 F  
HD PREN 12 CHOCO WP .89 F

Identification → VISA/MASTERCARD

Date, time → 9/04/00 6:24 PM 0152 04 0429 109

SUB-TOTAL 4.87  
TAX .00  
BALANCE 4.87

STAR MARKET  
GREAT ROAD  
STOW, MA

CHANGE

SIGN UP TODAY TO GET EXTRA SAVINGS  
WITH THE STAR MARKET ADVANTAGE CARD  
KEITH SHAW - STORE MANAGER  
THANK YOU

# Encore

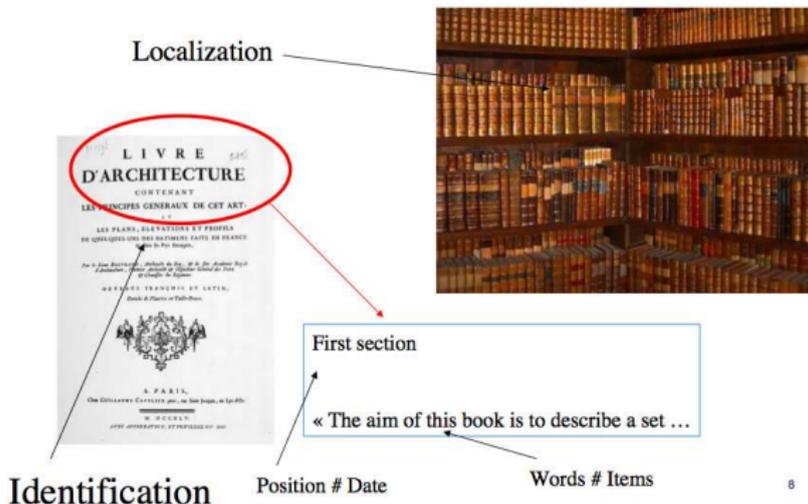
## Textes

$S_1$  : ⟨ "s-Tomosyn", "as", "well", "as", "m-tomosyn", "was", "mainly", ... ⟩

$S_2$  :

⟨ "This", "region", "was", "necessary", "but", "not", "sufficient", "for", ... ⟩

...



## Autres exemples de séquences de données

### Biological Sequences : DNA, RNA and Proteins

*GAATTCTCTGTAACACTAAGCTCTCTTCCTCAAACCAGAGGTAGA  
ATGTGTAATAATTTACAGAATTTCTAGACTTCAACGATCTGATTTTT  
ATTTATTTTTATTTTTTTCAGGTTGAGACTGAGCTAAAGTTAATCTG*

## Autres exemples de séquences de données

### Biological Sequences : DNA, RNA and Proteins

```
GAATTCTCTGTAACACTAAGCTCTCTTCCTCAAACCAGAGGTAGA  
ATGTGTAATAATTTACAGAATTTCTAGACTTCAACGATCTGATTTTT  
ATTTATTTTTATTTTTTTCAGGTTGAGACTGAGCTAAAGTTAATCTG
```

### Event Sequences : Weblogs, System Traces, Purchase Histories and Sales Histories

- weblog :  
 $\langle 100, a \rangle, \langle 100, b \rangle, \langle 200, a \rangle, \langle 300, b \rangle, \langle 200, b \rangle, \langle 400, a \rangle, \langle 100, a \rangle, \langle 400, b \rangle$
- customer purchase history :  
 $\langle 223100, 05/26/06, 10am, CentralStation, \{ WholeMealBread, AppleJuice \} \rangle,$   
 $\langle 225101, 05/26/06, 11am, CentralStation, \{ Burger, Pepsi, Banana \} \rangle$
- Storewide sales history :  
 $\langle 97100, 05/06, \{ \langle Apple : \$85K \rangle, \langle Bread : \$100K \rangle, \langle Cereal : \$150K \rangle, \dots \} \rangle,$   
 $\langle 90089, 05/06, \{ \langle Apple : \$65K \rangle, \langle Bread : \$105K \rangle, \langle Diaper : \$20K \rangle, \dots \} \rangle$

# Pourquoi l'extraction de motifs séquentiels ?

Un important problème en DM avec de nombreuses applications :

- Analyse des achats des consommateurs
- Analyse ADN,
- Conséquences des catastrophes naturelles,
- Web log mining,
- Détection de tendances

# Outline

- 1 Introduction
- 2 Définitions**
- 3 Algorithmes
- 4 Web Usage Mining
- 5 Conclusions

Soit  $\mathcal{I} = \{i_1, i_2, \dots, i_n\}$  un ensemble de littéraux appelés **items**

- $\mathcal{I} = \{\text{PC, TV, bière, couches, etc.}\}$

Soit  $\mathcal{I} = \{i_1, i_2, \dots, i_n\}$  un ensemble de littéraux appelés **items**

- $\mathcal{I} = \{\text{PC, TV, bière, couches, etc.}\}$

## Transaction

Une transaction est composée de :

- Un identifiant (*id\_client*),
- Une date de transaction,
- Un ensemble d'items (**itemsets**)
- Exemple :  $T = [Cid1, (Beer, Cake, Diaper)_5]$

# Séquence et séquence de données

## Séquence :

Une **liste ordonnée** d'itemsets

- Exemple :  $\langle (TV), (DVD\text{-}Reader, Star\ War\ box) \rangle$

# Séquence et séquence de données

## Séquence :

Une **liste ordonnée** d'itemsets

- Exemple :  $\langle (TV), (DVD\text{-}Reader, Star\ War\ box) \rangle$

## Séquence de données

Soient  $T_1, T_2, \dots, T_m$ , les transactions d'un client  $C$ , la séquence de données de  $C$  est la paire :

$$(C, \langle itemset(T_1), itemset(T_2), \dots, itemset(T_m) \rangle)$$

Ex : Les achats d'un consommateur au cours du temps.

# Séquence et séquence de données

## Séquence :

Une **liste ordonnée** d'itemsets

- Exemple :  $\langle (TV), (DVD\text{-}Reader, Star\ War\ box) \rangle$

## Séquence de données

Soient  $T_1, T_2, \dots, T_m$ , les transactions d'un client  $C$ , la séquence de données de  $C$  est la paire :

$$(C, \langle itemset(T_1), itemset(T_2), \dots, itemset(T_m) \rangle)$$

Ex : Les achats d'un consommateur au cours du temps.

## Base de séquences (de données)

$SDB =$

- $(C_1, \langle (Coffe, Mustard), (Coke), (Diaper) \rangle)$
- $(C_2, \langle (Beer)(Coke) \rangle)$

## Inclusion

Soient deux séquences  $S_1 = \langle a_1, a_2, \dots, a_n \rangle$  et  $S_2 = \langle b_1, b_2, \dots, b_{n'} \rangle$ ,  $S_1$  est une sous-séquence de  $S_2$  ( $S_2$  superséquence de  $S_1$ , noté  $S_1 \preceq S_2$ ) si il existe des entiers  $1 \leq i_1 < i_2 < \dots < i_n \leq n'$  tels que :

$$a_1 \subseteq b_{i_1}, a_2 \subseteq b_{i_2}, \dots, a_n \subseteq b_{i_n}$$

## Exemple

- $S_1 = \langle (10)(20, 30), (40), (20) \rangle$
- $S_2 = \langle (20), (40) \rangle \preceq S_1$
- $S_3 = \langle (20), (30) \rangle \not\preceq S_1$

## Support d'une séquence

L'occurrence d'une séquence n'est considérée qu'une seule fois dans une séquence de données

Ex :  $\langle(20)\rangle$  et  $\langle(10)(20)(20, 30), (40), (20)\rangle$

On dit aussi que la séquence de données **contient** la séquence  $\langle(20)\rangle$ .

### Support d'une séquence

Le support d'une séquence  $s$  dans une base de données  $SDB$  correspond au nombre de séquences de données qui contiennent  $s$ .

## Exemple

Customers	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

- $Absolute\_Support(\langle(10, 30)(20)(20, 60)\rangle) = 3$
- $Relative\_Support(\langle(10, 30)(20)(20, 60)\rangle) = \frac{3}{4} = 75\%$

# Problématique

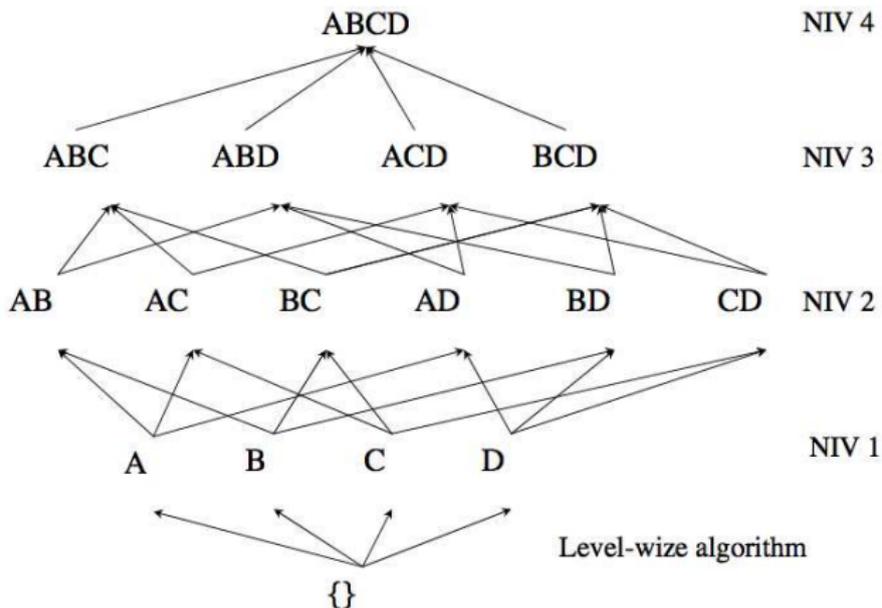
Etant donné un ensemble de séquences de données  $SDB$  et un seuil de support minimum  $minsupp$ , le but de l'extraction des motifs séquentiels est de trouver l'ensemble complet des séquences qui ont un support supérieur ou égal à  $minsupp$ .

- Le nombre de motifs séquentiels « cachés » dans les séquences de données peut être très importants
- Un algorithme d'extraction doit donc :
  - trouver **l'ensemble complet** des motifs séquentiels
  - être efficace (passage à l'échelle) en limitant le nombre de passes sur les données
  - permettre d'incorporer un ensemble varié de contraintes définies par l'utilisateur (syntaxiques, temporelles, etc.)

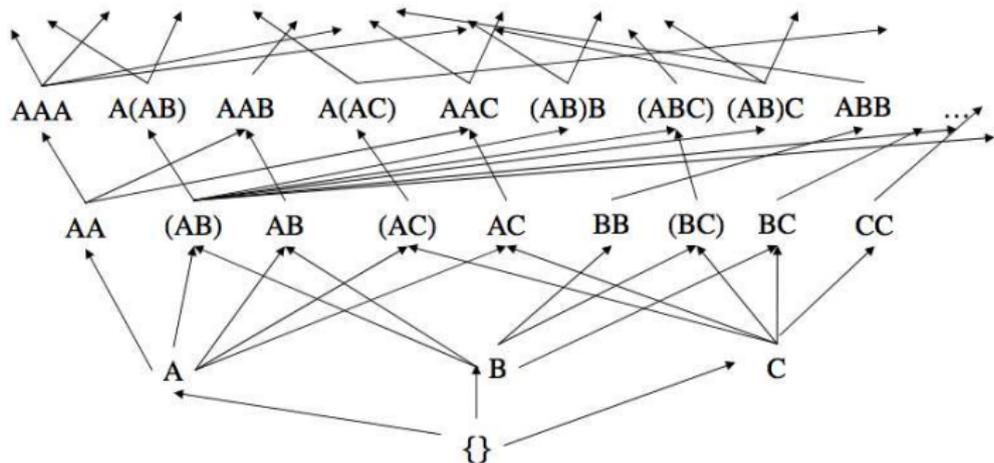
# Outline

- 1 Introduction
- 2 Définitions
- 3 Algorithmes**
- 4 Web Usage Mining
- 5 Conclusions

# Itemset : l'espace de recherche (un treillis)



# Motifs séquentiels : l'espace de recherche



# Propriété Apriori des motifs séquentiels

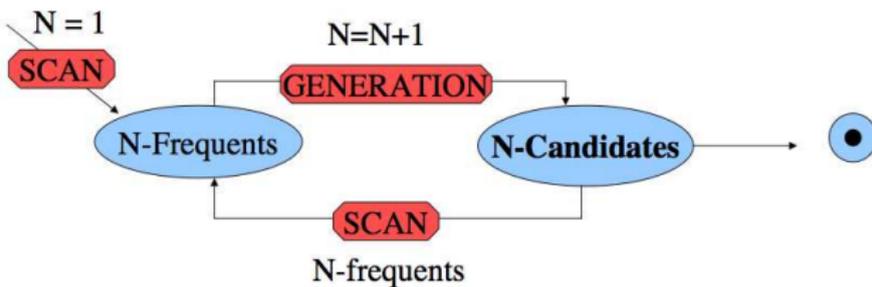
## Une propriété fondamentale [Agrawal et Srikant, 94]

- Si une séquence  $S$  n'est pas fréquente
- Alors aucune de ses super-séquences est fréquente
- Ex :  $\langle hb \rangle$  non fréquent alors  $\langle hab \rangle$   $\langle (ah)b \rangle$  non plus

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

minsupp = 2

# Approche générale : générer/élaguer



# Génération de candidats : deux types d'extension

## S-Extension

On ajoute un nouvel itemset (une séquence) à la séquence considérée

- $\langle\langle a, b \rangle(c)\rangle \rightarrow \langle\langle a, b \rangle(c)(d)\rangle$

## I-Extension

On ajoute un nouvel item à la séquence considérée dans un itemset déjà créé.

- $\langle\langle a, b \rangle(c)\rangle \rightarrow \langle\langle a, b \rangle(c, d)\rangle$

$L=1$

While ( $\text{Result}_L \neq \text{NULL}$ )

    Candidate Generate

    Prune

    Test

$L=L+1$

Une passe sur les données pour extraire les séquences composées d'un unique item (dans un unique itemset).

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

Cand	Sup
<a>	3
<b>	5
<c>	4
<d>	3
<e>	3
<f>	2
<del>&lt;g&gt;</del>	1
<del>&lt;h&gt;</del>	1

# Les processus global

**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 longueur 2

S-Extension  
51 2-Candidates

	<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>

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>						

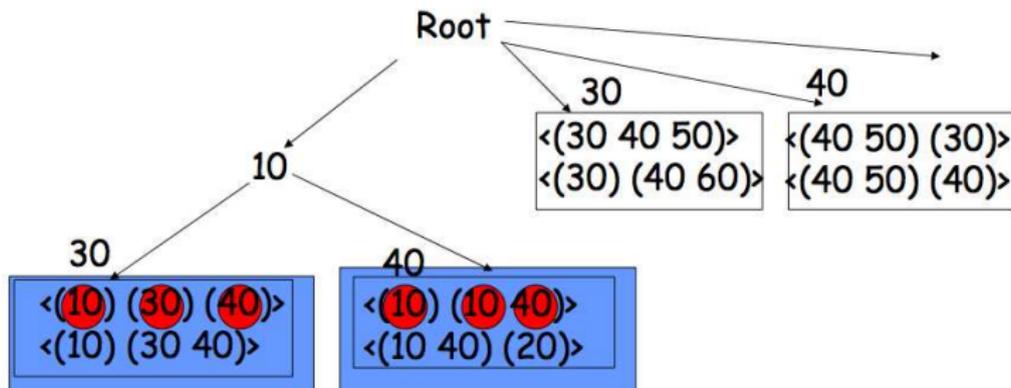
Without the  
antimonotonic property  
 $8*8+8*7/2=92$   
candidates

## L'étape la plus coûteuse

- Les candidats sont stockés en mémoire centrale.
- Il faut limiter les accès disques sur la base de données
- Possibilité de charger la base en mémoire quand c'est possible

# Comment stocker efficacement les candidats ?

A Hash tree structure

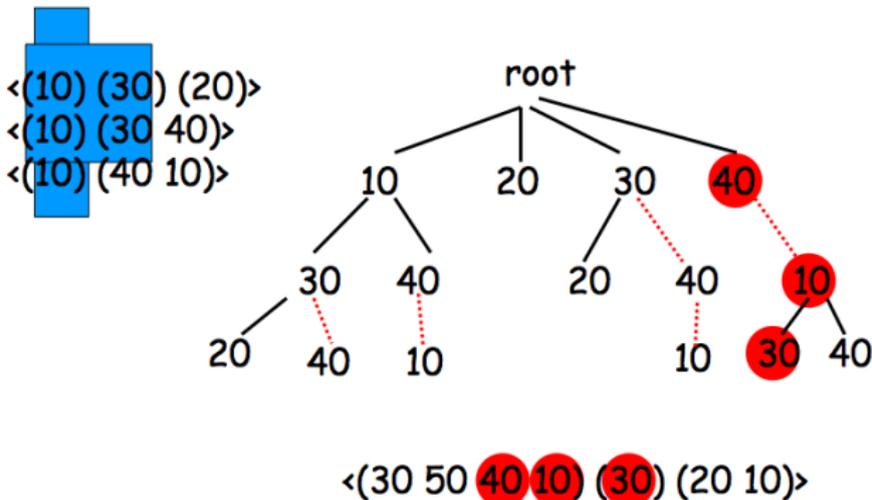


$$S = \langle (10)(30)(10, 40) \rangle$$

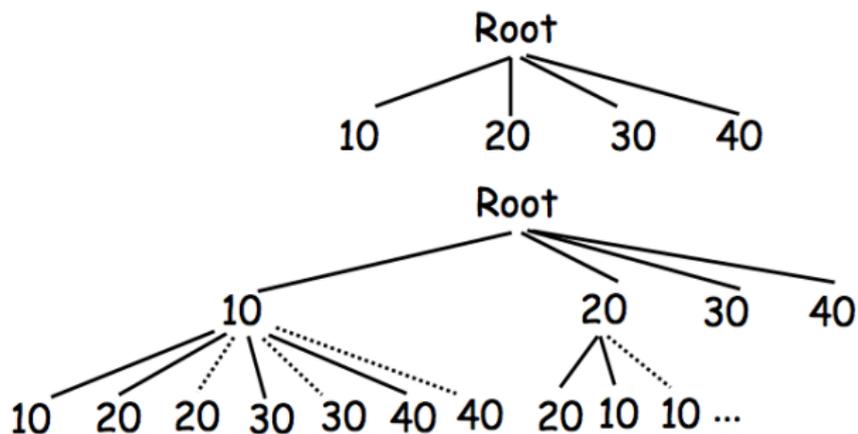
# PSP (Prefix Tree for SP) [Masseglia et al. 98]

Une structure plus efficace basée sur un arbre des préfixes.

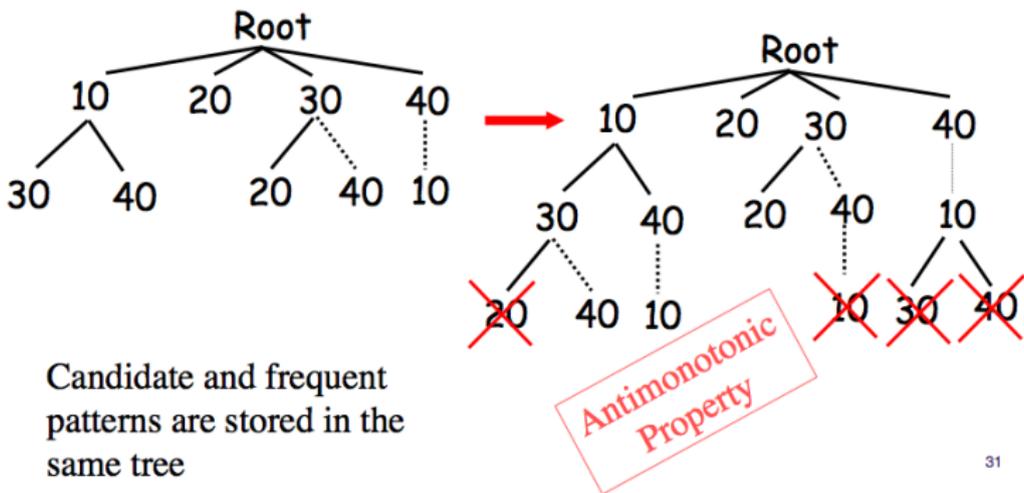
- 2 types d'arc



## PSP : génération des 2-candidats



## PSP : génération des k-candidats ( $k > 2$ )



31

## SPADE (Sequential PAttern Discovery using Equivalent Class) [Zaki 2001]

- représentation verticale de la base de données
- base de séquences transformée en un ensemble de triplet (item, SID,EID)
- Extraction de motifs est effectuée avec une génération de candidats basée sur Apriori

# SPADE : pour un calcul du support plus efficaces

SID	EID	Items
1	1	a
1	2	abc
1	3	ac
1	4	d
1	5	cf
2	1	ad
2	2	c
2	3	bc
2	4	ae
3	1	ef
3	2	ab
3	3	df
3	4	c
3	5	b
4	1	e
4	2	g
4	3	af
4	4	c
4	5	b
4	6	c

a		b		...
SID	EID	SID	EID	...
1	1	1	2	
1	2	2	3	
1	3	3	2	
2	1	3	5	
2	4	4	5	
3	2			
4	3			

ab			ba			...
SID	EID (a)	EID(b)	SID	EID (b)	EID(a)	...
1	1	2	1	2	3	
2	1	3	2	3	4	
3	2	5				
4	3	5				

aba				...
SID	EID (a)	EID(b)	EID(a)	...
1	1	2	3	
2	1	3	4	

- Une surgénération de candidats :
  - Pour 1000 1-séquences fréquentes, on génère  $1000 \times 1000 \times \frac{1000 \times 999}{2} = 1,499,500$  2 candidats
  - De multiples passages sur la bases de données
  - Approche en largeur sont coûteuse en gestion mémoire
- Pour extraire de longues séquences, ce type d'approche n'est pas adapté :
  - un nombre exponentiel de sous séquences candidates générées
  - pour une séquence de longueur 100 :  $2^{100} - 1 \approx 10^{30}$

## Approche « pattern growth »

- pas de génération de candidats
- extraction d'items fréquents sur des bases projetées
- approche gloutonne en profondeur

# Préfixe et suffixe

- $\langle a \rangle$ ,  $\langle aa \rangle$  et  $\langle a(abc) \rangle$  sont des **préfixes** de la séquence  $\langle a(abc)(ac)d(cf) \rangle$

# Préfixe et suffixe

- $\langle a \rangle$ ,  $\langle aa \rangle$  et  $\langle a(abc) \rangle$  sont des **préfixes** de la séquence  $\langle a(abc)(ac)d(cf) \rangle$
- Etant donnée la séquence  $\langle a(abc)(ac)d(cf) \rangle$

## Préfixe et suffixe

- $\langle a \rangle$ ,  $\langle aa \rangle$  et  $\langle a(abc) \rangle$  sont des **préfixes** de la séquence  $\langle a(abc)(ac)d(cf) \rangle$
- Etant donnée la séquence  $\langle a(abc)(ac)d(cf) \rangle$

Préfixe	Suffixe (Prefix-Based Projection)
$\langle a \rangle$	$\langle (abc)(ac)d(cf) \rangle$
$\langle a\underline{a} \rangle$	$\langle (\_bc)(ac)d(cf) \rangle$
$\langle a\underline{b} \rangle$	$\langle (\_c)(ac)d(cf) \rangle$

- Des items particuliers :  $(\_b)$

# Extraction de motifs séquentiels par projection des préfixes

- Etape 1 : extraction des 1-séquences fréquentes :

$\langle a \rangle, \langle b \rangle, \langle c \rangle, \langle d \rangle, \langle e \rangle, \langle f \rangle$

- Etape 2 : l'ensemble complet des motifs séquentiels peut être partitionné en 6 sous-ensembles :
  - ceux de préfixe  $\langle a \rangle$ ,
  - ceux de préfixe  $\langle b \rangle$ ,
  - ceux de préfixe  $\langle c \rangle$ ,
  - ceux de préfixe  $\langle d \rangle$ ,
  - ceux de préfixe  $\langle e \rangle$ ,
  - ceux de préfixe  $\langle f \rangle$ .

## Trouver les motifs séquentiels de préfixe $\langle a \rangle$

Simplement considérer les projections par rapport à  $\langle a \rangle$  :

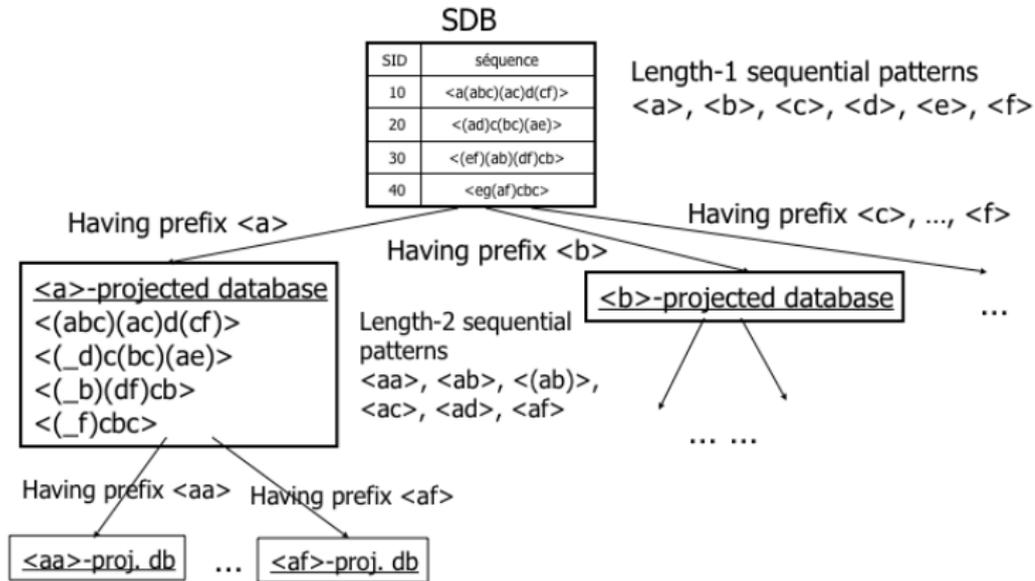
- $\langle (abc)(ac)d(cf) \rangle$ ,
- $\langle (-d)c(bc)(ae) \rangle$ ,
- $\langle (-b)(df)cb \rangle$ ,
- $\langle (-f)cbc \rangle$

Motifs séquentiels de longueur 2 de préfixe  $\langle a \rangle$  :

- $\langle aa \rangle$ ,
- $\langle ab \rangle$ ,
- $\langle (ab) \rangle$ ,
- $\langle ac \rangle$ ,
- $\langle ad \rangle$ ,
- $\langle af \rangle$

## Nouvelle partition en 6 ss-ensembles

# Complétude de PrefixSpan



# Efficacité de PrefixSpan

- Pas de génération de candidats
- La taille des bases projetées diminue sans cesse
- Le principal coût de PrefixSpan : Construire les bases projetées
  - Est amélioré à l'aide de **pseudo projections**

# Pseudo projection

- Quand la base de données considérée peut être gérée en mémoire, **utilisation de pointeurs** pour les projections
- Pointeur sur les séquences
- Offset sur le suffixe

The diagram shows a sequence  $s = \langle a(abc)(ac)d(cf) \rangle$  with red highlighting on  $(abc)$ ,  $(ac)$ , and  $(cf)$ . Below it, two projection operations are shown:

- $s|_{\langle a \rangle} : (, 2) \langle (abc)(ac)d(cf) \rangle$  with a vertical arrow pointing from  $(abc)$  to  $\langle a \rangle$ .
- $s|_{\langle ab \rangle} : (, 4) \langle (_c)(ac)d(cf) \rangle$  with a vertical arrow pointing from  $(ac)$  to  $\langle ab \rangle$ .

Red arrows point from the start of the sequence  $s$  to the start of the first projection  $(, 2)$  and to the start of the second projection  $(, 4)$ .

# Pseudo projection vs. projection physique

- La pseudo projection évite de stocker physiquement les suffixes
  - Efficacité (temps d'exécution et espace mémoire) quand la base peut être stocker en mémoire
- Quid des bases qui ne peuvent pas être stockées en mémoire ?
  - Intégration de projections physiques et de pseudo projections
  - Utilisation de pseudo projections quand la base tient en mémoire (la taille des bases projetées diminuant)

# Motifs séquentiels fermés

Définition ?

## Définition ?

## Des motivations doubles

- Réduire le nombre de motifs (redondants) tout en maintenant la qualité de la connaissance extraite (pas de perte d'information)
- Améliorer l'extraction des motifs séquentiels en introduisant des propriétés d'élagages supplémentaires.

## Définition ?

## Des motivations doubles

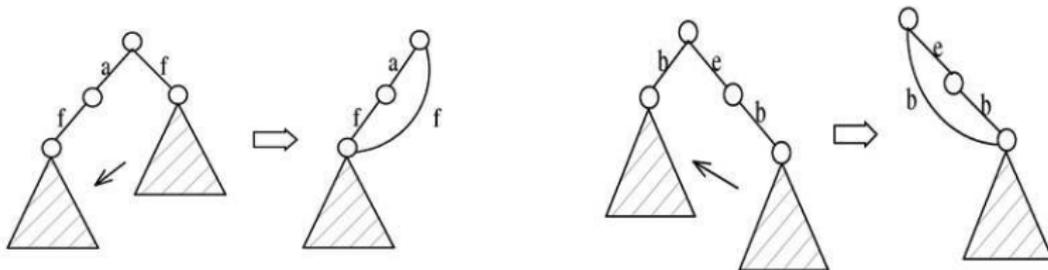
- Réduire le nombre de motifs (redundants) tout en maintenant la qualité de la connaissance extraite (pas de perte d'information)
- Améliorer l'extraction des motifs séquentiels en introduisant des propriétés d'élagages supplémentaires.

## Deux approches :

- CloSpan (Yan et al. 2003)
- Bide (Wang et al. 2007)

Eviter de parcourir plusieurs fois les mêmes bases projetées

« Using Backward Subpattern and Backward Superpattern pruning to prune redundant search space »



## Les limites de la gestion d'ensemble de candidats

- post-traitement :  $O(n^2)$

Il faut éviter de gérer des candidats

## BIDE : Idée Principale

Extension d'une  $g$ - $k$ -séquence préfixe  $\langle s_1, s_2, \dots, s_g \rangle$  :

## BIDE : Idée Principale

Extension d'une  $g$ - $k$ -séquence préfixe  $\langle s_1, s_2, \dots, s_g \rangle$  :

- vers l'avant inter itemset  $S' = \langle s_1, s_2, \dots, s_g, \{e'\} \rangle$

Extension d'une  $g$ - $k$ -séquence préfixe  $\langle s_1, s_2, \dots, s_g \rangle$  :

- 1 vers l'avant inter itemset  $S' = \langle s_1, s_2, \dots, s_g, \{e'\} \rangle$
- 2 vers l'avant intra itemset  $S' = \langle s_1, s_2, \dots, s_g \cup \{e'\} \rangle$

Extension d'une  $g$ - $k$ -séquence préfixe  $\langle s_1, s_2, \dots, s_g \rangle$  :

- 1 vers l'avant inter itemset  $S' = \langle s_1, s_2, \dots, s_g, \{e'\} \rangle$
- 2 vers l'avant intra itemset  $S' = \langle s_1, s_2, \dots, s_g \cup \{e'\} \rangle$
- 3 vers l'arrière inter itemset  $S' = \langle s_1, s_2, \dots, s_i, \{e'\}, s_{i+1}, \dots, s_g \rangle$

Extension d'une  $g$ - $k$ -séquence préfixe  $\langle s_1, s_2, \dots, s_g \rangle$  :

- 1 vers l'avant inter itemset  $S' = \langle s_1, s_2, \dots, s_g, \{e'\} \rangle$
- 2 vers l'avant intra itemset  $S' = \langle s_1, s_2, \dots, s_g \cup \{e'\} \rangle$
- 3 vers l'arrière inter itemset  $S' = \langle s_1, s_2, \dots, s_i, \{e'\}, s_{i+1}, \dots, s_g \rangle$
- 4 vers l'arrière intra itemset  $S' = \langle s_1, s_2, \dots, s_i \cup \{e'\}, s_{i+1}, \dots, s_g \rangle$

# BIDE : Idée Principale

Extension d'une  $g$ - $k$ -séquence préfixe  $\langle s_1, s_2, \dots, s_g \rangle$  :

- 1 vers l'avant inter itemset  $S' = \langle s_1, s_2, \dots, s_g, \{e'\} \rangle$
- 2 vers l'avant intra itemset  $S' = \langle s_1, s_2, \dots, s_g \cup \{e'\} \rangle$
- 3 vers l'arrière inter itemset  $S' = \langle s_1, s_2, \dots, s_i, \{e'\}, s_{i+1}, \dots, s_g \rangle$
- 4 vers l'arrière intra itemset  $S' = \langle s_1, s_2, \dots, s_i \cup \{e'\}, s_{i+1}, \dots, s_g \rangle$

Séquence Close :

- Si pas d'extension qui conserve le support de la séquence

## Intervalles de $\langle s_1, s_2, \dots, s_g \rangle$

Exhiber des items qui apparaissent tous les  $i^{\text{èmes}}$  intervalles

$\underbrace{l_1}, s_1, \underbrace{l_2}, s_2, \underbrace{l_3}, s_3, \dots, s_{g-1}, \underbrace{l_g}, s_g$

## Intervalles de $\langle s_1, s_2, \dots, s_g \rangle$

Exhiber des items qui apparaissent tous les  $i^{\text{èmes}}$  intervalles

$\underbrace{l_1}, s_1, \underbrace{l_2}, s_2, \underbrace{l_3}, s_3, \dots, s_{g-1}, \underbrace{l_g}, s_g$

Une séquence peut apparaître plusieurs fois dans une séquence de données

- Séquence  $\langle (a, b)(a, c) \rangle$
- Séquence de données  
 $\langle (a, b)(a, c)(a, b)(a, c)(a, b)(a, c)(a, b)(a, c) \rangle$

## Intervalles de $\langle s_1, s_2, \dots, s_g \rangle$

Exhiber des items qui apparaissent tous les  $i^{\text{èmes}}$  intervalles

$\underbrace{l_1}_{s_1}, \underbrace{l_2}_{s_2}, \underbrace{l_3}_{s_3}, \dots, \underbrace{l_g}_{s_{g-1}}, s_g$

Une séquence peut apparaître plusieurs fois dans une séquence de données

- Séquence  $\langle (a, b)(a, c) \rangle$
- Séquence de données  $\langle (a, b)(a, c)(a, b)(a, c)(a, b)(a, c)(a, b)(a, c) \rangle$

Maximiser ces intervalles

## Intervalles de $\langle s_1, s_2, \dots, s_g \rangle$

Exhiber des items qui apparaissent tous les  $i^{\text{èmes}}$  intervalles

$\underbrace{l_1}_{s_1}, \underbrace{l_2}_{s_2}, \underbrace{l_3}_{s_3}, \dots, s_{g-1}, \underbrace{l_g}_{s_g}$

Une séquence peut apparaître plusieurs fois dans une séquence de données

- Séquence  $\langle (a, b)(a, c) \rangle$
- Séquence de données  
 $\langle (a, b)(a, c)(a, b)(a, c)(a, b)(a, c)(a, b)(a, c) \rangle$

Maximiser ces intervalles

$l_1 : \langle (a, b)(a, c) \rangle$

$\langle \underbrace{(a, b)(a, c)(a, b)(a, c)(a, b)(a, c)}_{(a, b)(a, c)} (a, b)(a, c) \rangle$

## Intervalles de $\langle s_1, s_2, \dots, s_g \rangle$

Exhiber des items qui apparaissent tous les  $i^{\text{èmes}}$  intervalles

$\underbrace{l_1}_{s_1}, \underbrace{l_2}_{s_2}, \underbrace{l_3}_{s_3}, \dots, \underbrace{l_g}_{s_{g-1}}, s_g$

Une séquence peut apparaître plusieurs fois dans une séquence de données

- Séquence  $\langle (a, b)(a, c) \rangle$
- Séquence de données  
 $\langle (a, b)(a, c)(a, b)(a, c)(a, b)(a, c)(a, b)(a, c) \rangle$

Maximiser ces intervalles

$l_2 : \langle (a, b)(a, c) \rangle$

$\langle (a, b) \underbrace{(a, c)(a, b)(a, c)(a, b)(a, c)(a, b)}_{(a, c)} (a, c) \rangle$

# Les motifs séquentiels sous contraintes

## Extraction de motifs sous contraintes :

Permet de surmonter deux difficultés majeures de l'extraction de motifs :

- améliorer les connaissances extraites
- améliorer le processus d'extraction

## Les contraintes : plus proche de l'utilisateur

- Les contraintes peuvent permettre de modéliser l'intérêt de l'utilisateur.

# Une large gamme de contraintes

- item constraint
- length constraint
- aggregate constraint
- etc.

# Des contraintes spécifiques aux séquences

---

# Des contraintes spécifiques aux séquences

- min-gap
- max-gap
- durée (window size)

# Exemple

---

Au tableau

# Algorithmes d'extraction de motifs séquentiels sous contraintes

---

- Spirit [Garofalakis et al, 02]
- [Pei et al, 02]

## Motivations

Difficulté de fixer le bon seuil de support :

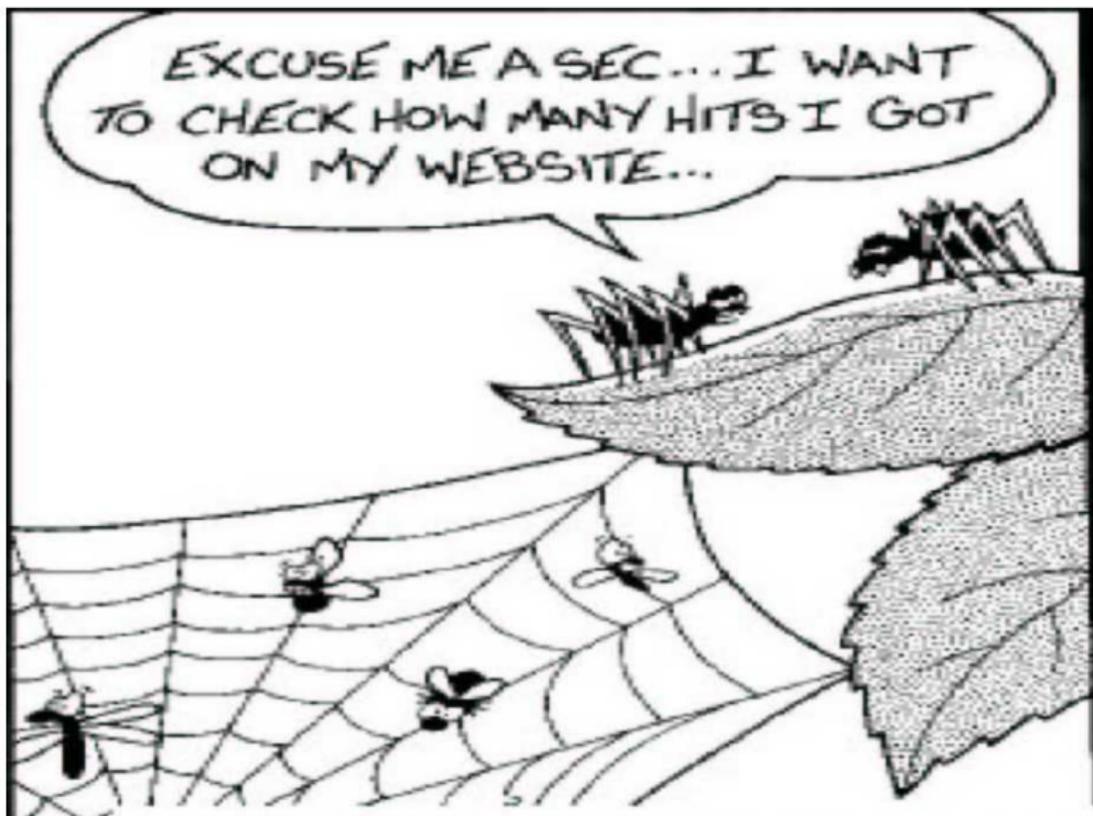
- coca-cola non fréquent
- pepsi non fréquent
- MAIS : soda fréquent

Peu d'approches permettant la prise en compte des hiérarchies dans l'extraction de motifs séquentiels

# Outline

- 1 Introduction
- 2 Définitions
- 3 Algorithmes
- 4 Web Usage Mining**
- 5 Conclusions

## Web Usage Mining



La découverte de motifs intéressants sur la navigation des visiteurs à partir de logs d'un site web

- Les pages contiennent des informations
- Les liens sont des « routes »
- Comment les gens naviguent sur Internet ?
- **WUM = clickstream analysis**

## Hyper liens dynamiques

- générer des hyper liens dynamiques en regardant la navigation du visiteur

## Hyper liens dynamiques

- générer des hyper liens dynamiques en regardant la navigation du visiteur

## Personnalisation

Fournir au visiteur ce **qu'il veut** sans le lui demander explicitement

- générer des recommandations pour chaque utilisateur pendant sa navigation

# Applications

## Hyper liens dynamiques

- générer des hyper liens dynamiques en regardant la navigation du visiteur

## Personnalisation

Fournir au visiteur ce **qu'il veut** sans le lui demander explicitement

- générer des recommandations pour chaque utilisateur pendant sa navigation

## Site web adaptatif

**Changer le site web** en fonction des motifs extraits

## Amélioration de site web

- comparer les caractéristiques des « clients » et des « non clients »
- changer le site afin que les « non clients » deviennent « clients »
- e.g. changer des hyper liens entre certaines pages

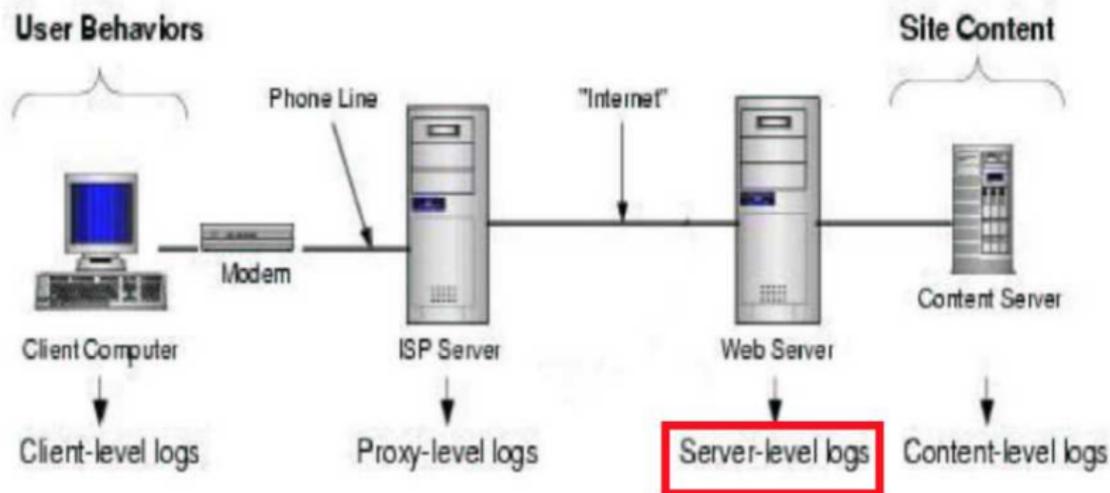
# Web Usage Mining

- 75% des Français achètent une raquette de tennis et moins de trois après, des chaussures de sports.
- hyper lien dynamique



# Log ou logs

Informations sur les chemins de navigations sont disponibles dans des fichiers de logs



# Web logs

IP or domain name      User Id      Date and Time      Request

123.456.78.9 - - [24/Oct/1999:19:13:44 -0400] "GET /Images/tagline.gif HTTP/1.0"

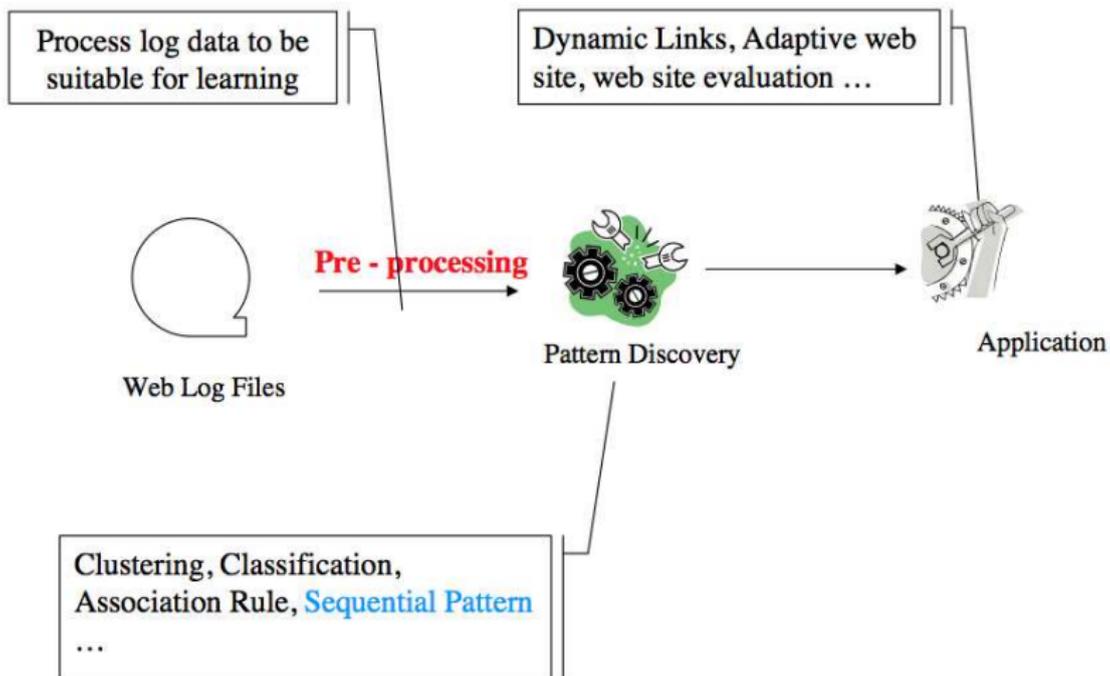
200 1449 <http://www.teced.com/> "Mozilla/4.51 [en] (Win98;l)"

Status      File Size      URL      Browser      Cookies

# Web logs

IP Address	Time	Method/URL/Protocol	Sta	Size	Referred	Agent
123.456.78.9	[25/Apr/1998:03:04:41 -0500	GET A.html HTTP/1.0	20 0	3290	-	Mozilla/3.01 (Win95, I)
123.456.78.9	[25/Apr/1998:03:05:34 -0500	GET B.html HTTP/1.0	20 0	2050	A.html	Mozilla/3.01 (Win95, I)
123.456.78.9	[25/Apr/1998:03:05:39 -0500	GET L.html HTTP/1.0	20 0	4130	-	Mozilla/3.01 (Win95, I)
123.456.78.9	[25/Apr/1998:03:06:02 -0500	GET F.html HTTP/1.0	20 0	5096	B.html	Mozilla/3.01 (Win95, I)
123.456.78.9	[25/Apr/1998:03:06:58 -0500	GET A.html HTTP/1.0	20 0	3290	-	Mozilla/3.01 (X11, I, IRIX6.2, IP22)
123.456.78.9	[25/Apr/1998:03:07:42 -0500	GET B.html HTTP/1.0	20 0	2050	A.html	Mozilla/3.01 (X11, I, IRIX6.2, IP22)
123.456.78.9	[25/Apr/1998:03:07:55 -0500	GET R.html HTTP/1.0	20 0	8140	L.html	Mozilla/3.01 (Win95, I)
123.456.78.9	[25/Apr/1998:03:09:50 -0500	GET C.html HTTP/1.0	20 0	1820	A.html	Mozilla/3.01 (X11, I, IRIX6.2, IP22)
123.456.78.9	[25/Apr/1998:03:10:02 -0500	GET O.html HTTP/1.0	20 0	2270	F.html	Mozilla/3.01 (Win95, I)
123.456.78.9	[25/Apr/1998:03:10:45 -0500	GET J.html HTTP/1.0	20 0	9430	C.html	Mozilla/3.01 (X11, I, IRIX6.2, IP22)

# KDD for WUM



## Filtrage, nettoyage

- Status code (1xx : Informational, 2xx : Success, 3xx : Redirection, 4xx : Client Error, 5xx : Server Error)
- Requêtes automatiques (bots, performance monitoring systems)
- Supprimer toutes les entrées représentant des requêtes pour des objets graphiques, etc.
- Supprimer les entrées générées par des spiders/crawlers (google, etc.)

## User Identification - Session Identification

- Comment identifier un utilisateur unique ? une transaction d'un utilisateur ?
- Pb :
  - Les identifiants des utilisateurs sont souvent supprimés par mesure de sécurité
  - Les adresses IP sont parfois cachées derrière des proxy
  - → web logs pas toujours fiables

## User Identification - Session Identification

- Comment identifier un utilisateur unique ? une transaction d'un utilisateur ?
- Pb :
  - Les identifiants des utilisateurs sont souvent supprimés par mesure de sécurité
  - Les adresses IP sont parfois cachées derrière des proxy
  - → web logs pas toujours fiables
- Solutions : identification du client, cookies côté client, etc.

## Identifier une session

Temps de navigation :

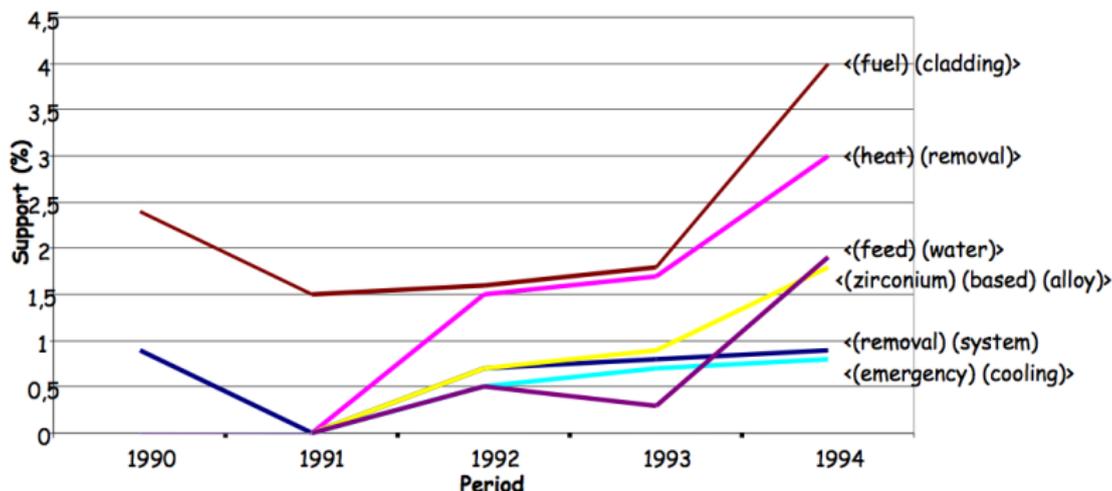
- Durée totale d'une session ( $\leq 30$  minutes)
- Durée par page ( $\leq 10$  minutes par page)

Sources de données :

- fichiers logs
- mais aussi cookies, bd d'utilisateurs (clients)

# Analyse de tendance avec des motifs séquentiels

Patents « Induced Nuclear Reactions:  
Processes, Systems and Elements »



# Outline

- 1 Introduction
- 2 Définitions
- 3 Algorithmes
- 4 Web Usage Mining
- 5 Conclusions**

# Nouveaux challenges

- privacy preserving mining (k anonymous sequential patterns)
- d'autres types de motifs (arbres, graphes)
- motifs séquentiels inattendus
- motifs séquentiels dans les flux de données.