



Extension des BDI

**pour la découverte de chroniques
avec contraintes temporelles**

Introduction

- Fouille de données temporelles
 - Complexité dûe à l'introduction du temps numérique
- Base de données inductives
 - Un cadre formel de la fouille de données




intégrer le temps dans une BDI

Plan



- Introduction
- Présentation générale de la fouille de données temporelles
- Base de données inductive et chroniques
 - Relation d'ordre - fréquence
- Traitement d'une requête
 - Algorithme de Mitchell
 - FACE : un outil de fouille de données temporelles

Fouille de données temporelles (1)

A partir d'une séquence d'évènements :
une liste ordonnée d'occurrences
d'évènements



On découvre des motifs



Fenêtre = 6

• [Manilla et al. 1997]

Fouille de données temporelles (2)

Techniques de la fouille de données
« classiques »

- Itemset \Leftrightarrow Ensemble d'évènements
- Intérêt d'un motif essentiellement basé sur la fréquence.

Date	Enregistrement
1	A, B
2	C
5	A, C

Base de données inductive

[L. De Raedt]

Une formalisation de la fouille de données

Base de données « classique » : pas de motifs

Base de données inductive : Une base de données
et une base de motifs

- La fouille de données est vue comme un processus d'extraction par **requête**

Exemple de requêtes sur les motifs et les données :

- $\text{Fréquence}(m, D_1) > T_{\min}$
- $\text{Fréquence}(m, D_2) < T_{\max}$
- $\text{Sous-motif}(m, M_1)$
- $\text{Sous-motif}(M_1, m)$

m : motifs cibles à déterminer
 D_1, D_2 : données
 T_{\dots} : fréquence
 M_1 : motifs

Notre approche :



Intégrer une notion numérique du temps dans les BDI

- Les bases de données inductives actuelles n'intègrent pas de notion numérique du temps

[Lee et De Raedt 2002, Dzeroski 2002, Imielinski et Manilla 1996]




Les données : des séquences d'évènements



Les motifs : des chroniques

Les motifs temporels : les chroniques




- Une chronique : Ensemble d'évènements contraints temporellement
- Une contrainte : $[a,b]$ tel que $a,b \in \mathbb{Z}$

Relation de généralité

- C plus générale que C' ($C \sqsubseteq C'$)

\Leftrightarrow


Il existe un sous-graphe de C' tel que les contraintes de C sont égales ou plus larges que celles de ce sous-graphe.



Fréquence et relation d'ordre


Contrainte monotone

- Ex : $\text{freq}(m, D) \leq T$
 - $C \in m \wedge C' \sqsubseteq C \Rightarrow C' \in m$
 - $\text{Freq}(C') \leq \text{Freq}(C)$





Contrainte anti-monotone

- Ex : $\text{freq}(m, D) \geq T$
 - $C \in m \wedge C' \sqsubseteq C \Rightarrow C' \in m$
 - $\text{Freq}(C') \geq \text{Freq}(C)$



Fréquence d'une chronique



$$I_C(D) = \{i_1, i_2, i_3, i_4, i_5, i_6\}$$

Critère de reconnaissance Q

- $\text{Freq}(C, D) = |E|, E \subseteq I_C(D), Q(E)$


E est unique

(Anti)monotonie des contraintes sur la fréquence

Exemple, $Q_{d\&t}$: critère d'instances disjointes au plus tôt

- $E = \{i_1, i_3, i_6\}$ et $F(C, D) = 3$


Traitement d'une requête



Calcul des bords de l'espace des versions

$$\text{freq}(m, D_1) \geq \mathcal{T}_1 \wedge \text{freq}(m, D_2) < \mathcal{T}_2$$

- Algorithme de Mitchell




FACE

Frequency Analyser for Chronicle Extraction

Séquence d'évènements



Chroniques
représentatives




Principe :

- $\text{Freq}(m, D) \geq \mathcal{T}$
 - Contrainte Anti-monotone
 - Une chronique peut être fréquente si toutes ses sous-chroniques sont fréquentes.

Algorithme général de FACE

Adaptation de l'algorithme *A PRIORI*




FACE...

...Un outil de fouille de données

- Optimisé pour la génération d'un nombre minimum de chroniques
 - Synthèse efficace \neq recherche des CMFs
- Un extracteur complet et correct d'instances !
 - À partir des instances reconnues on peut retrouver les chroniques maximalement spécifiques et fréquentes (CMFs)

Algorithme modifié de FACE



Raffinage pour résultats

- ⇔ Recherche des motifs fréquents sur des données numériques

- Très coûteux : en temps, en espace

- Introduction d'un nouveau critère d'intérêt : la densité

- Meilleure caractérisation des chroniques intéressantes
- Réduction du nombre de CMFs

- Utilisation et adaptation d'algorithmes de clustering

- Basé sur la densité, algorithmes hiérarchiques...

Conclusion

- Extension des BDIs à la recherche de motifs intégrant une notion temporelle
 - Nécessité de calculer seulement les CMFs de chaque séquence d'évènements
- Formalisation de la notion de chronique
 - Relation d'ordre
 - Fréquence, critère de reconnaissance
- Utilisation d'un outil de fouille de données existant : FACE


Perspectives

- Poursuivre la réalisation des bases de données inductives étendues au temps
- Utilisation d'autres mesures d'intérêt
 - Fréquence sans critère de reconnaissance
 - Autre que la fréquence
- Application dans le domaine de la détection d'intrusions dans les réseaux de télécommunications




Extension des BDI

pour la découverte de
chroniques avec contraintes
temporelles




Raffinage pour résultats

- Une instance \Leftrightarrow un point
- Une chronique \Leftrightarrow un hypercube
- Rechercher les hypercubes minimaux englobant au moins \mathcal{T} points



- Très coûteux
 - En temps
 - En espace
- Recherche des motifs fréquents sur des données numériques

Densité des CMFs (1)



Chronique intéressante :

- Fréquente
- Maximalement spécifique
- **dense**

Densité des CMFs (2)

- Utilisation et adaptation d'algorithmes de clustering
 - Basé sur la densité, algorithmes hiérarchiques...
- Réduction du nombre de CMFs
- Meilleure caractérisation des chroniques intéressantes