Mining Frequent Patterns in Data Streams at Multiple Time Granularities

Chris Giannella, Jiawei Han, Jian Pei, Xifeng Yan, Philip S.Yu

2002

www-faculty.cs.uiuc.edu/~hanj/pdf/fpstm03.pdf

2008年10月08日
論文ゼミ
M1　武智環

概要

- 頻出パターンのマイニングは，広く研究されてきているが，流動的なデータだと難しい.
- 最初ほとんど確認されないパターンでも，データが集まっていけば，頻出パターンとなったりする.

- FP-Streamを用いている

既往の研究

- 頻出パターンのマイニングは多くのアルゴリズムがある
  - **Apriori** [Agrawal & Srikant 1994]
  - **FP-growth** [Han, Pei & Yin 2000]
  - **FP-tree** [Han, Pei & Yin 2000]
  - **CLOSET** [Pei, Han & Mao 2000]
  - **CHARM** [Pei, Han & Yin 2002]

パターンの定義

- パターンのカテゴリを3つに分ける
  - 　　頻出パターン　　＞σ
  - σ＞時々起こるパターン＞ε
  - 　　不定期パターン

Support = 出現パターン／扱うデータ
min_support=σ
maximum support error = ε

- FP-Streamを構成する2つのもの
  - メインの記録から得られる全体的な頻出パターン
  - Pattern-treeに埋め込まれた「tilted-time window」

時間の影響を受ける頻出パターンのマイニング

- 比較的最近の詳細なデータへの興味
- 長期間の変化をみるとデータが粗くなる
- 「今」に近いほど精度がいい
- 精度を求めると，データの期間が短く，データの長さを求めると，精度が落ちる

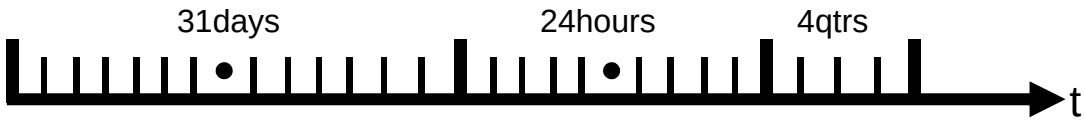

Natural Tilted-Time Windows Frames

Frequent Pattern for Tilted-Time Windows

- 先の時系列の中に，頻出パターンのデータを組み込むことで，過去の情報を保持したまま分析に使える

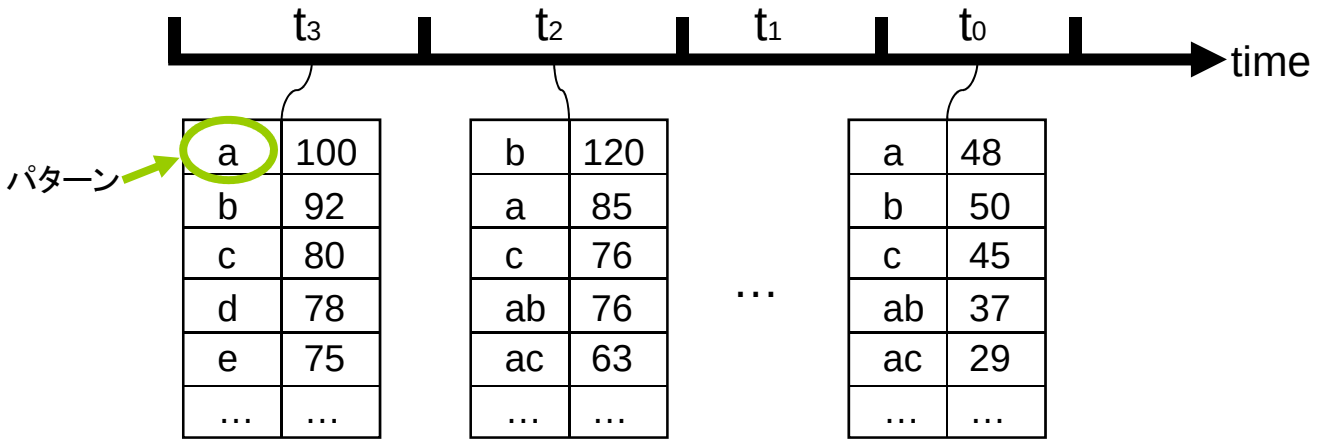

- t_2とt_3で頻出のパターンは何か？
- [a,b]が頻出なのはいつか？
- t_3とt_0の変化を裏付けるものは何か？
  - 過去のデータ同士の比較が可能
  - 頻出パターン毎に重み付けが可能

Pattern-treeの記述方法

pattern	support
a	100
b	92
c	80
ab	78
ac	75
bc	70
abc	63

Frequent Pattern

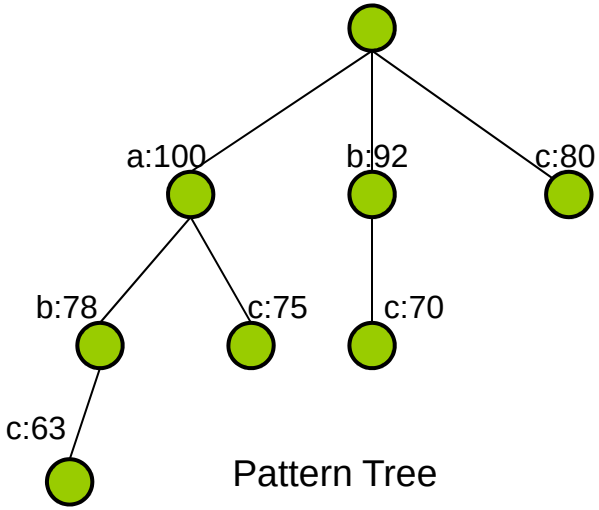

Pattern Tree

- ノード毎にパターンを示している
- 頻出パターンの記述が可能

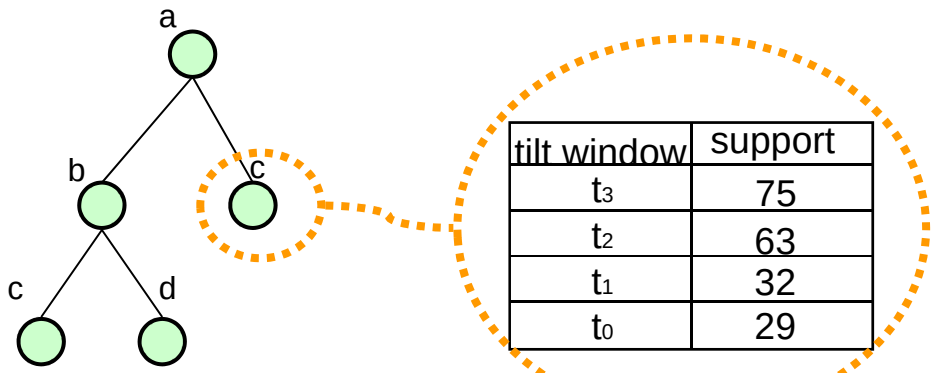

Pattern Tree

tilt window	support
t_3	75
t_2	63
t_1	32
t_0	29

Tilted-time Window Table

- それぞれのノードにTiletd-time Windowsを組み込むと簡潔

Logarithmic Tilted-time Window

$$\cdots\cdots 8\times\frac{1}{8},\quad 4\times\frac{1}{4},\quad 2\times\frac{1}{2}$$

$$366\times 24\times 4 = 35136$$

$$\log_2\left(365\times 24\times 4\right)+1\approx 17$$

$$\log_2\left(n\right)+1$$

•大量のデータであった場合も，対数をとることで，分析に用いやすくなる

$$i\geq j,\ B\left(i,j\right)$$

$$U_{k=j}^{i}B_k \qquad f_I\left(i,j\right)$$

itemset Iが与えられたとき，

$B(i,j)$の中のIの頻度

B : *fixedsized batches*

I : *given itemset*

$$f\left(n,n\right);\ f\left(n-1,n-1\right);\ f\left(n-2,n-3\right);\ f\left(n-4,n-7\right),\cdots$$

計算方法

$f(8,8);\ f(7,7);\ f(6,5);\ f(4,1)$

Level0 Level1 Level2 Level3

B9

$f(9,9);\ f(8,8);\ [f(7,7)];\ f(6,5);\ f(4,1)$

Level0 Level1 Level2 Level3

$$f(8,7) = f(8,8) + f(7,7)$$

B10

$f(10,10);\ f(9,9);\ f(8,7);\ [f(6,5)];\ f(4,1)$

Level0 Level1 Level2 Level3

B11

$f(11,11);\ f(10,10);\ [f(9,9)];\ f(8,7);\ [f(6,5)];\ f(4,1)$

Level0 Level1 Level2 Level3

B12

$f(12,12);\ f(11,11);\ f(10,9);\ f(8,5);\ [f(4,1)]$

入力データがなくなったら終了

Algorithm

- 1. FP-treeのなかを空にする
- 2. 頻度を下げるようなitemの集合（f_list）
  - f_listによって得られるデータを途切れることなく，FP-treeに入れていく
- 3. 全てのデータが入ったら，FP-treeを更新する
  - FP-treeは，FP-streamを使ってる

結果

Data

- ■Number of pattern:**10000**
- ■Average length of the maximal pattern:**4**
- ■Correlation coefficient between pattern:**0.25**
- ■Average confidence in a rule:**0.75**
- ■Support threshold:**σ** （サポート閾値）

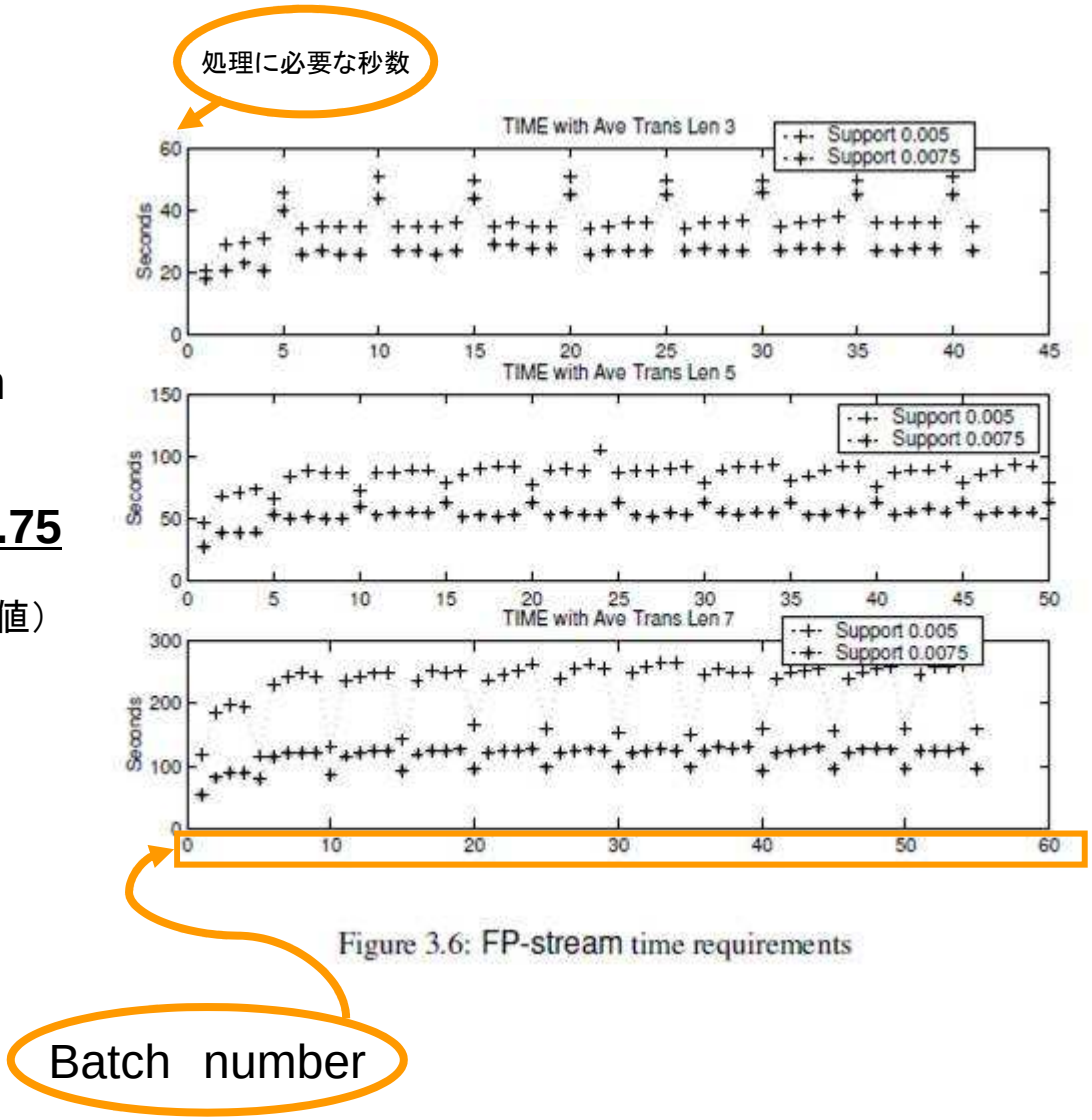

Figure 3.6: FP-stream time requirements

まとめ

- 過去の頻度の高いパターンの情報を保持したまま，現在のデータとの分析を行った.
- FP-treeベースの，頻出パターンの抽出法を示した.