

不確実データベースからの 負の相関ルールの抽出

情報システム解析学科4年

藤田岳行

ソーシャルネットワーク
センサーネットワーク

個人情報保護

データの正確性


不確実データの増加

不確実データベースの分析への要求増


分析手法の拡張を提案

既存研究との関係

表現の拡張




不確実データベースへの対応




目次


- 相関ルール
 - 負の相関ルール
 - 確率的相関ルール
 - 確率的負の相関ルール
 - 定義と計算方法
 - 探索の方針
 - 実験と結果
 - まとめ
- } 既存研究



不確実データベースへの対応



相関ルール



2つの集合の共起をルールで表したものの



評価基準

支持度(同時確率)

$$\text{sup}(\underline{X} \Rightarrow \underline{Y})$$

確信度(条件付き確率)


$$\text{conf}(\underline{X} \Rightarrow \underline{Y})$$

前件

後件


* 前件Xおよび後件Yは集合

$$\text{sup}(X \Rightarrow Y)$$



支持度とはパターンが出現した数である

$$\text{conf}(X \Rightarrow Y)$$



確信度とは前件が出現したうち後件が出現する確率である

有効な相関ルールの定義



$$\text{conf}(X \Rightarrow Y) \geq \underline{\text{mc}}$$

$$\text{sup}(XY) \geq \underline{\text{ms}}$$

mc(最小確信度),ms(最小支持度)は
ユーザーが任意に定める閾値

支持度において $X \Rightarrow Y$ と XY は同じである

不確実データベースへの対応



負の相関ルール

出現(X)と否出現($\neg X$)の組み合わせをルールとして表したものの

$$\begin{array}{l} X \Rightarrow \neg Y \\ \neg X \Rightarrow Y \\ \neg X \Rightarrow \neg Y \end{array}$$

有効な負の相関ルールの定義

$$\text{conf}(X \Rightarrow \neg Y) \geq \underline{\text{mc}}$$

$$\text{sup}(X \neg Y) \geq \underline{\text{ms}}$$



$$\text{sup}(X) \geq \underline{\text{ms}} \wedge \text{sup}(Y) \geq \underline{\text{ms}}$$

$$\text{sup}(XY) < \underline{\text{ms}}$$

mc(最小確信度),ms(最少支持度)は
ユーザーが任意に定める閾値

不確実データベースへの対応

表現の拡張



確率的相関ルール

確率的相関ルールとは不確実データベースを対象とした相関ルール

What is 不確実データベース？

データが存在するか否かの確率(**存在確率**)を持つデータベース

不確実データベースの種類

アイテムに基づく不確実データベース

ID	アイテムセット
T ₁	{イチゴ:24%, トマト:33%}
T ₂	{イチゴ:11%, バナナ:27%, みかん:76%}

トランザクションに基づく不確実データベース

ID	アイテムセット	%
T ₁	{イチゴ, トマト, バナナ, ブドウ, リンゴ}	24
T ₂	{イチゴ, バナナ, みかん, リンゴ}	47
T ₃	{トマト, バナナ, みかん}	29

可能世界意味論

可能世界とは？

- 可能世界意味論(possible world semantics)
- 存在確率に従い複数の世界を考える
 - 各データが存在する世界と存在しない世界に分ける
 - 各世界が確率的に存在する

可能世界による場合分け


	ID	T_1	T_2	確率 (%)
アイ	w_1	{ イチゴ, トマト }	{ イチゴ, みかん }	6.67
	w_2	{ イチゴ, トマト }	{ イチゴ }	2.59
	w_3	{ イチゴ, トマト }	{ みかん }	7.83
	w_4	{ イチゴ, トマト }	{ }	7.83
	w_5	{ イチゴ }	{ イチゴ, みかん }	14.18
	w_6	{ イチゴ }	{ イチゴ }	5.51
	w_7	{ イチゴ }	{ みかん }	12.76
	w_8	{ イチゴ }	{ }	4.07
W	w_9	{ トマト }	{ イチゴ, みかん }	3.92
	w_{10}	{ トマト }	{ イチゴ }	1.52
	w_{11}	{ トマト }	{ みかん }	4.60
	w_{12}	{ トマト }	{ }	1.79
	w_{13}	{ }	{ イチゴ, みかん }	8.33
	w_{14}	{ }	{ イチゴ }	2.66
	w_{15}	{ }	{ みかん }	9.78
	w_{16}	{ }	{ }	3.24

イチゴの支持度は？

ID	T_1	T_2	確率 (%)	
w_1	<u>{ イチゴ, トマト }</u>	<u>{ イチゴ, みかん }</u>	6.67	sup(イチゴ)=2
w_2	{ イチゴ, トマト }	{ イチゴ }	2.59	
w_3	<u>{ イチゴ, トマト }</u>	<u>{ みかん }</u>	7.83	sup(イチゴ)=1
w_4	{ イチゴ, トマト }	{ }	7.83	
w_5	{ イチゴ }	{ イチゴ, みかん }	14.18	
w_6	{ イチゴ }	{ イチゴ }	5.51	
w_7	{ イチゴ }	{ みかん }	12.76	
w_8	{ イチゴ }	{ }	4.07	
w_9	{ トマト }	{ イチゴ, みかん }	3.92	
w_{10}	{ トマト }	{ イチゴ }	1.52	
w_{11}	<u>{ トマト }</u>	<u>{ みかん }</u>	4.60	sup(イチゴ)=0
w_{12}	{ トマト }	{ }	1.79	
w_{13}	{ }	{ イチゴ, みかん }	8.33	
w_{14}	{ }	{ イチゴ }	2.66	
w_{15}	{ }	{ みかん }	9.78	
w_{16}	{ }	{ }	3.24	


評価尺度

確率(%)



イチゴの支持度

支持度は確率変数となる




評価尺度

パターンXが支持度*i*以上である確率

$$P_{\geq i}(X) = \sum_{w_j \in W, (S(X, w_j) \geq i)} P(w_j)$$

$S(X, w_j)$ は世界 w_j におけるパターンXの支持度

評価尺度

$$P_{\geq ms}(X) = \sum_{w_j \in W, (S(X, w_j) \geq ms)} P(w_j) \geq mp$$


ユーザーの定めた閾値ms, mpを満たすものを
確率的頻出パターンと言う

確率的相関ルール

普通の相関ルールは...

支持度同様に確率を考慮すると...



$$P \left[\begin{array}{l} \text{conf}(XY) \geq mc \\ \text{sup}(XY) \geq ms \wedge \end{array} \right] = \sum P(w_j)$$

w_j は条件を満たす世界

可能世界に展開することで計算可能

不確実データベースへの対応

表現の拡張



確率的負の相関ルール

この定義を満たすもの計算するために
式変形を行う

$$\begin{aligned}
 & \left[\text{cum}(V \rightarrow \neg V) > mc \wedge \neg \right] \\
 P(X \Rightarrow \neg Y) \\
 &= \sum_{i=ms}^N P_i(X \neg Y) \sum_{j=0}^{\min(ms-1, \frac{(1-mc) \cdot i}{mc})} P_j(XY) \sum_{k=ms-j}^N P_k(\neg XY)
 \end{aligned}$$

既存研究を用いて可能世界に展開することなく
計算可能！

探索の方針

$$P \left[\begin{array}{l} \sup(X \Rightarrow \neg Y) \geq ms \wedge \\ \text{conf}(X \Rightarrow \neg Y) \geq mc \wedge \\ \sup(X) \geq ms \wedge \\ \sup(Y) \geq ms \wedge \\ \sup(XY) < ms \end{array} \right]$$

定義の一部に着目し前件,後件の条件に

$$P_{\geq ms}(X) \geq mp$$


$$P_{\geq ms}(Y) \geq mp$$

前件,後件共に確率的頻出なパターンのみを対象にする。


木構造の探索

- 既存手法により確率的頻出パターンを抽出
- 抽出されたパターンを木に配置

前件



後件



実験結果

- Java言語を用いて実装
- 利用したデータ
 - Frequent Itemset Mining Dataset Repository から入手したretail データ
1000件(ms:10,mp:0.2,mc:0.2),227個,1997秒
 - twitterより入手したツイートのデータ
1000件(ms:10,mp:0.2,mc:0.2),607個,7987秒
 - TaFengDataset より入手した買い物データ
1000件(ms:5,mp:0.2,mc:0.2),8632個,25382秒

実験結果

$$X \Rightarrow \neg Y$$

前件

後件

フォロー



ます,おはよう

楽天



裏ワザ

楽天,本



私

相互,初心者



♪

月,年



おはよう,ます

まとめ

- 不確実データベースから確率的負の相関ルールの抽出方法を提案した
- 提案に沿って実装をし,実験を行い結果を得た

今後の課題

もう一つの形式の不確実データベースに対して同様の計算及び実装や,実装面では並列計算による高速化が可能であるかを検証が必要.