

文章编号:1004-1478(2011)04-0068-04

基于兴趣度剪枝的 Apriori 优化算法

刘上力, 杨清

(湖南科技大学 网络信息中心, 湖南 湘潭 411201)

摘要:鉴于关联规则挖掘中的 Apriori 算法在挖掘潜在有价值、低支持度模式时效率较低,因此提出一种优化的 Apriori 挖掘算法,即在频繁项集挖掘中引入项项正相关兴趣度量剪枝策略,有效过滤掉非正相关长模式和无效项集,从而扩大了可挖掘支持度阈值范围。实验结果表明,该算法是有效和可行的。

关键词:Apriori 算法; 频繁项集; 兴趣度; 项项正相关; 剪枝

中图分类号:TP392 **文献标志码:**A

Optimized Apriori algorithm based on interestingness measure pruning

LIU Shang-li, YANG Qing

(Network Infor. Center, Hunan Univ. of Sci. and Tech., Xiangtan 411201, China)

Abstract: To solve the problem that the Apriori algorithm of mining association rules in database mining is not quite effective in the process of mining potentially valuable low-support patterns, an optimized apriori mining algorithm was proposed. This algorithm exploits an efficient pruning strategy which uses the interestingness measure to filter the non-positive correlated long model and invalid itemsets. The range of support threshold is expanded. The experimental results indicated that the given algorithm was efficient and feasible.

Key words: Apriori algorithm; frequent itemset; interestingness measure; between-items positive correlation; pruning

0 引言

关联规则^[1]是数据挖掘的重要研究领域,它包括频繁项集挖掘和关联规则发现 2 个过程,挖掘的总体性能主要由频繁项集挖掘决定。R. Agrawal 等^[2]在 1993 年首次提出 Apriori 算法,该算法是布尔关联规则挖掘频繁项集的原创性算法,它通过连接和剪枝操作生成频繁项集,此后出现的各种类

Apriori 算法大多利用这种策略来提高频繁项集挖掘效率。但对于低支持度下大型稠密数据库的频繁项集,由于频繁项集数量和长度的急剧增长,利用 Apriori 算法和类 Apriori 算法则难以挖掘。

本文拟结合现有兴趣度方法^[3]和基于约束条件的项集剪枝思想^[4],提出新的兴趣度量度,即将兴趣度量嵌入到 Apriori 算法,实现频繁项集兴趣量度剪枝,以减少低兴趣度长模式频繁项集的生成。

收稿日期:2011-05-13

基金项目:湖南省教育厅重点科学项目(10A028);湖南省科技计划项目(JT3031)

作者简介:刘上力(1978—),男,湖南省湘潭市人,湖南科技大学工程师,硕士,主要研究方向为数据挖掘。

1 兴趣度量度

传统的关联规则一般采用支持度 - 置信度框架,这种框架容易产生无意义、冗余、甚至是误导的关联规则^[5~6]. 为了解决这些问题,研究者提出了兴趣度量度 $F(A, B)$. 兴趣度量结果可反映出 A (或 B) 的出现对 B (或 A) 的出现的提升程度. 兴趣度一般分为客观兴趣度、主观兴趣度和基于语义的兴趣度 3 种^[7]. 其中,客观兴趣度是研究和应用的重点.

研究者较早提出了客观兴趣度是提升度度量 $lift(A, B) = P(A, B) / (P(A)P(B))$ ^[8], 其中 $P(A, B)$ 表示 A 与 B 并的概率(下同), 用于评估一个出现“提升”另一个的程度. 随后,研究者提出了多种兴趣度,但对于应用而言,能适用各类挖掘要求和场合的兴趣度是不存在的^[7]. 本文提出一种新的兴趣度.

设 $I = \{I_1, I_2, \dots, I_m\}$ 为 m 个不同项的集合, 给定 l 条事务的数据库 $D = \{T_1, T_2, \dots, T_l\}$, 其中, $T \in I$.

定义 1 对于项集 $X \in I$, X 在 D 中支持度计数是指 D 中 X 的事务数, 记为 $X.count$, 则称 $X.sup = P(X) = X.count/l$ 为 X 在 D 中的支持度.

定义 2 若 $X.sup \geq minsup$ (最小支持度阈值), 则 X 为 D 的频繁项集.

定义 3 给定一个项集 $X = A \cup B$, 兴趣度量 $F(A, B)$ 定义为

$$F(A, B) = \frac{(P(A, B) - P(A, \neg B) + P(\neg A, B) - P(\neg A, \neg B))/2}{P(A) + P(B)} \quad ①$$

它主要考察项集并集概率与其中一项不出现时的并集概率的差异, 这种差异反映了项集间真正的蕴含关系. 分母作为标准因子, 使得量度值仅受 A, B 和 AB 概率的影响, 而不受事务总个数的影响; 分子中的算术均值运算对于量度值间的比较没有意义, 可忽略. 由于 $P(A, \neg B) = P(A) - P(A, B)$, $P(\neg A, B) = P(B) - P(A, B)$, 可得到①的简化式

$$F(A, B) = \frac{4P(A, B)}{P(A) + P(B)} - 1 \quad ②$$

为有效控制规则数量并保证规则质量, 文献[8]总结了评价兴趣度量标准的 7 个原则:

1) 如果 A 和 B 统计独立, $F(A, B) = 0$;

- 2) 其他参数不变时, $F(A, B)$ 随 $P(A, B)$ 单调递增;
- 3) 其他参数不变时, $F(A, B)$ 随 $P(A)$ 或 $P(B)$ 单调递减;
- 4) A, B 置换时, $F(A, B)$ 应保持不变;
- 5) 零不变性, 即不包含 A, B 的记录的增减对 $F(A, B)$ 结果应没有影响;
- 6) 兴趣度阈值的范围应该是固定的;
- 7) 兴趣度的语义表达应该是容易理解的.

这些原则可作为评价相关度量的依据. 表 1 为定义 3 给出的兴趣度量度与置信度、全置信度^[3]、提升度之间依据以上原则给出的评估分值对比. 结果表明, 定义 3 给出的兴趣度得分最高, 其中, 遵循原则的给 1 分, 否则记 0 分.

表 1 不同量度间的评估对比

原则	置信度	全置信度	提升度	本文量度
1)	0	0	0	0
2)	1	1	1	1
3)	1	1	1	1
4)	0	1	1	1
5)	1	1	0	1
6)	1	1	0	1
7)	1	0	1	1
合计	5	5	4	6

表 2 给出了一组事务数据集, 以及对应的相依表和 4 种量度的值. A 和 B 在数据集 $D_1 \sim D_2$ 正相关, 在 D_3 中属于并发关系, 统计独立, 在 $D_4 \sim D_7$ 负相关. 对于独立情况, 除了提升度外, 其余 3 种度量都是好的指示器, 除此以外, 置信度由于忽略了 $P(B)$ 的影响, 在 D_6 上出现误导; 全置信度表现较好, 但仅考虑最小置信度, 在 D_4 和 D_5 间无法区别相关程度; 提升度因不具备零不变性, 受零事务影响误差较大; 只有本文提出的量度在所有数据集中均有较好表现, 不受零事务影响, 正负相关判断准确, 取值范围规范.

2 频繁项集挖掘算法

挖掘者往往根据应用的不同而选择特定相关量度, 例如求解关联束挖掘^[9]、前后项集对称型应用等问题, 需要量度规则中项项间正相关. 本文在 Apriori 挖掘算法中引入兴趣度, 实现了项项正相关

表 2 使用不同数据集的相依表比较 4 种量度

数据集	AB	$\neg AB$	$A \neg B$	$\neg A B$	置信度	全置信度	提升度	本文量度
D_1	1 000	100	100	100 000	0.91	0.91	83.64	0.82
D_2	1 000	100	100	10 000	0.91	0.91	9.26	0.82
D_3	1 000	1 000	1 000	10 000	0.50	0.50	3.25	0.00
D_4	100	1 000	1 000	100 000	0.09	0.09	8.44	-0.82
D_5	1 000	100	10 000	100 000	0.09	0.09	9.18	-0.67
D_6	10 000	100 000	1000	100 000	0.91	0.09	1.74	-0.67
D_7	0	10 000	100	100 000	0.00	0.00	0.00	-1.00

频繁项集的挖掘,同时,通过频繁项剪枝以提高算法的效率.

2.1 项项相关兴趣度

为适应频繁项兴趣度剪枝,对②式进行改进.

定义 4 给定一个项集 $X = \{i_1, i_2, \dots, i_n\}$, $n > 1$, 则 X 的项项相关兴趣度 $F'(X)$ 定义为

$$F'(X) = \min \left\{ \frac{4P(i_j, i_k)}{P(i_j) + P(i_k)} - 1 \mid \forall j, \forall k \in 1, \dots, n; j \neq k \right\}$$

该量度具有良好的性质: 1) 它具有稳定的上下界 $[-1, 1]$; 2) 具有良好的反单调性质, 可以利用该性质实现 Apriori 算法中频繁项集挖掘的项集剪枝, 以减少长模式和低兴趣度候选项集的产生; 3) 当 $F'(X) > 0$ 时, 可确保 X 中任意一项的发生均能提升 X 的其余项发生的概率, 表明 X 中的项两两正相关, 以该量度作为频繁项集剪枝的标准可得到项项正相关频繁项集. 下面给出该量度反单调性质的证明.

性质 1 当项集 $X' \subset X$, θ 为阈值, 如果 $F'(X') < \theta$, 则有 $F'(X) < \theta$, 即 $F'(X)$ 具有反单调性质.

证明 设 $X' = \{i_1, i_2, \dots, i_{n'}\}$, $X = \{i_1, i_2, \dots, i_n\}$, 则

$$\begin{aligned} F'(X) &= \min \left\{ \frac{4P(i_j, i_k)}{P(i_j) + P(i_k)} - 1 \mid \forall j, \forall k \in 1, \dots, n; j \neq k \right\} \\ &\leq \min \left\{ \frac{4P(i_j, i_k)}{P(i_j) + P(i_k)} - 1 \mid \forall j, \forall k \in 1, \dots, n'; j \neq k \right\} = \\ &F'(X') < \theta \end{aligned}$$

性质成立, 得证.

2.2 Apriori 频繁项集兴趣度剪枝算法

输入: 事务数据库 D , 最小支持度计数阈值 $minsup$, 最小兴趣度阈值 θ .

输出: D 中的频繁项集 L .

```

Begin
1)  $L_1 = \text{find\_frequent\_1\_itemsets}(D);$ 
2) for ( $k = 2; L_{k-1} \neq \varnothing; k++$ ) {
    $C_k = \text{apriori\_gen}(L_{k-1});$ 
   3) for each 事务  $t \in D$  // 扫描  $D$  用于计数
       $C_t = \text{subset}(C_k, t);$  // 得到  $t$  的子集
      for each 候选  $c \in C_t$ 
          $c.\text{count}++$ 
      }
      // 兴趣度剪枝,
      // 即  $F'(c) < \theta$  的候选  $c$  直接剪枝掉
   4)  $L_k = \{c \in C_k \mid c.\text{count} \geq \text{minsup}, F'(c) \geq \theta\}$ 
   }
5) return  $L = \bigcup_k L_k;$ 
End

procedure apriori_gen( $L_{k-1}$ )
1) for each 项集  $l_1 \in L_{k-1}$ 
   for each 项集  $l_2 \in L_{k-1}$ 
      if ( $l_1[1] = l_2[1] \wedge (l_1[2] = l_2[2] \wedge \dots \wedge$ 
          $(l_1[k-2] = l_2[k-2]) \wedge (l_1[k-1] < l_2[k-1])$ 
         then { $c = l_1 > < l_2$ ; // 连接步: 产生候选
            if has_infrequent_subset( $c, L_{k-1}$ ) then {
               delete  $c$ ; // 剪枝步: 删除非频繁候选
            } else add  $c$  to  $C_k$ ;
            }
      }
   2) return  $C_k;$ 
procedure has_infrequent_subset( $c, L_{k-1}$ )
1) For each  $(k-1)$ -subset  $s$  of  $c$ 
   If  $s \notin L_{k-1}$  then return TRUE;
2) return FALSE;

```

算法中,除了 Apriori 算法固有的连接和剪枝操作外,为了同步清除低兴趣度的频繁项集,在主程序的第 4 步中加入兴趣度剪枝,降低了频繁项集产生的规模,使得最终得到的频繁项集内都项项正相关.

3 实验测试

在 Pumsb_star 数据集^[10]上进行实验。测试环境为 P4 1.5 GHz 的 CPU 和 1 G 内存, Windows 2003 操作系统。Apriori 算法采用文献[1]的方法,考虑到程序移植性,采用 Java(jdk1.5)实现。

实验测试 Apriori 算法在引入项项正相关频繁项剪枝前后的执行性能。如图 1 所示,针对稠密数据库 Pumsb_star,加入兴趣度前,算法在低支持度阈值($minsup = 45\%$)以下难以有效挖掘频繁项集;加入兴趣度剪枝后,由于对低兴趣度的项集及时剪枝,精简了候选项集的空间,可设置的最小支持度阈值可降低到 10% 以内,另外,算法的整体执行效率也得到提高。

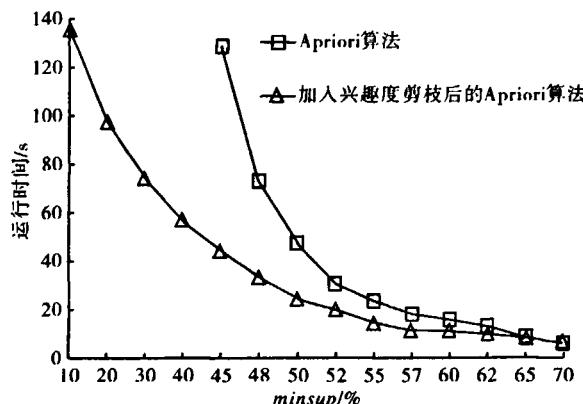


图 1 Pumsb_star 引入项项正相关兴趣度剪枝前后频繁项集挖掘效率对比

4 结语

本文提出一种具有反单调性质的项项正相关兴趣度,并将该量度引入到 Apriori 频繁项集挖掘算法中,通过 2 项集及 2 项以上集兴趣度剪枝,优化了项集空间,扩大了可挖掘支持度阈值范围,提高了挖掘效率。在真实数据库上进行实验对比,验证了

算法的可行性。

参考文献:

- [1] Jiawei Han, Micheline Kamber. Data Mining: Concepts and Techniques [M]. Second Edition. Beijing: China Machine Press, 2006:147–172.
- [2] Agrawal R, Imielinski T, Swami A. Mining association rules between sets of items in large databases [C]//Proc of the ACM SIGMOD Conf on Mana of Data (SIGMOD'93), New York: ACM Press, 1993:207–216.
- [3] Omiecinski E. Alternative interesting measures for mining associations [J]. IEEE Trans Knowledge and Data Eng, 2003, 15:57.
- [4] 李英杰. 项约束频繁项集挖掘的新方法 [J]. 计算机工程与应用, 2009, 45 (3):161.
- [5] 张玉芳, 熊忠阳, 彭燕, 等. 基于兴趣度含正负项目的关联规则挖掘方法 [J]. 电子科技大学学报, 2010, 39 (3):407.
- [6] 王艳, 刘双红, 李玲玲. 基于加权关联规则的选课推荐系统的构建 [J]. 郑州轻工业学院学报: 自然科学版, 2009, 24(5):44.
- [7] Geng L Q, Hamilton H J. Interestingness measures for data mining: A survey [J]. ACM Comp Surveys, 2006, 38 (3):9.
- [8] Brin S, Motwani R, Silverstein C. Beyond market baskets: generalizing association rules to correlations [C]//Proc ACM SIGMOD Int Conf on Mana of Data, Tucson: ACM Press, 1997:265–276.
- [9] Huang Wenzhe, Krneta Milorad, Lin Limin, et al. Association bundle—A new pattern for association analysis [C]//Sixth IEEE Int Conf on Data Mining Workshops (ICDMW'06) Washington: IEEE Computer Society, 2006:601–605.
- [10] FIMI. Frequent Itemset Mining Dataset Repository [EB/OL]. (2003-11-19) [2011-03-08]. <http://fimi.cs.helsinki.fi/data/>, 2003.