

文章编号: 1001-0920(2003) 03-0272-05

基于 SVM 的二叉树多类分类算法 及其在故障诊断中的应用

马笑潇, 黄席樾, 柴毅
(重庆大学 自动化学院, 重庆 400044)

摘要: 基于结构风险最小化原则的支持向量机(SVM)对小样本决策具有较好的学习推广性。但由于常规 SVM 算法是从 2 类分类问题推导出的, 在解决故障诊断这种典型的多类分类问题时存在困难, 因而提出一种依赖故障优先级的基于 SVM 的二叉树多级分类器实现(2PTMC)方法, 该方法具有简单、直观, 重复训练样本少的优点。通过将其应用于柴油机振动信号的故障诊断, 获得了令人满意的效果。

关键词: 支持向量机; 故障诊断; 二叉树

中图分类号: TK428

文献标识码: A

2PTMC classification algorithm based on support vector machines and its application to fault diagnosis

MA Xiao-xiao, HUANG Xi-yue, CHAI Yi

(College of Automation, Chongqing University, Chongqing 400044, China)

Abstract: Support vector machines is a new general machine learning tool based on structural risk minimization principle that exhibits good generalization. Fault diagnosis based on support vector machines is discussed. Since SVM was originally designed for binary classification, while most of fault diagnosis problems are multi-class cases, a new multi-class classification named 2PTMC is presented. This classifier is a binary tree classifier composed of several SVMs organized by fault priority, which is simple and has little duplicating training samples. The application to fault diagnosis for diesel engine shows the effectiveness of the method.

Key words: Support vector machines; Fault diagnosis; Binary tree classifier

1 引言

传统的统计学所研究的是渐进理论, 即当样本趋向于无穷大时的极限特性。然而实际中, 样本数目通常是有限的, 因此, 研究在小样本数据前提下的统计学习规律是一个非常具有实用价值的问题。

智能故障诊断面临的一个难题之一是故障特征知识的发现问题, 在要求不解体、实时诊断的情况下, 获取故障的大量有效样例更为困难。而常规的诊

断方法大都依赖于大样本情况下的统计特性, 当训练样本有限时, 难以保证有较好的分类推广性。基于统计学习理论的支持向量机(SVM)是在结构风险最小化原则的基础之上发展起来的通用学习方法。该方法通过将输入空间映射为高维特征空间, 从而有效地降低待求解问题的 VC 维, 寻求经验风险和置信范围的最小化。

本文针对 SVM 算法源于 2 类分类问题, 提出

收稿日期: 2002-01-14; 修回日期: 2002-04-30。

基金项目: 教育部高校博士点基金资助项目(99061116)。

作者简介: 马笑潇(1975—), 男, 山东临沂人, 博士生, 从事人工智能与模式识别和复杂系统智能故障诊断的研究; 黄席樾(1943—), 男, 重庆奉节人, 教授, 博士生导师, 从事人工智能与知识工程, 现代集成制造系统等研究。

了一种适合故障诊断的带故障优先级的二叉树多类分类方法。并将该方法应用于柴油机缸盖振动信号的故障诊断中, 收到了令人满意的诊断效果。

2 统计学习理论的基本观点

给定一个一般的学习问题: 在概率测度 $F(z)$ 未知情况下, 已知服从该分布的样本 z_1, z_2, \dots, z_l , 学习的目标是通过最小化风险泛函

$$R(\alpha) = \int Q(z, \alpha) dF(z), \quad \alpha \in \Lambda \quad (1)$$

估计概率分布 $F(z)$, 其中 $Q(z, \alpha)$ ($\alpha \in \Lambda$) 为损失函数集。对该问题的解决, 传统的学习方法采用了经验风险最小化 (ERM) 的准则, 即用样本定义经验风险准则

$$R_{\text{emp}}(\alpha) = \frac{1}{l} \sum_{i=1}^l Q(z_i, \alpha) \quad (2)$$

作为对式 (1) 的估计, 设计学习算法使其最小化。

以 $R_{\text{emp}}(\alpha)$ 代替 $R(\alpha)$ 并没有充分的根据。针对小样本问题, 统计学习理论提出了结构风险最小化原则 (SRM)^[1,2]。该理论认为: 根据有限已知样本进行一般问题估计的实际风险值, 不仅取决于经验风险最小化, 而且取决于由待估计问题的 VC 维决定的置信范围的大小, 即

$$R(\alpha) \approx R_{\text{emp}}(\alpha) + \Phi(h, l) \quad (3)$$

其中: $\Phi(h, l)$ 表示置信范围, h 为函数的 VC 维, l 为样本大小。

基于 SRM 原则, Vapnic 等人于 1995 年提出了支持向量机 (SVM) 的机器学习方法^[2]。

3 SVM 用于故障诊断的步骤

利用 SVM 进行故障分类包括学习和识别两个阶段。下面给出具体的实现步骤:

1) 学习阶段:

Step1: 根据专家经验或动态聚类结果, 建立训练样本集 $\{x_i, y_i\}, y_i \in \{1, -1\}$ 。

Step2: 选择合适的核函数 $K(x, x_i)$ 及有关参数, 作为高维特征空间在低维输入空间的一个等效形式。选择的根据是要求满足 Mercer 定理^[1]。核函数通常选择多项式函数、径向基函数或 Sigmoid 函数等。

Step3: 根据 Kernel 核函数的要求, 将输入样本正规化。

Step4^[1,2]: 在约束条件 $\sum_{i=1}^l \alpha_i y_i = 0, 0 \leq \alpha_i \leq C$ 下, 最大化

$$Q(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j K(x_i, x_j)$$

以求解拉格朗日系数 α 。现已有几种快速算法^[3,4] 来解决该问题。

Step5: 找出支持向量 sv , 求解分类超平面系数 b 。

Step6: 建立训练数据的最优决策超平面, 训练结束。

2) 识别阶段:

Step1: 装入 SVM 学习阶段的有关数据(包括 $\{x_i, y_i\}, \alpha, b, sv$)。

Step2: 据式 $f(x) = \sum_{\text{支持向量}} y_i \alpha_i K(x_i, x) - b$, 计算新输入特征数据 x 的决策输出值。

Step3: 利用指示函数, 将 $f(x)$ 归为 $\{-1, 1\}$, 作出分类决策。

SVM 机器学习方法的本质是能够在有限特征信息的情况下, 最大限度地发掘数据中隐含的分类知识。在训练阶段, 特征数据所隐含的各种故障特征知识是隐式地表达在样本中有限数目的支持向量及其相应的拉格朗日系数上。也就是说, 仅用支持向量就决定了分类器的性能。因此, SVM 具有良好的外推能力, 这对故障诊断而言具有很强的实际意义^[4]。

4 基于 2PTMC 的多级 SVM 分类器

SVM 算法是从 2 类分类问题推导出的, 在解决象故障诊断这种典型的多类分类问题时需要作一些处理(可认为这是 SVM 不如 ANN 的唯一一个方面)。目前, 将 SVM 机器学习方法延伸到多类分类问题还处于初步研究阶段^[5]。已提出的解决该问题的思路有: 1) 构造多个 2 类分类器并组合起来完成多类分类, 分成 "one against one" 和 "one against all" 两种类型^[8]。这种思路简单有效, 但存在无法识别的阴影区域, 而且重复训练的样本较多; 2) 只使用一个 SVM 实现多个分类输出 (all together)^[6], 这种思路涉及十分复杂的优化问题, 对训练样本数目相对较大时, 运算时间长而且误差较大^[5]。这里提出一种适合故障诊断的带故障优先级的二叉树多类分类方法 (2PTMC)^[4], 该方法属于第一大类, 但采用了一种 "one against others" 的分类器构造策略, 具有算法简单直观、重复训练样本少的优点。图 1 给出了 2PTMC 故障诊断结构。

下面给出算法说明。

给定一个 k 类分类问题, 学习样本为

$$(x_1, y_1), \dots, (x_l, y_l), \quad x_j \in R^n$$

$$j = 1, 2, \dots, l, \quad y_j \in \{1, 2, \dots, k\}$$

一个 2PTMC 结构是一个 4 元组 <http://www.cnki.net>

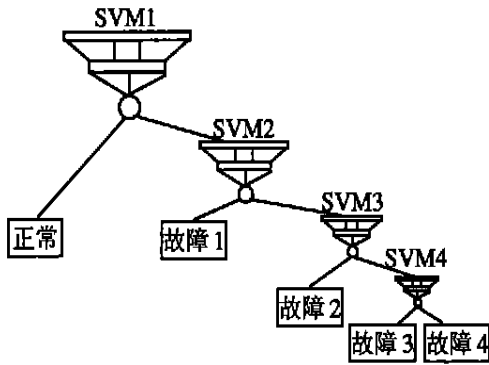


图 1 基于 SVM 的 2PTMC 故障诊断结构

$$F, P, SVM, SC \quad (4)$$

$F = \{f^1, \dots, f^i, \dots, f^k\}$, 是二叉树的终止节点集合, 由待识别系统的 k 个可能的故障模式集(包括正常状态) 构成。

$P = \{p^1, \dots, p^i, \dots, p^k\}$ 表示故障发生的优先级, 可根据各种状态发生频率的高低排序确定。最可能出现的状态优先级定为 p^1 , 发生可能性最低的状态定为最后一级 p^k 。 P 决定了 2PTMC 中多个支持向量机的安排方式。

$SVM = \{SVM_{p^1}, \dots, SVM_{p^i}, \dots, SVM_{p^{k-1}}\}$, 是由所设计的 $k - 1$ 个支持向量机组成的二叉树的全部非终止节点集合。对一个 k 类分类问题, 需要构造 $k - 1$ 个 SVM 机。其中第 i 个 SVM 决定的故障优先级为 p^i 。

$SC = \{SC_1, \dots, SC_i, \dots, SC_k\}$, 为属于 k 个故障状态类别的全部学习样本集合, 其中

$$SC_i = \{(x^1, y^i), \dots, (x^j, y^i), \dots, (x^l, y^i)\}$$

表示第 i 类的样本组成, $x^j \in R^n, y^i \in \{1, 2, \dots, k\}$ 。

$l_i = l$ 构成全部学习样本。

第 i 级支持向量 SVM_{p^i} 的训练样本 S_{p^i} 按下述原则确定。

$$\begin{cases} S_{p^1} = \text{全部样本} \\ S_{p^i} = \overline{SC^{k-1}}_{j=1}, \\ S_{p^i} = \overline{SC^i}_{j=1} \oplus SC_i, \end{cases} \quad i = 1, 2, \dots, k - 1 \quad (5)$$

$\overline{SC^i}_{j=1}$ 表示不属于第 $1, 2, \dots, i$ 类的样本全体。可见随优先级的降低, 训练样本数逐渐减少。

第 i 个 SVM 解决以下问题^[6]

$$\min_{\omega, b, \xi} \frac{1}{2} (\omega)^T \omega + C \sum_{j=1}^l \xi_j^i \quad (6)$$

如果 $y_j = i$, 则

$$(\omega)^T H(x_j) + b = 1 - \xi_j^i$$

如果 $y_j \neq i$, 则

$$(\omega)^T H(x_j) + b = -1 + \xi_j^i$$

其中: $\xi_j^i \geq 0, j = 1, 2, \dots, l, H(x_j)$ 是训练样本 x_j 在高维特征空间中的映射, C 是不可分情况下的惩罚因子, 以降低训练错误数目。

这样可得到 $k - 1$ 个决策函数

$$\begin{aligned} (\omega)^T H(x) + b_1 \\ \vdots \\ (\omega_{k-1})^T H(x) + b_{k-1} \end{aligned} \quad (7)$$

对每一级 SVM 训练后找出对应该级的支持向量, 建立最优分类超平面。由于 $k - 1$ 个 SVM 是按照优先级由高到低排列的, 新模式产生时, 只需按照二叉树由高到低进行搜索, 就可得出结论。

可见, 2PTMC 总体上属于基于 SVM 的多类策略中的第一大类, 相对于“one against all”和“one against one”策略, 大大降低了样本的重复训练量。下面给出证明:

对一个由 l 个训练样本组成的 k 个故障模式的分类问题, 2PTMC 的重复训练样本量是最小的。

R_{others} 定义为重复训练样本数与重复次数的乘积, 则

$$R_{others} = \sum_{i=2}^{k-1} l_i(i-1) + l_k(k-2), \quad k \geq 3 \quad (8)$$

“one against all”方法, 需要构造 k 个支持向量机, 重复训练样本量为

$$R_{all} = \sum_{i=1}^k l_i k - \sum_{i=1}^k l_i, \quad k \geq 3 \quad (9)$$

式中前一项为全部 k 类样本总的训练量, 后一项为训练一次的训练量, 二者相减即为重复量。

“one against one”方法需构造 $k(k - 1)/2$ 个支持向量机, 其重复训练量为

$$R_{oe} = \sum_{i=1}^k l_i(k-2), \quad k \geq 3 \quad (10)$$

由于每一类都需要与其它 $(k - 1)$ 类参与训练 1 次, 故重复训练量为式(10)。

例如: 令 $l_i = 10, i = 1, 2, \dots, k, k = 5$, 则 $R_{others} = 90, R_{all} = 200, R_{oe} = 150$ 。可见, 2PTMC 的训练样本重复量是最小的, 只是“one against all”方法的 45%, 和“one against one”方法的 60%, 且当样本量增大时, 其训练样本重复量与其他两种方法的差别会拉大, 这大大降低了样本训练量。在目前 SVM 训练时间还较长的现状下, 2PTMC 是一种较为理想的选择。

5 应用研究

柴油机具有振源多、运动部件多、长期工作在高温高压环境下的特点, 一旦发生故障不易诊断。利用缸盖的振动信号特征进行故障诊断是一种经常采用的有效方法^[7]。

本文提出的柴油机缸盖振动信号故障诊断的策略是: 首先对测取的汽缸振动信号进行小波包分解, 提取振动信号在不同频带的正交特征参量, 建立

学习样本; 然后训练由 4 个 SVM 机按照故障优先级不同构成的二叉树多级分类器(2PTMC) 进行故障的检测和辨识。

实验对象为 6135 型柴油机, 通过对其缸盖振动信号进行同步采样来获取一个完整工作循环内的离散振动信号序列。采样时, 以第一缸燃烧上止点信号作为触发采样信号, 信号长度为每循环 2 000 个点, 采样频率为 25 kHz。对在不同工作状态下测取的振动信号, 采用 3 阶 Daubechies 小波, 对信号进行 3 层分解得到的 8 个频带的宽度均为 1 562.5 Hz^[4]。图 2 为新气阀轻微漏气故障时缸盖振动信号的分解波形, 按图号顺序从(a) 到(h) 频段由低到高分布。

信号经过小波包分解后, 可直观地了解故障的特征频带, 但如直接送至学习机进行训练, 则数据量太大。为了降低分类器的复杂度, 可求出该频带内的幅值谱, 然后计算各频带的相对幅值谱值, 作为该频带的特征参量, 就可大大简化特征空间。由于样本数目较多, 表 1 为部分样本特征参量示例。

对上述高维特征数据运用 2PTMC 进行故障模式决策。6135 型柴油机的气门故障主要有 4 种, 按照故障发生的可能性进行优先级排序分别为排气门间隙过小, 排气门间隙过大, 新气阀轻微漏气和气阀严重漏气。在缸盖上测取大量不同气门间隙状态下的振动信号, 经小波包分解后提取特征向量, 构成 8 维特征参量的输入样本。按照优先级由高到低分别训练 4 个支持向量机。由于实验数据很多, 这里只给出第 1 级和最后一级的一部分实验结果。

(1) 训练阶段

第 1 级 SVM 1:

样本构成: 正常及各种故障状态下的振动特征

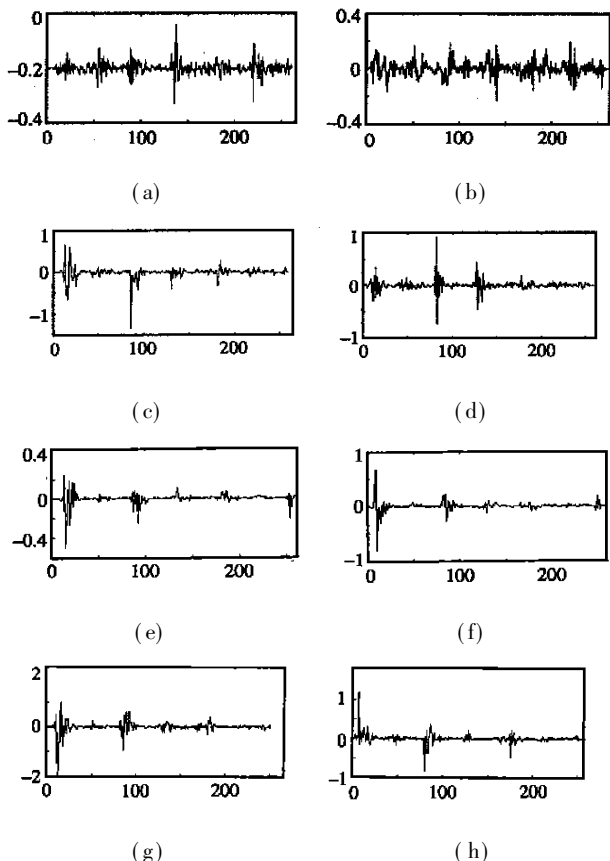


图 2 新气阀轻微漏气时的振动信号小波包分解结果

表 1 小波包特征参量

样本	相 对 值							
	频带 1	频带 2	频带 3	频带 4	频带 5	频带 6	频带 7	频带 8
1	0.07	0.093 8	0.099 7	0.128 8	0.227 6	0.150 9	0.118 4	0.110 8
2	0.091 9	0.092 4	0.129 4	0.101 9	0.170 2	0.161 4	0.124 2	0.128 5
3	0.071 1	0.082 2	0.202	0.132 7	0.041	0.061 9	0.313 3	0.095 9
4	0.074 3	0.119 2	0.080 2	0.135 4	0.195 8	0.154 4	0.117 5	0.123 2
5	0.066 5	0.080 3	0.245 7	0.116 9	0.055	0.052 4	0.296 9	0.086 3
6	0.067 6	0.082 1	0.130 9	0.125 4	0.122 6	0.137 3	0.167 6	0.166 3
7	0.069 8	0.070 8	0.161 5	0.104 8	0.055 1	0.093 6	0.296 7	0.147 7
8	0.067 4	0.093 9	0.136 1	0.126 6	0.207 3	0.143 8	0.116 4	0.108 5
9	0.072 5	0.088 4	0.125 1	0.143 6	0.111 3	0.107 7	0.220 1	0.131 3
10	0.069 4	0.063	0.163 2	0.121 6	0.071 4	0.092	0.274 8	0.144 6

数据,共 35 组。

取径向基核函数($C = +$)

$$K(x, x_i) = \exp(-\frac{\|x - x_i\|^2}{2\sigma^2})$$

经实验, γ 取值大于 2.0 以后, 支持向量数目稳定为 3。此时, 对应的支持向量及其拉氏系数见表 2。

表 2 $\gamma = 2.0$ 时 SVM1 获得的支持向量及拉氏系数

sv 向量	样本序号	所属类别	拉氏系数
sv1	5	正常	10.116 7
sv2	7	正常	1.257 2
sv2	16	第三故障	11.329 5

取多项式核函数($C = +$)

$$K(x, x_i) = [(x \cdot x_i) + 1]^d, \quad d = 3$$

时获取的支持向量与 $\gamma = 2.0$ 时 Rbf 核函数得到的支持向量完全相同, 拉氏系数见表 3。

表 3 $d = 3$ 时 SVM1 获得的支持向量及拉氏系数

sv 向量	样本序号	所属类别	拉氏系数
sv1	5	正常	0.051 6
sv2	7	正常	0.004 2
sv2	16	第三故障	0.082 6

第 4 级 SVM4:

样本构成: 新气阀轻微漏气故障与严重漏气状态下的振动特征数据, 共 14 组。省略参数选择过程, 直接给出最优参数下的训练结果。

取多项式核函数在 $C = +$, $d = 3$ 时获取的支持向量与相应拉氏系数见表 4。

表 4 $d = 3$ 时 SVM4 获得的支持向量及拉氏系数

sv 向量	样本序号	所属类别	拉氏系数
sv1	1 + 14	第三故障	0.014 2
sv2	5 + 14	第三故障	0.003 0
sv3	6 + 14	第三故障	0.008 9
sv4	8 + 14	第四故障	0.024 8
sv5	9 + 14	第四故障	0.013 6
sv6	12 + 21	第四故障	0.017 5

每一级训练之后得到的支持向量的数目为:

SVM1	SVM2	SVM3	SVM4
3	3	5	6

(2) 诊断阶段

在训练数据集之外, 每一类中随机抽出 10 组共 5×10 组特征数据, 来测试机器推广能力。

1) 记忆能力测试

以全部 35 组数据作为输入, 代入分类器, 结果

全部正确, 证明了 2PTMC 具有记忆功能。


2) 推广能力测试

以 5×10 组未学习的特征数据来测试机器推广能力, 结果如表 5 所示。


表 5 2PTMC 故障诊断推广能力测试结果

	SVM 1	SVM 2	SVM 3	SVM 4
样本总数	50	40	30	20
错分数	0	0	1	0
准确率 / %	100	100	96.77	100

图 3 给出了第 3 个 SVM 实现排气门间隙过大故障与其他故障分类时, 2 维可视情况下的部分分类效果图。图中, (a) 为仅以第 1, 2 维特征数据进行分类的结果; (b) 为仅以第 2, 3 维特征数据分类结果, 图中“圆圈”和“菱形”代表两类不同特征, “+”标出了支持向量, 中间实线为最优分类面。



(a) 仅以第 1, 2 维特征数据分类结果



(b) 仅以第 2, 3 维特征数据分类结果

图 3 SVM 故障分类的 2 维可视效果图

6 结 论

本文提出了一种适合故障诊断的带故障优先级的二叉树多类分类方法(2PTMC), 该方法采用了一种“one against others”的分类器构造策略, 具有算法简单直观、重复训练样本少的优点。通过运用 2PTMC 对柴油机实测振动信号的小波包特征参量进行分级故障诊断, 收到了令人满意的诊断效果, 表明了该方法的有效性和实用性。另外, 该算法在其他多级分类系统中亦具有参考价值。

(下转第 284 页)

Control of Dynamic Systems [M]. Mass: Addison-Wesley, 1986.

[2] 王广雄, 王新生. 鲁棒镇定问题的 H_∞ 优化设计[J]. 自动化学报, 2002, 28(4): 601-605.

(Wang Guangxiong, Wang Xinsheng. H_∞ Optimal design for robust stabilization [J]. *Acta Automatica Sinica*, 2002, 28(4): 601-605.)

[3] Boyd S, Ghaoui L El, Feron E, et al. *Linear Matrix Inequalities in System and Control Theory* [M]. Philadelphia: SIAM, 1994.

[4] Wang Shaopeng, Chow J H. Low-order controller design for SISO systems using coprime factors and LMI[J]. *IEEE Trans Automatic Control*, 2000, 45(6): 1166-1169.

[5] Gahinet P, Nemirovski A, Laub A J, et al. *LMI Control Toolbox* [M]. Mass: The Math Works Inc, 1995.

[6] Gahinet P, Apkarian P. A linear matrix inequality approach to H_∞ control[J]. *Int J Robust and Nonlinear Control*, 1994, 4(1): 421-448.

(上接第 276 页)

参考文献(References):

[1] Vapnik V. *The Nature of Statistical Learning Theory* [M]. New York: Springer, 1998.

[2] Vapnic. 统计学习理论的本质[M]. 张学工, 译. 北京: 清华大学出版社, 2000.

[3] Platt J C. Fast training of SVMs using sequential minimal optimization[A]. *Advances in Kernel Methods Support Vector Learning*[C]. MIT Press, 1998. 185-208.

[4] 马笑潇. 智能故障诊断中的机器学习新理论及其应用[D]. 重庆: 重庆大学, 2002.

[5] CHIH-WEI HSU, CHIH-JEN LIN. A comparison of methods for multi-classification support vector

machines[EB/OL]. <http://www.csie.ntu.edu.tw/~cjlin/bsvm/>.

[6] Weston J, Watkins C. Multi-class support vector machines[A]. *Proc of ESANN 99*[C]. Brussels D Facto Press, 1999.

[7] 耿尊敏, 宋孔杰, 李兆前, 等. 关于柴油机振声特点及动态诊断方法的研究与讨论[J]. 内燃机学报, 1995, 13(2): 140-147.

(Geng Z M, Song K J, Li Z Q, et al. The research and discussion on the characteristic of vibration of diesel engine and dynamic diagnosis methods [J]. *Trans CSICE*, 1995, 13(2): 140-147.)

(上接第 280 页)

参考文献(References):

[1] Agrawal R, Imielinski T, Swami A. Mining association rules between sets of items in large databases[A]. *Proc of ACM SIGMOD Conf on Management of Data*[C]. Washington, 1993. 207-216.

[2] Agrawal R, Srikant R. Fast algorithms for mining association rules[A]. *Proc of the 20th Int Conf on Very Large Databases*[C]. Santiago, 1994. 487-499.

[3] Agrawal R, Mannila H, Srikant R, et al. Fast discovery of association rules[A]. *Advances in Knowledge Discovery and Data Mining*[C]. AAAI/MIT Press, 1996. 307-328.

[4] Brin S, Motwani R, Silverstein C. Beyond market bas-

ket: Generalizing association rules to correlations[A]. *Proc 1997 ACM-SIGMOD Int Conf Management of Data*[C]. Tucson, 1997. 265-276.

[5] Srikant R, Agrawal R. Mining generalized association rules[A]. *Proc of the 21st Int Conf on Very Large Data Bases*[C]. Zurich, 1995. 407-419.

[6] Srikant R, Agrawal R. Mining quantitative association rules[A]. *Proc of the ACM SIGMOD*[C]. Montreal, 1996. 1-12.

[7] Savasere A, Omiecinski E, Navathe S. Mining for strong negative association in a large database of customer transactions[A]. *Proc of the Int Conf on Data Engineering*[C]. Orlando, 1998. 494-502.