

一种新的模糊补偿多类支持向量机^{*})

张永^{1,2} 迟忠先² 闫德勤¹

(辽宁师范大学计算机系 大连 116029)¹ (大连理工大学计算机科学与工程系 大连 116024)²

摘要 支持向量机是 Vapnik 等学者在统计学习理论的基础上提出的一种新的机器学习方法。针对支持向量机理论中的多类分类问题和对于噪音数据的敏感性,本文提出了一种模糊补偿多类支持向量机算法 FC-SVM。该算法是在 Weston 等人提出的多类 SVM 分类器的直接构造方法中引入模糊补偿函数,针对每个输入数据对分类结果的两方面影响,将目标函数中的惩罚项不仅进行了模糊化,而且对于分类情况进行了加权补偿,并重构了优化问题及其约束条件,然后重构了 Lagrange 公式,给出了理论推导。在充分的数值实验基础上,将文中提出的方法应用于建设银行个人房贷的信用评估系统中,得到了较好的实验结果。

关键词 模糊补偿,多类分类,支持向量机,信用评估

A Novel Fuzzy Compensation Multi-Class Support Vector Machine

ZHANG Yong^{1,2} CHI Zhong-Xian² YAN De-Qin¹

(Department of Computer, Liaoning Normal University, Dalian 116029)¹

(Department of Computer Science and Engineering, Dalian University of Technology, Dalian 116024)²

Abstract Support vector machine (SVM), proposed by Vapnik based on statistical learning theory (SLT), is a novel machine learning method which has been applied to many application fields successfully. But there are two kinds of problems to be solved in such field, one is the multi-class classification problem, and the other is the sensitivity to the noisy data. In order to overcome these difficulties, a novel method of fuzzy compensation multi-class support vector machine is proposed in this paper, which is named as FC-SVM in the present paper. This method imports a fuzzy compensation function to the penalty in the straightly construction multi-class SVM classification problem proposed by Weston and Watkins. Aiming at the dual affects to classification results by each input data, this method has punish item be fuzzy, compensates weight to classification, reconstructs the optimization problem and its restrictions, reconstructs Lagrange formula, and presents the theories deduction. This method is applied to the credit evaluating system of personal loan. The experiment presents this method is feasible.

Keywords Fuzzy compensation, Multi-class classification, Support vector machine, Credit evaluation

1 引言

支持向量机(Support Vector Machine, SVM)是 20 世纪 90 年代中期在统计学习理论(Statistical Learning Theory, SLT)的基础上提出的一种新的机器学习方法,它基于 VC 维理论和结构风险最小化原理,在很大程度上克服了传统机器学习中的维数灾难以及局部极小等问题^[1,2]。SVM 理论中,在线性可分的情况下,就是建立一个超平面使得可分的两类数据到该平面的距离最小,通常称该平面为最优分离超平面;对于非线性可分问题,是通过一个非线性映射(核函数)把原始数据映射到另一个称之为特征空间的新数据集上,使得新数据集在该特征空间上是线性可分的。一个最优分类超平面将分类器的泛化能力最大化,最优分类超平面可以由少量的数据点生成,这些点称为支持向量(Support Vector, SV)。这一理论已经广泛地应用于数据分类问题和回归问题,例如文本分类、手写体数字的识别、物体的识别、语音识别、空间数据的分析以及生物信息等。

自 20 世纪 90 年代以来,支持向量机在实用算法研究、设计和实现方面已取得了一些丰硕的成果,可归结为几个大的研究方向^[4]: 1)将两类分类问题的解决办法有效地延伸至多类分类问题,目前常用的思路有两种:一是构造多个 2 类分类器组合起来完成多类分类,如 DAGSVM 等方法^[6],二是直接构造多类分类器,如 k-SVM^[5]; 2)提高 SVM 的计算速度,以便于处理大规模问题,如序列最小化算法^[7]等; 3)利用最优化技术改进或改造支持向量机形式,简化计算过程,如线性 SVM^[8], LS-SVM^[9]等; 4)依据结构风险最小化原则和支持向量机的某些思想提出新的算法,如 ν -SVM^[10], 广义 SVM^[11]等算法; 4)利用结构风险最小原则、核思想和正则化技术等改造传统的线性算法,构造出相应的核形式,如核主成份分析等; 5)克服 SVM 对孤立点(outlier)和噪音数据的敏感性研究,提出了很多模糊支持向量机的方法,如 F-SVM^[12]。

本文针对多类分类问题以及噪音数据问题,提出了一种新的模糊补偿多类支持向量机方法,简记为 FC-SVM。与传统的多类 SVM 相比,FC-SVM 方法是直接构造多类分类器。

^{*}国家自然科学基金(6033372071)、辽宁省教育厅基金(2004C031)。张永 博士生,讲师,主要研究领域为机器学习、智能计算、数据挖掘;迟忠先 教授,博士生导师,主要研究领域为机器学习、数据挖掘、数据仓库、软件工程;闫德勤 博士,教授,主要研究领域为人工智能、知识发现、粗集理论。

我们首先在 Weston 和 Watkins 所提出的多类 SVM 分类器直接构造方法^[5]的惩罚项中引入了模糊补偿函数,将目标函数中的惩罚项不仅进行了模糊化,而且对于分类情况进行了加权补偿,并重构了优化问题及其约束条件,然后重构了 Lagrange 公式,使得原公式(模型)所对应的最优分类超平面的解即为其对偶形式的解。在本文中,首先对所提出的方法给出了理论推导;并且在给出充分的数值实验的基础上,在某建设银行个人房贷信用评价的数据集上进行了进一步的实验,取得了较好的实验效果。

2 SVM 相关知识

2.1 支持向量机简介

依据统计学习理论中的结构风险最小化原则,Vapnik 等人首先提出了模式分类算法^[1,2]。假设训练样本集为

$$(x_1, y_1), (x_2, y_2), \dots, (x_l, y_l) \quad (1)$$

其中: $x_i \in R_n, i=1, 2, \dots, l$ (R 为实数域); 对于两类的分类问题, $y_i \in \{+1, -1\}$ 。

支持向量机分类问题的原始形式可归结为下列二次规划问题:

$$\begin{aligned} \min_{w, b, \xi} \quad & \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \xi_i \\ \text{s. t.} \quad & y_i (w \cdot x - b) + \xi_i - 1 \geq 0 \\ & \xi_i \geq 0 \quad i=1, \dots, n \end{aligned} \quad (2)$$

求解这个二次规划问题,引入 Lagrange 乘子。最终推导得的 Wolfe 对偶问题为

$$\begin{aligned} \max_{\lambda} \quad & W(\lambda) = \sum_{i=1}^n \lambda_i - \frac{1}{2} \sum_{i,j=1}^n \lambda_i \lambda_j y_i y_j x_i \cdot x_j \\ \text{s. t.} \quad & \sum_{i=1}^n \lambda_i y_i = 0 \\ & C \geq \lambda_i \geq 0 \quad i=1, \dots, n \end{aligned} \quad (3)$$

判别函数为:

$$f(x) = \text{sgn}(\sum_{i=1}^n \lambda_i y_i K(x_i \cdot x) - b) \quad (4)$$

2.2 多类 SVM 分类方法简介

利用 SVM 解决多类分类问题,目前主要有两种途径:一是间接构造,把多个 2-类 SVM 分类器进行组合,研究的内容包括对组合方式的改进以及对每个 2-类 SVM 分类器的改进;另外一种方法是利用 Weston 等人提出的直接构造多类 SVM 分类器方法^[5]。

2.2.1 间接构造多类分类器

先构造多个 2-类分类器,然后将它们组合起来构成一个多类分类器。该思路源于传统的模式识别方法来解决多类问题,根据训练样本组成的不同,又可分为“one against one”和“one against all”两种类型,前者的每一个 SVM 的训练样本是由两个不同类别的样本组成,需要构造 $(k(k-1)/2)$ 个 SVM 才能完成整个分类任务,其中 k 为类别数;后者的每个 SVM 的训练样本都由全部样本组成,需构造 k 个支持向量机才能完成。

2.2.2 直接构造多类分类器

Weston 和 Watkins 提出了解决 k -类问题的一种直接方法^[5],它是二次优化式(3)的一种自然扩展形式:

$$\min \phi(w, \xi) = \frac{1}{2} \sum_{m=1}^k (w_m \cdot w_m) + C \sum_{i=1}^n \sum_{j \neq y_i} \xi_j^n \quad (5)$$

其约束条件为:

$$(w_{y_i} \cdot x_i) + (b_{y_i} \geq (w_m \cdot x_i) + b_m + 2 - \xi_i^n) \quad (6)$$

$$\xi_i^n \geq 0, i=1, 2, \dots, l, m, y_i \in \{1, 2, \dots, k\}, m \neq y_i \quad (7)$$

由此,得到下面的 k -类 SVM 分类器的判别函数:

$$f(x) = \arg \max [(w_i \cdot x) + b_i], i=1, 2, \dots, k \quad (8)$$

本文将在 Weston 和 Watkins 提出的直接构造多类 SVM 分类方法基础上,在惩罚项中引入模糊补偿函数,使得每个数据点对分类结果产生更合理的影响。因而,使用该方法后,可以降低噪音数据对分类结果的影响。

3 模糊补偿多类 SVM

3.1 模糊性与模糊补偿

在 SVM 理论中,训练过程对于孤立点与噪声点是十分敏感的。在式(2)中用参数 C 来控制对错分样本惩罚的程度,较大的 C 值意味着为错误项指定了较大的惩罚值,从而减少了错误分类的数据点,但较小的 C 值意味着忽略了一些“微不足道”的错误分类点,因而可以得到较大的分类间隔(margin)。无论 C 取何值,在 SVM 的整个训练过程中该参数始终保持不变,即在 SVM 的训练过程中,所有训练点都是被同等对待的。这样就导致了 SVM 对某些特殊情形的过分敏感,例如孤立点与噪声,出现所谓的“过学习”现象。

在这样的意义下,训练点不再严格属于某一类。而有可能存在下列情况,某一个训练样本 90% 的概率属于某一类,10% 的概率不属于这一类。在此基础上,针对支持向量机中由于噪声和孤立点带来的过拟合问题,提出了模糊支持向量机。一些学者对模糊 SVM(FSVM)已经作了初步的探索。针对分类问题,Lin 等人^[13]提出的 FSVM 方法通过对每个输入样本增加一个模糊隶属度,使得重要性不同的变量其错分程度也有不同的衡量要求,但这种样本点隶属度的含义很模糊。在回归估计问题上,Sun 等^[14]将模糊化和模糊推理过程加入到最小二乘 SVM(LS-SVM)之前,对输入数据进行模糊预处理,这种方法训练的是模糊规则。在分析线性和非线性模糊回归理论的基础上,Hong 等^[15]首次提出了基于 SVM 的模糊回归模型。

但现有的模糊支持向量机多是基于 2-类分类的,对于多类分类问题需要构造多个 2-类分类问题,对多类分类并不直观。另外,数据集中的数据不完全肯定来自于假设总体的情形,不同的数据对数据集的域描述可以有不同的贡献^[16]。也就是说,要充分地综合考虑样本对分类贡献的差异,使分类性能得到进一步提高。由此我们提出了模糊补偿支持向量机,对于一个训练样本不仅考虑正确分类情况,而且也考虑被错分的情况,从而使一个训练样本对应 2 份误差。这样,不仅能保持模糊支持向量机克服过度拟合的优点,又能充分利用有限样本,增加其分类推广能力。

3.2 模糊补偿多类 SVM

结合上面的分析,我们提出了模糊补偿多类支持向量机 FC-SVM。在 Weston 和 Watkins 提出的多类 SVM 分类器直接构造方法的惩罚项中引入了模糊补偿函数,将目标函数中的惩罚项不仅进行了模糊化,而且对于分类情况进行了补偿,并重构了优化问题及其约束条件。

假设给出一个带有类别标记以及模糊成员函数的训练样本集 S :

$$(x_1, y_1, t_1), (x_2, y_2, t_2), \dots, (x_l, y_l, t_l) \quad (9)$$

每一个训练样本 $x_i \in R_n$ 都给出了与其对应的类别标记 $y_i \in \{1, 2, \dots, k\}$ 以及模糊成员函数 $t_i, \sigma \leq t_i \leq 1$, 其中 $i=1, 2, \dots, l, \sigma$ 是一个充分小的正数。

模糊补偿多类 SVM 的最优分类超平面由下面的二次优化的解给出:

$$\min \phi(w, b, \xi, \eta) = \frac{1}{2} \sum_{m=1}^k (w_m \cdot w_m) + C \sum_{i=1}^l \sum_{j=1}^k [\xi_i^m + (1 - \xi_i^m) \eta_j^m] \quad (10)$$

约束条件:

$$\begin{aligned} (w_{y_i} \cdot x_i) + b_{y_i} &\geq (w_m \cdot x_i) + b_m + 2 - \xi_i^m, \\ (w_{y_i} \cdot x_i) + b_{y_i} &\leq (w_m \cdot x_i) + b_m - 2 + \eta_j^m, \\ \xi_i^m &\geq 0, \eta_j^m \geq 0, i=1, 2, \dots, l, \\ m, y_i &\in \{1, 2, \dots, k\}, m \neq y_i \end{aligned} \quad (11)$$

其中 C 是一个常数(通常称为惩罚常数),模糊成员函数 t_i 是样本 x_i 属于某一类的隶属度,参数表示 SVM 解的错误度量,而 $t_i \xi_i$ 是样本分到某一类所具有的不同权值的错误率, $(1 - t_i) \eta_j$ 表示没有分到该类的模糊补偿错误率。

所对应的 Lagrange 公式为:

$$\begin{aligned} L(w, b, \xi, \eta) &= \frac{1}{2} \sum_{m=1}^k (w_m \cdot w_m) + C \sum_{i=1}^l \sum_{j=1}^k [\xi_i^m + (1 - \xi_i^m) \eta_j^m] \\ &- \sum_{i=1}^l \sum_{m=1}^k \alpha_{ij}^m [(w_{y_i} - w_m) \cdot x_i + b_{y_i} - b_m - 2 + \xi_i^m] \\ &+ \sum_{i=1}^l \sum_{m=1}^k \alpha_{ij}^m [(w_{y_i} - w_m) \cdot x_i + b_{y_i} - b_m + 2 - \eta_j^m] \\ &- \sum_{i=1}^l \beta_{ij}^m \xi_i^m - \sum_{i=1}^l \beta_{ij}^m \eta_j^m \end{aligned} \quad (12)$$

以及约束条件:

$$\begin{aligned} \alpha_{ij}^m &\geq 0, \alpha_{ij}^m \geq 0, \beta_{ij}^m \geq 0, \beta_{ij}^m \geq 0, \\ \xi_i^m &\geq 0, i=1, \dots, l, m \in \{1, \dots, k\} \setminus y_i \end{aligned} \quad (13)$$

对于式(12),分别求关于 w_n, b_n 及 ξ 的偏导数,有

$$\frac{\partial L}{\partial w_n} = w_n + \sum_{i=1}^l (\alpha_{ij}^m - \alpha_{ij}^n) x_i - \sum_{i=1}^l (A_{2i} - A_{1i}) c_i^m x_i \quad (14)$$

$$\frac{\partial L}{\partial b_n} = \sum_{i=1}^l (A_{2i} - \alpha_{ij}^n) + \sum_{i=1}^l (A_{2i} - A_{1i}) c_i^m \quad (15)$$

$$\frac{\partial L}{\partial \xi_i^m} = C c_i^m - \alpha_{ij}^m - \beta_{ij}^m \quad (16)$$

$$\frac{\partial L}{\partial \eta_j^m} = C(1 - \xi_i^m) - \alpha_{ij}^m - \beta_{ij}^m \quad (17)$$

在鞍点处应满足的条件为

$$\frac{\partial L}{\partial w_n} = 0 \Rightarrow w_n = \sum_{i=1}^l (A_{1i} - A_{2i}) c_i^m x_i - \sum_{i=1}^l (\alpha_{ij}^m - \alpha_{ij}^n) x_i \quad (18)$$

$$\frac{\partial L}{\partial b_n} = 0 \Rightarrow \sum_{i=1}^l (\alpha_{ij}^m - \alpha_{ij}^n) = \sum_{i=1}^l (A_{1i} - A_{2i}) c_i^m \quad (19)$$

$$\frac{\partial L}{\partial \xi_i^m} = 0 \Rightarrow C c_i^m = \alpha_{ij}^m + \beta_{ij}^m \quad (20)$$

$$\frac{\partial L}{\partial \eta_j^m} = 0 \Rightarrow C(1 - \xi_i^m) = \alpha_{ij}^m + \beta_{ij}^m \quad (21)$$

其中,引入了符号 c_i^m, A_{1i} 和 A_{2i} , 其意义如下:

$$c_i^m = \begin{cases} 1, & y_i = n \\ 0, & y_i \neq n \end{cases}, A_{1i} = \sum_{m=1}^k \alpha_{ij}^m, A_{2i} = \sum_{m=1}^k \alpha_{ij}^m \quad (22)$$

将上述结果代入式(12),可以得到下式:

$$\begin{aligned} L(w, b, \xi, \eta) &= \frac{1}{2} \sum_{m=1}^k \sum_{i=1}^l \sum_{j=1}^k [c_i^m (A_{1i} - A_{2i}) - \alpha_{ij}^m + \alpha_{ij}^n] \\ &[c_i^m (A_{1i} - A_{2i}) - \alpha_{ij}^m + \alpha_{ij}^n] (x_i \cdot x_j) \\ &+ \sum_{i=1}^l \sum_{m=1}^k [(\alpha_{ij}^m + \beta_{ij}^m) \xi_i^m + (\alpha_{ij}^m + \beta_{ij}^m) \eta_j^m] \\ &- \sum_{i=1}^l \sum_{m=1}^k \alpha_{ij}^m [(w_{y_i} - w_m) \cdot x_i + b_{y_i} - b_m - 2 + \xi_i^m] \end{aligned} \quad (23)$$

$$\begin{aligned} &+ \sum_{i=1}^l \sum_{m=1}^k \alpha_{ij}^m [(w_{y_i} - w_m) \cdot x_i + b_{y_i} - b_m + 2 - \eta_j^m] \\ &- \sum_{i=1}^l \beta_{ij}^m \xi_i^m - \sum_{i=1}^l \beta_{ij}^m \eta_j^m \end{aligned}$$

利用式(18)~(22),对上式化简,可得:

$$\begin{aligned} L(w, b, \xi, \eta) &= \sum_{i,j,m} [-\frac{1}{2} c_i^m (A_{1i} - A_{2i}) (A_{1i} - A_{2i}) + (\alpha_{ij}^m \\ &- \alpha_{ij}^n) (\alpha_{ij}^m - \alpha_{ij}^n) - \frac{1}{2} (\alpha_{ij}^m - \alpha_{ij}^n) (\alpha_{ij}^m - \alpha_{ij}^n)] (x_i \cdot \\ &x_j) + 2 \sum_{i=1}^l \sum_{m=1}^k (\alpha_{ij}^m + \alpha_{ij}^n) \end{aligned} \quad (24)$$

约束条件为: $\sum_{i=1}^l \alpha_{ij}^m = \sum_{i=1}^l c_i^m A_i, n=1, \dots, k$

$$0 \leq \alpha_{ij}^m \leq C, \alpha_{ij}^m = 0, i=1, \dots, l, m \in \{1, \dots, k\} \setminus y_i$$

判别函数为:

$$f(x, a) = \arg \max_n$$

$$[\sum_{i=1}^l [c_i^m (A_{1i} - A_{2i}) - (\alpha_{ij}^m - \alpha_{ij}^n)] (x_i \cdot x) + b_{ij}]$$

4 算法实验分析与比较

4.1 数值实验

本文将 FC-SVM 算法和以前的 1-against-1(1-a-1)算法、1-against-all(1-a-a)算法进行了实验比较。我们采用的数据是利用文[17]中 UCI 机器学习数据库所提供的 5 个数据集,分别是 iris, wine, glass, soy 和 Blood-cell。为了验证 FC-SVM 对噪音数据的适用性,利用 NDC 数据生成器^[18]生成了一个含有噪音的数据集 Voice-data。该数据集含有 1000 个样本,10 个属性值,分为 4 类。在训练阶段,我们选取较大的 C 值,使得训练集能够被正确地分类。在测试阶段,选取了径向基核。对每一组数据,我们选用了相同的参数值 σ 。

表 1 将本文提出的 FC-SVM 算法与 1-a-1 以及 1-a-a 进行了比较。在表 1 中的数据表示对测试集的正确分类率(%)。

表 1 标准数据集试验结果

数据集	数据点个数	属性个数	类别数	1-a-1	1-a-a	FC-SVM
iris	150	3	4	97.24	97.24	97.32
wine	178	13	3	97.16	97.08	97.22
glass	214	9	7	83.36	82.68	84.20
soy	289	208	17	96.84	96.84	96.84
vowel	528	10	11	81.26	80.80	83.72
blood-cell	3097	13	12	91.48	92.02	92.36
Voice-data	1000	10	4	75.60	76.50	81.20

由实验结果可以看出,FC-SVM 与其它几种 SVM 分类器相比,对由数据生成器所生成的带有噪音的 Voice-data 数据集而言,具有较好的分类精度。这说明该算法对处理噪音数据是比较有效的。

4.2 个人房贷信用分析实验

近年来,我国金融机构贷款量快速增长,不良贷款余额仍然下降缓慢,不良贷款损失额仍然在增加。如何加强贷款管理,尤其是对我国现阶段越来越多的个人消费信贷的管理,是所有金融结构必须加以重视的问题。1998 年银监会下发《贷款风险分类指导原则(试行)》文件,目的是为了建立现代银行制度,改进贷款分类方法,加强银行信贷管理,提高信贷资产质量。该文件为了评估银行贷款质量,采用以风险为基础的分类方法,即把贷款分为正常、关注、次级、可疑和损失五类,

后三类合称为不良贷款。本文的应用背景是建设银行大连市分行个人住房贷款风险分析,并建立了个人房贷风险分析模型。

涉及个人贷款的特征数据很多,我们从相关的个贷系统的个人基本信息表、个人贷款申请表和信贷管理信息系统的个贷合同信息表中抽取出了相关的特征数据,一共 32 个。通过仔细分析,并通过属性约简技术,我们过滤了一些对个贷没有影响或影响很小的一些特征属性(数据),得到最终用于分析的特征属性(数据)15 个。

原始实验数据共 3423 条,实验前首先进行了数据预处理。从中随机抽取 2/3 样本(2282 个)作为训练数据,剩余的 1/3 样本(1141 个)作为测试数据。重复抽取 10 次,最后得到 10 组数据。我们利用这 10 组数据针对 1-a-a 算法和 FC-SVM 算法,分别采用径向基核、多项式核、线性核进行了训练和预测。实验结果如表 2 所示,表中数据为分类正确率(%)。

表 2 个人房贷风险分析实验结果

实验 组别	RBF 核		多项式核		线性核	
	$(\sigma^2=18, C=2)$		$(d=3, C=0.05)$		$(C=0.05)$	
	1-a-a	FC-SVM	1-a-a	FC-SVM	1-a-a	FC-SVM
1	0.85	0.93	0.80	0.87	0.74	0.83
2	0.90	0.94	0.82	0.90	0.76	0.84
3	0.84	0.91	0.79	0.83	0.72	0.81
4	0.89	0.90	0.82	0.86	0.75	0.82
5	0.85	0.92	0.78	0.82	0.74	0.83
6	0.80	0.91	0.76	0.86	0.72	0.82
7	0.82	0.93	0.77	0.83	0.76	0.83
8	0.85	0.94	0.79	0.83	0.71	0.79
9	0.91	0.91	0.81	0.85	0.7	0.82
10	0.86	0.93	0.83	0.86	0.75	0.82
平均	0.857	0.922	0.797	0.85	0.74	0.822

在信用风险评估中,我们并不能判定某个客户是绝对好客户,该客户一定能按时偿还所有贷款;我们也不能说另一个就是绝对的差客户,他一定会拖欠债务。客户信用的评价是通过概率值来确定的,他们只是在违约概率上的大小不同,即使一个最佳信用客户也完全可能拖欠贷款。从试验结果中分析,我们发现 FC-SVM 方法具有较高的正确分类率,而且在支持向量机中使用径向基核的准确度比多项式核和线性核要高。

结束语 本文提出了一种新的基于直接构造多类 SVM 分类器的模糊补偿多类 SVM 算法;FC-SVM 算法,重构了优化问题及其约束条件,重构了 Lagrange 公式,并进行了推导。我们将该算法成功地应用到了中国建设银行大连分行个人住

房贷风险分析系统,并建立了个人房贷风险分析模型,通过试验数据分析比较,算法取得了比较满意的效果。但我们的算法在进一步优化时也存在一个问题,即参数太多。这是我们下一步的工作。

参考文献

- Vapnik V N. Statistical Learning Theory. New York: John Wiley & Sons, 1998
- Hsu C W, Lin C J. A comparison of methods for multi-class support vector machines. IEEE Transactions on Neural Networks, 2002, 13(2): 415~425
- Burges J C. A tutorial on support vector machines for pattern recognition. Data Mining and Knowledge Discovery, 1998, 2(2): 121~167
- XU Jian-hua, ZHANG Xue-gong, LI Yan-da. Advances in Support Vector Machines. Control and Decision, 2004, 19(5):481~484
- Weston J, Watkins C. Multi-class support vector machines; [Technical Report SD2TR298204]. Department of Computer Science, Royal Holloway University of London, 1998
- Platt J C, Cristianini N, Shawe-Taylor J. Large margin DAG's for multiclass classification. Advances in Neural Information Processing Systems. Cambridge, MA: MIT Press, 2000, 12: 547~553
- Platt J. Fast training of support vector machines using sequential minimal optimization [A]. Advances in Kernel Methods -Support Vector Learning [C]. Cambridge: MIT Press, 1999. 185~208
- Vapnik V N. The Nature of Statistical Learning Theory [M]. 2nd edition. New York: Springer-Verlag, 1999
- Suykens J, Vandewalle J. Least squares support vector machines [J]. Neural Processing Letters, 1999, 9(3): 293~300
- Scholkopf B, Smola A J, Williamson R C, et al. New support vector algorithms [J]. Neural Computation, 2000, 12(5): 1207~1245
- Mangasarian O L. Generalized support vector machines [A]. Advances in Large Margin Classifiers [C]. Cambridge: MIT Press, 2000. 135~146
- Inoue T, Abe S. Fuzzy Support Vector Machines for Pattern Classification. In: Proceedings of International Joint Conference on Neural Networks, 2001. 1449~1454
- Lin C F, Wang S D. Fuzzy Support Vector Machines. IEEE Transactions on Neural Networks, 2002, 13(2): 464~471
- Sun Z H, Sun Y X. Fuzzy Support Vector Machine for Regression Estimation. IEEE International Conference on Systems, Man and Cybernetics, 2003, 4: 3336~3341
- Hong D H, Hwang C. Support Vector Fuzzy Regression Machines. Fuzzy Sets and Systems, 2003, 138(2): 271~281
- Huang Z, Chen H C, Hsu C J, et al. Credit rating analysis with support vector machines and neural networks; a market comparative study. Decision Support Systems, 2004, 37:543~558
- http://www.ics.uci.edu/~mllearn/MLRepository.html
- http://www.cs.wisc.edu/musicant/data/ndc, 1998
- Funabiki N, Kitamichi J. Three-stage Greedy and Neural-network Approach for Subgraph Isomorphism Problem. In: Proceedings of the 1998 IEEE International Conference on System, Man and Cybernetics, IEEE, Piscataway, NJ, USA, 1998, 2:1892~1897
- Karp R M. Reducibility among combinatorial problems [M]. New York: Plenum Press, 1972. 83~85
- Babai L, Luks E. Canonical labeling of graphs. In: Proc. 15th ACM Symp. on Theory of Computing, 1983. 171~183
- Hopcroft J E, Tarjan R E. A V^2 algorithm for determining isomorphism of planar graphs. Information Processing Letters, 1971. 32~34
- Sfudhar A. A Fast Algorithm for Testing Isomorphism of Permutation Networks. Computers, IEEE Transactions on, 1989, 38(6):903~909

(上接第 151 页)

- 谢志鹏,刘宗田. 概念格的快速渐进式构造算法. 计算机学报, 2002(5):490~496
- 简宋全,胡学钢,蒋美华. 扩展概念格的渐进式构造. 计算机工程与应用, 2001, 15:132~134
- 胡可云,陆玉昌,石纯一. 基于概念格的分类和关联规则的集成挖掘方法. 软件学报, 2000, 11(11):1478~1484
- 李锋,李晓燕. 图的同构判定算法;关联度序列表及其应用. 复旦学报(自然科学版), 2001, 40(3)
- Chen Lin. Parallel and Distributed Systems. IEEE Transactions on 1996, 7(3):308~319
- 陈峻,殷新春. 无向图同构判定的并行算法. 计算机工程, 2002, 6(28)