

# 回归支持向量机的改进序列最小优化学习算法\*

张浩然<sup>†</sup>, 韩正之

(上海交通大学 自动化系, 上海 200030)

## An Improved Sequential Minimal Optimization Learning Algorithm for Regression Support Vector Machine

ZHANG Hao-Ran<sup>†</sup>, HAN Zheng-Zhi

(Department of Automation, Shanghai Jiaotong University, Shanghai 200030, China)

+ Corresponding author: Phn: 86-21-62932083 ext 810, E-mail: gczhr@sjtu.edu.cn

<http://www.sjtu.edu.cn>

Received 2002-11-04; Accepted 2003-03-04

Zhang HR, Han ZZ. An improved sequential minimal optimization learning algorithm for regression support vector machine. *Journal of Software*, 2003,14(12): 2006~2013.

<http://www.jos.org.cn/1000-9825/14/2006.htm>

**Abstract:** Support vector machine (SVM) is a learning technique based on the structural risk minimization principle, and it is also a class of regression method with a good generalization ability. This paper presents an improved SMO (sequential minimal optimization) algorithm to train the regression SVM, which gives an analytical solution to the QP problem of size two. A new working set selection method and a stopping condition are developed. The simulation results show that the improved SMO algorithm is significantly faster and more precise than the original SMO one.

**Key words:** support vector machine; kernel method; regression; SMO (sequential minimal optimization)

**摘要:** 支持向量机(support vector machine,简称 SVM)是一种基于结构风险最小化原理的学习技术,也是一种新的具有很好泛化性能的回归方法,提出了实现回归支持向量机的一种改进的 SMO(sequential minimal optimization)算法,给出了两变量子优化问题的解析解,设计了新的工作集选择方法和停止条件,仿真实例说明,所提出的 SMO 算法比原始 SMO 算法具有更快的运算速度.

**关键词:** 支持向量机;核方法;回归;序列最小优化

中图法分类号: TP18 文献标识码: A

自从 Vapnik<sup>[1]</sup>等人提出支持向量机(support vector machine,简称 SVM)理论以来,由于其出色的泛化能力,已在模式识别和函数估计方面取得了越来越多的进展<sup>[2-4]</sup>.但是,由于 SVM 的训练方法归结为求解一个受约束的二次型规划问题,对于较多训练样本数据的情况而言,训练支持向量机的计算量是比较大的,需要很大的内存和很长的运行时间,因此限制了它的实际应用.为了简化支持向量机的训练,降低其计算复杂度,Platt<sup>[5]</sup>提出了序列最小优化(sequential minimal optimization,简称 SMO)方法,其主要思想是把一个大的优化问题分解成一系列

\* 第一作者简介: 张浩然(1972—),男,安徽灵璧人,博士生,主要研究领域为神经网络,支持向量机,智能信号处理.

只含有两个变量的优化问题.由于SMO算法的出色性能,Smola和Scholkopf<sup>[6,7]</sup>提出一种训练回归SVM的SMO算法,这个算法是Platt算法的类比扩展.S.K. Shevade<sup>[8]</sup>和Gary William Flake<sup>[9]</sup>对Smola的算法进行了一些改进.本文提出另一种改进的SMO算法,这种算法的特点是充分利用支持向量机的几何意义,以便提高算法的快

## 1 回归SVM简介

对于回归问题,给定训练样本 $x_i \in R^n, y_i \in R, i=1, \dots, l$ ,采用式(1)拟合样本集:

$$f(x) = w^T \phi(x) + b. \quad (1)$$

这里, $\phi(\cdot)$ 是指由输入空间到特征空间的非线性映射, $f(\cdot)$ 在特征空间中表示为一个线性函数.回归SVM的目的是用函数 $f(\cdot)$ 去拟合数据样本,同时保证能得到很好的泛化能力.为了增加回归的鲁棒性,Vapnik<sup>[1]</sup>提出了 $\varepsilon$ -不灵敏损失函数,其特点是忽略小于 $\varepsilon$ 的拟合误差.综合考虑拟合误差和函数复杂度,回归SVM可以表示为如下的约束优化问题:

$$\begin{aligned} \min & \left[ \frac{1}{2} w^T w + \frac{1}{2} C \sum_{i=1}^l (\zeta_i + \zeta_i^*) \right] \\ & y_i - w^T \phi(x_i) - b \leq \varepsilon + \zeta_i \\ \text{s.t.} & \quad w^T \phi(x_i) + b - y_i \leq \varepsilon + \zeta_i^* \\ & \quad \zeta_i, \zeta_i^* \geq 0 \end{aligned} \quad (2)$$

这里, $C > 0$ 是函数复杂度和损失误差的一个平衡量.优化问题(2)的Lagrange函数为

$$L = \frac{1}{2} w^T w + C \sum_{i=1}^l (\zeta_i + \zeta_i^*) - \sum_{i=1}^l \alpha_i (w^T \phi(x_i) + b - y_i + \varepsilon + \zeta_i) - \sum_{i=1}^l \alpha_i^* (y_i - w^T \phi(x_i) - b + \varepsilon + \zeta_i^*) - \sum_{i=1}^l (v_i \zeta_i + v_i^* \zeta_i^*).$$

KKT优化条件要求Lagrange函数相对于变量 $w, b, \zeta_i, \zeta_i^*$ 的偏导数为0.

$$\begin{aligned} \frac{\partial L}{\partial w} = 0 & \Rightarrow w = \sum_{i=1}^l (\alpha_i - \alpha_i^*) \phi(x_i), \\ \frac{\partial L}{\partial b} = 0 & \Rightarrow \sum_{i=1}^l (\alpha_i - \alpha_i^*) = 0, \\ \frac{\partial L}{\partial \zeta_i} = 0 & \Rightarrow v_i = C - \alpha_i, \\ \frac{\partial L}{\partial \zeta_i^*} = 0 & \Rightarrow v_i^* = C - \alpha_i^*. \end{aligned}$$

把上述KKT条件代入优化问题(2)的目标函数中,根据对偶原理和核函数技术,可以得到式(2)的对偶优化问题:

$$\begin{aligned} \min & \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) k(x_i, x_j) + \varepsilon \sum_{i=1}^l (\alpha_i + \alpha_i^*) - \sum_{i=1}^l y_i (\alpha_i - \alpha_i^*) \\ \text{s.t.} & \quad \sum_{i=1}^l (\alpha_i - \alpha_i^*) = 0, \\ & \quad 0 \leq \alpha_i, \alpha_i^* \leq C, \quad i=1, \dots, l \end{aligned} \quad (3)$$

这里, $k(x_i, x_j) = \phi(x_i)^T \phi(x_j)$ 是核函数.

SVM的输出为

$$f(x) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) k(x_i, x) + b. \quad (4)$$

## 2 改进的SMO算法

为了推导方便,作一些变量替换,令

$$\begin{aligned} \bar{\alpha}_i &= \alpha_i - \alpha_i^*, \\ |\bar{\alpha}_i| &= \alpha_i + \alpha_i^*, \\ \bar{\alpha}_0 &= b. \end{aligned}$$

则式(3)、式(4)分别变为

$$\begin{aligned} \min & \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \bar{\alpha}_i \bar{\alpha}_j k_{ij} + \varepsilon \sum_{i=1}^l |\bar{\alpha}_i| - \sum_{i=1}^l \bar{\alpha}_i y_i \\ \text{s.t.} & \sum_{i=1}^l \bar{\alpha}_i = 0 \end{aligned} \quad (5)$$

$$\begin{aligned} -C \leq \bar{\alpha}_i \leq C, \quad i=1, \dots, l \\ f(x, \lambda) = \sum_{i=1}^l \bar{\alpha}_i k(x_i, x) + \bar{\alpha}_0, \end{aligned} \quad (6)$$

核函数 $k(x_i, x_j)$ 简写为 $k_{ij}$ .

### 2.1 子优化问题的解析解

SMO 算法是把一个大的 QP 问题转化成一系列的具有两个变量的 QP 问题,参照文献[9]的一些方法,假设待求的两个优化变量为  $\bar{\alpha}_a, \bar{\alpha}_b$ ,把式(5)的目标函数表示成变量  $\bar{\alpha}_a, \bar{\alpha}_b$  的函数,而把其他 Lagrange 乘子视为常数,可得:

$$L(\bar{\alpha}_a, \bar{\alpha}_b) = \frac{1}{2} \bar{\alpha}_a^2 k_{aa} + \frac{1}{2} \bar{\alpha}_b^2 k_{bb} + \bar{\alpha}_a \bar{\alpha}_b k_{ab} + \varepsilon |\bar{\alpha}_a| + \varepsilon |\bar{\alpha}_b| - \bar{\alpha}_a y_a - \bar{\alpha}_b y_b + \bar{\alpha}_a v_a^* + \bar{\alpha}_b v_b^* + L', \quad (7)$$

其中  $v_i^* = \sum_{j=1, j \neq a, b}^l \bar{\alpha}_j^* k_{ij} = f_i^* - \bar{\alpha}_a^* k_{ai} - \bar{\alpha}_b^* k_{bi} - \bar{\alpha}_0$ ,  $L'$  是式(5)的目标函数中不含有  $\bar{\alpha}_a, \bar{\alpha}_b$  的项,即相对于  $\bar{\alpha}_a, \bar{\alpha}_b$  来说是不变的.具有上标\*的量是指前一次迭代的值.由优化问题的等式约束,可以假设:

$$s^* = \bar{\alpha}_a^* + \bar{\alpha}_b^* = \bar{\alpha}_a + \bar{\alpha}_b, \quad (8)$$

由式(8)可以得到:

$$\bar{\alpha}_a = s^* - \bar{\alpha}_b, \quad (9)$$

把式(9)代入式(7),有

$$\begin{aligned} L(\bar{\alpha}_b) &= \frac{1}{2} (s^* - \bar{\alpha}_b)^2 k_{aa} + \frac{1}{2} \bar{\alpha}_b^2 k_{bb} + (s^* - \bar{\alpha}_b) \bar{\alpha}_b k_{ab} + \varepsilon |s^* - \bar{\alpha}_b| + \varepsilon |\bar{\alpha}_b| - \\ & (s^* - \bar{\alpha}_b) y_a - \bar{\alpha}_b y_b + (s^* - \bar{\alpha}_b) v_a^* + \bar{\alpha}_b v_b^* + L'. \end{aligned} \quad (10)$$

为了求式(10)的极小值,必须求偏微分  $\frac{\partial L(\bar{\alpha}_b)}{\partial \bar{\alpha}_b}$ ,然而由于式中含有绝对值项,式(10)不是严格可微的,但是可以定义:

$$\begin{aligned} \frac{d|x|}{dx} &= \text{sgn}(x), \\ \text{sgn}(x) &= \begin{cases} 1 & x > 0 \\ \text{待定} & x = 0 \\ -1 & x < 0 \end{cases}. \end{aligned}$$

这种定义在数学上是允许的,这样可求得:

$$\frac{\partial L(\bar{\alpha}_b)}{\partial \bar{\alpha}_b} = \varepsilon (\text{sgn}(\bar{\alpha}_b) - \text{sgn}(s^* - \bar{\alpha}_b)) + y_a - y_b + (\bar{\alpha}_b - s^*) k_{aa} + \bar{\alpha}_b k_{bb} + (s^* - 2\bar{\alpha}_b) k_{ab} - v_a^* + v_b^*. \quad (11)$$

由  $\frac{\partial L(\bar{\alpha}_b)}{\partial \bar{\alpha}_b} = 0$  可得:

$$\begin{aligned}
 \bar{\alpha}_b(k_{bb} + k_{aa} - 2k_{ab}) &= y_b - y_a + \varepsilon(\text{sgn}(s^* - \bar{\alpha}_b) - \text{sgn}(\bar{\alpha}_b)) + s^*(k_{aa} - k_{ab}) + v_a^* - v_b^* \\
 &= y_b - y_a + f_a^* - f_b^* + \varepsilon(\text{sgn}(s^* - \bar{\alpha}_b) - \text{sgn}(\bar{\alpha}_b)) + \bar{\alpha}_a^* k_{aa} - \bar{\alpha}_a^* k_{ab} + \bar{\alpha}_b^* k_{aa} - \bar{\alpha}_b^* k_{ab} - \\
 &\quad \bar{\alpha}_a^* k_{aa} - \bar{\alpha}_b^* k_{ab} - \bar{\alpha}_0^* + \bar{\alpha}_a^* k_{ab} + \bar{\alpha}_b^* k_{bb} + \bar{\alpha}_0^* \\
 &= y_b - y_a + f_a^* - f_b^* + \varepsilon(\text{sgn}(s^* - \bar{\alpha}_b) - \text{sgn}(\bar{\alpha}_b)) + \bar{\alpha}_b^*(k_{aa} + k_{bb} - 2k_{ab}).
 \end{aligned} \tag{12}$$

由式(12)可以写出变量  $\bar{\alpha}_b$  的递推计算公式,如下:

$$\bar{\alpha}_b = \bar{\alpha}_b^* + \eta[y_b - y_a + f_a^* - f_b^* + \varepsilon(\text{sgn}(s^* - \bar{\alpha}_b) - \text{sgn}(\bar{\alpha}_b))], \tag{13}$$

其中  $\eta = \frac{1}{k_{aa} + k_{bb} - 2k_{ab}}$ .

由于两个符号函数的存在,式(13)是递归的,必须求其解.如果 SVM 的核函数满足 Mercer 条件,就可以保证下式成立:

$$\eta = \frac{1}{k_{aa} + k_{bb} - 2k_{ab}} \geq 0.$$

这样由式(11)可知偏导数  $\frac{\partial L(\bar{\alpha}_b)}{\partial \bar{\alpha}_b}$  是  $\bar{\alpha}_b$  的增函数,

即随  $\bar{\alpha}_b$  的增加而增加,而且,如果  $s^* \neq 0$ ,偏导数的变化曲线是具有两次突变的分段直线,如图 1 所示.

图 1 显示了对偶目标函数的偏导数  $\frac{\partial L(\bar{\alpha}_b)}{\partial \bar{\alpha}_b}$  的变




Fig.1 The curve of  $\partial L(\bar{\alpha}_b)/\partial \bar{\alpha}_b$

图1 随变化曲线图

化情况.考虑以上因素我们来求方程(13)的解,这个方程存在 5 个可能的解,3 个解对应于  $(\text{sgn}(s^* - \bar{\alpha}_b) - \text{sgn}(\bar{\alpha}_b))$  的值,取-2,0,2,另两个解是  $\bar{\alpha}_b$  等于 0 和  $s^*$ .

取  $(\text{sgn}(\bar{\alpha}_a) - \text{sgn}(\bar{\alpha}_b))$  的值分别为-2,0,2,代入式(7)中,如果能使式(11)等于 0 则接受此新值,如果上面的取值失败,尝试取  $\bar{\alpha}_b$  值为 0 或  $s^*$ ,利用  $\bar{\alpha}_b$  值的正(负)扰动是否能使式(11)取正(负)值来判断取 0 还是  $s^*$ .总结以上讨论,可以得到  $\bar{\alpha}_b$  的更新律,见式(14),式中  $0^+, 0^-, s^{*+}, s^{*-}$  分别表示 0 和  $s^*$  的正负微小扰动.

$$\bar{\alpha}_b = \begin{cases} \bar{\alpha}_b^* + \eta[y_b - y_a + f_a^* - f_b^* + 2\varepsilon] & \bar{\alpha}_a > 0 > \bar{\alpha}_b \\ \bar{\alpha}_b^* + \eta[y_b - y_a + f_a^* - f_b^* - 2\varepsilon] & \bar{\alpha}_a < 0 < \bar{\alpha}_b \\ \bar{\alpha}_b^* + \eta[y_b - y_a + f_a^* - f_b^*] & \text{sgn}(\bar{\alpha}_a) = \text{sgn}(\bar{\alpha}_b) \\ 0 & \frac{\partial L(\bar{\alpha}_b)}{\partial \bar{\alpha}_b}(\bar{\alpha}_b = 0^+) > 0 \text{ and } \frac{\partial L(\bar{\alpha}_b)}{\partial \bar{\alpha}_b}(\bar{\alpha}_b = 0^-) < 0 \\ s^* & \frac{\partial L(\bar{\alpha}_b)}{\partial \bar{\alpha}_b}(\bar{\alpha}_b = s^{*+}) > 0 \text{ and } \frac{\partial L(\bar{\alpha}_b)}{\partial \bar{\alpha}_b}(\bar{\alpha}_b = s^{*-}) < 0 \end{cases} \tag{14}$$

考虑到  $\bar{\alpha}_b$  所受的矩形约束,即  $-C \leq \bar{\alpha}_b \leq C$ ,我们定义:

$$L = \max(s^{*-} - C, -C),$$

$$H = \min(C, s^{*+} + C),$$

以上等式的高低边界限制可以确保优化变量  $\bar{\alpha}_a, \bar{\alpha}_b$  的值在  $\pm C$  之间.

根据KKT条件可求得常值偏差  $\bar{\alpha}_0$  的更新,强迫使SVM的输出  $f_a = y_a, f_b = y_b$ ,有

$$\bar{\alpha}_0^a = \bar{\alpha}_0^{\text{old}} + f_a^* - y_a + (\bar{\alpha}_a^{\text{new}} - \bar{\alpha}_a^{\text{old}})k_{aa} + (\bar{\alpha}_b^{\text{new}} - \bar{\alpha}_b^{\text{old}})k_{ab},$$

$$\bar{\alpha}_0^b = \bar{\alpha}_0^{\text{old}} + f_b^* - y_b + (\bar{\alpha}_a^{\text{new}} - \bar{\alpha}_a^{\text{old}})k_{ab} + (\bar{\alpha}_b^{\text{new}} - \bar{\alpha}_b^{\text{old}})k_{bb}.$$

把以上两式平均,即可得到

$$\bar{\alpha}_0 = 0.5(\bar{\alpha}_0^a + \bar{\alpha}_0^b).$$

## 2.2 选择待优化Lagrange乘子

在 SMO 算法中,如何选择子优化问题的的工作集是非常重要的,它严重影响了算法的收敛性和快速性.事实上,即使我们不采用任何选择方法,只是按顺序抽取  $\bar{\alpha}_a, \bar{\alpha}_b$  的所有组合进行优化,目标函数也会不断下降,直到任意一对  $\bar{\alpha}_a, \bar{\alpha}_b$  都不能继续优化,目标函数就会收敛到极小值.但是这种情况下算法的收敛速度会很慢,为了提高算法的收敛速度,必须采用某种启发式方法来选择工作集.Platt 和 Smola 采用了一种两层循环的方法,外层循环遍历所有样本,找到训练集中违反 KKT 条件的样本,内层循环针对违反 KKT 条件的样本选择另一个样本与它配对优化(即指优化它们的 Lagrange 乘子),选择的依据是尽量使这样一对样本能取得最大优化步长.我们认为,这种选择优化变量的启发式策略存在一定的缺陷,就是第 1 个优化变量的选取过于随机.下面对这种优化变量的选择策略作进一步的改进,采用另一种启发式方法来选择待优化的 Lagrange 乘子  $\bar{\alpha}_a, \bar{\alpha}_b$ .

对于优化问题(5),当只考虑等式约束时,可以得到目标函数:

$$L = \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \bar{\alpha}_i \bar{\alpha}_j k_{ij} + \varepsilon \sum_{i=1}^l |\bar{\alpha}_i| - \sum_{i=1}^l \bar{\alpha}_i y_i + \lambda \sum_{i=1}^l \bar{\alpha}_i.$$

根据文献[10]可知,Lagrange乘子  $\lambda$  等于待求函数的常值参数  $b$ ,即  $\lambda=b$ ,因此有

$$L = \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \bar{\alpha}_i \bar{\alpha}_j k_{ij} + \varepsilon \sum_{i=1}^l |\bar{\alpha}_i| - \sum_{i=1}^l \bar{\alpha}_i y_i + b \sum_{i=1}^l \bar{\alpha}_i.$$

可求得目标函数对优化变量  $\bar{\alpha}_b$  的梯度分量为

$$\begin{aligned} \frac{\partial L}{\partial \bar{\alpha}_b} &= \sum_{i=1}^l \bar{\alpha}_i k_{ib} + b - y_b + \varepsilon \operatorname{sgn}(\bar{\alpha}_b) \\ &= f(x_b) - y_b + \varepsilon \operatorname{sgn}(\bar{\alpha}_b) \\ &= E_b + \varepsilon \operatorname{sgn}(\bar{\alpha}_b), \end{aligned}$$

其中  $\operatorname{sgn}(\cdot)$  是符号函数.

对于一个目标函数来说,一个优化变量的梯度分量的绝对值越大,这个优化变量的变化对目标函数值的改变就越大,因此我们就根据这一点来选择第 1 个优化变量,对于第 2 个优化变量的选择,像 Smola 所使用的方一样,使优化变量本身获得最大的变化量.综上所述,选择两个待优化变量的策略如下:

① 对第 1 个优化变量的选择是算法的外部循环,首先遍历训练样本集中的非边界样本,找出样本中违反 KKT 条件的样本,若找不到则遍历整个训练集,找出样本中违反 KKT 条件的样本,如果还是不存在违反 KKT 条件的样本则退出循环,结束程序;从违反 KKT 条件的样本中找出使目标函数梯度绝对值最大的样本(即  $\operatorname{Max}(|E_b + \varepsilon \operatorname{sgn}(\bar{\alpha}_b)|)$ )所对应的优化变量  $\bar{\alpha}_b$  作为第 1 个优化变量.

② (A) 在确定第 1 个优化变量之后,进入算法的内部循环,再从违反 KKT 条件的非边界样本中找出使  $|E_a - E_b|$  最大所对应的 Lagrange 乘子  $\bar{\alpha}_a$  作为第 2 个优化变量进行优化;

(B) 若(A)步所选择的优化变量不能产生改进,则遍历非边界样本,从违反 KKT 条件的优化变量中随机找出 Lagrange 乘子  $\bar{\alpha}_a$  进行优化;

(C) 若(B)也无法使优化变量产生改进,则遍历整个训练集,从违反 KKT 条件的优化变量中随机找出 Lagrange 乘子  $\bar{\alpha}_a$  进行优化;

(D) 若(A),(B),(C)都不行,则算法忽略外部循环中所选择的第 1 个样本,继续外部循环.

这种选择策略的第①步是使所选取的优化变量能够使目标函数的下降最多,第②步是使优化变量本身的变化量大,进而使目标函数的变化量大.

## 2.3 完整的SMO算法

总结以上各部分的讨论,完整的 SMO 算法可以表示如下:

- (1) 初始化  $\bar{\alpha}_a^{\text{old}}, \bar{\alpha}_b^{\text{old}}$ ;
- (2) 利用第 2.2 节提供的方法选择优化变量  $\bar{\alpha}_a, \bar{\alpha}_b$ ;

- (3) 利用式(14)计算  $\bar{\alpha}_b^{\text{new}}$ ;
- (4) 如果  $\bar{\alpha}_b^{\text{new}} > H$ , 设定  $\bar{\alpha}_b^{\text{new}} = H$ , 如果  $\bar{\alpha}_b^{\text{new}} < L$ , 设定  $\bar{\alpha}_b^{\text{new}} = L$ ;
- (5)  $\bar{\alpha}_a^{\text{new}} = \bar{\alpha}_a^{\text{old}} + \bar{\alpha}_b^{\text{old}} - \bar{\alpha}_b^{\text{new}}$ ;
- (6)  $\bar{\alpha}_0^{\text{new}} = \frac{1}{2}(\bar{\alpha}_0^a + \bar{\alpha}_0^b)$ ;
- (7) 如果对于所有的样本均满足 KKT 条件, go to (8), 否则 go to (2);
- (8) 输出  $\bar{\alpha}$ , 停止程序.

### 3 仿真实验

本节将采用一个具体的实例来验证我们所提出的算法, 选择所需要拟合的函数为

$$y(x) = 4\sin(2x) - x.$$

首先产生训练和测试样本集, 产生一个随机数列  $x$ , 具有 200 个点, 代入上式生成 200 个样本  $(x(k), y(k))$ , 如图 2 所示. 总样本集中的前 100 个作为训练样本, 用来训练 SVM, 后 100 个作为测试样本, 用来检验 SVM 的学习性能和泛化能力.

选择 SVM 的有关设计参数, 核函数选 RBF 函数, 即  $k(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right)$ , 并且设定:  $\frac{1}{2\sigma^2} = 0.4$ ,  $\varepsilon = 0.01$ ,

$C=50$ ,  $\tau=0.5$ . 采用上文提到的 SMO 算法来训练 SVM, 同时也利用原始的 SMO 算法来训练 SVM, 以便于比较. 得到如图 3 和图 4 所示的仿真结果.




Fig.2 Samples set

图2 样本集




Fig.3 The simulation result of improved SMO algorithm

图3 改进的SMO仿真结果




Fig.4 The simulation result of original SMO algorithm

图4 原始SMO算法仿真结果

图中, 点(.)代表 SVM 的输出, 实线(—)代表实际样本的输出. 从仿真结果图 3 和图 4 可以看出, 两个训练方法都能够使 SVM 具有良好的学习性能. 原始 SMO 的运行时间约为 5.6s, 训练误差为 0.11, 测试误差为 0.12; 我们提


出的 SMO 算法的运行时间为 1.7s,训练误差为 0.09,测试误差为 0.11.可以明显看出,我们提出的 SMO 算法比原始算法优越,不但运行时间短,而且拟合精度也好.

**Table 1** The contrast of improved SMO and original SMO

**表1** 改进的SMO和原始SMO的比较

	Training error	Testing error	Running time (s)
Improved SMO algorithm	0.09	0.11	1.7
Original SMO algorithm	0.11	0.12	5.4

在改变不灵敏参数 $\epsilon$ 时,可得到学习机的 $\epsilon$ 参数和支持向量的个数的关系,如图5所示.



**Fig.5** The number of support vector with parameter  $\epsilon$

图5 支持向量数随 $\epsilon$ 变化的曲线

可以看出,随着不灵敏参数 $\epsilon$ 的增大,支持向量数递减,支持向量机解的稀疏性增加.

## 4 结论

针对回归支持向量机的学习方法计算复杂度过高的难题,本文提出一种改进的 SMO 算法.仿真实验表明,它具有运算速度快、拟合精度高等优点,是较为实用的学习算法.未来的研究目标是设计出在线 SMO 学习算法,能用它来解决 SVM 的在线学习问题.

## References:

- [1] Vapnik VN. The Nature of Statistical Learning Theory. New York: Springer-Verlag, 1995.
- [2] Cherkassky V, Mulier F. Learning from Data-Concepts, Theory and Methods. New York: John Wiley Sons, 1998.
- [3] Joachims T. Text categorization with support vector machines: Learning with many relevant features. In: Proceedings of the European Conference on Machine Learning (ECML). Berlin: Springer-Verlag, 1998. 37~142.
- [4] Weston GJ, Barnhill S. Gene selection for cancer classification using support vector machines. Machine Learning, 2002,46(1-3): 389~422.
- [5] Platt JC. Fast training of support vector machines using sequential minimal optimization. In: Scholkopf B, Burges C, Smola A, eds. Advances in Kernel Methods: Support Vector Machines. Cambridge: MIT Press, 1998. 185~208.
- [6] Smola AJ. Learning with kernels [Ph.D. Thesis]. University of Birlinghoven, 1998.
- [7] Smola AJ, Scholkopf B. A tutorial on support vector regression. Technical Report, TR 1998-030. London: Royal Holloway College, 1998.

- [8] Shevade SK, Keerthi SS, Bhattacharyya C. Improvements to SMO algorithm for SVM regression. IEEE Transactions on Neural Networks, 2000,11(5):1188~1194.
- [9] Flake GW, Lawrence S. Efficient SVM regression training with SMO. Machine Learning Special Issue on SVMs, 2000,46(1~3): 271~290.
- [10] Martin M. On-Line support vector machines for function approximation. Technical Report, LSI-02-11-R. Catalunya: Department of Software, Universitat Politecnica de Catalunya, 2002.

## 2004 年全国理论计算机科学学术年会

### 征 文 通 知

由中国计算机学会理论计算机科学专业委员会主办, 海军工程大学信息与电气学院承办的“2004 年全国理论计算机科学学术年会”将于 2004 年 10 月在武汉召开。会议录用论文将收录在正式出版的论文集中, 欢迎大家积极投稿。现将有关征文要求通知如下:

1. 应征论文应未在其他刊物或学术会议上正式发表过。特别欢迎有创见的论文和有应用前景的论文。

2. 稿件要求用计算机打印, 格式为 38 行×38 字, 字体为 5 号宋体。稿件中的图形要求画得工整、清晰、紧凑, 尺寸要尽量小; 图中字体要求为六号宋体。稿件正文不超过六千字。标题、作者姓名、作者单位、摘要、关键词采用中英文间隔行文。稿件各部分依次为: 一、引言; 二、...; 最后是结束语。附录放在参考文献之后; 参考文献限已公开发表的, 文中最好不要出现文献序号。参考文献的格式为:

序号 作者·书名·出版社所在地: 出版社名, 出版年代

序号 作者·论文名·出处, 年代·卷号(期号): 起迄页码

务必附上第一作者简历(姓名、性别、出生年月、职称、学位、研究方向等)、通信地址和联系电话。并注明论文所属领域。请提供打印稿和电子稿各一份。来稿一律不退, 请自留底稿。

#### 3. 征文范围

程序理论(程序逻辑、程序正确性验证、形式开发方法等); 计算理论(算法设计与分析、复杂性理论、可计算性理论等); 语言理论(形式语言理论、自动机理论、形式语义学、计算语言学等); 人工智能(知识工程、机器学习、模式识别、机器人等); 逻辑基础(数理逻辑、多值逻辑、模糊逻辑、模态逻辑、直觉主义逻辑、组合逻辑等); 数据理论(演绎数据库、关系数据库、面向对象数据库等); 计算机数学(符号计算、数学定理证明、计算几何等); 并行算法(分布式并行算法、大规模并行算法、演化算法等)。

4. 征文截止日期: 2004 年 5 月 1 日

5. 论文投寄地址: (430033) 武汉 海军工程大学信息与电气学院 张志祥 收

联系电话: 027-83443985, 83443984 (张志祥, 贲可荣)

电子信箱: tcs2004@vip.sina.com; hgzzx@163.com