

r-SVR 中参数 r 与输入噪声间线性反比关系的仿真研究^{*})

朱嘉钢^{1,2} 王士同² 杨静宇¹

(南京理工大学计算机科学与工程系 南京 210094)¹ (江南大学信息工程学院 无锡 214035)²

摘要 为研究 r 范数-支持向量回归机 r -SVR 的鲁棒性,验证 r -SVR 中参数 r 与输入噪声方差之间的近似反比线性关系,对 r -SVR 进行了仿真。推导出了作为仿真的依据的 r -SVR 的解的形式和对其进行求解的牛顿迭代公式。仿真结果显示:输入噪声为高斯分布时, r -SVR 中参数 r 与输入噪声方差之间存在近似线性反比关系;这一关系曲线随着信噪比增加而斜率减小、整个曲线下移。这一结果印证和丰富了现前的理论推导结果,为在已知输入高斯噪声方差时合理地选择 r 提供了更可信的依据。

关键词 支持向量机,支持向量回归机, r 范数损失函数,计算机仿真

Experimental Studies on Inversely Linear Dependency between r and the Input Noise in r -support Vector Regression

ZHU Jia-Gang^{1,2} WANG Shi-Tong² YANG Jing-Yu¹

(Department of Computer Science and Technology, Nanjing University of Science and Technology, Nanjing 210094)¹

(School of Information & Engineering, Southern Yangtze University, Wuxi 214036)²

Abstract When the distribution of the input noise is known, the optimal parameter choice for the loss function can help SVR enhance its robustness. R -loss function is a more general form of both quadratic loss function and Laplacian loss function. Therefore, research on the dependency relationship between parameter r in r -loss function and input noise has more general significance. It has been theoretically deduced that inversely linear dependency exists between r and the input noise in r -SVR. In this paper, we intend to validate the linear dependency between r and the input noise through studying its implementation method and simulations. We derive the solution of r -SVR by using the Newton descent method. Our experimental results confirm the previously obtained theoretical conclusion.

Keywords Support vector machines(SVM), Support vector regression(SVR), R -loss function, Simulations

1 引言

近年来,支持向量机 SVM 在各种分类问题和回归(又可称为建模)问题中得到广泛应用。各种 SVM 通常基于三类损失函数,即 ϵ -不敏感损失函数、Huber 损失函数^[12]和 r 范数损失函数。其中, r 范数损失函数当 r 为 2 时是平方损失函数,而当 r 为 1 时则为 Laplace 损失函数。

当 SVM 用于建模时,通常称其为支持向量回归机 SVR (support vector regression)。由于真实的数据经常含有噪声,因此,在用 SVR 进行建模时,如何选择合适的参数使 SVR 具有更好的鲁棒性就成了一个重要研究课题。J. Kwok 和本文作者最近研究了当输入噪声已知时, ϵ -支持向量回归机 ϵ -SVR、Huber-支持向量回归机 Huber-SVR 的参数最佳选择方法^[7,8],并从理论上研究了 r 范数-支持向量回归机 r -SVR 中参数 r 的选择问题。在后验概率最大化的理论框架下,本文作者先前的理论工作表明: r -SVR 中参数 r 与输入噪声方差间存在近似线性反比关系,即在已知输入噪声方差情况下,可以通过调节 r -SVR 的参数 r 来抑制输入噪声^[11]。理论的结果需要验证,但 r -SVR 的解的形式由于需要另行推导,对其进行求解的方法需要另行设计,故需要专门来研究仿真结果,以验证理论结果的正确性。本文的目的在此。

在 SVR 的仿真方面, ϵ -SVR 和 Huber-SVR 已有现成的求解公式,求解 ϵ -SVR 和 Huber-SVR 的问题是一个二次规划问题,对 ϵ -SVR 和 Huber-SVR 的仿真相对容易些。而求

解 r -SVR 比求解二次规划问题复杂,仿真难度更大。为对 r -SVR 进行仿真,本文推导出了 r 范数-支持向量回归机的求解公式,并进一步推导出了对其 r 范数-支持向量回归机的牛顿迭代公式。在此基础上,用仿真的方法研究了输入噪声为高斯噪声时 r -SVR 中参数 r 与输入噪声方差之间的关系,得出了 r -SVR 中参数 r 与输入噪声方差之间的近似线性反比关系的结果。这一结果印证和丰富了现前的理论推导的结果,为在已知输入高斯噪声方差时合理地选择 r 提供了更可信的依据。

本文第 2 节扼要介绍 r 范数-支持向量回归机并推导出 r 范数-支持向量回归机的解,第 3 节推导出求解 r 范数-支持向量回归机的牛顿迭代公式,第 4 节给出仿真的方法和仿真结果,最后对结果作一些讨论。

2 r 范数-支持向量回归机及其解

2.1 r 范数-支持向量回归机 r -SVR

本节先定义 r 范数-支持向量回归机 r -SVR 的基本概念。

考虑用函数 $f(x) = \langle w, x \rangle + b$

来逼近下列数据集:

$D = \{(x_1, y_1), \dots, (x_n, y_n)\}, x \in R^d, y \in R$, 这里 n 为样本数目。

若使用 r 范数损失函数:

$L_r(f(x) - y) = |f(x) - y|^r$

最优回归函数可通过求解下式得到:

^{*}) 本文的工作得到国家自然科学基金资助(60225015),江苏省自然科学基金(BK2003017),南京大学软件新技术国家重点实验室开放课题和江苏计算机技术重点实验室开放课题的资助。朱嘉钢 博士生,副教授,主要研究领域为人工神经网络,模式识别。王士同 教授,博士生导师,主要研究领域为人工神经网络,模式识别,计算机视觉,模糊系统等。

$$\min \Phi(w, \xi) = \frac{1}{2} \|w\|^2 + C \sum_i \xi_i, \quad (1)$$

s. t.

$$\begin{cases} |f(x_i) - y_i| \leq \xi_i, i=1, \dots, l \\ \xi_i \geq 0 \end{cases}$$

这里 C 是设定常数, $\xi = (\xi_1, \xi_2, \dots, \xi_l)$, 其中 $\xi_i (i=1, 2, \dots, l)$ 表示约束系统输出的松弛变量。上式中也可用核函数 $K(w, x)$ 代替点积 $\langle w, x \rangle$ 。

r 范数损失函数与式(1)一起即构成 r 范数-支持向量回归机 r -SVR。

2.2 r 范数-支持向量回归机的解的形式

为对 r 范数-支持向量回归机 r -SVR 进行仿真, 需要有 r -SVR 的解的形式。现在推导 r -SVR 的解的形式。

对式(1), 由 KKT 条件可将式(1)化为

$$\min L(w, b, \xi, \alpha, \alpha^*, \gamma) = \frac{1}{2} \|w\|^2 + C \sum_i \xi_i + \sum_i \alpha_i [y_i - f(x_i) - \xi_i^{\frac{1}{r}}] + \sum_i \alpha_i^* [f(x_i) - y_i - \xi_i^{\frac{1}{r}}] - \sum_i \gamma_i \xi_i$$

s. t.

$$\begin{cases} \alpha_i \geq 0, \\ \alpha_i^* \geq 0, \\ \gamma_i \geq 0, i=1, \dots, l \\ \xi_i \geq 0 \end{cases}$$

再分别令 $\frac{\partial L}{\partial w} = 0, \frac{\partial L}{\partial b} = 0$, 和 $\frac{\partial L}{\partial \xi_i} = 0, \frac{\partial L}{\partial \gamma_i} = 0, i=1, \dots, l$, 并代入上式, 可得

$$\min L(\alpha, \alpha^*, \gamma) = \frac{1}{2} \sum_{i,j=1}^l (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) \langle x_i, x_j \rangle - \sum_{i=1}^l (\alpha_i - \alpha_i^*) y_i + \frac{r-1}{r^{\frac{r-1}{r-1}} C^{\frac{r-1}{r-1}}} \sum_{i=1}^l (\alpha_i + \alpha_i^*)^{\frac{r}{r-1}}$$

s. t.

$$\begin{cases} \alpha_i \geq 0, \\ \alpha_i^* \geq 0, \\ \gamma_i \geq 0, i=1, \dots, l \\ \sum_{i=1}^l (\alpha_i - \alpha_i^*) = 0 \end{cases}$$

显然在极值点, 有 $\gamma_i = 0, i=1, \dots, l$ 。于是上述问题变为

$$\min L(\alpha, \alpha^*) = \frac{1}{2} \sum_{i,j=1}^l (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) \langle x_i, x_j \rangle - \sum_{i=1}^l (\alpha_i - \alpha_i^*) y_i + \frac{r-1}{r^{\frac{r-1}{r-1}} C^{\frac{r-1}{r-1}}} \sum_{i=1}^l (\alpha_i + \alpha_i^*)^{\frac{r}{r-1}} \quad (2)$$

s. t.

$$\begin{cases} \alpha_i \geq 0, \\ \alpha_i^* \geq 0, i=1, \dots, l \\ \sum_{i=1}^l (\alpha_i - \alpha_i^*) = 0 \end{cases}$$

式(2)即为 r 范数支持向量机式(1)的解。注意在式(2)中可以用核函数 $K(x_i, x_j)$ 代替点积 $\langle x_i, x_j \rangle$, 考虑本文的重点是探讨 r -SVR 中参数 r 与噪声之间的关系, 这里就不必给予更多的研究了。

3 求解 r 范数-支持向量回归机的牛顿迭代公式

求解 r -SVR 是一个优化的问题, 我们分别用负梯度下降法、牛顿迭代法等进行求解和仿真。由于牛顿迭代法收敛速度快, 本文给出用牛顿迭代法仿真的过程。

首先推导求解式(2)的牛顿迭代公式。与其它支持向量回归机解的形式不同, 式(2)的最小值问题不是一个二次规划问题, 不能直接用求解二次规划的方法来求解, 其求解要困难一些。我们用其它的优化方法来求解, 一般的做法是, 先设法

将条件极值问题转化为与其等价(或近似等价)的无条件极值问题, 再求解该无条件极值问题。

考虑到约束条件中参数的严格非负, 用内点法^[10]将式(2)的条件极值问题转化为无条件极值问题。若令障碍项为

$$P(\alpha, \alpha^*) = -N \left(\sum_{i=1}^l \log \alpha_i + \sum_{i=1}^l \log \alpha_i^* \right) + M \left[\sum_{i=1}^l (\alpha_i - \alpha_i^*) \right]^2$$

其中 M, N 为障碍因子, 则可构造障碍函数

$$\varphi(\alpha, \alpha^*) = L(\alpha, \alpha^*) + P(\alpha, \alpha^*)$$

则上述条件极值问题即成为如下无条件极值问题

$$\min \varphi(\alpha, \alpha^*) = L(\alpha, \alpha^*) + P(\alpha, \alpha^*)$$

为提高收敛速度, 用牛顿法(即二阶梯度法)求解之, 迭代公式为

$$\begin{bmatrix} \alpha_k \\ \alpha_k^* \end{bmatrix} = \begin{bmatrix} \alpha_{k-1} \\ \alpha_{k-1}^* \end{bmatrix} - [\nabla^2 \varphi(\alpha_{k-1}, \alpha_{k-1}^*)]^{-1} \nabla \varphi(\alpha_{k-1}, \alpha_{k-1}^*) \quad (3)$$

其中 k 为迭代次数, 则

$$\text{梯度 } \nabla \varphi(\alpha, \alpha^*) = \begin{bmatrix} \frac{\partial \varphi}{\partial \alpha_1} \\ \vdots \\ \frac{\partial \varphi}{\partial \alpha_i} \\ \vdots \\ \frac{\partial \varphi}{\partial \alpha_i^*} \\ \vdots \\ \frac{\partial \varphi}{\partial \alpha_l^*} \end{bmatrix}, \text{ 是一个 } 2l \text{ 维向量。 (注意, 为}$$

书写方便, 这里的下标 k 被忽略, 下文同此)。

其中, 经推导得,

$$\frac{\partial \varphi}{\partial \alpha_i} = \sum_{j=1}^l (\alpha_j - \alpha_j^*) \langle x_i, x_j \rangle - y_i + \left(\frac{\alpha_i + \alpha_i^*}{rC} \right)^{\frac{1}{r-1}} - \frac{N}{\alpha_i} + 2M$$

$$\sum_{j=1}^l (\alpha_j - \alpha_j^*), i=1, \dots, l,$$

$$\frac{\partial \varphi}{\partial \alpha_i^*} = - \sum_{j=1}^l (\alpha_j - \alpha_j^*) \langle x_i, x_j \rangle + y_i + \left(\frac{\alpha_i + \alpha_i^*}{rC} \right)^{\frac{1}{r-1}} - \frac{N}{\alpha_i^*} -$$

$$2M \sum_{j=1}^l (\alpha_j - \alpha_j^*), i=1, \dots, l,$$

$$\text{而 } \nabla^2 \varphi(\alpha, \alpha^*) =$$

$$\begin{bmatrix} \frac{\partial^2 \varphi}{\partial \alpha_1^2} & \dots & \frac{\partial^2 \varphi}{\partial \alpha_1 \partial \alpha_1} & \frac{\partial^2 \varphi}{\partial \alpha_1 \partial \alpha_1^*} & \dots & \frac{\partial^2 \varphi}{\partial \alpha_1 \partial \alpha_1^*} \\ \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 \varphi}{\partial \alpha_i \partial \alpha_1} & \dots & \frac{\partial^2 \varphi}{\partial \alpha_i^2} & \frac{\partial^2 \varphi}{\partial \alpha_i \partial \alpha_1^*} & \dots & \frac{\partial^2 \varphi}{\partial \alpha_i \partial \alpha_1^*} \\ \frac{\partial^2 \varphi}{\partial \alpha_1^* \partial \alpha_1} & \dots & \frac{\partial^2 \varphi}{\partial \alpha_1^* \partial \alpha_i} & \frac{\partial^2 \varphi}{\partial (\alpha_1^*)^2} & \dots & \frac{\partial^2 \varphi}{\partial \alpha_1^* \partial \alpha_i^*} \\ \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 \varphi}{\partial \alpha_i^* \partial \alpha_1} & \dots & \frac{\partial^2 \varphi}{\partial \alpha_i^* \partial \alpha_i} & \frac{\partial^2 \varphi}{\partial \alpha_i^* \partial \alpha_1^*} & \dots & \frac{\partial^2 \varphi}{\partial (\alpha_i^*)^2} \end{bmatrix}, \text{ 是一}$$

个 $2l \times 2l$ 的 Hessian 矩阵。

其中, 经推导得,

$$\frac{\partial^2 \varphi}{\partial \alpha_i \partial \alpha_j} = \begin{cases} \langle x_i, x_i \rangle + \frac{1}{r-1} \left(\frac{\alpha_i + \alpha_i^*}{C} \right)^{\frac{2-r}{r-1}} + \frac{N}{\alpha_i^2} + 2M, i=j \\ \langle x_i, x_j \rangle + 2M, i \neq j \end{cases}, i, j=1, \dots, l$$

$j=1, \dots, l$

$$\frac{\partial^2 \varphi}{\partial \alpha_i^* \partial \alpha_j^*} = \begin{cases} \langle x_i, x_i \rangle + \frac{1}{r-1} \left(\frac{\alpha_i + \alpha_i^*}{C} \right)^{\frac{2-r}{r-1}} + \frac{N}{\alpha_i^2} + 2M, i=j \\ \langle x_i, x_j \rangle + 2M, i \neq j \end{cases}, i, j=1, \dots, l,$$

$$\frac{\partial^2 \varphi}{\partial \alpha_i \partial \alpha_j^*} = \frac{\partial^2 \varphi}{\partial \alpha_j^* \partial \alpha_i} =$$

$$\begin{cases} (x_i, x_i) + \frac{1}{r-1} \left(\frac{\alpha_i + \alpha_i'}{C} \right)^{\frac{2}{r-1}} + \frac{N}{\alpha_i^2} + 2M, i=j \\ (x_i, x_j) + 2M, i \neq j \end{cases}, i, j=1, \dots, l,$$

通过选择合适的 M 和 N 序列 ($0 < M_1 < M_2 < \dots < M_k$ 和 $N_1 > N_2 > \dots > N_k > 0$)，式(3)的解就近似于式(2)的解。

4 仿真结果与分析

4.1 仿真步骤

本文作者在文[11]中从理论上推导出了 r 与 σ 之间的近似线性反比关系。现在让我们运用上述算法通过仿真来验证 r 与 σ 之间的近似线性反比关系是不是成立。方法如下：

取函数 $y = \frac{\sin(x)}{x}$, $x \in [-10, 10]$ ，为基准信号，令 x 从 -10 至 10，步长为 0.5 产生其样本 (x_i, y_i) , $i=1, \dots, 41$ ，用 r -SVR 对这些样本作回归得到对应于 $y = \frac{\sin(x)}{x}$ 的回归曲线 $f = f(x)$ 。

对应地，取函数 $y' = \frac{\sin(x)}{x} + k \cdot \eta$, $x \in [-10, 10]$ ，为加入了噪声的信号，其中 k 为信噪比系数， $\eta \sim N(0, \sigma^2)$ 为高斯噪声。令 x 从 -10 至 10，步长为 0.5 产生其样本 (x_i, y'_i) , $i=1, \dots, 41$ ，用 r -SVR 对这些样本作回归得到对应于 $y' = \frac{\sin(x)}{x} + k \cdot \eta$ 的回归曲线 $f' = f(x)$ 。

在进行 r -SVR 回归时，令 σ 在 $[0, 2.8]$ 上变化，对于一个给定的 σ_k ，取使 $\sum_{i=1}^{41} (f'_i - f_i)^2$ 最小的 r_k ，得到一个点 (r_k, σ_k) , $k=1, \dots, 15$ 。最后对 (r_k, σ_k) , $k=1, \dots, 15$ 作回归，得到 r 与 σ 之间的关系曲线。由于 η 是随机变量，实际计算时，对于每一个给定的 σ_k ，产生 20 组 η 的值，每一组都计算出一个 r'_k ，取该 20 个 r'_k 的平均值作为最后的 r_k ，以抑制 r_k 的随机性。

4.2 仿真结果

图 1 至图 5 给出了仿真结果。




图 1 无噪声时的回归曲线 $r=2$




图 2 加噪声后的回归曲线 $r=2$

(“*”为无噪声时的样本点，“+”为加噪声后的样本点， $k=0.05$)

图 1 中，符号“+”是样本 (x_i, y_i) , $i=1, \dots, 41$ ，实线是对其回归的结果；图 2 中，符号“*”是样本 (x_i, y_i) , $i=1, \dots, 41$ ，符号“+”是加了噪声的对应的样本，虚线是对“+”号点回归的结果。

在图 3 至图 5 中，符号“+”是 r ，由于 r 有随机性，对其进行回归并用实线表示，实线反映了 r 随着 σ 的变化而变化的趋势。




图 3 $k=0.05$ 时的 r 与 σ 的关系曲线




图 4 $k=0.15$ 时的 r 与 σ 的关系曲线




图 5 $k=0.30$ 时的 r 与 σ 的关系曲线

4.3 结果分析

从上面的仿真结果可知， r 与 σ 之间存在着近似的线性反比关系， r 随着 σ 的增加而减小； r 与 σ 的关系曲线随着信噪比增加而斜率减小，整个曲线下移。信噪比较小时，噪声对信号几乎没有影响， r 的取值接近于 2；信噪比噪声较大时，噪声对信号产生影响， r 的取值呈现下降趋势，即线性反比关系。注意，由于这里的仿真基于近似计算， r 的实际取值范围的下限应更小一些。

由上述可知， r 与 σ 之间存在着近似的线性反比关系的理论推导结果与仿真结果基本吻合，而仿真结果进一步给出了 r 与 σ 的关系曲线随着信噪比增加而斜率减小的规律，是对理论推导结果的丰富和完善。

结论 本文用仿真的方法验证理论推导已经得出的 r 范

(下转第 238 页)

- ware Engineering, 1986, 12(2):211~221
- 21 Shoham Y. Agent-oriented programming. Artificial Intelligence, 1993, 60 (1):51~92
 - 22 Kiczales G, Lamping J, Mendhekar A, et al. Aspect-Oriented Programming. ACM Computing Surveys, Dec. 1996.28
 - 23 Cordsen J, Schroder-Preikschat W. Object-Oriented Operating System Design and the Revival of Program Families. In: Proc. of the Second Intl. Workshop on Object Orientation in Operating Systems (I-WOOS' 91), 1991. 24~28
 - 24 Chen L T. AgentOS: the agent-based distributed operating system for mobile networks, Special issue on networks and distributed systems Winter 1998 (2):12~14
 - 25 Coady Y, Kiczales G, Feeley M. Exploring an Aspect-Oriented Approach to Operating System Code. Workshop on Advanced Separation of Concerns at OOPSLA 2000, Minneapolis, MN, Oct. 2000
 - 26 Liedtke J. On μ -Kernel Construction. In: Proc. of the Fifteenth ACM Symposium on Operating System Principles (Copper Mountain Resort, CO., Dec. 3-6). ACM Press, New York, NY, 1995. 237~250
 - 27 Artiaga A E, Serra A, Gil M. Porting multithreading libraries to an exokernel system. In: Proc. of the 9th workshop on ACM SIGOPS European workshop: beyond the PC; new challenges for the operating system, 2000. 121~126
 - 28 Ganger G, Engler D, Kaashoek M F, Briceno H, Hunt R, Pinckney T. Fast and Flexible Application-Level Networking on Exokernel Systems. ACM Transactions on Computer Systems, Feb. 2002, 20(1):49~83
 - 29 Christophe Rippert Protection in flexible operating system architectures, ACM SIGOPS Operating Systems Review, 2003, 37(4): 8~18
 - 30 Swift M M, Bershad B N, Levy H M. Improving the reliability of commodity operating systems, In: Proc. of the nineteenth ACM symposium on Operating systems principles, 2003. 207~222
 - 31 Burnside M, Keromytis A D. HighSpeed I/O: The Operating System As A Signalling Mechanism, ACM SIGCOMM 2003 Workshops, Aug. 2003. 25~29
 - 32 Bomberger A C, Frantz W S, Hardy A C, et al. The KeyKOS Nanokernel Architecture. In: Proc. of the USENIX Workshop on Micro-Kernels and Other Kernel Architectures, USENIX Association, April 1992. 95~112
 - 33 Assenmacher H, Breitbach T, Buhler P, Htibsch V, Schwarz R. The PANOVA System Architecture - A Pico-Kernel Approach. In: Proc. 4th Workshop on Future Trends of Distributed Computing Systems, Lisbon, Portugal, Sep. 1993. 470~476
 - 34 Zegzhda D P, Stepanov P G, Otavin A D. Fenix Secure Operating System: Principles, Models, and Architecture. MMM-ACNS 2001, LNCS 2052, 2001. 207~218
 - 35 Sztipanovits J, Karsai G. Generative Programming for Emedded Systems. GPCE 2002, LNCS 2487, 2002. 32~49

(上接第 207 页)

数-支持向量回归机中参数 r 与 σ 之间的近似线性反比关系的结论,并进一步得出了 r 与 σ 的关系曲线的斜率随着信噪比增加而减小、整个曲线下移的结果。上述结果印证和丰富和补充了先前的对此问题的理论研究结果,为 r 范数-支持向量回归机在输入信号存在噪声时合理的选择参数以提高其鲁棒性提供了更可信的依据。

参 考 文 献

- 1 Cristianini N, Shawe-Taylor J. An Introduction to Support Vector Machines[M]. Cambridge University Press, 2000
- 2 Vapnik V. Statistical Learning Theory[M]. New York: Wiley, 1998
- 3 Kwok J T, Tsang I W. Linear dependency between ϵ and the input noise in ϵ -support vector regression[J]. IEEE Transaction on Neural Networks, 2003(5)
- 4 Smola A J, Murata N, Schölkopf B, Müller K-R. Asymptotically optimal choice of ϵ -loss for support vector machines[A]. In: Proc. of the Intl. Conf. on Artificial Neural Networks[C]. 1998
- 5 Smola A J, Schölkopf B. A tutorial on support vector regression. Royal Holloway College, 1998, NeuroCOLT2 Technical Report NC2-TR-1998-030
- 6 Law M H, Kwok J T. Bayesian support vector regression[A]. In: Proc. of the English Intl. Workshop on Artificial Intelligence and Statistics[C]. Florida; Key West, 2001. 239~244
- 7 Gao J B, Gunn S R, Ham's C J. A probabilistic framework for SVM regression and Error Bar Estimation[J]. Machine Learning, 2002, 46:71~89
- 8 Cherkassky V, Ma Yunqian. Practical selection of SVM parameters and noise estimation for SVM regression[J]. Neural Networks, in press, 2003
- 9 阎平凡, 张长水. 神经网络和模拟进化计算[M]. 北京: 清华大学出版社, 2001
- 10 沈永欢, 等. 实用数学手册[M]. 北京: 科学出版社, 2002
- 11 朱嘉钢, 王士同, 杨静宇. 鲁棒的 r -支持向量回归机中参数 r 的选择研究[J]. 控制与决策(已录用, 文号 04105)