

文章编号: 1001-0920(2008)12-1363-05

一种基于 Cholesky 分解的动态无偏 LS-SVM 学习算法

蔡艳宁, 胡昌华

(第二炮兵工程学院 302 教研室, 西安 710025)

摘要: 针对最小二乘支持向量机用于在线建模时存在的计算复杂性问题, 提出一种动态无偏最小二乘支持向量回归模型. 该模型通过改进标准最小二乘支持向量机结构风险的形式消除了偏置项, 得到了无偏的最小二乘支持向量机, 简化了回归系数的求解. 根据模型动态变化过程中核函数矩阵的特点, 设计了基于 Cholesky 分解的在线学习算法. 该算法能充分利用历史训练结果, 减少计算复杂性. 仿真实验表明了所提出模型的有效性.

关键词: 最小二乘支持向量机; 在线学习; 时间序列预测; 系统辨识

中图分类号: TP183

文献标识码: A

Dynamic non-bias LS-SVM learning algorithm based on Cholesky factorization

CAI Yan-ning, HU Chang-hua

(Unit 302, The Second Artillery Engineering Institute, Xi'an 710025, China. Correspondent: CAI Yan-ning, E-mail: caiyaning666@yahoo.com.cn)

Abstract: Aiming at the computational complexity of LS-SVM's on-line modeling, a dynamic non-bias least square support vector regression model is proposed. The model eliminates the bias of LS-SVM by improving the form of structure risk. As a result, the non-bias LS-SVM is achieved and the calculation method of regression coefficients is simplified. Then an online learning algorithm based on the Cholesky factorization is designed according to the character of kernel function matrix in the model's dynamic change process. The improved learning algorithm can make full use of the historical training results and reduce the computational complexity. Experimental results indicate the effectiveness of the dynamic non-bias LS-SVM.

Key words: Least square support vector machine (LS-SVM); Online learning; Time series prediction; System identification

1 引言

支持向量机(SVM)是20世纪90年代中期提出的一种机器学习算法,其理论基础是Vapnik等人提出的统计学习理论^[1]. Suykens等人在统计学习理论的基础上,对SVM进行了扩展^[2],提出一种最小二乘支持向量机(LS-SVM).这两种方法由于其优秀的学习和泛化能力,已逐步应用于模式识别、函数拟合、概率密度估计等领域,并取得了较好的效果.这些应用实例绝大部分是离线式的,采用离线学习算法就可以解决.但是,如果训练样本随着时间的推移逐步注入到训练集中,就必须使用支持向量机的在线学习算法.近年来,一些学者针对标准SVM

提出了在线学习方法^[3-5],该问题的本质是在线求解带约束条件的二次规划问题,计算复杂性较高.因此,一些学者研究在线LS-SVM算法,其中新近提出的方法的主要思想是将核函数矩阵分块,利用分块矩阵求逆公式对LS-SVM进行在线训练^[6,7].

为了进一步提高LS-SVM的在线建模效率,本文提出一种动态无偏LS-SVM模型,并设计了新的在线学习算法.该模型的优点在于简化了在线学习过程中回归系数的求解;针对核函数矩阵的特点设计了基于分块矩阵Cholesky分解的在线学习算法.与在线LS-SVM相比,动态无偏LS-SVM模型具有较快的运算速度,更适合于在线学习和预测.

收稿日期: 2007-09-21; 修回日期: 2008-01-02.

基金项目: 国家自然科学基金重点项目(60736026); 教育部新世纪优秀人才支持计划项目.

作者简介: 蔡艳宁(1980—),女,辽宁瓦房店人,博士生,从事故障预报、时间序列预测的研究; 胡昌华(1966—),男,湖北罗田人,教授,博士生导师,从事控制系统自动检测、故障诊断等研究.

2 最小二乘支持向量机

对于有 l 个数据的样本集合 $\{(x_i, y_i)\}, x_i \in R^n, y_i \in R, i = 1, 2, \dots, l$, LS-SVM 可描述为如下约束优化问题:

$$\begin{aligned} \min & \frac{1}{2} \sum_{i=1}^l \tau + \frac{1}{2} C \sum_{i=1}^l \eta_i^2, \\ \text{s.t.} & y_i - \sum_{j=1}^n \tau_j (x_i)_j - b = \eta_i, \\ & i = 1, 2, \dots, l. \end{aligned} \quad (1)$$

其中: τ_j 将输入数据映射到高维特征空间, τ 为权值向量, $C > 0$ 为惩罚系数, η_i 和 b 分别为误差变量和偏置. 针对式(1) 建立 Lagrange 函数

$$\begin{aligned} L = & \frac{1}{2} \sum_{i=1}^l \tau + \frac{1}{2} C \sum_{i=1}^l \eta_i^2 - \\ & \sum_{i=1}^l \lambda_i [\sum_{j=1}^n \tau_j (x_i)_j + b + \eta_i - y_i], \end{aligned} \quad (2)$$

其中 λ_i 为 Lagrange 乘子. 对式(2) 各变量求偏导并整理, 得线性方程组

$$\begin{bmatrix} 0 & E^T \\ E & K + C^{-1}I \end{bmatrix} \begin{bmatrix} b \\ Y \end{bmatrix} = \begin{bmatrix} 0 \\ Y \end{bmatrix}. \quad (3)$$

其中: $K_{i,j} = (\sum_{k=1}^n (x_i)_k \cdot (x_j)_k) = k(x_i, x_j), k(\cdot, \cdot)$ 为核函数; $Y = (y_1, y_2, \dots, y_l)^T, \tau = (\tau_1, \tau_2, \dots, \tau_l)^T, E = (1, \dots, 1)^T, I$ 为单位阵. LS-SVM 的输出为

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

令 $H = K + C^{-1}I$, 则 τ 和 b 可由下式求出:

$$b = \frac{E^T H^{-1} Y}{E^T H^{-1} E} \quad (5)$$

$$\tau = H^{-1} (Y - \frac{E E^T H^{-1} Y}{E^T H^{-1} E}). \quad (6)$$

在线 LS-SVM 的学习算法利用 H 的分块求逆来实现^[6,7]. 该方法有两个缺陷: 一是没有利用 H 矩阵对称正定这一特点; 二是需经过繁杂的矩阵运算方可求出回归系数和偏置. 针对这两个问题, 本文提出了改进算法.

3 无偏 LS-SVM

支持向量机的结构风险最小化的核心思想是

$$R[f] = R_{emp} + R_{gen}. \quad (7)$$

其中: $R[f]$ 为期望风险; R_{emp} 为经验风险, 它是回归函数与样本偏差的一种度量; R_{gen} 是置信范围, 它是回归函数复杂度的一种度量. 文献[8-10] 对标准支持向量机的置信范围进行了改动, 形成了新的支持向量机, 并提出了新的训练算法. 借鉴这种思路, 本文对 LS-SVM 结构风险的形式进行改进, 形成一种无偏 LS-SVM. 该模型的目标函数和约束条件为

$$\min \frac{1}{2} \sum_{i=1}^l \tau + \frac{1}{2} b^2 + \frac{1}{2} C \sum_{i=1}^l \eta_i^2,$$

$$\begin{aligned} \text{s.t.} & y_i - \sum_{j=1}^n \tau_j (x_i)_j - b = \eta_i, \\ & i = 1, 2, \dots, l. \end{aligned} \quad (8)$$

令 $\tau = (\tau_1, \tau_2, \dots, \tau_l)^T$, 则式(8) 变为

$$\begin{aligned} \min & \frac{1}{2} \sum_{i=1}^l \tau + \frac{1}{2} C \sum_{i=1}^l \eta_i^2, \\ \text{s.t.} & y_i - \sum_{j=1}^n \tau_j (x_i)_j - b = \eta_i, \\ & i = 1, 2, \dots, l. \end{aligned} \quad (9)$$

为求解上述优化问题, 建立 Lagrange 函数

$$\begin{aligned} L = & \frac{1}{2} \sum_{i=1}^l \tau + \frac{1}{2} C \sum_{i=1}^l \eta_i^2 - \\ & \sum_{i=1}^l \lambda_i [\sum_{j=1}^n \tau_j (x_i)_j + b + \eta_i - y_i]. \end{aligned} \quad (10)$$

对式(10) 各变量求偏导并整理, 得线性方程组

$$(K + C^{-1}E + C^{-1}I) \tau = Y. \quad (11)$$

其中: E 为全 1 矩阵, I 为单位阵. 无偏 LS-SVM 回归函数的形式为

$$f(x) = \sum_{i=1}^l \lambda_i (k(x, x_i) + \tau_i). \quad (12)$$

由式(12) 可以看出, 无偏 LS-SVM 模型通过引入参数 τ_i 消除了偏置项. 令 $H = K + C^{-1}E + C^{-1}I, H > 0, C > 0$, 则式(11) 简化为 $H \tau = Y$. 下面讨论矩阵 H 的性质, 以求取回归系数向量 τ .

定理 1 设 X 是 R^n 的子集. 若 $k(x, x)$ 是定义在 $X \times X$ 上的支持向量机核函数, 则对于任意的 $x_1, \dots, x_l \in X, H = K + C^{-1}E + C^{-1}I$ 是对称正定矩阵. 其中: $K_{i,j} = k(x_i, x_j), \lambda_i > 0, C > 0$.

证明 对称性. 设 X 是 R^n 的一个子集, $k(x, x)$ 是支持向量机的核函数, 则存在 X 到某一高维空间的映射 $\phi(\cdot)$, 使得 $k(x, x) = (\phi(x) \cdot \phi(x))$. 因为 $K_{i,j} = k(x_i, x_j) = (\phi(x_i) \cdot \phi(x_j)) = k(x_j, x_i) = K_{j,i}$, 所以矩阵 K 为对称矩阵, 且 E 为全 1 矩阵, I 为单位阵, 因此 H 为对称矩阵.

正定性. 对于任意的 $z = (z_1, \dots, z_l)^T \neq 0$, 有

$$\begin{aligned} z^T H z = & z^T K z + \sum_{i=1}^l z_i^T E z + C^{-1} z^T z = \\ & \left\| \sum_{i=1}^l z_i \phi(x_i) \right\|^2 + \sum_{i=1}^l z_i^2 + C^{-1} \sum_{i=1}^l z_i^2 > 0. \end{aligned} \quad (13)$$

因此矩阵 H 为对称正定矩阵.

由定理 1 可知, 矩阵 H 满足对称正定性, 因此可进行 Cholesky 分解. H 可唯一地分解为 $H = U^T U$, 其中 U 为上三角阵. U 中矩阵的元素由以下计算公式确定:

$$\begin{aligned} u_{ii} = & \left(h_{ii} - \sum_{k=1}^{i-1} u_{ki}^2 \right)^{1/2}, \quad i = 1, 2, \dots, l; \\ u_{ij} = & \left(h_{ij} - \sum_{k=1}^{i-1} u_{ki} u_{kj} \right) / u_{ii}, \quad j > i. \end{aligned} \quad (14)$$

无偏 LS-SVM 模型中 可由下式计算:

$$p_i = \left(y_i - \sum_{k=1}^{i-1} u_{ki} p_k \right) / u_{ii},$$

$$i = \left(p_i - \sum_{k=i+1}^n u_{ik} x_k \right) / u_{ii}. \quad (15)$$

4 动态无偏 LS-SVM 的在线学习

动态无偏 LS-SVM 的在线学习算法的设计思想是:当得到新的样本时,遗忘最早时刻的旧样本,并以尽可能小的计算代价更新当前时间窗中训练样本的回归系数向量.

设滑动时间窗的长度为 l , t 时刻时间窗中样本的形式为 $(x_i, y_i), i = t - l + 1, \dots, t$. 动态无偏 LS-SVM 模型的核函数矩阵 K , 训练样本输出 Y 和待求的回归系数向量 都是 t 的函数,表示如下:

$$K_{i,j}(t) = k(x_i, x_j),$$

$$x(t) = (x_{t-l+1}, \dots, x_t)^T,$$

$$Y(t) = (y_{t-l+1}, \dots, y_t)^T.$$

设 $H(t) = K(t) + \sigma^2 E + C^{-1} I$, 则 $x(t)$ 可由 $H(t) x(t) = Y(t)$ 求取. 若得到 $t+1$ 时刻模型的输入变量 x_{t+1} , 则可以求取动态无偏 LS-SVM 的输出预测值

$$f(x_{t+1}) = \sum_{i=t-l+1}^t x_i(t) (k(x_{t+1}, x_i) + \sigma^2). \quad (16)$$

当得到 $t+1$ 时刻模型输出的实际值 y_{t+1} 时,为了更新动态无偏 LS-SVM 模型,将新样本 (x_{t+1}, y_{t+1}) 加入时间窗,同时遗忘时间窗中最早时刻的旧样本 (x_{t-l+1}, y_{t-l+1}) . 在此基础上,更新矩阵 $K(t)$ 为 $K(t+1)$, $Y(t)$ 为 $Y(t+1)$, 并求取新的回归系数向量 $x(t+1)$.

4.1 增加样本

由上述分析可知,在 t 时刻矩阵 $H(t)$ 为

$$H(t) = \begin{bmatrix} k(x_{t-l+1}, x_{t-l+1}) + \sigma^2 + C^{-1} & \dots & k(x_{t-l+1}, x_t) + \sigma^2 \\ \dots & \ddots & \dots \\ k(x_t, x_{t-l+1}) + \sigma^2 & \dots & k(x_t, x_t) + \sigma^2 + C^{-1} \end{bmatrix}. \quad (17)$$

由 t 时刻的学习结果可得到 $H(t) = U(t)^T U(t)$, $U(t)$ 已知. 设 $t+1$ 时刻增加一个新样本 (x_{t+1}, y_{t+1}) , 对应于 $H(t)$, 有

$$H(t+1) = \begin{bmatrix} H(t) & V(t+1) \\ V(t+1)^T & v(t+1) \end{bmatrix} R^{(l+1) \times (l+1)}. \quad (18)$$

其中: $v(t+1) = k(x_{t+1}, x_{t+1}) + \sigma^2 + C^{-1}$, $V(t+1) = [k(x_{t+1}, x_{t-l+1}) + \sigma^2, \dots, k(x_{t+1}, x_t) + \sigma^2]^T$. 下面求取 $U(t+1)$, 使得 $H(t+1) = U(t+1)^T U(t+1)$.

由定理 1 可知, $H(t+1)$ 为对称正定矩阵, 对其采用 Cholesky 分解定理进行计算, 所得的结果为

$$U(t+1) = \begin{bmatrix} U(t) & W(t+1) \\ \mathbf{0}^T & w(t+1) \end{bmatrix}. \quad (19)$$

其中: $W(t+1)$ 和 $w(t+1)$ 分别为 l 维列向量和实数, 求取方法分别为

$$W_i(t+1) = \left(H_{i,l+1}(t+1) - \sum_{k=1}^{i-1} U_{k,i}(t+1) U_{k,l+1}(t+1) \right) / U_{ii}(t-1), \quad (20)$$

$$w(t+1) = \left(H_{l+1,l+1}(t+1) - \sum_{k=1}^l U_{k,l+1}^2(t+1) \right)^{1/2}. \quad (21)$$

从式(19) 可以看出, $t+1$ 时刻增加一个新样本后, 对所形成的 $H(t+1)$ 矩阵进行分解时, 可直接利用 t 时刻 $H(t)$ 的分解结果 $U(t)$.

4.2 消减样本

设去掉最早时刻的样本后新形成的回归系数求取矩阵为 $H(t+1)$. 由定理 1 可知, $H(t+1)$ 为对称正定矩阵, 设其分解结果为 $H(t+1) = R^T(t+1) R(t+1)$. 如何求取 $R(t+1)$ 是样本消减过程的关键. 将矩阵 $H(t+1)$ 和 $U(t+1)$ 重新进行分块, 即

$$H(t+1) = \begin{bmatrix} \Phi(t-l+1) & \mathbf{V}^T(t+1) \\ \mathbf{V}(t+1) & \mathbf{H}(t+1) \end{bmatrix}, \quad (22)$$

$$U(t+1) = \begin{bmatrix} \Phi(t-l+1) & \mathbf{W}^T(t+1) \\ \mathbf{0} & \mathbf{U}(t+1) \end{bmatrix}. \quad (23)$$

由 $H(t+1) = U(t+1)^T U(t+1)$, 可得

$$H(t+1) = \mathbf{U}^T(t+1) \mathbf{U}(t+1) + \mathbf{W}(t+1) \mathbf{W}^T(t+1), \quad (24)$$

式中 $\mathbf{U}(t+1)$ $R^{l \times l}$ 和 $\mathbf{W}^T(t+1)$ R^l 为已知. 根据式(24), 求 $R(t+1)$ 的方法为

$$J(l) \dots J(1) [\mathbf{W}(t+1), \mathbf{U}^T(t+1)]^T = [\mathbf{0}, R^T(t+1)]^T. \quad (25)$$

其中 $J(i)$ $R^{(l+1) \times (l+1)}$ 的确定方法如下(设其下标从 0 开始):

$$J_{m,n}(i) = \begin{cases} 1, & m = n = 0, i; \\ \sin i, & m = n = 0, i; \\ -\cos i, & m = 0, n = i; \\ \cos i, & m = i, n = 0; \\ 0, & \text{其他.} \end{cases} \quad (26)$$

由式(25) 计算出的 $R(t+1)$ 满足 $H(t+1) = R^T(t+1) R(t+1)$, 且该算法的时间复杂度为 $O(l^2)$ ^[11,12], 而对于 $H(t+1)$ 重新进行 Cholesky 分解的时间复杂度为 $O(l^3)$, 因此该方法能提高动态无偏 LS-SVM 的效率. 求出 $R(t+1)$ 后即可求出新的回归系数, 形成 $t+1$ 时刻的预测模型. 随着滑动

时间窗中样本的平移,反复进行样本的增加和消减过程,并求取新的回归函数,便完成了动态无偏LS-SVM的在线建模.

5 仿真实验

5.1 混沌时间序列预测

将动态无偏LS-SVM应用于Mackey-Class混沌时间序列^[13]预测,该模型为

$$dx(t)/dt = 0.2x(t - \tau)/(1 - x^{10}(t - \tau)) - 0.1x(t).$$

本仿真实例取 $\tau = 30$, 样本的输入为 $(x(t - (D - 1)\tau), \dots, x(t - \tau), x(t))$, 输出为 $x(t + T)$. 设置 $D = 9, \tau = T = 1$. 首先用 $x(500)$ 到 $x(608)$ 组织100组样本训练无偏LS-SVM, 得到初始预测模型, 并不断组织新样本, 采用动态无偏LS-SVM模型进行500次在线预测. 模型采用 Gauss 径向基核 $k(x, x) = \exp(-\|x - x'\|^2/2p^2)$. 用交叉验证法确定模型参数的取值为 $C = 200, \gamma = 1, p = 2$.

该预测过程的性能可用如下指标衡量:

$$e = \frac{1}{N} \sum_{t=1}^N \left| \frac{y(t) - \hat{y}(t)}{y(t)} \right|,$$

$$e = \frac{1}{N} \sum_{t=1}^N (y(t) - \hat{y}(t))^2.$$

其中 $y(t)$ 为实际值, $\hat{y}(t)$ 为预测值, N 表示在线预测的步数. 图1是动态无偏LS-SVM的预测结果, 值为0.0193, e 值为5.4235e-004. 在数据完全相同

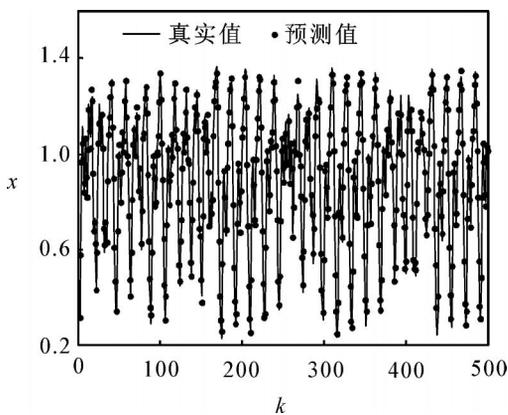


图1 动态无偏LS-SVM预测结果

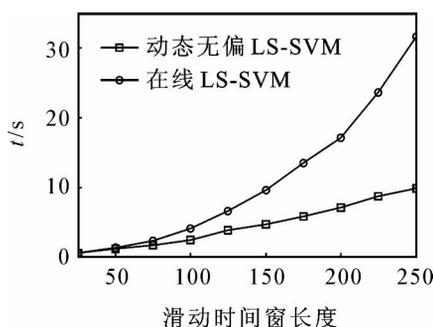


图2 两种算法运行时间曲线

的情况下,采用分块矩阵求逆方式的在线LS-SVM模型的 e 值为0.0213, e 值为6.1013e-004.

为了衡量动态无偏LS-SVM的计算效率,分别采用不同的滑动时间窗长度运行动态无偏LS-SVM模型和基于分块矩阵求逆的在线LS-SVM模型各10次,两种算法的时间曲线如图2所示.从图1和图2可以看出,动态无偏LS-SVM模型能以较快的速度对混沌时间序列的动态变化作出反应.

5.2 系统辨识

非线性模型^[14]描述如下:

$$y(k + 1) = k_1 y(k) / (k_2 + y^2(k)) + k_3 u^3(k).$$

在本次仿真实验中,滑动时间窗长度为50,算法运行200个离散时间步,仿真模型的参数给定如下:

$$y(k + 1) = \begin{cases} y(k) / (1 + y^2(k)) + u^3(k), & k \leq 120; \\ 1.1y(k) / (1.5 + y^2(k)) + 1.2u^3(k), & k > 120. \end{cases}$$

仿真结果如图3所示, e 值为0.1020, e 值为3.6106e-003. 模型采用径向基核.用交叉验证法确定模型参数的取值为 $C = 200, \gamma = 1, p = 1.5$. 采用完全相同的数据, 基于分块矩阵求逆的在线LS-SVM模型的 e 值为0.0978, e 值为3.7424e-003. 两种算法的时间曲线如图4所示.

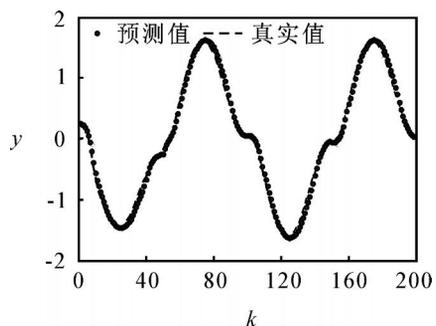


图3 动态无偏LS-SVM辨识结果

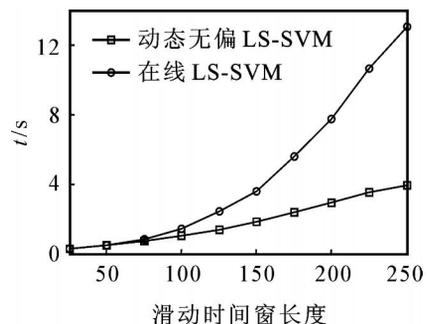


图4 两种算法运行时间曲线

从该实例可以看出,动态无偏LS-SVM与在线LS-SVM的预测精度相当,但前者能以较快的速度拟合系统模型.当模型发生变化时,动态无偏LS-SVM能在较短的时间内跟踪模型的变化趋势.

6 结 论

本文首先对标准 LS-SVM 进行了改进,提出了无偏最小二乘支持向量机模型;然后在此基础上根据模型中核函数矩阵的特点,设计了基于 Cholesky 分解的在线学习算法,形成了动态无偏 LS-SVM. 仿真实验表明,该模型适于时间序列预测和系统辨识,具有良好的在线学习和预测能力,而且与新近提出的基于分块矩阵求逆的在线训练算法相比,具有较快的运算速度,这为将支持向量机技术应用于实时信号处理领域提供了有力的工具.

参考文献(References)

- [1] Vapnik V N. Statistical learning theory [M]. New York:Wiley, 1998.
- [2] Suykens J A K, Vandewalle J. Least square support vector machines classifiers [J]. Neural Processing Letters, 1999, 9(3): 293-300.
- [3] Alistair Shilton M, Palaniswami Daniel Ralph, Ah Chung Tsoi. Incremental training of support vector machines[J]. IEEE Trans on Neural Networks, 2005, 16(1): 114-131.
- [4] Lau K W, Wu Q H. Online training of support vector classifier[J]. Pattern Regression, 2003, 36(8): 1913-1920.
- [5] Ma J, Theiler J, Perkins S. Accurate on-line support vector regression [J]. Neural Computation, 2003, 15(11): 2683-2703.
- [6] 张浩然,汪小东. 回归最小二乘支持向量机的增量和在线式学习算法[J]. 计算机学报, 2006, 29(3): 400-406.
(Zhang H R, Wang X D. Incremental and online learning algorithm for regression least square vector machine[J]. Chinese J of Computers, 2006, 29(3): 400-406.)
- [7] 范玉刚,李平,宋执环. 动态加权最小二乘支持向量机[J]. 控制与决策, 2006, 21(10): 1129-1133.
(Fan Y G, Li P, Song Z H. Dynamic weighted least square support vector machines [J]. Control and Decision, 2006, 21(10): 1129-1133.)
- [8] Vijayakumar S. Sequential support vector classifiers and regression[C]. Proc of Int Conf on Soft Computing. Genoa, 1999: 610-619.
- [9] Haoran Zhang, Changjiang Zhang, Xiaodong Wang, et al. A new support vector machine and its learning algorithm[C]. Proc of the 6th World Congress on Control and Automation. Dalian, 2006: 2820-2824.
- [10] Yaakov Engel, Shie Mannor, Ron Meir. Sparse online greedy support vector regression[C]. Proc of European Conf on Machine Learning. Berlin: Springer-Verlag, 2002: 84-96.
- [11] Gene H Golub, Charles F Van Loan. Matrix Computations [M]. Baltimore: The Johns Hopkins University Press, 1996.
- [12] Matthias Seeger. Low rank updates for the Cholesky decomposition[R]. Tuebingen: Max Planck Society, 2005.
- [13] Chiang J H, Hao P Y. Support vector learning mechanism for fuzzy rule-based modeling: A new approach[J]. IEEE Trans on Fuzzy Systems, 2004, 12(1): 1-11.
- [14] Narendra K S, Parthasarathy K. Identification and control of dynamic systems using neural networks[J]. IEEE Trans on Neural Networks, 1990, 1(1): 4-27.

(上接第 1358 页)

- [7] Ampazis N, Perantonis S J. Two highly efficient second-order algorithms for training feed forward networks[J]. IEEE Trans on Neural Networks, 2002, 13(5): 1064-1073.
- [8] 诸静. 模糊控制理论与系统原理[M]. 北京: 北京机械工业出版社, 2005.
(Zhu J. Fuzzy control system theory and principle[M]. Beijing: Beijing Machinery Industry Press, 2005.)
- [9] 潘琢金,施国军. C8051Fxxx 高速 SOC 单片机原理及应用[M]. 北京: 北京航空航天大学出版社, 2002.
(Pan Z J, Shi G J. C8051Fxxx-SOC principles and application of SCM [M]. Beijing: Beijing University Press Aviation Space, 2002.)
- [10] 朱铭皓,赵勇,甘泉. DSP 应用系统设计[M]. 北京: 电子工业出版社, 2002.
(Zhu M G, Zhao Y, Gan Q. DSP application system design [M]. Beijing: Electronic Publishing Industry, 2002.)