

文章编号: 1001-0920(2006)10-1129-05

## 动态加权最小二乘支持向量机

范玉刚, 李 平, 宋执环

(工业控制技术国家重点实验室, 浙江大学 工业控制技术研究所, 杭州 310027)

**摘 要:** 提出一种基于动态加权最小二乘支持向量机(LS-SVM)的时间序列预测方法. 动态加权LS-SVM能够跟踪时变非线性系统的动态特性, 适合于系统辨识和时间序列预测; 同时采用鲁棒方法确定权系数, 以减小噪声的影响. 将动态加权LS-SVM算法应用于工业PTA氧化过程中的4-CBA浓度预测, 结果显示, 动态加权LS-SVM预测精度高, 能够有效减小噪声的影响.

**关键词:** 最小二乘支持向量机; 时间序列预报; PTA氧化过程

中图分类号: TP274

文献标识码: A

## Dynamic Weighted Least Squares Support Vector Machines

FAN Yu-gang, LI Ping, SONG Zhi-huan

(National Lab of Industrial Control Technology, Institute of Industrial Process Control, Zhejiang University, Hangzhou 310027, China. Correspondent: FAN Yu-gang, E-mail: ygf@ipc.zju.edu.cn)

**Abstract:** A time series forecasting method based on dynamic weighted least squares support vector machine (LS-SVM) is proposed. Dynamic weighted LS-SVM is suitable for system recognition and time series prediction because the algorithm can track the dynamics of nonlinear time-varying systems. The weights are determined by a robust method in order to reduce the effect of the noise data. Dynamic weighted LS-SVM is applied to predict the concentration of 4-Carboxybenzaldehyde (4-CBA) in purified terephthalic acid (PTA) oxidation process. Results indicate that the proposed method reduces the effect of outliers and yields high accuracy.

**Key words:** Least squares support vector; Time series prediction; PTA oxidation process

### 1 引 言

支持向量机(SVM)具有完备的统计学习理论基础,特别是对小样本数据的模式识别和函数估计具有出色的学习推广性能,已成为机器学习界研究的新热点,并在很多领域得到了成功的应用,如手写体数字识别、人脸检测和概率密度函数估计等<sup>[1]</sup>. Suykens等人<sup>[2,3]</sup>在Vapnik统计学习理论的基础上提出一种新型支持向量机方法——最小二乘支持向量机(LS-SVM),作为SVM的扩展,LS-SVM将SVM的二次规划问题转换为求解线性方程组的问题,在精度要求范围内,LS-SVM较SVM有更优良的学习速度,而且结构简单,算法简练.在克服SVM的不足(计算复杂)的同时,LS-SVM产生了新的缺

陷,如丢失了SVM的松散性和鲁棒性.为了克服LS-SVM缺失鲁棒性这一问题,Suykens等人<sup>[4]</sup>提出了加权LS-SVM,较好地克服了奇异点对LS-SVM造成的影响.

本文借鉴递归LS-SVM的思想<sup>[5]</sup>,提出动态LS-SVM.与递归LS-SVM和文献[6]采用的在线最小二乘支持向量机相比,本文采用新的算法调整LS-SVM模型,并充分利用原有模型来调整下一时刻的模型参数.在此基础上,采用鲁棒方法确定权系数,将动态LS-SVM和加权LS-SVM相结合,形成动态加权LS-SVM算法.由于LS-SVM把学习问题转化为解线性方程组问题,因此与在线SVM算法<sup>[7,8]</sup>相比,动态加权LS-SVM运算速度较快,适合

收稿日期: 2005-08-15; 修回日期: 2005-12-09

基金项目: 国家 863 计划项目(2002AA412010-12); 浙江省科技计划项目(2004C31106).

作者简介: 范玉刚(1973—),男,山东文登人,博士生,从事数据挖掘、机器学习等研究;李平(1954—),男,广西北流人,教授,博士生导师,从事工业过程模型化、智能控制等研究.

在线学习和预测 实验结果也证明了这一点

### 2 最小二乘支持向量机

给定一个有  $N$  个数据的训练集合  $\{x_k, y_k\}, k = 1, 2, \dots, N$ . 其中输入数据  $x_k \in R^n$ , 输出数据  $y_k \in R$ . 根据统计学理论, 函数拟合问题可描述为以下最优化问题:

$$\min_{w, b, e} J(w, e) = \frac{1}{2} w^T w + \frac{1}{2} \gamma \sum_{k=1}^N e_k^2,$$

$$\text{s.t. } y_k = w^T \mathcal{Q}(x_k) + b + e_k, k = 1, \dots, N. \quad (1)$$

其中:  $\mathcal{Q}(\cdot): R^n \rightarrow R^h$  是将输入数据映射到高维特征空间的函数; 权值向量  $w \in R^h$ ; 误差变量和偏置值满足  $e_k \in R$  及  $b \in R$ ;  $\gamma > 0$  为惩罚系数, 可调整误差所起的作用, 如果训练数据有较大的噪声, 则应当选择较小的  $\gamma$ .

根据式(1) 将模型变换到对偶空间加以解决, 得到如下 Lagrange 函数:

$$L(w, b, e; \alpha) = \frac{1}{2} w^T w + \frac{1}{2} \gamma \sum_{k=1}^N e_k^2 - \sum_{k=1}^N \alpha_k \{w^T \mathcal{Q}(x_k) + b + e_k - y_k\}, \quad (2)$$

其中  $\alpha \in R$  是 Lagrange 乘子. 对上式各变量求偏导并整理得线性方程组

$$\begin{bmatrix} 0 & \mathbf{1}^T \\ \mathbf{1} & \Omega + \gamma^{-1} \mathbf{1} \mathbf{1}^T \end{bmatrix} \begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix}, \quad (3)$$

其中:  $y = [y_1, y_2, \dots, y_N]^T, \alpha = [\alpha_1, \alpha_2, \dots, \alpha_N]^T, \mathbf{1}^T = [1, \dots, 1]^T$ ;  $\Omega$  为核矩阵, 其第  $i$  列  $j$  行的元素为  $\Omega_{ij} = K(x_i, x_j) = \mathcal{Q}(x_i)^T \mathcal{Q}(x_j), i, j = 1, \dots, N, K(\cdot, \cdot)$  为核函数. 核函数必须满足 Mercer 定理, 常用的有线性函数  $K(x_i, x_j) = x_i^T x_j$ , 多项式函数  $K(x_i, x_j) = (\frac{x_i^T x_j}{c} + 1)^d$ , 径向基 (RBF) 函数  $K(x_i, x_j) = e^{-\frac{\|x_i - x_j\|^2}{2\sigma^2}}$  等. 本文采用 RBF 核函数

求解式(3) 得  $\alpha$  和  $b$ , 从而可得 LS-SVM 拟合模型为

$$y(x) = \sum_{k=1}^N \alpha_k K(x, x_k) + b \quad (4)$$

由此可见, 训练 LS-SVM 模型主要是对线性方程组 (3) 进行求解, 而用 LS-SVM 模型进行预测只需计算各个训练样本与待测样本之间的核函数  $K(x_i, x)$ , 不涉及函数  $\mathcal{Q}(\cdot)$  的具体形式

### 3 动态加权 LS-SVM

#### 3.1 加权 LS-SVM [4]

为了获得鲁棒性, 对式(1) 的误差  $e_k$  加权. 设  $e_k$  对应的权值为  $v_k$ , 式(1) 的优化问题变为

$$\min_{w, b, e} J(w, e) = \frac{1}{2} w^*{}^T w^* + \frac{1}{2} \gamma \sum_{k=1}^N v_k e_k^2,$$

$$\text{s.t. } y_k = w^{*T} \mathcal{Q}(x_k) + b^* + e_k^*,$$

$$k = 1, \dots, N, \quad (5)$$

对应的 Lagrange 函数为

$$L(w^*, b^*, e^*; \alpha^*) = \frac{1}{2} w^{*T} w^* + \frac{1}{2} \gamma \sum_{k=1}^N v_k e_k^{*2} - \sum_{k=1}^N \alpha_k^* \{w^{*T} \mathcal{Q}(x_k) + b^* + e_k^* - y_k\}, \quad (6)$$

消去变量  $w^*$  和  $e_k^*$  后, 可得线性方程组

$$\begin{bmatrix} 0 & \mathbf{1}^T \\ \mathbf{1} & \Omega + V \gamma \end{bmatrix} \begin{bmatrix} b^* \\ \alpha^* \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix}, \quad (7)$$

其中:  $V = \text{diag}\{\frac{1}{v_1}, \dots, \frac{1}{v_N}\}$ ,  $v_k$  是由误差变量  $e_k$  确定

$$v_k = \begin{cases} 1, & |e_k/s| < c_1; \\ \frac{c_2 - |e_k/s|}{c_2 - c_1}, & c_1 < |e_k/s| < c_2; \\ 10^{-4}, & \text{otherwise} \end{cases} \quad (8)$$

其中:  $\hat{s}$  是误差变量  $e_k$  的标准方差的鲁棒估计值, 即  $\hat{s} = \frac{IQR}{2 \times 0.6745}$ ,  $IQR$  是  $e_k$  的 75% 分点与 25% 分点的间距; 常数  $c_1$  和  $c_2$  一般设置为  $c_1 = 2.5$  和  $c_2 = 3$

加权 LS-SVM 可以简述如下:

- 1) 给定训练样本集  $\{x_k, y_k\}, k = 1, 2, \dots, N$ , 确定最优参数  $\gamma$  和  $\sigma$  (参数  $\gamma$  和  $\sigma$  的优化选择可以采用两层网格搜索的策略来确定), 训练得到 LS-SVM 模型, 并确定  $e_k = \alpha_k / \gamma$
- 2) 根据  $e_k$  的分布情况计算  $\hat{s}$
- 3) 根据  $e_k$  和  $\hat{s}$ , 由式(8) 计算权重  $v_k$
- 4) 求解式(7) 得到  $\alpha^*$  和  $b^*$ , 确定函数模型

$$y(x) = \sum_{k=1}^N \alpha_k^* K(x, x_k) + b^*.$$

#### 3.2 动态 LS-SVM

为了跟踪系统的动态特性, 当系统产生新的数据时, 应将新信息加入系统的函数模型中. 数据增加, 核矩阵的维数将随之增加, 最终会导致系统资源的耗尽. 因此动态 LS-SVM 应包括两个过程: 增加样本和消减样本. 在此定义  $Q_N = \Omega + V \gamma$ , 其中:  $Q_N \in R^{N \times N}$ ;  $\Omega$  为一个方阵, 其第  $i$  列  $j$  行的元素为  $\Omega_{ij} = K(x_i, x_j) = \mathcal{Q}(x_i)^T \mathcal{Q}(x_j), i, j = 1, \dots, N$ .

式(7) 可以展开为

$$\begin{cases} \mathbf{1}^T \times \alpha^* = 0, \\ \mathbf{1} \times b^* + Q_N \times \alpha^* = y, \end{cases}$$

求解可得

$$b^* = \frac{\mathbf{1}^T Q_N^{-1} y}{\mathbf{1}^T Q_N^{-1} \mathbf{1}}, \quad (9)$$

$$\alpha^* = Q_N^{-1} (y - \mathbf{1} \times b^*). \quad (10)$$

由式(9) 和式(10) 可知, 计算出  $Q_N^{-1}$  就可以确定  $\alpha^*$  和  $b^*$ , 得到函数模型. 只要将新样本添加到  $Q_N$



中,同时消去同等数量的旧样本,就可以不断更新  $Q_N^{-1}$ ,得到新的  $\alpha^*$  和  $b^*$ ,这是本文提出的动态 LS-SVM 的基本思想

### 3 2 1 增加样本

设新增加一个样本  $(x_{N+1}, y_{N+1})$ , 对应于  $Q_N$ , 有

$$Q_{N+1} = \begin{bmatrix} Q_N & k_{N+1} \\ k_{N+1}^T & k_{N+1}^* \end{bmatrix} \quad R^{(N+1) \times (N+1)},$$

其中

$$k_{N+1} = [k(x_{N+1}, x_i)]^T, i = 1, \dots, N,$$

$$k_{N+1}^* = \frac{1}{y_{N+1}} + k(x_{N+1}, x_{N+1}),$$

因为本文采用 RBF 核函数,所以  $k_{N+1}^* = \frac{1}{y_{N+1}} + 1$ .

由矩阵求逆引理<sup>[9]</sup>,  $Q_{N+1}^{-1}$  由下式求得:

$$Q_{N+1}^{-1} = \begin{bmatrix} Q_N & k_{N+1} \\ k_{N+1}^T & k_{N+1}^* \end{bmatrix}^{-1} = \begin{bmatrix} Q_N^{-1} + Q_N^{-1} k_{N+1} k_{N+1}^T Q_N^{-1} \rho^{-1} & - Q_N^{-1} k_{N+1} \rho^{-1} \\ - k_{N+1}^T Q_N^{-1} \rho^{-1} & \rho^{-1} \end{bmatrix}, \quad (11)$$

其中  $\rho = k_{N+1}^* - k_{N+1}^T Q_N^{-1} k_{N+1}$ .

### 3 2 2 消减样本

增加样本之后,应该消减样本 假设已经增加了一个新样本,并且  $Q_{N+1}^{-1}$  已知,将  $Q_{N+1}$  重新表述为以下形式:

$$Q_{N+1} = \begin{bmatrix} k_1^* & \hat{k}_1^T \\ k_1 & \hat{Q}_N \end{bmatrix},$$

其中:  $k_1^* = \mathcal{Y}^{-1} + k(x_1, x_1) = \mathcal{Y}^{-1} + 1, k_1 = [k(x_1, x_i)]^T, i = 2, \dots, N + 1, \hat{Q}_N = \hat{\Omega}_N + \hat{V}_N, \hat{Q}_N \times R^{N \times N},$

$\hat{V}_N = \text{diag}\{\frac{1}{y_{N+1}}, \dots, \frac{1}{y_{N+1}}\}, \hat{\Omega}_N$  是核矩阵,其第  $i - 1$  列  $j - 1$  行的元素  $\Omega_{(i-1)(j-1)} = K(x_i, x_j), i, j = 2, \dots, N + 1$ . 应用矩阵求逆引理得

$$Q_{N+1}^{-1} = \begin{bmatrix} \rho^{-1} & - k_1^T \hat{Q}_N^{-1} \rho^{-1} \\ - \hat{Q}_N^{-1} k_1 \rho^{-1} & \hat{Q}_N^{-1} + \hat{Q}_N^{-1} k_1 k_1^T \hat{Q}_N^{-1} \rho^{-1} \end{bmatrix} = \begin{bmatrix} q & P^T \\ P & Q^* \end{bmatrix}, \quad (12)$$

其中:  $\rho = k_1^* - k_1^T \hat{Q}_N^{-1} k_1, Q^* \in R^{N \times N}, P \in R^N$ . 由式 (12) 可以求得  $Q_{N+1}^{-1}$  为

$$Q_{N+1}^{-1} = Q^* - P P^T / q \quad (13)$$

增加一个样本  $(x_{N+1}, y_{N+1})$ , 然后消减第 1 个样本  $(x_1, y_1)$ , 新的核矩阵为  $\hat{\Omega}_N$ , 对应的  $Q_{N+1}^{-1}$  由式 (13) 求得,更新  $\alpha^*$  和  $b^*$  得到新的函数模型 由于填入了新信息,消除旧信息,从而能够跟踪系统的动态特性

### 3 3 动态加权 LS-SVM 算法

以时间序列预报为例,动态加权 LS-SVM 算法

描述如下:

1) 指定  $N$  的大小,由加权 LS-SVM 训练过程,得到函数模型  $y(x) = \sum_{k=1}^N \alpha_k^* K(x, x_k) + b^*$ ,用于预报  $x_{N+1}$  对应的  $y_{N+1}$ ; 记录  $Q_N^{-1}, e_k$  和  $\hat{s}$

2) 采样得到新向量  $x_{N+1}$ , 预报  $y_{N+1}$ .

3) 采样得到新数值  $y_{N+1}$ , 组成新样本  $(x_{N+1}, y_{N+1})$ , 计算误差  $e_{N+1} = y_{N+1} - \hat{y}_{N+1}$ ; 由式 (8) 计算权重  $v_{N+1}$ .

4) 由式 (11) 计算  $Q_{N+1}^{-1}$ , 将  $Q_{N+1}^{-1}$  按照式 (12) 分解为  $Q^*, q$  和  $P$ .

5) 由式 (13) 计算  $Q_N^{-1}, Q_N^{-1}$  对应于  $\hat{\Omega}_N, \hat{\Omega}_N$  是增加样本  $(x_{N+1}, y_{N+1})$  并消减样本  $(x_1, y_1)$  后的核矩阵

6)  $Q_N^{-1}$ , 将带入式 (9) 和式 (10) 计算  $b^*$  和  $\alpha^*$ ,

得到新的函数模型  $y(x) = \sum_{k=1}^N \alpha_k^* K(x, x_k) + b^*$ .

7) 将样本集和误差集移位:  $x_i = x_{i+1}, y_i = y_{i+1}, e_i = e_{i+1}, i = 1, \dots, N$ ; 重新计算  $\hat{s}$

8)  $Q_N^{-1} = Q_{N+1}^{-1}$ , 转到 2).

由上述过程可以看出,当将  $v_{N+1}$  始终设置为 1 时,就成为动态 LS-SVM 算法

## 4 仿真实验

### 4 1 Mackey-Glass 时间序列预测

将动态 LS-SVM 用于 Mackey-Glass 混沌模型的时间序列预测,该模型被许多文献采用为研究对象<sup>[10]</sup>. Mackey-Glass 混沌模型为

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

其中要求  $\tau > 17$ , 本文仿真采用的延迟时间为  $\tau = 30$

时间序列预测的目的是用  $t$  时刻前的  $x$  值, 预测  $t + T$  时刻的  $x$  值, 即用  $(x(t - (D - 1)\Delta), \dots, x(t - \Delta), x(t))$  来预报  $x(t + T)$ . 实验设置  $D = 9, \Delta = T = 1$ . 首先用 25 组时间序列训练 LS-SVM, 因此该实验中动态 LS-SVM 的时间间隔  $N = 25$ . 从  $x(526)$  开始预测, 并且不断组织新的时间序列, 更新函数模型, 直到  $x(1000)$ , 因此, 从  $x(526)$  到  $x(1000)$  为测试样本

性能指标采用

$$PI = \frac{1}{N} \sum_{t=1}^N (y(t) - y^*(t))^2,$$

其中:  $y(t)$  是实际值,  $y^*(t)$  是预报值

图 1 是动态 LS-SVM 的预测结果, PI 值为 0.00042313, 表明动态 LS-SVM 的预测精度较高 实验采用 RBF 核函数, 参数  $\alpha = 5.6, \lambda = 84.2$

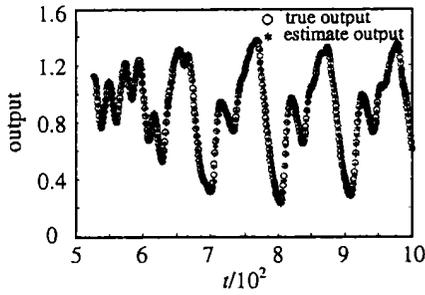


图1 动态LS-SVM 时间序列预报结果

#### 4.2 PTA 氧化过程中4-CBA 含量预测

作为聚酯工业重要原材料的 PTA 主要由 PX (Para-Xylene) 氧化而来。在氧化反应中, 4-CBA 浓度是氧化反应进程的“观测器”, 是 PTA 产品中的主要杂质及重要质量指标。根据反应机理研究, 4-CBA 含量过低, 表明氧化反应程度加深, 副反应加剧, 能耗、醋酸及 PX 单耗增加; 而浓度过高则表明氧化反应停留时间较少, 氧化反应不足, 将导致 PX 转化率过低, 这是生产过程中必须控制和克服的问题。因此为了节能降耗, 并保证 PTA 的产品纯度, 对氧化反应单元的 4-CBA 含量进行实时控制是非常重要的。

在工业生产中 4-CBA 含量往往通过离线光谱分析获得, 但离线的分析一般要滞后数小时, 且分析采样次数较少(一天仅两、三次), 远远不能满足控制的要求, 为了实时预测中间反应物 4-CBA 含量, 需要建立一个预测模型。另外, 在 PTA 氧化过程生产中为了清洗干燥器以及调节中间缓冲罐液位而经常进行升、降负荷的操作, 这一段时间的操作与正常的操作相比, 具有本质的不同。因此, 由于升、降负荷操作的存在使得数据样本中不可避免地存在孤立点, 需要采取措施排除其干扰。

进行两次实验, 首先从实时数据库中采集数据, 并对数据进行预处理和时序匹配, 得到 463 个样本。每个样本有 10 个输入变量, 分别是混合罐进料流量, 反应氧化器进料流量, 催化剂浓度, 反应器温度, 反应器液位, 氧化反应器冷凝抽出水流量, 反应器尾氧含量, 总的反应装置抽出水量, 第 1 结晶器温度, 第 1 结晶器的尾氧含量; 样本输出为 4-CBA 浓度。然后用动态 LS-SVM 和动态加权 LS-SVM 分别建立预报模型。两次实验中,  $N = 25$ , 从  $x(26)$  开始预测, 不断更新函数模型, 直到  $x(463)$ , 因此从  $x(26)$  到  $x(463)$  为测试过程。

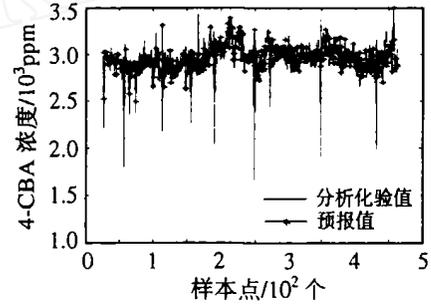
性能指标采用

$$PI = \frac{1}{N} \sum_{t=1}^N \left( \frac{y(t) - y^*(t)}{y(t)} \right)^2,$$

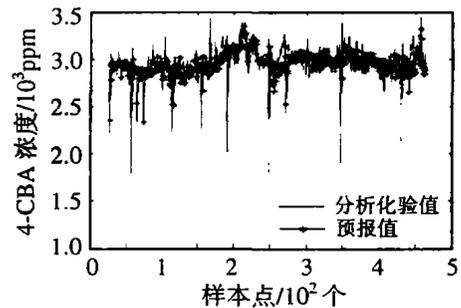
其中:  $y(t)$  是实际值,  $y^*(t)$  是预报值。实验采用

RBF 核函数, 参数  $\alpha = 6.5, \lambda = 50$

图 2(a) 为动态 LS-SVM 预测结果, PI 值为 0.0079; 图 2(b) 为动态加权 LS-SVM 预测结果, PI 值为 0.0069。从图 2 可以看出, 动态 LS-SVM 预测结果和动态加权 LS-SVM 预测结果都比较理想, 可以为监控 PTA 氧化生产过程提供有用的参考。样本集中存在孤立点, 动态加权 LS-SVM 具有抗噪声的能力, PI 值 (0.0069) 较动态 LS-SVM 的 PI 值 (0.0079) 小。



(a) 动态LS-SVM 预测结果



(b) 动态加权LS-SVM 预测结果

图2 4-CBA 预测结果

## 5 结 语

动态加权 LS-SVM 适合于系统辨识和时间序列预测, 其结合了动态 LS-SVM 和加权 LS-SVM 的优点。Mackey-Glass 时间序列预测仿真实验证明动态 LS-SVM 预测精度较高。工业实例证明, 动态 LS-SVM 和动态加权 LS-SVM 都具有较高的预测精度, 可以为监控生产过程提供参考。动态加权 LS-SVM 采用鲁棒方法确定权值, 提高了 LS-SVM 的抗噪声的能力, 在工业实例中预测结果好于动态 LS-SVM。

## 参考文献 (References)

- [1] Cortes C, Vapnik V. Support-Vector Network [J]. *Machine Learning*, 1995, 20(3): 273-297.
- [2] Suykens J A K, Vandewalle J. Least Squares Support Vector Machines Classifiers [J]. *Neural Processing Letters*, 1999, 9(3): 293-300.
- [3] Suykens J A K, Van Gestel T, De Brabanter J, et al.

- Least Squares Support Vector Machines* [M]. Singapore: World Scientific Publishing Co Pte Lte, 2002
- [4] Suykens J A K, De Brabanter J, Lukas L, et al Weighted Least Squares Support Vector Machines: Robustness and Sparse Approximation [J]. *Neurocomputing*, 2002, 48(1-4): 85-105
- [5] Suykens J A K, Vandewalle J. Recurrent Least Squares Support Vector Machines[J]. *IEEE Trans on Circuits Systems — I*, 2000, 47(7): 1109-1114
- [6] 叶美盈, 汪晓东, 张浩然. 基于在线最小二乘支持向量机回归的混沌时间序列预测[J]. *物理学报*, 2005, 54(6): 2568-2573  
(Ye M Y, Wang X D, Zhang H R. Chaotic Time Series Forecasting Using Online Least Squares Support Vector Machine Regression[J]. *Acta Physics Sinica*, 2005, 54(6): 2568-2573)
- [7] Maj S, James Theiler, Simon Perkins. Accurate Online Support Vector Regression [J]. *Neural Computation*, 2003, 15(11): 2683-2703
- [8] 赵登福, 庞文晨, 张讲社, 等. 基于贝叶斯理论和在线学习支持向量机的短期负荷预测[J]. *中国电机工程学报*, 2005, 25(13): 8-13  
(Zhao D F, Pang W C, Zhang J S, et al. Based on Bayesian Theory and Online Learning SVM for Short Term Load Forecasting[J]. *Proc of the CSEE*, 2005, 25(13): 8-13)
- [9] Lehel Csato, Manfred Opper. Sparse On-line Gaussian Processes [J]. *Neural Computation*, 2002, 14(3): 641-668
- [10] 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
- [11] Van Gestel T, Suykens J A K, Baestaens D, et al. Financial Time Series Prediction Using Least Squares Support Vector Machines within the Evidence Framework [J]. *IEEE Trans on Neural Networks*, 2001, 12(4): 809-821

## (上接第 1123 页)

- [4] Megerian S, Koushanfar F, Potkonjak M, et al. Coverage Problems in Wireless ad-hoc Sensor Networks [A]. *IEEE IN FOCOM* [C]. New York, 2001: 1380-1387
- [5] Adlakha S, Srivastava M. Critical Density Thresholds for Coverage in Wireless Sensor Networks [A]. *IEEE Wireless Communications and Networking Conf* [C]. New York, 2003: 1615-1620
- [6] Gupta P, Kumar P R. The Capacity of Wireless Networks [J]. *IEEE Trans on Information Theory*, 2000, 46(2): 388-404
- [7] Megerian S, Koushanfar F, Qu G, et al. Exposure in Wireless ad-hoc Sensor Networks [A]. *Proc of the 7th Int Conf on Mobile Computing and Networking* [C]. Rome, 2001: 139-150
- [8] Megerian S, Koushanfar F, Qu G, et al. Exposure in Wireless ad-hoc Sensor Networks: Theory and Practical Solutions [J]. *J of Wireless Networks*, 2002, 8(5): 443-454
- [9] Marengoni M, Draper B A, Hanson A, et al. System to Place Observers on a Polyhedral Terrain in Polynomial Time [J]. *Image and Vision Computing*, 1996, 18(10): 773-780
- [10] Feng Zhao, Leonidas Guibas. *Wireless Sensor Networks: An Information Processing Approach* [M]. Boston: Elsevier/Morgan Kaufmann, 2004
- [11] Gregg W W, Esaias W E, Feldman G C, et al. Coverage Opportunities for Global Ocean Color in a Multimission Era [J]. *IEEE Trans on Geoscience and Remote Sensing*, 1998, 36(5): 1620-1627

## (上接第 1128 页)

- [7] 张化光, 全永兵. 基于模糊双曲正切模型的一类稳定的模糊控制器设计 [J]. *控制与决策*, 2002, 17(6): 956-960  
(Zhang H G, Quan Y B. Design of Stable Fuzzy Controller Based on Fuzzy Hyperbolic Model [J]. *Control and Decision*, 2002, 17(6): 956-960)
- [8] Man Z, Paplinski A P, Wu H R. Robust Tracking Control for Rigid Robotic Manipulators [J]. *IEEE Trans on Automatic Control*, 1994, 39(12): 2464-2469
- [9] Salim L, Mohamed S B, Thierry M G. Adaptive Fuzzy Control of a Class of MIMO Nonlinear System [J]. *Fuzzy Sets and Systems*, 2005, 151(1): 59-77
- [10] Wang L X. Fuzzy Systems are Universal Approximation [A]. *Proc IEEE Internat Conf Fuzzy Systems* [C]. 1992, 22: 1163-1170