

序贯最小二乘支持向量机的结构系统识别^{*}

唐和生¹, 薛松涛^{1,2}, 陈 磊¹, 晋 侃¹

(1. 同济大学结构工程与防灾研究所, 上海 200092; 2. 日本近畿大学工学部建筑学科, 日本 大阪 577-8502)

摘要: 提出一种用于结构系统识别的序贯最小二乘支持向量机 (SLS-SVM) 方法, 通过对训练数据的序列进入和数
据缩减, 分别采用增量算法和减缩修剪算法有效地改进了 LS-SVM 这种方法克服了标准 LS-SVM 算法的稀疏性缺
失的缺点, 并使 LS-SVM 的序贯训练成为可能。对非线性滞迟结构的在线参数识别显示了所提出方法的鲁棒性和
高效率, 同时也表明 SLS-SVM 算法的速度比批处理 SVM 算法要快。

关键词: 系统识别; 滞迟结构; 序贯; 最小二乘; 支持向量机

中图分类号: TB123; O241.5 文献标识码: A 文章编号: 1004-4523(2006)03-0382-06

引 言

作为统计学习理论的一种, SVM 方法在系统识别, 模式识别和函数估计领域得到了快速的发展^[1-6]。SVM 方法用对偶空间中的凸优化问题来描述, 但是, 解这样的二次规划问题需要很长的计算时间。最近, 用最小二乘法改进的 SVM 方法在分类、函数估计和非线性系统优化控制中得到应用^[7-11]。LS-SVM 方法用于函数估计时, 用平方和误差损失函数替代传统 SVM 方法中的瓦普尼克 X 不敏感损失函数。此外, 在 LS-SVM 方法中用等式型的约束来替代 SVM 方法中的不等式约束。虽然这样的改进通过直接求解一组线性方程组而不是凸二次优化问题大大的简化了问题的求解, 但是 LS-SVM 算法中支持向量的稀疏特性将缺失。

传统的 SVM 算法和 LS-SVM 算法需要一次性输入训练数据, 这是一种离线训练算法, 然而离线训练算法不适合实际应用, 如在线系统识别和控制问题, 这些问题中数据的引入是序贯的。标准 SVM 方法普遍应用于静态问题中: 如分类、回归和函数估计。当应用于在线系统识别和在线控制这些动力问题中时, 这种方法是无法胜任的。因为每当训练数据序列改变时, 必须从头开始训练。因此, 需要一种在线训练模型, 可以方便地加入数据或从训练序列中去除已有的数据。以前提出的 SVM 近似在线训练算法, 如增量法^[12]、梯度法^[13], 这些方法的主要缺点是训练过程的拟合速度非常慢。

结合增量更新和减缩修剪算法, 本文提出序贯

最小二乘支持向量机 (SLS-SVM) 算法实现对具有滞迟特性系统的在线识别。针对具有滞迟特性的系统曾先后提出了许多参数识别理论。例如, 1989 年, 胡海岩首次采用双折线本构关系的 Fourier 级数与 Chebyshev 级数直接逼近技巧^[14], 将非线性参数识别转化为线性参数识别问题, 提出了一次辨识全部参数的识别方法。1991 年, 根据保守力与非保守力耗能性质的不同, 李岳锋又提出了一种参数识别的能量法^[15]。1994 年, 陈乃立运用频域广义正交概念, 提出了参数识别的频域方法, 提高了识别算法的抗噪能力^[16]。但这些参数识别方法都不能实现在线识别的功能。而 SLS-SVM 算法克服了传统 LS-SVM 方法的稀疏性缺失并且使 LS-SVM 方法的在线递归训练成为可能。

1 最小二乘支持向量机 (LS-SVM)

对于一组由 N 对输入-输出数据构成的训练集 $\{(x_k, y_k)\}_{k=1}^N$, 这里 $x_k \in \mathbf{R}^l$ 是输入, $y_k \in \mathbf{R}$ 是输出, 采用如下的回归模型

$$y(x) = \mathbf{w}^T \cdot h(x) + b \quad (1)$$

式中 $h(\cdot)$ 为从输入数据到高维特征空间的映射, \mathbf{w} 为权重向量, b 为偏置。在用 LS-SVM 进行函数回归估计中, 目标函数的优化问题如下

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

约束条件为

$$y_k = \mathbf{w}^T \cdot h(x_k) + b + e_k, k = 1, 2, \dots, N \quad (3)$$

式中 C 为使用者定义的调整常数, 用来平衡模型

* 收稿日期: 2005-06-29; 修订日期: 2005-12-12

的复杂度和近似的精确度; α 为近似误差

相应的拉格朗日函数如下

$$L(\mathbf{w}, b, e, \mathbb{T}) = J(\mathbf{w}, e) - \sum_{k=1}^N \mathbb{T}_k [\mathbf{w}^T \mathbf{h}(\mathbf{x}_k) + b + e_k - y_k] \quad (4)$$

式中 \mathbb{T}_k 为拉格朗日乘子(支持向量值), 最优化的

Kun-Tucker条件如下^[17]

$$\begin{cases} \frac{\partial L}{\partial \mathbf{w}} = 0 \rightarrow \mathbf{w} = \sum_{k=1}^N \mathbb{T}_k \mathbf{h}(\mathbf{x}_k) \\ \frac{\partial L}{\partial e_k} = 0 \rightarrow \mathbb{T}_k = Ce_k \\ \frac{\partial L}{\partial b} = 0 \rightarrow \sum_{k=1}^N \mathbb{T}_k = 0 \\ \frac{\partial L}{\partial \mathbb{T}_k} = 0 \rightarrow \mathbf{w}^T \mathbf{h}(\mathbf{x}_k) + b + e_k - y_k = 0 \end{cases} \quad (5)$$

k 从 1 到 N . 消去 e_k 和 \mathbf{w} , 解答由以下线性方程组给出

$$A_N \mathbb{T}_N = Y_N \quad (6)$$

式中 $A_N = \begin{bmatrix} 0 & \mathbf{1}^T \\ \mathbf{1} & K_+ C^{-1} \mathbf{I} \end{bmatrix}$, $\mathbb{T}_N = \begin{bmatrix} \bar{b} \\ \mathbb{T} \end{bmatrix}$, $Y_N = \begin{bmatrix} \bar{y} \\ \mathbf{Y} \end{bmatrix}$, $Y = [y_1, y_2, \dots, y_N]^T$, $\mathbf{1} = [1, 1, \dots, 1]^T$, $\mathbb{T} = [\mathbb{T}_1, \mathbb{T}_2, \dots, \mathbb{T}_N]^T$, \mathbf{I} 为单位矩阵

其中 K 服从 Mercer 条件

$$K_{kl} = H(\mathbf{x}_k, \mathbf{x}_l) = \mathbf{h}(\mathbf{x}_k)^T \mathbf{h}(\mathbf{x}_l), k, l = 1, 2, \dots, N \quad (7)$$

式中 K_{kl} 代表 K 中的第 k 行第 l 列元素

式(1)和式(5)给出了 LS-SVM 模型用于函数估计的最终结果

$$y(\mathbf{x}) = \sum_{k=1}^N \mathbb{T}_k H(\mathbf{x}_k, \mathbf{x}) + b \quad (8)$$

式中 \mathbb{T} 和 b 为式(6)的解, $H(\cdot)$ 为核函数

2 序贯最小二乘支持向量机 (SLS-SVM)

2.1 序贯增量 LS-SVM 算法

序贯增量 LS-SVM 算法就是无论什么时候一个新的样本 $(\mathbf{x}_{N+1}, y_{N+1})$ 加入到训练序列 $\{(\mathbf{x}_k, y_k)\}_{k=1}^N$ 中, 序贯增量算法都会更新已经训练好的 LS-SVM

令 $(\mathbf{x}_{N+1}, y_{N+1})$ 为加入到开始 N 个数据对 $\{(\mathbf{x}_k, y_k)\}_{k=1}^N$ 中的新的训练样本. 由式(6), 当前模型 (N 个数据对) 和下一个新的模型 (新的 $N+1$ 个数据对) 之间的增量关系为

$$A_{N+1} \mathbb{T}_{N+1} = Y_{N+1} \quad (9)$$

式中 $A_{N+1} = \begin{bmatrix} A_N & \mathbf{a} \\ \mathbf{a}^T & c \end{bmatrix}$, $Y_{N+1} = \begin{bmatrix} Y_N \\ y_{N+1} \end{bmatrix}$, $\mathbb{T}_{N+1} =$

$$\begin{bmatrix} \mathbb{T}_N \\ \mathbb{T}_{N+1} \end{bmatrix}, A_N = \begin{bmatrix} 0 & \mathbf{1}^T \\ \mathbf{1} & K_+ C^{-1} \mathbf{I} \end{bmatrix}, Y_N = \begin{bmatrix} \bar{y} \\ \mathbf{Y} \end{bmatrix}, \mathbf{a} = [1, H(\mathbf{x}^1, \mathbf{x}^{N+1}), \dots, H(\mathbf{x}^N, \mathbf{x}^{N+1})]^T, c = C^{-1} + H(\mathbf{x}^{N+1}, \mathbf{x}^{N+1}).$$

序贯增量训练算法的目的是有效地更新 A_{N+1}^{-1} , 无论何时一个新的样本加入时通过递归运算不会明显增加求矩阵逆的计算量. 根据子矩阵运算^[18], 矩阵

$$A_{N+1} = \begin{bmatrix} A_N & \mathbf{a} \\ \mathbf{a}^T & c \end{bmatrix} \text{ 的逆为 } A_{N+1}^{-1} = \begin{bmatrix} [A_N - c^{-1} \mathbf{a} \mathbf{a}^T]^{-1} & A_N^{-1} \mathbf{a} [a^T A_N^{-1} \mathbf{a} - c]^{-1} \\ [a^T A_N^{-1} \mathbf{a} - c]^{-1} a^T A_N^{-1} & [c - a^T A_N^{-1} \mathbf{a}]^{-1} \end{bmatrix}^{-1} \quad (10)$$

根据矩阵求逆的引理 $(A + BCD)^{-1} = A^{-1} - A^{-1}B(C + DA^{-1}B)^{-1}DA^{-1}$, 得出

$$[A_N - c^{-1} \mathbf{a} \mathbf{a}^T]^{-1} = A_N^{-1} - A_N^{-1} \mathbf{a} [-c + a^T A_N^{-1} \mathbf{a}]^{-1} a^T A_N^{-1} \quad (11)$$

由式(10)和(11)得出 A_{N+1}^{-1} 如下

$$A_{N+1}^{-1} = \begin{bmatrix} A_N^{-1} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} \end{bmatrix} + [c - a^T A_N^{-1} \mathbf{a}]^{-1} \begin{bmatrix} A_N^{-1} \mathbf{a} \\ -1 \end{bmatrix} [a^T A_N^{-1} \quad -] \quad (12)$$

很明显, 在增量算法中更新 A_{N+1}^{-1} 避免了复杂的求逆运算而是通过递归运算来实现, 相应的权重和偏置由式(9)得出

2.2 序贯缩减 LS-SVM 算法

由于传统的 LS-SVM 采用了优化条件 $\mathbb{T}_k = C\alpha$, LS-SVM 失去了其稀疏性. 在序贯增量训练算法中, 由于没有足够的空间来存储这么多的支持向量, 这种方法用于在线估计的效率比较低. 因此本文提出一种序贯缩减修剪支持向量算法结合增量算法使 LS-SVM 获得近似的稀疏性. 它是根据已经大小分类好的支持向量值基础上, 忽略相对较小的、意义不大的支持向量, 然后重新递归计算 LS-SVM, 产生一种近似的稀疏, 当 LS-SVM 的支持向量逐步被缩减, 这种递归方法叫做序贯缩减算法.

根据文献 [18, 19], 当第 k 个样本从 $N+1$ 个数据序列对中去掉时, 得到了新的 A_N^{-1}

$$A_N^{-1} = A_{N+1}^{-1} (\mathbf{I}, \mathbf{J}) - [A_{N+1}^{-1}(k, k)]^{-1} \cdot A_{N+1}^{-1} (\mathbf{I}, k) A_{N+1}^{-1} (k, \mathbf{J}) \quad (13)$$

这里 $\mathbf{I}, \mathbf{J} = [1 \dots k \quad k+2 \dots N+1]$. 由式(13)和式(6)可以计算出相应的权重和偏置.

以上所述的递归增量算法和缩减算法使得 LS-SVM 在线学习成为可能. 此外, 逐步剔除大小分类

后的支持向量可以得到 SLS-SVM 的稀疏解,同时也解决了存储问题。用于参数估计的 SLS-SVM 算法如下:

SLS-SVM 算法:

1. 初始化,设定常量 C ,设定训练数据量 N 的阈值 $N_{thre}, N = N_{thre}$;
2. 给出训练数据 $\{(x^k, y^k)\}_{k=1}^N$;
3. 解 LS-SVM 式 (6),存储 A_N^{-1} ;
4. 输入新的训练数据 (x_{N+1}, y_{N+1}) ,计算 a 和 c ;
5. 更新 A_{N+1}^{-1} (式 (12)),更新权重 T_{N+1} ;
6. 计算式 (5)中的系数;
7. 如果 $N < N_{thre}$,返回步骤 4,否则进行步骤 8;
8. 存储 $|T_{N+1}|$ 的值;
9. 进行渐缩 LS-SVM (方程 (13)) 分类 $|T_{N+1}|$,去除其中 M 个最小的值,重新获得 $N - M$ 个数据点,令 $N = N - M$;
10. 返回步骤 6

3 算例分析

为了验证本文提出的 SLS-SVM 算法的有效和鲁棒性,利用该算法进行在线非线性多自由度结构系统识别。对于一个具有 m 个自由度的非线性剪切结构模型,在地面加速度 \ddot{x}_g 激励下的运动方程为

$$M\ddot{x} + f(x, \dot{x}) = -M\ddot{x}_g \quad (14)$$

式中 M 为 $m \times m$ 质量矩阵; x, \dot{x} 和 \ddot{x} 分别为对地面而言的相对位移、速度和加速度向量; I 为 $m \times m$ 单位列矩阵; \ddot{x}_g 为地面运动加速度; f 用 Bouc-Wen 模型表示的恢复力向量^[20]。在这种情况下,向量的第 i 个元素为

$$f_i = c_i \dot{u}_i + k_i u_i - T_i |u_i| |f_i|^{n_i-1} f_i - U_i |u_i| |f_i|^{n_i}, \quad i = 1, \dots, m \quad (15)$$

式中 $u_i = x_i - x_{i-1}$ 和 $\dot{u}_i = \dot{x}_i - \dot{x}_{i-1}$ 为第 i 层和 $i-1$ 层之间质点的相对速度和相对加速度; c, k, T, U 和 m 分别是阻尼、刚度和第 i 个质点的非线性参数。

假设仅地面的加速度和结构加速度是已知的,结构位移和速度由相应的加速度按照积分原则获得。为了简便起见,参数被标以下标 k 用以表明时间,代表第 i 阶自由度的下标 i 在下文中被忽略掉。 f_k 代表在时间 k 第 i 阶自由度的恢复力,定义未知参数 $w = [c, k, T, U]^T$ 。为了识别未知参数,必须将式 (14), (15) 代表的非线性运动方程离散化。根据 3 阶预测校正模型^[21],在 k 时间相对于第 i 阶自由度的恢复力的增量部分为

$$f_k = f_{k-1} + (\Delta t/12)(5f_k + 8f_{k-1} - f_{k-2}) \quad (16)$$

式中 Δt 为取样时间间隔

定义变量 y^*

$$y^* = f^k - f_{k-1} \quad (17)$$

和观察矩阵 H_k

$$H_k = \Delta t h_k \begin{bmatrix} \ddot{u}_k & \dot{u}_k & |u_k| |f_k|^{n_i-1} f_k & |u_k| |f_k|^{n_i} \\ \ddot{u}_{k-1} & \dot{u}_{k-1} & |u_{k-1}| |f_{k-1}|^{n_i-1} f_{k-1} & |u_{k-1}| |f_{k-1}|^{n_i} \\ \ddot{u}_{k-2} & \dot{u}_{k-2} & |u_{k-2}| |f_{k-2}|^{n_i-1} f_{k-2} & |u_{k-2}| |f_{k-2}|^{n_i} \end{bmatrix} \quad (18)$$

式中 $h_k = \frac{1}{12}[5, 8, -1]$

因此,用于识别第 i 阶自由度的系统方程为

$$y_k = w^T H_k^T + e_k \quad (19)$$

式中 e_k 为测量噪声。

不失一般性,考虑识别第 i 阶自由度的情况,假设质量已知,且给出训练数据序列 $\{y^k, H_k^T\}_{k=1}^N$, 其中 $y^k \in \mathbf{R}$ 为输出数据, $H_k^T \in \mathbf{R}^4$ 为输入数据。支持向量法的目的是建立一个函数 (式 (8)) 用来模拟系统函数 (式 (19))。

为了简便起见,式 (18) 用以下的向量形式表示

$$H_k^T = [h_k^1 \ h_k^2 \ h_k^3 \ h_k^4]^T \quad (20)$$

用于 LS-SVM 的核函数为

$$h(x_k) = [h_k^1 \ h_k^2 \ h_k^3 \ h_k^4]^T \quad (21)$$

对矩阵 K 应用 Mercer 条件 $K_{kl} = h(x_k)^T h(x_l)$

从而,根据 Kun-Tucker 条件,由式 (6) 和式 (8) 可以得到支持向量值 T_k , 然后可以得到结构系统的参数

$$w = \sum_{k=1}^N T_k h(x_k) \quad (22)$$

考虑一个受地面激励的非线性滞回 3 自由度结构系统 (图 1), 其参数值如下: $m_1 = 0.25 \text{ kgf} \cdot \text{s}^2 / \text{cm}, m_2 = m_3 = 0.5 m_1, c_1 = c_2 = c_3 = 0.07 \text{ kgf} \cdot \text{s} / \text{cm}, k_1 = 24.5 \text{ kgf/cm}, k_2 = k_1, k_3 = 2k_1/3, T_1 = T_2 = T_3 = 2, U_1 = U_2 = U_3 = 1, n_1 = n_2 = n_3 = 2$ 。El Centro 地震记录调整最大幅值为 25 cm/s^2 后作为输入,用于系统识别的结构响应采样间隔为 0.01 s 。通常采用两个样本作为起始数据组,本文中的最终训练数据组为 $N = 400$, 以及参数 $N_{thre} = 100, M = 10, C = 10$ 。

为了考察方法的抗噪声能力,考虑噪声影响的情况,在 \ddot{u}, \dot{u} 和 f 中混入噪信比水平为 $\xi = e_{noise} / e_{obser} \times 100\%$ 的高斯噪声,其中 e_{noise} 和 e_{obser} 分别是所加噪

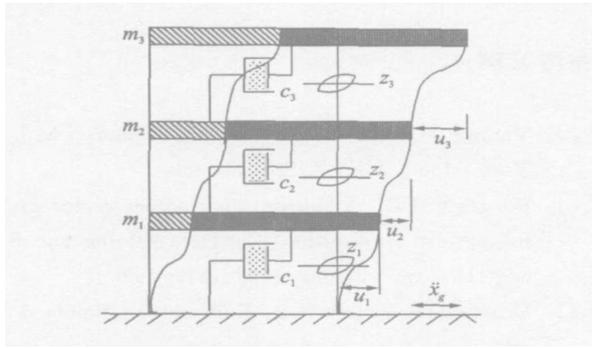


图 1 多自由度 Bouc-Wen 模型

声和观察信号的标准方差。为了验证 SLS-SVM 算法的鲁棒性,也考虑了训练数据混入非高斯噪声的情况(均值为 0 的高斯噪声叠加奇异信号),如图 2 所示为 f 中混入的非高斯噪声情况。

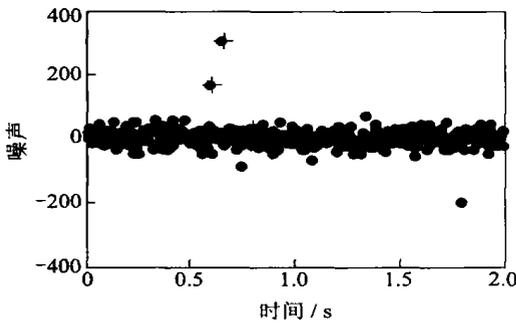


图 2 非高斯噪声

三层结构的在线识别结果如图 3~ 5 所示,虽然受到强烈的奇异信号的污染, SLS-SVM 系统参数在

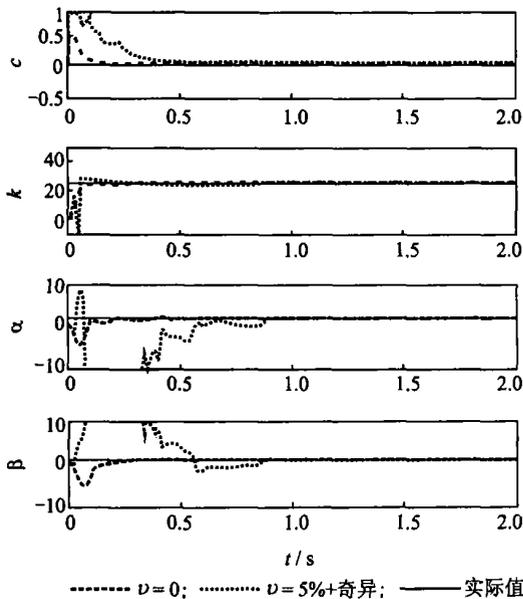


图 3 SLS-SVM 参数识别结果(第一层)

线识别没出现间断点现象,再次证明了该方法的鲁棒性和有效性 不失去一般性,只给出第一层的识别结果随 δ 在 0~ 10% 变化的曲线如图 6 所示 从这些图中可以看出 SLS-SVM 方法的有很高的识别精度和良好的抗噪声能力。

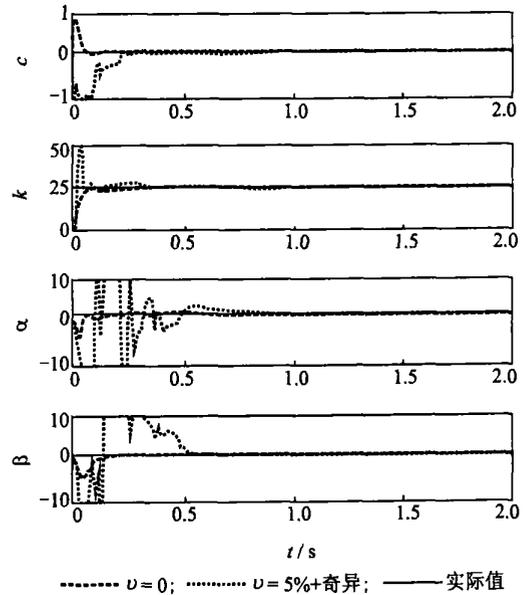


图 4 SLS-SVM 参数识别结果(第二层)

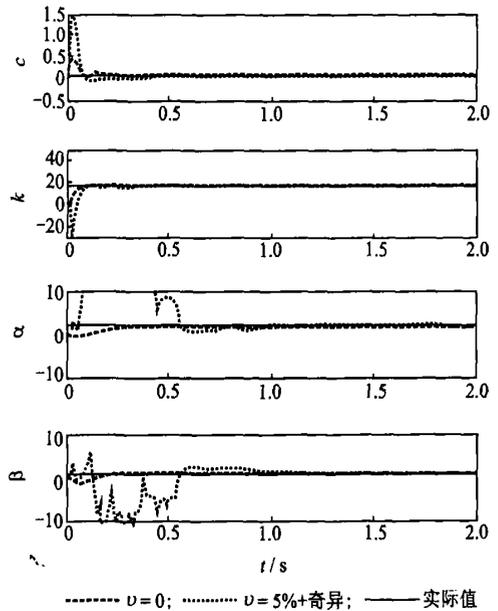


图 5 SLS-SVM 参数识别结果(第三层)

为了验证在 SLS-SVM 算法的快速,对比批处理 SVM 算法和 SLS-SVM 算法在不同数量的数据序列情况下的计算耗时,计算时间的比较如图 7 所示,可以看出 SLS-SVM 算法比批处理 SVM 算法要快很多。

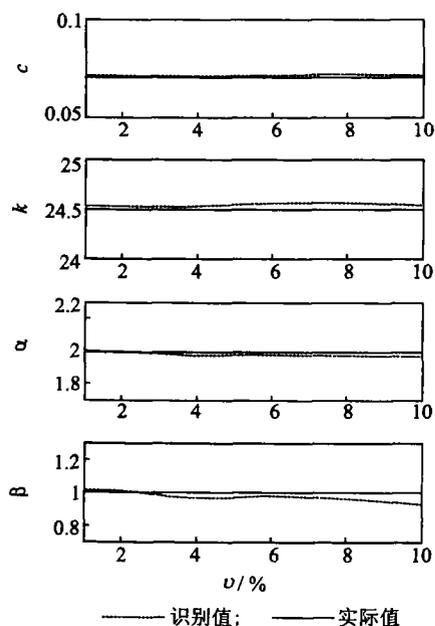


图6 识别结果与信号噪声比间关系(第一层)

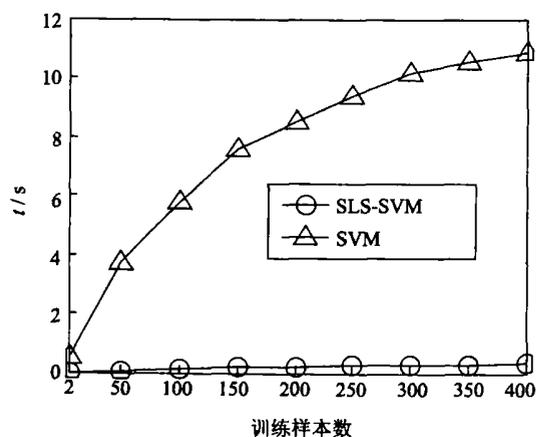


图7 计算时间比较

4 结论

本文提出序贯最小二乘支持向量机 (SLS-SVM)方法是一个同时结合了增量算法和缩减算法的递归算法,在对现存的样本有新的样本进入或旧的样本去除时可以有效地更新和修剪一个已经训练好的 LS-SVM,使传统的 LS-SVM 算法在线训练和近似稀疏成为可能。通过使用增量算法和缩减算法, SLS-SVM 算法只需解一个线性方程组而不是标准 SVM 方法的二次规划问题,这样避免了大型矩阵的求逆计算,从而缩短了计算时间。非线性结构系统的在线识别数值分析表明了这种算法有很高的识别精度以及良好的抗噪声能力和快速运算能力。

参考文献:

- [1] Vapnik V. Statistical Learning Theory [M]. New York: John Wiley & Sons, 1998.
- [2] Burges C J C. A tutorial on support vector machines for pattern recognition [J]. Data Mining and Knowledge Discovery, 1998, 2(2): 121-167.
- [3] Drucker H, Scholk F B, Kaufman L, Smola A, Vapnik V. Linear support vector regression machines [A]. The 10th Conference on Neural Information Processing Systems [C], Denver, Colorado, 1996. 155-161.
- [4] Vapnik V, Golowich S, Smola A. Support vector method for function approximation, regression estimation, and signal processing [A]. 10th Conference on Neural Information Processing Systems [C], Denver, Colorado, 1996. 281-287.
- [5] Müller K R, Smola A, Rätsch G, Scholkopf B, Kohlmorgen J, Vapnik V. Predicting time series with support vector machines [A]. 7th International Conference on Artificial Neural Networks [C], Lausanne, Switzerland, October, 1997. 999-1004.
- [6] Rojo-Alvarez J L, Martínez-Ramón M, De Prado-Cumplido M, et al. Support vector method for robust ARMA system identification [J]. IEEE Transaction on Signal Processing, 2004, 52(1): 155-164.
- [7] Suykens J A K, Vandewalle J, De Moor B. Optimal control by least squares support vector machines [J]. Neural Networks, 2001, 14(1): 23-35.
- [8] Suykens J A K, Vandewalle J. Least squares support vector machine classifiers [J]. Neural Process-Letters, 1999, 9(3): 293-300.
- [9] Suykens J A K, Vandewalle J. Sparse approximation using least squares support vector machines [A]. 2000 IEEE International Symposium on Circuits and Systems [C], Geneva, Switzerland, 2000. 757-760.
- [10] Suykens J A K. Support vector machines: a nonlinear modelling and control perspective [J]. European Journal of Control, Special Issue on Fundamental Issues in Control 2001, 7(2-3): 311-327.
- [11] Suykens J A K, Lukas L, Vandewalle J. Sparse least squares support vector machine classifiers [A]. 2000 European Symposium on Artificial Neural Networks [C], Bruges Belgium, 2000. 37-42.
- [12] Ralaivola L, d'Alché-Buc F. Incremental Support Vector Machine Learning: A Local Approach [M]. In G. Dorffner, H. Bischof, & K. Hornik (Eds.), Artificial Neural Networks - ICANN 2001 (2001),

- 322– 330, Berlin Springer-Verlag.
- [13] Vijayakumar S, Wu S. A gradient based technique for generating sparse representation in function approximation [A]. 6th International Conference on Neural Information Processing [C], Perth, Australia, 1999. 314– 319.
- [14] Fletcher R. Practical Methods of Optimization [M]. Chichester and New York: John Wiley and Sons, 1987.
- [15] 胡海岩. 具有记忆特性的非线性减振器参数识别 [J]. 振动工程学报, 1989, 2(2): 17– 26.
- [16] 李岳峰. 非线性系统参数识别的能量法 [J]. 振动工程学报, 1991, 4(3): 34– 40.
- [17] 陈乃立. 非线性滞迟系统的参数分离 [J]. 振动与冲击, 1994, 13(4): 7– 14.
- [18] Golub G H, Van Loan C F. Matrix Computations [M]. Baltimore MD: Johns Hopkins University Press, 1989.
- [19] Cauwenberghs G, Poggio T. Incremental and decremental support vector machine learning [A]. Advances in Neural Information Processing Systems [C]. Cambridge, MA: MIT Press, 2001, 13, 409– 123.
- [20] Wen Y K. Method for random vibration of inelastic structures [J], Applied Mechanical Reviews, 1989, 42 (2): 39– 52.
- [21] Lin J W, Betti R, Smyth A W, et al. On-line identification of non-linear hysteretic structural systems using a variable trace approach [J]. Earthquake Engineering and Structural Dynamics 2001, 30(9): 1 279– 1 303.

Sequential LS-SVM for structural systems identification

TANG He-sheng¹, XUE Song-tao^{1,2}, CHEN Rong¹, JIN Kan¹

(1. Research Institute of Structural Engineering and Disaster Reduction, Tongji University, Shanghai 200092, China;

2. Department of Architecture, School of Science and Engineering, Kinki University, Osaka 577-8802, Japan)

Abstract A sequential Least Squares Support Vector Machines (SLS-SVM) method is proposed for identification of structural systems in this paper. It efficiently updates a trained LS-SVM by means of incremental and decremental pruning algorithms whenever a sample is added to, or removed from, the training set. The method overcomes the drawback of sparseness lost within the standard LS-SVM and makes online training for the LS-SVM possible. Examples of nonlinear hysteretic structure parameters for online identification problems show the robustness and efficiency of the proposed method. They also show that the SLS-SVM algorithm is faster than the batch SVM algorithm.

Key words systems identification; hysteretic structure; sequential; least squares; support vector machines

作者简介: 唐和生(1973-),男,博士,讲师。电话: (021) 65982390; E-mail: thst@mial.tongji.edu.cn