

# 基于 WLS - SVM 的飞机状态监控与预测方法

张建业<sup>1</sup>, 潘 泉<sup>1</sup>, 宋吉学<sup>2</sup>

(1. 西北工业大学 自动化学院, 陕西 西安 710072; 2. 空军工程大学 工程学院, 陕西 西安 710038)

**摘要:**介绍了加权最小二乘支持向量机(WLS-SVM)在时间序列预测中应用的基本方法, 给出了一维时间序列建模预测的一般框架。提出采用BIC准则选取嵌入维数, 并给出了基于统计量的模型性能评价方法。针对飞机发动机的典型状态参数, 分别进行基于加权最小二乘支持向量机和AR模型的建模与预测, 给出了详细的比较结果。试验表明, 由于加权最小二乘支持向量机采用了新型的结构风险最小化准则, 因而表现出优秀的推广能力, 可预测区间较长且具有较高的准确度。

**关键词:**加权最小二乘; 支持向量机; AR模型; 监控; 预测; 飞机

**中图分类号:** V249    **文献标识码:**A    **文章编号:**1009-3516(2007)06-0001-04

时间序列分析是复杂非线性系统建模与预测的一类重要方法<sup>[1]</sup>。目前使用较成熟的主要是一些线性建模方法, 但对复杂系统, 线性方法往往效果不佳。支持向量机以其具有逼近任意复杂系统的能力和先进完备的理论体系而备受学术界的瞩目, 并且已在各个领域得到了广泛的应用<sup>[2-6]</sup>。最小二乘支持向量机采用等式约束条件, 而不是传统支持向量机所采用的不等式约束条件, 并且用最小二乘线性系统作为损失函数, 代替传统支持向量机采用的二次规划方法<sup>[7]</sup>。本文基于加权最小二乘支持向量机(WLS-SVM)<sup>[8]</sup>, 给出了一维时间序列预测建模的一般框架, 介绍了WLS-SVM用于序列预测的基本方法, 分析了预测结构优化的选取方法, 建立了WLS-SVM预测模型, 并与AR预测模型进行了比较。并利用飞机发动机典型状态参数进行了试验, 结果表明, WLS-SVM模型用于飞机发动机状态预测具有良好的效果和优秀的推广能力。

## 1 WLS-SVM 用于序列预测的基本方法

### 1.1 WLS-SVM 用于函数逼近的方法

给定N组样本数据 $\{x_k, y_k\}, k=1, 2, \dots, N$ , 其中 $x_k \in \mathbf{R}^m, y_k \in \mathbf{R}$ 。利用一个非线性映射 $\varphi$ , 将数据 $x$ 映射到高维特征空间 $F$ , 并在这个空间进行线性逼近, 找到映射 $f$ 使其能够很好地逼近给定数据组。由统计学习理论可知, 该函数具有以下形式:

$$f(x) = (\omega, \varphi(x)) + b, \varphi: \mathbf{R}^m \rightarrow F, \omega \in F \quad (1)$$

式中:(,)表示内积运算。则函数逼近问题可以归结为如下的优化问题:

$$\begin{aligned} \min_{w^*, b^*, e^*} J(w^*, b^*, e^*) &= \frac{1}{2} w^{*T} w^* + \frac{1}{2} \gamma \sum_{k=1}^N v_k e_k^{*2} \\ \text{s. t. } y_k &= w^{*T} \varphi(x_k) + b^* + e_k^*, k = 1, \dots, N \end{aligned} \quad (2)$$

定义拉格朗日函数:

$$L(w^*, b^*, e^*; \alpha^*) = J(w^*, b^*, e^*) - \sum_{k=1}^N \alpha_k^* \{w^{*T} \varphi(x_k) + b^* + e_k^* - y_k\} \quad (3)$$

收稿日期:2007-04-09

基金项目:国家“863”计划资助项目(2006AA701409);陕西省自然科学基金资助项目(2005F52)

作者简介:张建业(1971-),男,山西忻州人,副教授,博士生,主要从事信息融合、飞机状态监控、时间序列分析研究;  
潘 泉(1961-),男,上海人,教授,博士生导师,主要从事数据融合、小波分析等研究。

式中:拉格朗日乘子  $\alpha^* \in \mathbf{R}$ 。加权最小二乘支持向量机的未知参数用星号表示。对上式变量分别求偏导,并消去式中  $w^*, e^*$ ,可得:

$$\begin{bmatrix} 0 & \mathbf{1}_v^\top \\ \mathbf{1}_v & \Omega + V_\gamma \end{bmatrix} \begin{bmatrix} \frac{\mathbf{b}^*}{\alpha^*} \end{bmatrix} = \begin{bmatrix} 0 \\ \mathbf{y} \end{bmatrix} \quad (4)$$

式中: $\alpha = [\alpha_1, \dots, \alpha_N]$ ,  $\mathbf{y} = [y_1, \dots, y_N]$ ,  $\mathbf{1}_v = [1, \dots, 1]$ , 对角矩阵  $V_\gamma$  为

$$V_\gamma = \text{diag}\left\{\frac{1}{\gamma_{v_1}}, \dots, \frac{1}{\gamma_{v_N}}\right\} \quad (5)$$

式中  $v_k$  的选择是根据无加权最小支持向量机的误差变量  $e_k = \alpha_k/\gamma$  来确定的,即

$$v_k = \begin{cases} 1 & \text{if } |e_k/\hat{s}| \leq c_1 \\ \frac{c_2 - |e_k/\hat{s}|}{c_2 - c_1} & \text{if } c_1 \leq |e_k/\hat{s}| \leq c_2 \\ 10^{-4} & \text{其它} \end{cases} \quad (6)$$

选择  $c_1 = 2.5$ ,  $c_2 = 3$ , 考虑到对于高斯分布来说没有残差值大于  $2.5\hat{s}$ , 因而这是一个合理的选择。其中  $\hat{s}$  是最小二乘支持向量机误差变量  $e_k$  的标准偏差的鲁棒估计:

$$\hat{s} = 1.483 \text{MAD}(x_k) \quad (7)$$

式中:MAD 为绝对中值偏差。应用核技巧可得到  $\Omega_{kl} = \varphi(x_k)^\top \varphi(x_l) = K(x_k, x_l)$ , 则回归 LS-SVM 支持向量机决策函数为

$$y(x) = \sum_{k=1}^N \alpha_k K(x, x_k) + b \quad (8)$$

## 1.2 WLS-SVM 预测器结构的确定

对于给定的时间序列  $\{x_1, x_2, \dots, x_N\}$ , 假设已知  $x(t)$  预测  $x(t+1)$ , 可建立映射  $f: \mathbf{R}^m \rightarrow \mathbf{R}$ , 即:

$$\hat{x}(t+1) = f(x(t-(m-1)), \dots, x(t-1), x(t)) \quad (9)$$

加权最小二乘支持向量机预测器的拓扑结构如图 1 所示。式(9)中,  $m$  称为嵌入维数, 这里实际是指模型的阶数。由于支持向量机具有任意逼近的非线性映射能力, 且对于上述映射确定的预测器网络结构由算法自动最优化生成。因此, 只需要采用合适的模型选择准则, 优化选取支持向量机的输入节点数, 即可得到最优的预测器结构。

## 1.3 WLS-SVM 嵌入维数的确定

对时间序列  $\{x_1, x_2, \dots, x_N\}$  建模, 将其分成 2 部分, 其中前  $n_{tr}$  个数据用来训练预测器、进行参数估计和预测器的拓扑结构确定, 其余的数据用来验证模型的有效性, 为了更有效的进行预测模型建模, 对其进行相空间重构, 即将一维的时间序列转化成矩阵形式, 获得数据间的关联关系以挖掘到尽可能大的信息量, 建立输入  $x_t = \{x_{t-1-(m-1)\tau}, \dots, x_{t-1-\tau}, x_{t-1}\}$  与输出  $y_t = \{x_t\}$  之间映射关系  $f: \mathbf{R}^m \rightarrow \mathbf{R}$ , 可以看出嵌入维数  $m$  的值反映了转换后矩阵蕴涵的知识量。

$$X = \begin{bmatrix} x_1 & x_3 & \cdots & x_m \\ x_2 & x_3 & \cdots & x_{m+1} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n_{tr}-m} & x_{n_{tr}-m+1} & \cdots & x_{n_{tr}-1} \end{bmatrix}, \quad Y = \begin{bmatrix} x_{m+1} \\ x_{m+2} \\ \vdots \\ x_{n_{tr}} \end{bmatrix} \quad (10)$$

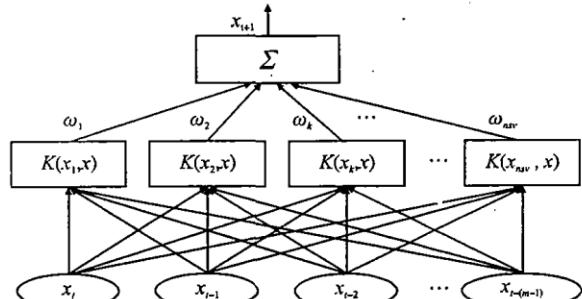


图 1 WLS-SVM 预测器结构

在时间序列预测中, 对于嵌入维数的选取尚无严格意义上的理论依据。本文采用 BIC 准则评价模型的预测误差, 并根据误差大小选取  $m$ , 即

$$\text{BIC}(m) = n_{tr} \ln \sigma_a^2 + m \ln n_{tr} \quad (11)$$

式中:  $\sigma_a^2 = E(a_{n_{tr}}) = \frac{1}{n_{tr} - m - 1} \sum_{t=m+1}^{n_{tr}} [x_t - \sum_{i=m+1}^{n_{tr}} \alpha_i k(x_i \cdot x_t) + b]^2$ ;  $n_{tr}$  表示用于训练的数据个数;  $m$  为需要确定的嵌入维数, 并且当  $m$  值增大时, 残差  $\sigma_a^2$  将减少, 因此总可以找到一个最优值  $m$  使得 BIC 达到最小。

#### 1.4 WLS-SVM 预测模型

在确定了 WLS-SVM 预测器的拓扑结构, 得到学习样本后, 就可对支持向量机进行训练, 得到的回归函数表示如下:

$$y_t = \sum_{i=m+1}^{n_{tr}} \alpha_i \cdot k(x_i \cdot x_t) + b \quad (12)$$

式中:  $t = m + 1, \dots, n_{tr}$ ,  $x_t = \{x_{t-1-(m-1)}, x_{t-2}, x_{t-1}\}$  1 步预测模型为

$$y_{t+1} = \sum_{i=m+1}^{n_{tr}} \alpha_i \cdot k(x_i \cdot x_{t+1}) + b \quad (13)$$

式中:  $x_{t+1} = \{x_{t+1-m}, x_{t-1}, x_t\}$ ,  $l$  步预测模型为:

$$y_{t,l} = \sum_{i=m+1}^{n_{tr}} \alpha_i \cdot k(x_i \cdot x_{t,l}) + b \quad (14)$$

式中:  $x_{t,l} = \{x_{t-m}, \dots, x_{t-l}, \hat{x}_{t,1}, \dots, \hat{x}_{t,(l-1)}\}$ ,  $t = n_{tr+1}, \dots, N$ ,  $\hat{x}$  表示预测值。

## 2 应用实例

为了检验 WLS-SVM 的预测性能, 文章同时还建立了相应的 AR 模型进行对比分析。选取飞机发动机的典型状态参数低压转子转速  $N_1$ 、高压转子转速  $N_2$ 、涡轮后燃气温度  $T_4$  和滑油压力  $P_m$  分别建模进行预测。

#### 2.1 数据预处理

为了降低建模误差, 对数据进行初始化处理, 得到新的时间序列, 建模分析之后再将其返还到原始区间。图 2 为低压转速  $N_1$  的数据序列。

#### 2.2 建立预测模型

共选取 500 个数据, 前 450 个作为训练数据, 后 50 个作为预测验证数据; 分别采用 AR 模型、WLS-SVM 回归模型进行 1 步 - 5 步的预测。其中对 AR 模型采用 FPE 准则评价预测误差, 并根据误差大小选取模型阶数。WLS-SVM 采用高斯径向基函数, 选取  $\sigma^2 = 1$ , 常数  $\gamma = 10$ 。为了评价模型的预测性能, 采用如下统计量对模型进行评估:

$$\text{ERROR} = \frac{1}{N - n_{tr}} \sum_{t=n_{tr}+1}^N \left| \frac{x(t) - y(t)}{x(t)} \right| \quad (15)$$

式中:  $y(t)$  是  $x(t)$  的预测值。

图 3 确定了 AR 模型、WLS-SVM 模型的阶数和嵌入维数。从中可以看出, 当  $n_{AR} = 37$  时 AR 模型 FPE = 0.024 728, 为最小值; 而当  $m_{SVM} = 4$  时 BIC = -1 723.8 为最小值, 图中也反映出 WLS-SVM 具有很高的建模精度。

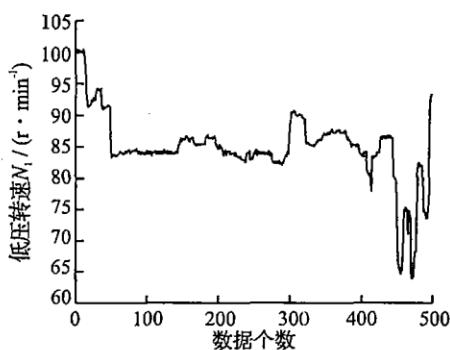


图 2  $N_1$  的时间序列数据

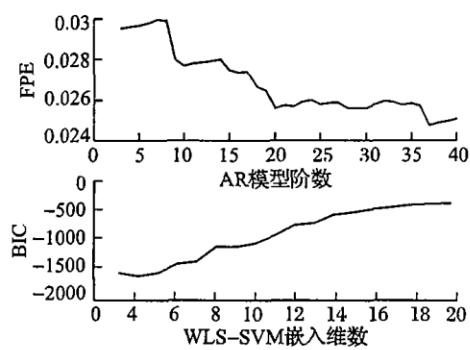


图 3 模型阶数和嵌入维数的确定

### 2.3 结果分析

从表 1 中可以看出, WLS - SVM 在短期预测中具有非常理想的效果, 在较长区间预测中仍然具有较高的预测精度(5 步预测仍可保证 95.26% 的准确率), 而 AR 模型不管在中短期, 还是在较长预测中都表现出较差的能力, 预测误差相对较大(5 步预测准确率降低至 85.26%)。这一结果对于飞机状态的监控具有重要的价值。即在已知序列的基础上利用支持向量机模型对飞机状态参数进行建模, 可以提前 5 个采样时间间隔进行有效的预测。

表 1 预测步数与平均相对误差

预测步数	WLS - SVM 模型	AR 模型
1	0.007 3	0.005 3
2	0.013 3	0.031 8
3	0.029 8	0.079 7
4	0.033 7	0.117 5
5	0.047 4	0.147 4

## 3 结论

首先, 随着预测步数的增加, WLS - SVM 仍具有较高的精度, 这说明支持向量机相比 AR 模型具有更强的推广能力; 其次, WLS - SVM 仅取决于支持向量, 而支持向量一般小于样本的个数, 因而可以有效降低建模的复杂性; 第 3, 嵌入维数选取准则、模型性能评价方法需要根据不同的应用场合分别加以确定。结果表明, WLS - SVM 是进行飞机状态监控及预测的有效方法, 具有很好的推广前景。

### 参考文献:

- [1] 杨叔子, 吴雅. 时间序列分析的工程应用 [M]. 武汉: 华中理工大学出版社, 1992.
- [2] 李应红, 尉询楷, 刘建勋. 支持向量机的工程应用 [M]. 北京: 兵器工业出版社, 2004.
- [3] 李应红, 尉询楷. 支持向量机和神经网络的融合发展 [J]. 空军工程大学学报: 自然科学版, 2005, 6(4): 70 - 73.
- [4] 倪世宏, 史忠科, 沙孟春. 一种基于支持向量回归的发动机振动监控方法 [J]. 空军工程大学学报: 自然科学版, 2006, 7(5): 1 - 3.
- [5] Vapnik V. The Nature of Statistical Learning Theory [M]. New York: Springer, 1999.
- [6] Steve Gunn. Support vector machines for classification and regression [R]. ISIS, Southampton University, 1998.
- [7] Suykens J A K, Vandewalle J. Least squares support vector machine classifiers [J]. Neural Processing Letters, 1999, 9(3): 293 - 300.
- [8] Suykens J A K, DeBrabanter L, Lukas L. Weighted Least Squares Support Vector Machines: robustness and sparse approximation [R]. Department of Electrical Engineering, ESAT - SISTA, 2000.

(编辑: 田新华, 徐楠楠)

## A Monitoring and Forecasting Method of Airplane Status Based on WLS - SVM

ZHANG Jian - ye<sup>1</sup>, PAN Quan<sup>1</sup>, SONG Ji - xue<sup>2</sup>

(1. School of Automation, Northwestern Polytechnical University, Xi'an 710072, China; 2. The Engineering Institute, Air Force Engineering University, Xi'an 710038, China)

**Abstract:** The essential method of application of weighted least squares support vector machines (WLS - SVM) to time series forecasting is introduced in detail in this paper, and the general framework for one dimensional time series modeling forecasting is proposed. BIC rule is adopted to select the embedded dimension, and a model performance evaluation method based on statistic is presented. The WLS - SVM model and AR model are set up and used to forecast the status of airplane based on the representative parameters, also the comparison result between the two models is given. The result shows that the WLS - SVM has excellent extended capability because the new type of structural risk minimization principle is adopted, and simultaneously it is of high accuracy and has long forecasting intervals.

**Key words:** weighted least squares; support vector machines; AR model; monitoring; forecasting; airplane