

## 基于支持向量机 的航空发动机滑油监控分析

尉询楷<sup>1</sup>, 李应红<sup>1</sup>, 王 硕<sup>2</sup>, 路建明<sup>1</sup>, 汪 诚<sup>1</sup>

(1. 空军工程大学 工程学院, 陕西 西安 710038;

2. 山东青岛即墨鹤山工业园, 山东 青岛 266217)

**摘要:** 提出了一种基于支持向量机的航空发动机滑油金属含量预测方法。详细分析了支持向量机用于时间序列预测的理论基础, 并给出了运用支持向量回归进行多步预测的一般公式, 提出了用最终预报误差(FPE)准则优化选取嵌入维数。与传统的 AR 预测模型相比, 支持向量机由于采用了新型的结构风险最小化准则表现出优秀的推广能力。经过数值仿真得出自回归(AR)模型仅适合于短期预测; 支持向量机预测推广能力强、具有较强的鲁棒性和容错性, 对较长区间预测仍具有较好的效果。最后, 将其应用于某型发动机滑油的铁金属含量预测, 取得了较好的效果。

**关键词:** 航空、航天推进系统; 滑油监控; 自回归模型; 支持向量回归; 时间序列预测

**中图分类号:** V233.4

**文献标识码:** A

## Aeroengine Lubrication Monitoring Analysis Via Support Vector Machines

WEI Xun-kai<sup>1</sup>, LI Ying-hong<sup>1</sup>, WANG Shuo<sup>2</sup>,LU Jian-ming<sup>1</sup>, WANG Cheng<sup>1</sup>

(1. Air Force engineering university, Xi'an 710038, China;

2. He-Shan Industrial Estate of Ji Mo, Qingdao 266217, China)

**Abstract:** A novel aeroengine lubrication monitoring method based on support vector machines is presented in this paper. Basic theory analysis of support vector regression in time series forecasting is introduced in detail and a multi-step forecasting formula is presented. Final Prediction Error (FPE) principle is suggested to select the embedding dimension. Compared with general autoregressive forecasting method it adopts new type of structural risk minimization principle and thus it owns excellent generalization ability. During numerical simulations, we infer that Auto-Regressive (AR) forecasting method is suitable to short intervals while Support Vector Machines (SVM) still possesses good robustness and fault-tolerant virtue in metaphase intervals forecasting. Finally, some types of aeroengine's lubrication metal content have been monitored for feasibility validation and test results are satisfactory.

**Key words:** aerospace propulsion system; lubrication monitoring; auto-regressive model; support vector regression; time series forecasting

收稿日期: 2003-09-28; 修订日期: 2003-12-23

作者简介: 尉询楷(1981-), 男, 山东莱阳人, 空军工程大学工程学院博士生, 主要从事航空发动机的智能控制与故障诊断研究。

随着航空发动机性能的不断提高,使得发动机各个部件的工作状况变得更加恶劣。滑油的消耗量及滑油中金属含量值能比较准确反映发动机的轴承、附件和齿轮的工作情况。当滑油消耗量或滑油中某些金属含量偏高,则说明轴承、机匣或齿轮磨损厉害。通过对滑油消耗量及滑油中镁、铝、铁和铜含量值及其趋势监控,可达到对发动机轴承、机匣或齿轮工作情况的监控,从而减少不必要的零部件更换,并能降低故障模式的二次损伤,有效的监视发动机传动系统零部件的磨损情况及故障特征。

某型飞机飞参系统记录了大量关于滑油的数据,通过光谱分析可以得到滑油中的金属含量,本文依据现场有的滑油金属含量历史数据,建立时间序列预测模型来预测分析金属含量的变化趋势。常规的时间序列预测方法主要以自回归(AR)模型为主,这种模型在理论上十分成熟,但其精度不高,且容错性差,仅仅适合做短区间预报;而支持向量机由于采用了新型的学习机制,使得预测模型具有很高的推广能力,即便在较长区间预测中仍可保证具有相当的精度。

本文分别建立了某型发动机的 AR 和支持向量机滑油金属含量预测模型,并做出了比较,最后给出了结论。

## 1 支持向量机用于序列预测的理论分析

### 1.1 支持向量机

支持向量机是由 Vapnik 在上世纪 90 年代中期提出的一种机器学习算法<sup>[1]</sup>。支持向量机以其良好的理论背景,从结构风险最小化原则为机器学习提供了一个崭新的方向。支持向量机在最小化经验风险的同时,最小化置信风险,有效的保证了较强的推广特性且推广能力可以得到方便的控制。采用核函数方法将输入空间映射到一个高维内积空间中,有效避免了“维数灾难”。支持向量机通过解一个线性约束的二次规划问题得到全局最优解,因而不存在局部极小值问题。支持向量机调整参数少,且模型结构由最能提供信息特征的支持向量点反映,可以大大降低建模的复杂性。回归型支持向量机<sup>[2~7]</sup>在形式上类似神经网络,输出是中间节点的线性组合,每个中间节点对应一个支持向量。其结构如图 1 所示。




图 1 回归型支持向量机的一般结构

Fig. 1 Architecture of support vector regression machines

### 1.2 支持向量回归

支持向量回归的基本思想是通过一个非线性映射  $\Phi$ , 将数据  $\vec{x}$  映射到高维特征空间  $F$ , 并在这个空间进行线性回归。

$$f(\vec{x}) =$$

$$[w, \Phi(\vec{x})] + b, \Phi: R^n \rightarrow F, w \in F \quad (1)$$

其中  $b$  是域值。则回归问题等价于使如下泛函最小:

$$R_{reg}[f] = R_{emp}[f] + \lambda \|w\|^2 = \sum_{i=1}^l C(e_i) + \lambda \|w\|^2 \quad (2)$$

其中  $e_i = f(\vec{x}_i) - y_i$ ,  $l$  表示样本容量,  $C(\cdot)$  是损失函数,  $\lambda$  为规则化常数。由于  $\Phi$  是固定不变的,  $\|w\|^2$  反映函数  $f$  在高维空间平坦的复杂性。考虑到线性  $\epsilon$  不敏感损失函数具有较好的稀疏特性,可保证得到的结果有较好的泛化能力,选取损失函数为:

$$|y - f(\vec{x})|_\epsilon =$$

$$\text{Max}\{0, |y - f(\vec{x})| - \epsilon\} \quad (3)$$

取经验风险为:

$$R_{emp}^{\epsilon}[f] = \frac{1}{l} \sum_{i=1}^l |y - f(\vec{x})|_\epsilon \quad (4)$$

则求解(1)式等价于求解如下的优化问题。

$$\text{Min } J = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l (\xi_i^* + \xi_i) \quad (5)$$

$$\text{s. t. } \begin{cases} y_i - [w, \Phi(\vec{x})] - b \leq \epsilon + \xi_i^* \\ [w, \Phi(\vec{x})] + b - y_i \leq \epsilon + \xi_i \\ \xi_i, \xi_i^* \geq 0 \end{cases}$$

式中:  $C$  用于控制模型复杂度和逼近误差的折中,  $C$  越大则对数据的拟合程度越高。  $\epsilon$ : 用于控制回

归逼近误差管道的大小,从而控制支持向量的个数和泛化能力,其值越大,则支持向量越少,但精度不高。应用中常常利用(5)式的对偶式,同时引入核函数方法,则(5)式转化为:

$$\begin{aligned} \text{Max } J = & -\frac{1}{2} \sum_{i,j=1}^l (\alpha_i^* - \alpha_i)(\alpha_j^* - \alpha_j) \cdot \\ & K(\vec{x}_i, \vec{x}_j) + \sum_{i=1}^l \alpha_i^* (y_i - \varepsilon) - \\ & \sum_{i=1}^l \alpha_i^* (y_i + \varepsilon) \end{aligned} \quad (6)$$

$$\text{s. t. } \begin{cases} \sum_{i=1}^l \alpha_i = \sum_{i=1}^l \alpha_i^* \\ 0 \leq \alpha_i \leq C \\ 0 \leq \alpha_i^* \leq C \end{cases}$$

理论上,位于边界上的点(满足  $0 \leq \alpha_i, \alpha_i^* \leq 1/\lambda$ ),可以得到预测误差的唯一确定值  $\delta_k = \text{esign}(\alpha_k - \alpha_k^*)$ ,出于稳定性考虑,推荐采用边界点上的平均值:

$$b = \text{average}_k \left\{ \delta_k + y_k - \sum_i (\alpha_i - \alpha_i^*) \cdot k(\vec{x}_i, \vec{x}_k) \right\}$$

求解上述凸二次规划得到的非线性映射可表示为:

$$f(\vec{x}) = \sum_{i=1}^{\text{nav}} w_i K(\vec{x}_i, \vec{x}) + b \quad (7)$$

### 1.3 基于支持向量回归的时间序列预测模型

#### 1.3.1 数据准备

对于平稳时间序列  $\{x_1, x_2, \dots, x_n\}$ ,为了能够采用支持向量机进行预测,关键是如何重构相空间<sup>[8~11]</sup>,如何将其转化成矩阵形式获得数据间的相互关联关系以便于挖掘尽可能大的信息量。简单的讲就是如果  $\{x_t\}$  是预测的目标值,将先前的目标值  $\{x_{t-1}, x_{t-2}, \dots, x_{t-p}\}$  作为相关量,由于先前的目标值可能会影响到未来值,因此在模型中考虑先前值的影响将有助于更好的预测。建立自相关输入  $\vec{x}_t = \{x_{t-1}, x_{t-2}, \dots, x_{t-p}\}$  与输出  $y_t = \{x_t\}$  之间一一映射关系  $f: R^p \rightarrow R$ ,其中  $p$  值称为嵌入维数,可以看出  $p$  值的选取实际隐含反映了转换后矩阵蕴涵的知识量。而在支持向量回归平稳时间序列预测中,其选取尚无严格的理论指导。同时为了与 AR 模型比较,本文也采用  $FPE$  准则评价预测误差,并根据误差值大小来优化选取嵌入维数  $p$ 。经过这样的变换之后,可以得到用于向量机学习的样本:

$$X = \begin{bmatrix} x_1 & x_2 & \cdots & x_p \\ x_2 & x_3 & \cdots & x_{p+1} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n-p} & x_{n-p+1} & \cdots & x_{n-1} \end{bmatrix}$$

$$Y = \begin{bmatrix} x_{p+1} \\ x_{p+2} \\ \vdots \\ x_n \end{bmatrix}$$

#### 1.3.2 预测模型

在得到学习样本之后,就可对支持向量机进行训练,得到的回归函数表示如下:

$$y_t = \sum_{i=1}^{n-p} (\alpha_i - \alpha_i^*) k(\vec{x}_i, \vec{x}_t) + b$$

$$t = p+1, \dots, n \quad (8)$$

注意到在上面的数据项中还有一项没有利用即:

$$\vec{x}_{n-p+1} = \{x_{n-p+1}, x_{n-p+2}, \dots, x_n\}$$

因此可得到对第  $n+1$  点的预测为:

$$y_{n+1} = \sum_{i=1}^{n-p} (\alpha_i - \alpha_i^*) \cdot k(\vec{x}_i, \vec{x}_{n-p+1}) + b \quad (9)$$

得到第  $n+1$  点后,又可以得到一个样本:

$$\vec{x}_{n-p+2} = \{x_{n-p+2}, x_{n-p+3}, \dots, x_n, \hat{x}_{n+1}\}$$

其中  $\hat{x}_{n+1}$  表示第  $n+1$  个数据的预测值,同样得第  $n+2$  点的预测值:

$$y_{n+2} = \sum_{i=1}^{n-p} (\alpha_i - \alpha_i^*) \cdot k(\vec{x}_i, \vec{x}_{n-p+2}) + b \quad (10)$$

一般的可以得到第  $l$  步的支持向量机的预测模型为:

$$y_{n+l} = \sum_{i=1}^{n-p} (\alpha_i - \alpha_i^*) \cdot k(\vec{x}_i, \vec{x}_{n-p+l}) + b \quad (11)$$

其中:

$$\vec{x}_{n-p+l} = \{x_{n-p+l}, \dots, \hat{x}_{n+1}, \hat{x}_{n+l-1}\}$$

#### 1.3.3 模型评价准则

本文采用最终预报误差( $FPE$ )准则来评价模型的适用性。

$$FPE(k) = \frac{n+k}{n-k} \sigma_a^2 \quad (12)$$

其中:

$$\sigma_a^2 = E(a_n^2) = \frac{1}{n-k} \sum_{t=k+1}^n \left[ x_t - \sum_{i=1}^{n-k} (\alpha_i - \alpha_i^*) k(\vec{x}_i, \vec{x}_t) - b \right]^2$$

当  $k$  值增大时, 残差  $\sigma_a^2$  将减少, 因此可以找到一个最优值  $p$  使得  $FPE$  达到最小。

## 2 应用实例

本文采用的数据来自某型发动机从一次换油到另一次换油的完整工作阶段的滑油光谱分析数据, 并按照光谱分析的时间排序得到金属含量数据序列(共计 94 个), 因为在滑油监测中以 Fe 的金属含量为主要监控对象, 因此本文仅以含 Fe 量的时间序列分析为例。

### 2.1 数据的预处理

首先, Fe 金属含量的原始时间序列如图 2 所示。将数据序列进行相对化处理, 再对数据进行零化处理得到新的 Fe 金属的相对含量时间序列  $\{x_i\}$ 。本文采用工程处理方法<sup>[12,13]</sup>不对其进行正态性检验, 认为经过处理之后的时间序列  $\{x_i\}$  满足平稳、正态要求。




图 2 Fe 含量时间序列

Fig. 2 Fe content time series curve




图 3  $p$  与  $FPE$

Fig. 3 Relationship between  $p$  and  $FPE$

### 2.2 AR 模型与回归支持向量机预测模型的建立

采用  $FPE$  准则分别建立 AR 和支持向量机的预测模型, 从图 3 中可以看出当  $p_{AR}=13$  时 AR 模型  $FPE$  值达到最小  $1.44 \times 10^{-2}$ ; 而当  $p_{svm}=11$  时  $FPE$  值达到最小  $0.92 \times 10^{-6}$ , 图中也可以反映出支持向量回归方法确实具有很高的建模精度。

### 2.3 训练与测试结果比较

将数据分成两组: 前 60 次数据作为训练数据, 后 34 次作为测试数据, 采用 AR 模型、支持向量回归模型分别进行提前 1 步~5 步的预测, 其中提前 1 步与 5 步的结果比较分别见图 4 和图 5, 1~5 步二者的预测平均相对误差值如表 1 所示。其中回归向量机采用高斯径向基函数, 经过计算选取  $\sigma^2=0.5$ , 常数  $C=10000$ ,  $\epsilon=0.0001$ 。




图 4 1 步提前预测的结果

Fig. 4 One step ahead forecasting results




图 5 5 步提前预测的结果

Fig. 5 Five step ahead forecasting results

表 1 预测步数与平均相对误差

Table 1 Forecasting step ahead and mean relative error

预测步数	svm	AR
1	0.0009	0.1285
2	0.0025	0.1618
3	0.0131	0.1741
4	0.0653	0.1923
5	0.1525	0.2157

另外,本文也考虑了支持向量机自身参数的选择对于预测结果的影响。以单步预测为例,向量机采用高斯径向基核函数,采用 Cross-Validation 方法<sup>[14]</sup>进行参数优选,部分所得的结果如表 2 所示。

从表中可以得出:对于不同的参数选择支持向量机的预测效果也不尽相同。在相同的  $\sigma^2$  和  $\epsilon$  下,当  $C$  值较小时对预测的结果影响不大,而当  $C$  值继续增大到一定值时,预测误差随之增大;而在相同的  $C$  值和  $\sigma^2$  下,随着  $\epsilon$  的增大,相应的预测误差也随之增大(低于优选值 0.0001 时,误差基本不变);在相同的  $C$  值和  $\epsilon$  下,随着  $\sigma^2$  的增大,预测的误差则存在最优值  $\sigma^2=0.5$ 。因此,应根据实际问题优化选取向量机的参数,方能取得最佳效果。

### 3 结 论

本文详细分析了支持向量机用于时间序列预测的理论基础,针对某型发动机滑油金属含量的预测分别采用传统的 AR 模型和基于现代统计理论下的支持向量回归模型对滑油时间序列进行了预测建模。通过数值仿真和测试分析得出:

(1) 支持向量机应用于航空发动机金属含量的时间序列预测是成功的,由表 1 可见随着预测步数的增加 AR 模型以及支持向量机的预测平均相对误差均增加,但支持向量机与 AR 相比仍然具有较高的精度,这说明支持向量机具有很强的推广能力。

(2) 与 AR 模型相比,支持向量回归仅取决于支持向量,而支持向量一般小于样本的个数,从而有效降低了建模的复杂性。支持向量往往位于变化剧烈的点,因而使得回归型支持向量机能更好跟踪时间序列的发展趋势,做出合理的预测分析。

(3) 通过数值计算发现,对于不同的参数选择,支持向量机具有不同的预测效果,对于实际问题需要根据适当的方法合理的选取支持向量机的参数才能取得最佳的效果。

(4) 在给定金属含量警戒值下,采用支持向量机可以进行较长区间有效预警,从而可为航空发动机的健康状况监控提供重要的依据。

表 2 不同参数时的单步预测平均相对误差

Table 2 Single step ahead forecasting mean relative error under different parameters selection condition

参数组合	$C$	$\epsilon$	$\sigma^2$	平均相对误差
1	1000	0.005	0.5	0.0053
2	10000	0.005	0.5	0.0053
3	100000	0.005	0.5	0.0189
4	1000000	0.005	0.5	0.0673
5	10000	0.0001	0.5	0.0009
6	10000	0.001	0.5	0.0022
7	10000	0.005	0.5	0.0053
8	10000	0.01	0.5	0.0107
9	10000	0.0001	0.25	0.0025
10	10000	0.0001	1.5	0.0019
11	10000	0.0001	3.8	0.0028
12	10000	0.0001	5.0	0.0153

## 参考文献:

- [1] Vapnik V. The Nature of Statistical learning[M]. New York: Springer, 1995.
- [2] Gunn S. Support Vector Machines for Classification and Regression [R]. Image Speech Intelligent System Research Group ISIS-1-98, Southampton University, 1998.
- [3] Drucker H, Burges C J C, Kaufman L, Smola A, Vapnik V. Support Vector Regression Machines[A]. In Mozer M, Jordan M, Petsche T, Editors, Advances in Neural Information Processing Systems 9[C]. Cambridge, MA: MIT Press, 1997: 155-161.
- [4] Campbell C. An Introduction to Kernel Methods[A]. In Howlett R J, Jain L C, Editors, Radial Basis Function Networks: Design and Applications[C]. Berlin: Springer Verlag, 2000: 31-38.
- [5] Smola A. Regression Estimation with Support Vector Learning Machines[D]. Master's thesis, München: Technische Universität München, Germany, 1996.
- [6] Smola A J, Schölkopf B. A Tutorial on Support Vector Regression[R]. NeuroCOLT Technical Report NC-TR-98-030, Royal Holloway College, University of London, UK, 1998.
- [7] Vapnik V, Golowich S, Smola A. Support Vector Method for Function Approximation, Regression Estimation, and Signal Processing[A]. In Mozer M, Jordan M, Petsche T, Editors, Advances in Neural Information Processing Systems 9[C]. Cambridge, MA: MIT Press, 1997: 281-287.
- [8] Müller K R, Smola A, Rütsch G, Schölkopf B, Kohlmorgen J, Vapnik V. Predicting Time Series with Support Vector Machines[A]. In Schölkopf B, Burges C J C, Smola A J, Editors, Advances in Kernel Methods-Support Vector Learning [C]. Cambridge, MA: MIT Press, 1999: 243-254.
- [9] Mukherjee S, Osuna E, Girosi F. Nonlinear Prediction of Chaotic Time Series Using a Support Vector Machine[A]. In Principe J, Gile L, Morgan N, Wilson E, Editors, Neural Networks for Signal Processing VII - Proceedings of the 1997 IEEE Workshop[C]. New York: IEEE, 1997: 511-512.
- [10] Cao L J, Gu Q M. Dynamic Support Vector Machines for Non-Stationary Time Series Forecasting[J]. Intelligent Data Analysis, 2002, 6(1): 67-83.
- [11] Tay F E H, Cao L J. Applications of Support Vector Machines in Financial Forecasting[J]. Omega, 2001, 9(4): 309-317.
- [12] 杨叔子, 吴雅. 时间序列分析的工程应用(上、下册)[M]. 武汉: 华中理工大学出版社, 1996.
- [13] 沈玉娣. 支持向量机在智能诊断中的应用[D]. 西安: 西安交通大学, 2003.
- [14] Cherkassky V. Comparison of Model Selection for Regression[J]. Neural Computation, 2003, 15(7): 1691-1714.