

基于支持向量机的航空发动机性能衰退指标预测

谭巍¹, 徐健², 于向财¹

(1. 海军航空兵学院, 辽宁葫芦岛 125001; 2. 海军驻沈阳地区发动机专业军事代表室, 沈阳 110031)

摘要: 针对航空发动机性能衰退状态的趋势预测问题, 基于非线性支持向量机回归建立了发动机性能衰退指标的预测模型, 给出了反映其性能衰退的综合指标。利用该模型对发动机的性能衰退指标进行了预测分析, 并与神经网络模型预测结果进行了比较。结果表明: 支持向量机回归预测模型能更准确地对发动机的未来状况进行预测。

关键词: 支持向量机; 性能衰退; 性能指标; 性能预测; 航空发动机

中图分类号: V235.13

文献标识码: A

doi: 10.13477/j.cnki.aeroengine.2014.04.010

Prediction of Aeroengine Performance Deterioration Index Based on Support Vector Machine

TAN Wei¹, XU Jian², YU Xiang-cai¹

(1. Naval Aviation, Academy Liaoning Huludao 125001, China; 2. Navy Station in Shenyang Military Representative Office on Engine, Shenyang 110031, China)

Abstract: Aiming at the problems of trends prediction for aeroengine performance deterioration, the prediction model of engine performance deterioration index was regressive built based on the nonlinear Support Vector Machine (SVM), and synthetic index reflected performance deterioration was obtained. The index of engine performance deterioration was predicted and analyzed by SVM model, which compared with the Artificial Neural Network (ANN) model. The results show that the SVM model can accurately predict engine operation in the future.

Key words: SVM; performance deterioration; performance index; performance forecasting; aeroengine

0 引言

从发动机正常使用到完全失效要经历一系列不同的性能衰退阶段, 如果能在发动机的衰退过程中评估其所处的性能衰退阶段, 并对其性能衰退进行预测分析, 就可以有针对性的采取维护措施, 对于推动视情维修, 降低维护使用成本, 提高飞行安全具有重要意义^[1]。

性能衰退评估研究重点是利用当前数据和历史数据, 获取发动机当前运行状态的信息。而发动机性能衰退预测则是对发动机性能衰退状态进一步的发展趋势进行分析, 防止故障的扩展。由于支持向量机 (Support Vector Machine, SVM) 具有完备的统计学习理论基础和出色的学习性能, 根据结构风险最小化 (Structural Risk Minimization, SRM) 原则^[2], 可以尽量提高学习机的泛化能力, 非常适合航空发动机这类小

样本下的预测分析问题, 因此基于 SVM 的预测模型具有很强的推广能力。

本文针对航空发动机性能衰退状态的发展趋势进行预测分析。以支持向量机回归理论为基础, 给出了反映发动机性能衰退的综合指标, 建立了发动机性能衰退的一步及多步预测模型。

1 航空发动机性能衰退指标的建立

在航空发动机性能衰退的过程中要经历不同的阶段, 其性能数据在特征空间中呈现一定的分布规则。采用 SVM 分类器对发动机性能退化状态进行分类, 是由于其特征参量与正常状态下的特征参量存在一定的差别。

1.1 性能衰退评估模型

建立基于 SVM 的性能衰退评估模型, 如图 1 所

收稿日期: 2013-10-22

作者简介: 谭巍 (1982), 男, 博士, 主要从事航空发动机教学研究工作; E-mail: twchy@sina.cn。

引用格式: 谭巍, 徐健, 于向财. 基于支持向量机的航空发动机性能衰退指标预测[J]. 航空发动机, 2014, 40(4): 51-55. TAN Wei, XU Jian, YU Xiangcai. Prediction of aeroengine performance deterioration index based on Support Vector Machine [J]. Aeroengine, 2014, 40(4): 51-55.

示。该模型主要包括训练和测试 2 个步骤。




图1 基于 SVM 几何距离的性能衰退评估模型

在性能衰退评估模型中,特征空间内原输入空间中反映发动机性能特征参数向量 x 及其到最优分类面 H 之间的距离 d 计算为

$$d = \frac{w \cdot \varphi(x) + b}{\|w\|} \quad (1)$$

其中

$$w = \sum_{i=1}^l y_i a_i^* \phi(x_i) \quad (2)$$

$$b = \frac{1}{l} * \sum_{i=1}^l (y_i - w \cdot \phi(x_i)) \quad (3)$$

$$\|w\|^2 = \sum_{i,j \in S} y_i y_j a_i^* a_j^* K(x_i, x_j) \quad (4)$$

式中: a 为 SVM 系数; w 为分类面的权系数向量; b 为偏置系数; (x_i, y_i) 为数据样本集; $x_i \in \mathbb{R}^N$, $y_i \in \{-1, 1\}$, $(i=1, \dots, l)$; K 为核函数。

图1中的虚线和实线分别表示 SVM 模型训练和测试过程。将待测样本送入训练好的模型中,计算数据 x_i 的几何距离 d_i 。将得到的 d_i 进行归一化处理,得到 $-1 \leq d_i \leq 1$, 并且规定当 $d_i < 0$, $x_i \in \{\text{正常}\}$; $d_i > 0$, $x_i \in \{\text{异常}\}$ 。为了描述方便,将几何距离转化为

$$DV = 0.5d_i + 0.5 \quad (5)$$

这样就可以将发动机性能特性量变成性能衰退

指标 DV (Degradation Value), $0 \leq DV \leq 1$, 并且在分界面表征性能衰退数据的一侧,离分类面距离越远的发动机性能特性参数表示性能衰退越严重。

1.2 模型参数优化选择

在 SVM 中,通常由模型参数 C 和核函数的参数来决定数据与最优分类面之间的距离参量^[9]。根据 SVM 的性质,对于同类数据来说,距离应越小越好,而对于不同类别的数据来说则是距离越大越好,综合以上 2 个原则,提出优化准则为

$$\max J_d(\theta) = \sum_{y_i} \left(\frac{V_{y_i}(\theta)}{\overline{M}_{y_i}(\theta)} \right), y_i = \{-1, 1\} \quad (6)$$

其中

$$V_{y_i}(\theta) = D(d(x_i, \theta)), \{x_i | y_i = \{1, -1\}\}, i=1, \dots, l$$

$$\overline{M}_{y_i}(\theta) = E(d(x_i, \theta)), \{x_i | y_i = \{1, -1\}\}, i=1, \dots, l$$

式中: (x_i, y_i) 为给定的 2 类数据测试样本; $V_{y_i}(\theta)$ 为同类数据方差; $\overline{M}_{y_i}(\theta)$ 为不同类数据均值。

通过搜索 $J_d(\theta)$ 最大值的过程,确定最优参数 θ 。对于相同的测试样本集,如果参数 θ 使得发动机性能退化状态数据与发动机处于正常状态数据的 $J_d(\theta)$ 越大,则说明该参数使得模型对性能退化状态越敏感。但是,在几何距离性能衰退评估模型中,采用的是 DV 值描述性能衰退的程度,因此需要对原判据进行修正

$$\max J_{DV}(\theta) = \sum_{y_i} \left(\frac{V_{y_i}(\theta)}{\overline{M}_{y_i}(\theta)} \right), y_i = \{-1, 1\} \quad (7)$$

其中

$$V_{y_i}(\theta) = D(DV(x_i, \theta)), \{x_i | y_i = \{1, -1\}\}, i=1, \dots, l$$

$$\overline{M}_{y_i}(\theta) = E(DV(x_i, \theta)), \{x_i | y_i = \{1, -1\}\}, i=1, \dots, l$$

1.3 性能衰退指标曲线

以某型航空发动机为研究对象,选取低、高压压气机流量,高、低压涡轮效率,低、高压转子转速,高压压气机后压力和尾喷口温度共 8 维数据,均为相对变化量。采用机理分析和数学模型相结合的方法产生数据样本^[4],将部件性能参数(包括效率和流量)按照一定比例减小,带入到稳态模型中去,基于稳态模型得到对应的 46 组数据。采用核主成分分析的方法对原始数据进行特征约简后带入 SVM 模型进行训练,计算得到性能衰退指标的曲线如图 2 所示。

从图 2 中可见,发动机性能衰退指标是 1 个连续




图2 性能衰退指标曲线

变化的指标参数,依据性能特征参数给出的1个无量纲的性能指标,并且随着时间递增,表示发动机随着部件性能的降低和测量参数的偏离,性能衰退综合指标偏离正常值越远,这与实际相符。

2 性能衰退指标的回归预测

2.1 支持向量机回归模型的建立

航空发动机的性能衰退是1个连续、渐进的过程。性能退化指标DV具有时序性和关联性,即当前DV值与其过去时刻的有一定的联系;同时性能退化指标是综合发动机部件和整机状态量得到的信息,因此该指标值是连续有界的,可以将发动机性能衰退指标作为可预测时间序列进行研究。由于航空发动机结构复杂,工作情况多变,再加以发动机中一些结构的非线性,使得其工作参数具有一定的非线性特征,因此采用非线性支持向量机回归对性能衰退指标进行预测分析^[5]。

对于给定时间序列 $\{x_1, x_2, \dots, x_n\}$,建立映射关系 $f: \mathbb{R}^m \rightarrow \mathbb{R}$,满足:

$$x(t+l) = f(x(t-(m-1)\tau), \dots, x(t-\tau), x(t)) \quad (8)$$

式中: l 为预测步长; m 为嵌入维数; τ 为时间延迟。

为了采用回归支持向量机对上述时间序列 $x_1, x_2, \dots, x_n$,进行预测,首先要对时间序列进行相空间重构^[6],建立如下输入:

$$\begin{aligned} \bar{x}(t) &= [x(t+(m-1)\tau), \dots, x(t+\tau), x(t)] \\ t &= 1, 2, \dots, n-(m-1)\tau \end{aligned} \quad (9)$$

与输出 $y(t) = f[\bar{x}(t)]$ 之间的映射关系为 $f: \mathbb{R}^m \rightarrow \mathbb{R}$ 。

从上述描述中可见, m 和 τ 值的优化选取反映了利用最少而且最有效的原始时间序列数据信息最大限度的挖掘原始1维数据的时间序列信息。而对具体 m 和 τ 值的优化选取,尚无理论可以借鉴,多是采用反复试验和智能算法。

采用如下方法进行优化选取最佳的 m 和 τ 。流程^[7]如下:

(1)给定最大的 m 和 τ 值分别为 $m_{\max}$ 和 $\tau_{\max}$;

(2)使 $m=2:m_{\max}$ 和 $\tau=1:\tau_{\max}$ 变化,遍历所有的 m 和 τ 。对于每1组 m_i 和 τ_i ,对应着1组重构预测矩阵,利用这组矩阵数据训练此网络,记录下此时的 r_{1i} , m_i 和 τ_i 。其中, $i \in [1, \tau_{\max} * (m_{\max}-1)]$;

(3)采取打擂台法,选取最小的 r_{1i} , m_i 和 τ_i ,此时 $r_{1\text{best}} = r_{1i}$, $m_{\text{best}} = m_i$, $\tau_{\text{best}} = \tau_i$;

(4)利用最优的 m_{best} 和 τ_{best} 对未来测量参数时间序列进行预测分析,并对测量数据预测效果进行检验。

通过建立输入与输出之间的映射关系,具体重构结果为

$$X = \begin{pmatrix} x_1 & x_2 & \cdots & x_m \\ x_2 & x_3 & \cdots & x_{m+1} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n-m} & x_{n-m+1} & \cdots & x_{n-1} \end{pmatrix} = \begin{pmatrix} \vec{x}_1 \\ \vec{x}_2 \\ \vdots \\ \vec{x}_{n-m} \end{pmatrix} \quad (10)$$

$$Y = \begin{pmatrix} x_{m+1} \\ x_{m+2} \\ \vdots \\ x_n \end{pmatrix} = \begin{pmatrix} y_{m+1} \\ y_{m+2} \\ \vdots \\ y_n \end{pmatrix}$$

根据非线性支持向量回归决策函数式,可得^[8]

$$y_t = \sum_{i=1}^{n-m} (a_i - a_i^*) K(\vec{x}_t, \vec{x}_{t-m}) + b \quad (11)$$

式中: $t=m+1, \dots, n$,则1步预测模型为

$$y_{n+1} = \sum_{i=1}^{n-m} (a_i - a_i^*) K(\vec{x}_t, \vec{x}_{n-m+1}) + b \quad (12)$$

进一步推广到 l 步预测模型为

$$Y_l = \begin{pmatrix} y_{n+1} \\ y_{n+2} \\ \vdots \\ y_{n+l} \end{pmatrix} = \begin{pmatrix} \sum_{i=1}^{n-m} (a_i - a_i^*) K(\vec{x}_t, \vec{x}_{n-m+1}) + b \\ \sum_{i=1}^{n-m+1} (a_i - a_i^*) K(\vec{x}_t, \vec{x}_{n-m+2}) + b \\ \vdots \\ \sum_{i=1}^{n-m+l-1} (a_i - a_i^*) K(\vec{x}_t, \vec{x}_{n-m+l}) + b \end{pmatrix} \quad (13)$$

在 multi-step 预测模型式(13)中,除 y_{n+1} 之外,其 $l-1$ 个预测值都要用到前一步的预测值,因此 l 步预测值的预测不确定性会随着步长的增长而增加。

使用回归支持向量机对性能衰退指标进行预测分析。同时,为了评估预测效果的优劣引入平均相对误差(Mean Relative Error, MRE)作为评判标准^[9]

$$MRE = \frac{\sum_{t=1}^n \left| \frac{e(t)}{y(t)} \right|}{n} \quad (14)$$

式中: $e(t) = \hat{y}(t) - y(t)$ 为绝对误差; $y(t)$ 、 $\hat{y}(t)$ 和 n 分别为真实值、预测值和样本大小。

根据上述定义可知, MRE 值越小, 表明预测值与实际值的拟合精度越高, 则预测的准确度越高。

2.2 衰退指标回归预测仿真与分析

在性能衰退指标的基础上进行分析, 选择前 40 组数据作为训练样本, 后 26 组数据作为测试样本。首先建立 SVM 预测模型, 优化选取最佳的 m 和 τ , 分别为 $m_{\text{best}}=3$, $\tau_{\text{best}}=2$ 。对于一步预测, 按照式(10)进行相空间重构, 从而得到

$$X = \begin{bmatrix} X_1 & X_2 & X_3 \\ X_2 & X_3 & X_4 \\ \vdots & \vdots & \vdots \\ X_{n-3} & X_{n-2} & X_{n-1} \end{bmatrix} = \begin{bmatrix} \rightarrow X_1 \\ \rightarrow X_2 \\ \vdots \\ \rightarrow X_{n-3} \end{bmatrix} \quad (15)$$

$$Y = \begin{bmatrix} X_4 \\ X_5 \\ \vdots \\ X_n \end{bmatrix} = \begin{bmatrix} y_4 \\ y_5 \\ \vdots \\ y_n \end{bmatrix}$$

式中: X 为训练数据; Y 为目标数据。

训练完毕之后, 将测试样本 $X_{\text{test}}^n = (x_1, x_2, \dots, x_n)$ 带入训练后的预测模型, 从而可得到回归预测的一步预测值 $y = x_n$ 。

SVM 的参数采用交叉验证方案^[10]进行优化选取, 得到预测参数惩罚因子 $C=1.3$, 不敏感损失系数 $\varepsilon=0.0012$, 核函数系数 $\sigma=1.1$, 采用 MRE 作为评定预测精度的评判标准。按照类似的方法逐渐增加预测步数, 分别建立多步预测模型。其中 4 步预测参数选取为 $C=1.3$, $\varepsilon=0.001$, $\sigma=1.0$ 。

为了便于比较, 本文采用了 BP 神经网络的方法对相同的训练样本和预测样本进行学习与预测, 性能衰退指标的 1 步及多步预测结果分别如图 3、4 所示, 预测误差对比见表 1。




图3 性能衰退指标的1步预测结果




图4 性能衰退指标的4步预测结果

综上所述, 无论是短期预测还是中长期预测, SVM 的预测精度都要高于神经网络的; 并且随着预测步长的增加, 数据之间的关联性变差, 不确定度加大, 导致 2 种方法的预测精度降低, 但是 SVM 的预测精度相对于神经网络来说明显降低得比较缓慢, 这说明 SVM 具有较强的容错性和鲁棒性, 能够在提前步数较多(4 步)的情况下, 仍能以较高精度(97.05%)地预测出发动机性能的降低, 说明其对中期预测仍具有较好的效果, 具有较强的推广能力。

3 结束语

(1) 发动机性能衰退指标能综合发动机各部件性能的参数信息, 在一定程度上能反映发动机的性能衰退。

(2) 基于支持向量机回归的预测模型在发动机性能衰退指标预测上要优于神经网络, 更适合预测航空发动机性能趋势。

(3) 在对发动机进行性能衰退评估过程中, 如何制定该指标参数报警门限值, 对于指导发动机工作人员掌握发动机工作状态十分必要, 是下一步的研究重点。

参考文献:

- [1] 廉筱纯, 吴虎. 航空发动机原理[M]. 西安: 西北工业大学出版社, 2001: 101-104.
LIAN Xiaochun, WU hu. Aeroengine theory [M]. Xi'an: Northwestern Polytechnical University Press, 2001: 101-104. (in Chinese)
- [2] 邓乃扬, 田英杰. 支持向量机理论、算法与拓展[M]. 北京: 科学出版社, 2009: 46-47.
DENG Naiyang, TIAN Yingjie. Theory, algorithm and development of support vector machine [M]. Beijing: Science Press, 2009: 46-47. (in Chinese)
- [3] 韩磊, 洪杰, 苗学问. 基于支持向量机和信息融合的整机振动状态监视与诊断[J]. 航空发动机, 2010, 36(4): 32-36.

- HAN Lei, HONG Jie, MIAO Xuewen. The monitoring and diagnosis of aeroengine vibration based on the support vector machine and information fusion [J]. Aeroengine, 2010, 36(4): 32-36. (in Chinese)
- [4] 尹大伟. 某型发动机模型修正研究[D]. 烟台: 海军航空工程学院, 2007.
- YIN Dawei. Research of model correction of X engine [D]. Yantai: Naval Aeronautical Engineering Institute, 2007. (in Chinese)
- [5] 尉询楷, 刘芳, 陈良峰, 等. 航空发动机健康管理用户的诊断预测指标体系[J]. 航空发动机, 2012, 38(5): 27-35.
- WEI Xunkai, LIU Fang, CHENG Liangfeng, et al. Diagnostic and prognostic metrics of aeroengine health management [J]. Aeroengine, 2012, 38(5): 27-35. (in Chinese)
- [6] 王俨凯, 廖明夫. 基于试车数据统计的振动限制值确定方法[J]. 推进技术, 2008, 29(5): 617-621.
- WANG Yankai, LIAO Mingfu. Estimating vibration limit value based on statistics for engine testing data [J]. Journal of Propulsion Technology, 2008, 29(5): 617-621. (in Chinese)
- [7] 司守奎. 数学建模算法与程序 [M]. 北京: 国防工业出版社, 2007: 325-360.
- SI Shoukui. Algorithm and program of mathematical modeling [M]. Beijing: National Defence Industry Press, 2007: 325-360. (in Chinese)
- [8] 胡金海, 谢寿生, 骆广琦, 等. 基于支持向量机方法的发动机性能趋势预测[J]. 推进技术, 2005, 26(3): 260-264.
- HU Jinhai, XIE Shousheng, LUO Guangqi, et al. Study of support vector machines for aeroengine performance trend forecasting [J]. Journal of Propulsion Technology, 2005, 26(3): 260-264. (in Chinese)
- [9] Côme E, Cottrell M, Verleysen M, et al. Aircraft engine health monitoring using self-organizing maps [J]. Proceedings of the Industrial Conference on Data-Mining, 2011: 1-10.
- [10] 何学文. 基于支持向量机的故障智能诊断理论与方法研究[D]. 长沙: 中南大学, 2004.
- HE Xuewen. Research of theory and method of intelligent fault diagnosis based on SVM [D]. Changsha: Central South University, 2004. (in Chinese)