

DOI:10.3969/j.issn.1001-4551.2016.05.024

基于 LS-SVM 的一次风机振动在线监测 及故障预警研究^{*}

韩 平¹, 王天堃¹, 孟永毅²

(1. 神华国能(神东电力)集团, 北京 100033; 2. 山西鲁能河曲发电有限公司, 山西 忻州 036504)

摘要:针对火电厂一次风机运行工况复杂和多状态变量强耦合特性而难以构建设备精确模型问题,将智能数据挖掘方法应用于风机设备故障预警和诊断中。通过对风机典型运行特性进行分析,提出了一种基于最小二乘支持向量机(LS-SVM)的一次风机振动状态估计和故障预警方法。结合山西河曲发电厂1号机组的1#一次风机历史运行数据,应用Matlab对所提出的方法进行了验证和分析。研究表明,该预测方法有较高的估计精度,能够及时辨别一次风机在运行中的振动异常,适用于火电厂辅机设备的故障诊断,具有一定的工程应用价值。

关键词:一次风机;在线监测;最小二乘支持向量机(LS-SVM);故障预警;

中图分类号:TM621.7;TH113.1;

文献标志码:A

文章编号:1001-4551(2016)05-0629-04

Research of LS-SVM based method for online monitoring and fault prediction of primary air fan vibration

HAN Ping¹, WANG Tian-kun¹, MENG Yong-yi²

(1. Shenhua Guoneng Energy Group Co., Ltd, Beijing 100033, China;

2. Shanxi Luneng Hequ Power Generation Co., Ltd, Xinzhou 036504, China)

Abstract: Aiming at the problem of real-time monitoring and fault diagnosis of primary air fan in thermal power plant, a data mining based Least Squares Support Vector Machine (LS-SVM) primary air fan vibration estimation and fault early warning method was proposed due to it difficult to achieve fault diagnosis through the precise mechanism modeling because of the complex, changeable operation and the cross-coupling process variables of the auxiliary equipment. The historical operation data of the 1# primary air fan of unit 1 in Hequ power plant was tested. The results indicate that the method has high estimation accuracy, and can identify the abnormal vibration of the primary air fan in time. The validity of the method is verified.

Key words: primary air fan; online monitoring; Least-Square Support Vector Machines (LS-SVM); fault prediction

0 引 言

一次风机是火力发电厂的重要辅助设备之一,通过提供一定的空气压力和流量的一次风,来保证制粉系统的正常输出。在一般情况下,大型风机的振动较为激烈和较易发出噪音,风机更易出现故障。一旦发

生故障,主机生产线将会关闭,导致严重的经济损失。故障的发生是一个由产生到发展、从轻微到严重的过程。多年来,各种在线监测和故障诊断的部署已被广泛应用在火电厂故障监测方面,以确保发电厂安全稳定运行。火电厂故障检测可以通过多种定量或定性的方法来实现,包括多变量,如基于模型的、基于人工智

收稿日期:2015-09-30

基金项目:企业委托技术研发项目(未提供)

作者简介:韩 平(1966-),男,北京人,主要从事火电厂设备故障诊断方面的研究,Email: young_cnhz@gmail.com

能方法^[1],以及传统单变量,如基于过程变量的阈值报警技术^[2]。

一次风机的运行过程复杂,变量间相互耦合,传统建模方法难以取得理想效果。近年来,已有一些理论上的故障监测的方法提出。多变量状态估计方法被用于设备早期故障征兆的监测^[3],虽然这种方法表现出良好的运行速度,建模的所需要的多工况的历史记忆数据的是大量的,数据来源是与设备相关的所有测点,如果结构的历史记忆矩阵是不完整,估计精度将降低。神经网络也可用于状态预测^[4],但是神经网络基于经验风险最小化准则,会导致过度拟合,泛化能力弱,可能导致故障预警性能变弱。

多年来,支持向量机(SVM)在非线性回归估计和时间序列预测中,已经成为一种有效的工具^[5-6]。SVM 采用统计学习理论中的标准化风险最小化的原则,最小二乘支持向量机(LS-SVM)在保留 SVM 标准风险最小化、小样本和其它特征的基础上,将风险函数转换为最小二乘函数,不等式约束转化为等式约束,把二次优化转化为一个线性方程组问题,大大减少算法的计算复杂度^[7]。

本研究中,LS-SVM 利用设备的正常运行数据,通过分析一次风机运行过程中状态变量之间相关性,建立非线性估计模型,通过正常运行状态下数据的训练,与振动相关的一次风机的状态变量可以用来估计振动大小。

1 最小二乘支持向量机原理

最小二乘支持向量机的基本原理可以描述如下。给定一组训练样本:

$$\{(x_i, y_i) \mid i = 1, 2, \dots, N\} \quad (1)$$

式中: $x_i \in R^n$ —输入向量; $y_i \in R$ —输出,输入向量通过非线性映射 $\varphi(\cdot)$ 从原来的空间映射到一个高维(k 维, $k > n$) 特征空间,在这个空间中的样本输入,在这个空间中构造如下最优线性回归函数:

$$f(x) = \omega \varphi(x) + b \quad (2)$$

式中: ω —权系数向量, $b \in R^n$ —常数。支持向量机原理图如图 1 所示。




图 1 支持向量机原理图

基于结构风险最小化准则,在最小二乘支持向量机的回归模型可以转化为:

最小化:

$$\frac{1}{2} \omega^2 + \gamma \sum_{i=1}^N \xi_i^2 \quad (3)$$

约束为:

$$y_i = \omega^T \varphi(x_i) + b + e_i \quad (4)$$

式中: $\gamma (\gamma > 0)$ —惩罚因子, e_i —回归值与实际值之间的误差。

$$\begin{cases} \omega = \sum_{i=1}^N \alpha_i \varphi(x_i) \\ \sum_{i=1}^N \alpha_i = 0 \\ \alpha_i = \gamma e_i \\ \omega \varphi(x_i) + b + e_i - y_i = 0 \end{cases} \quad (5)$$

通过构造拉格朗日函数,根据 KKT(Karush-Kuhn-Tucker) 条件,一组方程可以得出如下公式(5)。

通过消除 e_i 和 γ ,基于方程组(5),可以得到以下方程:

$$\begin{bmatrix} 0 & 1^T \\ 1 & \Omega + \gamma^{-1} I \end{bmatrix} \begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix} \quad (6)$$

式中: $y = [y_1, y_2, \dots, y_N]$, $I = [1, 1, \dots, 1]$, $\alpha = [\alpha_1, \alpha_2, \dots, \alpha_N]$, I —单位阵。

$$\Omega_{ij} = K(x_i, x_j) = \varphi(x_i) \varphi(x_j) \quad (7)$$

式中: $i, j = 1, 2, \dots, N$, $K(x_i, x_j)$ —核函数。

解 α 和 b , 最终最小二乘支持向量机的结果可表示为:

$$f(x) = \sum_{i=1}^N \alpha_i K(x_i, x) + b \quad (8)$$

核函数参数的多少反映了模型的复杂程度,从这个方面,径向基核函数(RBF) 优于多项式函数和 Sigmoid 函数,又由于径向基核函数(RBF) 的普适性,本研究采用支持向量机应用最广泛的径向基核函数中的高斯核函数^[8]:

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (9)$$

2 LS-SVM 模型估计一次风机振动

2.1 一次风机振动实时建模测点选取

本研究中根据所提出的基于振动检测信号 LS-SVM 估计的火电一次风机早期故障诊断与预警方法的数据来源于山西河曲发电有限公司的在线监测系统数据库,利用采集的实时/历史数据,用

LS-SVM 建模方法分别对 1 号机组的 1# 一次风机进行了设备建模,并进行实验验证。

根据 PI 系统监控画面,本研究共收集了一次风机挡板开度、出口压力、电动机的润滑油压力、一次风机轴承温度等 20 个相关测点。在本研究中,#1 一次风机轴承自由端的振动速度进行预测。首先对同一个测量点的多个温度变量进行降维,剔除冗余变量。然后选择与振动速率密切相关的变量作为 LS-SVM 模型的输入来估计一次风机轴承自由端的振动大小。本研究采用相关度分析来选择相关变量。统计学中常用相关系数 r 来衡量两个变量之间的线性相关的强弱,当 x_i 不全为零, y_i 也不全为零时,则两个变量的相关系数的计算公式如下:

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} = \frac{\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y}}{\sqrt{(\sum_{i=1}^n x_i^2 - n \bar{x}^2)(\sum_{i=1}^n y_i^2 - n \bar{y}^2)}} \quad (10)$$

通过计算,与一次风机振动有关的状态变量与其相关性排名如表 1 所示。

表 1 状态变量相关性系数

序号	参数描述	相关系数
1	润滑油压力	0.876 5
2	轴承温度	0.657 2
3	挡板开度	0.654 6
4	出口压力	0.493 3
5	一次风机电流	0.259 3

如表 1 所示,本研究选择润滑油压力,自由端轴承温度,挡板开度,出口压力作为支持向量机模型的输入。

2.2 实例分析

2.2.1 样本数据选取与预处理

本研究从 PI 数据库中读取了一次风机从 2015 年 3 月 23 日 ~ 2015 年 4 月 12 日 20 天的运行数据作为 LS-SVM 模型的训练数据集,其中输入包括润滑油压力、挡板开度、轴承温度、出口压力,输出为振动速度。首先应对数据进行处理。由于不同测点每天的数据量是不同的,首先应对数据进行处理,以一定的时间为步长,进行数据插值,从而得到相同时间、相同数据量的数据。其次,由于电厂中设备模型相关测点的量纲不同,且不同测点数据绝对值相差很大,为保证使用非线性算子正确衡量不同输入向量之间的距离,需要对各

个测点的测量值根据各自的极值进行归一化处理,使实际测量值映射到[0 1] 区间。

2.2.2 性能指标

本研究采用平均绝对百分比误差 e_{MAPE} 和均方根误差

e_{RMSE} 两种评价指标对模型进行评估,其计算式如下:

$$e_{MAPE} = \frac{1}{N} \sum_{i=1}^N \left| \frac{V_i - V_{pi}}{V_i} \right| \times 100 \quad (11)$$

$$e_{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (V_i - V_{pi})^2} \quad (12)$$

式中: V_i — 实际振动值大小, V_{pi} — 预测振动值, N — 样本个数。

2.2.3 实验及结果分析

为了验证 LS-SVM 模型一次风机在线振动估计和故障预测的性能,本研究通过在 Matlab 平台上的仿真实验对所提的方法进行评估,使用神经网络估计方法作为比较基准。

LS-SVM、BP 算法对# 1 一次风机振动速度的估计结果如图 2、图 3 所示。




图 2 LS-SVM 模型振动估计结果




图 3 BP 振动估计结果

数据源于 4 月 13 日 1#一次风机的运行数据,每 10 分钟采样一次。可以看出,相比于 BP 算法,均方根误差减小了 9.75%,LS-SVM 模型估计残差更小,表明基于 LS-SVM 的建模方法能够准确估计一次风机的振

功率。

表 2 不同算法的误差比较

平均绝对百分比误差		均方根误差/(%)	
LS-SVM	BP	LS-SVM	BP
0.070 9	0.112 2	11.67	21.42




图 4 一次风机振动异常残差曲线

当风机振动异常时,振动强度随时间不断增加而,估计残差也会不断增大,一次风机振动异常差曲线如图 4 所示。这时,现场监控人员应注意残差曲线的变化趋势,如果残差继续增大,应通知维修人员确认一次风机的是否运行正常,及时采取相应的保护和维修措施。

3 结束语

为了满足大型机组的安全经济运行,本研究提出一种基于 LS-SVM 的一次风机振动在线估计和监测方法。笔者通过现场设备实时采集的数据,基于线性关联分析寻找与一次风机振动相关的变量集,采用 LS-SVM 实现对设备的实时动态建模,能够发现异常实现故障早期预警。通过河曲发电厂的数据仿真,验证了本研究一次风机状态监测方法的准确性和有效性。

在未来工作中,本研究中所提出的方法将继续结合在火电厂一次风机应用过程中所获取的数据进行深度分析和挖掘,并将该方法应用于火电厂其他重要辅

机设备的运行状态分析和故障辨识。同时,将对早期故障的特征状态进行精确提取,并针对故障程度和类型的辨识进行针对性的研究。

参考文献(References):

[1] SHAH M. D. Fault Detection and Diagnosis in Nuclear Power Plant-A Brief Introduction [C]//International Conference On Engineering: Ahmedabad, Gujarat: IEEE, 2011:1-5.

[2] P GOU, D INFIELD, X YANG. Wind turbine generator condition monitoring using temperature trend analysis[J]. **IEEE Transactions on Sustainable Energy**,2012,3(1): 124 - 133.

[3] 常澍平,郭江龙,吕玉坤,等. 非线性状态估计(NSET)建模方法在故障预警系统中的应用[J]. 软件,2011,32(7):57-60.

[4] YANG. T. S, CHEN. B, ZHANG. H. L, et al. State Trend Prediction of Spacecraft Based on BP Neural Network [C]//International Conference on Measurement, Information and Control, Harbin: IEEE,2013:809-812.

[5] MAO H Y, AN S L, ZHU Y C, et al. Prediction for ATE State Parameters Based on Improved LS-SVM [C]// The 11th IEEE International Conference on Electronic Measurement & Instrument, Harbin: IEEE,2013:692-695.

[6] ADANKON. M. M, MOHAMED. C, ALAIN. B. Semi-supervised Learning Using Bayesian Interpretation: Application to LS-SVM[J]. **IEEE Transactions on Neural Networks**,2011. 22(4):593-524.

[7] ZHAO W Q, ZHANG J J, LI K. An Efficient LS-SVM-Based Method for Fuzzy System Construction[J]. **IEEE Transacthehs. on Fuzzy Systems**,2014,23(3):627-643.

[8] SCHöLKOPF, BERNHARD, AJSMOLA. Learning with Kernels[M]. Cambridge: MIT Press,2002:2165-2176.

[编辑:周昱晨]

本文引用格式:

韩 平,王天堃,孟永毅. 基于 LS-SVM 的一次风机振动在线监测及故障预警研究[J]. 机电工程,2016,33(5):629 - 632.

HAN Ping, WANG Tian-kun, MENG Yong-yi, et al. Research of LS-SVM based method for online monitoring and fault prediction of primary air fan vibration [J]. *Journal of Mechanical & Electrical Engineering*, 2016,33(5):629 - 632.

《机电工程》杂志: <http://www.meem.com.cn>