

基于支持向量回归的多参数设备故障预测方法*

武兵¹, 林健², 熊晓燕¹

(1. 太原理工大学机械电子工程研究所 太原, 030024) (2. 太原理工大学信息化管理与建设中心 太原, 030024)

摘要 针对热连轧生产线的大型、复杂生产装备, 构建了一个基于支持向量回归的无量纲参数智能故障预测系统。通过对已有的热连轧生产线在线监测信息进行无量纲统计分析, 提出了利用支持向量回归技术对多个特征量进行并行预测, 并对各类特征及其各预测步骤的剩余使用寿命预测结果进行趋势分析, 通过置信区间估计确定最终预测结果, 为管理者制定维修决策提供可靠依据。

关键词 剩余使用寿命; 支持向量回归; 无量纲统计量; 故障预测

中图分类号 TH165. 3

引言

为了保证复杂机电系统的正常运行, 大多数企业的维护措施仍然以定期检查和预防性维修为主。传统的计划性维修不仅耗费大量的人力、物力与财力, 且为了避免意外故障停机和提前准备昂贵的备品备件, 存在不同程度的过度维修。基于故障预测的视情维修(condition based maintenance, 简称CBM)技术和方法在设备可靠性、可用性、可维护性和安全性方面表现出明显的优势, 可显著降低生产的停工、备件库存、维修成本和安全风险等, 成为研究和应用的热点。

故障预测的目标是在设备生命周期内显示监测对象的结构、系统或部件的性能, 提供合理的保障, 估计其剩余使用寿命(remaining useful life, 简称RUL)^[1]。故障预测方法大致可分为基于模型和基于数据驱动两类^[2]。实际应用中, 基于物理模型的方法存在性价比不高、很难适应状态变化等缺点, 只要有足够的数据用以构建损伤映射空间, 基于数据驱动的技术更易于实现故障预测。大多数基于数据驱动的RUL估计技术都是通过曲线拟合的方法指示失效期, 可用的历史数据有时会很短或不完整, 推理产生很大误差。目前, 大多数智能预测方法都是基于神经网络的, 尽管神经网络模型的能力很强, 但也存在网络结构难以确定、需大量样本、易陷入局部极小和泛化能力差等缺点。支持向量机(support vec-

tor machine, 简称SVM)是建立在统计学习理论的VC(Vapnik-Chervonenkis)维理论和结构风险最小化原则基础上的一种新算法^[3], 具有结构简单、学习速度快、全局最优、泛化性好等优点, 能较好地解决小样本、非线性、高维数和局部极小等问题, 被认为是替代神经网络的较好方法。支持向量回归(support vector regression, 简称SVR)就是基于SVM做回归分析, 具有SVM的基本特性。

笔者针对热连轧生产线的生产过程, 构建一个智能故障预测系统。目前, 利用支持向量机的预测大都为基于单输入特征量计算, 笔者通过对已有的热连轧生产线在线监测信息进行统计分析, 提出了利用支持向量回归技术对多个特征量进行并行预测, 并综合各类特征及其各步的剩余使用寿命预测结果, 通过置信区间估计确定最终预测结果。提出利用无量纲的统计量作为预测算法的特征量, 介绍了在线支持向量回归算法的原理。描述了基于在线支持向量回归的故障预测流程, 包括特征数据提取和归一化处理, 以及基于支持向量回归的智能预测模型。利用长期记录的在线监测数据对提出的模型进行验证, 结果表明该方法具有较高的预测精度, 能够满足实际的预测需求。

1 统计特征量确定和支持向量回归算法

1.1 统计特征量确定

设备或零部件损伤与故障扩展动力学是一个随

* 国家自然科学基金资助项目(编号:50975188); 山西省自然科学基金资助项目(编号:2012011046-10)

收稿日期:2012-06-01; 修改稿收到日期:2012-09-03

机过程,过程的随机性由损伤扩展的随机特性导致,并可能通过测量过程引入随机成分。因此,损伤扩展过程是一个随机动态过程。热连轧生产过程设备随着工况的变化所引起的状态变化很难用精确的模型表示。在实测信号中不仅混有高斯白噪声,而且还有未知频谱结构的高斯有色噪声,对这类信号采用单一的特征提取方法很难有效。对于预测估计而言,特征信息中的趋势信息比精确区分类别的能力更重要。

基于时域信号的高阶统计量能够从不同方面反映信号的性质和特征,同时也反映故障的不同分类。利用时域参数不能精确诊断故障所在,但它能够及时判断有无故障出现以及故障程度如何。另一方面,高阶统计量可以有效抑制高斯噪声,增大信号的信噪比,并可定量描述随机信号偏离正态分布的程度,信号的高阶累积量或高阶矩的值越大,其偏离正态分布的程度就越严重。在许多机器中振动信号偏离正态分布的程度就反映了故障程度。计算一阶、二阶、三阶、四阶甚至更高阶的矩,可以提取有效的故障信息^[4]。因此,使用统计特征量进行设备剩余使用寿命估计具有较好的适应性。

文献[5]指出,无量纲幅值域诊断参数对故障足够敏感,而对信号的幅值和频率变化不敏感,和机器的工作条件关系不大。无量纲指标具有如下特性:
a. 无量纲指标不受振动信号绝对水平的影响,与振动检测器、放大器的灵敏度和整个测试系统的放大倍数无关,系统无需进行标定,且传感器或放大器的灵敏度即使变动,也不会出现测量误差;
b. 各种无量纲指标对不同故障敏感程度不同;
c. 工况、载荷和转速对无量纲指标基本无影响。

笔者利用无量纲的各阶统计量如波形指标、脉冲指标、峰值指标、偏度指标和峭度指标等作为故障预测的特征参数。

波形指标为

$$W_f = \frac{\left[\int_{-\infty}^{+\infty} |x|^2 p(x) dx \right]^{1/2}}{\left[\int_{-\infty}^{+\infty} |x| p(x) dx \right]} = \frac{X_{\text{rms}}}{|\bar{X}|} \quad (1)$$

脉冲指标为

$$I_f = \frac{\lim_{t \rightarrow \infty} \left[\int_{-\infty}^{+\infty} |x|^t p(x) dx \right]^{1/t}}{\left[\int_{-\infty}^{+\infty} |x| p(x) dx \right]} = \frac{X_{\text{max}}}{|\bar{X}|} \quad (2)$$

峰值指标为

$$C_f = \frac{\lim_{t \rightarrow \infty} \left[\int_{-\infty}^{+\infty} |x|^t p(x) dx \right]^{1/t}}{\left[\int_{-\infty}^{+\infty} |x|^2 p(x) dx \right]^{1/2}} = \frac{X_{\text{max}}}{X_{\text{rms}}} \quad (3)$$

偏度指标为

$$S_f = \frac{\int_{-\infty}^{+\infty} [x - \bar{x}]^3 p(x) dx}{\sigma^3} \quad (4)$$

峭度指标为

$$K_f = \frac{\int_{-\infty}^{+\infty} [x - \bar{x}]^4 p(x) dx}{\sigma^4} \quad (5)$$

其中: x 为信号幅值; $p(x)$ 为 x 的概率密度函数; X_{max} 为最大值; X_{rms} 为均方根值; $|\bar{X}|$ 为均值; σ 为标准差。

1.2 支持向量回归

支持向量回归分析^[6]的基本思想是通过一种非线性映射 ϕ ,将输入空间的数据 X 映射到高维特征空间 G 中,并在这个空间进行线性回归。给定 k 个数据样本 $\{x_i, y_i\}, i=1, 2, \dots, k, (x_i \in R^n, y_i \in R), y_i$ 为期望值。SVM通过引入不敏感系数 ϵ 来简化回归问题,该算法称为 ϵ -SVR,作为SVR的标准算法,其目标是对样本数据进行估计,函数 $f(x)$ 的输出即为带有误差限为 ϵ 的预测输出 y 。估计函数为

$$y = f(x) = (\omega, \phi(x)) + b \quad (6)$$

$(\phi: R^n \rightarrow G, \omega \in G)$

其中: b 为偏置量。

在优化估计函数时对优化目标取极值

$$\min J = \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^k (\xi_i^* + \xi_i)$$

使得

$$\begin{cases} y_i - (\omega, \phi(x)) - b \leq \epsilon + \xi_i \\ (\omega, \phi(x)) + b - y_i \leq \epsilon + \xi_i^* \\ \xi_i^*, \xi_i \geq 0 \end{cases} \quad (7)$$

其中: C 为惩罚系数,用以实现经验风险和置信风险的折中, C 越大,对数据的拟合能力越高; ξ_i^* 和 ξ_i 为松弛因子,用来控制线性不可分边界。

通过拉格朗日乘数法转换为计算以下最大化函数

$$\begin{aligned} W(\alpha, \alpha^*) = & -\frac{1}{2} \sum_{i,j=1}^k (\beta_i - \beta_i^*)(\beta_j - \beta_j^*) k(x_i, x_j) + \\ & \sum_{i=1}^k (\beta_i + \beta_i^*) y_i - \sum_{i=1}^k (\beta_i + \beta_i^*) \epsilon \end{aligned} \quad (8)$$

约束条件为

$$\begin{cases} \omega = \sum_{i=1}^k (\beta_i - \beta_i^*) x_i \\ 0 \leq \beta_i, \beta_i^* \leq C \\ \sum_{i=1}^k (\beta_i - \beta_i^*) = 0 \end{cases}$$

其中: $\beta_i, \beta_i^* \geq 0; i=1, 2, \dots, k$ 为拉格朗日乘子。

回归函数可表示为

$$f(x) = \sum_{i=1}^k (\beta_i + \beta_i^*) k(x_i, x_j) + b \quad (9)$$

其中: b 为偏置项, 可以根据库恩-塔克(KKT)条件计算得到; $k(x_i, x_j) = (\phi(x_i), \phi(x_j))$ 为核函数。

根据文献[5]可知, 常用的核函数预测精度在同一数量级, 其中, 径向基核函数的预测精度最高, 因此本研究选用径向基核函数

$$k(x, y) = \exp(-\|x - y\|^2 / \sigma^2) \quad (10)$$

在模型参数 ϵ, C, σ 的选择上, 不敏感系数 ϵ 控制模型拟合的精度。 ϵ 越大, 拟合精度越低, 支持向量数较少, 模型的复杂程度较低, 其泛化能力较强。惩罚系数 C 表示对误差的惩罚, C 越大, 对拟合精度要求越高, 训练误差和校验误差都将减少, 但也使训练变得困难、费时。当 C 增至一定程度后, 拟合误差渐趋稳定, 当 C 过大时会出现过拟合现象, 此时预测误差反而会增大, 因此要合理的选择 C 以免影响预测性能。当宽度系数 σ 较小时, 径向基函数的拟合性能较好, 但过小会造成泛化能力变差。在 SVM 中当 σ 较小时, 惩罚系数 C 可取小些, 即所需的惩罚力度减少。基于以上分析, 模型参数的选择要兼顾三者的影响, 合理选取^[7]。

2 基于SVR的多参数剩余使用寿命估计

2.1 数据获取

本研究中的数据来源于某热连轧机状态监测系统中记录的真实历史数据。该系统针对轧钢机机械设备的结构和运行特点, 以齿轮传动和电动机等易发生故障的关键设备为主要监测对象, 建立了由传感器、智能数采箱、状态数据服务器、工程师站、监测分析、故障诊断软件和光纤网络等组成的网络化实时监测诊断系统, 其主要功能包括数据采集和存储、振动监测、信号分析和故障诊断专家系统等。

图1为采集的某台精轧机的驱动电机轴承部位的时域信号。在有故障情况下每次轧机咬钢时均会产生明显的脉冲冲击, 且随故障发展幅度会增大。

图2为各个时段的脉冲指标、峰值指标、波形指标、偏度指标和峭度指标等统计量的对比情况。可以看出, 各类统计量均能够不同程度反映故障发生及其发展趋势。作为维修前后的对比, 从第32个时刻开始为更换轴承后的相应统计量, 各项指标均产生大幅回落。




图1 精轧机驱动电机轴承的振动时域波形对比




图2 各类统计特征量变化趋势

2.2 轧机驱动系统部件的剩余使用寿命估计

利用多样本在线支持向量回归算法进行剩余使用寿命估计的流程如图3所示。作为热连轧机状态监测系统的组成部分,可以实时获取相关测点的监测数据进行各类统计量计算,形成一组与时间对应的特征向量序列作为支持向量回归的输入进行学习训练。另外,需要根据历史事件数据信息辅助确定支持向量回归的训练向量集,并结合事件相关历史数据确定相应特征量的阈值。在剩余使用寿命估计时,首先,对各类特征量进行回归估计,得到估计特征量达到相应阈值的时间,按照等间隔特征计算原则,每得到一个新的特征量就会产生一个新的估计值,由此形成一组时间估计数组;然后,对各个特征量的估计结果进行综合,最终的预测结果不但包括相应的无偏估计,而且包括该无偏估计的标准偏差,以便确定预测值的上、下限。

假设回归预测值 y_n 的置信度为 $1 - \alpha$, ($0 < \alpha < 1$), 则其置信区间可表示为

$$\left[\bar{y}_n - \frac{S}{\sqrt{n}} t_{\frac{\alpha}{2}}(n-1), \bar{y}_n + \frac{S}{\sqrt{n}} t_{\frac{\alpha}{2}}(n-1) \right] \quad (8)$$

其中: \bar{y}_n, S 分别为预测样本均值和样本方差。

对于置信度 $1 \sim \alpha$ 不同的取值,可以得到不同的置信区间。

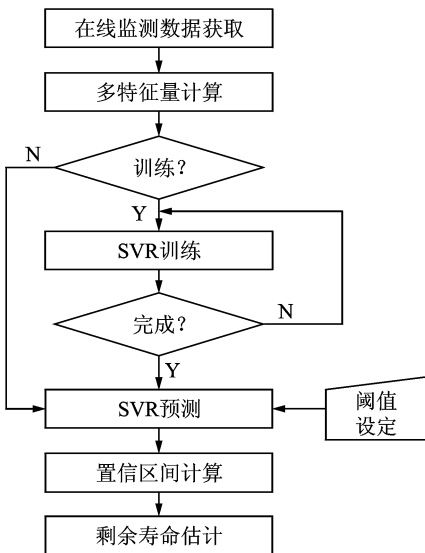


图3 支持向量回归的多参数剩余使用寿命估计流程

3 热连轧设备故障监测数据验证

选取热连轧机状态监测系统某精轧机驱动电机轴承的振动加速度信号作为验证数据,信号包含了从正常运行到故障严重并进行更换维修的全过程信息。分别对等间隔的(这里取每天相同工况数据)脉冲指标、峰值指标、波形指标、偏度指标和峭度指标等统计量进行支持向量回归的迭代计算,将每次计算的预测值作为下一次迭代的输入量,当预测值达到设定的阈值时,通过迭代次数计算预测时间。表1为前15个特征量作为训练值的预测结果。当预测步骤大于15时终止计算。表1中的 $P+1, P+5, P+10$ 分别表示有1,5,10个新增实测量输入时的时间预测值,表示从前15个训练值之后计算的预测时间。

表1 回归计算的阈值与预测时间

| 时间 | 特征量 | | | | |
|----------|------|------|------|------|------|
| | 脉冲指标 | 峰值指标 | 波形指标 | 偏度指标 | 峭度指标 |
| 阈值 | 18 | 0.12 | 150 | 0.5 | 26 |
| $P+1/d$ | >15 | >15 | >15 | >15 | >15 |
| $P+5/d$ | >15 | 14 | >15 | 15 | >15 |
| $P+10/d$ | 12 | 10 | 14 | 9 | 13 |

图4为不同参数、不同步骤下的预测时间频度,这里未显示预测值>15的计数值。根据每个特征量的各步预测时间,按式(8)进行置信区间估计,令 $\alpha = 0.01$, 则置信度 $1 - \alpha = 0.99$ 时的置信区间为 [26.525, 27.781]。在随后的第30天大修拆解时发现,该轴承的内圈裂纹故障已相当严重并进行了更换维修,如图5所示。




图4 预测时间频度分布




图5 轴承内圈裂纹故障

4 结束语

针对热连轧生产线的生产过程,构建一个智能故障预测系统。通过对已有的热连轧生产线在线监测信息进行统计分析,提出利用支持向量回归技术对多个特征量进行并行预测,并将各类特征及其各自的剩余使用寿命预测结果进行综合,通过置信区间估计确定最终预测结果。计算结果表明,剩余使用寿命估计结果与实际维修时的状况相吻合,能够为管理者制定维修决策提供可靠依据。

需要进一步研究的内容包括:获取更多类型和实际故障数据对此方法加以验证;优化特征量的类型;将频域分析和时频分析中包含趋势变化、具有泛化能力的相关特征计算方法引入本系统。

参 考 文 献

- [1] Jardine A K S, Lin D, Banjevic D. A review on machinery diagnostics and prognostics implementing condition based maintenance[J]. *Mechanical Systems and Signal Process*, 2006, 20:1483-1510.
- [2] Aiwin H, Sheng Z, Andy C C, et al. Rotating machinery prognostics: state of the art, challenges and opportunities[J]. *Mechanical Systems and Signal Processing*, 2009, 23:724-739.

- [3] Cortes C, Vapnik V. Support vector networks [J]. *Machine Learning*, 1995, 20(1): 273-297.
- [4] 李智,陈祥初,刘政波. 包络分析及其在设备故障诊断中的应用[J]. *测试技术学报*, 2002, 16(2):92-95.
Li Zhi, Chen Xiangchu, Liu Zhengbo. Envelopment analysis and its application in the fault diagnosis [J]. *Journal of Test and Measurement Technology*, 2002, 16(2):92-95. (in Chinese)
- [5] 张清华,邵龙秋,李红芳,等. 基于无量纲指标的旋转机械并发故障诊断技术[J]. *华中科技大学学报:自然科学版*, 2009, 37: 156-159.
Zhang Qinghua, Shao Longqiu, Li Hongfang, et al. Research of concurrent faults diagnosis technology of rotating machinery based on the non-dimensional parameter [J]. *Journal of Huazhong University of Science & Technology: Natural Science Edition*, 2009, 37: 156-159. (in Chinese)
- [6] 宋梅村,蔡琦. 基于支持向量回归的设备故障趋势预测[J]. *原子能科学技术*, 2011, 45(8): 972-976.
Song Meicun, Cai Qi. Fault trend prediction of device based on support vector regression [J]. *Atomic Energy Science and Technology*, 2011, 45(8): 972-976. (in Chinese)
- [7] 王晶,靳其兵,曹柳林. 面向多输入输出系统的支持向量机回归[J]. *清华大学学报:自然科学版*, 2007, 47(S2):1737-1741.
Wang Jing, Jin Qibing, Cao Liulin. Support vector regression algorithm for multi-input multi-output systems [J]. *Journal of Tsinghua University: Science & Technology*, 2007, 47(S2): 1737-1741. (in Chinese)



第一作者简介:武兵,男,1968年7月生,博士,讲师。主要研究方向为机电系统故障诊断、动态测试。曾发表《三产品重介旋流器堵塞故障诊断与监测方法》《*煤炭学报*》2008年第33卷第2期)等论文。
E-mail:wubing@tyut.edu.cn