

4-16-2019

Modeling and Simulation of Health Degradation Trend for Wind Turbine Bearing

Xinghui Dong

1. School of Energy Power and Mechanical Engineering, North China Electric Power University, Beijing 102206, China; ;

Xiaoshuang Ma

1. School of Energy Power and Mechanical Engineering, North China Electric Power University, Beijing 102206, China; ;

Youxing Cheng

1. School of Energy Power and Mechanical Engineering, North China Electric Power University, Beijing 102206, China; ;

Wang Shuai

2. School of Electric Engineering, Henan Polytechnic University, Jiaozuo 454000, China;

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Modeling and Simulation of Health Degradation Trend for Wind Turbine Bearing

Abstract

Abstract: By taking a wind turbine bearing as research object, *the model of bearing temperature health's degradation trend is established through using least squares surface fitting and the monitored parameters from Supervisory Control And Data Acquisition (SCADA). Bearings' degradation trend with unsteady characteristics is decomposed by modified Ensemble Empirical Mode Decomposition(EEMD) to obtain several relatively steady components.* Components are predicted respectively by time series neural network and the predicted results of all the components are added to obtain final prediction result. Comprehensive simulations and comparisons show that the proposed method can predict the health degradation trend of wind turbine bearings with higher accuracy.

Keywords

wind turbine bearing, degradation trend prediction, least squares surface, EEMD, time series neural network

Recommended Citation

Dong Xinghui, Ma Xiaoshuang, Cheng Youxing, Wang Shuai. Modeling and Simulation of Health Degradation Trend for Wind Turbine Bearing[J]. Journal of System Simulation, 2019, 31(1): 151-158.

风电机组轴承健康劣化趋势建模与仿真

董兴辉¹, 马晓双¹, 程友星¹, 王帅²

(1. 华北电力大学能源动力与机械工程学院, 北京 102206; 2. 河南理工大学电气学院, 河南 焦作 454000)

摘要: 以风电机组轴承为研究对象, 利用 SCADA(Supervisory Control And Data Acquisition)监测参数, 应用最小二乘曲面拟合算法, 建立轴承温度健康状态劣化趋势模型。改进并应用 EEMD (Ensemble Empirical Mode Decomposition)方法, 分解具有非平稳性特性的轴承劣化趋势为一系列相对平稳的分量, 利用时间序列神经网络分别对各分量单独预测, 叠加所有分量的预测值作为最终的预测结果。经过仿真测试, 该方法能够以更高的精度预测风电机组轴承健康状态劣化趋势。

关键词: 风电机组轴承; 劣化趋势预测; 最小二乘法曲面; EEMD 方法; 时间序列神经网络

中图分类号: TM 315; TP202+.1 文献标识码: A 文章编号: 1004-731X (2019) 01-0151-08
DOI: 10.16182/j.issn1004731x.joss.17-0067

Modeling and Simulation of Health Degradation Trend for Wind Turbine Bearing

Dong Xinghui¹, Ma Xiaoshuang¹, Cheng Youxing¹, Wang Shuai²

(1. School of Energy Power and Mechanical Engineering, North China Electric Power University, Beijing 102206, China;
2. School of Electric Engineering, Henan Polytechnic University, Jiaozuo 454000, China)

Abstract: By taking a wind turbine bearing as research object, the model of bearing temperature health's degradation trend is established through using least squares surface fitting and the monitored parameters from Supervisory Control And Data Acquisition (SCADA). Bearings' degradation trend with unsteady characteristics is decomposed by modified Ensemble Empirical Mode Decomposition(EEMD) to obtain several relatively steady components. Components are predicted respectively by time series neural network and the predicted results of all the components are added to obtain final prediction result. Comprehensive simulations and comparisons show that the proposed method can predict the health degradation trend of wind turbine bearings with higher accuracy.

Keywords: wind turbine bearing; degradation trend prediction; least squares surface; EEMD; time series neural network

引言

风电机组运行环境恶劣, 受气象等多种不确定因素的影响, 容易出现性能与状态劣化, 频繁出现故障。关键部件一旦失效, 检修时间较长, 影响发

电量, 增加风电场的运维成本^[1-3]。风机轴承作为风电机组关键部件, 在机组机械故障中占有很高的比例, 发电机、齿轮箱的机械故障中约 80%是由轴承失效所导致^[4]。实时正确评估风电机组轴承的劣化程度和较早预测劣化趋势, 在可预知情况下合理安排检修, 有助于提高整机的可靠性和利用率。

近年来, 围绕风电机组轴承健康状态研究主要集中在健康劣化程度分析及故障预警上。针对风电机组轴承故障振动信号的非平稳特性, 应用集成经验模态分解与峭度-相关系数准则的多特征量, 对



收稿日期: 2017-01-18 修回日期: 2017-08-21;
基金项目: 国家重点研发计划(2017YFE0109000);
作者简介: 董兴辉(1962-), 男, 河南沁阳, 博士, 教授, 研究方向为风电机组状态评估、故障识别等; 马晓双(1990-), 女, 山东蒙阴, 硕士, 研究方向为风电机组状态评估、故障识别。

<http://www.china-simulation.com>

轴承故障劣化程度进行了分类和识别^[5], 将最大相关峭度解卷积与经验模态分解相结合, 通过分析振动信号频率成分判断故障类型^[6], 以振动偏差为参变量, 开发了基于健康样本的风电机组轴承状态评估与异常检测系统^[7]; 实现轴承早期故障劣化程度的判断。考虑振动信号易受到各种不确定噪声干扰, 较难准确捕捉轴承早期的劣化征兆, 又提出基于温度特征量的风电机组关键部件劣化渐变概率分析方法^[1,8], 采用动态阈值确定风电机组轴承劣化度, 应用非线性状态估计方法建立了风电机组轴承温度模型^[9], 监测轴承运行状态, 及时发现轴承早期故障, 但未发现继续对劣化发展趋势开展预测研究。

研究表明, 受不同工况之间的频繁切换影响, 风电机组轴承健康劣化趋势具有明显的非平稳性的特性。采用适用于处理非平稳、非线性信号的经验模式分解(EMD), 有时出现局部不平稳和不连贯现象, 得不到理想的分解结果^[10]; EEMD^[11]利用高斯白噪声具有频率均匀分布的统计特性, 使信号在不同尺度上具有连续性, 避免了模态混叠现象。非线性有源自回归神经网络(NARX)非常适合预测具有较复杂的时间序列问题^[12], 本文选用 EEMD 与 NARX 相结合的组合模型, 预测风电机组轴承劣化发展趋势问题。

1 轴承健康劣化模型

1.1 轴承劣化度

选用轴承温度参数作为风电机组健康状态评价指标, 应用相对劣化度 $d(t)$ 表征风电机组轴承当前相对劣化程度。

$$d(t) = \begin{cases} 1 & T(t) \geq T_{\max} \\ \frac{T(t) - \hat{T}(t)}{T_{\max} - \hat{T}(t)} & T(t) - \hat{T}(t) > 0 \\ 0 & T(t) = \hat{T}(t) \\ \frac{T(t) - \hat{T}(t)}{T_{\min} - \hat{T}(t)} & T(t) - \hat{T}(t) < 0 \\ 1 & T(t) \leq T_{\min} \end{cases} \quad (1)$$

式中: $d(t) \in [0, 1]$, 0 代表最佳状态; 1 代表最差状态; T_{\max} 和 T_{\min} 分别为劣化度上限、下限阈值; $\hat{T}(t)$ 为轴承温度期望值; $T(t)$ 为轴承温度实测值; t 为风机轴承运行时刻。

1.2 轴承健康状态模型

1) 样本数据

风电场 SCADA 数据中, 与风电机组轴承温度相关联的主要参数有环境温度、发电机转速、风速和功率^[8]。通过对本文数据的相关性分析, 见表 1, 风速、功率与轴温的属于强相关。从 SCADA 系统中, 提取 N 组同一时刻的轴承温度、风速和有功功率三维健康历史数据, 构建样本集 $\{(V_i, P_i, T_i)\}$, $i = 1, 2, \dots, N$, V_i 表示风速, P_i 表示有功功率, T_i 表示轴承温度。

表 1 各参数与轴承温度的相关系数

Tab. 1 Correlation coefficient of each parameter and bearing temperature				
变量	风速	功率	发电机转速	环境温度
相关系数	0.557	0.553	0.453	0.136
相关程度	强	强	中	弱

2) 曲面拟合

采用二次曲面方程 $T = \sum_{j=0}^2 \left(\sum_{i=j}^2 c_{j,i-j} V^j P^{i-j} \right)$ 拟

合样本数据, 应用最小二乘法^[13]求出方程中的 $c_{00}, c_{01}, c_{02}, c_{10}, c_{11}, c_{20}$ 系数, 得到轴承运行的期望状态温度 $\hat{T}(t)$ 。

3) 工况划分

不同风速下, 风机轴承存在区间状态(温度)特性。按照 0.5 m/s 的 Bin 方法对风速划分, 得到不同工况下的、以 \hat{T}_{\max} , \hat{T}_{\min} 为阈值的轴承健康三维曲面模型。图 1 是轴承 $V_{\text{Bin}}\{4.5 \sim 5.0\}$ -P-T 健康三维曲面。

$$\hat{T}_{\max/\min} = \bar{T}(t) \pm 3\sigma \quad (2)$$

式中: \hat{T}_{\max} 为上限阈值; \hat{T}_{\min} 为下限阈值; $\bar{T}(t)$ 为轴承温度统计均值; σ 是标准差。

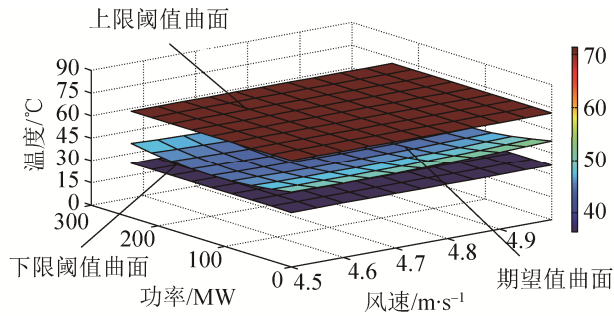


图 1 风电机组轴承(单 bin)风速-功率-温度三维曲面

Fig. 1 Three-dimension surface of wind speed-power-temperature for wind turbine bearing (Single bin)

4) 劣化度

t 时刻轴承温度实时监测值 $T(t)$, 当前风速工况下的健康状态期望温度 $\hat{T}(t) = f(V(t), P(t))$ 以及 \hat{T}_{\max} , \hat{T}_{\min} , 根据式(1)计算轴承当前劣化度 $d(t)$ 。

2 轴承健康劣化趋势预测模型

风电机组轴承健康劣化趋势具有明显的非平稳的特性, 直接影响到预测精度, 需要提前处理将劣化趋势分解成相对平稳的分量。

EMD (Empirical Mode Decomposition) 将复杂的非平稳信号分解为一系列相对平稳的本征模态函数(Intrinsic Mode Function, IMF)分量和一个剩余分量, 一定程度上避免了人为因素对分解结果的干预。但在某些情况下, 产生模态混叠, 出现分解后有局部不平稳和不连贯现象, EMD 又往往得不到理想的分解结果。EEMD 加入高斯白噪声, 利用高斯白噪声具有频率均匀分布的统计特性, 使信号在不同尺度上具有连续性, 避免了模态混叠现象^[10-11]。

2.1 EEMD 模态分解

依照如下步骤完成 EEMD 模态分解。

1) 初始化 EMD 执行的总次数 m 和白噪声信号的幅值系数 k 。

2) 将多组具有有限振幅的高斯白噪声序列 $n_i(t)$ 添加到原始劣化趋势 $d(t)$ 上, 即:

$$d_i(t) = d(t) + kn_i(t) \quad i = 1, 2, \dots, m \quad (3)$$

式中: $d_i(t)$ 是 t 时段第 i 次加入白噪声后的劣化趋势。

3) 对 $d_i(t)$ 分别进行 EMD 分解, 得到 n 个本征模态函数 $c_{ij}(t)$ 和一个 $r_i(t)$ 。其中, $c_{ij}(t)$ 表示第 i 次加入高斯白噪声后, 分解获得的第 j 个 IMF, $j=1, 2, \dots, n$ 。

4) 将获得的 IMF 进行总体平均运算, 得到基于 EEMD 的 IMF。即:

$$d(t) = \sum_{j=1}^n \left(\frac{1}{m} \sum_{i=1}^m c_{ij}(t) \right) + \frac{1}{m} \sum_{i=1}^m r_i(t) \quad (4)$$

2.2 EEMD 改进

风电机组轴承健康状态劣化趋势受包括随机噪声、脉冲噪声在内的各种噪声的影响, 而现有 EEMD 分解仅能去除信号中的随机噪声, 留下脉冲噪声尚待处理。考虑到小波变换对信号去噪能滤除高频噪声部分, 重构低频部分, 保留有价值的信息^[13], 若在对信号进行 EEMD 分解之前进行小波去噪, 可以提升后续的预测准确度。步骤如下:

- 1) 选择合适的小波基, 并确定分解层数 n , 然后对信号进行 n 层小波分解;
- 2) 将高频系数全部置零;
- 3) 对第 n 层的低频系数和第 1 至 n 层经过阈值处理后的高频系数进行重构, 得到去噪后的信号。

2.3 组合预测

非线性有源自回归神经网络(Nonlinear Auto Regressive Neural Network with Exogenous Input, NARX)模型综合应用神经网络非线性映射能力, 引入 ARX (Auto-regression with External input) 时间序列概念, 使得 NARX 模型具备良好的动态特性和较强抗干扰能力, 具有逼近任意的非线性的能力。NARX 模型的输出不仅取决于当前的输入, 还与过去时刻的输入密切相关, 而且其网络含有了多步输入和输出时延, 具有很强记忆功能的网络。因此, NARX 非常适合对具有较复杂的时间序列展开预测, 模型定义为^[12]:

$$y(t) = f \left[\begin{matrix} y(t-1), y(t-2), \dots, y(t-n_y), \\ x(t-1), x(t-2), \dots, x(t-n_d) \end{matrix} \right]$$

式中: $y(t-1), y(t-2), \dots, y(t-n_y)$ 表示过去的输出

时间序列; $x(t-1), x(t-2), \dots, x(t-n_d)$ 是影响输出 $y(t)$ 的多维变量时间序列。

预测步骤如下:

1) 首先确定网络的输入和输出变量, 并对参数进行归一化处理;

2) 设置网络模型延迟数 L 、隐含层数目 p 以及激活函数等模型重要参数;

3) 分析预测性能的各项指标系数以及修改网络结构, 优化模型预测性能, 得到最终的预测结果。

应用时间序列神经网络模型对 EEMD 各分量分别进行预测, 叠加各分量预测结果, 得到最终预测结果。如图 2 所示。

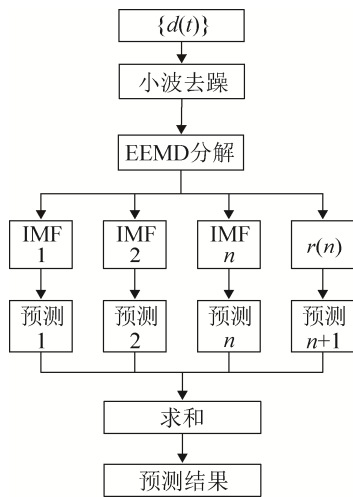


图 2 EEMD-时间序列神经网络组合预测流程图

Fig. 2 Flowchart of EEMD-Time series neural network combined prediction

3 预测模型仿真试验

选用 Matlab 建立模型, 应用 SCADA 监测数

据, 分别对轴承健康劣化模型和劣化趋势预测模型进行仿真验证。

3.1 数据准备

以华北某风电场 56#风电机组的发电机后轴承为对象, 该风机切入风速为 3 m/s, 切出风速为 24 m/s。随机选择 2015-06-01~2015-12-20 区间的、采样频率为 10 min 的发电机后轴承温度、风速和有功功率的 SCADA 数据, 筛选后共有 20 900 组样本健康数据。如表 2 所示。

表 2 健康数据集

Tab. 2 Normal data set

序号	风速/(m/s)	功率/kW	轴承温度/°C
1	6.54	432.7	33
2	5.21	260.3	36.3
3	4.81	158.4	39.2
...
20 898	8.08	834.8	38.4
20 899	7.1	551.2	38.1
20 900	6.84	518.3	37.5

3.2 健康数据模型

从 20 900 组数据中, 选取 20 800 组作为建模样本, 其余的 100 组数据作为测试样本。表 3 是不同工况下的轴承温度健康曲面模型的重要参数。由于机组运行在 22~24 m/s 的风速数据不多, 表 3 对其做舍弃处理。

应用测试样本数据计算, 发电机后轴承温度仿真结果与实际测量值平均相对误差为 4.25%, 健康数据模型具有较高精度。

表 3 分工况曲面模型重要参数

Tab.3 Important parameters of surface model with different working conditions

风速区间	c_{00}	c_{01}	c_{02}	c_{10}	c_{11}	c_{20}	上限	下限
3.0~3.5	287.115	0.137	0.000 36	-151.46	-0.048	23.515	71.4	34
3.5~4.0	254.668	0.048 8	-0.000 024	-114.49	-0.014	15.55	71.2	37.9
4.0~4.5	-136.133	0.207 9	0.000 072	79.055	-0.054	-8.543	71.3	36.4
...
20.5~21.0	-159 568.72	70.20	-0.010 28	10 136	-1.84	-175.37	68.9	36.6
21.0~21.5	142 629.65	-18.13	-0.013 7	-12 102	2.86	180.53	58.9	41
21.5~22.0	0	7.48	0.004 5	-487.12	-1.00	46.40	66.2	51.3

3.3 健康状态劣化趋势仿真试验

选择 56# 机组 2015-12-25 T 06:10:00~2015-12-31 T 23:50:00 时间段的 200 组 SCADA 风速、功率和轴承温度数据, 分工况计算当前轴承健康值 $\hat{T}(t)$ 以及劣化度 $d(t)$ 。如图 3 所示, 仿真计算结果表明, 发电机后轴承温度状态参数开始劣化, 其劣化呈波动逐渐上升趋势, 但仍处于正常运行状态。




图 3 风机轴承健康状态劣化趋势图

Fig. 3 Degradation trend graph of wind turbine

3.4 模态分解

从图 3 可看出, 风机轴承健康状态劣化趋势具有复杂的非平稳性, 为了提高状态劣化趋势预测的准确性, 利用改进的 EEMD 将其分解, 结合算法提出者的建议和本文的实验经验数据, 参数 $m=100$, k 取为 0.2 倍信号的标准偏差, 分解结果如图 4 所示。

图 4 中 $c_1 \sim c_7$ 为不同尺度的较平稳的 IMF, c_7 是趋势分量。可以看出, 分解后的分量比原始序列变化规律性更强, 有助于更准确预测。

3.5 预测仿真试验

时间序列神经网络预测模型能较好地适应信号的非线性和非平稳性, 具有较高预测精度。

用 200 组中的前 160 组数据进行训练和测试, 用后 40 组数据进行仿真验证。经过反复尝试和比较各组参数的预测模型, 当延迟数 $L=3$ 、隐含层 $p=12$ 的时候, 模型达到最好预测效果。 $c_1 \sim c_7$ 的预测结果如图 5 所示。




图 4 基于改进的 EEMD 轴承健康状态劣化趋势分解结果
Fig. 4 Decomposed results of degradation trend for wind turbine based on modified EEMD

纵观图 5(a)~(g), 随着轴承健康状态劣化趋势变化的平稳性越好和规律性越强, 预测精度越高; 到图 5(g)时, 实际状态劣化趋势和预测仿真结果具有较高的吻合度。

将各分量的预测结果进行叠加, 得到风机轴承健康状态劣化趋势的最终预测结果, 如图 6 所示。显然, 本文提出的预测模型可以有效地跟踪风机轴承劣化趋势。

4 仿真结果误差分析

选用平均绝对误差(MAE)、平均绝对百分比误差(MAPE)、均方根误差(RMSE)和均方根百分比误差(MSPE)作为误差分析指标。分别应用 BP 神经网络模型(BPNN)、RBF 神经网络模型(RBFNN)、支持向量机模型(SVM)、时间序列神经网络模型(NARX)以及未改进的 EEMD-时间序列神经网络模型(EEMD-NARX), 对随机选择的机组发电机后轴承状态劣化趋势进行预测仿真试验, 误差如表 4 所示。

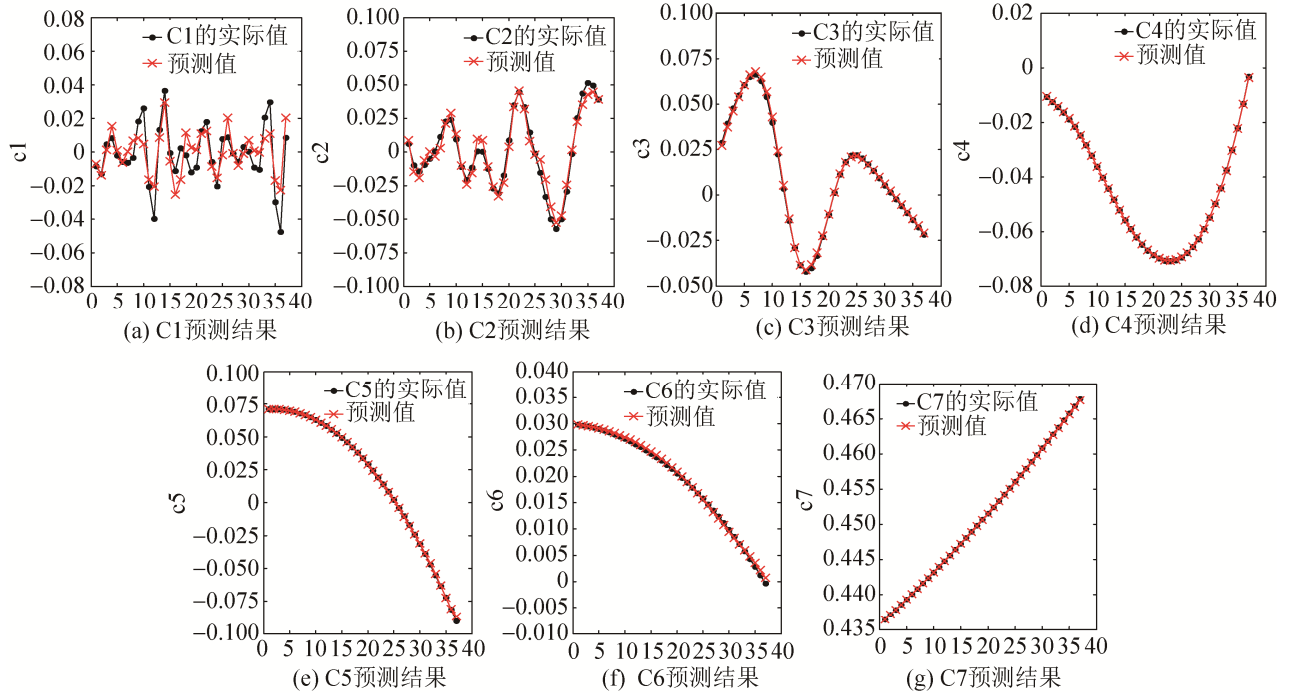


图5 c1~c7 的预测结果

Fig. 5 Predicted results of c1~c7




图6 预测最终结果

Fig. 6 Final predicted results of wind turbine degradation trend

以 RMSE 为例分析不同模型的计算误差。首先,对比传统的单个预测模型,时间序列神经网络模型的平均误差最小,其 RMSE 误差最大值为 0.159,平均误差为 0.102,比 RBFNN 模型 RMSE 误差指标降低了 21.5%。说明对于较复杂非线性和非平稳性的信号,时间序列神经网络模型预测精度相对其他传统单个预测模型更高。其次,在使用 EEMD 方法之后,EEMD-时间序列神经网络预测模型的 RMSE 误差范围为 0.023 8~0.061,平均误差为 0.04,又比时间序列神经网络模型的 RMSE 误差指标降低了 60%。

表4 5种模型的误差指标

Tab. 4 Error indexes of the five models

机组	误差指标	状态参数模型				
		BPNN	RBFNN	SVM	NARX	EEMD-NARX
38	MAE	0.135	0.047	0.046	0.042	0.019 6
	RMSE	0.161	0.059	0.057	0.055	0.023 8
	MAPE	0.290	0.264	0.222	0.242	0.087 5
	MSPE	0.519	0.914	0.750	0.898	0.224
56	MAE	0.219	0.197	0.247	0.125	0.047
	RMSE	0.264	0.236	0.309	0.159	0.061
	MAPE	0.167	0.192	0.182	0.152	0.058 2
	MSPE	0.184	0.284	0.234	0.269	0.082
87	MAE	0.179	0.0774	0.077	0.072	0.029
	RMSE	0.205	0.096	0.095	0.093	0.034
	MAPE	0.667	0.895	0.832	0.680	0.159
	MSPE	1.096	2.670	2.412	1.907	0.310 2
均值	MAE	0.178	0.107	0.123	0.080	0.032
	RMSE	0.210	0.130	0.154	0.102	0.040
	MAPE	0.375	0.450	0.412	0.358	0.097 5
	MSPE	0.600	1.289	1.132	1.025	0.205 4

在模型的运算时间没有明显增加的前提下,EEMD 结合传统参数预测模型的综合预测,明显提高预测精度。

为了确认使用小波去噪提升 EEMD 预测精度

的最佳时机, 分别对 EEMD 分解前的信号和 EEMD 分解后的各分量进行小波去噪仿真试验, 预测误差如表 5 所示。

表 5 改进 EEMD 组合预测模型的误差指标
Tab. 5 Error indexes of modified EEMD combination forecasting model

机组	误差指标	EEMD-小波	小波-EEMD
38	MAE	0.030 7	0.015 2
	RMSE	0.039 9	0.020 3
	MAPE	0.093 8	0.020 3
	MSPE	0.477 6	0.024 9
56	MAE	0.059 7	0.037 7
	RMSE	0.089 1	0.053 4
	MAPE	0.127 1	0.032 5
	MSPE	0.338 9	0.131 1
87	MAE	0.037 5	0.025 1
	RMSE	0.044 6	0.034 7
	MAPE	0.391 2	0.069 2
	MSPE	1.039 3	0.120 7
均值	MAE	0.042 6	0.026
	RMSE	0.057 9	0.036 1
	MAPE	0.204 0	0.040 7
	MSPE	0.618 6	0.092 2

仿真试验结果表明, 在 EEMD 分解之前进行小波去噪, 能提高预测精度; 而对 EEMD 分解后的各分量进行小波去噪, 在一定程度上反而降低了预测精度。

5 结论

1) 利用风电机组轴承温度、风速、功率 3 个参数, 应用最小二乘法建立其温度健康状态三维期望曲面模型, 结合健康运行上下预警阈值, 可有效地描述轴承的劣化程度。

2) 应用 EEMD 结合时间序列神经网络的组合预测模型对风机轴承健康状态劣化趋势分解, 得到具有相对较高的平稳性和规律性分量, 能很好地跟踪轴承劣化趋势; 相对于传统的单个预测模型, 明显提高了预测精度。

3) 通过小波去噪改进的 EEMD 结合时间序列神经网络的组合预测模型, 可有效去除信号中的噪

声, 更精准地预测风电机组轴承健康状态劣化度, 有利于风电场制定检修策略和开展可靠性评估。

参考文献:

- [1] 李辉, 胡姚刚, 唐显虎, 等. 并网风电机组在线运行状态评估方法[J]. 中国电机工程学报, 2010, 30(33): 103-109.
Li Hui, Hu Yaogang, Tang Xianhu, et al. Method for on-line operating conditions assessment for a grid-connected wind turbine generator system[J]. Proceedings of the CSEE, 2010, 30(33): 103-109.
- [2] Tchakoua P, Wamkeue R, Ouhrouche M, et al. Wind turbine condition monitoring: state-of-the-art review new trends and future challenges[J]. Energies(S1996-1073), 2014, 7(4): 2595-2630.
- [3] YANG W, TAVNER P J, CRABTREE C J, et al. Cost-effective condition monitoring for wind turbines[J]. IEEE Transaction on Industrial Electronics(S0278-0046), 2010, 57(1): 263-271.
- [4] 苏连成, 李兴林, 李小但, 等. 风电机组轴承的状态监测和故障诊断与运行维护[J]. 轴承, 2012 (1): 47-53.
Su Liancheng, Li Xinglin, Li Xiaoli, et al. Condition monitoring and fault diagnosis and operating maintenancesystems for wind turbine bearings[J]. Bearing, 2012(1): 47-53.
- [5] 彭进, 王维庆, 王海云, 等. 基于 EEMD 峭度-相关系数准则的多特征量风电机组轴承故障诊断[J]. 可再生能源, 2016, 34(10): 1481-1490.
Peng Jin, Wang Weiqing, Wang Haiyun, et al. Fault diagnosis method of wind turbine's bearing based on EEMD kurtosis-correlation coefficients criterion and multiple features[J]. Renewable Energy, 2016, 34(10): 1481-1490.
- [6] 赵洪山, 李浪. 基于 MCKD-EMD 的风电机组轴承早期故障诊断方法[J]. 电力自动化设备, 2017, 37(2): 29-36.
Zhao Hongshan, Li Lang. Incipient bearing fault diagnosis based on MCKD-EMD for wind turbine [J]. Electric Power Automation Equipment, 2017, 37 (2): 29-36.
- [7] 安学利, 唐拥军, 王允. 基于健康样本的风电机组滚动轴承健康状态评估[J]. 中国水利水电科学研究院学报, 2015, 13(1): 48-53.
An Xueli, Tang Yongjun, Wang Yun. State evaluation of rolling bearings for wind turbines based on health samples[J]. Journal of China Institute of Water Resources and Hydropower Research, 2015, 13(1): 48-53.

(下转第 165 页)