

基于自适应 EEMD 的风电机组联轴器松动故障诊断*

李国英¹, 王诗彬², 陈雪峰²

(1. 西安石油大学经济管理学院 西安, 710065)

(2. 西安交通大学机械制造系统工程国家重点实验室 西安, 710061)

摘要 联轴器是风电机组高速旋转齿轮箱和发电机之间的唯一机械连接件, 针对联轴器松动后存在振动信号微弱、干扰大、故障特征难以识别的难题, 提出了一种以协同信噪比(collaborative signal-to-noise ratio index, 简称 CSNR)为测度指标的自适应集成经验模式分解(ensemble empirical mode decomposition, 简称 EEMD)故障诊断方法。将该方法应用于数值仿真信号, 实现了仿真信号构成分量的准确分离; 应用于风场风电机组联轴器的松动故障诊断, 有效提取了联轴器松动噪声微弱信号中的故障特征, 验证了该方法在工程实际应用中的有效性和实用性。

关键词 集成经验模式分解; 风电机组; 故障诊断; 振动信号

中图分类号 TH133.4

引言

风电机组中常见的典型故障之一是连接齿轮箱和发电机的联轴器故障, 因外界风场中的风速是频繁变化的, 使得联轴器受到叶轮转动中传递的随机变载, 非常容易发生联轴器松动、联轴器打滑甚至飞车等事故, 给机组的安全、稳定运行带来很大影响。风电机组故障的并发性及其结构和周围环境的复杂性使得故障动态信号不但被强噪声污染, 而且又相互调制和耦合, 给故障识别带来难度。

Wu 等^[1]提出了集成经验模式分解方法, 通过在待分析的本征模式分量(intrinsic mode function, 简称 IMF)中依次加入一定量的高斯白噪声, 得到一系列的 IMF, 将得到的 IMF 进行集总平均, 作为总体平均经验模式分解的本征模式分量, 以达到抑制模式混叠的目的。国内外相关领域专家进一步研究了 EEMD 及其相应的改进算法^[2-5], 并将相关算法成功应用于海洋科学、车辆动力学、经济学^[6]、能源价格预测^[7]及生物医学等各个领域, 在信号处理^[8-9]、故障诊断^[10-19]领域更是得到了广泛应用和发展。

EEMD 在实际应用的过程中, 加噪声方式及总体平均次数的取值^[2]多数情况下都需经验确定。笔者针对 EEMD 方法中噪声幅值大小和集合平均次数的确定缺乏有效理论指导的问题, 提出了基于协同信噪比的自适应集成经验模式分解方法, 以揭示

噪声添加的定量机制, 实现加入噪声大小及总体平均次数的自适应选取, 提高 EEMD 对微弱故障特征信号的检测能力。

1 EEMD 的基本算法流程

EEMD 抑制模式混叠^[20]的算法流程如图 1 所示。根据算法流程, 可以得到具体分解步骤如下。

1) 假定原始采集到的振动信号为 $x(t)$, 均值为零的白噪声为 $n_i(t)$, 其幅值标准差是一个常数值, 则加噪后的信号表示为

$$x_i(t) = x(t) + n_i(t) \quad (1)$$

其中: $x_i(t)$ 为加入第 i 次噪声的信号。

2) 将加噪信号 $x_i(t)$ 通过 EMD 依次进行分解, 得到每一个加噪信号 $x_i(t)$ 对应的一系列本征模式分量, 记为 $c_{ij}(t)$, 其含义为加入第 i 次噪声的信号通过 EMD 分解得到的第 j 个基本模式分量, 余项用 $r_i(t)$ 表示。

3) 将第 j 个基本模式分量对应的加入第 1 次到第 N 次噪声的信号 $c_{ij}(t)$ 进行总体平均, 计算得出最后的基本模式分量作为 EEMD 的结果, 即

$$c_j(t) = \frac{1}{N} \sum_{i=1}^N c_{ij}(t) \quad (2)$$

其中: $c_j(t)$ 为原始振动信号通过 EEMD 后计算得出的第 j 个 IMF。

* 国家自然科学基金资助项目(51335006); 西安石油大学博士科研启动基金资助项目(134890001)

收稿日期: 2021-02-21; 修回日期: 2021-08-30

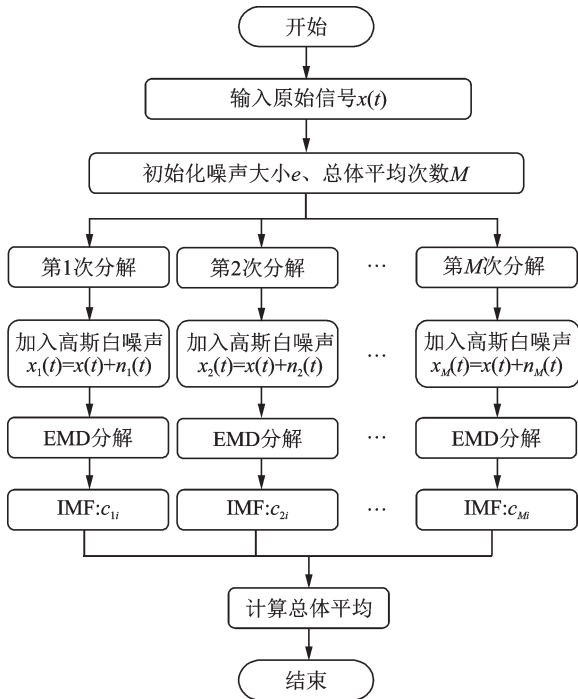


图 1 EEMD 算法流程

Fig.1 The flow chart of EEMD

EEMD 方法通过多次分解取平均值,减小了加入的高斯白噪声对目标信号基本模式分量分解结果的影响。

EEMD 应用过程中,需要确定最佳的总体平均次数,以便既能快速实现运算结果,又能保证得到准确的基本模式分量。在分解过程中若设置不当,会增大输入信号与 EEMD 分解后 IMF 的相对误差,从而导致分解结果无意义。文献[21]研究得出,EEMD 方法的应用过程中,噪声幅值比值系数和总体平均次数存在一定的关系,即

$$e = \alpha / \sqrt{N} \quad (3)$$

或
$$\ln e + \frac{\alpha}{2} \ln N = 0 \quad (4)$$

其中: N 为总体平均次数; α 为比值系数,即加噪后幅值标准差和原始振动信号的幅值标准差之比; e 为相对误差,即期望的原始振动信号和通过 EEMD 方法进行分解后得到的基本模式分量之和的预期相对误差。

文献[20]指出,在 EEMD 方法中加入较小的白噪声时误差也会较小。不断地提高总体平均次数值,相对误差可以减小至可接受范围。由式(3)或式(4)可以看出,期望的信号分解相对误差 e 设定后,一旦得到比值系数 α 的值,即可求出总体平均次数 N 的准确值。

当 α 过大时,相对误差增大,会淹没原信号的故

障特征,使整个分解过程变得没有意义;当 α 过小时,不足以引起原始信号局部极值点的变化,达不到改变信号极值点分布的目的,一般建议 α 取 0.2^[20]。原则上讲, N 值越大分解误差越小,但 N 值的增大会降低计算效率。

2 自适应集成经验模式分解方法

针对 EEMD 的重要参数多数情况下都需要人为经验来设定的问题,根据待处理信号的时频特性与 EEMD 原理,提出了基于协同信噪比的自适应集成经验模式分解方法,以协同信噪比指标 CSNR 为测度指标,当目标频率范围内的 CSNR 达到最大值时,它所对应的调节参数为最优参数,从而实现了白噪声幅值标准差系数 α 的最优化自适应选取,进而求得总体平均次数 N 。

2.1 协同信噪比指标

测度指标会直接影响运算算法的有效性和准确性,针对不同的系统性能需求,需要使用不同的测度指标。协同信噪比指标^[22]是在经典信噪比的基础上,将目标信号频谱中最高谱峰位置、互相关系数、残余噪声方差及过零点比率等成分引入构造而成。

协同信噪比指标 CSNR 的计算公式为

$$CSNR = \text{sgn}(\text{SNR}) \frac{|C|^{1-z}}{N_{\text{var}}} |\text{SNR}|^{1-z} A \quad (5)$$

其中: SNR 为信噪比; C 为互相关系数; N_{var} 为残余信号方差; z 为过零点比率; A 为最高谱峰与次高谱峰的幅值之差。

$|C|, |\text{SNR}|$ 和 N_{var} 全部归一化处理使其取值范围变为 $(0, 1]$ 区间。这部分可以让检测结果更加逼近真实信号的频率值,再借助 A 可进一步凸显目标频率的谱峰。

2.2 自适应 EEMD 算法流程

基于协同信噪比 CSNR 指标的自适应集成经验模式分解方法的算法流程如图 2 所示。算法流程的详细步骤如下。

1) 信号前处理:首先用 EMD 方法处理原始振动信号,并计算第 1 个 IMF 分量的幅值标准差,再计算这个高频分量的幅值标准差与原始信号幅值标准差的比值 ϵ 。

2) 设定参数:设置期望的信号分解相对误差 e ,一般设置为 0.5% 的标准偏差。

3) 参数初始化:引入调控参数 β ,调控参数 β 为噪声强度大小调节参数,是高频分量幅值标准差比值系数 ϵ 与噪声分量幅值标准差比值系数 α 的比值,即存在关系 $\beta=\epsilon/\alpha$ 。一般设置调节参数 β 的初始值为1,步长为1,取值区间为 $[1,10]$ 。

4) 加入的白噪声幅值标准差比值系数 α 的自适应提取:用网格搜索算法,以CSNR为目标函数,得到最优参数 β 。具体计算过程为:对噪声强度大小调节参数 β 的每一个值,用第1个IMF的幅值标准差比值系数 ϵ 除以 β ,得到对应的 α ,再利用式(3)计算总体平均次数 N ;用求得的每一组 (α, N) 进行EEMD分解,得到一系列总体平均后的IMF。

针对每一组IMF,计算其协同信噪比CSNR,在参数 β 的搜索范围内寻找最大值,将最大的协同信

噪比CSNR值及其相应的最优 β 值进行存储;进而利用 $\alpha=\epsilon/\beta$ 的关系计算得到最优的白噪声幅值标准差系数 α 。当噪声强度调节参数 β 超出搜索范围时,改变参数 β ,并转回第2步,重新设定 β 的初始值及相应的搜索范围和搜索步长。

5) 输出优化结果:用最优的噪声强度调节参数 β 得到最优参数 (α, N) ,再次进行EEMD分解,从而实现了目标信号特征频率的自适应提取和有效检测。

3 数值仿真与工程应用

3.1 数值仿真

首先构造一组仿真信号进行仿真实验进行验证。考虑到工程实际中旋转机械出现故障时的故障信号主要由各种频率的谐波成分与冲击响应成分构成,为此构造包含谐波成分与冲击响应成分的仿真信号来验证。

仿真信号表示为

$$x(t) = x_1(t) + x_2(t) + x_3(t) + n(t) \quad (6)$$

冲击响应信号分量为

$$x_1(t) = 2e^{-2\pi W_n t_1} \sin(2\pi W_n t_1 \sqrt{1-j^2}) \quad (7)$$

高频谐波信号分量为

$$x_2(t) = \sin(2\pi f_2 t) \quad (8)$$

低频谐波信号分量为

$$x_3(t) = \sin(2\pi f_3 t) \quad (9)$$

其中: j 为阻尼系数; W_n 为固有频率。

此信号中 $j=0.035$, $W_n=1\ 500$ Hz, 采样频率 $f_s=20$ kHz, 数据长度为 $N_0=2\ 048$, 高频频率 $f_2=160$ Hz, 低频频率 $f_3=50$ Hz。由4个分量构成的仿真信号如图3所示。

应用所提方法对构造的仿真信号进行分解。首先,通过经验模式分解对原始仿真振动信号分解,获得的第1个高频成分基本模式分量的比值系数 $\epsilon=0.217\ 8$;其次,设置期望的信号分解相对误差的值为 $e=0.005$,设置调节参数 β 的初始值为1,步长为1,取值区间为 $[1,10]$;然后,以协同信噪比指标为目标函数,经过上述算法流程,可自动计算出 $\beta=1$ 时,协同信噪比指标取得最大值,最大值为 $CSNR=55.02$,这时对应的白噪声幅值标准差为 $\alpha=0.337\ 0$,进而计算得到最优的总体平均次数为 $N=4\ 542$;最后,对原始仿真信号用EEMD重新分解,可得如图4所示的结果。自适应集成经验模式分解方法分解得到的 c_2, c_5, c_6 这3个IMF分量很好地对应了仿真信

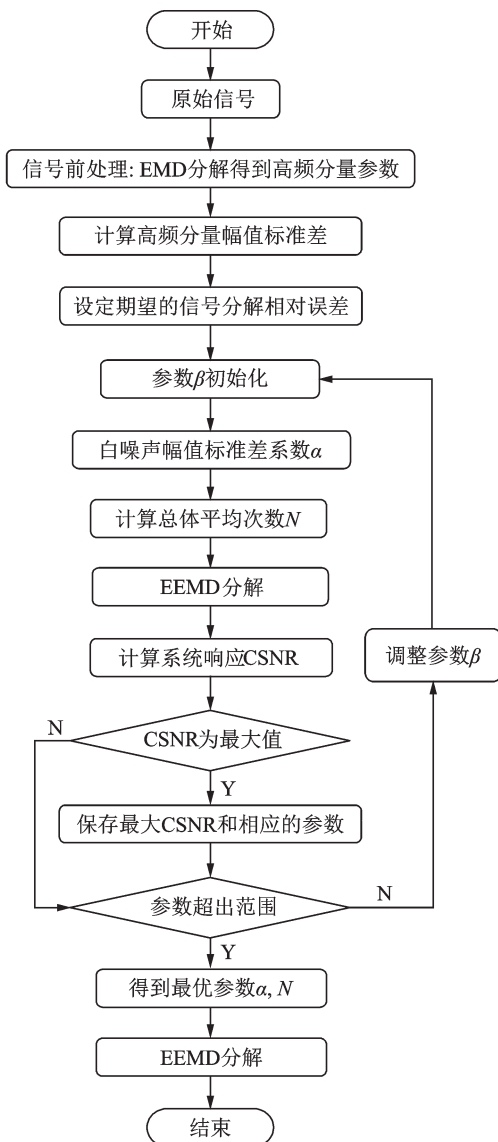


图2 基于CSNR的自适应EEMD算法流程

Fig.2 The flow chart of the adaptive EEMD method based on the CSNR

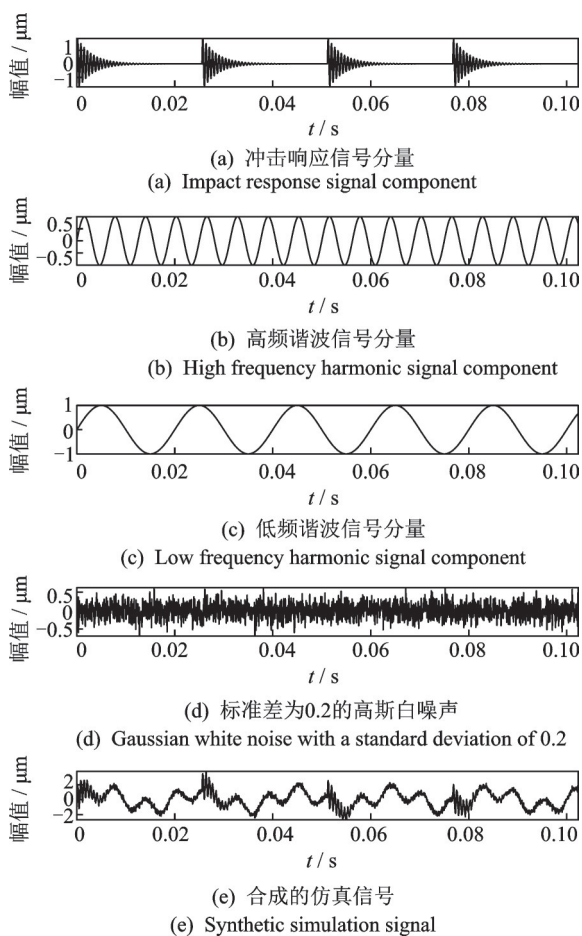


图 3 仿真信号的组成图

Fig.3 The composition diagram of the simulation signal

号的 3 个频率成分,分别是冲击响应分量、高频谐波分量和低频谐波分量。可看出,自适应集成经验模式分解方法能很好地将仿真信号中 3 个分量准确地分离出来。

3.2 工程应用

笔者选取某风场振动异常的 6# 风电机组发电机振动信号进行工程应用验证。6# 风电机组发电机的结构简图及传感器测点分布如图 5 所示,其中:①~⑦均为振动加速度传感器;⑧为高速轴转速的接近开关。

6# 风电机组高速轴与发电机的联轴器和现场传感器安装位置如图 6 所示。

选择图 5 中测点 6 发电机前轴承振动信号进行分析验证,振动信号基本情况如图 7 所示。

图 7 的时域波形、频谱图及包络谱图中均未观测到明显的轴承故障特征,难以确定发电机前轴承的状态。图 7(b)所示的频谱图中,因强噪声的影响,能量集中在高频区域,在低频区域可以看到明显的转




图 4 原始仿真信号所提方法的分解结果

Fig.4 The analyzed results for the simulation signal based on the proposed method

频 25 Hz。根据现场技术人员的描述,结合轴承松动故障特征,可依稀看到不太明显的转频谐波分量。

采用笔者所提方法对此振动信号进行分析,根据算法流程,首先得到第 1 个 IMF 的幅值标准差比





图 5 风电机组结构示意图及相应测点分布

Fig.5 The structure diagram and distribution corresponding to measurement points on the wind turbine

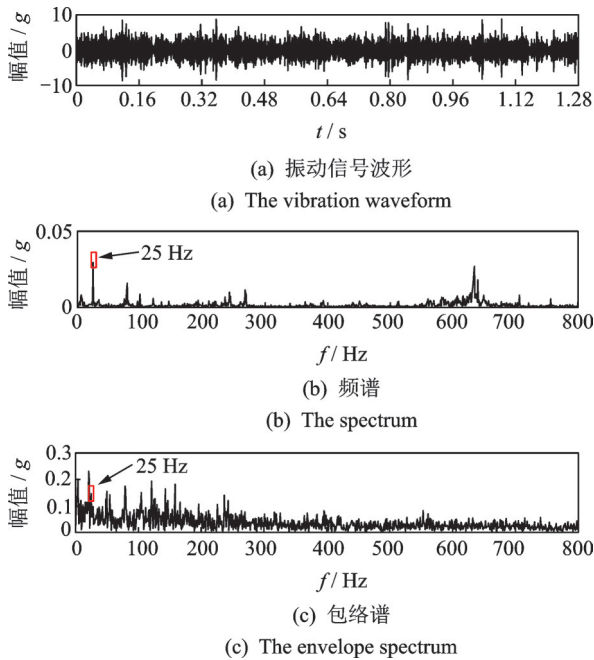
值系数 ϵ 为 1.004 1, 设置相对误差 $e=0.005$, 可计算出 $\beta=1$ 时, CSNR 取得最大值, 为 1.011 1, 对应的白噪声幅值标准差比值系数 $\alpha=1.004 1$, 进而计算得到最优总体平均次数 $N=40\ 327$, 最后得到分解结果, 如图 8 所示。



(a) 联轴器 (b) 传感器安装位置
(a) The coupling (b) The sensor position

图 6 风电机组联轴器及传感器

Fig.6 The coupling and the sensor position



(a) 振动信号波形
(a) The vibration waveform

(b) 频谱
(b) The spectrum

(c) 包络谱
(c) The envelope spectrum

图 7 发电机前轴承振动信号波形频谱及其包络谱

Fig.7 The vibration waveform and spectrum and envelope spectrum of the generator front bearing

分解结果的频谱如图 9 所示。可以清楚地看到, c_7 基本模式分量的频谱图中很好地包含了转频特征频率 25 Hz 及其谐波频率 50 Hz 和 75 Hz, 系统响应频谱中相应的目标信号频率谱峰突出。

进一步对测点 5 齿轮箱高速轴承进行分析, 其振动信号的时域波形、频谱及其包络谱如图 10 所示。由图可以看出, 时域波形杂乱无章, 虽能看到一些较为明显的冲击成分, 但不规则, 无法进行判断; 频谱图中, 能量主要集中在前中段, 在低频处看到不太明显的 25 Hz 转频及其倍频谐波分量, 但也没有明显的故障特征信息, 无法判断齿轮箱高速轴的情况;




图 8 发电机前轴承振动信号所提方法分解结果

Fig.8 The analyzed results for the vibration signal of the generator front bearing based on the proposed method




图 9 发电机前轴承振动信号所提方法分解频谱图

Fig.9 the spectrogram of the analyzed results for the vibration signal of the generator front bearing based on the proposed method

包络谱中能看到明显的 25 Hz 的转频信息, 但并未观察到故障特征信息。

图 11 所示为用本研究所提方法对齿轮箱高速轴的振动信号进行分解后的基本模式分量。其频谱图如图 12 所示。可以看出, c_6 IMF 分量中转频的 3 倍频 75 Hz 谱峰明显, c_7 IMF 分量中转频 25 Hz 谱峰突出。

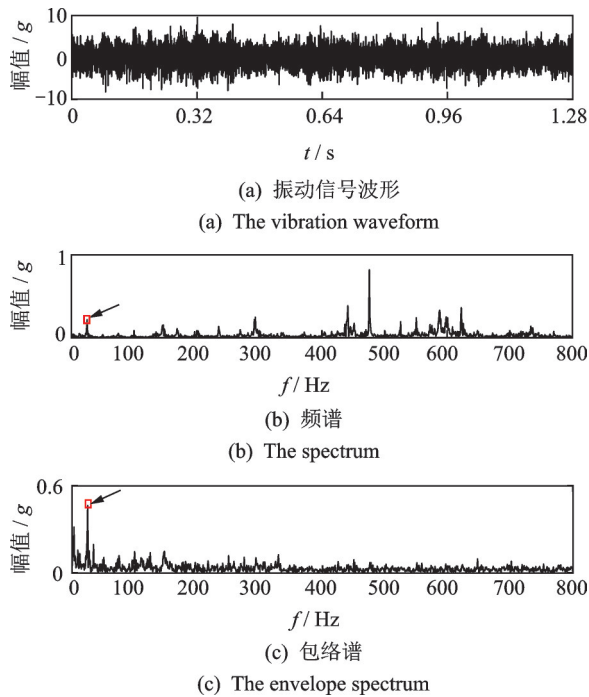


图 10 齿轮箱高速轴振动信号波形及其频谱包络谱
Fig.10 The vibration waveform and spectrum and envelope spectrum of the gearbox high-speed shaft




图 11 齿轮箱高速轴振动信号所提方法分解结果
Fig.11 The analyzed results for the vibration signal of gearbox high-speed shaft based on the proposed method

由测点 5 齿轮箱高速轴和测点 6 发电机前轴承的振动分析来看,两者的振动信号中均含有相同的转频 25 Hz 及其谐波频率 50 Hz 和 75 Hz 成分,结合现场工作人员的观察,验证了测点 5 和测点 6 之间即齿轮箱高速轴和发电机前轴承之间的联轴器发生松动故障。




图 12 高速轴振动信号所提方法分解频谱图
Fig.12 The spectrogram of the analyzed results for the vibration signal of gearbox high-speed shaft based on the proposed method

4 结束语

基于协同信噪比 CSNR 指标的参数自适应选取,提出了自适应集成经验模式分解的算法流程,揭示了噪声添加的定量机制,基于协同信噪比指标的最优化自适应地求解出其对应的最优参数,从而实现添加精确幅值的噪声及精确的集合平均次数,有效解决了人为设定加噪方式及幅值大小与集合平均次数的不合理问题,实现了故障特征频率的自适应提取,提高了 EEMD 方法对微弱故障特征信号的检测能力。数值仿真数据及风场风机联轴器故障的工程应用均验证了该方法的有效性。

参 考 文 献

[1] WU Z, HUANG N E. Ensemble empirical mode decomposition: a noise-assisted data analysis method [J]. Advances in Adaptive Data Analysis, 2009, 1(1): 1-41.
 [2] ZHANG J, YAN R, GAO R X, et al. Performance enhancement of ensemble empirical mode decomposition [J]. Mechanical Systems and Signal Processing, 2010, 24 (7): 2104-2123.
 [3] 周智, 朱永生, 张优云, 等. 基于 EEMD 和共振解调的滚动轴承自适应故障诊断[J]. 振动与冲击, 2013(2): 76-80.
 ZHOU Zhi, ZHU Yongsheng, ZHANG Youyun, et al. Adaptive fault diagnosis of rolling bearings based on EEMD and demodulated resonance [J]. Journal of Vibration and Shock, 2013(2): 76-80. (in Chinese)
 [4] 沈长青, 谢伟达, 朱忠奎, 等. 基于 EEMD 和改进的

- 形态滤波方法的轴承故障诊断研究[J]. 振动与冲击, 2013(2): 39-43, 66.
- SHEN Changqing, XIE Weida, ZHU Zhongkui, et al. Rolling element bearing fault diagnosis based on EEMD and improved morphological filtering method[J]. Journal of Vibration and Shock, 2013(2): 39-43, 66. (in Chinese)
- [5] 刘永强, 李翠省, 廖英英. 基于EEMD和自相关函数峰态系数的轴承故障诊断方法[J]. 振动与冲击, 2017(2): 111-116.
- LIU Yongqiang, LI Cuixing, LIAO Yingying. Fault diagnosis method for rolling bearings based on EEMD and autocorrelation function kurtosis [J]. Journal of Vibration and Shock, 2017(2): 111-116. (in Chinese)
- [6] MAO X G, YANG A C, PENG C K, et al. Analysis of economic growth fluctuations based on EEMD and causal decomposition [J]. Physica a-Statistical Mechanics and Its Applications, 2020, 553:124661.
- [7] LI J M, WANG J. Stochastic recurrent wavelet neural network with EEMD method on energy price prediction [J]. Soft Computing, 2020, 24(22): 17133-17151.
- [8] THAKRAN S. A hybrid GPFA-EEMD fuzzy threshold method for ECG signal de-noising[J]. Journal of Intelligent & Fuzzy Systems, 2020, 39(5): 6773-6782.
- [9] SUN Z Y, XI X G, YUAN C M, et al. Surface electromyography signal denoising via EEMD and improved wavelet thresholds [J]. Mathematical Biosciences and Engineering, 2020, 17(6): 6945-6962.
- [10] 雷亚国, 孔德同, 李乃鹏, 等. 自适应总体平均经验模式分解及其在行星齿轮箱故障检测中的应用[J]. 机械工程学报, 2014(3): 64-70.
- LEI Yaguo, KONG Detong, LI Naipeng, et al. Adaptive ensemble empirical mode decomposition and its application to fault detection of planetary gearboxes [J]. Journal of Mechanical Engineering, 2014(3): 64-70. (in Chinese)
- [11] 林旭泽, 蔡艳平, 王新军. 自适应的EEMD及其在滚动轴承故障诊断中的应用[J]. 机械科学与技术, 2016(11): 1727-1732.
- LIN Xuze, CAI Yanping, WANG Xinjun. Adaptive EEMD and its applications to rolling bearing fault diagnosis [J]. Mechanical Science and Technology, 2016(11): 1727-1732. (in Chinese)
- [12] ZOU P, HOU B C, JIANG L, et al. Bearing fault diagnosis method based on EEMD and LSTM [J]. International Journal of Computers Communications & Control, 2020, 15(1):1-14.
- [13] SHIFAT T A, HUR J W. EEMD assisted supervised learning for the fault diagnosis of BLDC motor using vibration signal[J]. Journal of Mechanical Science and Technology, 2020, 34(10): 3981-3990.
- [14] LOBATO T H G, DA SILVA R R, DA COSTA E S, et al. An integrated approach to rotating machinery fault diagnosis using, EEMD, SVM, and augmented data [J]. Journal of Vibration Engineering & Technologies, 2020, 8(3): 403-408.
- [15] AMAROUAYACHE I I E, SAADI M N, GUERSI N, et al. Bearing fault diagnostics using EEMD processing and convolutional neural network methods [J]. International Journal of Advanced Manufacturing Technology, 2020, 107(9/10): 4077-4095.
- [16] 张琛, 赵荣珍, 邓林峰. 基于EEMD奇异值熵的滚动轴承故障诊断方法[J]. 振动、测试与诊断, 2019, 39(2): 353-358.
- ZHANG Chen, ZHAO Rongzhen, DENG Linfeng. Rolling bearing fault diagnosis method based on EEMD singular value entropy[J]. Journal of Vibration, Measurement & Diagnosis, 2019, 39(2): 353-358. (in Chinese)
- [17] 程军圣, 王健, 桂林. 改进的EEMD方法及其在滚动轴承故障诊断中的应用[J]. 振动与冲击, 2018, 37(16): 51-56.
- CHENG Junsheng, WANG Jian, GUI Lin. An improved EEMD method and its application in rolling bearing fault diagnosis[J]. Journal of Vibration and Shock, 2018, 37(16): 51-56. (in Chinese)
- [18] 陈略, 瞿艳阳, 何正嘉, 等. 总体平均经验模式分解与1.5维谱方法的研究[J]. 西安交通大学学报, 2009, 43(5): 94-98.
- CHEN Lue, ZI Yanyang, HE Zhengjia, et al. Research and application of ensemble empirical mode decomposition principle and 1.5 dimension spectrum method [J]. Journal of Xi'an Jiaotong University, 2009, 43(5): 94-98. (in Chinese)
- [19] FENG Z, LIANG M, ZHANG Y, et al. Fault diagnosis for wind turbine planetary gearboxes via demodulation analysis based on ensemble empirical mode decomposition and energy separation [J]. Renewable Energy, 2012, 47: 112-126.
- [20] WU Z H, HUANG N E. Ensemble empirical mode decomposition: a noise-assisted data analysis method[J]. Advances in Adaptive Data Analysis, 2009,1(1): 1-41.
- [21] WU Z H, HUANG N E. A study of the characteristics of white noise using the empirical mode decomposition method[J]. Proceedings of the Royal Society of London Series A: Mathematical, Physical and Engineering Sciences, 2004, 460(2046): 1597-1611.
- [22] LI G, LI J, WANG S, et al. Quantitative evaluation on the performance and feature enhancement of stochastic resonance for bearing fault diagnosis [J]. Mechanical Systems and Signal Processing, 2016, 81: 108-125.



第一作者简介:李国英,女,1977年1月生,讲师。主要研究方向为信号处理与故障诊断。曾发表《Quantitative evaluation on the performance and feature enhancement of stochastic resonance for bearing fault diagnosis》(《Mechanical Systems and Signal Processing》2016, Vol.81)等论文。

E-mail: lgy@xsyu.edu.cn