

# 基于 BAACMD 和 BESDFIF 的风电机组 主轴承故障诊断

吴智泉<sup>1</sup>, 路忠峰<sup>2</sup>, 陈克锐<sup>1</sup>, 朱琳<sup>3</sup>, 杨智勇<sup>4</sup>

(1. 国家电投集团云南国际电力投资有限公司, 云南 昆明 650228;

2. 哈尔滨能创数字科技有限公司, 黑龙江 哈尔滨 150000;

3. 云南电投绿能科技有限公司, 云南 昆明 650228;

4. 国家电投集团云南国际电力投资有限公司新能源开发分公司, 云南 昆明 650228)

**摘要:**针对风电机组主轴承故障难以诊断的问题,提出一种基于带宽感知自适应啁啾模式分解(Bandwidth Aware Adaptive Chirp Mode Decomposition, BAACMD)和秃鹰算法优化直接快速迭代滤波(Bald Eagle Search Direct fast Iterative Filtering, BESDFIF)的故障诊断方法。首先采用加权频谱趋势法准确划分信号频段,诊断各频段的有效成分,随后利用模型拟合方法确定 ACMD 方法中惩罚因子 $\alpha$ 和初始中心频率 $f$ ,并通过 BAACMD 方法实现对故障信号进行处理实现故障特征信息的提取;其次利用秃鹰优化算法对 DFIF 方法中影响参数及分量选取过程进行寻优;最后使用最优滤波区间参数的 BESDFIF 方法对所得分量进行分解降噪处理,从中诊断出微弱的风电机组主轴承故障特征频率成分。现场数据分析结果表明,所研究方法可以有效诊断风电机组主轴承的微弱故障特征,实现风电机组主轴承的故障诊断。

**关键词:**风电机组主轴承;秃鹰优化算法;直接快速迭代滤波;故障诊断

中图分类号:TH17

文章编号:1000-0682(2024)02-0124-06

文献标识码:A

DOI:10.19950/j.cnki.CN61-1121/TH.2024.02.022

## Wind turbines based on BAACMD and BESDFIF spindle bearing damage detection

WU Zhiquan<sup>1</sup>, LU Zhongfeng<sup>2</sup>, CHEN Kerui<sup>1</sup>, ZHU Lin<sup>3</sup>, YANG Zhiyong<sup>4</sup>

(1. SPIC Yunnan International Power Investment Co., Ltd., Yunnan Kunming 650228, China;

2. Harbin Energy Innovation Digital Technology Co., Ltd., Heilongjiang Haerbin 150000, China;

3. Yunnan Power Investment Green Energy Technology Co., Ltd., Yunnan Kunming 650228, China;

4. SPIC Yunnan International New Energy Development Branch, Yunnan Kunming 650228, China)

**Abstract:** Aiming to solve the problem that it is difficult to diagnose the main bearing fault of wind turbine, a fault diagnosis method based on BAACMD and BESDFIF is proposed. Firstly, the weighted spectrum trend method is used to accurately divide the signal frequency band and diagnose the effective components of each frequency band, the penalty factor and the initial center frequency  $f$  in the ACMD method are determined by the model fitting method, and the fault feature information is extracted by processing the fault signal by the BAACMD method. Then the vulture optimization algorithm is used to optimize the filter interval parameters in the DFIF method. Finally, the BESDFIF method with optimal filtering interval parameters is used to decompose and reduce the noise of the obtained components, from which the weak fault characteristic frequency components of wind turbine main bearings are diagnosed. The field data analysis results show that the research method can effectively diagnose the weak fault characteristics of the wind turbine main bearing and realize the fault diagnosis of the wind turbine main bearing.

**Keywords:** wind turbine main bearing; bald eagle search; direct fast iterative filtering; fault diagnosis

收稿日期:2023-11-17

第一作者:吴智泉(1974—),男,汉族,湖北武汉人,博士,正高级工程师,主要从事可再生能源发电技术研究。

E-mail:aaa111201116@163.com

## 0 引言

风电机组主轴承作为机组传动系统的关键部件,受到自然风的影响,承受着巨大的随机冲击力,

频繁发生多种类型的故障<sup>[1]</sup>。若能准确诊断主轴承的故障状态,并根据故障状态制定有效的维护方法,可以保障风电机组的安全稳定运行,降低维护成本。因此,开展风电机组主轴承的故障诊断具有重要意义<sup>[2]</sup>。

由于风电机组主轴承尺寸较大,所处环境恶劣,噪声影响较多,对其进行微弱故障的故障诊断难度较大,部分学者对其进行了一定的研究,例如石志标<sup>[3]</sup>等提出了一种通过萤火虫算法优化支持向量机的方法,实现对风机主轴承的故障诊断,但该方法诊断准确性较低。张博<sup>[4]</sup>使用倒频谱的方法对振动信号进行加权处理,从而诊断出故障发生的部位,但该方法对微弱故障诊断难度较大。王振亚<sup>[5]</sup>等提出了奇异谱分解联合互信息理论的主轴故障特征提取方法,但该方法流程复杂,诊断速度较慢。王春梅<sup>[6]</sup>采用深度置信网络对风电机组主轴承故障进行诊断,王桂兰<sup>[7]</sup>等提出利用极端梯度提升算法预测风机主轴承故障,但该方法需要大量数据作为基础,无法对风电机组故障进行快速诊断。

Chen<sup>[8]</sup>等最近研究了一种带宽感知自适应啁啾模式分解(Bandwidth Aware Adaptive Chirp Mode Decomposition, BAACMD)方法,该方法能够提取出与轮轨激励相关的主导信号模态,然后提前从振动信号中减去,从而成功诊断出轴承故障诱发的信号模态。而风电机组主轴承在运行过程中同样易受到来自风机叶片、传动系统、发电机形成的噪声分量干扰,为此,该文将 BAACMD 方法引入风电机组主轴承故障诊断领域,通过递归框架提取信号模态,将无关噪声分量逐个剔除,实现故障特征信息的提取。在现场监测数据的实际应用过程中,发现采集的风电机组主轴承有效信号分量中存在强噪声干扰,使得主轴承的故障特征无法被准确提取,诊断效果难以达到预期水平。针对此问题,该文利用秃鹰优化算法<sup>[9]</sup>的全局搜索能力对直接快速迭代滤波<sup>[10]</sup>方法影响参数及分量选取过程进行优化,研究了一种秃鹰算法优化直接快速迭代滤波(Bald Eagle Search Direct Fast Iterative Filtering, BESDFIF)方法。该方法可以实现对振动信号进行自适应分解降噪处理,完成微弱故障的诊断工作。

为了从风电机组主轴承的振动监测数据中准确诊断出故障特征信息,该文将 BAACMD 方法与 BESDFIF 方法进一步融合,分别作为预处理和后处理方法对主轴承振动监测信号进行分析,实现对风电机组主轴承故障特征的准确诊断。

## 1 BAACMD 方法

### 1.1 ACMD 方法原理

ACMD 方法旨在通过振幅调制和频率调制<sup>[8]</sup>,将一个非平稳振动信号进行分解。具体过程如下:

首先通过最小化约束提取出目标信号分量:

$$\begin{cases} \min_{\alpha_k, \beta_k, f_k} \left\{ \sum_{k=1}^K \left[ \|\alpha_k''(t)\|_2^2 + \|\beta_k''(t)\|_2^2 + \tau \|x(t) - \right. \right. \\ \left. \left. x_k(t)\|_2^2 \right] \right\} \\ s. t. x_k(t) = \alpha_k(t) \cos \left[ 2\pi \int_0^t \tilde{f}_k(s) ds \right] + \beta_k(t) \\ \sin \left[ 2\pi \int_0^t \tilde{f}_k(s) ds \right] \end{cases} \quad (1)$$

其中: $\tilde{f}_k$  为解调算子的频率函数; $\alpha_k(t)$  和  $\beta_k(t)$  为两个解调信号; $\|*\|_2^2$  代表  $L_2$  范数; $\tau$  代表权重系数。

假设原始信号的样本数为  $N$ ,由式(1)得到目标函数为:

$$\min_{\{v\}, \{H\}_k} \left\{ \|\Theta v\|_2^2 + \tau \|x(t) - Gv\|_2^2 \right\} \quad (2)$$

$$\Theta = \begin{bmatrix} \Omega & 0 \\ 0 & \Omega \end{bmatrix} \quad (3)$$

$$C_k = \text{diag}[\cos(\theta_k(t_0)), \dots, \cos(\theta_k(t_{N-1}))] \quad (4)$$

$$S_k = \text{diag}[\sin(\theta_k(t_0)), \dots, \sin(\theta_k(t_{N-1}))] \quad (5)$$

其中:  $v_k = [\alpha_k^T \beta_k^T]^T$ ,  $x = [x(t_0), \dots, x(t_{N-1})]^T$ ,  $G_k = [C_k, S_k]$ ,  $\Omega$  为二阶差分矩阵,  $\theta_k = 2\pi \int_0^t \tilde{f}_k(s) ds$ 。

从而将解调信号更新为:

$$v^m = \left[ \frac{1}{\tau} \Theta^T \Theta + (G^m)^T G^m \right]^{-1} (G^m)^T x \quad (6)$$

其中:  $G^m$  由中心系数构建;  $m$  为迭代次数。

进一步地,提取目标分量:

$$x_k^m = G_k^m v_k^m \quad (7)$$

重复上述过程,直到两次相邻迭代的差值小于预设收敛精度时,即可提取原始信号中的目标模式。

### 1.2 BAACMD 方法实现流程

ACMD 的性能依赖于惩罚因子  $\alpha$  和指定的初始中心频率  $f$ 。如果提前得到各信号模式的频段,并确定 ACMD 输入参数,就能得到风电机组主轴承的故障信息。因此通过改进传统的频谱趋势法,引入加权频谱趋势(Weighted Spectrum Trend, WST)<sup>[11]</sup>来准确划分频段,采用能量密度作为加权因子来衡量

各频段信号强度,诊断各频段的有效成分,找到合适的带宽来覆盖有效的信号分量,继而自动确定惩罚因子 $\alpha$ 和初始中心频率 $f$ ,具体步骤如下:

首先,将诊断到的有效频带按照各频带 WST 值降序排列,排列的频带可以表示为:

$$l_1 = [f_{D_i}, f_{D_{i+1}}] \quad (8)$$

其中,  $l = 1, \dots, L-1$ ,  $L$  为布置频带的边界频率。按照频带的先后顺序逐一提取信号模态,得到的初始频率和带宽分别为:

$$f_l^0 = \frac{f_{D_i} + f_{D_{i+1}}}{2} \quad (9)$$

$$BW_l = f_{D_{i+1}} - f_{D_i} \quad (10)$$

由于带宽随 $\alpha$ 的变化规律类似于幂函数,因此采用模型拟合的方法得到带宽的定量表达式,可反向得到惩罚因子 $\alpha$ 的表达式为:

$$\alpha = [2.9868 \times (BW - 0.002137)]^{3.9323} \quad (11)$$

再次执行上述过程,对 WST 提取的其他信号模态进行 ACMD 处理,计算所提取分量和原信号的相关系数作为终止准则来判断是否已提取出所有有效信号分量。

由此,利用提出的 WST 和模型拟合表达式,可以自动确定 ACMD 的所有控制参数,从而实现故障特征信息的提取。

## 2 BESDFIF 方法

### 2.1 DFIF 方法原理

直接快速迭代滤波方法 (Direct Fast Iterative Filtering, DFIF) 可以将一个十分复杂的信号通过滤波器函数分解为若干个互不影响的 IMF 分量和一个趋势项,采用内、外两个嵌套循环对复杂信号进行分解,内循环负责生成单个 IMF 分量,外循环负责生成总体 IMF 分量,其具体过程如下:

$$L_m(f_m)(x) = \int_{-l_m}^{l_m} f(x+t) \cdot w_m(x) dt \quad (12)$$

$$l_m = 2 \lfloor \alpha \cdot \frac{N}{K} \rfloor \quad (13)$$

其中: $t$  为时间序列; $x$  为延迟时间序列; $m$  为迭代次数; $w_m(x)$  为滤波器函数; $l_m$  为半支撑长度; $\alpha$  为滤波区间调正参数; $N$  为样本点数; $K$  为极值点数; $\lfloor \cdot \rfloor$  表示将参数四舍五入至整数。

将所得信号分量  $L_m$  从原始振动信号中减去,获得振荡信号分量为:

$$IMF_m = M_m(f_m) = f_m - L_m = f_{m+1} \quad (14)$$

$$r = f - IMF_1 \quad (15)$$

其中,  $IMF_1$  为满足产生条件的滤波所得第一个信号分量,  $r$  为所得振荡信号,随着迭代过程的进行,原始信号被分解为若干个频率范围从高到低的 IMF 信号分量:

$$IMF_K = \lim_{m \rightarrow \infty} M^m(f - IMF_1 - \dots - IMF_{K-1}) \quad (16)$$

$$f_m = \sum_{k=1}^n IMF_k + r \quad (17)$$

其中,  $n$  为 IMF 数量,当满足迭代终止条件时分解停止,其终止条件为:

$$\frac{N_o^{N_o}}{(N_o + 1)^{N_o + 1}} < \frac{\delta}{|S|_{\infty} \sqrt{n-1-k}} \quad (18)$$

其中,  $k$  为  $[0, n]$  的整数。

DFIF 为了使获得 IMF 分量的计算更加直接简便,根据以下表达式准确得出  $N_o$  的值:

$$N_o = \text{round}\left(\frac{\log(k)}{\log\left(\frac{\max_{1-\lambda_i-\tau}}{1-\lambda_i-\tau}\right)(1-\lambda_i)}\right) \quad (19)$$

其中, 阈值参数  $\tau$  无限接近于 1,  $k \approx \max_{1-\lambda_i-\tau} (1-\lambda_i)^{N_o}$

### 2.2 滤波区间参数 $\alpha$ 的选取

滤波区间参数 $\alpha$ 的选取对 DFIF 分解降噪效果的影响很大,同时在 DFIF 分解降噪过程中需要人工筛选降噪效果最佳的 IMF 分量进行保留。为了解决主观经验选取滤波区间参数和人为保留 IMF 分量导致影响 DFIF 算法处理效果的问题,利用秃鹰优化算法<sup>[9]</sup>强大的全局搜索能力,该文提出一种秃鹰优化算法优化直接快速滤波方法。秃鹰优化算法是根据秃鹰捕食过程开发的全局式智能优化算法,具有灵活性高、收敛速度快等优点,通过秃鹰优化算法对 DFIF 方法中滤波区间参数 $\alpha$ 进行寻优,并自动选择最优 IMF 分量,具体实现过程如下:

(1) 秃鹰观测不同地区的捕食密度寻找最优搜索空间,并根据观测结果更新位置,其中秃鹰表示搜索的滤波区间参数 $\alpha$ ,所在位置为所得 IMF 分量适应度函数的值:

$$P_{i,\text{new}} = P_{\text{best}} + \beta \cdot \text{rand} \cdot (P_{\text{mean}} - P_i) \quad (20)$$

其中: $P_{i,\text{new}}$  为第  $i$  只秃鹰更新后位置; $P_{\text{best}}$  为根据先前搜索确定的最佳位置; $\beta$  为控制秃鹰位置变化的参数,  $\text{rand}$  为  $(0, 1)$  范围内随机数; $P_{\text{mean}}$  为平均位置; $P_i$  为第  $i$  只秃鹰更新前位置。

(2) 为了准确评估故障特征,引用一种最小信息熵指标,采用不同滤波区间参数 $\alpha$ 条件下 DFIF 处理所得到的所有 IMF 分量的信息熵<sup>[12]</sup>作为适应度函数,能更有效地衡量故障特征信息,当分解产生

的  $IMF$  分量越有序时,包含的故障信息越明显,熵值也就越小。其表达式为:

$$H(x) = - \sum_{i=1}^N p_i \lg p_i \quad (21)$$

其中:  $N$  和  $p_i$  分别表示 DFIF 处理所得  $IMF$  分量的样本点数和随机函数取值为  $i$  时的概率。

(3)空间猎物搜索。在初始选择的搜寻空间内,秃鹰螺旋式飞行寻找最佳俯冲捕捉地点,秃鹰位置更新公式为:

$$P_{i,new} = P_i + x_1(i) \cdot (P - P_{mean}) + y_1(i) \cdot (P_i - P_{i+1}) \quad (22)$$

其中:  $P_{i+1}$  为第  $i$  只秃鹰下一次更新位置;  $x_1(i), y_1(i)$  为秃鹰的极坐标位置。

(4)俯冲捕获猎物。搜索到猎物位置后,秃鹰迅速从最优搜索空间俯冲而下,群体其他个体同时向猎物移动并发起攻击。秃鹰俯冲捕食的位置更新公式为:

$$P_{i,new} = rand \cdot P_{best} + x_2(i) \cdot (P_i - c_1 P_{mean}) + y_2(i) \cdot (P_i - c_2 P_{best}) \quad (23)$$

其中:  $P_{i,new}$  为此阶段第  $i$  只秃鹰更新后位置;  $c_1$  和  $c_2$  为运动强度值,取值均在  $[1, 2]$  范围内。

随着迭代过程进行,秃鹰将围绕最优个体进行搜索,当信息熵值最小,秃鹰所处为最优位置时,算法将获得最优滤波区间参数  $\alpha$ , 并成功选取最优  $IMF$  分量,实现对故障信号的分解降噪处理。

### 3 风电机组主轴承故障诊断流程

针对风电机组主轴承故障诊断问题,提出了基于 BAACMD 和 BESDFIF 的故障诊断方法。通过将 BAACMD 与 BESDFIF 进行改进并进一步融合,分别作为预处理方法及后处理方法对风电机组主轴承原始振动信号进行故障诊断,能够有效挖掘出主轴承早期故障状态下蕴含的微弱特征信息,所提方法故障诊断流程如图 1 所示,具体实现过程如下:

(1)加载现场实测风电机组主轴承振动监测信号,初始化 BAACMD 方法参数;

(2)通过 WST 方法准确划分频段,提取有效信号分量,自适应确定惩罚因子  $\alpha$  与初始频率  $f$ ;

(3)选择风电机组主轴承故障特征信息所在分量进行 BAACMD 分析,实现故障特征信息的提取;

(4)初始化 BES 算法的参数,设置秃鹰种群规模  $z = 20$ ,最大迭代次数  $T_{max} = 15$ ,以所得  $IMF$  分量的信息熵为适应度函数,确定滤波区间参数为秃鹰个体解,设定滤波区间参数取值范围  $[1, 5]$ ;

(5)当迭代次数达到设定的最大值后,输出 DFIF 方法所得最优滤波区间参数和保留的信息熵值最小的  $IMF$  分量;

(6)得到降噪  $IMF$  信号分量后对其进行包络分析,从包络谱中诊断故障特征频率,进而实现风电机组主轴承局部故障的准确诊断。

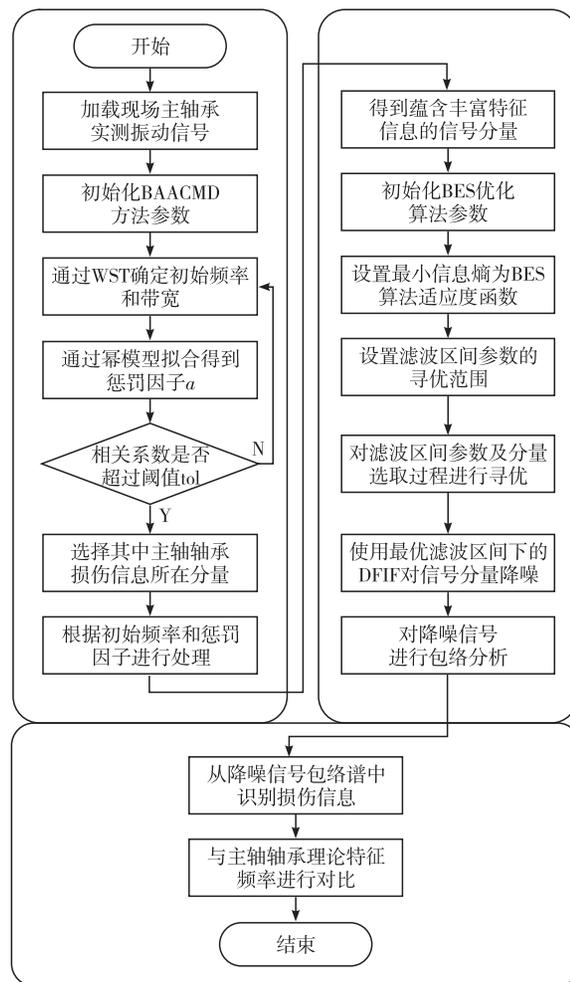
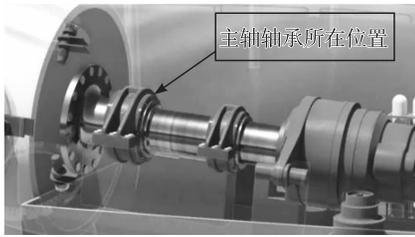


图 1 故障诊断流程图

### 4 风电机组主轴承现场监测数据验证

针对某风场风电机组主轴承振动数据进行分析,机组主轴承型号为 NJ36/620ECMA/V,节径为 1680 mm,接触角为  $20^\circ$ ,滚子数目 46 个,滚子直径为 42 mm。主轴承具体安装位置及环境如图 2(a) 和图 2(b) 所示,通过布设在主轴承水平及竖直方向的压电加速度传感器如图 2(c)、图 2(d) 所示对其振动信号进行持续跟踪监测,采样频率  $f_s$  为 4096 Hz,每隔 6 h 监测采集一组数据,在持续监测过程中系统出现报警,停机拆卸解体检查发现主轴承滚动体出现裂痕。为验证该文方法对风电机组主轴承早期微弱故障诊断效果,选取该轴承发生故障警告前 15 天的某

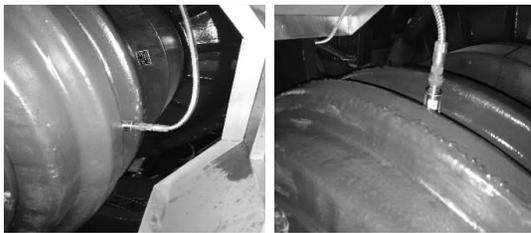
段振动数据进行分析。其转频  $f_r = 0.53 \text{ Hz}$ , 根据轴承特征频率相关公式<sup>[13]</sup>可以计算得到理论滚动体故障特征频率为  $f_s = 10.51 \text{ Hz}$ 。



(a) 风电机组主轴安装位置示意图



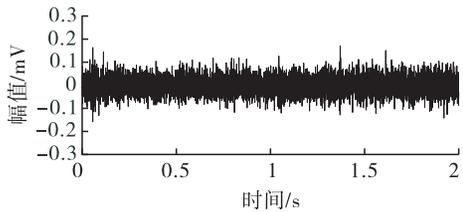
(b) 风电机组主轴现场环境示意图



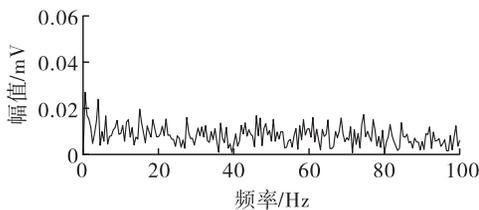
(c) 传感器水平测点 (d) 传感器竖直测点

图 2 主轴安装位置及传感器安装位置示意图

选取主轴承振动数据中时长为 2 秒、数据量为 8192 点的振动信号进行分析, 滚动体故障信号波形及包络谱如图 3 所示, 其时域波形中干扰较多, 无法准确表征主轴承滚动体故障状态。包络谱中由于强烈的背景噪声干扰, 未能明确提取出故障特征频率。



(a) 原始振动信号的时域波形

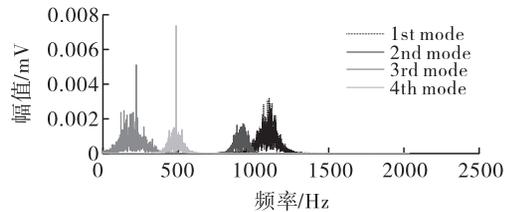


(b) 原始振动信号的包络谱

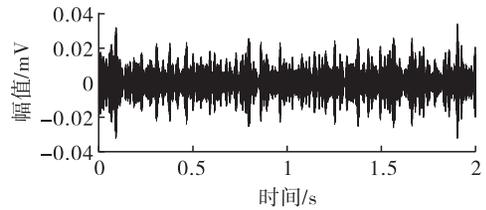
图 3 原始振动信号时域波形及包络谱

BAACMD 最终提取的信号模式如图 4(a) 所

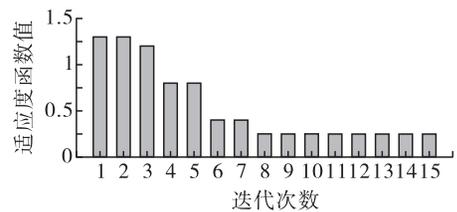
示, 可以看出, 提取的四种模式分别对应于风电机组主轴承运行中存在的随机脉冲、轴承故障信号、环境噪声信号和多边形化谐波。选取其中第 2 模式进行处理, 所得结果如图 4(b) 所示, 其时域波形表现出由滚动体故障诱发的较强周期性冲击特性, 随后通过 BES 优化算法对 DFIF 中滤波区间参数及分量选择过程进行寻优, 适应度函数值随迭代次数变化曲线如图 4(c) 所示, 在第 8 次迭代时完成收敛。采用 BESDFIF 算法对 BAACMD 所得信号分量进行处理, 得到最优降噪分量信号后并进行包络分析, 所得结果如图 4(d) 所示, 包络谱中转频  $f_r$ 、故障特征频率  $f_s$  及其倍频幅值明显, 谱图清晰, 能够准确诊断出主轴承滚动体故障。



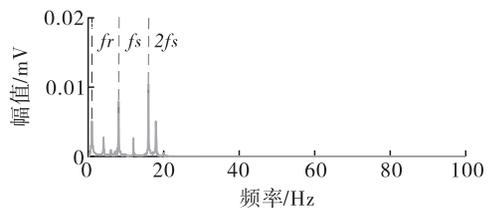
(a) 所提取的四种信号模式频谱



(b) BAACMD处理后波形



(c) 适应度值随迭代次数变化曲线



(d) 降噪信号分量包络谱

图 4 该文研究方法处理结果

随后, 利用原始 ACMD 方法对主轴承振动数据进行处理, 根据人为经验选取惩罚因子  $\alpha$  与初始频率  $f$ , 得到信号分量波形及包络谱如图 5 所示, 其时域波形中未能准确发现周期性冲击特征, 包络谱中无法找出主轴承滚动体故障特征频率。

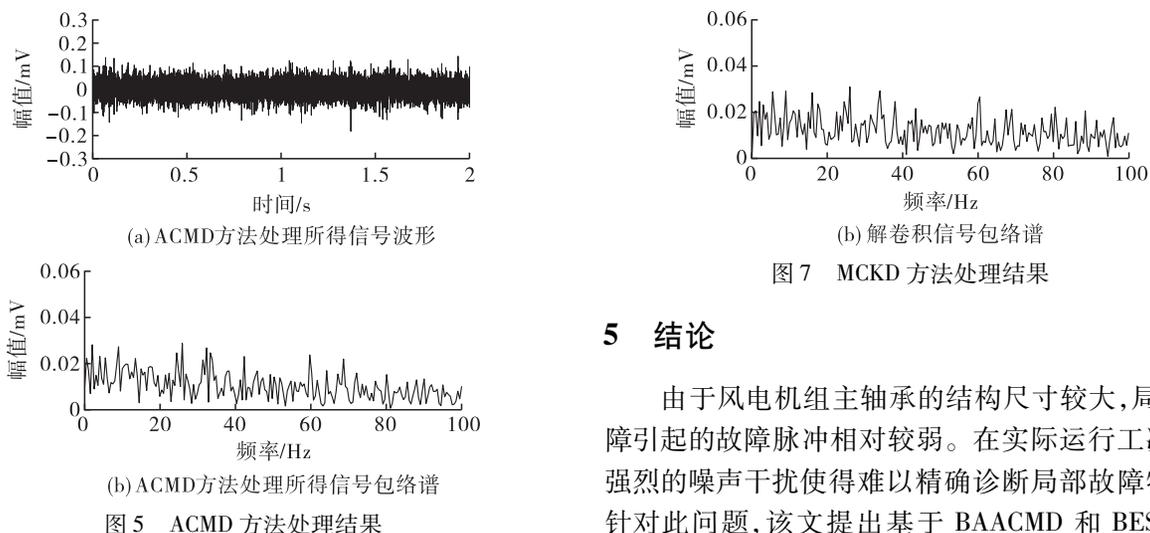


图5 ACMD方法处理结果

为进一步验证该文方法的优势,选用故障诊断领域常用的变分模态提取(Variational Mode Extraction, VME)<sup>[14]</sup>和最大相关峰度解卷积(Maximum Correlated Kurtosis Deconvolution, MCKD)方法<sup>[15]</sup>分别对主轴承振动数据进行分析对比。

经VME方法提取的信号波形及包络谱如图6所示,其波形中无法准确诊断出规律的瞬态冲击,包络谱中背景噪声较强,噪声信号掩盖了潜在的故障特征频率。

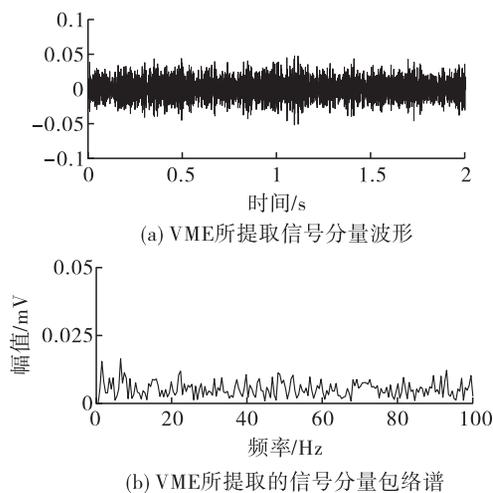


图6 VME方法处理结果

使用MCKD方法对主轴承振动信号进行处理,所得解卷积信号波形及包络谱如图7所示,解卷积信号时域波形中冲击杂乱不具有周期性,包络谱中无法诊断出故障特征频率。

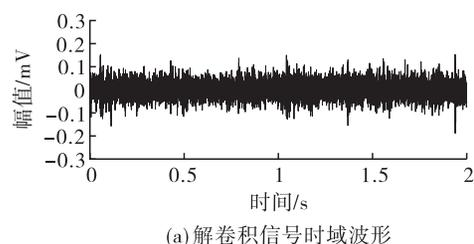


图7 MCKD方法处理结果

## 5 结论

由于风电机组主轴承的结构尺寸较大,局部故障引起的故障脉冲相对较弱。在实际运行工况下,强烈的噪声干扰使得难以精确诊断局部故障特征。针对此问题,该文提出基于BAACMD和BESDFIF的风电机组主轴承故障诊断方法。通过对实际工程数据进行验证,结果表明:

(1)通过BAACMD方法对原始振动信号进行处理能够实现微弱故障特征信息的提取。采用BES优化算法对DFIF方法中滤波区间参数进行寻优并保留最优IMF分量,能够对所得信号进行分解降噪处理,准确判断风电机组主轴承故障位置;

(2)相较于单独使用BAACMD方法或者BESDFIF方法对主轴承振动监测数据进行分析而言,该文将BAACMD和BESDFIF这两种方法的优点进行结合,所取得的诊断效果更加优异;

(3)主轴承的现场监测数据验证结果表明,该文所研究方法能够有效提取出主轴承振动监测数据中蕴含的微弱故障特征成分。

### 参考文献:

- [1] 凌永志,鲁纳纳,孙启涛,等. 风电机组主轴承故障的分析与预测[J]. 风能,2020(04):74-78.
- [2] 党存禄,杜小波. 粒子群优化变论域模糊PID控制在风电机组变桨距中的应用[J]. 工业仪表与自动化装置,2017(05):97-100.
- [3] 石志标,姜红阳. 基于IEM-FA优化LSSVM的风机主轴承故障诊断研究[J]. 组合机床与自动化加工技术,2019(1):90-93.
- [4] 张博,程珩. 倒频谱在直驱风机主轴承故障诊断中的应用[J]. 机械设计与制造,2014(07):265-267.
- [5] 王振亚,伍星,刘韬,等. 奇异谱分解联合互信息的主轴承故障特征提取研究[J]. 振动与冲击,2023,42(15):23-30+47.
- [6] 王春梅. 基于深度置信网络的风电机组主轴承故障诊断方法研究[J]. 自动化仪表,2018,39(05):33-37.
- [7] 王桂兰,赵洪山,米增强. XGBoost算法在风机主轴承故障预测中的应用[J]. 电力自动化设备,2019,39(01):73-77+83.

(下转第142页)

- 1135.
- [6] 陈丽娟,王致杰. 基于改进下垂控制的微电网运行控制研究[J]. 电力系统保护与控制,2016,V44(4):16-21.
- [7] 彭克,戚日常,张新慧. 多端互联交直流配电网的潮流分层控制策略及算法[J]. 电力系统自动化,2016,40(14):72-77.
- [8] 吴争,孔力,袁晓冬,等. 基于电力电子变压器的交直流混合可再生能源关键技术[J]. 电工电能新技术,2019,38(02):1-10.
- [9] 郝晓弘,胡开伟,裴婷婷,等. 风电接入交直流混联电网外送消纳能力研究[J]. 太阳能学报,2021,42(10):195-201.
- [10] 衣立东,摆世彬,张文朝,等. 综合能源交直流混联外送系统暂态过电压分析与快速估算[J]. 太阳能学报,2023,44(06):122-129.
- [11] 丁明,潘浩,张晶晶. 分布式电源接入交直流混合微电网群优化规划研究[J]. 太阳能学报,2021,42(06):54-62.
- [12] 周建萍,薛亚林,徐征. 基于功率交互和充放速率优化的交直流混合微网控制策略研究[J]. 太阳能学报,2018,39(12):3558-3567.
- [13] 麻秀范,崔换君. 改进遗传算法在含分布式电源的配电网规划中的应用[J]. 电工技术学报,2011,26(3):175-181.
- [14] 戴上,张焰,祝达康. 含有微电网的配电网规划方法[J]. 电力系统自动化,2010(22):41-45.
- [15] 盛四清,范林涛,李兴,等. 基于帕累托最优的配电网多目标规划[J]. 电力系统自动化,2014,38(15):51-57.
- [16] 肖峻,张婷,张跃,等. 基于最大供电能力的配电网规划理念与方法[J]. 中国电机工程学报,2013,33(10):106-113.
- [17] 李高望,陈锐智,陈艳波. 考虑网络划分优化的交直流系统并行电磁暂态仿真研究[J]. 电力系统保护与控制,2021,49(04):72-80.
- [18] 陈汉雄,李婷,李奥. 提升电网运行的交直流系统协调控制策略研究[J]. 电力系统保护与控制,2021,49(10):123-134.
- [19] 李兴,杨智斌,颜远,等. 考虑换流站损耗特性的交直流系统多目标无功优化控制[J]. 电力系统保护与控制,2017,45(09):119-125.

(上接第123页)

- [11] JAMIL M, YANG X S. A literature survey of benchmark functions for global optimization problems[J]. International Journal of Mathematical Modelling and Numerical Optimisation, 2013, 4(2): 150-194.
- [12] 李中,路宇,王鑫,等. 基于ABC-LSTM的变压器表面振动基频幅值预测[J]. 工业控制计算机,2021,34(06):21-23+26.
- [13] 马宏忠,赵宏飞,陈楷,等. 基于振动的变压器铁心松动判定方法[J]. 电力系统自动化,2013,37(14):101-106.
- [14] 韩中合,焦宏超,徐搏超,等. 基于EEMD样本熵和SVM的振动故障诊断研究[J]. 汽轮机技术,2015,57(06):457-460.
- [15] 徐搏超. 基于HVD和相关向量机的转子多故障分类优化[D]. 保定:华北电力大学,2017.
- [16] 李浩瀚. 燃气轮机控制系统执行器的复合故障诊断研究[D]. 北京:华北电力大学(北京),2022.

(上接第129页)

- [8] CHEN S, GUO L, FAN J, et al. Bandwidth-aware adaptive chirp mode decomposition for railway bearing fault diagnosis[J]. Structural Health Monitoring, 2024; 23(2):876-902.
- [9] ALMONACID B, SOTO R. Andean condor algorithm for cell formation problems[J]. Natural Computing, 2019, 18: 351-381.
- [10] CICONE A, LIU J, ZHOU H. Adaptive local iterative filtering for signal decomposition and instantaneous frequency analysis[J]. Applied and Computational Harmonic Analysis, 2016, 41(2): 384411.
- [11] LIU Y, YUAN D, GONG Z, et al. Adaptive spectral trend based optimized EWT for monitoring the parameters of multiple power quality disturbances[J]. International Journal of Electrical Power & Energy Systems, 2023, 146: 108797.
- [12] 李华,伍星,刘韬,等. 基于信息熵优化变分模态分解的滚动轴承故障特征提取[J]. 振动与冲击,2018,37(23):219-225.
- [13] JACEK D. Diagnosing of rolling element bearings using amplitude level based decomposition of machine vibration signal[J]. Measurement, 2018, 126:413153.
- [14] LI C, LIU Y, LIAO Y, et al. A VME method based on the convergent tendency of VMD and its application in multifault diagnosis of rolling bearings[J]. Measurement, 2022, 198: 111360.
- [15] 王建国,刘冀韬,张文兴. 自适应MCKD和VMD在行星齿轮箱早期故障诊断中的应用[J]. 机械设计与制造,2022(6):130-133.