

# 基于 EWT-MDS 的风力机轴承劣化趋势识别及故障诊断

谭 媛<sup>1</sup>, 孙文磊<sup>1</sup>, 温广瑞<sup>2</sup>, 黄 鑫<sup>2</sup>

(1. 新疆大学机械工程学院, 乌鲁木齐 830047; 2. 西安交通大学机械工程学院, 西安 710049)

**摘 要:**为解决风力机轴承劣化趋势识别精度低与早期故障诊断困难问题,提出一种基于经验小波分解和多维尺度变换的EWT-MDS方法。该方法首先将轴承全生命周期振动信号进行经验小波自适应分解,以信息熵为指标定量分析各模态分量的变化特点,然后结合多维尺度变换算法获取高维空间中各劣化表征分量的协同变化规律,与常规方法相比在检测效率和精度上有较大提升。仿真和实验结果表明该方法可提前检测轴承异常状态节点,通过轴承劣化表征模态分量时域重构,结合频谱和包络谱可准确判别轴承早期故障类型。

**关键词:** 风力机; 轴承; 故障诊断; 劣化趋势; 经验小波变换

**中图分类号:** TH17

**文献标识码:** A

## 0 引 言

风能是太阳能的一种特殊转化形式,随着全球能源紧缺,风力发电作为一种清洁能源在国内外得到了快速的发展。截至2017年底,中国风电装机容量占全球35%的份额,仍保持全球最大的风能市场地位。

新疆地区蕴含极为丰富的风力资源,其风能资源总储量9.57亿kW,技术开发量为2.34亿kW<sup>[1]</sup>。随着国家一带一路战略的稳步推进,新疆地区风力资源将得到持续的开发和利用,但新疆地形地貌与气候特征特殊,地形复杂造成气流受地形影响易发生畸变,进而导致风力机长期工作于复杂的交变载荷下,长时间的极端运行环境极易引发一系列问题,与之伴随的风电机组状态监测和故障诊断需求也日益凸显<sup>[2]</sup>。

滚动轴承是风电机组中的重要部件,恶劣的工作环境及风况变化引起的交变载荷极易使轴承发生故障,若不及时采取措施将引发严重事故并造成重大损失。风力机轴承运行状态劣化趋势识别及早期故障诊断技术可为实施先进的预知维护及主动维修提供依据,有利于避免重大事故的发生,降低风电设备全

寿命周期维护费用,为提高大型风电设备的安全性、稳定性、可靠性提供有效的科学手段。

赵洪山等<sup>[3]</sup>针对经验模态分解难以有效提取轴承早期微弱故障特征的问题,将最大相关峭度解卷积算法与经验模态分解相结合,应用于风力机轴承早期故障诊断,仿真及试验结果表明该方法具有良好的效果。任学平等<sup>[4]</sup>利用双树复小波变换可将信号分解为若干不同频带分量的优点,在频带幅值熵的基础上提出将Teager能量谱与双树复小波变换相结合的轴承早期故障诊断方法。马增强等<sup>[5]</sup>通过变分模态分解得到若干本征模态分量,之后通过Teager能量算子解调得到Teager能量谱,有效提高风力机轴承早期故障信号的信噪比及微弱故障诊断的精度。代俊习等<sup>[6]</sup>提出一种基于复合多尺度熵的滚动轴承故障特征提取新方法,并将序列前向选择方法与拉普拉斯支持向量机相结合应用于滚动轴承故障智能诊断中。蒲子玺等<sup>[7]</sup>将平稳小波及峭度准则引入变分模态分解中,可有效提取强噪声背景下的滚动轴承早期故障信息。邓飞跃等<sup>[8]</sup>通过Hermitian小波进行连续小波变换得到轴承的时间-小波能量谱样本熵,量化分析其故障特征信息。

现有风力机轴承振动信号处理算法大部分基

收稿日期: 2017-10-10

基金项目: 国家自然科学基金(51565055; 51365051); 新疆维吾尔自治区研究生科研创新项目(XJGR12017026)

通信作者: 孙文磊(1962—), 男, 博士、教授, 主要从事风电装备运行状态监测与故障诊断及动力学分析方面的研究。sunwenxj@163.com

于内积变换原理,缺乏自适应性。Jerome Gilles<sup>[9]</sup>提出一种新的信号处理方法——经验小波变换(empirical wavelet transform, EWT),其核心思想是通过信号的 Fourier 谱进行自适应划分,建立合适的小波滤波器组来提取信号不同的 AM-FM 成分,其计算量远小于 EMD 方法且具有较强的鲁棒性<sup>[10]</sup>。

风电机组轴承运行状态劣化是一个缓慢渐变的过程,直接在时域、频域等低维空间中观察难以直接捕捉到风力机轴承运行状态变化的节点,因此需在高维拓扑空间中探索轴承振动信号特征变化的规律。多维尺度变换(multi-dimensional scaling, MDS)是一种观察分析高维多元数据结构与空间分布的技术,可有效揭示高维数据样本之间的相对关系,展示数据样本高维空间分布情况及隐藏的信息和规律。

本文结合经验小波分解和多维尺度变换提出了风力机轴承劣化趋势 EWT-MDS 识别方法,对风力机轴承全生命周期的振动信号进行经验小波分

解,选取劣化表征模态分量进行多维尺度变换,识别高维空间中风力机轴承运行状态变化节点并进行早期故障类型识别。

## 1 EWT-MDS 理论基础

### 1.1 经验小波变换理论

经验小波变换建立在小波分析的理论框架下,基于待处理信号的频谱特性构造带通滤波器组实现多分量信号的自适应分解。

首先将待处理信号的频域支撑区间  $[0, \pi]$  自适应地分解为  $N$  部分,用信号频谱 2 个相邻极大值点之间的中点  $\omega_n$  表示各部分之间的边界:

$$\Lambda_n = [\omega_{n-1}, \omega_n], n = 1, 2, \dots, N \quad (1)$$

$$U_{n=1}^N \Lambda_n = [0, \pi] \quad (2)$$

针对不同的区间  $\Lambda_n$  分别构造经验尺度函数  $\phi_n(\omega)$  和经验小波函数  $\psi_n(\omega)$  作为带通滤波器组以实现信号的自适应处理:

$$\hat{\phi}_n(\omega) = \begin{cases} 1, & |\omega| \leq (1-\gamma)\omega_n \\ \cos\left\{\frac{\pi}{2}\beta\left[\frac{1}{2\gamma\omega_n}(|\omega| - (1-\gamma)\omega_n)\right]\right\}, & (1-\gamma)\omega_n \leq |\omega| \leq (1+\gamma)\omega_n \\ 0, & \text{其他} \end{cases} \quad (3)$$

$$\hat{\psi}_n(\omega) = \begin{cases} 1, & (1+\lambda)\omega_n \leq |\omega| \leq (1-\gamma)\omega_n \\ \cos\left\{\frac{\pi}{2}\beta\left[\frac{1}{2\gamma\omega_{n+1}}(|\omega| - (1-\gamma)\omega_{n+1})\right]\right\}, & (1-\gamma)\omega_{n+1} \leq |\omega| \leq (1+\gamma)\omega_{n+1} \\ \sin\left\{\frac{\pi}{2}\beta\left[\frac{1}{2\gamma\omega_{n+1}}(|\omega| - (1-\gamma)\omega_{n+1})\right]\right\}, & (1-\gamma)\omega_n \leq |\omega| \leq (1+\gamma)\omega_n \\ 0, & \text{其他} \end{cases} \quad (4)$$

式中,  $\gamma$  ——伸缩因子;  $\beta(x)$  ——信号函数。

$$\beta(x) = x^4(35 - 84x + 70x^2 - 20x^3) \quad (5)$$

$$\gamma < \min_n \left( \frac{\omega_{n+1} - \omega_n}{\omega_{n+1} + \omega_n} \right) \quad (6)$$

仿照经典小波变换的形式定义经验小波变换:

$$W_f(n, t) = \langle f(t), \psi_n(t) \rangle = F^{-1}[f(\omega)\hat{\psi}_n(\omega)] \quad (7)$$

$$W_f(0, t) = \langle f(t), \psi_1(t) \rangle = F^{-1}[f(\omega)\hat{\psi}_1(\omega)] \quad (8)$$

式中,  $W_f(n, t)$  ——细节系数;  $W_f(0, t)$  ——近似系数;  $f(t)$  ——调幅-调频(AM-FM)信号函数。

则待处理信号可重构为:

$$f(t) = F^{-1}[\hat{W}_f(0, \omega)\hat{\phi}_1(\omega) + \hat{W}_f(n, \omega)\hat{\phi}_n(\omega)] \quad (9)$$

定义待处理信号中包含的本征模态分量为:

$$f_0(t) = W_f(0, t) \times \varphi_1(t) \quad (10)$$

$$f_k(t) = W_f(k, t) \times \psi_k(t) \quad (11)$$

式中,  $f_0(t)$  ——初始模态函数;  $f_k(t)$  ——本征模态函数。

从而完成多分量信号的自适应分解与处理。

### 1.2 多维尺度变换理论

设  $g$  维 ( $g \gg 3$ ) 空间中有  $i$  个样本,

$M = \{m_1, m_2, \dots, m_i\} \in \mathbb{R}^g$ ,  $D$  为  $M$  的距离矩阵:

$$D = \begin{bmatrix} 0 & d_{12} & d_{13} & \dots \\ d_{21} & 0 & \dots & \dots \\ d_{31} & \dots & \dots & \dots \\ \dots & \dots & \dots & 0 \end{bmatrix} \quad (12)$$

式中,  $d_{ij} = \|m_i - m_j\|$ 。

为观察  $g$  维空间中各样本之间的关系,需对  $M$  进行降维处理,设降到  $p$  维空间后的样本为  $N = \{n_1, n_2, \dots, n_i\} \in \mathbb{R}^p$ ,  $E$  为  $N$  的距离矩阵:

$$E = \begin{bmatrix} 0 & e_{12} & e_{13} & \dots \\ e_{21} & 0 & \dots & \dots \\ e_{31} & \dots & \dots & \dots \\ \dots & \dots & \dots & 0 \end{bmatrix} \quad (13)$$

式中,  $e_{ij} = \|n_i - n_j\|$ 。

MDS 算法的核心思想是将分析对象在较低维度欧几里德空间中的相关性距离度量尽可能的匹配原始距离度量:

$$e_{ij} \cong d_{ij} \quad (14)$$

为实现式(14),需构造矩阵  $T = NN^T$ :

$$T = \begin{bmatrix} t_{11} & t_{12} & t_{13} & \dots \\ t_{21} & t_{22} & \dots & \dots \\ t_{31} & \dots & \dots & \dots \\ \dots & \dots & \dots & t_{ij} \end{bmatrix} \quad (15)$$

式中,  $t_{ij} = n_i \times n_j$ ;  $d_{ij} = e_{ij} = \|n_i - n_j\|$ 。

则:

$$d_{ij}^2 = (n_i - n_j)^2 = n_i^2 + n_j^2 - 2n_i n_j \quad (16)$$

将  $D^2$  中的元素分别按行求和,按列求和,全部元素求和,可得:

$$\sum_{i=1}^k d_{ij}^2 = kn_j^2 + \sum_{i=1}^k n_i^2 - 2n_j \sum_{i=1}^k n_i \quad (17)$$

$$\sum_{j=1}^k d_{ij}^2 = kn_i^2 + \sum_{j=1}^k n_j^2 - 2n_i \sum_{j=1}^k n_j \quad (18)$$

$$\sum_{i=1}^k \sum_{j=1}^k d_{ij}^2 = k \sum_{i=1}^k n_i^2 + k \sum_{j=1}^k n_j^2 - 2kn_j \sum_{i=1}^k n_i - 2kn_i \sum_{j=1}^k n_j \quad (19)$$

由式(17)~式(19)可得:

$$t_{ij} = -\frac{1}{2} \left( d_{ij}^2 - \frac{1}{k} \sum_{i=1}^k d_{ij}^2 - \frac{1}{k} \sum_{j=1}^k d_{ij}^2 + \frac{1}{k^2} \sum_{i=1}^k \sum_{j=1}^k d_{ij}^2 \right) \quad (20)$$

求得矩阵  $T$  后,再对其进行奇异值分解:

$$T = U\Lambda U^T = U\Lambda^{1/2} \Lambda^{1/2} U^T \quad (21)$$

式中,  $U$  ——矩阵  $T$  的特征向量;  $\Lambda$  ——矩阵  $T$  的特征值。

由此可以求出降维后的目标矩阵  $N$ :

$$N = U\Lambda^{1/2} \quad (22)$$

### 1.3 EWT-MDS方法流程

EWT-MDS 方法流程框图如图 1 所示,首先利用经验小波变换处理风力机轴承全生命周期振动信号,分析每个模态分量的时域信息熵变化规律,

寻找劣化表征模态分量并对其信息熵进行多维尺度变换。

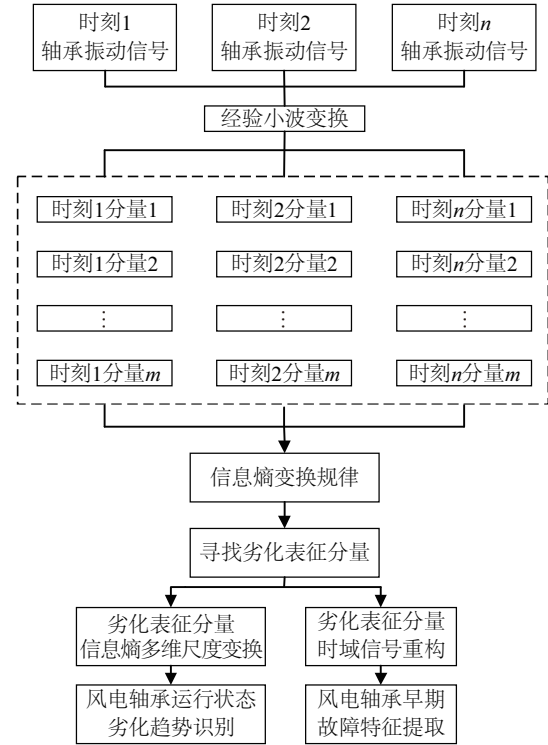


图1 EWT-MDS方法流程图

Fig. 1 Flow chart of EWT-MDS method

在低维空间中观察各劣化表征分量信息熵的协同变化规律,寻找轴承运行状态跳变节点并对其劣化表征分量进行时域重构,结合频谱和包络谱判断风力机轴承早期故障类型。

## 2 EWT仿真信号分析

本文首先进行仿真信号分析以验证经验小波分解风力机轴承振动信号的有效性。

当风力机轴承出现故障时,振动信号中会出现以风力机轴承故障频率为调制频率,轴承元件固有频率为载波频率的调幅信号,通常表现为周期性的脉冲衰减信号<sup>[11]</sup>。

根据式(23)构造轴承故障的仿真信号,其中轴承的位移常数  $y_0 = 0.8$ ,阻尼系数  $\xi = 0.1$ ,冲击故障发生的周期为 0.2 s,采样频率  $f_s = 1000$  Hz,采样点数  $N = 2000$ 。

$$y_a(t) = y_0 e^{-\xi \omega_s t} \sin \omega_n \sqrt{1 - \xi^2} t \quad (23)$$

为模拟风电装备实际运行工况,在上文构造的仿真信号中加入 3 个正弦调制分量:

$$y_b(t) = 0.7 \times \sin(2 \times \pi \times 5 \times t) \quad (24)$$

$$y_c(t) = 0.5 \times \sin(2 \times \pi \times 10 \times t) \quad (25)$$

$$y_d(t) = \sin(2 \times \pi \times 50 \times t) \quad (26)$$

仿真信号时域波形如图 2 所示,对其进行经验小波变换,结果如图 3 所示,经验小波变换可将仿真信号准确分解为单分量信号,无模态混叠现象。




图2 仿真信号时域波形图

Fig. 2 Simulation signal in time-domain

本文以 EMD 算法作为对比算法对仿真信号进行处理,分析结果如图 4 所示,EMD 将构造的仿真信号分解为 7 个本征模态分量,IMF0 分量中包含 2 种时域特征差异较大的模态分量,IMF0、IMF1 和 IMF2 中均包含时域特征相近的模态分量,存在明显的模态混叠现象。




图3 仿真信号EWT分解结果

Fig. 3 EWT results of Simulation signal

EMD 的实现过程是用“筛”的方法把一个复杂信号分解为有限个本征模态函数之和<sup>[12]</sup>。EMD 在求取仿真信号包络线的过程中,极值点的选取受到周期脉冲信号的干扰,从而导致计算出的包络为脉冲信号的局部包络和正弦调制信号包络的

组合。利用该包络计算出来的 IMF 同时包含信号的固有模态和脉冲信号模态,导致同一 IMF 中包含了相邻时间尺度的固有模态分量,从而产生模态混叠。




图4 仿真信号EMD分解结果

Fig. 4 EMD results of Simulation signal

仿真信号分析结果表明,当待处理信号中存在周期脉冲等跳跃性成分时,对信号进行 EMD 分解会存在模态混叠现象,EWT 可以较为准确的分解该类信号,具有良好的精度和鲁棒性。

### 3 轴承运行状态劣化趋势识别

#### 3.1 实验台介绍

轴承全生命周期振动数据来自于美国 NSF/UCR 智能维护中心(IMS)<sup>[13,14]</sup>,实验台如图 5 所示,通过弹性系统在轴承上施加约 26671 N 的径向力以模拟轴承载荷。




图5 轴承实验平台

Fig. 5 Bearing test rig

实验共持续 9840 min(约 164 h),实验过程中信号采集系统每隔 10 分钟以采样频率 20 kHz 采集



时长为 1 s 的振动数据, 每组数据 20480 点, 共采集 984 组振动数据。1#轴承参数如表 1 所示<sup>[15]</sup>, 经计算可得 1#轴承外圈故障特征频率约为 235 Hz。

表 1 1#轴承相关参数

Table 1 Parameters of 1# bearing

型号	滚子数	轴承节径	滚柱直径	接触角
ZA-2115	16	7.15 cm	0.84 cm	15.17°

### 3.2 全生命周期振动数据分析

首先求取 1#轴承全生命周期振动数据的脉冲指标、峭度、信息熵、峰-峰值、偏斜度变化如图 6 所示, 从而得到轴承运行状态从正常运行状态劣化至失效的全过程, 当轴承运行至约 7000 min 时相关时域指标开始出现明显跳变, 可判断出轴承运行状态已出现异常, 在此之前各指标无明显变化。




图 6 轴承全生命周期振动指标变化

Fig. 6 Domain index of bearing vibration signal

为验证本文所提 EWT-MDS 方法识别风力机轴承早期故障状态的有效性, 将全生命周期振动信号进行 EWT 分解, 并分别计算各模态分量信息熵如图 7 所示, 第  $C_2$ 、 $C_3$ 、 $C_4$  分量信息熵值在 5000 min 时有较为明显的下降。信息熵是由 Shannon 提出用来度量系统不确定性的物理量, 当信号中信息熵降低时说明信号中的周期成分增多, 由此可得出  $C_2$ 、 $C_3$ 、 $C_4$  分量在约 5000 min 时开始出现周期性的冲击成分。

本文以轴承振动数据经经验小波分解之后的  $C_2$ 、 $C_3$ 、 $C_4$  分量为劣化表征模态分量, 探索轴承全生命周期运行状态劣化规律。但是  $C_2$ 、 $C_3$ 、 $C_4$  分量数据样本众多, 且各分量变化规律并非完全一致, 因此需借助多维尺度变换观察高维空间中各劣化表征分量的协同变化规律, 对  $C_2$ 、 $C_3$ 、 $C_4$  分量全生命周

期信息熵值进行多维尺度变换, 将高维信息熵数据降维至二维, 结果如图 8 所示, 轴承运行状态在 5320 min 处出现明显跳变, 即 5320 min 为轴承运行状态劣化节点时刻。

现有常规监测方法无法准确捕捉到轴承运行劣化节点, 本文所提方法可有效识别风力机轴承运行状态变化的节点, 为及早维修与视情维护提供科学的依据。




图 7 轴承各模态分量信息熵变化

Fig. 7 Comentropy variation of each mode component




图 8 基于 EWT-MDS 方法的轴承劣化趋势识别

Fig. 8 Identification of deterioration tendency by EWT-MDS

## 4 轴承早期故障诊断

实际风电现场应用时除需准确识别轴承运行状态变化节点, 还需确定轴承故障类型。轴承 5320 分钟振动数据时域波形如图 9 所示, 经 EWT 处理结果如图 10 所示, 为保证处理结果的一致性, 同样将振动信号分解为 10 个分量。




图9 状态变化节点振动时域波形

Fig. 9 Joint vibration signal in time-domain




图10 状态变化节点振动信号EWT分解结果

Fig. 10 EWT results of joint vibration signal

取时刻 5320 min 处的  $C_2$ 、 $C_3$ 、 $C_4$  分量进行时域重构,如图 11 所示。




图11 劣化表征模态分量时域重构

Fig. 11 Reconstruction of symptom mode component

对重构分量分别求取频谱和包络谱,如图 12 和图 13 所示。重构信号的频谱图和包络谱图中均出现 238 Hz 分量,说明此时轴承已出现外圈损伤。实验结束后,开盖检查发现 1#轴承失效形式为严重外

圈剥落故障,如图 14 所示,早期故障判别结果和最终实验结果一致。




图12 劣化表征模态分量重构频谱图

Fig. 12 Frequency spectrum of symptom mode component




图13 劣化表征模态分量重构包络谱图

Fig. 13 Envelope spectrum of symptom mode component



图14 轴承外圈故障图

Fig. 14 Outer race defect of bearing

## 5 结 论

经验小波分解作为一种全新的自适应信号处理算法,可准确分析处理风力机轴承振动信号,无模态混叠现象,具有较强的鲁棒性。

多维尺度变换可在低维空间中观察分析高维

多元数据结构与空间分布,有效分析风力机轴承各高维劣化表征分量之间的信息熵协调变化规律,准确捕捉风力机轴承运行状态变化节点。在滚动轴承全生命周期运行实验中,EWT-MDS方法比常规监测方法提前1680 min检测到轴承运行状态变化,且通过重构劣化表征分量的频谱图和包络谱图可准确判断轴承早期故障类型为外圈损伤,识别结果与最终开盖检查结果一致。

风力机轴承运行状态劣化趋势识别可为后续维修决策争取时间,从而有效降低风电装备发生重大事故的风险,具有重要的工程价值。

### [参考文献]

- [1] 周伟. 新疆风力资源分布状况及风力发电前景展望[J]. 新疆农机化, 2007, (1): 61—62.
- [1] Zhou Wei. The distribution of wind resources in xinjiang and the prospect of wind power[J]. XinJiang Agricultural Mechanization, 2007, (1): 61—62.
- [2] 陈雪峰, 李继猛, 程航, 等. 风力发电机状态监测和故障诊断技术的研究与进展[J]. 机械工程学报, 2011, 47(9): 45—52.
- [2] Chen Xuefeng, Li Jimeng, Cheng Hang, et al. Research and application of condition monitoring and fault diagnosis technology in wind turbines[J]. Journal of Mechanical Engineering, 2011, 47(9): 45—52.
- [3] 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.
- [3] 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.
- [4] 任学平, 王朝阁, 张玉皓, 等. 基于DT-CWT自适应Teager能量谱的轴承早期故障诊断[J]. 振动、测试与诊断, 2017, 37(4): 735—742.
- [4] Ren Xueping, Wang Chaoge, Zhang Yuhao, et al. Early fault diagnosis of rolling bearing based on dual-tree complex wavelet transform adaptive teager energy spectrum[J]. Journal of Vibration, Measurement & Diagnosis, 2017, 37(4): 735—742.
- [5] 马增强, 李亚超, 刘政, 等. 基于变分模态分解和Teager能量算子的滚动轴承故障特征提取[J]. 振动与冲击, 2016, 35(13): 134—139.
- [5] Ma Zengqiang, Li Ya chao, Liu Zheng, et al. Rolling bearings' fault feature extraction based on variational mode decomposition and Teager energy operator[J]. Journal of Vibration and Shock, 2016, 35(13): 134—139.
- [6] 代俊习, 郑近德, 潘海洋, 等. 基于复合多尺度熵与拉普拉斯支持向量机的滚动轴承故障诊断方法[J]. 中国机械工程, 2017, 28(11): 1339—1345.
- [6] Dai Junxi, Zheng Jinde, Pan Haiyang, et al. Rolling bearing fault diagnosis method based on composite multiscale entropy and Laplacian SVM[J]. China Mechanical Engineering, 2017, 28(11): 1339—1345.
- [7] 蒲子玺, 殷红, 张楠, 等. 基于峭度准则VMD及平稳小波的轴承故障诊断[J]. 机械设计与研究, 2017, (1): 67—71.
- [7] Pu Zixi, Yin Hong, Zhang Nan, et al. Bearing fault diagnosis using VMD and stationary wavelet method based on kurtosis criterion[J]. Machine Design & Research, 2017, (1): 67—71.
- [8] 邓飞跃, 唐贵基. 基于时间-小波能量谱样本熵的滚动轴承智能诊断方法[J]. 振动与冲击, 2017, 36(9): 28—34.
- [8] Deng Feiyue, Tang Guiji. An intelligent method for rolling element bearing fault diagnosis based on time-wavelet energy spectrum sample entropy[J]. Journal of Vibration and Shock, 2017, 36(9): 28—34.
- [9] Gilles J. Empirical wavelet transform[J]. IEEE Transactions on Signal Processing, 2013, 61(16): 3999—4010.
- [10] 陈浩, 郭军海, 齐巍. 基于经验小波变换的目标加速度估计算法[J]. 北京航空航天大学学报, 2015, 41(1): 154—159.
- [10] Chen Hao, Guo Junhai, Qi Wei. Estimation of target's acceleration based on empirical wavelet transform[J]. Journal of Beijing University of Aeronautics and Astronautics, 2015, 41(1): 154—159.
- [11] 彭富强, 于德介, 罗洁思, 等. 基于多尺度线调频基稀疏信号分解的轴承故障诊断[J]. 机械工程学报, 2010, 46(7): 88—95.
- [11] Peng Fuqiang, Yu Dejie, Luo Jiesi, et al. Sparse signal decomposition method based on multi-scale chirplet and its application to bearing fault diagnosis[J]. Journal of Mechanical Engineering, 2010, 46(7): 88—95.
- [12] 胡爱军, 孙敬敬, 向玲. 经验模态分解中的模态混叠问题[J]. 振动、测试与诊断, 2011, 31(4): 429—434.
- [12] Hu Aijun, Sun Jingjing, Xiang Ling. Modal aliasing in empirical mode decomposition[J]. Journal of Vibration,

- Measurement & Diagnosis, 2011, 31(4): 429—434.
- [13] Lee J, Qiu H, Yu G, et al. Bearing data set, NASA Ames prognostics data repository (<http://ti.arc.nasa.gov/project/prognostic-data-repository>) [R]. NASA Ames Research Center, Moffett Field, CA.
- [14] Qiu Hai, Lee Jay, Lin Jing, et al. Wavelet filter-based weak signature detection method and its application on rolling element bearing prognostics [J]. Journal of Sound & Vibration, 2006, 289(4): 1066—1090.
- [15] 张 龙, 黄文艺, 熊国良. 基于多尺度熵的滚动轴承故障程度评估[J]. 振动与冲击, 2014, 33(9): 185—189.
- [15] Zhang Long, Huang Wenyi, Xiong Guoliang, et al. Assessment of rolling element bearing fault severity using multi-scale entropy [J]. Journal of Vibration and Shock, 2014, 33(9): 185—189.

## WIND TURBINE BEARING DETERIORATION TREND IDENTIFICATION AND FAULT DIAGNOSIS BASED ON EWT-MDS

Tan Yuan<sup>1</sup>, Sun Wenlei<sup>1</sup>, Wen Guangrui<sup>2</sup>, Huang Xin<sup>2</sup>

(1. School of Mechanical Engineering, Xinjiang University, Urumqi 830047, China;

2. School of Mechanical Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

**Abstract:** In order to solve the low identification accuracy of deterioration trend of wind turbine bearings and difficult problem of early fault diagnosis, a EWT-MDS method based on empirical wavelet decomposition and multidimensional scaling transform is proposed. Firstly, the method performs the adaptive empirical wavelet decomposition of the whole life cycle vibration signals of the bearings. The variation characteristics of various modal components are quantitatively analyzed by using information entropy as an index; then the multi-dimensional scaling transform algorithm is used to obtain the synergistic variation rule of each degradation component in high-dimensional space, which has a large improvement in detection efficiency and precision compared with the conventional method. The simulation and experimental results show that the proposed method can detect the nodal points of abnormal state of bearings in advance, and can accurately identify the early fault type of bearings through the time domain reconstruction of modal components characterized by bearing degradation and combining the spectrum and the envelope spectrum.

**Keywords:** wind turbines; bearings; fault diagnosis; deterioration trend; empirical wavelet transform