

# 基于 AVMD 与 Teager 能量算子的风电机组故障 诊断方法\*

时培明<sup>1</sup>, 伊思颖<sup>1</sup>, 张慧超<sup>1</sup>, 范雅斐<sup>1</sup>, 韩东颖<sup>2</sup>

(1.燕山大学电气工程学院 秦皇岛,066004)

(2.燕山大学车辆与能源学院 秦皇岛,066004)

**摘要** 为解决变分模态分解(variational mode decomposition,简称VMD)在噪声情况下提取风电机组故障特征时因参数设置的人为经验不足而带来的误差问题及耗费时间的问题,提出一种基于自适应变分模态分解(adaptive variational mode decomposition,简称AVMD)算法的风电机组故障诊断方法。首先,将包络熵-峭度-互信息准则(envelope entropy, kurtosis and mutual information,简称EKM)作为黏菌算法(slime mold algorithm,简称SMA)的适应度函数来寻找最优解,并按照最优解对故障信号进行分解;其次,计算每个固有模态函数分量(inherent modal function,简称IMF)的峭度和与原信号的互信息,选择具有故障特征的分量进行重构;最后,通过Teager能量算子解调来识别风电机组故障特征频率。仿真信号和实际风电机组故障信号表明,所提方法能够找到故障频率及其倍频,验证了其在风电机组故障诊断领域中的有效性。

**关键词** 自适应变分模态分解;黏菌算法;包络熵-峭度-互信息准则;Teager能量算子

**中图分类号** TH133.3;TS737<sup>+</sup>.1

## 引言

目前,我国风电产业在经过快速扩张后遇到了部件损坏、机组寿命难以估计等问题,针对风电机组的修复研究得到了学者们的广泛关注。实际采集的风电机组故障信号含有大量的噪声,且易受其他因素的干扰,导致信号采集微弱且不稳定,所以提取故障频率是风电机组故障诊断的难点。

Dragomiretskiy等<sup>[1]</sup>提出变分模态分解算法,与经验模态分解(empirical mode decomposition,简称EMD)相比,VMD解决了端部效应、模态混合的问题。唐贵基等<sup>[2]</sup>使用粒子群优化算法与VMD相结合,搜寻到包络值最小的最优参数解,实现了VMD的自适应,但实际信号的故障频率并不明显。除了用优化算法寻找VMD的最优解外,使用构建新型自相关函数的方法<sup>[3-4]</sup>也能确定分解参数。马增强等<sup>[5]</sup>通过VMD分解故障信号,并根据峭度准则重构信号,再计算Teager能量谱,通过实际数据证明了方法的有效性,但没有解决VMD的参数问题,有一定的误差。孟宗等<sup>[6]</sup>通过能量占比确定了VMD的分解数,有效避免了虚假分量的产生。时培明等<sup>[7]</sup>

提出了一种VMD与变尺度多稳随机共振相结合的方法,经实例分析验证了方法的可行性。武英杰等<sup>[8]</sup>在研究风电机组故障诊断时,将VMD,EMD及局部均值分解(local mean decomposition,简称LMD)进行了对比,结果表明,VMD相对于EMD和LMD可以避免模态混叠问题,但不适合提取信号中的高频成分。

笔者提出一种自适应变分模态分解算法。首先,将VMD与SMA<sup>[9]</sup>相结合,以提出的复合指标函数为适应度函数,采用与Teager能量算子解调相结合的方法来提取风电机组轴承的故障特征;其次,通过仿真信号与实际风电机组实验数据的对比,证明该方法可以找到诊断频率及倍频,同时提高了诊断效率。所提方法解决了传统EMD的模态混叠及VMD参数选择困难的问题,能够有效提取冲击特征,在风电机组的轴承故障诊断领域有较好的效果。

## 1 改进的自适应变分模态分解方法

笔者提出一种新的指标来对分解效果进行定量评估,即包络熵-峭度-互信息准则,用EKM的最

\* 河北省自然科学基金资助项目(F2024203035);湖北省工程研究中心开放课题资助项目(IDICP-KF-2024-10)

收稿日期:2022-06-24;修回日期:2022-11-02

小值作为优化算法的适应度函数来寻求最优解。其公式为

$$\min(\text{fitness}) = \min\left(\dot{E}_p * \frac{1}{K_u - 3.5} * \frac{1}{MI}\right) \quad (1)$$

$$\begin{cases} K = N \sum_{i=1}^N (x_i - \bar{x})^4 / \left( \sum_{i=1}^N (x_i - \bar{x})^2 \right)^2 \\ K_u = \max\{K_{uk}\} \end{cases} \quad (2)$$

$$\begin{cases} p_j = a(j) / \sum_{i=0}^N a(j) \\ E_p = - \sum_{j=1}^N p_j \lg(p_j) \end{cases} \quad (3)$$

$$\begin{cases} \bar{E}_p = \sum_{i=1}^K E_p / K \\ \text{MI}(X, Y) = H(X) - H(X|Y) \\ \delta_i = \text{MI}_i / \max(\text{MI}_i) \end{cases} \quad (4)$$

其中: $\bar{E}_p$ 是分解为 $k$ 个IMF分量的包络熵的平均值; $K_u$ 是分解为 $k$ 个IMF分量中峭度最大的值;MI为 $K$ 个IMF分量与原信号的互信息值。

AVMD是将SMA以VMD分解的EKM作为黏菌算法的适应度函数,SMA的数学模型如下。

阶段1:黏菌通过空气中的气味来寻找食物,即

$$X(t+1) = \begin{cases} X_b(t) + v_b(WX_A(t) - X_B(t)) & (r < p) \\ v_c X(t) & (r \geq p) \end{cases} \quad (5)$$

其中: $v_b$ 的范围为 $[-a, a]$ ;  $v_c$ 的范围为 $[0, 1]$ 并呈线性递减; $t$ 为当前迭代次数; $X_b$ 为当前迭代中发现的气味浓度最高的个体方位; $X$ 为黏菌的位置; $X_A, X_B$ 为随机选择的2个黏菌的方位; $W$ 为权重。

$P, a$ 和 $W$ 的计算公式为

$$p = \tan h|S(i) - D_F| \quad (i = 1, 2, \dots, n) \quad (6)$$

其中: $S(i)$ 为每个黏菌的适应度; $D_F$ 为迭代过程中的最佳适应度。

$$a = \arctan h \left( - \left( \frac{t}{\max_t} \right) + 1 \right) \quad (7)$$

$$W(S_{\text{mellIndex}}) = \begin{cases} 1 + r \log \left( \frac{b_F - s(i)}{b_F - w_F} + 1 \right) & (C_{\text{condition}}) \\ 1 - r \log \left( \frac{b_F - s(i)}{b_F - w_F} + 1 \right) & (\text{其他}) \end{cases} \quad (8)$$

$$S_{\text{mellIndex}} = \text{sort}(S) \quad (9)$$

其中: $C_{\text{condition}}$ 为适应度值排在种群数前1/2的个体; $r$ 为在 $[0, 1]$ 上的随机数; $\max_t$ 为最大迭代次数; $b_F, w_F$ 为当前迭代中的最优和最差适应度值; $S_{\text{mellIndex}}$ 为排序后的适应度值序列。

阶段2:包围食物。搜索食物时,黏菌体内会受到食物浓度的影响产生一种信号。黏菌静脉接触的食物浓度越高,体内产生的波越强,细胞质流动越快,静脉变得越粗。当食物浓度较高时,该区域附近的权重较大;当食物浓度较低时,该区域的权重会降低。更新黏菌位置的计算公式为

$$W^* = \begin{cases} r_{\text{and}}(U_B - L_B) & (r_{\text{and}} < z) \\ X_b(t) + v_b(WX_A(t) - X_B(t)) & (r < p) \\ v_c X(t) & (r \geq p) \end{cases} \quad (10)$$

其中: $L_B, U_B$ 分别为搜索范围的上、下边界值; $r_{\text{and}}, r$ 为 $[0, 1]$ 中的随机数。

SMA以EKM为适应度函数找到最优解后,按照最优参数进行VMD模态分解,从而达到最好的效果。VMD约束变分问题可构造为

$$\begin{aligned} \min_{\{h_k\}, \{\omega_k\}} & \left\{ \sum_k \left\| -j\omega \left[ \delta(t) + j \frac{1}{\pi t} \right] * h_k(t) \right\|_2^2 \right\} \\ \text{s.t.} & \sum_{k=1}^K h_k(t) = x(t) \end{aligned} \quad (11)$$

其中: $\{h_k\}$ 为VMD分解得到的所有IMF函数的集合; $\{\omega_k\}$ 为VMD分解得到的各个IMF函数中心角频率的集合; $x(t)$ 为原始信号。

构建一个增广拉格朗日函数,引入拉格朗日乘法算子 $\lambda(t)$ 和二次约束因子 $\alpha$ ,则增广拉格朗日乘子的表达式为

$$\begin{aligned} L(\{h_k\}, \{\omega_k\}, \lambda) = & \alpha \sum_k \left\| -j\omega_k \left[ \delta(t) + j \frac{1}{\pi t} \right] * h_k(t) \right\|_2^2 + \\ & \left\| x(t) - \sum_k h_k(t) \right\|_2^2 + \langle \lambda(t), x(t) - \sum_k h_k(t) \rangle \end{aligned} \quad (12)$$

上述非约束问题可以通过交替方向乘子法来解决,随后的模态 $h_k^{n+1}$ 、中心频率 $\omega_k^{n+1}$ 和拉格朗日乘法算子 $\lambda_k^{n+1}$ 的更新如下

$$h_k^{n+1}(\omega) = \frac{\hat{x}(\omega) - \sum_{i \neq k} \hat{h}_i(\omega) + \hat{\lambda}(\omega)/2}{1 + 2\alpha(\omega - \omega_k)^2} \quad (13)$$

$$\omega_k^{n+1}(\omega) = \int_0^\omega \omega |\hat{h}_k(\omega)|^2 d\omega / \int_0^\omega |\hat{h}_k(\omega)|^2 d\omega \quad (14)$$

$$\hat{\lambda}^{n+1}(\omega) \leftarrow \hat{\lambda}^n(\omega) + \tau \left( \hat{f}(\omega) - \sum_k \hat{h}_k^{n+1}(\omega) \right) \quad (15)$$

笔者提出的AVMD算法流程图如图1所示。首先,初始化SMA的各个参数,包括黏菌个数、最大迭




图1 AVMD算法流程图

Fig.1 AVMD algorithm flow chart

代次数、维数以及优化参数的上、下界;其次,计算复合指标函数,更新黏菌位置;然后,再次计算复合指标函数并进行比较,得到最小值保存,进入下一次迭代过程;最后,到达最大迭代次数,保存最小值并结束。

## 2 基于Teager能量算子解调的AVMD方法

为了有效提取出故障信号,笔者引入2个指标作为信号重构的判断依据,分别为峭度值和互信息。另外,引入3个指标对AVMD进行量化分析,分别为信噪比、排列熵和模糊熵。信噪比是衡量信号与噪声比例效果的重要指标,其定义为

$$\text{SNR} = 10\lg(P_S/P_N) \quad (16)$$

其中: $P_S, P_N$ 分别为信号和噪声的有效功率。

排列熵作为衡量时间序列复杂程度的指标,越规则的时间序列其对应的排列熵越小,即

$$\text{PE}(m, t) = - \sum_{l=1}^{n-(m-1)t} p_l \ln p_l \quad (17)$$

其中: $p_l$ 为重构符号序列; $m$ 为嵌入维数; $t$ 为延迟参数。

模糊熵用来度量模糊集的模糊性,其定义为  $\text{FuzzyEn}(n, m, r) =$

$$\lim_{M \rightarrow \infty} [\ln o^n(m, r) - \ln o^{n+1}(m, r)] \quad (18)$$

其中: $n$ 为采样序列按照序号的连续顺序重构的一组矢量的维数; $m, r$ 分别为模糊指数函数边界的梯度和宽度。

假设一离散信号 $x(n)$ ,其Teager能量算子的定义为

$$\phi[x(n)] = x^2(n) - x(n-1)x(n+1) \quad (19)$$

其中: $n$ 为离散采样点数; $n+1$ 和 $n-1$ 分别为与 $n$ 相邻的2个点。

对AVMD方法分解得到的各模态分量进行Teager计算,可得到各模态分量的瞬时频率 $f(n)$ 和瞬时幅值 $A(n)$ 。对 $A(n)$ 进行频道分析,可得到各模态分量的Teager包络谱 $A = \text{DFT}[A(n)]$ ,其中DFT表示离散傅里叶变换。

笔者提出的AVMD-Teager算法流程如图2所示。原始信号的输入数据经归一化处理后输入到AVMD中,并计算每组 $(K, a)$ 的VMD对应的EKM。在SMA优化空间内,寻找最小的EKM值,最后返回 $K$ 和 $a$ 并保存。根据最佳参数分解得到的 $K$ 个IMF分量的峭度和互信息值,选择除互信息最大的分量外,峭度值大于3的IMFs中大于平均值的IMFs进行重构,新信号经过Teager能量算子进行解调以得到明显的冲击成分,最终识别故障频率。




图2 AVMD-Teager算法流程图

Fig.2 AVMD-Teager algorithm flow chart

## 3 仿真数据

为了验证本研究模型的有效性,采用模拟信号进行仿真实验。设 $x(t)$ 为单一周期冲击信号,加入-5 dB白噪声来模拟轴承故障, $A$ 为均值为1.1、方差为0.5的随机数, $C$ 为200,信号的采样点数为6 000,采样频率为12 kHz,故障频率为50 Hz,冲击信号的周期数为25。仿真信号如图3所示。将上述仿真信号分别采用笔者提出的基于SMA的AVMD与基于灰狼优化算法(grey wolf optimization algorithm,简称GWO)的AVMD自适应变分模态分解算法、人为参数设定的变分模态分解算法进行运算,对得到的结果进行分析比较,有

$$\begin{cases} x(t) = \sum_i A h(t - iT - \tau_i) + n(t) \\ h(t) = \exp(-Ct) \sin(2\pi f_n t) \end{cases} \quad (20)$$

用AVMD方法对原始信号进行分解,首先需要




图 3 仿真信号  
Fig.3 Simulation signal

初始化 GWO 和 SMA 的各个参数。优化算法初始化设置如表 1 所示。2 种优化算法的收敛过程和对比如表 2 和图 4 所示。可见,2 种方法都根据 EKM 提取出了最优解,且结果是相近的,但 SMA 自适应优化算法比 GWO 自适应优化算法速度更快。

表 1 仿真数据优化算法初始化设置

| Tab.1 Optimization algorithm initialization settings of simulation data |           |           |
|-------------------------------------------------------------------------|-----------|-----------|
| 变量                                                                      | SMA       | GWO       |
| SearchAgents_no                                                         | 15        | 15        |
| MaxIteration                                                            | 50        | 50        |
| dim                                                                     | 2         | 2         |
| lb                                                                      | [2,1 000] | [2,1 000] |
| ub                                                                      | [8,2 000] | [8,2 000] |
| fitness                                                                 | EKM       | EKM       |

表 2 仿真数据 2 种优化算法的对比

| Tab.2 Comparison of two optimization algorithms of simulation data |         |             |         |             |
|--------------------------------------------------------------------|---------|-------------|---------|-------------|
| 算法                                                                 | $K$     | $\alpha$    | EKM     | $t/s$       |
| SMA                                                                | 5.018 9 | 1 503.166 5 | 0.006 9 | 979.898 0   |
| GWO                                                                | 4.751 9 | 1 476.127 2 | 0.006 9 | 2 028.634 0 |




图 4 仿真数据 2 种优化算法的收敛过程  
Fig.4 Convergence process of two optimization algorithms of simulation data

根据 2 种算法的最佳优化解,取  $K=5, \alpha=1\ 480$  输入到 VMD 中进行分解。AVMD 与 EMD 分解信号对比如图 5 所示。根据笔者提出的信号重构判断依据,AVMD 各 IMF 分量峭度值及互信息值见表 3。EMD 各 IMF 分量峭度值见表 4。根据峭度准则,峭度值大于 3 被认为是故障分量,因此重构 IMF<sub>2</sub>,IMF<sub>3</sub>,IMF<sub>4</sub>和 IMF<sub>7</sub>分量,最后再用 Teager 能量算子进行解调。AVMD 与 EMD 重构信号的 Teager 解调频率对比如图 6 所示。由图可以看出故障频率及其多倍频,但 EMD-Teager 方法没有 AVMD-Teager 方法的效果好。




图 5 AVMD 与 EMD 分解信号对比

Fig.5 Comparison of AVMD and EMD decomposed signals

2 种方法的量化指标对比如图 7 所示。由图可见,AVMD 相较于 EMD 信噪比得到提高,2 种熵值

表 3 仿真数据 AVMD 各 IMF 分量峭度值及互信息值  
Tab.3 The kurtosis value and mutual information value of each IMF component of AVMD of simulation data

| IMF | IMF <sub>1</sub> | IMF <sub>2</sub> | IMF <sub>3</sub> | IMF <sub>4</sub> | IMF <sub>5</sub> |
|-----|------------------|------------------|------------------|------------------|------------------|
| 峭度值 | 2.997 2          | 3.036 4          | 3.129 6          | 2.730 2          | 2.879 4          |
| 互信息 | 0.083 2          | 0.104 9          | 0.135 3          | 0.117 1          | 0.119 7          |

表 4 EMD 各 IMF 分量峭度值  
Tab.4 The kurtosis value of each IMF component of EMD

| IMF <sub>1</sub> | IMF <sub>2</sub> | IMF <sub>3</sub> | IMF <sub>4</sub> | IMF <sub>5</sub> |
|------------------|------------------|------------------|------------------|------------------|
| 2.497 9          | 3.011 9          | 3.133 5          | 3.192 4          | 2.728 3          |
| IMF <sub>6</sub> | IMF <sub>7</sub> | IMF <sub>8</sub> | IMF <sub>9</sub> |                  |
| 2.388 1          | 3.452 0          | 2.666 8          | 2.016 2          |                  |




图 6 AVMD 与 EMD 重构信号的 Teager 解调频率对比  
Fig.6 Comparison of Teager demodulation frequency between AVMD and EMD reconstructed signals

变小,在不改变故障特征的情况下有效平稳了信号。通过以上分析可以得出,笔者提出的基于 SMA 的 AVMD 比基于 GWO 的 AVMD 速度更快,减少了人为经验带来的误差及时间的浪费,在信号特征提取方面表现也很突出,具有一定的优越性。




图 7 仿真数据 2 种方法的量化指标对比  
Fig.7 Two methods of quantitative indicators of simulation data

4 实际数据

本节使用的数据来源于河北麒麟山风电机组,采用的是华锐 SL-1500 型机组,其风机为二级行星轮。机组结构模型如图 8 所示。传感器每隔 4 h 左右进行 1 次数据记录,经过振动分析可找出不同类型的故障数据。根据轴承型号计算得到发电机前轴承的外圈损伤故障频率为 94.53 Hz,转频为 30.20 Hz;发电机后轴承外圈损伤故障频率为 69.53 Hz,转频为 24.08 Hz;发电机后轴所在轴不对中旋转频率为 29.69 Hz。采样频率为 12.8 kHz,采样时间为 0.312 5 s。




图 8 机组结构模型  
Fig.8 Unit structural model

设采样点数为 4 000,本研究分别选择发电机前轴、后轴轴承的外圈损伤数据以及发电机所在轴不对称、不对中数据作为样本。原始数据时频域如图 9 所示。其中,后轴轴承的外圈损伤信号具有明显的周期冲击,且该信号和发电机所在轴不对称、不对中信号中有许多的噪声干扰。笔者以这 3 种信号来验证所提模型的有效性,并与 EMD 算法进行了对比。

分别利用提出的 SMA 优化 AVMD 参数方法、GWO 优化 AVMD 参数方法以及 EMD 法进行实验分析对比。首先,采用 2 种优化算法的 AVMD 对 3 种故障信号分解参数进行寻优,优化算法初始化设置见表 5,种优化算法的对比见表 6。




图 9 原始数据时频域

Fig.9 Time frequency domain of raw data

表 5 实际数据优化算法初始化设置

Tab.5 Optimization algorithm initialization settings of actual data

| 变量              | SMA       | GWO       |
|-----------------|-----------|-----------|
| SearchAgents_no | 50        | 50        |
| MaxIteration    | 100       | 100       |
| dim             | 2         | 2         |
| lb              | [3,2 000] | [3,2 000] |
| ub              | [8,8 000] | [8,8 000] |
| fitness         | EKM       | EKM       |


表 6 实际数据 2 种优化算法的对比

Tab.6 Comparison of two optimization algorithms of actual data

| 故障类型  | 算法  | K         | $\alpha$  | EKM       | t/s       |
|-------|-----|-----------|-----------|-----------|-----------|
| 前轴外圈  | SMA | 7.023 8 5 | 207.134 2 | 0.001 4 1 | 503.898 0 |
|       | GWO | 7.412 6 5 | 123.605 4 | 0.001 2 2 | 997.630 4 |
| 后轴外圈  | SMA | 7.759 1 4 | 654.416 8 | 0.003 4 1 | 456.488 4 |
|       | GWO | 6.648 6 4 | 548.943 1 | 0.002 8 2 | 679.497 4 |
| 后轴不对中 | SMA | 7.684 5 1 | 279.468 7 | 0.002 6 1 | 359.667 7 |
|       | GWO | 6.999 7 1 | 344.498 4 | 0.002 9 2 | 968.954 6 |


根据 2 种算法的优化结果,分别选定以下参数组合对 3 种信号进行分解:① $K=7, \alpha=5150$ ;② $K=7, \alpha=4600$ ;③ $K=7, \alpha=1320$ 。3 种信号的 AVMD 分解结果如图 10 所示。AVMD 各 IMF 分量峭度值及互信息值见表 7。根据提出的信号重构判断依据,前轴外圈信号选择 IMF<sub>1</sub>和 IMF<sub>2</sub>分量、后轴外圈信号选择 IMF<sub>7</sub>分量、后轴不对中信号选择 IMF<sub>4</sub>和 IMF<sub>7</sub>分量作为重构信号。EMD 分解信号后,选取峭度值大于 3 的分量进行重构。3 种信号的 EMD 分解结果如图 11 所示。

2 种方法的量化指标对比如图 12 所示。其中, $x$ 轴上方为 AVMD 分解后效果; $x$ 轴下方为 EMD 分




(a) 发电机前轴外圈故障信号 AVMD 分解结果

(a) The fault signal of the outer ring of the front axle of the generator is decomposed by AVMD



(b) 发电机后轴外圈损伤信号 AVMD 分解结果

(b) The fault signal of the outer ring of the rear axle of the generator is decomposed by AVMD



(c) 发电机后轴不对中信号 AVMD 分解结果

(c) The signal of generator rear axle misalignment is decomposed by AVMD

图 10 3 种信号的 AVMD 分解结果


Fig.10 Three kinds of signal by AVMD decomposition

表 7 实际数据 AVMD 各 IMF 分量峭度值及互信息值  
Tab.7 The kurtosis value and mutual information value of each IMF component of actual data


| 指标               | 前轴外圈信号  |         | 后轴外圈信号  |         | 后轴不对中   |         |
|------------------|---------|---------|---------|---------|---------|---------|
|                  | $K_u$   | MI      | $K_u$   | MI      | $K_u$   | MI      |
| IMF <sub>1</sub> | 3.642 1 | 0.039 5 | 1.599 2 | 0.018 5 | 2.011 8 | 0.155 0 |
| IMF <sub>2</sub> | 3.630 4 | 0.083 5 | 4.279 2 | 0.128 4 | 3.174 8 | 0.028 1 |
| IMF <sub>3</sub> | 1.874 8 | 0.241 6 | 2.177 0 | 0.305 3 | 2.806 8 | 0.042 9 |
| IMF <sub>4</sub> | 1.922 5 | 0.287 8 | 1.713 8 | 0.351 9 | 3.931 9 | 0.134 2 |
| IMF <sub>5</sub> | 2.796 7 | 0.088 2 | 1.677 6 | 0.326 0 | 4.211 5 | 0.043 7 |
| IMF <sub>6</sub> | 3.561 9 | 0.052 0 | 2.500 7 | 0.068 1 | 2.247 7 | 0.263 3 |
| IMF <sub>7</sub> | 2.927 8 | 0.077 4 | 4.292 4 | 0.060 7 | 3.897 2 | 0.105 9 |

解后效果。为了更直观地看出结果,将 2 种熵值扩大了 10 倍,使数值范围在 0~20。可见,AVMD 相较于 EMD 信噪比得到了提高,2 种熵值变小,在不改变故障特征的情况下有效地平稳了信号。


将重构后的信号通过 Teager 能量算子进行解调。2 种方法的 Teager 包络谱对比如图 13 所示,图中 BPFO 表示滚珠通过外圈时产生的频率。由图可见,AVMD 将 3 种故障频率以及倍频都找了出来,后轴外圈故障信号频率尤为明显,能看到其多倍频,并且和理论上的故障频率一致。EMD 方法幅值相对 AVMD 更小,且后轴不对中信号转频倍频不明



(a) 发电机前轴外圈故障信号的 EMD 分解结果  
(a) The fault signal of the outer ring of the front axle of the generator is decomposed by EMD



(b) 发电机后轴外圈故障信号的 EMD 分解结果  
(b) The fault signal of the outer ring of the rear axle of the generator is decomposed by EMD



(c) 发电机后轴不对中信号的 EMD 分解结果  
(c) The signal of generator rear axle misalignment is decomposed by EMD

图 11 3 种信号的 EMD 分解结果  
Fig.11 Three kinds of signal by EMD decomposition







图 12 实际数据 2 种方法的量化指标对比  
Fig.12 Two methods of quantitative indicators of actual data



(a) AVMD 模型与 EDM 模型前轴外圈故障信号包络谱对比  
(a) Comparison of envelope spectrum of front axle outer ring fault signal between AVMD model and EDM model



(b) AVMD 模型与 EDM 模型后轴外圈故障信号包络谱对比  
(b) Comparison of envelope spectrum of rear axle outer ring fault signal between AVMD model and EDM model



(c) AVMD模型与EMD模型后轴不对中包络谱对比

(c) Comparison of rear axle misalignment envelope spectrum between AVMD model and EMD model

图13 2种方法的Teager包络谱对比

Fig.13 Comparison of Teager spectral envelope of two methods

显,说明所提出的AVMD及信号重构在故障特征提取方面具有不错的效果。

## 5 结 论

1) 提出了一种自适应变分模态分解与Teager能量算子相结合的方法,并将其应用到轴承信号的故障特征提取上,通过仿真数据和实际风电机组数据进行了实验验证。

2) 该方法可以根据信号本身的信息有效地确定分解的本征模态数 $K$ 和惩罚参数 $\alpha$ ,解决了人为经验参数设置的困扰。

3) 提出新的适应度函数指标,通过实验验证了该指标在AVMD分解效果上的优越性。结合新的优化算法SMA来寻求AVMD的最优解,相比于其他优化算法,SMA速度更快。

## 参 考 文 献

- [1] DRAGOMIRETSKIY K, ZOZZO D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.
- [2] 唐贵基, 王晓龙. 参数优化变分模态分解方法在滚动轴承早期故障诊断中的应用[J]. 西安交通大学学报, 2015, 49(5): 73-81.  
TANG Guiji, WANG Xiaolong. Parameter optimized variational mode decomposition method with application to incipient fault diagnosis of rolling bearing[J]. Journal of Xi'an Jiaotong University, 2015, 49(5): 73-81. (in Chinese)
- [3] 卿宗胜, 高云鹏, 吴聪, 等. 基于自适应VMD和改进功率谱估计的球磨机负荷特征提取[J]. 仪器仪表学报, 2020, 41(5): 234-241.  
QING Zongsheng, GAO Yunpeng, WU Cong, et al.

Feature extraction method of ball mill load based on the adaptive variational mode decomposition and the improved power spectrum analysis[J]. Chinese Journal of Scientific Instrument, 2020, 41(5): 234-241. (in Chinese)

- [4] LIAN J A, LIU Z, WANG H J, et al. Adaptive variational mode decomposition method for signal processing based on mode characteristic[J]. Mechanical Systems and Signal Processing, 2018, 107: 53-77.
- [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.  
MA Zengqiang, LI Yachao, 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. (in Chinese)
- [6] 孟宗, 吕蒙, 殷娜, 等. 基于改进变分模态分解的滚动轴承故障诊断方法[J]. 计量学报, 2020, 41(6): 717-723.  
MENG Zong, LÜ Meng, YIN Na, et al. Fault diagnosis method of rolling bearing based on improved variational mode decomposition[J]. Acta Metrologica Sinica, 2020, 41(6): 717-723. (in Chinese)
- [7] 时培明, 苏晓, 袁丹真, 等. 基于VMD和变尺度多稳随机共振的微弱故障信号特征提取方法[J]. 计量学报, 2018, 39(4): 515-520.  
SHI Peiming, SU Xiao, YUAN Danzhen, et al. A new feature extraction method of weak fault signal based on VMD and re-scaling multi-stable stochastic resonance[J]. Acta Metrologica Sinica, 2018, 39(4): 515-520. (in Chinese)
- [8] 武英杰, 甄成刚, 刘长良. 变分模态分解在风电机组故障诊断中的应用[J]. 机械传动, 2015, 39(10): 129-132.  
WU Yingjie, ZHEN Chenggang, LIU Changliang. Application of variational mode decomposition in wind power fault diagnosis[J]. Journal of Mechanical Transmission, 2015, 39(10): 129-132. (in Chinese)
- [9] LI S M, CHEN H L, WANG M J, et al. Slime mould algorithm: a new method for stochastic optimization[J]. Future Generation Computer Systems, 2020, 111: 300-323.



第一作者简介: 时培明, 男, 1979年9月生, 博士、教授。主要研究方向为机械故障诊断。

E-mail: spm@ysu.edu.cn