DOI: 10. 13382/j. jemi. B1902687

旋转机械状态非线性特征提取及状态分类*

李 江1 李 春2 许子非2 金江涛2

(1. 黔南民族职业技术学院 管理学院 都匀 558022; 2. 上海理工大学 能源与动力工程学院 上海 200093)

摘 要:为提取淹没于环境和结构噪声下风力机轴承故障信号,基于能量追踪法,提出改进变分模态分解法(improved variational mode decomposition, IVMD),并采用粒子群算法求解最优约束因子,获取准确模态分量;摒弃传统对故障特征频分量的提取,基于非线性分形理论提出多重分形谱特征因子(multi-fractal spectrum, MFC)以选取最具非线性特征的模态分量,以不同故障程度 及状态的轴承加速度信号为对象,采用优化递归变分模态分解获取多分量,通过多重分形谱特征因子最大值选取有效信息分量,通过支持向量机进行故障分类。结果表明优化递归变分模态分解可准确分解振动信号至不同频段,以便故障信息提取;多重分形谱特征因子与信噪比呈正相关,以其最大值选取的分量具备更多有效信息;对 IVMD-MFC 所选取非线性分量,通过 8 种非线性特征值构建特征矩阵,通过 BP 神经网络实现故障分类,诊断准确度达 97.5%。表明所提出方法可对不同故障程度的轴 承状态进行区分。

关键词: 变分模态分解;非线性;信息提取;状态分类

中图分类号: TP306.3 文献标识码: A 国家标准学科分类代码: 460.1520

Nonlinear feature extraction and state classification for rotating machine

Li Jiang¹ Li Chun² Xu Zifei² Jin Jiangtao²

(1. School of Management, Qiannan Nationality Professional Technology College, Duyun 558022, China;2. Energy and Power Engineering Institute, University of Shanghai for Science and Technology, Shanghai 200093, China)

Abstract: In order to extract the wind turbine bearing fault signal submerged under environmental and structural noise, a recursive variational mode decomposition method is proposed based on the energy tracking method, and the particle swarm optimization algorithm is used to solve the optimal constraint factor to obtain the accurate modal component. Based on the nonlinear fractal, the theory proposes a multifractal spectral feature factor to select the best modal component. Taking the fault degree and the loaded bearing acceleration signal as the object, the optimized recursive variational mode decomposition is used to obtain multiple components. The effective information component is selected by the maximum value of the multifractal spectral feature factor, and the fault classification is performed by the support vector machine. The results show that the optimized recursive variational mode decomposition; the multifractal spectrum feature factor is positively correlated with the signal to noise ratio, and the component selected by its maximum value has more effective information; The BPNN is used to classified the hybrid fault degrees of different states, the test samples are constructed by selected components by IVMD-MFC with eight nonlinear characteristics. The diagnostic accuracy is 97.5%. There is a good performance in hybrid fault degree of different status classification.

Keywords: variational mode decomposition; nonlinearity; feature extraction; state classification

收稿日期:2019-10-21 Received Date: 2019-10-21

^{*}基金项目:贵州省高校人文社科项目(2018ZC097)资助

0 引言

随着风电机组日渐大型化,其结构复杂性及环境非 稳定性导致风力机转子、齿轮及轴承等重要传动部件变 得易损。滚动轴承是风电传动系统重要的零部件之一, 其健康状态直接影响风力机发电性能^[1]。当轴承出现损 伤或故障时,轻则停机维护,重则出现灾难性事故^[2]。因 此,需对风力机传动系统的机械部件进行状态监测及早 期故障诊断,以减少风力机停机时间及维修成本,对提高 风电场运行可靠性及经济性尤为重要^[3]。

振动信号法广泛应用于风电机组传动链的运行状态 监测^[4]。但因风的随机性与风力机传动部件振动的耦合 导致振动数据具有非线性、非稳定性及强噪声背景等特 点,以至于故障特征频率混叠,难以提取,成为故障诊断 的挑战性问题^[5]。因此,在强背景噪声中准确提取故障 特征为风力机滚动轴承故障诊断难点且具重要意义^[6]。

基于轴承振动信号的强非线性高噪声背景,传统的 经验模态分解(empirical mode decomposition, EMD)因包 络叠加导致模态分解失效,从而难以准确提取故障信 息^[7-9]。Dragomiretskiy 等^[10]所提出的变分模态分解 (variational mode decomposition, VMD)方法可有效解决类 EMD 方法中模态混淆及端点效应,已被应用于滚动轴承 故障诊断中^[11-13]。文献[14]采用 VMD 方法与包络谱相 结合对滚动轴承早期故障进行研究,结果表明该方法对 微弱故障信号提取的有效性。文献[15]采用谱峭度与 VMD 方法对早期轴承故障信号进行提取,分析包络谱中 特征频率以实现故障诊断。Li 等^[16]将 VMD 法与深度神 经网络相结合对齿轮箱进行故障分析,结果显示该方法 具有良好的准确率及鲁棒性。Huang 等^[17]采用 VMD 方 法对高铁轴承振动信号进行分解,并通过包络分析进行 故障诊断。Chen 等^[18]采用 VMD 方法对风力机轴承振 动信号进行分解获得多阶模态,将分量的能量熵作为特 征值进行机器学习分类,结果表明 VMD 能量熵法可准确 进行风力机轴承的故障诊断。值得注意的是,采用 VMD 方法时,中心频率初值选择影响计算速率,分解个数与惩 罚因子取值组合决定了处理效果^[19]。但以上研究采用 VMD 方法进行信号处理时, 仅采用局部寻优的方法对分 解个数与惩罚因子进行优化,从而忽略参数间互交性:构 建特征向量时也欠考虑因机械设备复杂性及环境非稳定 性导致的振动信号非线性^[20]。

因此,针对以上问题,以滚动轴承不同故障程度,4 种状态的加速度信号为研究对象,以目标信号功率谱最 值作为中心频率初值,提升分解速率;基于能量追踪法将 原属变分问题的 VMD 算法改进为递归 VMD 方法,避免 预设分解数对处理效果的影响;又采用粒子群算法 (PSO)求取最优惩罚因子,保证优化 VMD 分解精度与效 率。摒弃传统目标提取故障特征频分量的方法,以非线 性信息为目标,基于多重分形可描述信号结构特征及非 线性局部动力学行为的特点^[21],考虑全标度下的多重分 形特性,提出多重分形谱特征因子(multi-fractal spectrum,MFC),选取经 IVMD 分解所获的有限带宽本征 模态分量(band-limited intrinsic mode function, BIMF)中 有效信号分量,选取 8 中非线性特征值,构建基于 IVMD-MFC 所提取分类的特征矩阵,采用 BP 神经网络(BP neural network, BPNN)对 3 种故障程度、4 种轴承状态进 行分类,实现故障诊断。与传统研究切入点不同,改提取 方法重点在于提取轴承非线性信息,并非凸显轴承故障 特征频,为风力机传动系统故障诊断及微弱非线性信息 提取提供理论基础与实现途径。

1 IVMD

1.1 VMD 算法

基于维纳滤波、Hilbert 变换及外差解调形成 VMD 算 法。VMD 可将信号 f(t) 分解为 K 个离散模态 $u_k(k = 1, 2, 3, \dots, K)$ 。 与 EMD 算法不同, u_k 的频带具有稀疏特 性, 属 AM-FM (amplitude modulation-frequency modulation) 信号, 对于抑制 EMD 类方法出现的模态混淆 现象效果显著。VMD 算法中涉及约束变分模型为:

$$\begin{cases} \min_{\|u_k\| \le \omega_k} \left\{ \sum_{k=1}^{K} \| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) \times u_k(t) \right] e^{-j\omega_k t} \|_2^2 \right\} \\ \text{s. t. } \sum_k u_k = f \end{cases}$$
(1)

式中: $\{u_k\} = \{u_1, u_2, \dots, u_k\} = \{\omega_1, \omega_2, \dots, \omega_k\}$ 分别为分解数*K*及相应中心频率; $\delta(t)$ 为单位脉冲函数; j表示虚数单位;×表示卷积运算; ∂_t 为偏导运算;*f*为目标信号。

引人惩罚因子 α 和 Lagrange 乘子 λ 以求解变分约束问题。所得增广 Lagrange 表达式如下:

$$L(\{u_k\},\{\omega_k\},\lambda) = \alpha \sum_{k=1}^{K} \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) \cdot u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_{k=1}^{K} u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_{k=1}^{K} u_k(t) \right\rangle$$
(2)

采用交替方向乘子算法(alternate direction method of multipliers, ADMM)更新迭代求解式(2) 鞍点, 在频域内 迭代更新 u_k, ω_k 及 λ_o

- VMD 将信号分解为 K个模态分量,其步骤如下。
- 1) 初始化 $\{\hat{u}^1\}$ 、 $\{\hat{\omega}^1\}$ 、 $\hat{\lambda}^1$ 和 n 为 0。
- 2) u_k 和 ω_k 分别有式(3)、(4) 迭代更新。

$$\hat{u}_{k}^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i=1}^{k-1} \hat{u}_{i}^{n+1}(\omega) - \sum_{i=k+1}^{k} \hat{u}_{i}^{n}(\omega) + \frac{\hat{\lambda}_{i}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_{k}^{n})^{2}}$$
(3)

$$\omega_k^{n+1} = \frac{\int_0^{\omega} |\hat{u}_k^{n+1}(\omega)|^2 \mathrm{d}\omega}{\int_0^{\infty} |\hat{u}_k^{n+1}(\omega)|^2 \mathrm{d}\omega}$$
(4)

式中: τ 为保真系数; < 表示傅里叶变换; n 为迭代次数。 3)根据式(5)更新 λ。

$$\hat{\lambda}^{n+1}(\omega) = \hat{\lambda}^{n}(\omega) + \tau \left(\hat{f}(\omega) - \sum_{k=1}^{K} \hat{u}_{k}^{n+1}(\omega) \right)$$
(5)

4) 重复步骤 2) 和 3), 至满足迭代终止条件:

 $\sum_{k=1}^{n} \left(\| \hat{u}_{k}^{n+1}(\omega) - \hat{u}_{k}^{n}(\omega) \|_{2}^{2} / \| \hat{u}_{k}^{n}(\omega) \|_{2}^{2} \right) < \varepsilon \quad (6)$ 式中: ε 为判别精度, 且 $\varepsilon > 0_{\circ}$

5) 输出 *K* 个模态分量。

J) 相山A 丨 侠芯刀

1.2 PSO 算法

PSO 算法由 Eberhart 等受鸟群觅食行为启发所提出^[22]。在 PSO 算法中,每个粒子具有相应的速度与位置以调整自身的状态,粒子的位置代表待优化问题的潜在解。

PSO 算法数学描述如下。

在 D 维空间中,存在由 m 个粒子组成的种群,第 i 个 粒子在 D 维空间中的位置向量为 $X_i = (x_{i1}, x_{i2}, \dots, x_{iD})^{\mathrm{T}}$, 其速度向量为 $V_i = (v_{i1}, v_{i2}, \dots, v_{iD})^{\mathrm{T}}$,第 i 个粒子的最佳位 置由向量 $P_i = (p_{i1}, p_{i2}, \dots, p_{iD})^{\mathrm{T}}$ 表示,种群的最佳位置由 向量 $P_g = (p_{g1}, p_{g2}, \dots, p_{gD})^{\mathrm{T}}$ 表示,速度与位置的更新由式 (7)、(8)所示。

$$v_{id}^{k+1} = \omega v_{id}^{k} + c_1 \eta (p_{id} - x_{id}^{k}) + c_2 \eta (p_{gd} - x_{id}^{k})$$
(7)
$$x_{id}^{k+1} = x_{id}^{k} + v_{id}^{k+1}$$
(8)

式中:i=1,2,...,m;d=1,2,...,D;k为当前进化代数; c_1 与 c_2 为学习因子; ω 为惯性权重; η 为[0,1]内随机数。

1.3 IVMD 算法

1) 改进变分模型

与属递归分解 EMD 类算法,VMD 具有较高的准确 性与稳定性。但 EMD 类方法无需预设分解模态个数,通 过停止条件即可完成自动分解。因此,借鉴 EMD 递归思 想,提出一种递归 VMD 算法,各 BIMF 分量通过 VMD 变 分模型求解,通过能量截止法设定停止条件,实现递归 VMD 算法。该递归 VMD 算法不仅可抑制因求解包络线 误差叠加导致的失真,而且可实现自动分解,无需预设分 解模态个数 K。

基于传统 VMD 算法,初设分解个数 K=1 的约束变 分模型,获得一个 BIMF 分量,将式(1)转化为式(9)。

$$\left\{ \min_{u,\omega} \left\{ \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) \times u(t) \right] e^{-j\omega t} \right\| \right\} \\
\text{s. t. } u = f$$
(9)

引人惩罚因子 α 和 Lagrange 乘子 λ 后,式(2)将变 为式(10),式(5)与(6)将转换为式(10)与(11),其余步 骤与经典 VMD 算法相同。

$$L(u_k, \omega_k, \lambda) = \alpha \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) \times u(t) \right] e^{-j\omega_k t} \right\|_2^2 + (\lambda) \left(\frac{j}{2} + \frac{j}{2} \right) \left(\frac{j}{2} +$$

$$\|f(t) - u(t)\|_{2}^{2} + \langle \lambda(t), f(t) - u(t) \rangle$$

$$(10)$$

$$\hat{u}^{n+1}(\omega) = \frac{\hat{f}(\omega) - \hat{\lambda}(\omega)/2}{1 + 2\alpha(\omega_0 - \omega)^2}$$
(11)

$$\boldsymbol{\omega}^{n+1} = \frac{\int_{0}^{\infty} \boldsymbol{\omega} | \hat{\boldsymbol{u}}(\boldsymbol{\omega}) |^{2} \mathrm{d}\boldsymbol{\omega}}{\int_{0}^{\infty} | \hat{\boldsymbol{u}}(\boldsymbol{\omega}) |^{2} \mathrm{d}\boldsymbol{\omega}}$$
(12)

采用 ADMM 算法时,中心频率 ω_k 需预先给出。而 Dragomiretskiy 等^[10]提出三种初始化中心频率的方法(为 零、线性及随机初值化)均有一定的局限性。其中线性初 值具有较好的准确性与稳定性,但由于 K=1 将导致线性 化失败,即与 $\omega_k = 0$ 情况相同。因此,提出以目标信号功 率密度 谱 (power density spectrum, PSD) 最大值作为 ω_k 初值。

2)停止准则

由于 Wu 等^[23]与文献[24]提出的停止准则均不适 用于 VMD 算法,因此,采用 Cheng 等^[25]提出的能量差追 踪法应用于本文所提出的改进变分模型。基于能量差追 踪法的 VMD 停止准则如下。

假设目标信号 f(t) 分解后所得 BIMF 分量 $u_k(t)$ 具有正交性,由式(13)所示,总能量表达式为式(14)。

$$f(t) = u_1(t) + u_2(t) + \dots + u_n(t) = \sum_{k=1}^n u_k(t) \quad (13)$$

$$E_{x} = \int_{-\infty}^{\infty} f^{2}(t) dt = \int_{-\infty}^{\infty} \left[\sum_{k=1}^{n} u_{k}(t) \right]^{2} dt$$
(14)

式中: E_x 为原信号能量;

因各 BIMF 分量具正交性,式(13)可表示为:

$$E_{x} = \int_{-\infty}^{\infty} \left[\sum_{k=1}^{n} u_{k}(t) \right]^{2} dt =$$

$$\int_{-\infty}^{\infty} u_{1}(t) dt + \int_{-\infty}^{\infty} u_{2}(t) dt + \dots + \int_{-\infty}^{\infty} u_{n}(t) dt =$$

$$E_{1} + E_{2} + \dots + E_{n}$$
(15)

式中: $E_1 + E_2 + \cdots + E_n$ 为各 BIMF 分量的能量。

当 BIMF 分量完全正交时,各 BIMF 能量之和 E_{total} 应 与原信号能量 E_x 相等:

$$E_{\text{total}} = E_1 + E_2 + \dots + E_n = E_x \tag{16}$$

但当 BIMF 分量不完全正交时, E_{total} 与 E_x 之间存在 误差 E_{xr} :

$$E_{err} = E_x - E_{\text{total}} = E_x - (E_1 + E_2 + \dots + E_n) \quad (17)$$

能量误差 E_{err} 越接近 0,表明分解效果越好。因此, 令 $|E_{err}|$ 为停止准则,当 $|E_{err}|$ 小于收敛阈值时停止迭 代,并获取最佳分解个数 K_{o}

3) 递归 VMD 算法

基于以上提出的改进变分模型及能量截止法收 敛条件,递归 VMD 算法流程如图 1 所示,具体流程 如下。

1) 通过计算目标信号的 PSD,以 PSD 最大值对应的 频率最为中心频率 ω_{initial}。

 采用步骤 1) 获取的中心频率进行迭代,并预设 K=1 以获取式(9)的变分模型,并通过式(10)与(11)分 别获取 u_k 与 ω_k。

3) 采用步骤 2) 获取的 *u_k* 作为 BIMF 分量,将*f* - *u_k* 作为新目标信号并重复步骤 1) 与 2)。

4) 对于分解所得 BIMF 分量,通过式(17) 计算能量 误差 $|E_{err}|$,当 $|E_{err}|$ 小于收敛阈值时停止分解并获取 全部 BIMF 分量。根据计算经验,采用 $|E_{err}| \leq [(0.7 - 2.0)\%]E_x$ 为收敛阈值。



图 1 递归 VMD 流程

Fig. 1 The recursive VMD diagram

1.4 优化递归 VMD

尽管递归 VMD 算法可自适应选取合适分解模态数 K,但为求解非约束性变分问题而引入惩罚因子 α 若取 值不当,将导致信号分解失效^[26]。因此,以能量误差 $|E_{err}|$ 为寻优过程的适应度函数,将适应度函数取值最 小作为寻优目标,基于 PSO 算法对改进递归 VMD 的最 优 α 选取流程如图 2 所示。



图 2 PSO 优化 VMD 参数流程



1) 初始化 PSO 算法各项变量并确定寻优过程中的 适应度函数 |*E*_{er}|,以惩罚因子作为粒子位置,并随机初 始化粒子移动速度。

2) 在不同粒子位置条件下对信号进行递归 VMD 处

理,获该位置下信号能量误差 $|E_{er}|$,以此作为对应粒子的适应度函数。

3) 对比各粒子适应度函数大小(优劣),若有粒子的 适应度函数 | *E*_{err} | 小于当前最小适应度函数,则对粒子 进行更新。

4) 通过式(7)与(8)更新粒子属性。

5)判断粒子是否满足种群进化停止条件,若不满足则重复步骤 2)继续寻优,直到满足最大种群进化预设值,输出最佳粒子,即为最优惩罚因子α。

2 MFC 及诊断流程

2.1 多重分形谱特征因子

滚动轴承初期的故障信号由于损伤微弱,正常部件 与损伤部位接触产生冲击较弱,并存在结构振动及环境 噪声的干扰,传感器获取的振动信号信噪比较低。

分形维数在描述非线性信号中取得良好效果^[27],但 因其只能刻画单测度下非线性特征,从而选取多重分形 度量非线性特性,多重分形较单分形具备更优的非线性 状态识别能力。

对于淹没于环境噪声与耦合机械振动的早期滚动轴 承故障信号,由于微弱冲击信号分量难以通过峭度准确 选取,且其强非线性导致传统特征参数难以对故障分量 作出判断。因此,为了弥补峭度选取故障信号分量的不 足,基于多重分形谱^[28]提出基于 MFC 以搜寻最优分量。 MFC 可反应系统非线性特征,其定义如下:

$$Mc = \frac{\max X(q)}{\sqrt{\sum_{i=-Q}^{Q} X(q)^2 / N}}$$
(18)

式中: *X*(*q*) 为多重分形谱值,*q* 为权重因子,其取值范围为[-Q,Q];*N* 为数据长度。

2.2 诊断流程

针对风力机轴承故障信号遭受环境、结构噪声影响, 采用提出 IVMD-MFC-SVM 对轴 3 种故障程度、4 种故障 状态进行故障分类,其步骤如图 3 所示。



图 3 IVMD-MFC-BPNN 故障诊断 Fig. 3 Fault diagnosis based on IVMD-MFC

3 仿真信号分析

3.1 IVMD 可靠性验证

为验证所提出的 IVMD 方法的有效性,采用两个低频信号及间断高频信号合成仿真冲击信号 f(t)。 每隔 0.2 s 向 10 Hz 正弦信号 $f_2(t) = \sin(20\pi t)$ 和 80 Hz 正弦 信号 $f_3(t) = 0.65\sin(160\pi t)$ 加入持续时间 0.05 s, 240 Hz 的正弦信号 $f_1(t) = 0.25\sin(480\pi t)$,采样频率为 2 048 Hz,采样时长为 1 s。冲击信号及其分量波形图如 图 4 所示。





采用 PSO 算法对改进递归 VMD 优化所得分解模态 数 K=3,最优惩罚因子 $\alpha = 500$ 。分解结果如图 5 所示, 与原信号各模态的相关系数如表 1 所示。





表 1 BIMF 与原始模态相关系数 Table 1 The correlation coefficient between

the original component mode and BIMF

原始信号	f_1	f_2	f_3
ρ	0.992	0.949	0.928

由图 5 和表 1 可知,当 α = 500,*K* = 3 时,采用 IVMD 分解效果较好,各 BIMF 分量与原始模态的相关系数均 大于 90%,表明 IVMD 具有良好的分解效果。

3.2 MFC 有效性验证

为验证 MFC 在早期故障分量选取的有效性,采用以 下模型^[29]模拟轴承内圈早期局部损伤振动信号 *x*(*t*):

$$\begin{cases} t_{k} = t - kT - \tau_{k} \\ m(t) = 1 - A_{0}\cos(2\pi f_{r}t) \\ h(t_{k}) = \sum_{-\infty}^{+\infty} e^{-c(t_{k})} \cdot \cos(2\pi f_{n}(t_{k})) \cdot U(t_{k}) \\ s(t) = m(t) \cdot h(t_{k}) \\ x(t) = s(t) + n(t) \end{cases}$$
(19)

式中: s(t) 为周期性冲击信号; n(t) 为高斯噪声;信号 衰减指数 C=1000;系统共振频率 $f_n=5000$ Hz; τ_k 表示 第 k 次冲击相对于特征周期的小波动,该随机波动服从 均值为0,标准差为0.5% 转频的正态分布;特征频率 $f_r =$ 120 Hz。 $U(t_k)$ 为单位阶跃函数。加入高斯噪声信号后 得信噪比为-12 dB 的仿真信号。采样频率为16000 Hz, 采样点 N=4096。加入噪声前后的时域及频谱如图 6 所示。

如图 6 所示,轴承早期内圈损伤振动信号,在时域及 频域内均被噪声淹没,无法准确的区分故障特征频率。 因此,采用本文所提出的 IVMD 对轴承早期内圈含噪故 障信号进行处理,其中最优分解参数为α=17 200,K=7, 所得时域及频域结果如图 7 所示。

由图7可知,各 BIMF 分量频谱中在不同频段出现波





Fig. 7 Each BIMF components in time and frequency domain

峰,与图 6(b)对比,本文所提出的 IVMD 分解方法已将 目标信号从噪声环境中区分。由 7(d)可知,BIMF4 时域 波形最为清晰,并由其频谱可知主频多集中在低频段,蕴 含与仿真故障信号特征频率相近信息,可视为有效信号 分量。而由图 7(g)中可看出,分量 BIMF7 的频谱波峰主 要集中在 5 000 Hz 附近,与系统共振频率相近,可视为局 部损伤导致的系统共振对应的分量信号。

峭度对冲击信号较为敏感,已有研究表明,当峭度大 于3时,冲击信号明显,视为有效的故障分量,因此,分别 计算 BIMF,~BIMF,的峭度,结果如表2 所示。

表 2 各 BIMF 峭度 Table 2 The kurtosis of each BIMF

BIMF	1	2	3	4	5	6	7
峭度	3.00	3.26	2.96	2.69	3.40	2.90	2.78

由图 7(d) 与表 2 可知,对于 BIMF4 分量频谱中波峰 均集中在低频段,与故障特征频率相近,但其峭度值并未 达冲击信号筛选标准(峭度=3)。因此,仅凭峭度难以准 确选出故障信号分量。

早期內圈故障,因损伤的瑕点并不明显,从而随转频 变换的故障特征频率对应的波峰亦不显著,因此,凭借峭 度选取故障特征频率会产生误选或漏选^[30]。从信号波 形看,信号属典型非线性信号,传统特征值无法准确描述 其非线性特征。

分别计算轴承内圈仿真故障信号^[30]在不同噪声环 境下的 MFC 值,其结果如图 8 所示。



Fig. 8 Shock signal and its component waveform

由图 8 可知, MFC 值随信噪比增大而增大, 当信噪比 达 20 dB 时, MFC 值接近 1.9。信噪比-MFC 趋势线可说 明,随着信噪比的增高, MFC 增大。因此, 以 MFC 值判别 故障分量信号的非线性及其蕴含有效信息程度是有效可 靠的。

因此, 计算各 BIMF 分量的 MFC 值, 结果如表 3 所示。

表 3 各 BIMF 多重分形谱特征因子 Table 3 The MFC of each BIMF

BIMF	1	2	3	4	5	6	7
MFC	1.89	1.85	1.78	1.93	1.71	1.76	1.73

由表 3 可得,BIMF4 的 MFC 最大,为 1.93,其频谱也 在低频段有大量波峰,表明此分量为有效的故障特征分 量,对于不同的故障特征,MFC 值越大,表明蕴含非线性 信号越多。因此,筛选 IVMD 分解所获分量 MFC 最大值 为有效分量,进行进一步故障分析。

4 实验结果与分析

实验数据选用凯斯西储大学的轴承振动信号^[31],数 据采样频率为12 000 Hz,电机负载为0 Hp,选用叶片端 轴承正常、滚珠、内圈及外圈故障加速度信号,并采用 IVMD-BPNN 对不同故障程度分别为 0.007、0.014 与 0.021 in 轴承不同状态进行分类。

为体现本文所提出的基于 IVMD-MFC 故障信息提取 的有效性,随机选取样本时,为避免随机性对结果的影 响,其中,准确率均为运行 30 次后的平均准确率,且由于 篇幅原因,仅展示部分神经网络分类结果图。

4.1 故障信息非线性测度分析

首先,为验证本文提出非线性信息的准确性、有效性 及可靠性,对不同故障程度的轴承状态进行 IVMD-MFC 信息提取,对提取信息如图 9 所示。

如图 9 所示,经 IVMD-MFC 提取的非线性信息, 虽然部分振动信号不具备故障特征频率,但不同状态 振动形式区分明显。因早期故障信号微弱,通常故障 特征频不明显,传统基于提取故障特征频的方法失其 准确性(例如,当轴承内圈故障微弱时,特征频不明 显,但在共振频处有波峰)。因此,采用非线性差别来 描述振动信号,为直观表现提取信号的非线性差别, 采用分形盒维数作为特征量,计算 50 组经 IVMD-MFC 提取,不同故障程度及状态的和分形维数,结果 如图 10 所示。

如图 10 所示,不同故障程度,经 IVMD-MFC-盒维数 已能区分,验证了本文提出的非线性提取方法的有效性 和准确性,该方法着眼于系统、信号的非线性,摒弃传统 基于故障特征频的提取,为表明该方法的普适性,采用 BPNN 对不同故障程度及混合故障程度进行非线性状态 分类,结果如下。

4.2 混合程度故障

以往研究仅对比分析相同故障程度时故障类型的分类,为表明提出方法的普适性,选用故障程度不同,4种 轴承工作状态的信号作为研究对象,采所提出的 IVMD-MFC 提取有效非线性信息,通过分形维数、样本熵和近 似熵等非线性特征量,基于被选非线性分量构建特征向 量,归一化后进行 BPNN 分类。其 BPNN 分类结果如图 11 所示,非线性向量如表4 所示。



图 9 非线性信息提取结果





Table 4 Nonlinear feature matrix

标签	状态	盒维数	模糊熵	近似熵	样本熵	排列熵	信息熵	关联维	条件熵
0	Normal	-0.170	-0.390	-0.381	-0.254	-0.171	-0.563	-0.549	-0.254
1	Ball	-0.881	-0.025	-0.245	0. 253	0.326	0. 235	0.003	0.253
2	Inner race	0.120	-0.705	-0.814	-0.965	-0.942	0.149	-0.396	-0.965
3	Outer race	0.130	-0.008	-0.392	0.210	0. 285	0.257	-0.533	0.210





由图 11 可知,对于混合故障程度,基于 IVMD-MFC 筛选分量,采用 8 种非线性特征值构成的测试集,采用 BPNN 进行分类,预测原本与真实样本具有较高的吻合 度,分类具有较好的准确性,准确度达 97.5%。表明本文 基于 IVMD-MFC 提取故障信息方法在轴承故障分类有效 性及准确性。

5 结 论

为提升旋转机械故障诊断精度,本文提出一种基于 能量追踪法与 PSO 算法的优化递归变分模态分解方法, 以更准确地实现振动解耦,并基于多重分形谱提出全局 无标度性 MFC 值,以提取模态分量中非线性代表量。与 峭度值不同,以 MFC 值提取的特征并不着眼于冲击信 号,而是为了获取信号中自相似性较强的非线性特征。 以提取模态的 8 种非线性特征值作为特征样本,供神经 网络进行学习并分类,实现旋转机械的故障诊断。

参考文献

- [1] QIAO W, LU D. A survey on wind turbine condition monitoring and fault diagnosis-part II: Signals and signal processing methods [J]. IEEE Transactions on Industrial Electronics, 2015, 62(10): 1-1.
- [2] LI C, SANCHEZG V, ZURITA G, et al. Rolling element bearing defect detection using the generalized synchrosqueezing transform guided by time-frequency ridge enhancement [J]. ISA Transactions, 2015(60): 274-284.
- [3] 唐贵基,庞彬,刘尚坤.基于奇异差分谱和平稳子空间 分析的滚动轴承故障诊断[J].振动与冲击,2015, 34(11):83-87.

TANG G J, PANG B, LIU SH K. Fault diagnosis of rolling bearings based on difference spectrum of singular value and stationary subspace analysis [J]. Journal of Vibration and Shock, 2015, 34(11): 83-87.

- [4] NIE M, WANG L. Review of condition monitoring and fault diagnosis technologies for wind turbine gearbox[J].
 Procedia Cirp 2013(11): 287-290.
- [5] LEI J H, LIU C, JIANG D X. Fault diagnosis of wind turbine based on long short-term memory networks [J]. Renewable Energy, 2019, 133: 422-432.
- [6] LV J, YU J. Average combination difference morphological filters for fault feature extraction of bearing[J]. Mechanical Systems and Signal Processing, 2018, 100: 827-845.
- YEH J R, SHIEH J S, HUANG N E. Complementary ensemble empirical mode decomposition: A novel noise enhanced data analysis method [J]. Advanced in Adaptive Data Analysis, 2010, 2(2): 135-156.
- [8] LIU H, ZHANG J, CHENG Y, et al. Fault diagnosis of gearbox using empirical mode decomposition and multifractal detrended cross-correlation analysis [J]. Journal of Sound and Vibration, 2016,385(?):350-371.
- [9] LU L, YAN J, De SILVA C W. Dominant feature selection for the fault diagnosis of rotary machines using modified genetic algorithm and empirical mode decomposition [J]. Journal of Sound and Vibration, 2015, 344: 464-483.
- [10] DRAGOMIRETSKIY K, ZOSSO D. Variational Mode Decomposition [J]. IEEE Transactions on Signal Processing, 2014, 62(3):531-544.
- [11] 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.

LI H, WU X, LIU T, et al. Bearing fault feature extraction based on VMD optimized with information entropy [J]. Journal of Vibration and Shock, 2018, 37(23):219-225.

- [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.
 LI H, WU X, LIU T, et al. Bearing fault feature extraction based on VMD optimized with information entropy[J]. Journal of Vibration and Shock, 2018,37(23):219-225.
- [13] GONG T, YUAN X, YUAN Y, et al. Application of tentative variational mode decomposition in fault feature detection of rolling element bearing [J]. Measurement, 2018(135):481-491.
- [14] 唐贵基,王晓龙.变分模态分解方法及其在滚动轴承 早期故障诊断中的应用[J].振动工程学报,2016, 29(4):638-648.
 TANG G J, WANG X L. Variational mode decomposition method and its application on incipient fault diagnosis of rolling bearing [J]. Journal of Vibration Engineering,
- [15] 唐贵基,刘尚坤. 基于 VMD 和谱峭度的滚动轴承早期 故障诊断方法[J]. 中国测试,2017,43(9):112-117.
 TANG G J, LIU S K. Incipient fault diagnosis method for rolling bearing based on VMD and spectral kurtosis[J].
 China Measurement & Test, 2017, 43(9): 112-117.

2016, 29(4): 638-648.

- [16] LI Y, CHENG G, LIU C, et al. Study on planetary gear fault diagnosis based on variational mode decomposition and deep neural networks [J]. Measurement, 2018, 130:94-104.
- [17] HUANG Y, LIN J H, LIU Z C, et al. A modified scalespace guiding variational mode decomposition for high speed railway bearing fault diagnosis [J]. Journal of Sound and Variation, 2019(444): 216-234.
- [18] CHEN X J, YANG Y M, CUI Z X, et al. Vibration fault diagnosis of wind turbines based on variational mode decomposition and entropy [J]. Energy, 2019 (174): 1100-1109.
- [19] BI F, LI X, LIU C C, et al. Knock detection based on the optimized variational mode decomposition [J]. Measurement, 2019(140):1-13.
- [20] 李永健,刘吉华,张卫华,等.改进样本熵及其在列车 轴承损伤检测中的应用[J].仪器仪表学报,2018, 39(9):179-186.
 - LI Y J, LIU J H, ZHANG W H, et al. Improved sample

entropy and its application in the detection of train bearing damage [J]. Chinese Journal of Scientific Instrument, 2018, 39(9): 179-186.

- [21] 李颖. 多重分形信号特征提取及在往复压缩机故障诊断中的应用[D]. 大庆:东北石油大学,2015.
 LI Y. Multifractal signal feature extraction and its application in fault diagnosis of reciprocating compressor[D]. Daqin: Northeast Petroleum University, 2015.
- [22] KENNEDY J. Particle swarm optimization [C]. Encyclopedia of Machine Learning. Boston: Springer, 2011.
- [23] 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.
- [24] 黄骏,何永勇. 经验模态分解停止准则及在故障诊断中的应用[J]. 机械强度,2011,33(5):27-31.
 HUANG J, HE Y Y. Empirical mode decomposition stopping criterion and its application in fault diagnosis[J]. Journal of Mechanical Strength, 2011,33(5): 27-31.
- [25] CHENG J S, YANG Y, YANG Y. A rotating machinery fault diagnosis method based on local mean decomposition [J].
 Digital Signal Processing, 2012, 22(2): 356-366.
- [26] 吕中亮.基于变分模态分解与优化多核支持向量机的 旋转机械早期故障诊断方法研究[D].重庆:重庆大 学,2016.

LV ZH L. Research on incipient fault diagnosis method for rotating machinery based on VMD and optimized MSVM [D]. Chongqing: Chongqing University, 2016.

[27] 李洋,李春,杨阳,等.基于分形学的轴承故障诊断分析[J].热能动力工程,2017,32(12):73-77.

LI Y, LI C, YANG Y, et al. Bearing diagnosis and analysis based on fractal [J]. Journal of Engineering for Thermal Energy and Power, 2017, 32(12): 73-77.

[28] 王浩天,段修生,单甘霖,等.一种基于 ILCD 融合与多 重分形去趋势波动分析的退化特征提取方法[J].振 动与冲击,2019,38(6):233-238.

WANG H T, DUAN X SH, SHAN G L, et al. Method for degradation feature extraction based on the ILCD fusion and multi fractal detrended fluctuation analysis [J]. Journal of

Vibration and Shock, 2019, 38(6): 233-238.

- [29] MCFADDEN P D, SMITH J D. Model for the vibration produced by a single point defect in a rolling element bearing [J]. Journal of Sound and Vibration, 1984, 96(1):69-82.
- [30] GLOWACZ A, GLOWACZ W, GLOWACZ Z, et al. Early fault diagnosis of bearing and stator faults of the single-phase induction motor using acoustic signals [J]. Measurement, 2018, 113: 1-9.
- [31] RAUBER T W, FRANCISCO D A B, VAREJAO F M. Heterogeneous feature models and feature selection applied to bearing fault diagnosis[J]. IEEE Transactions on Industrial Electronics, 2015, 62(1): 637-646.

作者简介



李江,1989年于贵州师范大学获得学 士学位,现为黔南民族职业技术学院副教 授,主要研究方向为体育工程学、运动人体 科学、体育管理和体育教育训练。

E-mail:lijiangjiang1234@ sina. com

Li Jiang received his B. Sc. degree from Guizhou Normal University in 1989. Now he is an associate professor of Qiannan Nationality Professional Technology College. His main research interest includes sports engineering, sports human science, sports management and physical education training.



李春(通信作者),分别在1985年、1988 年和1991年于哈尔滨工业大学获得学士学 位、硕士学位和博士学位,现为上海理工大 学教授、博士生导师,主要从事动力机械及 流体机械优化设计、风能利用等方面研究 工作。

E-mail:Lichunusst@163.com

Li Chun (Corresponding author) received his B. Sc., M. Sc. and Ph. D. degrees all from Harbin Institute of Technology in 1985, 1988 and 1991, respectively. Now, he is a professor and Ph. D. supervisor at University of Shanghai for Science and Technology. His main research interest includes power machinery and fluid machinery optimization design and wind energy utilization.