

基于改进参数自适应 VME 的轴承故障诊断方法^{*}

李翠省¹, 刘文朋², 王宝森³

(1. 河北工业职业技术大学汽车工程学院 石家庄, 050091)

(2. 石家庄铁道大学省部共建交通工程结构力学行为与系统安全国家重点实验室 石家庄, 050043)

(3. 石家庄铁道大学机械工程学院 石家庄, 050043)

摘要 针对强背景噪声下轴承故障难以有效辨识的问题,提出了一种改进的参数自适应变分模态提取(variational mode extraction, 简称 VME)方法。VME 提取轴承故障特征的能力与其初始参数密切相关。为提升 VME 关键参数设定的自适应性与准确性,首先,在 VME 收敛趋势图的基础上提出了中值负熵指标,用于筛选故障敏感分量,以确定最佳初始中心频率(initial center frequency, 简称 ICF);其次,以中值负熵为基础构建目标函数,指引算术优化算法(arithmetic optimization algorithm, 简称 AOA)进行全局寻优,以获取最优惩罚因子;然后,使用参数优化的 VME 提取出目标分量,对目标分量进行包络谱分析,用于提取故障特征频率;最后,通过分析高速列车轴箱轴承实测信号,验证所提方法的有效性,并与 Infogram 和自适应变分模态分解方法进行了比较。结果表明,所提方法具备更加出色的故障辨识性能。

关键词 轴承;故障诊断;变分模态提取;中值负熵;算术优化算法

中图分类号 TH17

0 引言

滚动轴承作为机械设备中的关键旋转部件,具有减轻摩擦、传递动力等重要作用。然而,轴承在服役过程中常处于高速、重载等环境,其组成元件如内圈、外圈、滚动体等易出现故障,影响设备运行安全^[1]。因此,对轴承开展早期故障识别研究具有重要意义。

机械系统在运行过程中会承受多种激励,使得振动信号中普遍存在多个具有不同特性的子信号。其中,轴承微弱的故障特征信号常被背景噪声或其他信号所淹没,导致难以准确识别故障特征^[2]。因此,需采用信号分析技术对采集的振动信号进行处理。经验模态分解(empirical mode decomposition, 简称 EMD)方法是一种应用于机械故障诊断领域的经典自适应信号分解方法。针对 EMD 方法存在的模态混叠、边界效应、缺乏数学理论支撑等不足,研究人员提出了多种改进算法,包括总体经验模态分解、局部均值分解、经验小波变换、变分模态分解(variational mode decomposition, 简称 VMD)等^[3]。其中,VMD 方法具备完善的数学理论基础,且可有效改善 EMD 的模态混叠和端点效应等问题,因而被

应用于多个学科领域。然而,模型参数包括模态个数、惩罚因子、ICF 等制约着 VMD 的性能^[4]。Ma 等^[5]运用尺度空间谱分割技术确定了 VMD 的模态个数。Zhang 等^[6]采用蝗虫优化算法(grasshopper optimization algorithm, 简称 GOA)确定模态个数和惩罚因子的最优组合,搭建了 GOA-VMD 方法。江星星等^[7]研究了 ICF 对 VMD 分解特性的影响,提出了基于收敛趋势的 VMD 方法。此外,Nazari 等^[8]在 VMD 的理论框架下创立了 VME 方法。VME 分解信号仅能得到一个特定的模态,克服了 VMD 需要设定模态个数的缺陷,运算速度更快。同时,VME 考虑了残差信号的影响,使得其提取故障信息的精度比 VMD 更高^[9]。

与 VMD 类似,VME 的性能与模型的初始关键参数密切相关,包括 ICF 和惩罚因子。郭远晶等^[10]利用 S 变换谱确定了所提取模态中心频率的初始值,却忽略了惩罚因子对模态带宽的影响。在笔者此前的研究中,使用基于故障特征系数引导的改进灰狼优化算法,获取了 ICF 和惩罚因子的最佳参数组合^[11]。然而,该方法需提前获知轴承的故障特征频率,因此较为依赖先验知识。Pang 等^[12]基于

^{*} 国家自然科学基金资助项目(12302067);河北省自然科学基金资助项目(A2024210004);河北省教育厅科学研究资助项目(QN2026526);河北工业职业技术大学博士基金资助项目(bz202504)

收稿日期:2025-05-06;修回日期:2025-07-28

EMD的递归分解思想,提出了递归VME方法,可实现多分量信号的分解。与EMD类似,该方法出现过度分解问题,且惩罚因子是根据经验公式计算获得,其值往往不是最优解。Li等^[13]借助仿真信号深入探究了VME中心频率的收敛特性,构建了VME收敛趋势图方法,实现多分量信号的完全分解,但仍缺少对故障敏感分量选取的研究。王鑫等^[14]通过理论推导证实了VME中心频率的收敛趋势现象,利用峭度指标筛选故障敏感分量。然而,峭度存在易受冲击噪声影响的不足。

基于上述背景,本研究针对轴承单一故障诊断中VME关键初始参数设置缺乏自适应性的问题,提出一种改进的参数自适应VME方法。在VME收敛趋势图的基本框架下,提出一种无需先验知识的故障信息评估指标——中值负熵,用于筛选故障敏感分量,以获取最佳ICF。同时,引入迭代速度快、寻优能力强的AOA算法^[15],用于获取最优惩罚因子。通过对高速列车轴箱轴承的实测信号进行分析,验证所提方法在轴承微弱故障识别中的有效性和优越性。

1 基于中值负熵的VME收敛趋势图

1.1 VME基本原理

VME算法的核心思想在于假定分析信号 $f(t)$ 可由期望模态 $u_d(t)$ 与残余信号 $f_r(t)$ 共同组成。期望模态 $u_d(t)$ 紧密围绕在其中心频率 ω_d 附近;同时,期望模态 $u_d(t)$ 与残余信号 $f_r(t)$ 的频谱重叠应达到最小程度。

1) VME算法的数学模型表示为

$$\min_{u_d, \omega_d, f_r} \left\{ \alpha \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_d(t) \right] e^{-j\omega_d t} \right\|_2^2 + \left\| \beta(t) * f_r(t) \right\|_2^2 \right\} \quad (1)$$

s. t. $u_d(t) + f_r(t) = f(t)$

其中: α 为惩罚因子; t 为时间; δ 为狄拉克分布; $\beta(t)$ 为所选滤波器的脉冲响应; $*$ 表示卷积运算。

2) 利用二次惩罚项与拉格朗日乘子 $\lambda(t)$ 将式(1)转化为无约束的增广拉格朗日函数,即

$$L(u_d, \omega_d, f_r, \lambda) =$$

$$\alpha \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_d(t) \right] e^{-j\omega_d t} \right\|_2^2 + \left\| \beta(t) * f_r(t) \right\|_2^2 + \left\| f(t) - (u_d(t) + f_r(t)) \right\|_2^2 + \langle \lambda(t), f(t) - (u_d(t) + f_r(t)) \rangle \quad (2)$$

3) 利用交替方向乘子法求解式(2),期望模态、中心频率的迭代表达式为

$$\hat{u}_d^{n+1}(\omega) = \frac{\hat{f}(\omega) + \alpha^2(\omega - \omega_d^n)^4 \hat{u}_d^n(\omega) + \hat{\lambda}(\omega)/2}{[1 + \alpha^2(\omega - \omega_d^n)^4][1 + 2\alpha(\omega - \omega_d^n)^2]} \quad (3)$$

$$\omega_d^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_d^{n+1}(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_d^{n+1}(\omega)|^2 d\omega} \quad (4)$$

其中: n 为迭代次数; $\hat{f}(\omega)$ 、 $\hat{u}_d(\omega)$ 、 $\hat{\lambda}(\omega)$ 分别为 $f(t)$ 、 $u_d(t)$ 、 $\lambda(t)$ 的傅里叶变换。

1.2 VME的收敛特性分析

VME算法的收敛特性较为稳定,即多个不同的ICF经过迭代更新,总会收敛到有限数量的终止中心频率。为说明该现象,根据下式构建滚动轴承局部损伤时的仿真信号,即

$$x(t) = \sum_{l=1}^L A_l s(t - lT_a - \tau_l) + \sum_{m=1}^M R_m s(t - mT_r) + \sum_{c=1}^C P_c \sin(2\pi f_c t + \varphi_c) + n(t) \quad (5)$$

其中: $\sum_{l=1}^L A_l s(t - lT_a - \tau_l)$ 是由轴承故障引起的重复瞬态; A_l 为故障冲击的幅值,其值服从均匀分布 $U=[0.5, 0.6]$; T_a 为故障周期, $T_a = 1/50$ s; τ_l 为用于模拟滚动体随机滑移引起的延迟。

式(5)中, $s(t)$ 为脉冲响应函数,表达式为

$$s(t) = e^{-\zeta t} \sin(2\pi f_0 t) \quad (6)$$

其中: ζ 为阻尼系数; f_0 为共振频率。

式(5)中, $\sum_{m=1}^M R_m s(t - mT_r)$ 为高幅值随机冲击,

作用是模拟由电磁干扰、随机碰撞等情况所产生的噪声; M 为随机冲击的个数; R_m 和 T_r 分别为随机冲击的幅值和发生时刻。 $\sum_{c=1}^C P_c \sin(2\pi f_c t + \varphi_c)$ 为用于模拟轴系旋转产生的谐波干扰, C 为谐波个数; P_c 、 f_c 、 φ_c 分别为第 c 个谐波的幅值、频率与相位。 $n(t)$ 为随机噪声,主要模拟轴承工作时的背景噪声,表达式为

$$n(t) = 0.4 \text{randn}(1, N) \quad (7)$$

其中: N 为样本个数。

生成仿真信号时,将故障冲击和随机冲击的共振频率分别设定为2 400、4 500 Hz,采样频率为10 000 Hz,仿真时长为1 s,仿真信号的4种子信号如图1所示。将4种子信号混合,生成的仿真信号如图2所示。图2(a)为时域波形,可以看到周期性故障冲击被噪声完全淹没;图2(b)为仿真信号频谱。




图1 仿真信号的4种子信号

Fig.1 4 sub-signals of simulation signals




图2 仿真信号

Fig.2 Simulation signals

对图2(a)所示的仿真信号执行多次VME算法,惩罚因子固定为300,ICF在0~5 000 Hz的范围中逐次选取,间隔为200 Hz。期望模态在不同初始值下中心频率的迭代轨迹如图3所示。由图可知,中心频率的迭代曲线是收敛的,共收敛到3个终止中心频率,其中第2、第3个终止中心频率与仿真信号中设置的共振频率非常相近。同时,整个频带被划分为3个收敛域,在每个收敛区域内,ICF越靠近终止中心频率,其迭代次数越少,即VME提取期望模态的速度越快。




图3 不同初始值下中心频率的收敛轨迹

Fig.3 Convergence trajectories of center frequencies under different initial values

1.3 VME收敛趋势图

为快速定位最优初始中心频率ICF, Li等^[13]在VME收敛特性的基础上,提出了VME收敛趋势图方法,该方法概述如下。

1) 对测试信号执行 Q 次期望模态提取,在每次VME运算中输入不同ICF,其值在 $[0, f_s/2]$ 区域内

以步长 $\gamma=100$ Hz依次取值。 Q 的计算式为

$$Q = \text{floor}(f_s/2\gamma) + 1 \quad (8)$$

其中: floor为向下取整函数; f_s 为采样频率。

2) 每次执行VME运算,其中心频率仅迭代一次,并计算初始值与更新值之差 δ ,即

$$\delta = \omega_d^2 - \omega_d^1 \quad (9)$$

其中: ω_d^2 为中心频率初始值 ω_d^1 经过一次迭代后的更新值。

3) 将数据集 $\delta = [\delta_1, \delta_2, \dots, \delta_Q]$ 以直方图的形式展现,横坐标为ICF,纵坐标为 δ 。定位满足 $\delta_q > 0$ 且 $\delta_{q+1} < 0$ ($1 \leq q \leq Q-1$)条件的频率边界,此类边界视为最优ICF,计算式为

$$\text{ICF}_k = q\gamma - 50 \quad (10)$$

其中: ICF_k 为第 k 个最优初始中心频率值。

将上述方法应用于图2(a)所示的仿真信号,仿真信号的VME收敛趋势图见图4,耗时0.166 s。由图可知,仿真信号中存在3个主要分量,相应的初始ICF为 $\text{ICF}_1=50$ Hz, $\text{ICF}_2=2\,350$ Hz, $\text{ICF}_3=4\,550$ Hz。




图4 仿真信号的VME收敛趋势图

Fig.4 VME convergence tendency diagram of simulation signals

VME收敛趋势图是一种有效的技术手段,可快速确定信号中主要分量的个数及其ICF值。然而,该方法存在一个亟待解决的问题,即如何在多个分量中筛选出富含故障信息的分量,这也是本研究重点讨论的内容之一。为此,本研究提出了一种新指标——中值负熵。

1.4 中值负熵

对于长度为 N 的时域离散信号 $x(n)$, $n=1, 2, \dots, N$,其在频带 $(f \pm \Delta f)$ 上的平方包络为

$$\text{SE}_x(n; f, \Delta f) = \left| x(n; f, \Delta f) + jH[x(n; f, \Delta f)] \right|^2 \quad (11)$$

其中: f 为频带中心频率; Δf 为频带带宽; $H(\cdot)$ 为希尔伯特变换。

则 $\text{SE}_x(n; f, \Delta f)$ 的负熵^[16],即时域负熵定义为

$$E_{SE} = \frac{SE_x(n; f, \Delta f)^2}{\left\langle SE_x(n; f, \Delta f)^2 \right\rangle} \ln \left[\frac{SE_x(n; f, \Delta f)^2}{\left\langle SE_x(n; f, \Delta f)^2 \right\rangle} \right] \quad (12)$$

时域负熵可度量故障信号的冲击性,但其对高幅值冲击噪声异常敏感,因此无法有效评估冲击成分的周期特性。为削弱冲击噪声的影响,本研究在负熵的基础上提出一种改进指标,即中值负熵。

中值负熵的核心思想在于将时域信号等分为若干段,计算每段信号的时域负熵,进而生成数据集 D 。鉴于中值对极端值不敏感,故以数据集 D 的中值来量化重复瞬态特征,其定义为

$$ME_{SE} = \text{Median}\{E_{SE-g}\} \quad (g = 1, 2, \dots, G) \quad (13)$$

其中: ME_{SE} 为中值负熵; $\text{Median}\{\cdot\}$ 用于计算一维数组的中值; E_{SE-g} 为期望模态中第 g 个子信号的时域负熵。

式(13)中, G 为期望模态被均分的个数,其值的确定公式^[17]为

$$G = \text{ceil}\left\{\left[\log_2(\text{length}(x))\right] + 1\right\} \quad (14)$$

其中: ceil 表示对数据进行向上取整; x 为原始振动信号。

由图4可知,从仿真信号中可提取3个主要分量。各分量的时域波形、包络谱分别如图5、图6所示。由图可知,分量1富含谐波噪声,分量2富含轴承故障信息,分量3中有随机冲击噪声。




图5 各分量的时域波形

Fig.5 Time-domain waveform of each component




图6 各分量的包络谱

Fig.6 Envelope spectrum of each component

为展示所提指标的优势,分别采用中值负熵、时域负熵、峭度(kurtosis index, 简称 KI)、基尼系数(Gini index, 简称 GI)^[18]这4种故障冲击评估指标来量化图5所示的3种分量,各指标对不同信号的量化结果如表1所示。由表1可知,中值负熵在分量2中取得最大值,而时域负熵、峭度、基尼系数则在分量3

中取得最大值。因此,本研究提出的中值负熵指标仅对重复瞬态信号敏感,可有效抑制谐波干扰、随机冲击等噪声的影响,而3个对比指标则对冲击噪声较为敏感。通过上述分析,验证了中值负熵的有效性与优越性,该指标适用于从多个复杂分量中筛选富含故障信息的分量。

表1 各指标对不同信号的量化结果

Tab.1 Quantitative results of various indicators on different signals

分量	ME_{SE}	E_{SE}	KI	GI
1	0.125 0	0.129 5	2.332 2	0.373 2
2	0.197 3	0.203 0	3.237 3	0.424 1
3	0.181 5	0.561 6	41.706 3	0.436 1

进一步,本研究得出一个不失一般性的规律:针对峭度、基尼系数等评价时域信号稀疏性的指标,可以借鉴中值负熵的构建框架,提出新的指标,用于提升该类指标的噪声鲁棒性。

2 AOA 自适应优化惩罚因子

基于中值负熵的VME收敛趋势图,解决了最佳ICF选取的问题,而惩罚因子会影响期望模态的带宽,因此是VME的另一个关键参数。为此,本研究借助AOA算法的全局优化能力,以自适应获取VME的最优惩罚因子。

2.1 AOA 基本原理

1) 通过数学优化器加速函数(math optimizer accelerated, 简称 MOA, 记为 M_{MOA})与随机数 $\xi_1 \in [0, 1]$ 确定寻优阶段,若满足 $\xi_1 > M_{MOA}$,则进入全局探索阶段;若满足 $\xi_1 < M_{MOA}$,则进入局部开发阶段。 M_{MOA} 的定义为

$$M_{MOA}(z) = M_{\min} + z \frac{M_{\max} - M_{\min}}{Z} \quad (15)$$

其中: $M_{\max}$ 和 $M_{\min}$ 分别为 MOA 的最大值和最小值; z 和 Z 分别为当前迭代次数与最大迭代次数。

2) 全局探索阶段:若满足 $\xi_2 < 0.5$,则执行除法探索策略;若满足 $\xi_2 \geq 0.5$,则执行乘法探索策略。计算式为

$$x_{i,v}(z+1) = \begin{cases} (P_{\text{best}}(x_v)/(M_{\text{MOP}} + \epsilon))((U_v - L_v)\mu + L_v) & (\xi_2 < 0.5) \\ P_{\text{best}}(x_v)M_{\text{MOP}}((U_v - L_v)\mu + L_v) & (\xi_2 \geq 0.5) \end{cases} \quad (16)$$

其中: $x_{i,v}(z+1)$ 为更新后第 i 组候选解中第 v 个解;

$P_{\text{best}}(x_\nu)$ 为当前最优候选解中的第 ν 个解; ϵ 为一个极小的正数; U_ν 和 L_ν 为第 ν 个解的上、下限; μ 为调整搜索过程的控制参数,其值为0.499; ξ_2 为随机数, $\xi_2 \in [0, 1]$; M_{MOP} 为数学优化器概率(math optimizer probability, 简称MOP)。

3) 局部开发阶段:若满足 $\xi_3 < 0.5$,则执行减法探索策略;若满足 $\xi_3 \geq 0.5$,则执行加法探索策略。计算式为

$$x_{i,\nu}(z+1) = \begin{cases} P_{\text{best}}(x_\nu) - M_{\text{MOP}}((U_\nu - L_\nu)\mu + L_\nu) & (\xi_3 < 0.5) \\ P_{\text{best}}(x_\nu) + M_{\text{MOP}}((U_\nu - L_\nu)\mu + L_\nu) & (\xi_3 \geq 0.5) \end{cases} \quad (17)$$

其中: ξ_3 为随机数, $\xi_3 \in [0, 1]$ 。

2.2 中值负熵引导的AOA算法

初始化AOA的参数:种群规模为10,最大迭代次数为5。在中值负熵的基础上构建了目标函数,即

$$\begin{aligned} & \operatorname{argmin} \{-\text{ME}_{\text{SE}_\beta}\} \\ & \beta = (\alpha, \omega_d) \\ & \text{s.t. } \alpha \in [100, 10\,000] \end{aligned} \quad (18)$$

其中: $\beta = (\alpha, \omega_d)$ 为VME的参数组合; ω_d 为基于VME收敛趋势图获取的最佳ICF; $\text{ME}_{\text{SE}_\beta}$ 为期望模态在 $\beta = (\alpha, \omega_d)$ 条件下的中值负熵。

利用AOA对VME的惩罚因子展开优化,适应度值的迭代曲线如图7所示,优化得到的最大中值负熵为0.216,最优惩罚因子 $\alpha = 2\,636.4$,耗时9.68 s。为体现本研究所提方法的优势,首先,与文献[14]使用的等步长搜索算法进行比较,等步长搜索算法的寻优过程如图8所示。获得的最大中值负熵为0.215 8,最优惩罚因子 $\alpha = 2\,700$,该算法耗时15.18 s。对比发现,无论是运算速度还是搜索精度,本研究所提方法均表现更加出色。




图7 适应度值的收敛曲线

Fig.7 Convergence curve of fitness values

随后,采用文献[12]中的惩罚因子经验公式来确定 α ,即

$$\alpha = \left[1 / \left(1 + e^{\frac{z}{\log_{10} z}} \right) - 0.5 \right] \frac{f_s}{2} \quad (19)$$




图8 等步长搜索算法的寻优过程

Fig.8 Optimization process of equal-step search algorithm

其中: f_c 为模态分量的中心频率; f_s 为采样频率。

式(19)计算获得的最优惩罚因子 $\alpha = 406.24$,最大中值负熵为0.196 4。与前2种方法相比,其精度最低,说明依靠经验获取的惩罚因子往往并非最优。

3 基于改进VME的轴承故障诊断

为有效解决VME关键参数选取困难的问题,本研究提出一种改进的自适应VME方法,并将其用于滚动轴承的故障识别。首先,基于中值负熵的VME收敛趋势图用于确定最佳ICF;其次,利用AOA自适应确定最优惩罚因子。基于改进VME的轴承故障诊断流程如图9所示。




图9 基于改进VME的轴承故障诊断流程

Fig.9 Flowchart of bearing fault diagnosis based on improved VME

具体的实施步骤如下。

- 1) 采集振动信号;
- 2) 利用VME收敛趋势图分析所采集的振动信号,获得 K 个潜在分量;
- 3) 计算各分量的中值负熵,筛选出中值负熵值最大的分量,其初始中心频率值即为最佳ICF;
- 4) 将最佳ICF导入AOA,通过中值负熵引导的AOA获取最优惩罚因子;
- 5) 将最佳ICF与最优惩罚因子输入VME中,用于获取最终的目标分量;
- 6) 对目标分量进行包络谱分析,与理论故障特征频率进行对比,进而判断轴承是否存在故障及故障类型。

4 实验验证

为验证所提方法的有效性与优越性,对从铁路轴承综合实验台上采集的振动信号进行分析。实验设备如图 10 所示,测试所用轴承为高速列车轴箱轴承,其外圈上存在长约 5 mm、宽约 1 mm、深约 0.7 mm 的轻微损伤。实验时,采样频率设为 51.2 kHz,转频为 28.5 Hz。同时,为尽可能模拟轴箱轴承的真实服役环境,在轴承的垂向、轴向均施加动态载荷。根据轴承尺寸与实验工况,得到测试轴承的理论故障特征频率如表 2 所示。




图 10 实验设备
Fig.10 Experimental equipment

表 2 理论故障特征频率

Tab.2 Theoretical fault characteristic frequencies

元件	频率/Hz
内圈	276.4
外圈	208.1
滚动体	97.5
保持架	12.2

测试信号的时域波形与包络谱如图 11 所示。由于强噪声干扰,难以从图 11(a)所示的时域波形中识别出重复瞬态。此外,未能从图 11(b)所示的包络谱中识别出相关故障特征频率。

所提方法的分析结果如图 12 所示。由图 12(a)所示的 VME 收敛趋势图可知,测试信号中主要存在 3 个潜在分量。其中分量 2 的中值负熵最大,其 ICF 值即为最佳值。随后,基于 AOA 获取最优的惩罚因子。采用具备最佳参数组合的 VME 算法提取目标分量,从图 12(b)所示的时域波形中,可观察到明显的周期性冲击。在图 12(c)所示的包络谱中,有 3 根凸出的谱线,对照表 2 可知,该谱线为外圈故障频率的前 3 阶倍频。因此,本研究所提方法可准确检测出测试轴承存在外圈故障,这一结论与事实相符。




图 11 测试信号的时域波形与包络谱
Fig.11 Time domain waveform and envelope spectrum of measured signals




图 12 所提方法的分析结果
Fig.12 Analysis results of proposed method

作为对比,将基于时域负熵的 Infogram 方法用于分析该实测信号,Infogram 方法的结果如图 13 所示。Infogram 方法确定的最优频带的中心频率为 400 Hz,带宽为 800 Hz。在图 13(b)中,存在高幅值随机冲击,未观察到明显的重复瞬态。在图 13(c)中,未能识别出外圈故障特征频率。结果表明,时域负熵对异常冲击较为敏感,无法有效评估冲击的周期性,使得 Infogram 方法不能准确定位故障敏感频带的位置。

GOA-VMD 方法的分析结果如图 14 所示。如图 14(a)所示,GOA 优化 VMD 获得的分量个数为 3,分量 1 的加权峭度值最大。分量 1 为最优分量,其时域波形和包络谱分别如图 14(b)、图 14(c)所示,从中无法识别出外圈的故障特征信息。分析结果表明,加权峭度指标不能有效抑制高幅值随机冲击信号的干扰,导致选取故障敏感分量失败。




图13 Infogram方法的分析结果

Fig.13 Analysis results of Infogram method




图14 GOA-VMD方法的分析结果

Fig.14 Analysis results of GOA-VMD method

以上分析为定性研究,为更加有力地展示所提方法的优越性,采用文献[11]中使用的故障特征系数(fault feature coefficient, 简称FFC)定量描述上述3种方法的故障特征提取能力,其定义为

$$FFC = \frac{\sum A^2(f_{\text{fault}})}{\sum A^2(f)} \quad (20)$$

其中: $A(f)$ 为包络谱中频率 f 的幅值; $A(f_{\text{fault}})$ 为包络谱中故障特征频率 f_{fault} 的幅值,通常取前3阶故障特征频率来计算FFC。

文献[11]指出,FFC值越大,表示信号中故障信息含量越多。基于FFC指标的定量分析如表3所

示。由表3可知,所提方法的FFC值最大,Infogram次之,GOA-VMD最小。因此,所提改进参数自适应VME方法提取的故障信息最多。综上所述,可以说明本研究所提方法的性能较为优越。

表3 基于FFC指标的定量分析

Tab.3 Quantitative analysis based on FFC indicator

方法	FFC
VME	0.252 5
Infogram	0.003 1
GOA-VMD	0.001 1

5 结 论

1) VME收敛趋势图可快速获取信号中潜在分量个数及中心频率,但在处理轴承单一故障信号时,会存在一些与故障信息无关的冗余分量。因此,本研究提出以中值负熵指标筛选故障敏感分量。

2) 以中值负熵为基础构造目标函数,引导AOA进行全局寻优,可准确获取VME的最优惩罚因子,其效果优于等步长搜索算法和经验公式。

3) 通过对实测信号进行分析,验证了所提方法的有效性。与Infogram和GOA-VMD方法相比,所提方法具有更强的故障特征提取能力。

4) 本研究所提方法适用于轴承在定转速工况下的故障识别,未来需要进一步研究新的策略,将所提方法拓展到变转速工况。

参 考 文 献

- [1] 李可, 彭雄, 宿磊, 等. 基于ISGMD-RPT的滚动轴承故障诊断方法[J]. 振动、测试与诊断, 2025, 45(1): 95-102.
LI Ke, PENG Xiong, SU Lei, et al. Fault diagnosis method of rolling bearing based on ISGMD-RPT[J]. Journal of Vibration, Measurement & Diagnosis, 2025, 45(1): 95-102. (in Chinese)
- [2] 史宗辉, 陈长征, 安文杰, 等. 基于SVDS-MSCNN的风电机组滚动轴承故障诊断[J]. 振动、测试与诊断, 2024, 44(6): 1152-1158.
SHI Zonghui, CHEN Changzheng, AN Wenjie, et al. Fault diagnosis of wind turbine rolling bearing based on SVDS-MSCNN[J]. Journal of Vibration, Measurement & Diagnosis, 2024, 44(6): 1152-1158. (in Chinese)
- [3] NASSEF M G A, HUSSEIN T M, MOKHIAMAR O. An adaptive variational mode decomposition based on sailfish optimization algorithm and Gini index for

- fault identification in rolling bearings[J]. *Measurement*, 2021, 173: 108514.
- [4] SONG Q Y, JIANG X X, WANG S, et al. Self-adaptive multivariate variational mode decomposition and its application for bearing fault diagnosis[J]. *IEEE Transactions on Instrumentation and Measurement*, 2022, 71: 1-13.
- [5] MA J, WU J D, WANG X D. Incipient fault feature extraction of rolling bearings based on the MVMD and teager energy operator[J]. *ISA Transactions*, 2018, 80: 297-311.
- [6] ZHANG X, MIAO Q, ZHANG H, et al. A parameter-adaptive VMD method based on grasshopper optimization algorithm to analyze vibration signals from rotating machinery[J]. *Mechanical Systems and Signal Processing*, 2018, 108: 58-72.
- [7] 江星星, 宋秋昱, 朱忠奎, 等. 基于收敛趋势变分模式分解的齿轮箱故障诊断方法[J]. *交通运输工程学报*, 2022, 22(1): 177-189.
JIANG Xingxing, SONG Qiuyu, ZHU Zhongkui, et al. Gearbox fault diagnosis method based on convergent trend-guided variational mode decomposition[J]. *Journal of Traffic and Transportation Engineering*, 2022, 22(1): 177-189.(in Chinese)
- [8] NAZARI M, SAKHAEI S M. Variational mode extraction: a new efficient method to derive respiratory signals from ECG[J]. *IEEE Journal of Biomedical and Health Informatics*, 2018, 22(4): 1059-1067.
- [9] LI C X, LIU Y Q, LIAO Y Y, et al. A VME method based on the convergent tendency of VMD and its application in multi-fault diagnosis of rolling bearings[J]. *Measurement*, 2022, 198: 111360.
- [10] 郭远晶, 金晓航, 魏燕定, 等. S变换引导变分模态提取的旋转机械故障诊断方法[J]. *振动工程学报*, 2022, 35(5): 1289-1298.
GUO Yuanjing, JIN Xiaohang, WEI Yanding, et al. Fault diagnosis method of rotating machinery using variational mode extraction guided by S transform[J]. *Journal of Vibration Engineering*, 2022, 35(5): 1289-1298.(in Chinese)
- [11] 李翠省, 刘永强, 廖英英, 等. 基于故障特征系数的 IGWO-VME方法及其在轮对轴承故障诊断中的应用[J]. *铁道学报*, 2024, 46(12): 49-57.
LI Cuixing, LIU Yongqiang, LIAO Yingying, et al. IGWO-VME method based on fault feature coefficient and its application in wheelset bearing fault diagnosis[J]. *Journal of the China Railway Society*, 2024, 46(12): 49-57.(in Chinese)
- [12] PANG B, NAZARI M, TANG G J. Recursive variational mode extraction and its application in rolling bearing fault diagnosis[J]. *Mechanical Systems and Signal Processing*, 2022, 165: 108321.
- [13] LI C X, LIU Y Q, LIU Z C, et al. A new fault diagnosis method for wheelset-bearing system based on VME convergence tendency diagram[J]. *Measurement Science and Technology*, 2023, 34(8): 085107.
- [14] 王鑫, 江星星, 宋秋昱, 等. 自适应变分模式提取的轴承故障诊断方法[J]. *振动与冲击*, 2023, 42(15): 83-91.
WANG Xin, JIANG Xingxing, SONG Qiuyu, et al. Bearing fault diagnosis method based on adaptive variational mode extraction[J]. *Journal of Vibration and Shock*, 2023, 42(15): 83-91.(in Chinese)
- [15] ABUALIGAH L, DIABAT A, MIRJALILI S, et al. The arithmetic optimization algorithm[J]. *Computer Methods in Applied Mechanics and Engineering*, 2021, 376: 113609.
- [16] 刘桂敏, 吴建德, 李卓睿, 等. Infogram 和参数优化 CYCBD 在滚动轴承复合故障特征分离中的应用[J]. *振动与冲击*, 2022, 41(10): 55-65.
LIU Guimin, WU Jiande, LI Zhuorui, et al. Application of the infogram and parameter optimization CYCBD in rolling bearing composite fault feature separation[J]. *Journal of Vibration and Shock*, 2022, 41(10): 55-65.(in Chinese)
- [17] 易彩, 林建辉, 汪浩, 等. VMD 引导的轮对与轴承复合故障诊断方法[J]. *西南交通大学学报*, 2024, 59(1): 151-159.
YI Cai, LIN Jianhui, WANG Hao, et al. Compound fault diagnosis method guided by variational mode decomposition for wheelsets and bearings[J]. *Journal of Southwest Jiaotong University*, 2024, 59(1): 151-159.(in Chinese)
- [18] MIAO Y H, WANG J J, ZHANG B Y, et al. Practical framework of Gini index in the application of machinery fault feature extraction[J]. *Mechanical Systems and Signal Processing*, 2022, 165: 108333.



第一作者简介:李翠省,男,1988年7月生,博士、讲师。主要研究方向为机械系统状态监测与故障诊断。曾发表《A VME method based on the convergent tendency of VMD and its application in multi-fault diagnosis of rolling bearings》(《Measurement》2022, Vol.198)等论文。
E-mail: licx@stdu.edu.cn