

参数优化 VMD 的滚动轴承故障诊断方法

李 可, 牛园园, 宿 磊, 顾杰斐, 卢立新

(江南大学机械工程学院江苏省食品先进制造装备技术重点实验室, 江苏 无锡 214122)

摘要: 由于滚动轴承早期故障信号特征微弱, 变分模态分解 (Variational Mode Decomposition, VMD) 的性能易受模态数和惩罚因子设置的影响, 提出了一种自适应优化 VMD 参数的方法。基于中心频率判断本征模态函数 (Band Limited Intrinsic Mode Functions, BIMF) 是否混叠的思想提出中心频率混叠商算法, 利用最小中心频率差与次小中心频率差的比值确定模态数。利用模糊熵原理, 提出求和模糊熵算法优化惩罚因子。利用相关系数筛选模态分量, 重构信号提取故障信息。通过对强噪声下外圈故障信号、内圈故障信号的分析, 表明该方法能自适应确定模态数和惩罚因子, 抑制模态混叠, 能够从强噪声下有效地提取出故障信号特征, 实现滚动轴承故障诊断。

关键词: 故障诊断; 滚动轴承; 变分模态分解; 模糊熵; 相关系数

中图分类号: TH165⁺.3; TH133.33⁺1 **文献标志码:** A **文章编号:** 1004-4523(2023)01-0280-08

DOI: 10.16385/j.cnki.issn.1004-4523.2023.01.029

引 言

滚动轴承作为旋转机械的关键零件, 通常在恶劣的环境下工作, 极易发生故障。但由于其工作环境和自身机理的原因, 采集到的振动信号信噪比低, 使得故障特征提取十分困难。针对滚动轴承故障诊断, 国内外学者做了诸多研究, 早期利用短时傅里叶变换处理振动信号, 但效果容易受所选窗函数的影响^[1]; 相比短时傅里叶变换, 小波变换具有更好的时频窗口特性, 但时域与频域分辨率的精度相互影响, 想要选取合适的分辨率十分困难^[2]; Huang 等^[3]提出了经验模态分解 (Empirical Mode Decomposition, EMD) 算法, 此方法适合处理非平稳信号, 因此广泛应用在设备诊断领域, 但其存在模态混叠、欠包络、过包络、边界效应等问题; 在 EMD 的基础上, 局部均值分解 (Local Mean Decomposition, LMD) 和局部特征尺度分解 (Local Characteristic-scale Decomposition, LCD) 相继被提出, 能够抑制模态混叠和端点效应^[4-5], 但结果容易受到环境噪声的影响; Dragomiretskiy 等^[6]在经验模态分解的基础上提出了一种可变尺度的信号处理方法 VMD, 抛弃了循环递归筛选的处理方式, 通过在变分框架范围内求解最优变分模型, 获得模态分量, 该方法不同于传统递归算法, 具有良好的鲁棒性和严谨的数学理论支撑; 万

书亭等^[7]利用 VMD 分析断路器动作性能, 有效地提取了断路器时间参数。由于 VMD 算法受参数设置的影响, 国内外学者提出了针对性的优化策略, Chen 等^[8]利用相位校正信号平均法 (Phase-Rectified Signal Averaging, PRSA) 优化模态数 K ; 刘尚坤等^[9]以互信息为判据改进了 VMD 的迭代停止条件, 提出了一种自适应确定模态数 K 的方法; 基于相关峭度^[10]对周期性冲击较为敏感的特点, 郑义等^[11]提出了相关峭度为适应度函数的蝗虫优化算法, 能够自适应选定 VMD 参数; Huang 等^[12]通过对中心频率带宽的预估, 利用预估值对惩罚因子加权, 以加权数为指标确定惩罚因子, 一定程度上实现了惩罚因子的优化。VMD 算法结果的优劣依赖模态数、惩罚因子、初始中心频率、保真系数和判断精度, 其中模态数 K 和惩罚因子 α 对结果影响较大。 K 过大会引起过分解, 即模态丢失; K 过小则会导致欠分解, 即模态混叠。惩罚因子设置不当同样会导致模态分量的混叠和丢失, 无法提取到重要特征。

目前针对模态数 K 的选择, 常用的优化方式是通过中心频率的观察, 判断其是否稳定从而确定最优 K 值^[13], 人为判断使得算法不具备自适应性, 影响分解效果。对于惩罚因子的优化, 通常使用的粒子群优化 (Particle Swarm Optimization, PSO) 算法^[14]容易陷入局部最优解, 无法适应在线实时监测的需求。针对以上问题, 本文提出中心频率混叠商

收稿日期: 2021-06-03; **修订日期:** 2021-08-20

基金项目: 国家自然科学基金资助项目 (51775243, 11902124); 山东省泰山产业领军人才计划资助项目; 高等学校学科创新引智计划 (111 计划) (B18027)。

法与求和模糊熵算法优化VMD参数,利用中心频率混叠商法选择出最优模态数 K ,再由求和模糊熵算法选择出最优惩罚因子。最后利用相关系数指标筛选模态分量重构信号,确定滚动轴承的故障类型。相比于经验确定VMD参数 K 和 α ,该方法具有严谨的理论支撑,避免了人为调参的不确定性。

1 基本原理

1.1 VMD算法原理

VMD作为一种非递归算法^[15],是在EMD的内禀尺度分量的概念上定义了一系列调频调幅信号,即本征模态函数,第 k 个本征模态函数 $u_k(t)$ 如下:

$$u_k(t) = A_k(t) \cos \varphi_k(t) \quad (1)$$

式中 $u_k(t)$ 满足 $\sum_{k=1}^K u_k = f(t)$, 其中, $f(t)$ 为原信号; $A_k(t)$ 为瞬时幅值; $\varphi_k(t)$ 为瞬时相位。瞬时频率 $\omega_k(t) = \varphi'_k(t)$ 且 $\varphi'_k(t) \geq 0, A_k(t) \geq 0$ 。

VMD实质就是构造和求解变分问题:1) 利用Hilbert变换对 $u_k(t)$ 解析,获得对应的单边频谱;2) 通过指数混合调制,将每个模态函数的频谱调制到响应基频带;3) 利用H高斯平滑解调信号,得到 $u_k(t)$ 的估计带宽,受约束的变分模型为:

$$\min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \quad (2)$$

式中 $\delta(t)$ 为狄利克雷函数, $j = \sqrt{-1}$ 。

为了得到上述变分模型的最优解,引入惩罚因子 α 和Lagrange乘子 λ 构造增广Lagrange函数,将其转化为无约束变分问题,Lagrange表达式如下:

$$L(\{u_k\}, \{\omega_k\}, \lambda(t)) = \alpha \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_{k=1}^K u_k(t) \right\| + \left\langle \lambda(t), f(t) - \sum_{k=1}^K u_k(t) \right\rangle \quad (3)$$

式中 α 保证重构精度; λ 保证模型的严格性。

将Lagrange表达式变换到频域:

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (4)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k(\omega)|^2 d\omega} \quad (5)$$

式中 $\hat{u}_k^{n+1}(\omega)$, $\hat{f}(\omega)$ 和 $\hat{\lambda}(\omega)$ 分别为 $u_k^{n+1}(t)$, $f(t)$ 和 $\lambda(t)$ 的傅里叶变换。

为了得到式(3)的“鞍点”,即式(2)的最优解,利用乘子交替方向算法(Alternating Direction Method of Multipliers, ADMM)迭代更新 $\{u_k\}$, $\{\omega_k\}$ 和 λ , 最终实现原始信号的分解。具体步骤如下:

- (1) 初始化 $\{\hat{u}_k^1\}$, $\{\omega_k^1\}$, $\hat{\lambda}^1$ 和 $n=0$ 。
- (2) 迭代次数 $n=n+1$ 。
- (3) 由式(4)和(5)对 $\hat{u}_k$ 和 $\hat{\omega}_k$ 进行迭代更新。
- (4) 对于所有 $\omega \geq 0$, 双上升更新 $\hat{\lambda}^{n+1}(\omega)$:

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

式中 τ 为噪声容限参数。

- (5) 满足 $\sum_{k=1}^K \|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2 / \|\hat{u}_k^n\|_2^2 < \epsilon$ (ϵ 为收敛精度, $\epsilon > 0$) 停止, 迭代结束, 否则返回步骤(2)。

ADMM算法最终迭代更新得到 K 个 $\hat{u}_k(\omega)$, 对其进行傅里叶逆变换得到的实部即为模态分量 $u_k(t)$ 。

1.2 模糊熵

模糊熵^[16]是在样本熵算法中加入模糊函数的熵值算法,是一种度量时间序列复杂程度的方法。衡量新模式产生的概率估计序列的复杂程度,模糊熵采用模糊隶属度函数作为判据,并增加了均值处理过程,提高了阈值的判断精确度。模糊熵定义如下:

- (1) 对所给长度为 N 的序列,按顺序得到 m 维向量 $X_i^m = \{x(i), x(i+1), \dots, x(i+m-1)\} - x_0(i)$, ($i = 1, 2, \dots, N-m+1$), 其中, X_i^m 为从第 i 个点开始连续 m 个数去均值,对于均值 $x_0(t)$ 则为:

$$x_0(i) = \frac{1}{m} \sum_{j=0}^{m-1} x(i+j) \quad (6)$$

同时计算 X_i^m 和 X_j^m 对应元素差值的最大值 d_{ij}^m 和相似程度 S_{ij}^m :

$$d_{ij}^m = d[X_i^m, X_j^m] = \max_{k \in (0, m-1)} \left\{ \left| [x(i+k) - x_0(i)] - [x(j+k) - x_0(j)] \right| \right\},$$

$$i, j = 1, 2, \dots, N-m+1; i \neq j \quad (7)$$

$$S_{ij}^m = \mu(d_{ij}^m, n, r) = e^{-\ln 2(d_{ij}^m/r)^r} \quad (8)$$

式中 μ 为模糊隶属度函数的指数形式; n 为模糊函数的边界梯度; r 为相似容限。

- (2) 定义模糊评价函数为:

$$\phi^m(n, r) = \frac{1}{N-m+1} \sum_{i=1}^{N-m+1} \left(\frac{1}{N-m} \sum_{j=1, j \neq i}^{N-m+1} S_{ij}^m \right) \quad (9)$$

将空间维数增加到 $m+1$,得到:

$$\phi^{m+1}(n, r) = \frac{1}{N-m+1} \sum_{i=1}^{N-m+1} \left(\frac{1}{N-m} \sum_{i=1, j \neq i}^{N-m+1} S_{ij}^{m+1} \right) \quad (10)$$

(3) 定义模糊熵。利用所构建的评价函数, 定义模糊熵:

$$FuzzyEn(m, r, n) = \lim_{N \rightarrow \infty} [\ln(\phi^m(n, r)) - \ln(\phi^{m+1}(n, r))] \quad (11)$$

当 N 为有限值时, 模糊熵简化为:

$$FuzzyEn(m, N, r, n) = \ln(\phi^m(n, r)) - \ln(\phi^{m+1}(n, r)) \quad (12)$$

2 VMD参数优化

2.1 优化模态数 K

由VMD算法特性可知, 模态分量中心频率是从低到高按规律分布的, 当分解不彻底时模态函数的中心频率数值接近。基于中心频率确定模态是否混叠的思想, 可以实现对混叠的判断。

基于此, 提出中心频率混叠商算法确定模态数 K 。在预分解后对各模态函数中心频率两两做差, 并选择出最小差和次小差 $\{\omega_i - \omega_j \mid i \neq j; i, j \in \{1, 2, \dots, k\}\}$, 将两者比值定义为“中心频率混叠商” P_k :

$$P_k = \frac{\min_{i \neq j; i, j \in \{1, 2, \dots, k\}} \{\omega_i - \omega_j\}}{\min_{i_1 \neq j_1; i_1, j_1 \in \{1, 2, \dots, k\}} \{\omega_{i_1} - \omega_{j_1}\}}, \quad \text{s.t. } i_1, j_1 \neq \arg \min_{i \neq j; i, j \in \{1, 2, \dots, k\}} \{\omega_i - \omega_j\} \quad (13)$$

利用 P_k 衡量中心频率是否接近, P_k 较小时说明中心频率数值接近。“中心频率混叠商”的阈值 P_{th} 取5%~20%, 由模态分量的中心频率分布特性及滚动轴承振动信号特点可知, 阈值在此范围内能够满足分解需求。

中心频率混叠商算法可以循环求解得到最优模态数 K , 自适应判断分解尺度。流程如图1所示, 具体步骤如下:

- (1) 初始化模态数 K , VMD预分解;
- (2) 判断 P_k 是否低于阈值 P_{th} ;
- (3) 若低于阈值, 过分解, 令 $K=K-1$, 求解VMD, 循环计算直至 $P_k > P_{th}$, 返回此时的 K 值;
- (4) 若高于阈值, 模态混叠即欠分解, 令 $K=K+1$, VMD分解直至 $P_k < P_{th}$, 并返回此时 $K-1$ 值。

初始 K 值设置为2, 通过步骤(4), 直至选定最终模态数。若初始值设定较大, 则通过步骤(3)迭代计算。 K 的初始值不影响最终模态数的选定, 对计算时间的影响也十分有限。




图1 模态数优化流程

Fig. 1 Optimization flowchart of the modal number

2.2 优化惩罚因子 α

模糊熵利用模糊思想代替单位阶跃函数, 能够达到类似于“软阈值”度量的效果^[17-18], 更能适应处理复杂时间序列的需要。关于模糊熵参数的选择, 文献[19]给出了建议。

基于模糊熵算法提出求和模糊熵优化惩罚因子 α 。对分解的 K 个模态分量求总模糊熵, 构建求和模糊熵(Summation of Fuzzy Entropy, SFE)作为评价指标。利用SFE衡量惩罚因子设置是否得当, 总熵值越大, 混乱程度越高, 分解效果越差, 反之则越好。SFE作为评价指标, 避免了经验确定参数对结果的影响, 流程如图2所示。具体步骤如下:

- (1) 设置惩罚因子最大值 $\alpha_{\max}$ 、最小值 $\alpha_{\min}$ 和步长因子 L , 并按中心频率混叠商算法确定的模态数设置VMD参数;
- (3) VMD分解并计算分量的求和模糊熵值SPE;
- (4) 判断当 α 小于 $\alpha_{\max}$ 时, 令 $\alpha = \alpha + L$, 更新 α ;
- (5) 当 α 大于 $\alpha_{\max}$ 时, 循环结束。求和模糊熵值SPE的最小值对应的 α 为最优值;

计算求和模糊熵时, 惩罚因子最小值对分解效果的影响可以忽略, 步长只影响寻优精度和算法计算时间, 惩罚因子最大值只影响计算时间。通常将最小值和步长设置为分解数据量的百分之一, 将最大值设置为4~5倍数据量时即可实现对最优惩罚因子的覆盖。由此得到模态数和惩罚因子, 并对原始信号进行VMD分解。

分解信号与原信号的相关性主要体现在故障成分的占比, 因此利用模态分量和原信号的相关系数选择模态分量并重构信号。为了保证获得较好的重构效果, 文献[20]给出了相关系数数值选取方法。




图 2 惩罚因子优化流程

Fig. 2 Optimization flowchart of the penalty coefficient

2.3 仿真分析

设计一组仿真信号 $y(t)$, 验证上述方法的有效性。仿真信号 $y = \frac{4}{\pi} \times (x_1 + x_2 + x_3) + x_4$ 由正弦信号叠加高斯白噪声而成, 信号 $y(t)$ 的时域波形如图 3 所示。

其中,
$$\begin{cases} x_1 = \sin(2\pi \times 10 \times t) \\ x_2 = \frac{1}{3} \sin(2\pi \times 30 \times t) \\ x_3 = \frac{1}{5} \sin(2\pi \times 50 \times t) \\ x_4 = 0.1 * randn(1, n), n = length(t) \end{cases}$$

对仿真信号进行分析, 利用中心频率混叠商算法迭代求解优化模态数 K 。结果如表 1 所示, $K=4$ 时低于阈值, 选定 K 为 3。求和模糊熵算法结果如图 4 所示, SFE 最小值为 5.967, 对应的惩罚因子为 260。从分解后的分量图 5 可以看出, 各分解分量与原信号 $y(t)$ 中包含的信号一致, 端点处有略微波动, 但没有对整体波形产生影响。仿真实验表明参数优化的 VMD 算法在分解模拟信号时具有良好的适应性。

表 1 不同 K 值下的 P_k

Tab. 1 P_k value of different K

$K=2$	$K=3$	$K=4$
-	0.8866	0.0873




图 3 仿真信号时域图

Fig. 3 Time domain diagram of simulation signal




图 4 仿真信号的 SFE 图

Fig. 4 SFE diagram of simulation signal




图 5 BIMF 时域图

Fig. 5 Time domain diagram of BIMF

3 实验分析

本文搭建转子实验平台如图 6 所示。实验用的滚动轴承外径为 52 mm, 内径为 25 mm, 宽为 15 mm, 有 13 个滚动体。采用线切割的方式分别在内外圈加工出 0.05 mm×0.3 mm(深度×宽度)的凹痕来模拟实际轴承内圈与外圈故障状态, 如图 7 所示。利用 PCB MA352A60 型加速度传感器分别采集垂直方向上内圈故障、外圈故障的轴承振动信号, 采样频率为 50 kHz。通过计算求得外圈故障频率 f_o 和内圈故障频率 f_i 分别为 90.2 Hz 和 55.1 Hz。

通过实验平台分别采集到正常状态、外圈故障、内圈故障状态下的振动信号, 分别对外圈故障信号和内圈故障信号进行分析。





图 6 故障诊断实验平台

Fig. 6 Experimental platform of fault diagnosis



(a) 外圈故障
(b) 内圈故障
(a) Fault of outer ring
(b) Fault of inner ring

图 7 滚动轴承故障类型

Fig. 7 The type of roller bearing fault

3.1 外圈故障

原始信号包络如图 8(a)所示,为了验证参数优化 VMD 算法的有效性,使用多种模态分解方法对外圈故障信号进行处理。利用 EMD,LCD 和 LMD 方法分解重构信号,重构信号包络分别如图 8(b),(c)和(d)所示。




图 8 外圈故障

Fig. 8 Fault of outer ring

从图 8(b)中可以看出,EMD 分解重构的包络谱 f_0 及其 2 倍频均不明显,且在 0~100 Hz 存在较大干扰;如图 8(c)中所示,外圈特征频率 f_0 及其 2 倍频、4 倍频成分被提取出,但 146.2 Hz 处存在高峰值的谐波干扰,且 4 倍频以后的频率不明显;从图 8(d)

中可以看到,特征频率 f_0 及其 2 倍频、4 倍频被提取出,但低频处谐波、噪声干扰较大,故障信息提取不足。

模态数 K 和惩罚因子 α 按经验设置^[6]。令 $K=4, \alpha=2210$,重构并做包络谱如图 9(a)所示,外圈故障频率的 2 倍频和 4 倍频出现峰值,但峰值不高;同样令 $K=8, \alpha=10000$,重构包络谱如图 9(b)所示,谐波频率和白噪声干扰较大,在强噪声条件下很容易使得故障特征频率淹没在噪声中,难以提取到故障信息。




图 9 VMD 包络谱

Fig. 9 Envelope spectrum of VMD

使用本文提出的参数优化 VMD 算法对信号进行处理,由中心频率混叠商算法得到不同 K 值下的 P_k 数如表 2 所示,当 $K=9$ 高于阈值,因此确定 $K=8$ 。

表 2 不同 K 值下的 P_k

Tab. 2 P_k value of different K

$K=2$	$K=3$	$K=4$	$K=5$	$K=6$	$K=7$	$K=8$	$K=9$
-	0.4327	0.7518	0.7828	0.4792	0.4930	0.4966	0.1605

保持 K 不变计算 SFE,结果如图 10 所示。从图中可以看出,最小值对应的 α 为 3700。将优化后的 K 和 α 作为 VMD 的参数,得到 8 个 BIMF 分量,其与原信号相关系数如表 3 所示。选择相关性系数较大的 BIMF6,BIMF7 和 BIMF8 分量进行重构并做包络谱,总耗时 284 s。从图 11(b)中可以明显看到,提取到了外圈故障特征频率 f_0 及其 2 倍频、3 倍频、4 倍频、5 倍频和 6 倍频成分。图 11(a)中使用的粒子群优化参数的方法耗时 1120 s,相比于粒子群算法,该算法提取出了更多倍频信息,提高了计算效率,重构信号的干扰分量更少,效果改善十分明显。

3.2 内圈故障

针对内圈故障信号,原始信号包络如图 12(a)所示。利用 EMD,LCD 和 LMD 算法分解重构信




图 10 外圈故障 SFE 图

Fig. 10 SFE diagram of outer ring fault




图 11 VMD 包络谱

Fig. 11 Envelope spectrum of VMD

表 3 BIMF 与原信号的相关系数

Tab. 3 Correlation coefficient between BIMFs and original signal

BIM F1	BIM F2	BIM F3	BIM F4	BIM F5	BIM F6	BIM F7	BIM F8
0.309	0.318	0.312	0.310	0.301	0.379	0.386	0.399

号,重构信号包络谱分别如图 12(b),(c)和(d)所示。从图 12(b)~(c)中可以看出,EMD 和 LCD 分解重构的包络谱几乎找不到故障特征频率;从图 12(d)中可以看出,仅提取到内圈故障特征频率 f_i ,噪声信息较多。EMD,LCD 和 LMD 方法在处理内圈故障效果并不显著。

令 VMD 参数 $K=4, \alpha=3000$, 分解重构信号包络谱如图 13(a)所示。内圈故障频率 f_i 和轴承转频 f_r 较为明显,其 2 倍频 310.5 Hz 处也有峰值,但其余各倍频均不明显,故障信息提取不足,谐波干扰较大。同样令 $K=6, \alpha=15000$, 包络谱如图 13(b)所示,从图中可以看出效果改善并不明显,此参数下效果同样不佳。

使用参数优化 VMD 方法,由中心频率混叠商算法迭代求解得到不同 K 值下 P_k 如表 4 所示,设置 K 为 4。







图 12 内圈故障

Fig. 12 Fault of inner ring





图 13 VMD 包络谱

Fig. 13 Envelope spectrum of VMD

表 4 不同 K 值下的 P_k

Tab. 4 P_k value of different K

$K=2$	$K=3$	$K=4$	$K=5$
-	0.5946	0.8275	0.1125

保持 K 不变,循环求解其 SFE,结果如图 14 所示。从图中可得,最小 SFE 对应的 α 为 1700。经过 VMD 分解为 4 个 BIMF,相关系数如表 5 所示。选择相关系数较大的 BIMF1 重构信号,算法总耗时 308 s。图 15(a)中的粒子群算法结果陷入了局部最

优,计算时间为 1316 s。从图 15(b)中可以看出,内圈故障特征频率 f_i 及其 2 倍频、3 倍频、4 倍频及 6 倍频特征频率都十分明显。故障特征频率及其倍频成分被提取出,主频幅值明显,谐波频率被抑制,可以判断发生了内圈故障。通过对比可以看出,本文所提方法效果改善十分明显。

表 5 BIMF 与原信号的相关系数
Tab. 5 Correlation coefficient between BIMFs and original signal

BIMF1	BIMF2	BIMF3	BIMF4
0.499	0.358	0.357	0.352




图 14 内圈故障 SFE 图
Fig. 14 SFE diagram of inner ring fault




图 15 VMD 包络谱
Fig. 15 Envelope spectrum of VMD

4 结 论

由于强噪声下滚动轴承早期故障信号微弱,VMD 在抑制边界效应、抑制模态混叠等方面具有优势。模态数 K 和惩罚因子 α 的优化成为使用 VMD 处理故障信号的关键。本文提出了基于中心频率混叠商算法和求和模糊熵算法优化模态数和惩罚因子的方法。应用到实际轴承诊断领域,能够取得不错效果,可得如下结论:

(1)利用中心频率混叠商算法确定模态数,能自适应地确定 VMD 分解尺度,避免了模态混叠和模态丢失;

(2)利用求和模糊熵算法选择最优惩罚因子值能提高寻优效率,避免设置参数的主观性,同时能够提升 VMD 算法的效果。

参考文献:

[1] 刘湘楠,赵学智,上官文斌.强背景噪声振动信号中滚动轴承故障冲击特征提取[J].振动工程学报,2021,34(1):202-210.
Liu Xiangnan, Zhao Xuezhi, Shanguan Wenbin. The impact features extraction of rolling bearing under strong background noise[J]. Journal of Vibration Engineering, 2021, 34(1): 202-210.

[2] 丁康,陈健林,苏向荣.平稳和非平稳振动信号的若干处理方法及发展[J].振动工程学报,2003,16(1):1-10.
Ding Kang, Chen Jianlin, Su Xiangrong. Development in vibration signal analysis and processing methods[J]. Journal of Vibration Engineering, 2003, 16(1): 1-10.

[3] Huang N E, Shen Z, Long S R, et al. The empirical mode decomposition and the Hilbert spectrum for non-linear and non-stationary time series analysis[J]. Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences, 1998, 454: 903-955.

[4] 陈是钊,彭志科,周鹏.信号分解及其在机械故障诊断中的应用研究综述[J].机械工程学报,2020,56(17):91-107.
Chen Shiqian, Peng Zhike, Zhou Peng. Review of signal decomposition theory and its applications in machine fault diagnosis[J]. Journal of Mechanical Engineering, 2020, 56(17): 91-107.

[5] 程军圣,杨怡,杨宇.局部特征尺度分解方法及其在齿轮故障诊断中的应用[J].机械工程学报,2012,48(9):64-71.
Cheng Junsheng, Yang Yi, Yang Yu. Local characteristic-scale decomposition method and its application to gear fault diagnosis[J]. Journal of Mechanical Engineering, 2012, 48(9): 64-71.

[6] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.

[7] 万书亭,豆龙江,李聪,等.基于振动信号的高压断路器合闸特性参数在线检测方法研究[J].振动工程学报,2019,32(2):359-367.
Wan Shuting, Dou Longjiang, Li Cong, et al. Study on on-line detection of high voltage circuit breaker closing characteristic parameters based on vibration signal[J]. Journal of Vibration Engineering, 2019, 32(2): 359-367.

[8] Chen Q M, Lang X, Xie L, et al. Detecting nonlinear oscillations in process control loop based on an im-

- proved VMD[J]. IEEE Access, 2019, 7: 91446-91462.
- [9] 刘尚坤,唐贵基,王晓龙.基于改进变分模态分解的旋转机械故障时频分析方法[J].振动工程学报, 2016, 29(6): 1119-1126.
- Liu Shangkun, Tang Guiji, Wang Xiaolong. Time frequency analysis method for rotary mechanical fault based on improved variational mode decomposition[J]. Journal of Vibration Engineering, 2016, 29(6): 1119-1126.
- [10] McDonald G L, Zhao Q, Zuo M J. Maximum correlated Kurtosis deconvolution and application on gear tooth chip fault detection[J]. Mechanical Systems and Signal Processing, 2012, 33: 237-255.
- [11] 郑义,岳建海,焦静,等.基于参数优化变分模态分解的滚动轴承故障特征提取方法[J].振动与冲击, 2021, 40(1): 86-94.
- Zheng Yi, Yue Jianhai, Jiao Jing, et al. Fault feature extraction method of rolling bearing based on parameter optimized VMD[J]. Journal of Vibration and Shock, 2021, 40(1): 86-94.
- [12] Huang Yan, Lin Jianhui, Liu Zechao, et al. A modified scale-space guiding variational mode decomposition for high-speed railway bearing fault diagnosis[J]. Journal of Sound and Vibration, 2019, 444: 216-234.
- [13] 孙灿飞,王友仁,沈勇,等.基于参数自适应变分模态分解的行星齿轮箱故障诊断[J].航空动力学报, 2018, 33(11): 2756-2765.
- Sun Canfei, Wang Youren, Shen Yong, et al. Fault diagnosis of planetary gearbox based on adaptive parameter variational mode decomposition[J]. Journal of Aerospace Power, 2018, 33(11): 2756-2765.
- [14] Chang Y, Bao G Q, Cheng S K, et al. Improved VMD-KFCM algorithm for the fault diagnosis of rolling bearing vibration signals[J]. IET Signal Processing, 2021, 15(4): 238-250.
- [15] 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 Guiji, Wang Xiaolong. Variational mode decomposition method and its application on incipient fault diagnosis of rolling bearing[J]. Journal of Vibration Engineering, 2016, 29(4): 638-648.
- [16] Chen Weiting, Wang Zhizhong, Xie Hongbo, et al. Characterization of surface EMG signal based on fuzzy entropy[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2007, 15(2): 266-272.
- [17] Costa M, Goldberger A L, Peng C K. Multiscale entropy analysis of complex physiologic time series[J]. Physical Review Letters, 2002, 89(6): 068102.
- [18] Costa M, Goldberger A L, Peng C K. Multiscale entropy analysis of biological signals[J]. Physical Review E: Statistical, Nonlinear, and Soft Matter Physics, 2005, 71: 021906.
- [19] 郑近德,陈敏均,程军圣,等.多尺度模糊熵及其在滚动轴承故障诊断中的应用[J].振动工程学报, 2014, 27(1): 145-151.
- Zheng Jinde, Chen Minjun, Cheng Junsheng, et al. Multiscale fuzzy entropy and its application in rolling bearing fault diagnosis[J]. Journal of Vibration Engineering, 2014, 27(1): 145-151.
- [20] 王建国,吴林峰,秦绪华.基于自相关分析和LMD的滚动轴承振动信号故障特征提取[J].中国机械工程, 2014, 25(2): 186-191.
- Wang Jianguo, Wu Linfeng, Qin Xuhua. Rolling bearing vibration signal fault feature extraction based on autocorrelation analysis and LMD[J]. China Mechanical Engineering, 2014, 25(2): 186-191.

Rolling bearing fault diagnosis method based on parameter optimized VMD

LI Ke, NIU Yuan-yuan, SU Lei, GU Jie-fei, LU Li-xin

(Jiangsu Key Laboratory of Advanced Food Manufacturing Equipment and Technology, School of Mechanical Engineering, Jiangnan University, Wuxi 214122, China)

Abstract: The early fault signal characteristics of the rolling bearing are weak. The performance of traditional variational mode decomposition (VMD) depends on the parameters, which include mode number and penalty coefficient. To solve this problem, an adaptive method to determine parameters of VMD was proposed. The minimum center frequency quotient algorithm was proposed based on the idea of the center frequency to judge whether the bend limited intrinsic mode function (BIMF) is overlapped or not, and the mode number was determined by the ratio of the minimum frequency and the sub small frequency. By using the fuzzy entropy principle, the sum fuzzy entropy (SFE) was proposed to optimize the penalty coefficient. The correlation coefficient was used to select the BIMFs. The method can adaptively determine the mode number and penalty factor, suppress the mode aliasing phenomenon. It can extract the fault signal features from the strong noise to judge the bearing state.

Key words: fault diagnosis; rolling bearing; VMD; fuzzy entropy; correlation coefficient

作者简介: 李可(1978—),男,教授,博士生导师。电话: 18118905856; E-mail: like@jiangnan.edu.cn。

通讯作者: 宿磊(1986—),男,副教授,硕士生导师。E-mail: lei_su2015@jiangnan.edu.cn。