

DOI: 10.13382/j.jemi.B2508705

多尺度融合稀疏测度最大相关峭度解卷积 滚动轴承故障特征提取^{*}

王宇森^{1,2,3} 王红军^{1,2,3} 何 山^{1,4} 梅 炜^{1,2,3} 窦 唯⁵ 金志磊⁵

(1. 北京信息科技大学机电工程学院 北京 100192; 2. 高端装备智能感知与控制北京市国际科技合作基地
北京信息科技大学 北京 100192; 3. 现代测控技术教育部重点实验室 北京信息科技大学 北京 100192;
4. 中国机械科学研究总院集团 北京 100048; 5. 北京航天动力研究所 北京 100076)

摘 要:滚动轴承是旋转机械中最为重要的零件之一,在运行过程中,其早期故障的瞬态冲击信号常被强背景噪声掩盖,传统方法难以有效分离特征。针对强噪声环境下滚动轴承微弱故障特征难以提取的问题,提出一种多尺度稀疏最大相关峭度解卷积的故障特征提取方法。首先,输入原信号,以玻尔兹曼香农互作用熵作为变分模态分解(variational modal decomposition, VMD)算法的优化准则,通过鹅优化算法(GOOSE algorithm, GOOSE)对VMD的惩罚因子 α 与模态数 K 进行寻优,实现信号的自适应分解,并根据包络谱峭度最大原则筛选出最优模态分量。其次,为提升对信号脉冲特征的适应性,构建了一种新型特征指标 KG ,它综合了信号包络谱峭度和脉冲模态分解的稀疏测度 GM_{2tol} ,实现信号冲击成分和全局脉冲分布的多尺度融合,以特征指标 KG 为优化目标对相关最大峭度解卷积算法(maximum correlated kurtosis deconvolution, MCKD)参数滤波器长度 L ,周期 T ,位移数 M 进行优化,实现对最优分量冲击成分的特征增强。最后,通过包络谱分析提取轴承故障特征频率。分别采用仿真信号和实验数据集进行验证,验证结果表明该方法清晰提取出故障频率及其多倍频,故障频率提取误差在0.54%,实现故障类别的判别。

关键词:滚动轴承;故障特征提取;变分模态分解;鹅优化算法;最大相关峭度解卷积
中图分类号: TH 133.33; TN 911.23 **文献标识码:** A **国家标准学科分类代码:** 510.40

Multi scale fusion sparse measure maximum correlation kurtosis deconvolution feature extraction of rolling bearing faults

Wang Yusen^{1,2,3} Wang Hongjun^{1,2,3} He Shan^{1,4} Mei Wei^{1,2,3} Dou Wei⁵ Jin Zhilei⁵

(1. College of Mechanical and Electrical Engineering, Beijing Information Science & Technology University, Beijing 100192, China;
2. Beijing International Science and Technology Cooperation Base for Intelligent Perception and Control of High end Equipment,
Beijing Information Science & Technology University, Beijing 100192, China; 3. Key Laboratory of Modern Measurement & Control
Technology, Ministry of Education, Beijing Information Science & Technology University, Beijing 100192, China; 4. China Academy
of Machinery Science and Technology, Beijing 100048, China; 5. Beijing Aerospace Propulsion Institute, Beijing 100076, China)

Abstract: Rolling bearings are one of the most important components in rotating machinery. During operation, the transient impact signals of their early failures are often masked by strong background noise, and traditional methods are difficult to effectively separate features. This paper proposes a multi-scale sparse maximum correlation kurtosis deconvolution method for extracting weak fault features of rolling bearings in strong noise environments. Firstly, using the Boltzmann Shannon interaction entropy as the optimization criterion for the variational modal decomposition (VMD) algorithm, the penalty factor α and mode number K of VMD are optimized through the GOOSE algorithm (GOOSE) to achieve adaptive decomposition of the signal, and the optimal mode components are selected based on the maximum kurtosis principle of the envelope spectrum. Secondly, in order to enhance the adaptability of signal pulse features, a new feature index KG was constructed, which integrates the sparsity measures of signal envelope spectrum kurtosis and pulse mode decomposition GM_{2tol} , achieving multi-scale fusion of signal impulse components and global pulse distribution. With the feature index KG

收稿日期: 2025-08-31 Received Date: 2025-08-31

^{*} 基金项目: 国家自然科学基金(52575095)、北京市自然科学基金(L258043, IS24076)项目资助

as the optimization objective, the filter length L , period T , and displacement M of the maximum corresponded kurtosis deconvolution (MCKD) parameter filter were optimized to enhance the features of the optimal component impulse components. Finally, the characteristic frequency of bearing faults is extracted through envelope spectrum analysis. The method was validated using simulated signals and experimental datasets, and the results showed that it clearly extracted fault frequencies and their multiples, with a fault frequency extraction error of 0.54%, achieving the discrimination of fault categories.

Keywords: rolling bearing; fault feature extraction; variational mode decomposition; goose optimization algorithm; maximum correlation kurtosis deconvolution

0 引言

滚动轴承是旋转机械设备中广泛使用的零部件之一,也是旋转机械最主要的故障来源之一^[1]。设备实际运行过程载荷多变,滚动轴承工作环境十分复杂严苛,常处于非线性非平稳状态,故障特征往往被强噪声所干扰和掩盖。

滚动轴承早期故障信号具有非线性与非平稳性,如何从中提取出有效故障特征信息是实现轴承故障诊断的关键一步^[2]。现今,短时傅里叶变换(short time Fourier transform, STFT)、小波变换(wavelet transform, WT)、经验模态分解(empirical mode decomposition, EMD)^[3]等信号分解方法已经较为常见。上述方法在信号分解方面取得了一定的效果,但是也都存在着一定的局限,STFT 因固定窗口无法实现自适应的信号分解,WT 高度依赖对小波基的选择,并且缺乏对低信噪比信号的有效分解能力,EMD 分解的信号在频率和带宽上缺乏稳定性,容易出现模态混叠的现象。王泽等^[4]提出了一种融合集合经验模态分解(EEMD)、多尺度排列熵与改进邻域粗糙集的特征提取方法,但该方法仍受限于 EEMD 固有的计算冗余和参数依赖问题。

针对模态分解的问题,变分模态分解(variational mode decomposition, VMD)作为一种完全非递归模型^[5],既能实现对信号的自适应模态分解,又能有效避免模态的混叠。He 等^[6]的研究通过频谱信息优化 VMD 参数,这种方法依赖于高质量的频谱信息输入,在实际应用中获取可能存在困难。刘泽锐等^[7]利用最大相关峭度解卷积对 VMD 结果进行筛选,通过快速谱峭度图确定滤波频带,但是这种方法难以在高噪声环境实现有效识别。近年来,滚动轴承故障诊断方法研究不断深入。徐统等^[8]引入 VMD 并以瞬时能量构建故障特征,结合遗传算法优化的 RBF 神经网络提升分类性能。为进一步优化 VMD 分量选取策略,徐统等^[9]后续又提出基于 K-L 散度筛选与原始信号分布最相似的模态分量,但 K-L 散度在短样本或强噪声下对分布估计敏感,无法适用于强噪声环境。

为了解决微弱脉冲信号在噪声影响下难以提取的问题,McDonald 等^[10]提出了最大相关峭度解卷积(maximum correlated kurtosis deconvolution, MCKD)算

法,用相关峭度指标来衡量信号的周期性冲击强度。李东炎等^[11]提出将粒子群优化算法(PSO)与 MCKD 结合,利用 PSO 的对 MCKD 的参数 $[L, T, M]$ 进行优化,从而提取故障特征,但该方法仅限于在低噪声环境下,难以在高噪声环境下准确提取信号的故障特征。刘兴教等^[12]利用 EEMD 对信号进行模态分解,再将分解后的模态进行 MCKD 处理,但 EEMD 十分依赖参数的选择,缺乏自适应性。潘昕怡^[13]尝试将 MCKD 与 VMD 结合,利用 VMD 的自适应分解能力预处理信号以降低噪声干扰,但该方法对 VMD 参数(如惩罚因子 α 和模态数 K)的敏感性未充分解决,在强噪声环境下仍存在特征提取不稳定的问题。任良等^[14]利用奇异谱分解(singular spectrum analysis, SSA)对信号进行提前分解后重构以提高 VMD 对信号的分解效果,但是这种方法虽然提高了故障信号特征提取的抗噪性,但是增加了算法的运行时间,降低了整体故障提取的效率。

由于机械故障信号在时域和频域具有稀疏性,因此基于稀疏测度和复杂性测度的故障特征提取被广泛应用于机械设备健康监测中^[15]。Hou 等^[16]基于几何均值针对信号的脉冲特性,提出一种新的稀疏测度 GM_{2tol} 。针对旋转机械在强噪声环境下微弱故障特征提取的挑战,苗永浩等^[17]将基尼指数(gini index, Gini)作为滤波器初始度度量准则,定位 MCKD 滤波器的初始参数,但是基尼指数本身没有对信号的脉冲特性的自适应能力。

尽管上述研究通过多种方法融合提升了 VMD 和 MCKD 的性能,但参数优化效率、抗噪能力及动态工况适应性仍存在局限。针对这些问题,提出了一种利用鹅优化算法和玻尔兹曼香农互作用熵优化 VMD 参数并结合多尺度稀疏测度改进 MCKD 算法的滚动轴承故障特征提取方法。

1 基本原理

1.1 VMD 原理

VMD 是一种非递归的信号分解方法,其通过构建约束变分模型将原始信号 $x(t)$ 分解为 K 个具有特定中心频率的本征模态函数(IMF)。其模型表达式如下:

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

$$\sum_{k=1}^K u_k(t) = x(t) \quad (2)$$

式中: $u_k(t)$ 表示第 k 个 IMF; ω_k 为其对应的中心频率; $\delta(t)$ 为狄拉克函数; $*$ 为卷积操作。目标函数的第 1 项通过希尔伯特变换构造解析信号,并计算其时间导数的 2 范数平方,以衡量模态带宽;第 2 项约束确保所有模态的叠加等于原始信号。

为求解上述问题,引入拉格朗日乘子 λ 构建增广拉格朗日函数,该模型通过交替方向乘法 (alternating directions method of multipliers, ADMM) 求解,核心参数包括惩罚因子 α (控制带宽约束强度) 和模态数 K 。

首先在频域中通过滤波操作更新模态的频谱:

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{u}(\omega) - \sum_{i \neq k} \hat{u}_i^n(\omega) - \frac{\lambda^n(\omega)}{2}}{1 + \alpha(\omega - \omega_k)^2} \quad (3)$$

随后,通过梯度下降法更新中心频率:

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

最后,更新拉格朗日乘子 λ :

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

迭代终止条件为预设最大次数 M 。

1.2 MKCD 原理及算法流程

MCKD 是一种基于周期性冲击特征增强的解卷积技术,通过优化有限脉冲响应 FIR 滤波器参数,从信号中提取周期性冲击特征。其核心思想是通过最大化输出信号的相关峭度 (correlated kurtosis),增强信号中周期性冲击成分的非高斯特性,从而分离出被噪声掩盖的故障特征。设计长度为 L 的 FIR 滤波器 $f(l)$ ($l = 0, 1, \dots, L-1$),构造输出信号 $y(n)$:

$$y(n) = \sum_{l=0}^{L-1} f(l)x(n-l) \quad (6)$$

先将输入信号 $x(n)$ 构造为滑动窗口矩阵 $\mathbf{X}$, 其元素 $X_{l,n} = x(n-l)$ 。随后,通过计算输出信号 $y(n) = \mathbf{f}^T \mathbf{X}$, 并构造位移矩阵 $\mathbf{Y}_l$, 进一步计算 $\alpha(n, m)$ 和 $\beta(n)$ 。

$$\alpha(n, m) = \left(\prod_{m'=0}^M y_{n+m'T} \right)^2 \cdot y_{n+m'T} \quad (7)$$

$$\beta(n) = \prod_{m=0}^M y_{n+mT} \quad (8)$$

代入式 (9) 对滤波器系数进行更新, 其中 $\mathbf{X}_{inv} = (\mathbf{X}^T \mathbf{X})^{-1}$ 。迭代过程中, 每次更新后对滤波器进行归一化 ($\|\mathbf{f}\|_2 = 1$), 直至达到预设的最大迭代次数。

$$f = \frac{\sum y^2}{2 \sum \beta^2} \mathbf{X}_{inv} \sum_{m=0}^M \mathbf{X}^T \alpha(:, m+1) \quad (9)$$

$$C_K^M(T) = \frac{\sum_{n=1}^{N-M} \left(\prod_{m=0}^M y_{n+mT} \right)^2}{\left(\sum_{n=1}^N y_n^2 \right)^{M+1}} \quad (10)$$

相关峭度 C_K^M 通过计算周期性冲击信号的高阶统计量, 量化连续脉冲的显著性。 C_K^M 值越大, 表明信号中周期性冲击越明显。

综上, MCKD 方法的步骤如下:

步骤 1) 输入原信号 x , 设定滤波器长度 L 和迭代次数 M , 通过计算理想故障频率特征设定解卷积周期 T ;

步骤 2) 生成初始化滤波器 f_0 , 迭代次数 i 设定为 0;

步骤 3) 对原信号 x 进行滤波, 获得滤波信号 y_i ;

步骤 4) 根据式 (9) 更新滤波器系数 f_i ;

步骤

入随机扰动避免局部最优;

步骤 3) 利用式 (11)、(12) 对不同的模式进行个体位置的更新;

步骤 4) 计算个体适应度值, 更新全局最优解;

步骤 5) 重复迭代步骤 2) ~ 4), 达到最大迭代次数, 输出最优解。

1.4 VMD 参数优化

玻尔兹曼香农熵 (Boltzmann-Shannon Interaction Entropy, BSIE) 是一种结合频率与几何分布的归一化熵度量, 适用于连续变量无偏估计^[19], 通过计算频率分布 p 与几何分布 q 之间的杰森-香农散度 (JSD) 来衡量样本的不确定性, 其数学表达式为:

$$BSIE(X) = 1 - \frac{1}{2} [D_{KL}(p \parallel m) + D_{KL}(q \parallel m)] \quad (13)$$

$$D_{KL}(p \parallel m) = \sum_{i=1}^K [\ln(p/m)_i] p_i \quad (14)$$

$$D_{KL}(q \parallel m) = \sum_{i=1}^K [\ln(q/m)_i] p_i \quad (15)$$

式中: m 是 p, q 的平均分布; $D_{KL}(\cdot \parallel \cdot)$ 为 Kullback-Leibler 散度, 频率分布与几何分布的 K-L 散度的结合组成了 JSD。 $D_{KL}(p \parallel m)$ 反映了样本在不同区间的出现频率, 对样本的局部特性敏感; $D_{KL}(q \parallel m)$ 反映了样本在不同区间的长度分布, 对样本的整体分布特性敏感。对于高噪声信号, 噪声成分会导致样本的分布更加均匀, 而 BSIE 对这种均匀分布非常敏感。最小化 BSIE 的模式分解结果包含信号中的有用信息, 而不是被噪声均匀化的部分。

这一度量指标通过比较频率分布与几何分布的差异, 增强对高噪声信号的鲁棒性, 同时归一化处理有效规避了传统熵估计中对样本大小的依赖问题。将 BSIE 用于模式分解中表现出更强的稳定性和实用性, 尤其适用于小样本或高噪声条件下的复杂信号分析。

1.5 多尺度稀疏测度特征指标

针对复杂工况下脉冲特征提取的挑战, 现有方法在特征表征在维度上存在明显局限。包络谱峭度虽能有效反映冲击能量的陡峭程度, 但其对高斯噪声环境敏感, 容易导致特征误判; 而传统稀疏测度指标 (如 $L1/L2$ 范数比值) 虽具备一定抗噪能力, 却未能有效表征脉冲信号在频域的周期性分布特征。这种特征表征的片面性导致现有方法在参数优化过程中存在收敛速度慢和易陷入局部最优解等问题。

于是, 提出一种结合包络谱峭度和稀疏测度 GM_{2tol} 的两种尺度融合信号脉冲特性度量指标 KG , 能够同时捕捉信号的局部非平稳特性与全局稀疏分布特性的多尺度融合指标, 其数学表达式为:

$$KG = \text{Kurtosis}_{\text{envelop}} \cdot GM_{2tol}(SE) \quad (16)$$

式中: $\text{Kurtosis}_{\text{envelop}}$ 为包络谱峭度; $GM_{2tol}(SE)$ 为基于几何均值的脉冲稀疏量化指标。

$$GM_{2tol}(SE) = \sqrt[S]{\prod_{i=1}^S M_{2tol}(SE^{(i)})} \quad (17)$$


$$M_{2tol}(SE) = \sqrt{\sum_{n=1}^L (SE)^2 / L / (\sum_{n=1}^L SE / L)} \quad (18)$$

$$SE = |jH(x) + x|^2 \quad (19)$$

GM_{2tol} 是一种用于量化冲击模态稀疏性分布的统计指标, 其中 S 为信号分段数, 在处理周期脉冲信号式通常设置为 $S = f_s \times T_s$, f_s 为目标故障特征频率, T_s 为样本采样时长, L 为信号样本长度。

GM_{2tol} 先对信号数据进行平方包络处理, 突出周期脉冲成分, 抑制非脉冲成分, SE 有助于后续的量化分析; 然后对平方包络结果进行 p - q 均值计算, 选择 $p=2, q=1$, 即均方根除以算术平均值, 衡量信号的稀疏性, 对于周期脉冲信号, 均方根较大而算术平均较小, M_{2tol} 就能反映出脉冲的稀疏性; GM_{2tol} 则是将信号按照脉冲数进行分割, 计算 M_{2tol} 的几何均值, 增强对目标信号的周期成分的识别; 3 步分别实现了信号的能量增强、稀疏性分离、周期性验证, 实现了对滚动轴承周期性故障特征的有效稀疏量化。

$\text{Kurtosis}_{\text{envelop}}$ 则是先通过对信号的平方包络谱计算, 对含噪信号的故障特征频率实现有效的量化; 再进行谱峭度的计算, 捕捉周期性脉冲的局部非高斯特性, 区分故障特征频率和噪声频率, 实现了对滚动轴承周期性故障特征的突出量化。



过程更加高效:包络谱峭度的高值区域指示潜在脉冲位置,而 $GM_{2\text{tol}}$ 的高值区域对应稀疏频带,两者的协同作用可快速定位最优参数组合,提升计算效率。其次, KG 的抗噪能力源于 $GM_{2\text{tol}}$ 对希尔伯特包络平方信号的处理,该方法减少了高斯噪声对包络谱峭度的干扰,使得在低信噪比条件下仍能稳定提取故障特征。此外, KG 的物理意义明确:包络谱峭度反映冲击能量的集中程度, $GM_{2\text{tol}}$ 表征脉冲在频域的分布规律,避免了单一指标可能存在的误判问题,从而提高特征提取的可靠性。

2 多尺度融合稀疏测度最大相关峭度解卷积故障特征提取模型

针对强噪声背景下的轴承故障信号,提出利用鹅优化算法优化 VMD 和 MCKD 的参数选取,构建玻尔兹曼香农互作用熵 BSIE 和多尺度稀疏测度 KG 适应度函数,实现对周期微弱故障特征的提取。故障特征提取模型如图 2 所示。




图 2 多尺度稀疏 MCKD 方法流程

Fig. 2 Flowchart of multi-scale sparse MCKD method

步骤 1)输入采集的振动信号 x ,以玻尔兹曼香农互作用熵为适应度函数,利用 GOOSE 算法优化 VMD 的惩罚因子 α 与模态数 K ,其中 $K \in [3, 7], \alpha \in [1\ 000, 3\ 000]$;

步骤 2)采用获取的最佳参数组合进行 VMD 分解,基于包络谱峭度最大准则筛选获得最优 IMF 分量;

步骤 3)采用多尺度稀疏测度作为 MCKD 参数优化的适应度函数,利用 GOOSE 算法搜索最优滤波长度 L 与周期 T ,位移数 M ;

步骤 4)利用最佳参数对最优模态进行 MCKD,提取振动信号的周期冲击成分;

步骤 5)采用包络谱图,分析比较故障特征频率,实现故障类型的诊断。

3 模型的仿真信号模拟与分析

为了模拟滚动轴承外圈故障的振动信号,首先构建了一个包含周期性冲击、外圈固有振动以及高斯白噪声的复合仿真信号:

$$x(t) = \sum_{k=0}^{N-1} e^{-a(t-kT)} \sin(2\pi f_{no}(t-kT)) \cdot u(t-kT) + \eta(t)$$

式中: $x(t)$ 为混合信号; $u(\cdot)$ 为单位阶跃函数; $\eta(t)$ 为高斯白噪声;外圈故障特征频率 f_0 (60 Hz),周期 T ($1/f_0$);外圈固有振动频率 f_{no} (3 000 Hz);衰减因子 a (1 500);采样频率 f_s (16 kHz);信号长度 L (8 192); N 为脉冲重复个数,信噪比 (SNR) 设置为 -16 dB。

图 3、4 分别为外圈轴承仿真信号的时域波形和包络谱图,添加强背景噪声后,在仿真信号的包络谱图中无法直接发现故障特征频率 f_o 。




图 3 仿真信号的时域波形

Fig. 3 Time domain waveform of simulated signals




图 4 仿真信号的包络谱图

Fig. 4 Envelope spectrum of simulated signals

为实现高噪声背景下轴承故障特征的有效提取,采

用多尺度稀疏测度最大峭度解卷积的方法对仿真信号进行分析。利用 GOOSE 算法以 BSIE 为优化目标对 VMD 的参数模态数 K 、惩罚因子 α 进行寻优,为了验证 GOOSE 算法在参数寻优上的优势,分别采用灰狼算法 (GWO)、黏菌优化算法 (SMA)、粒子群算法 (PSO) 进行迭代优化,其迭代曲线对比如图 5 所示。




图 5 适应度值优化对比

Fig. 5 Comparison of fitness value optimization

从图 5 可以看出 GOOSE 算法在第 3 次迭代时就已经完成了最佳适应度值的搜索,并且适应度值小于其余 3 种优化算法第 10 次迭代得到的适应度值,说明不论是在收敛速度还是适应度值的搜索上,GOOSE 算法相较于其他算法都更有优势。

为验证玻尔兹曼香农互作用熵 BSIE 在高噪声环境下对 VMD 参数寻优的有效性,分别以包络熵、信息熵、样本熵以及 BSIE 为适应度函数对 VMD 参数进行寻优,提取最优 IMF 分量的归一化故障特征幅值作为对比,具体结果如表 1 所示。

表 1 各适应度指标最优分量故障特征幅值

Table 1 The fault characteristic amplitude of the optimal component of each fitness index

适应度指标	最优模态分量	故障特征幅值/($\text{m}\cdot\text{s}^{-2}$)
包络熵	IMF3	0.022 4
信息熵	IMF5	0.040 2
样本熵	IMF4	0.056 4
BSIE	IMF4	0.058 8

从表 1 可以看出,样本熵和玻尔兹曼香农互作用熵 BSIE 的最优分量的故障特征频率幅值远大于另外两个适应度指标,说明最优模态中所包含的故障特征成分更多。以 BSIE 为适应度函数的最优分量的时域图与包络谱图如图 6 和 7 所示。

为了进一步说明 BSIE 的优势,以 BSIE 为适应度函数对原信号进行 VMD 分解,最优分量包络谱图如图 8 所示,能够观察到故障频率及其二倍频,以样本熵作为适应度值的 VMD 分解得到的最优分量的包络谱图,即图 8 中,仅能观察到故障频率,无法区分出其倍频成分,进一步说明了 BSIE 在强噪声干扰下的有效性。




图 6 BSIE-VMD 最优模态的时域图

Fig. 6 Time domain waveform of the optimal mode of BSIE-VMD




图 7 BSIE-VMD 最优模态的包络谱图

Fig. 7 The envelope spectrum of the optimal mode of BSIE-VMD




图 8 样本熵-VMD 最优模态的包络谱图

Fig. 8 Envelope spectrum of sample entropy-VMD

仅经过 VMD 处理得到的最优分量中,仍存在大量的干扰谱线,且只能较为明显地观察到二倍频,更高倍频的成分仍无法有效提取,为了进一步增强轴承故障的周期冲击成分,采用 MCKD 算法对 VMD 分解结果做进一步的特征增强,实现对故障特征频率的准确识别,采用 GOOSE 算法以多尺度测度稀疏指标 KG 为适应度函数对参数 MCKD 参数 $[L, T, M]$ 进行寻优,得到的最优参数组 $[794, 342, 5]$,其信号包络谱图如图 9 所示。

与 VMD 分解后的信号包络谱图进行对比,经过了多尺度稀疏 MCKD 的进一步提取,可以更加明显地观察到轴承




图 9 多尺度稀疏 MCKD 优化后包络谱图

Fig. 9 Multi-scale sparsity MCKD optimized envelope spectrum

背景下能够有效提取出对应故障特征,实现故障诊断。

通过比较 VMD 最优模态包络谱图与经过多尺度稀疏测度 MCKD 处理后的包络谱图,后者的特征频率频率更为明显,倍频同样清晰可见,干扰谱线明显减少,验证了 VMD 方法与 MCKD 结合的必要性,和多尺度稀疏测度 MCKD 在噪声环境提取故障特征的有效性。

4 模型的实际验证

4.1 轴承外圈故障特征提取

为了验证所提方法在实际滚动轴承故障信号的有效性,采用西安交通大学的 SY 滚动轴承加速寿命试验数据集进行实际验证,其实验平台如图 10 所示。




图 10 轴承加速寿命试验台

Fig. 10 Bearing acceleration life test bench

西安交通大学加速寿命试验台所采用的试验轴承为 LDK UER204 滚动轴承,轴承相关参数如表 2 所示。

表 2 LDK UER204 轴承结构参数

Table 2 LDK UER204 bearing structure parameters

参数	数值	参数	数值
外圈直径/mm	39.80	滚动体直径/mm	7.92
内圈直径/mm	29.30	滚动体个数	8
节圆直径/mm	34.55	接触角/(°)	0

选用的轴承外圈故障数据工况为转频 35 Hz、载荷 12 kN,采样频率为 25.6 kHz,采样点数为 32 768,采样时长为 1.28 s,由轴承相关参数,通过式 (21) 计算可得,其轴承外圈的理论故障特征频率为 107.912 Hz。

$$f_o = 0.5Z \left(1 - \frac{d}{D} \cos \alpha \right) f_r \tag{21}$$

$$f_i = 0.5Z \left(1 + \frac{d}{D} \cos \alpha \right) f_r \tag{22}$$

为了验证算法在高噪声环境下的有效性,将所采用轴承外圈故障信号的信噪比设置为 -16 dB,如图 11 所示,从包络谱中已经难以分辨故障频率及其倍频成分,其中存在大量的谱线干扰。




图 11 外圈故障信号时域波形包络谱图

Fig. 11 Envelope spectrum of outer ring fault signal

采用以 BSIE 为适应度函数、GOOSE 算法优化参数的 VMD 对信号进行处理,惩罚因子 $\alpha \in [1\ 000, 3\ 000]$,模态数 $K \in [3, 10]$,处理过后得到多个模态分量,根据包络谱峭度最大准则筛选出最优模态分量 IMF1,具体的 IMF 分量包络谱峭度如表 3 所示。

表 3 各模态分量包络谱峭度值

Table 3 The kurtosis values of the envelope spectra of IMF

模态分量	包络谱峭度/ ($\text{m} \cdot \text{s}^{-2}$)	模态分量	包络谱峭度/ ($\text{m} \cdot \text{s}^{-2}$)
IMF1	0.474	IMF6	0.461
IMF2	0.121	IMF7	0.337
IMF3	0.253	IMF8	0.017
IMF4	0.217	IMF9	0.112
IMF5	0.154		

将最优模态作为输入进行多尺度稀疏 MCKD 处理, MCKD 的 3 个优化参数设置为:滤波器长度 $L \in [100,$

1 000],解卷积周期 $[f_s/f_o - 10, f_s/f_o + 10]$, 位移数 $M \in [2, 7]$ 。

以多尺度稀疏测度 KG 为适应度值,利用 GOOSE 优化算法对参数组进行寻优,得到最优参数组[773,231,5]。经 MCKD 处理得到信号包络谱图如图 12 所示,从包络谱图中可以清楚看出故障特征频率 $f_o = 108.5$ Hz (与理论外圈故障频率相差 0.54%) 以及其倍频,能够实现有效的故障识别。




图 12 多尺度稀疏 MCKD 优化结果

Fig. 8 Optimization results of multi-scale sparse MCKD

为验证该方法相较于其他故障特征提取方法对高噪声环境下的故障特征的提取效果,用最小熵解卷积(minimum entropy deconvolution, MED)方法对含噪的轴承外圈故障信号进行处理,其处理结果如图 13 所示。




图 13 MED 故障特征提取包络谱图

Fig. 13 MED fault feature extraction envelope spectrum

可以看出, MED 提取结果的包络谱图中存在大量的噪声谱线的干扰,并不能实现故障特征的有效提取。证明了本文所提出的 GOOSE 算法优化 VMD-多尺度稀疏 MCKD 方法在高噪声背景下,轴承故障信号故障特征提取的有效性。

4.2 轴承内圈故障特征提取

内圈试验选用凯斯西储大学电气实验室提供的轴承内圈故障信号,驱动端轴承为 SKR6205-2RS 深沟球轴承,工况为转频 37.5 Hz,载荷 11 kN。信号采样频率为 12 kHz,采样时长为 1 s,轴承相关参数如表 4 所示,通过式(22)计算可得,其轴承内圈的理论故障特征频率为 162.179 Hz。

同样将信号的信噪比设置为 -16 dB,含噪声的轴承

表 4 SKR6205-2RS 深沟球轴承参数
Table 4 Parameters of SKR6205-2RS bearings

参数	数值	参数	数值
外圈直径/mm	52	滚动体直径/mm	7.94
内圈直径/mm	25	滚动体个数	9
节圆直径/mm	39.4	接触角/(°)	0




图 14 内圈故障信号时域图和包络谱图

Fig. 14 Time domain diagram and envelope spectrum diagram of inner ring fault signals

内圈故障信号的时域图和包络谱图如图 14 所示。

以 BSIE-VMD 方法对原信号进行分解,得到的最优参数组合为[1 977.122 8,10],其最优分量的包络谱如图 15 所示,虽然已经去除大量的噪声谱线的干扰,能够观察到故障特征频率,但未能有效识别其故障特征频率的倍频,同时还存在其他信号成分,可能造成误诊。




图 15 最优分量包络谱图

Fig. 15 Optimal component envelope spectrum

为进一步增强信号的周期脉冲成分,同时去除其他信号成分对诊断结果的影响,设置 MCKD 的参数组滤波器长度 $L \in [100, 1\ 000]$,解卷积周期 $[f_s/f_o - 10, f_s/f_o + 10]$,位移数 $M \in [2, 7]$,经过 GOOSE 算法以 KG 为适应度函数对 MCKD 参数组进行寻优,得到的最优参数组为

[542,74,4]。得到的 MCKD 处理结果的包络谱图如图 16 所示,可以清晰看到故障特征频率及其倍频,同时减少了其他信号成分的干扰。




图 16 多尺度稀疏 MCKD 优化包络谱图

Fig. 16 Multi-scale sparse MCKD optimized envelope spectrum

5 结 论

为解决强噪声下滚动轴承的微弱故障提取难题,本文研究了多尺度稀疏最大相关峭度解卷积方法。方法主要由“自适应分解筛选-多尺度指标优化解卷积”两大系统组成,利用玻尔兹曼熵交互作用熵以及 GOOSE 算法来完成 VMD 参数的全局寻优,结合包络谱峭度和几何均值构建多尺度稀疏测度指标 KG 对 MCKD 参数进行优化,解决了极低信噪比下模态混叠问题和单一测度表征限制。实验结果表明,在 -16 dB 下可以清晰提取故障特征频率及其多倍频,误差仅为 0.54%,可为早期微弱故障提供可靠支持。

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. Extraction of impact features of rolling bearing faults in vibration signals with strong background noise [J]. Journal of Vibration Engineering, 2021, 34(1): 202-210.

[2] 郭盼盼,张文斌,崔奔,等. 一种滚动轴承早期微弱故障检测与诊断方法[J]. 航空动力学报, 2025, 40(3): 349-366.
Guo Panpan, Zhang Wenbin, Cui Ben, et al. A method for detection and diagnosis of early weak faults in rolling bearings [J]. Journal of Aerospace Power, 2025, 40(3): 349-366.

[3] Huang N E, Shen Z, Long S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis [J]. Proceedings Mathematical Physical & Engineering Sciences, 1998, 454(1971): 903-995.

[4] 王泽,王红军. 基于多尺度排列熵的滚动轴承故障特征提取[J]. 组合机床与自动化加工技术, 2020(8): 30-34, 38.
Wang Ze, Wang Hongjun. Fault feature extraction of rolling bearings based on multi-scale permutation entropy [J]. Modular Machine Tool & Automatic Manufacturing Technique, 2020(8): 30-34, 38.

[5] Dragomiretskiy K, Zosso D. Variational mode decomposition [J]. IEEE Transactions on Signal Processing, 2013, 62(3): 531-544.

[6] He C B, Cheng X, Xiong L Y, et al. A novel maximum impulse amplitude deconvolution for rolling bearing weak fault identification enhanced by spectrum information guided VMD [J]. Mechanical Systems and Signal Processing, 2025, 237: 112973.

[7] 刘泽锐,邢济收,王红军,等. 基于 VMD 与快速谱峭度的滚动轴承故障诊断[J]. 电子测量与仪器学报, 2021, 35(2): 73-79.
Liu Zerui, Xing Jishou, Wang Hongjun, et al. Rolling bearing fault diagnosis based on VMD and fast spectral kurtosis [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(2): 73-79.

[8] 徐统,王红军. 基于 VMD 瞬时能量与 GA-RBF 的滚动轴承故障诊断[J]. 组合机床与自动化加工技术, 2020(2): 74-78, 83.
Xu Tong, Wang Hongjun. Rolling bearing fault diagnosis based on VMD instantaneous energy and GA-RBF [J]. Modular Machine Tool & Automatic Manufacturing Technique, 2020(2): 74-78, 83.

[9] 徐统,王红军,宋智勇,等. 基于 K-L 散度的 VMD 瞬时能量与 PNN 的滚动轴承故障诊断[J]. 电子测量与仪器学报, 2019, 33(8): 117-123.
Xu Tong, Wang Hongjun, Song Zhiyong, et al. Rolling bearing fault diagnosis based on VMD instantaneous energy and PNN using K-L divergence [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(8): 117-123.

[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] 李东炎,李常贤. 基于动态 PSO-MCKD-HHT 的滚动轴承故障诊断方法研究与应用[J]. 电子测量技术, 2021, 44(21): 12-18.
Li Dongyan, Li Changxian. Research and application of rolling bearing fault diagnosis method based on dynamic PSO-MCKD-HHT [J]. Electronic Measurement Technology, 2021, 44(21): 12-18.

[12] 刘兴教,赵学智,李伟光,等. 基于峭度原则的 EEMD-

- MCKD 的柔性薄壁轴承故障特征提取[J]. 振动与冲击, 2021, 40(1): 157-164.
- Liu Xingjiao, Zhao Xuezh, Li Weiguang, et al. Fault feature extraction of flexible thin-walled bearings based on EEMD-MCKD with kurtosis principle [J]. Journal of Vibration and Shock, 2021, 40(1): 157-164.
- [13] 潘昕怡. 基于 VMD 和 MCKD 的机车滚动轴承故障诊断研究[D]. 北京: 北京交通大学, 2022.
- Pan Xinyi. Research on fault diagnosis of locomotive rolling bearings based on VMD and MCKD[D]. Beijing: Beijing Jiaotong University, 2022.
- [14] 任良, 甄龙信, 赵云, 等. 基于 SSA-VMD-MCKD 的强背景噪声环境下滚动轴承故障诊断[J]. 振动与冲击, 2023, 42(3): 217-226.
- Ren Liang, Zhen Longxing, Zhao Yun, et al. Rolling bearing fault diagnosis under strong background noise environment based on SSA-VMD-MCKD[J]. Journal of Vibration and Shock, 2023, 42(3): 217-226.
- [15] 王冬, 侯炳昌, 王玉婷, 等. 稀疏测度和复杂性测度及其在设备健康监测中的研究进展[J]. 机械工程学报, 2025, 61(1): 123-139.
- Wang Dong, Hou Binchang, Wang Yuting, et al. Research progress on sparsity measures and complexity measures and their applications in equipment health monitoring [J]. Journal of Mechanical Engineering, 2025, 61(1): 123-139.
- [16] Hou B C, Xie M, Yan H, et al. Impulsive mode decomposition [J]. Mechanical Systems and Signal Processing, 2024, 211: 111227.
- [17] 苗永浩, 石惠芳, 李晨辉, 等. 周期精炼的最大相关峭度解卷积在滚动轴承微弱故障特征提取中的应用[J]. 振动工程学报, 2025, 38(6): 1317-1325.
- Miao Yonghao, Shi Huifang, Li Chenghui, et al. Application of periodic refined maximum correlated kurtosis deconvolution in weak fault feature extraction of rolling bearings [J]. Journal of Vibration Engineering, 2025, 38(6): 1317-1325.
- [18] Hamad R K, Rashid T A. GOOSE algorithm: A powerful optimization tool for real-world engineering challenges and beyond[J]. Evolving Systems, 2024, 15(4): 1249-1274.
- [19] Diggans C T, Almomani A A R. Boltzmann-Shannon interaction entropy: A normalized measure for continuous variables with an application as a subsample quality metric [J]. Chaos: An Interdisciplinary Journal of Nonlinear Science, 2023, 33(12): 123108.

作者简介



王宇森, 2021 年于重庆文理学院获得学士学位, 现为北京信息科技大学硕士研究生, 主要研究方向为旋转机构故障诊断关键技术研究。

E-mail: wangys780@163.com

Wang Yusen received his B. Sc. degree from Chongqing University of Arts and Sciences in 2021. Now he is a M. Sc. candidate at Beijing University of Information Science and Technology. His main research interest includes key technologies for fault diagnosis of rotating mechanisms.



王红军 (通信作者), 2005 年于北京理工大学获得博士学位, 现为北京信息科技大学教授、博士生导师, 主要研究方向为高端装备智能感知与控制、故障诊断与智能运维。

E-mail: wanghj86@163.com

Wang Hongjun (Corresponding author) received her Ph. D. degree from Beijing Institute of Technology in 2005. Now she is a professor and Ph. D. supervisor at Beijing Information Science and Technology University. Her research interests include intelligent sensing and control of high-end equipment, fault diagnosis and intelligent maintenance.