

控制与决策

Control and Decision

基于贝叶斯优化与信号重构的旋转机械故障诊断

陈科, 姬梦晓, 于坤杰, 廖粤峰

引用本文:

陈科, 姬梦晓, 于坤杰, 等. 基于贝叶斯优化与信号重构的旋转机械故障诊断[J]. *控制与决策*, 2026, 41(4): 1135-1142.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2025.0557>

您可能感兴趣的其他文章

Articles you may be interested in

基于动态观测器零极点优化的网络控制系统故障检测

Pole-zero optimization design of dynamic observer for fault detection of networked control systems

控制与决策. 2021, 36(6): 1351-1360 <https://doi.org/10.13195/j.kzyjc.2019.1107>

线控转向系统的自适应高阶滑模控制

Adaptive higher-order sliding mode control for SbW system

控制与决策. 2021, 36(6): 1529-1536 <https://doi.org/10.13195/j.kzyjc.2019.1526>

基于变速趋近律的Buck型变换器抗扰动控制

Disturbance rejection control of Buck converters based on variable rate reaching law

控制与决策. 2021, 36(4): 893-900 <https://doi.org/10.13195/j.kzyjc.2019.1073>

基于向量集逆区间滤波的故障观测器设计

Vector set inversion interval filtering based fault observer design

控制与决策. 2021, 36(12): 2973-2981 <https://doi.org/10.13195/j.kzyjc.2020.0212>

高超声速飞行器间歇故障改进自适应容错控制

Improved adaptive fault-tolerant control of intermittent faults in hypersonic flight vehicle

控制与决策. 2021, 36(11): 2627-2636 <https://doi.org/10.13195/j.kzyjc.2020.0483>

基于贝叶斯优化与信号重构的旋转机械故障诊断

陈科^{1,2}, 姬梦晓^{1,2}, 于坤杰^{1,2†}, 廖粤峰^{1,2}

(1. 郑州大学 电气与信息工程学院, 郑州 450001; 2. 龙门实验室, 河南 洛阳 471000)

摘要: 在复杂工况下, 旋转机械的振动信号通常表现出显著的非平稳性, 并伴随较强的噪声干扰, 导致传统信号处理方法在故障特征提取方面面临较大挑战. 鉴于此, 提出一种基于贝叶斯优化和信号重构的旋转机械故障诊断方法. 首先, 利用贝叶斯优化算法对逐次变分模态分解核心参数进行自适应调整; 然后, 提出一种基于平均瞬时频率的垂直距离判别方法, 用于区分逐次变分模态分解所得固有模态函数的高低频分量; 接着, 设计一种相关系数加权策略, 对不同固有模态函数进行加权重构; 最后, 从时域、频域和时频域提取多维特征构建特征集, 并进行故障分类. 通过在多个数据集上的实验比较和分析, 同时与现有方法进行对比, 验证了所提出方法的有效性和优越性.

关键词: 旋转机械; 故障诊断; 信号分解; 贝叶斯优化; 逐次变分模态分解; 信号重构

中图分类号: TP273 文献标志码: A

DOI: 10.13195/j.kzyjc.2025.0557

引用格式: 陈科, 姬梦晓, 于坤杰, 等. 基于贝叶斯优化与信号重构的旋转机械故障诊断 [J]. 控制与决策, 2026, 41(4): 1135-1142.

Fault diagnosis of rotating machinery based on Bayesian optimization and signal reconstruction

CHEN Ke^{1,2}, JI Meng-xiao^{1,2}, YU Kun-jie^{1,2†}, LIAO Yue-feng^{1,2}

(1. School of Electrical and Information Engineering, Zhengzhou University, Zhengzhou 450001, China; 2. Longmen Laboratory, Luoyang 471000, China)

Abstract: Under complex working conditions, the vibration signals of rotating machinery usually exhibit significant non-stationarity and are accompanied by strong noise interference, which leads to greater challenges for traditional signal processing methods in extracting fault features. In response to the above problems, this paper proposes a fault diagnosis method for rotating machinery based on Bayesian optimization and signal reconstruction. Firstly, the Bayesian optimization algorithm is utilized to adaptively adjust the core parameters of successive variational mode decomposition. Secondly, a vertical distance discrimination method based on the average instantaneous frequency is proposed to distinguish the high and low frequency components of the inherent mode function obtained by successive variational mode decomposition. Then, a correlation coefficient weighting strategy is designed to conduct weighted reconstruction of different inherent mode functions. Finally, multi-dimensional features are extracted from the time domain, frequency domain and time-frequency domain to construct the feature set and conduct fault classification. Through experimental comparisons and analyses on multiple datasets and comparisons with existing methods, the effectiveness and superiority of the proposed method are verified.

Keywords: rotary machinery; fault diagnosis; signal decomposition; Bayesian optimization; successive variational mode decomposition; signal reconstruction

0 引言

旋转机械是现代工业和日常生活的核心设备, 广泛应用于能源、制造、交通和化工等领域, 它在能

量转换和传递中扮演重要角色, 如电动机、发电机和汽轮机等. 旋转机械的高效性、可靠性和智能化发展促进了节能减排和技术进步, 对于安全生产和环保

收稿日期: 2025-05-29; 录用日期: 2025-07-25.

基金项目: 国家自然科学基金项目 (62206255, 62476254); 河南省自然科学基金项目 (252300421501); 河南省科协青年人才托举项目 (2024HYTP023); 河南省重点研发专项项目 (251111113900); 龙门实验室前沿探索课题项目 (LMQYTSKT031); 河南省高校科技创新人才支持计划项目 (23HASTIT023).

责任编辑: 王凌.

†通信作者. E-mail: yukunjie@zzu.edu.cn.

也具有重要意义^[1-3].

旋转机械故障诊断一般流程包括以下步骤:首先,利用传感器采集振动信号,获得设备运行的原始数据;然后,进行信号预处理,包括去噪、滤波等操作;接着,提取多域特征,获取反映故障类型的信息;随后,通过特征选择方法选择关键特征;最后,利用分类器构建故障诊断模型,对设备状态进行识别和分类,实现故障类型的准确判断^[4].

信号预处理在旋转机械故障诊断中至关重要,是保障特征提取和模型构建准确性的基础.原始振动信号常受到噪声和无关信息干扰,若未经处理,则关键故障特征易被掩盖,影响诊断结果.通过去噪、滤波、归一化等预处理手段,可有效增强故障特征的表达能力和稳定性,为后续诊断提供可靠支持.在旋转机械故障诊断中,复杂工况是指旋转机械在运行过程中所面临的工作条件较为复杂、多变且难以预测的情况.如在钢铁厂、矿山等工业现场,旋转机械的运行环境存在大量的强噪声源,这些强噪声会与机械的振动信号混合在一起,掩盖微弱的故障特征,使得故障诊断变得更加困难.近年来,针对复杂工况下振动信号的非平稳性和强噪声干扰,研究者提出了多种先进的信号分解方法用于预处理,其中较为常见的包括经验模态分解^[5]、集合经验模态分解^[6]、变分模态分解和逐次变分模态分解等.变分模态分解将信号分解为若干有限带宽的本征模态分量,具有良好的数学可控性和频域分离能力,但是,其分解效果对于预设的模态数和惩罚因子高度敏感;逐次变分模态分解在此基础上引入了逐模态提取机制,具备自适应参数更新和多种停止准则,提升了对非平稳、多尺度信号的适应性以及抗噪性能.

在逐次变分模态分解中,惩罚因子作为控制模态带宽和频谱集中的核心参数,对于模态分离效果起着关键作用^[7].惩罚因子的选择直接影响信号分解的精细程度和模态的物理可解释性,因此,开展有效的参数优化对于提升逐次变分模态分解的分解性能和稳定性具有重要意义.如 Sun 等^[8]提出了一种基于声音信号的列车塞拉门故障智能诊断方法,融合了经验模态分解信号重构、加权分数阶小波包能量熵和支持向量机分类器,虽然通过粒子群算法同步优化特征权重和模型参数实现了一定的诊断效果,但是,未对信号分解过程中的关键参数进行优化,导致模态分量的物理可解释性和分解稳定性较弱;Wen 等^[9]提出了一种基于贝叶斯优化的自适应变分模态分解方法,用于提升旋转机械中永磁同步电机匝间短路故障的诊断准确性,尽管该方法增强了

VMD (variational mode decomposition) 在参数选择上的自适应性,并结合 Hilbert 变换和三维时频图改善了特征可视化效果,但是其优化目标函数较为单一,未充分结合下游诊断任务需求,且对参数空间设置和优化收敛性的讨论仍然不充分.为克服现有方法的不足,本文利用贝叶斯优化算法对逐次变分模态分解惩罚因子进行自适应调节.

旋转机械常在复杂工况下产生故障,其振动信号通常具有非平稳性强、噪声干扰大、瞬态特征难以捕捉等特点,导致现有信号处理方法难以实现高精度故障识别^[8].针对上述问题,本文提出一种基于贝叶斯优化和信号重构的旋转机械故障诊断方法,旨在自适应调整信号分解参数,改善复杂工况背景下的模态提取效果,从而提高故障分类的准确率.

本文主要内容如下:

- 1) 利用贝叶斯优化算法对逐次变分模态分解参数进行自适应调节,可有效提升信号分解的质量和稳定性;
- 2) 设计一种基于平均瞬时频率的最大垂直距离判别方法,通过度量各固有模态函数分量间的频率差异来实现对高低频成分的准确区分;
- 3) 设计一种基于相关系数加权的信号重构方法,通过为各固有模态函数分量赋予差异化权重,从而提高重构信号的判别能力和特征质量.

1 相关理论基础

1.1 逐次变分模态分解 (SVMD)

逐次变分模态分解是一种信号处理方法,通过变分模态分解将复杂信号分解为多个模态函数,并通过迭代优化提取不同频率成分,最终重构原始信号^[10-11].SVMD 分解步骤如下.

step 1: 问题建模目标是将输入信号 $f(t)$ 分解为一组带限模态 $\{u_k(t)\}$, 每个模态集中于一个中心频率 ω_k . 原始优化目标 (每个模态的) 如下所示:

$$\min_{u_k, \omega_k} \|\partial_t^2 [(u_k(t)e^{-j\omega_k t})]\|_2^2 + \alpha \left\| f(t) - \sum_k u_k(t) \right\|_2^2. \quad (1)$$

其中: α 为惩罚因子, ∂_t^2 表示对模态 $u_k(t)$ 的二阶导数. 在逐次变分模态分解中,每次只提取一个模态 u_i , 其频谱表示为 $\hat{u}_i(\omega)$, 对应中心频率为 ω_i .

step 2: 频域建模 (每次一个模态) 在频域中使用变分形式,每次提取一个模态,有

$$\min_{\hat{u}_i, \omega_i} \|(\omega - \omega_i)^2 \hat{u}_i(\omega)\|_2^2 + \alpha \left\| \hat{f}(\omega) - \hat{u}_i(\omega) - \sum_{i=1}^{l-1} \hat{u}_i(\omega) \right\|_2^2. \quad (2)$$

其中: $\hat{f}(\omega)$ 为信号 $f(t)$ 的频谱表示, $\hat{u}(\omega)$ 为第 l 个模态的频谱表示, ω 为频域上的频率变量, ω_l 为当前模态的中心频率.

step 3: 采用拉格朗日乘子法求解上述问题, 引入拉格朗日乘子 $\lambda(\omega)$ 构建增广拉格朗日函数, 如下所示:

$$L(\hat{u}, \omega, \lambda) = \|(\omega - \omega_l)^2 \hat{u}(\omega)\|_2^2 + \alpha \left\| \hat{f}(\omega) - \hat{u}(\omega) - \sum \hat{u}_i(\omega) \right\|_2^2 + \lambda(\omega) \cdot \left(\hat{f}(\omega) - \sum \hat{u}(\omega) \right), \quad (3)$$

其中 $\lambda(\omega)$ 为拉格朗日乘子.

通过交替方向乘子法进行迭代优化, 分别更新: $\hat{u}_l^{(n+1)}(\omega)$ 为第 l 个模态的频谱, $\omega_l^{(n+1)}$ 为第 l 个模态的中心频率, $\lambda^{(n+1)}(\omega)$ 为拉格朗日乘子的更新.

step 4: 模态更新公式.

1) 模态频谱更新如下所示:

$$\hat{u}^{(n+1)}(\omega) = \frac{\hat{f}(\omega) + \frac{1}{2} \lambda^{(n)}(\omega) + R^{(n)}(\omega)}{1 + \alpha^2 (\omega - \omega_l^{(n)})^4 + \Phi(\omega)}. \quad (4)$$

其中: $R^{(n)}(\omega)$ 来自先前模态的叠加, $\Phi(\omega)$ 为优化频谱形态的附加滤波项.

2) 中心频率更新公式如下所示:

$$\omega_l^{(n+1)} = \frac{\int_{\omega>0} \omega |\hat{u}^{(n+1)}(\omega)|^2 d\omega}{\int_{\omega>0} |\hat{u}^{(n+1)}(\omega)|^2 d\omega}. \quad (5)$$

式 (5) 通过计算频谱的加权平均来确定模态的中心频率 $\omega_l^{(n+1)}$.

step 5: 模态选择的停止条件 SVMd 支持多种停止准则, 如误差收敛、模态数达到预设值、包络熵最小等.

step 6: 信号重构提取完所有模态后, 使用逆快速傅里叶变换将模态从频域重构回时域, 如下所示:

$$u_i(t) = \text{Re}(\text{IFFT}(\hat{u}_i(\omega))), \quad (6)$$

其中 $u_i(t)$ 为获得实值时域信号.

1.2 贝叶斯优化

贝叶斯优化是一种基于概率模型的优化方法, 旨在通过构建一个目标函数的概率模型来引导搜索过程. 与网格搜索和随机搜索不同, 贝叶斯优化通过迭代更新超参数的概率分布, 逐步选择最有可能改善性能的超参数组合, 从而高效地优化搜索过程^[12]. 具体步骤如下.

step 1: 构建一个代理模型来估计超参数空间中不同点的目标函数值;

step 2: 根据代理模型选择下一个要评估的超参

数组组合, 通常是选择期望改进最大的点;

step 3: 评估该超参数组合的实际性能, 并将结果反馈给代理模型;

step 4: 重复该过程直至达到预设的评估次数或收敛条件.

2 基于贝叶斯优化和信号重构的故障诊断

2.1 基本框架

本文提出一种基于贝叶斯优化和信号重构的旋转机械故障诊断方法, 其基本框架如图 1 所示. 该方法包括信号采集、信号重构以及故障分类 3 个主要步骤, 旨在提高旋转机械诊断精度.

2.2 基于贝叶斯优化算法的参数优化

本文提出基于贝叶斯优化的逐次变分模态分解参数优化方法, 通过优化关键参数 (惩罚因子), 以包络谱峰值因子作为分解效果的评价指标. 包络谱峰值因子越低, 模态越清晰, 能量越集中. 贝叶斯优化 SVMd 的流程如图 2 所示. 具体步骤如下.

step 1: 构造目标函数, 以包络谱峰值因子最小化为优化目标, 定义如下: 1) 信号 $f(t)$ 经逐次变分模态分解为 K 个固有模态函数 $u_i(t)$; 2) 对每个固有模态函数进行希尔伯特变换, 得到包络信号 $a_i(t)$, 即

$$a_i(t) = |\mathcal{H}[u_i(t)]|; \quad (7)$$

3) 定义第 i 个固有模态函数的包络谱峰值因子为

$$\text{CF}_i = \frac{\max(a_i(t)) - \min(a_i(t))}{\text{RMS}(u_i(t))}, \quad (8)$$

其中 $\text{RMS}(u_i(t))$ 为第 i 个模态的均方根值; 4) 最终优化目标函数为所有固有模态函数中的最小峰值因子, 如下所示:

$$\min_{\alpha} \text{Fitness}(\alpha), \quad (9)$$

这里 α 为 SVMd 的惩罚因子.

step 2: 利用贝叶斯优化对目标函数进行迭代求解, 设定最大评估次数, 自动记录每次评估的目标值和对应参数. 在最终优化结果中提取使得目标函数值最小的最优惩罚因子 α^* , 即

$$\alpha^* = \arg \min_{\alpha} \text{Fitness}(\alpha), \quad (10)$$

其中 α^* 为经贝叶斯优化获得的最优惩罚因子.

step 3: 将获得的最优参数 α^* 应用于逐次变分模态分解模型, 完成信号的最终分解, 如下所示:

$$[\text{IMF}, \hat{u}, \omega] = \text{SVMD}(f(t), \alpha^*, \tau, \text{tol}, \text{stopc}). \quad (11)$$

其中: IMF 为最终分解得到的固有模态函数, \hat{u} 为模态的频谱表示, ω 为每个模态的频率, τ 为拉格朗日乘子更新步长, tol 为收敛容差, stopc 为停止准则类

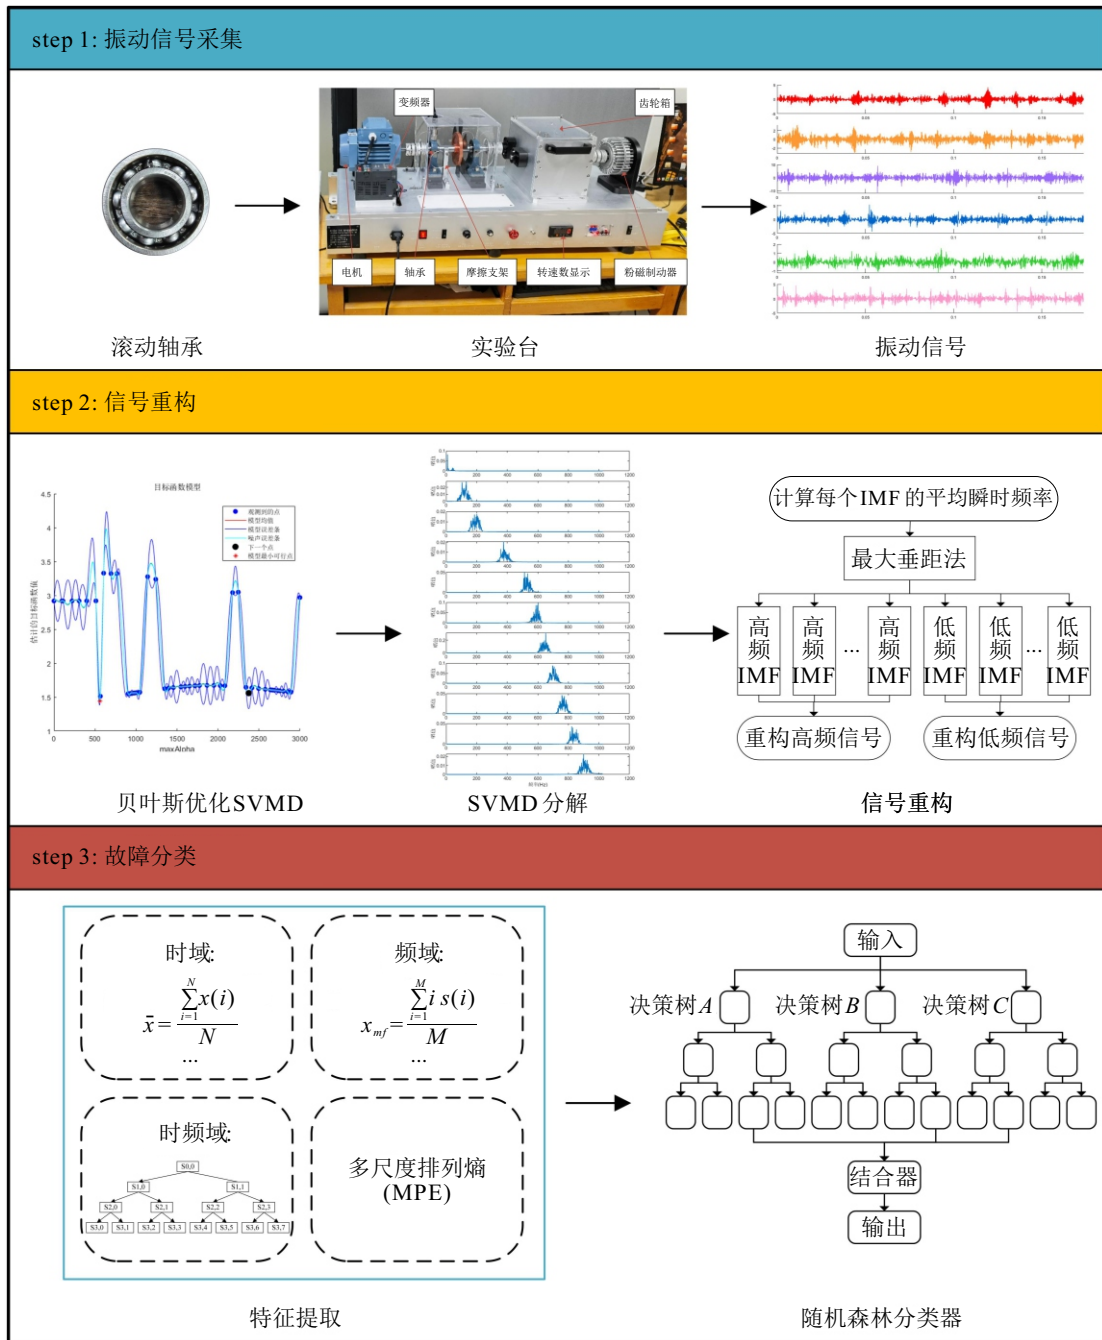


图1 基于贝叶斯优化和信号重构的旋转机械故障诊断流程

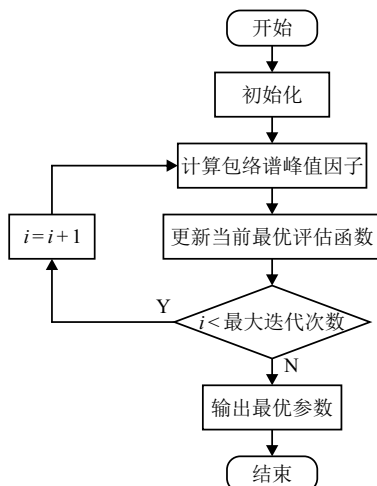


图2 贝叶斯优化 SVM 流程

型.

2.3 基于平均瞬时频率的最大垂直距离法

为实现逐次变分模态分解后固有模态函数分量的高低频自动区分, 本文设计一种基于平均瞬时频率的最大垂直距离法. 具体而言, 首先, 对每个固有模态函数计算其解析信号的瞬时频率, 瞬时频率反映了信号频率随时间的变化情况, 通常用于分析信号的频率特性; 然后, 计算每个固有模态函数的平均瞬时频率, 并将这些频率值形成一组序列, 将固有模态函数的序号作为横坐标, 平均瞬时频率作为纵坐标, 绘制成一张折线图, 连接该折线图的首尾两点, 形成一条参考直线; 最后, 计算每个固有模态函数曲

线上的点到参考直线的垂直距离,垂直距离的计算方法是通过每个点求其到参考直线的最短距离(即垂直距离),选取所有垂直距离中的最大值,所对应的固有模态函数序号即为高低频分界点.分界点之前的所有固有模态函数分量被归为高频部分,而分界点之后的固有模态函数分量则归为低频部分^[13].

2.4 基于相关系数加权的信号重构方法

信号重构是预处理中的关键步骤,有助于提取特征、降低噪声并恢复信号完整性.在信号重构过程中,高频分量更侧重于快速响应和细节捕捉,而低频分量则关注长期趋势和稳定性评估.因此,将高频分量与低频分量分别进行相关系数加权重构,能够有效避免单一尺度特征信息的丢失,并增强对瞬态冲击和长期工况波动的表征能力.

为提升重构效果,本文通过相关系数分析,根据分量与原始信号的相关性进行加权重构.具体地,假设高频组合和低频组合分别为 $u_h = \{u_1, u_2, \dots, u_m\}$ 和 $u_l = \{u_{m+1}, u_{m+2}, \dots, u_k\}$, 其中 $m < k$. 首先,计算高频组合和低频组合中各分量与原始信号间的相关系数,分别为 $\rho_h = \{\rho_1, \rho_2, \dots, \rho_m\}$ 和 $\rho_l = \{\rho_{m+1}, \rho_{m+2}, \dots, \rho_k\}$, ρ_h 和 ρ_l 计算如下所示:

$$\rho = \frac{\text{cov}(x(t), u_i)}{\sigma_{x(t)} \sigma_{u_i}}. \quad (12)$$

这里: $\text{cov}(x(t), u_i)$ 为协方差, $\sigma_{x(t)}$ 、 σ_{u_i} 分别为 $x(t)$ 和 u_i 的标准差. 具体内容如下.

1) 高频分量的加权重构为

$$x_{\text{高}}(t) = \sum_{h=1}^m \left(\frac{\rho_h}{\sum_{j=1}^m \rho_j} \cdot u_h \right). \quad (13)$$

其中: ρ_h 为第 h 个高频模态与原始信号的相关系数, u_h 为第 h 个高频模态分量.

2) 低频分量的加权重构为

$$x_{\text{低}}(t) = \sum_{i=m+1}^k \left(\frac{\rho_i}{\sum_{j=m+1}^k \rho_j} \cdot u_i \right). \quad (14)$$

其中: ρ_i 为第 i 个低频模态与原始信号的相关系数, u_i 为第 i 个低频模态分量.

2.5 多域特征提取

本文对于重构后的高频信号和低频信号,将采用统计特征法分别进行多域特征提取,包括时域、频域和时频域 3 类特征. 提取特征的相关介绍如下.

1) 时域特征 (12 维): 均值、标准差、偏度、峰度、峰值、均方根、波峰因子、波形因子、撞击因子、裕度

因子、最小值、最大值. 时域特征可直接反映设备运行的状态变化,包括正常状态和异常状态,提供了最直观的信息^[14].

2) 频域特征 (6 维): 平均频率、重心频率、频率均方根、频率标准差、频谱熵、包络信号谱熵. 频域特征揭示了信号的频率成分,能够更好地理解旋转机械的振动特性. 频域分析将复杂的时域信号转换为直观的频谱形式,便于检测谐波成分^[15]. 这些谐波往往与特定类型的故障密切相关.

3) 时频域特征 (14 维): 时频域特征能够揭示信号中频率成分及其随时间的演变,有助于全面分析信号的复杂性和潜在的故障机理^[16]. 本文共提取 14 维时频域特征. 其中: 8 维为小波包分解第 3 层 8 个频带的能量熵,用于表征不同频段的能量分布情况; 6 维为多尺度排列熵,分别在 6 个不同的粗粒化尺度下计算,用于刻画信号从高频瞬态到低频趋势的复杂性,增强对非平稳和弱特征的捕获能力.

2.6 故障分类

本文对提取后的多域特征集采用随机森林分类器进行故障类型识别. 随机森林是一种集成学习方法,通过多个决策树构建并结合投票机制,能够实现类别划分. 相比于其他方法,该方法适用于特征维度较高、特征间存在非线性关系的故障诊断场景^[17]. 针对重构后的高低频信号所提取的时域、频域以及时频域特征,本文将将其组合为统一的特征向量输入随机森林模型,通过训练和测试样本的对比来验证分类效果.

3 实验与结果分析

3.1 数据选择

为了测试算法的性能,实验采用山东大学的 PT500mini 实验台. 振动信号由加速度传感器采集,采样频率为 10 kHz,转速为 1200 转/min,共采集 2700 个样本. 实验针对 6 种故障状态进行分析,包括滚动体故障、轴承综合故障三秒、轴承内圈故障、轴承外圈故障、保持架故障以及正常状态. 通过采集的时序信号,构建了一个 32 维特征数据集,其中: 第 1 维 ~ 第 12 维为时域特征,第 13 维 ~ 第 18 维为频域特征,第 19 维 ~ 第 32 维为小波包分解和多尺度排列的时频域特征.

除上述山东大学 (SDU) 轴承数据集,还采用其他测试台公开的实验数据用于验证. 具体如下:

1) 江南大学 (JNU): 由江南大学提供^[18];

2) 渥太华大学 (UO): 由渥太华大学提供^[19];

3) 西安交通大学 (XJTU): 由西安交通大学设计科学与基础部件研究所提供^[20].

3.2 实验结果与分析

为验证贝叶斯优化在逐次变分模态分解参数选择中的有效性, 本文设计了参数优化前后的对比实验, 实验结果如图 3 所示. 在本实验中, 逐次变分模

态分解涉及的参数设置如下: 惩罚因子: 优化前设置为固定值 1000, 优化后由贝叶斯优化算法自适应选取, 搜索范围设定为 [0, 3000]; 拉格朗日乘子步长 $\tau = 0$; 收敛容差 $\text{tol} = 10^{-6}$; 停止准则类型 $\text{stopc} = 4$, 即通过比较相邻两个模式的功率变化来决定是否停止迭代.

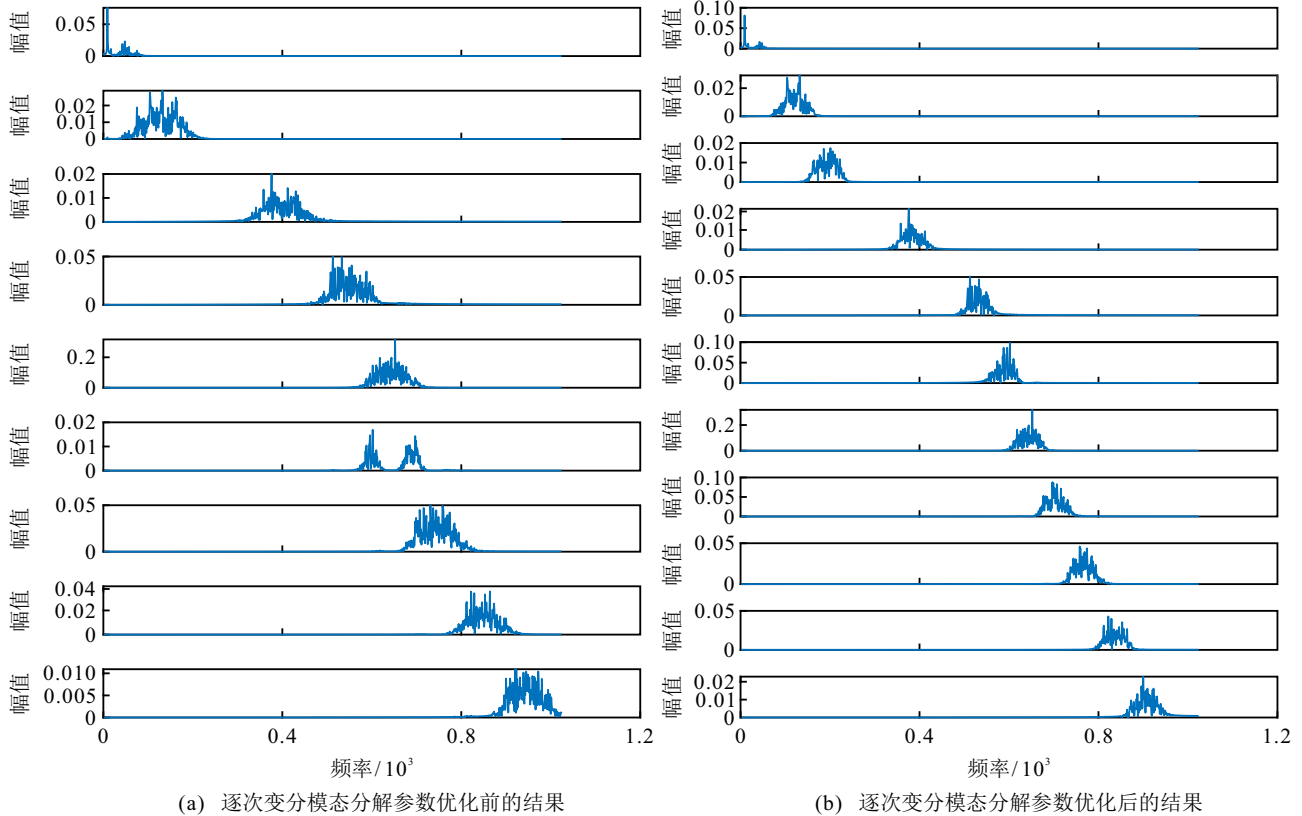


图3 SVMD 参数优化前后对比频谱图

由图 3 可知, 贝叶斯优化显著提升了参数选择的适应性和分解性能. 优化后的固有模态函数分量在频率轴上的分布更加均衡, 频带划分更清晰, 有效减少了模态间的频谱重叠和冗余现象.

为验证所提出方法的分类效果, 本文选择了 4 种方法进行对比: DWTVFD^[21]、EEMDBLP^[22]、MOFD^[23] 以及 TFWPD^[24], 结果如表 1 所示. 实验中, 对比算法和所提出算法的参数参见相关文献的建议. 每种算法独立运行 30 次. 实验采用每个数据集中 70% 的样本作为训练集, 30% 的样本作为测试集, 并使用随机森林评估训练集的分类错误率, 以避免特

征选择偏差. 最终通过测试集评估优化后的特征子集分类准确性. 该实验为验证所提出方法提供了全面且可靠的对比.


从实验结果来看, 所提出 BOSR 方法在所有数据集上的表现均非常出色, 尤其是在 SDU 数据集上达到了几乎 100% 的准确率, 显著优于其他现有方法. 此外, 采用混淆矩阵 (如图 4 所示) 表示 BOSR 在上述数据集的故障分类结果. 总体而言, BOSR 方法在所有数据集中的表现均明显优于其他几种现有分类方法.

为验证所提出算法在不同噪声条件下的故障诊断性能, 本文通过向振动信号中添加不同强度的噪声, 模拟了实际工况下可能会出现噪声环境. 表 2 展示了数据集在不同噪声条件下的变化.


结果表明, 即使在不同噪声情况下, 所有数据集的故障诊断性能变化较小. 因此, 所提出算法具有较强的抗噪性和鲁棒性.

表1 故障分类准确率 %


数据集	DWTVFD	EEMDBLP	MOFD	TFWPD	BOSR
SDU	98.29	99.63	99.79	90.20	99.82
JNU	81.78	84.54	94.29	93.95	94.42
UO	90.47	90.30	97.43	88.50	99.75
XJTU	83.19	94.23	95.79	97.04	97.28




(a) SDU



(b) JNU



(c) UO



(d) XAJU

图4 故障分类的混淆矩阵

表2 不同信噪比下 BOSR 算法的分类准确率 %

数据集	Noise-free	-2	-4	-6	-8	-10
SDU	99.82	99.65	99.62	99.61	99.55	99.54
JNU	94.42	94.39	94.06	93.63	93.07	92.03
UO	99.75	96.12	95.58	95.01	94.88	94.32
XJTU	97.28	97.18	97.05	96.81	96.28	95.94

4 结论

针对复杂工况下旋转机械振动信号的非平稳性和强噪声干扰问题,本文提出了一种基于贝叶斯优化和信号重构的旋转机械故障诊断方法.首先,利用贝叶斯优化算法实现了对逐次变分模态分解中惩罚因子的有效自适应调节;然后,针对分解后固有模态函数的高低频划分问题,设计了基于平均瞬时频率的最大垂直距离法,自动确定频率突变点;最后,通过相关系数加权重构策略,为不同模态分量分配了差异化权重,增强了关键信息对于重构信号的贡献,进一步提升了重构质量.实验结果表明,所提出方法在处理非平稳、噪声背景显著的复杂振动信号时展现出了良好的故障分类精度和鲁棒性.

参考文献 (References)

- [1] 高佳, 王艳红, 张俊, 等. 基于多元信号自适应分解的轴承故障诊断方法[J]. 控制与决策, 2025, 40(7): 2233-2241.
(Gao J, Wang Y H, Zhang J, et al. Bearing fault diagnosis method based on adaptive decomposition of multivariate signals[J]. Control and Decision, 2025, 40(7): 2233-2241.)
- [2] Liu D D, Cui L L, Wang H Q. Rotating machinery fault diagnosis under time-varying speeds: A review[J]. IEEE Sensors Journal, 2023, 23(24): 29969-29990.
- [3] 周旷, 覃文博, 孙天宇. 基于可信多源领域自适应的跨域滚动轴承故障诊断[J]. 控制与决策, 2025, 40(7): 2251-2260.
(Zhou K, Qin W B, Sun T Y. Cross-domain fault diagnosis of rolling bearings based on trusted multi-source domain adaptation[J]. Control and Decision, 2025, 40(7): 2251-2260.)
- [4] Ding X X, Li Q C, Lin L, et al. Fast time-frequency manifold learning and its reconstruction for transient feature extraction in rotating machinery fault diagnosis[J]. Measurement, 2019, 141: 380-395.
- [5] 沈志熙, 黄席樾, 马笑潇. 基于 EMD 多模态特征融合支持向量机的故障诊断[J]. 控制与决策, 2009, 24(6): 889-893.
(Shen Z X, Huang X Y, Ma X X. Fault diagnosis method based on empirical mode decomposition and support vector machine[J]. Control and Decision, 2009, 24(6): 889-893.)
- [6] Li H, Liu T, Wu X, et al. Research on test bench bearing fault diagnosis of improved EEMD based on improved

- adaptive resonance technology[J]. *Measurement*, 2021, 185: 109986.
- [7] Park J, Kim Y, Na K, et al. An image-based feature extraction method for fault diagnosis of variable-speed rotating machinery[J]. *Mechanical Systems and Signal Processing*, 2022, 167: 108524.
- [8] Sun Y K, Cao Y, Li P. Fault diagnosis for train plug door using weighted fractional wavelet packet decomposition energy entropy[J]. *Accident Analysis & Prevention*, 2022, 166: 106549.
- [9] Wen T, Dong D Y, Chen Q Y, et al. Maximal information coefficient-based two-stage feature selection method for railway condition monitoring[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2019, 20(7): 2681-2690.
- [10] Nazari M, Sakhaei S M. Successive variational mode decomposition[J]. *Signal Processing*, 2020, 174: 107610.
- [11] Zhang L J, Zhang Y J, Li G F. Fault-diagnosis method for rotating machinery based on SVM entropy and machine learning[J]. *Algorithms*, 2023, 16(6): 304.
- [12] 吕志明, 王霖青, 赵珺, 等. 一种基于自适应代理模型的并行贝叶斯优化方法[J]. *控制与决策*, 2019, 34(5): 1025-1031.
(Lyu Z M, Wang L Q, Zhao J, et al. A parallel Bayesian optimization method based on adaptive surrogate model[J]. *Control and Decision*, 2019, 34(5): 1025-1031.)
- [13] Chen K, Xue B, Zhang M J, et al. An evolutionary multitasking-based feature selection method for high-dimensional classification[J]. *IEEE Transactions on Cybernetics*, 2022, 52(7): 7172-7186.
- [14] Xu Q F, Lu S X, Jia W Y, et al. Imbalanced fault diagnosis of rotating machinery via multi-domain feature extraction and cost-sensitive learning[J]. *Journal of Intelligent Manufacturing*, 2020, 31(6): 1467-1481.
- [15] Liu S S, Zhao R, Yu K P, et al. Output-only modal identification based on the variational mode decomposition (VMD) framework[J]. *Journal of Sound and Vibration*, 2022, 522: 116668.
- [16] Qiao M Y, Tang X X, Liu Y X, et al. Fault diagnosis method of rolling bearings based on VMD and MDSVM[J]. *Multimedia Tools and Applications*, 2021, 80(10): 14521-14544.
- [17] Amiri A F, Oudira H, Chouder A, et al. Faults detection and diagnosis of PV systems based on machine learning approach using random forest classifier[J]. *Energy Conversion and Management*, 2024, 301: 118076.
- [18] Li K, Ping X L, Wang H Q, et al. Sequential fuzzy diagnosis method for motor roller bearing in variable operating conditions based on vibration analysis[J]. *Sensors*, 2013, 13(6): 8013-8041.
- [19] Huang H, Baddour N, Liang M. Bearing fault diagnosis under unknown time-varying rotational speed conditions via multiple time-frequency curve extraction[J]. *Journal of Sound and Vibration*, 2018, 414: 43-60.
- [20] Wang B, Lei Y G, Li N P, et al. A hybrid prognostics approach for estimating remaining useful life of rolling element bearings[J]. *IEEE Transactions on Reliability*, 2018, 69(1): 401-412.
- [21] Ali M Z, Shabbir M N S K, Zaman S M K, et al. Single- and multi-fault diagnosis using machine learning for variable frequency drive-fed induction motors[J]. *IEEE Transactions on Industry Applications*, 2020, 56(3): 2324-2337.
- [22] Patel S P, Upadhyay S H. Euclidean distance based feature ranking and subset selection for bearing fault diagnosis[J]. *Expert Systems with Applications*, 2020, 154: 113400.
- [23] Wang Z R, Huang H A, Wang Y R. Fault diagnosis of planetary gearbox using multi-criteria feature selection and heterogeneous ensemble learning classification[J]. *Measurement*, 2021, 173: 108654.
- [24] Sun Y K, Cao Y, Li P, et al. Vibration-based fault diagnosis for railway point machines using VMD and multiscale fluctuation-based dispersion entropy[J]. *Chinese Journal of Electronics*, 2024, 33(3): 803-813.

作者简介

陈科 (1990-), 男, 副研究员, 博士, 主要研究方向为计算智能、特征选择、故障诊断、数据挖掘、机器学习, E-mail: chenkezixf@zzu.edu.cn;

姬梦晓 (1999-), 女, 硕士生, 主要研究方向为故障诊断, E-mail: 1520875678@qq.com;

于坤杰 (1990-), 男, 教授, 博士, 博士生导师, 主要研究方向为演化计算、机器人协同调度、机器学习、复杂系统建模与优化, E-mail: yukunjie@zzu.edu.cn;

廖粤峰 (1988-), 男, 副教授, 博士, 主要研究方向为电力电子系统建模及控制、多智能体集群控制, E-mail: liaoyuefeng@zzu.edu.cn.