DOI：10.19666/j.rlfd.202606069

基于 MVMD-PE 协同降噪的风轮不平衡多模态信号特征提取方法

陈志文[1]，庞　万[2]，高海东[1,3]，杨韶毅[4]，杨政厚[1]，邢作霞[2]
（1.北京华能新锐控制技术有限公司，北京，102209；
2.沈阳工业大学电气工程学院，辽宁　沈阳，110870；
3.西安热工研究院有限公司，陕西　西安，710054；
4.河北邯峰发电有限责任公司，河北　邯郸，056200）

［摘　　要］【目的】针对复杂湍流风况下风电机组风轮不平衡故障特征易被噪声淹没、多通道信号独立分解易引发频率错位、轻度及耦合不平衡样本易混淆的问题。【方法】本文提出一种多元变分模态分解（multivariate variational mode decomposition, MVMD）与排列熵（permutation entropy, PE）协同降噪的特征提取方法。选取叶片挥舞载荷、摆振载荷、机舱前后向加速度及侧向加速度 4 路多模态响应信号，利用 MVMD 的共享中心频率机制实现多通道同源故障频率对齐，结合排列熵筛选有效本征模态函数重构降噪信号，以增强低频故障敏感分量；进一步提取信号的时域、频域及频谱分布特征，通过主成分分析（PCA）降维融合形成 22 维敏感特征集。基于 GH-Bladed 软件建立 3 MW 风电机组精细化模型，构建包含正常、单一不平衡及耦合不平衡的 10 类典型工况数据集进行验证。【结果】结果表明，所提 MVMD-PE-PCA 融合特征在麻雀搜索算法优化的支持向量机（SSA-SVM）模型中诊断准确率达 94.11%，较未降噪原始特征和单通道 VMD 降噪特征分别提升 21.61 和 11.25 个百分点；PCA 特征融合策略较单模态特征、直接拼接特征准确率分别提高 17.59 和 11.17 个百分点。【结论】该方法有效解决了多通道信号频率失配与噪声干扰问题，显著改善了轻度气动不平衡与低等级耦合不平衡样本的混淆现象，为风电机组传动系统健康监测提供了高鲁棒性的特征提取方案。

［关 键 词］风电机组；风轮不平衡；多模态信号；特征提取；多元变分模态分解

［引用本文格式］（本段作者勿动）作者姓名. 中文标题[J]. 热力发电, 2026, 55(1): 起始页码-终止页码. 作者姓名. 英文标题[J]. Thermal Power Generation, 2026, 55(1): 起始页码-终止页码.

Feature extraction method for multimodal signals of rotor imbalance in wind turbines based on MVMD-PE collaborative denoising

Chen Zhiwen[1], Pang Wan[2], Gao Haidong[1,3], Yang Shaoyi[4], Yang Houzheng[1], Xing Zuoxia[2]
(1. Beijing Huaneng Xinrui Control Technology Co., Ltd., Beijing 102209, China;
2. School of Electrical Engineering, Shenyang University of Technology, Shenyang 110870, China;
3. Xi'an Thermal Power Research Institute, Xi'an 710054, China;
4. Hebei Hanfeng Power Generation Co., Ltd., Handan 056200, China)

Abstract: [Objective] To address the issues that wind turbine rotor imbalance fault features are easily submerged by noise under complex turbulent wind conditions, multi-channel independent

收 稿 日 期：2026-06-19　修 回 日 期：2026-07-20　接 受 日 期：2026-07-27　网络首发日期：XXXX-XX-XX
基 金 项 目：中国华能集团有限公司总部科技项目（HNKJ26-H21）
Supported by：China Huaneng Group Science and Technology Project（HNKJ26-H21）
第一作者简介：陈志文（1989），男，硕士，工程师，主要研究方向为新能源发电，chenzhiwen@tpri.com。
通信作者简介：邢作霞（1976），女，博士，教授，主要研究方向为电力系统分析与新能源发电，2575629962@qq.com。

signal decomposition tends to cause frequency misalignment, and samples of mild and coupled imbalances are prone to confusion. [Method] To systematically address these issues, this paper proposes a collaborative feature extraction and noise reduction method that synergistically integrates Multivariate Variational Mode Decomposition (MVMD) and Permutation Entropy (PE). Instead of treating sensor data in isolation, four-channel multi-modal response signals are synchronously acquired, specifically including blade flapwise load, blade edgewise load, fore-aft acceleration, and lateral acceleration of the nacelle. By leveraging the shared center frequency mechanism inherent in MVMD, the proposed approach constrains multiple channels to share the same mode center frequencies during optimization, thereby realizing precise alignment of homologous fault frequencies and preserving intrinsic physical correlations among multi-source signals. Following decomposition, PE is utilized as a nonlinear dynamical measure to quantify the randomness and complexity of each decomposed Intrinsic Mode Function (IMF). An adaptive entropy threshold is applied to intelligently screen valid IMFs for reconstructing high-fidelity denoised signals, effectively amplifying low-frequency fault-sensitive components. Furthermore, comprehensive indicators covering time-domain statistical parameters, frequency-domain characteristics, and spectral distribution features are extracted. Principal Component Analysis (PCA) is subsequently applied to eliminate data collinearity and redundancies, fusing the extracted metrics into a compact 22-dimensional sensitive feature set. To ensure engineering relevance, a refined aeroelastic model of a 3 MW wind turbine is established via GH-Bladed software, and a representative dataset encompassing 10 typical operating conditions—covering normal states, single imbalance types, and various coupled imbalance scenarios—is constructed for rigorous validation. [Results] Quantitative verification demonstrates the superiority of the proposed framework. When the MVMD-PE-PCA fused features are fed into a Support Vector Machine optimized by the Sparrow Search Algorithm (SSA-SVM), the diagnostic model achieves a remarkable average accuracy of 94.11%. Comparative analyses reveal significant performance gains: the accuracy is improved by 21.61 and 11.25 percentage points compared to models utilizing raw, un-denoised features and those relying on conventional single-channel VMD denoised features, respectively. Additionally, the PCA-based feature fusion strategy proves far more effective than using isolated single-modal features or simply concatenating multi-channel features, yielding further accuracy improvements of 17.59 and 11.17 percentage points, respectively. These results confirm that the fused feature set possesses strong discriminative capabilities even for samples with subtle fault signatures. [Conclusion] The proposed method effectively resolves the issues of multi-channel frequency misalignment and noise interference. It significantly mitigates the confusion between samples of mild aerodynamic imbalance and low-level coupled imbalance, providing a highly robust feature extraction scheme for the health monitoring of wind turbine drive systems.

Key words: wind turbine; rotor imbalance; multimodal signal; feature extraction; multivariate variational mode decomposition

风轮不平衡是大型风电机组运行过程中的常见低频弱特征故障，当前复杂湍流风况下其诊断面临三方面问题：一是故障特征集中于 1P 转频及低阶谐波，易被背景噪声淹没，单一模态信号对质量、气动不平衡敏感性差异显著，难以全面表征故障状态；二是多通道信号独立分解易引发频率错位、模态混叠，跨通道特征对应关系不稳定；三是轻度气动不平衡、低等级耦合不平衡样本特征重叠度高，易出现混淆误判。

该类故障会引起风轮转频及低阶谐波附近的周期性载荷与振动响应，长期运行可能导致主轴、轴承及塔架疲劳损伤，降低机组运行稳定性与寿命[1]。随着风电机组单机容量不断增大以及柔性叶片广泛应用，风轮不平衡引发的结构载荷耦合效应更加显著。文献[2]研究表明，不合理叶片质量分布会加剧风轮轴向窜动与陀螺效应，并增大叶根和主轴疲劳载荷；文献[3]指出，在风剪切与偏航入流共同作用下，质量不平衡会进一步降低超大型风电机组叶片颤振稳定性。因此，开展复杂风况下风轮不平衡特征分析与故障识别研究，对保障风电机组安全稳定运行具有重要意义。

目前，针对风轮不平衡动力学响应与特征表征问题，国内外学者已开展相关研究。文献[4]通过仿真与试验结合分析了气动不平衡对风电机组动力学特性的影响，结果表明叶片挥舞载荷与机舱振动加速度对气动不平衡具有较高敏感性；文献[5]通过实验研究发现，叶片桨距失衡会导致风轮功率下降及侧向载荷增加；文献[6]进一步指出，风剪切与塔影效应会增强风轮非定常气动载荷波动，使复杂风况下的低频故障特征更易受到随机扰动影响；文献[7]提出基于模态分析的风轮质量不平衡识别方法，实现了不平衡叶片定位及不平衡程度估计。上述研究表明，风轮不平衡会在叶片载荷、机舱振动及运行状态等多个观测量中产生耦合响应特征。

由于风轮不平衡故障主要表现为低频弱特征，复杂湍流、结构耦合及环境噪声容易导致故障信息被淹没，因此，如何有效增强故障敏感特征成为风轮不平衡研究的重要问题。近年来，基于信号分解与特征增强的方法逐渐应用于风电机组故障特征分析。文献[8]利用变分模态分解与卷积神经网络实现风轮气动不平衡识别，通过模态分解增强了弱故障特征；文献[9]提出基于信号重构与支持向量机的风轮不平衡诊断方法，在不同噪声与湍流条件下表现出较好的鲁棒性；文献[10]采用多尺度加权斜率熵与特征模态分解相结合的方法，实现了非平稳振动信号下的风机叶片故障特征提取与识别。相关研究表明，合理的信号分解与特征构建方法能够有效提高风轮不平衡低频弱特征的可分性与抗噪能力。

实际上，风轮不平衡会同时影响叶片气动载荷、结构振动以及机组运行状态，不同观测量之间具有明显的互补特征。相比单一振动信号，多模态信息能够更加全面地表征复杂工况下的风轮动态响应。文献[11]提出融合时间维度信息的多传感器状态识别方法，提高了风电机组关键部件运行状态识别精度；文献[12]通过融合 SCADA 振动与非振动数据，实现了主传动链故障分层诊断；文献[13]结合振动与声学信号进行风机叶片故障分析，提高了复杂噪声环境下的诊断可靠性；文献[14]利用 SCADA 与振动数据联合建模，实现了风电机组异常状态检测；文献[15]通过融合振动与电流信号学习多视角相关特征，提高了复合故障状态下的特征表达能力。上述研究说明，多模态信息融合能够增强复杂工况下故障特征的稳定性，并提高弱故障特征的表达能力。

然而，现有研究大多采用单通道独立分解或直接特征拼接方式进行多模态分析，容易出现模态混叠、频率错位以及特征冗余等问题，难以稳定表征复杂湍流背景下的低频弱故障特征。文献[16]提出基于多元变分模态分解（MVMD）的多通道协同去噪方法，验证了 MVMD 在复杂噪声环境下保持多通道频率一致性的有效性。但目前 MVMD 在风轮不平衡多模态特征提取中的应用仍相对较少，尤其缺乏针对叶片载荷与机舱振动联合分析的研究。

针对上述问题，本文选取叶片挥舞载荷、摆振载荷、机舱前后向加速度和机舱侧向加速度作为多模态观测信号，提出一种多元变分模态（MVMD）与排列熵（PE）协同降噪的特征提取方法。利用 MVMD 的共享中心频率机制实现多通道同源故障频率对齐，通过 PE 筛选有效本征模态函数重构信号以抑制宽带随机噪声；进一步提取信号的多域特征，经 PCA 降维融合形成高敏感特征集。基于 GH-Bladed 建立 3 MW 风电机组精细化模型，构建包含正常、单一不平衡及耦合不平衡的 10 类典型工况数据集开展验证。结果表明，所提方法有效解决了多通道频率失配与噪声干扰问题，显著改善了轻度气动不平衡与低等级耦合不平衡样本的混淆现象，为风电机组传动系统健康监测提供了高鲁棒性的特征提取方案。

1 多模态信号获取与工况设计

1.1 风电机组仿真模型

基于 GH-Bladed 建立 3 MW 直驱水平轴风电机组整机动力学模型，模型包含风轮气动、传动链动力学以及叶片和塔架柔性振动模块。为模拟复杂风况下的不平衡响应特性，平均风速设为 10.5 m/s，纵向、横向和垂直湍流强度分别为 19.20%、13.67%和 9.98%，

气流倾斜角为 8°。10.5 m/s 为贴近额定风速的典型运行工况，是机组满功率出力的主要风速区间，风轮不平衡故障的低频特征响应最为显著。风电机组主要参数如表 1 所示。

表 1 风电机组主要参数
Tab.1 Main parameters of the wind turbine

序号	参数名称	数值
1	叶片数	3
2	叶片长度/m	55.12
3	风轮直径/m	113.09
4	轮毂高度/m	91.78
5	额定功率/MW	3
6	额定转速/(r·min^{-1})	14.25

1.2 不平衡工况与观测信号

质量不平衡通过在单叶片附加等效偏心质量模拟，气动不平衡通过设定单叶片桨距角错位模拟。质量不平衡主要是由于叶片质量分布差异引发附加离心惯性激励。若将单叶片的不平衡等效为特定半径 R_j 处的不平衡质量块 m_j，当风轮以角速ω匀速旋转时，产生的附加离心力 F_{cj} 计算公式为：

$$F_{cj} = m_j \cdot R_j \cdot \omega^2 \tag{1}$$

该离心力会在机舱侧向形成显著的周期性激振。另一方面，气动不平衡主要由叶片桨距角偏差导致各叶片气动力不一致引起。其导致风轮受到的气动不平衡附加转矩$T_q(t)$呈周期性波动，计算公式为：

$$T_q(t) = -T_{qr} + T_{qM}\sin(\omega_r t + \phi) \tag{2}$$

式中：T_{qr}为气动不平衡分量产生的附加转矩；T_{qM}为转矩周期波动的幅值；ω_r为风轮旋转角频率；ϕ为初始相位。

选取叶片挥舞方向载荷、叶片摆振方向载荷、机舱前后向加速度和机舱侧向加速度作为4路多模态观测信号，以同时表征叶片气动载荷、惯性载荷以及整机结构振动响应特性。表2为风轮不平衡工况设置。

表 2 风轮不平衡工况设置
Tab.2 Settings of rotor imbalance conditions

工况	状态类型	质量偏心/%	桨距角偏差/(°)
1	正常运行	0	0
2、3	质量不平衡	1、5	0
4、5	气动不平衡	0	1、5
6~10	耦合不平衡	1~5	1~5

1.3 湍流环境下的响应特性

为分析不同模态信号对风轮不平衡故障的响应差异，选取典型质量不平衡与气动不平衡工况下的叶片载荷和机舱振动信号进行时频分析，结果如图1所示。可以看出，不同模态信号在风轮转频及其低阶谐波附近均存在明显能量聚集，但不同信号对不平衡类型的敏感性存在差异。

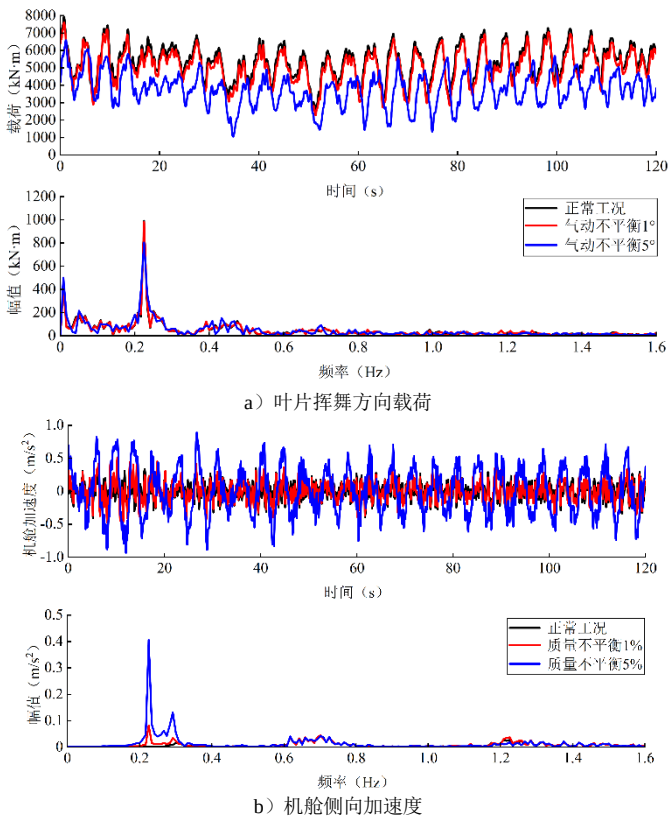


图 1 典型不平衡工况下多模态信号时频响应
Fig.1 Time-frequency responses of multimodal signals under typical imbalance conditions

其中，叶片挥舞方向载荷在气动不平衡工况下表现出更明显的1P频率幅值变化，这是由于桨距角偏差直接改变叶片气动力分布，导致叶片气动推力周期性波动增强；机舱侧向加速度在质量不平衡工况下呈现更强的周期性振动响应，说明偏心质量产生的离心惯性力更容易沿横向结构路径传递至机舱。耦合不平衡工况下，各模态信号均表现出不同程度的频率耦合与能量扩散现象，表明单一模态难以稳定区分复杂不平衡状态。

表3的敏感性分析结果表明，不同模态信号对风轮不平衡类型的响应存在显著差异。叶片挥舞载荷与机舱前后向加速度对气动不平衡表现为高敏感性，但对质量不平衡敏感性较低；机舱侧向加速度对质量不平衡表现为高敏感性，对气动不平衡敏感性较低；叶片摆振载荷虽对两类不平衡均有一定响应，但敏感性程度弱于上述信号。这种敏感性差异导致单一模态信号仅能覆盖特定类型不平衡的特征表征，难以同时区分质量与气动不平衡及其耦合状态。叶片载荷直接反映风轮局部的受力状态，机舱振动则体现故障激励经整机结构传递后的整体响应，二者从源端与末端两个物理层面形成互补，联合多模态信号可实现不同类型不平衡故障特征的全面提取，因此表3结果验证了叶片载荷与机舱振动之间存在明显

互补性。

表 3 多模态信号对风轮不平衡故障的敏感性归纳
Tab. 3Sensitivity summary of multimodal signals to rotor imbalance faults

信号模态	信号通道	质量不平衡敏感性	气动不平衡敏感性
叶片载荷	叶片挥舞载荷	低	高
叶片载荷	叶片摆振载荷	低	较高
机舱振动	机舱前后加速度	较低	高
机舱振动	机舱侧向加速度	高	低

2 MVMD-PE 协同降噪与特征融合

2.1 MVMD 多通道联合分解

为解决多通道信号独立分解导致的频率错位问题，引入MVMD对4路信号进行联合分解。MVMD通过共享中心频率约束实现跨模态故障频率对齐，其优化目标为：

$$\min_{u_{k,c},\omega_k}\left\{\sum_{k=1}^{K}\sum_{c=1}^{C}\left\|\partial_t\left[u_+^{k,c}(t)e^{-j\omega_k t}\right]\right\|_2^2\right\} \tag{3}$$

$$\sum_{k=1}^{K}u_{k,c}(t)=x_c(t),\quad c=1,2,\ldots,C \tag{4}$$

式中：C 为信号通道数；K 为分解模态数；$u_{k,c}(t)$为第 c 通道对应的第 k 个模态分量；ω_k 为共享中心频率。该目标函数通过最小化各模态带宽，实现不同通道中相同物理故障分量的频率一致性。

传统单通道 VMD 对各通道信号独立优化，未考虑多通道信号同源故障的物理关联，易导致同一故障分量（如风轮转频 1P）在不同通道中被分配至不同模态，出现频率错位、模态混叠问题。MVMD 通过引入共享中心频率约束，强制所有通道的同一阶模态收敛至同一中心频率，从机理上保障了跨通道故障特征的一致性，是解决多通道频率失配问题的核心模块。对于风轮不平衡故障，其主要特征集中于 1P 及低阶谐波附近，而复杂湍流会在各通道中引入不同程度的宽带随机扰动。MVMD 能够利用强信噪比通道中的稳定转频信息，引导弱信噪比通道向真实故障频率收敛，从而减少模态混叠和频率漂移问题。

为验证MVMD对多通道故障频率一致性的保持能力，对同一工况下4路信号分别采用单通道VMD和MVMD进行分解，结果如图2所示。单通道VMD由于各通道独立优化，相同故障分量在不同通道中可能被分配至不同模态，导致跨模态特征对应关系不稳定；MVMD则能够在各通道间保持一致的中心频率，对1P、2P和3P相关成分实现较好对齐。结合中心频率分布及转频信息完整性，最终取K=5、α=2 000。对应中心频率分别为0.231、0.462、0.662、1.312、7.367 Hz，其中低频模态覆盖1P及其低阶谐波，高频模态主要吸收宽带随机噪声。

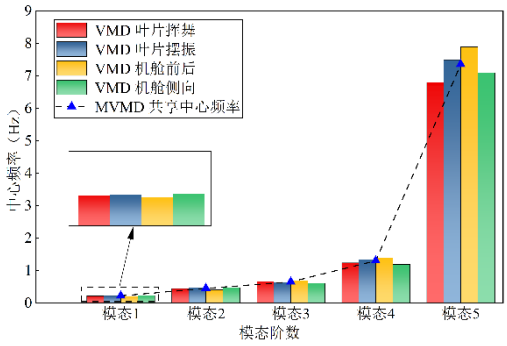


图 2 VMD 与 MVMD 中心频率对齐结果
Fig.2 Centre-frequency alignment of VMD and MVMD

2.2 排列熵模态筛选

经上述 MVMD 联合分解后，多通道故障频率已完成对齐，但各阶模态中既包含转频相关的周期性故障敏感分量，也包含复杂湍流引入的高频宽带随机噪声。为进一步区分有效模态与噪声模态，引入归一化排列熵对模态复杂度进行评价，计算公式为：

$$PE=\frac{-\sum_{j=1}^{m!}P_j\ln(P_j)}{\ln(m!)} \tag{5}$$

式中：P_j 为第 j 种排列模式出现概率；$m!$为排列模式总数。归一化后，排列熵取值范围为[0,1]。

对于风轮不平衡故障信号，其主要表现为转频附近的周期性振动成分，因此对应模态通常具有较低随机性和较小排列熵值；而宽带噪声模态则表现出较高随机性，其排列熵值接近 1。基于这一特性，通过设定阈值筛除高熵噪声模态，仅保留低频故障敏感模态进行信号重构。

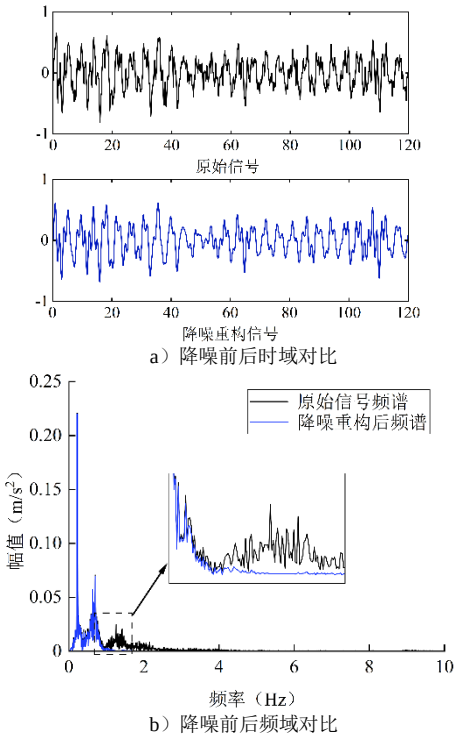
表 4 给出了 MVMD 参数设置及排列熵筛选结果。可以看出，模态 1~3 的排列熵明显低于模态 4 和模态 5，说明其包含更多周期性故障信息。因此，保留模态 1~3 进行重构，并采用θ=0.60 作为筛选阈值。

表 4 MVMD 参数设置与排列熵模态筛选结果
Table 4 MVMD parameters and PE-based mode screening results

指标	模态 1	模态 2	模态 3	模态 4	模态 5
共享中心频率	0.231	0.462	0.662	1.312	7.367
归一化排列熵	0.185	0.242	0.356	0.685	0.892
模态判定	保留	保留	保留	剔除	剔除
参数设置	K=5	α=2000	θ=0.60	M=4	τ=1

验证 MVMD-PE 协同降噪方法对弱故障特征的增强效果，对降噪前后信号进行对比分析，结果如图 3 所示。原始信号中包含大量由复杂湍流和结构随机振动引起的宽带噪声，导致低频故障特征被明显淹

没。经过 MVMD 联合分解及 PE 筛选后，重构信号中的低频周期性成分得到明显增强，1P 相关特征更加清晰，而高频随机波动明显减弱。这表明 MVMD-PE 能够在保留风轮不平衡低频特征的同时，有效抑制复杂风况下的宽带噪声干扰。



a）降噪前后时域对比

b）降噪前后频域对比

图 3 MVMD-PE 降噪重构前后信号对比

Fig.3 Comparison of signals before and after MVMD-PE denoising

2.3 多域特征提取与 PCA 融合

在重构后的 4 路信号上采用滑动窗口划分样本。每个通道提取峰峰值、有效值、标准差、峭度、偏度、1P 幅值、2P 幅值、3P 幅值、频谱重心和功率谱熵等 10 个指标，形成 40 维初始特征。

为全面表征复杂风况下风轮不平衡的动态响应特性，针对滑动窗口截取的长度为 N 的离散信号序列 x_i，提取包含时域、频域和信息论的特征指标。其中，时域有效值（RMS）用于衡量振动信号的平均能量强度，其计算公式为：

$$X_{RMS}=\sqrt{\frac{1}{N}\sum_{i=1}^{N}x_i^2} \tag{6}$$

峭度（Kurtosis）和偏度（Skewness）作为无量纲指标，对局部载荷冲击与波形不对称性极其敏感，其表达式为：

$$K_u=\frac{1}{N}\sum_{i=1}^{N}\frac{(x_i-\bar{x})^4}{X_{STD}^4} \tag{7}$$

$$S_k=\frac{1}{N}\sum_{i=1}^{N}\frac{(x_i-\bar{x})^3}{X_{STD}^3} \tag{8}$$

式中：$\bar{x}$ 为信号算术平均值；X_{STD} 为信号的标准差。

此外，为量化故障引起的 1P 转频能量聚集现象，引入功率谱熵（PSE）来评价信号频谱的有序度如式（9）所示：

$$H_{PSE}=-\sum_k P_k\log_2 P_k \tag{9}$$

式中：P_k 为信号功率谱密度归一化后的概率分布。

由于多模态特征直接拼接后存在较强相关性和冗余信息，容易导致分类器维度灾难和过拟合问题，因此采用 PCA 对高维融合特征进行降维处理。PCA 通过协方差矩阵特征分解，将原始相关变量映射为相互正交的主成分，如式（10）所示：

$$R=\frac{Z^TZ}{N-1} \tag{10}$$

式中：R 为协方差矩阵；N 为样本数；Z 为标准化后的特征矩阵。

进一步计算特征值及累计方差贡献率，计算公式为：

$$\eta_m=\frac{\sum_{i=1}^{K}\lambda_i}{\sum_{i=1}^{d}\lambda_i} \tag{11}$$

式中：η_m 为前 m 个主成分累计方差贡献率；λ_i 为第 i 个特征值；d 为原始特征维数。

由于叶片载荷与机舱振动均包含 1P 相关信息，直接拼接容易造成特征重复。PCA 能够提取不同模态之间的主要公共变化方向，从而形成更紧凑、更稳定的低维故障表征空间。当前 22 个主成分累计方差贡献率超过 95%，因此保留 22 维融合特征作为分类器输入。

3 特征有效性验证与结果分析

3.1 验证模型与评价指标

采用 SSA-SVM 对所提特征进行分类验证。每类工况截取 292 个样本，10 类工况共 2 920 个样本，训练集与测试集比例为 8:2。

由于降噪后的融合特征仍存在一定的非线性，本文采用支持向量机（SVM）构建故障分类模型。SVM 通过引入松弛变量 ξ_i 和惩罚因子 C，构建软间隔分类模型，其优化目标为：

$$\min_{w,b,\xi}\frac{1}{2}\|w\|^2+C\sum_{i=1}^{N}\xi_i \tag{12}$$

式中：$\boldsymbol{w}$ 为超平面法向量；$\boldsymbol{b}$ 为偏置项。约束条件为 $y_i(w^T x_i+b)\geq 1-\xi_i$。

为解决高维非线性映射问题，选用径向基（RBF）核函数，如式（13）所示：

$$K(x_i,x_j)=\exp\left(-\gamma\|x_i-x_j\|^2\right) \tag{13}$$

由于惩罚因子 C 和核函数参数γ对模型性能影响显著，本文利用麻雀搜索算法（SSA）的全局寻优能力对其进行自适应参数寻优，构建最优的 SSA-SVM 诊断模型。

为综合评价不同特征构建方法对风轮不平衡故障的识别能力，采用准确率、精确率、召回率和 F1 分数作为评价指标。其中，准确率用于反映整体分类正确比例；精确率反映模型对故障类别的误报控制能力；召回率用于衡量故障样本识别完整性；F1 分数则综合考虑精确率与召回率之间的平衡关系。对于第 i 类样本，各评价指标的具体定义如下：

$$Accuracy=\frac{N_{correct}}{N_{total}}\times 100\% \tag{14}$$

$$Precision_i=\frac{TP_i}{TP_i+FP_i} \tag{15}$$

$$Recall_i=\frac{TP_i}{TP_i+FN_i} \tag{16}$$

$$F1_i=\frac{2\times Precision_i\times Recall_i}{Precision_i+Recall_i} \tag{17}$$

式中：N_{correct} 为正确分类的样本总数；N_{total} 为测试集样本总数；TP_i 为第 i 类样本被正确诊断的数量；FN_i 为第 i 类样本被误判为其他类别的数量。

3.2 降噪、融合与算法消融对比

为验证 MVMD-PE 协同降噪及 PCA 融合特征的有效性，分别构建未降噪原始特征、单通道 VMD 降噪特征及 MVMD-PE 协同降噪特征进行对比，结果如表 5 所示。

表 5 不同算法组合的消融实验结果对比

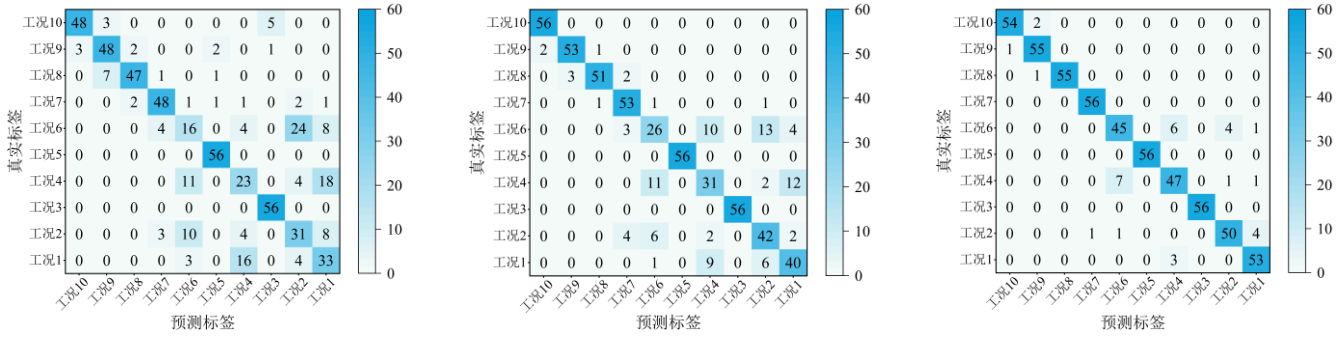
Table 5 Comparison of ablation experiment results for different algorithm combinations

模型编号	模型组合策略	准确率/%
M1	无降噪+PCA 融合+SSA-SVM	72.50
M2	单通道 VMD+PCA 融合+SSA-SVM	82.86
M3	MVMD-PE+单模态特征+SSA-SVM	76.52
M4	MVMD-PE+特征直接拼接+SSA-SVM	82.94
M5	MVMD-PE+PCA 融合+GA-SVM	90.20
M6	MVMD-PE+PCA 融合+PSO-SVM	92.25
M7	MVMD-PE+PCA 融合+SSA-SVM	94.11

由表 5 可知，未降噪特征在复杂湍流背景下易受随机扰动影响，准确率仅为 72.50%；单通道 VMD 能够改善部分故障识别效果，但跨通道频率一致性不足，准确率提高至 82.86%；MVMD-PE 协同降噪后准确率进一步提高至 94.11%，说明多通道联合分解能够有效增强低频故障敏感成分。

此外，PCA 融合特征优于单模态特征和直接拼接特征，说明多模态降维融合能够有效降低冗余相关性并提高故障特征可分性。SSA-SVM 交叉验证准确率最高，表明其具有更优参数寻优能力。

为进一步分析不同降噪方法对故障分类性能的影响，分别构建对应混淆矩阵，结果如图 4 所示。可以看出，未降噪条件下轻度质量不平衡、轻度气动不平衡及低等级耦合不平衡之间存在明显类别混淆；采用单通道 VMD 后，部分类别识别效果有所改善，但仍存在一定程度的模态错位问题。相比之下，MVMD-PE 处理后混淆矩阵主对角线更加集中，大部分工况均能够实现准确分类，说明该方法能有效提高不同不平衡状态之间的区分能力。



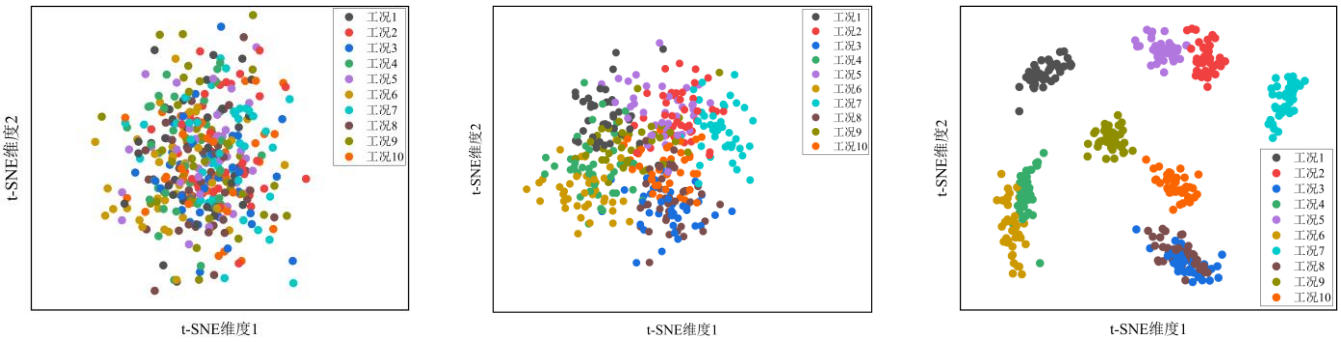
a）未降噪　　b）VMD　　c）MVMD-PE

图 4 不同降噪特征下的混淆矩阵

Fig. 4 Confusion matrices under different denoising features

为直观分析不同特征构建方式下样本空间分布情况，采用 t-SNE 对单模态特征、多模态拼接特征和 PCA 融合特征进行二维可视化，结果如图 5 所示。

可以看出，单模态特征样本分布较为离散，不同工况之间存在明显重叠；多模态直接拼接后类别间距有所增大，但部分类别边界仍不清晰。相比之下，PCA 融合特征形成了更紧凑的类内分布和更明显的类间边界，说明 PCA 能够有效降低多模态特征冗余并提高特征空间可分性。



a）单模态特征　b）多模态拼接特征　c）PCA 融合特征

图 5 不同特征构建方式下的 t-SNE 可视化结果

Fig. 5 t-SNE visualization results under different feature construction methods

4 结　论

针对复杂湍流风况下单模态信号难以有效表征风轮不平衡故障的问题，本文提出一种基于 MVMD-PE 协同降噪与多模态特征融合的风轮不平衡信号特征提取方法，并结合 SSA-SVM 模型进行了故障诊断验证。通过对基于 GH-Bladed 建立的 3 MW 风电机组仿真数据进行算例分析，得到如下主要结论：

1）建立了融合叶片载荷与机舱振动的多模态观测体系。研究表明，叶片挥舞方向载荷与机舱前后向加速度对气动不平衡具有高敏感性，而机舱侧向加速度对质量不平衡响应更显著。多模态信号的联合有效弥补了单一传感器的表征局限性。

2）所提 MVMD-PE 协同降噪方法能够有效克服多通道频率错位问题。提取的低频模态（0.231、0.462 和 0.662 Hz）完整保留了风轮不平衡的转频特征。相较于未降噪处理，该方法使最终诊断准确率提升了 21.61 个百分点，显著增强了复杂湍流背景下的低频弱故障特征提取能力。

3）提出的基于 PCA 的特征级融合有效消除了高维多模态特征的冗余性。将其输入至优化的 SSA-SVM 分类模型中进行诊断验证，结果表明：相比于单模态特征和直接拼接特征，PCA 融合特征的诊断准确率分别提高了 17.59 和 11.17 个百分点。验证模型最终诊断准确率达到 94.11%，成功改善了轻度气动不平衡与低等级耦合不平衡样本的混淆问题，充分证明了本文所提特征提取方法在风电机组故障识别中的可靠性与工程应用价值。

[参 考 文 献]

[1] 曹沂风.基于支持向量机的风轮不平衡故障诊断方法研究 [J]. 太阳能学报,2024,45(08):613-620. DOI:10.19912/j.0254-0096.tynxb.2023-2026.

CAO Y F. A Study on a Support Vector Machine-Based Method for Diagnosing Wind Turbine Unbalance Faults [J]. Journal of Solar Energy, 2024, 45(08): 613–620. DOI: 10.19912/j.0254-0096.tynxb.2023-2026

[2] 李治国,郝波,刘乐,等.分段式叶片质量分布对风轮轴向窜动和陀螺效应的影响 [J]. 振动与冲击 ,2022,41(07):193-198+249. DOI:10.13465/j.cnki.jvs.2022.07.025.

LI Z G, HAO B, LIU L, et al. The Effect of Segmented Blade Mass Distribution on Axial Runout and Gyroscopic Effects in Wind Turbines [J]. Vibration and Shock, 2022, 41(07): 193–198+249. DOI: 10.13465/j.cnki.jvs.2022.07.025.

[3] 田德,李贝,吴晓璇,等.风轮不平衡载荷下超大型风电机组叶片颤振极限研究 [J]. 太阳能学报 ,2024,45(02):198-205. DOI:10.19912/j.0254-0096.tynxb.2023-1751.

TIAN D, LI B, WU X X, et al. Study on the Flutter Limit of Blades in Ultra-Large Wind Turbines Under Unbalanced Loads [J]. Journal of Solar Energy, 2024, 45(02): 198–205. DOI:10.19912/j. 0254-0096.tynxb.2023-1751.

[4] 巫发明,杨从新,王清,等.大型风力机风轮气动不平衡的特性研究与验证[J].太阳能学报,2021,42(01):192-197. DOI:10.19912/j. 0254-0096.tynxb.2018-0763.

Wu, F., Yang, C., Wang, Q., et al. Study and validation of aerodynamic imbalance characteristics in large wind turbine rotors [J]. Journal of Solar Energy, 2021, 42(01): 192–197. DOI: 10.19912/j.0254-0096.tynxb.2018-0763.

[5]MAZZEO F，MICHELETTO D，TALAMELLI A，et al. An experimental study on a wind turbine rotor affected by pitch imbalance［J］. Energies，2022，15.

[6] 杨从新,张志梅,王强,等. 风剪切下塔影效应对水平轴风力机叶片及风轮气动载荷的影响[J]. 太阳能学报 ,2022,43(08):253-259. DOI:10.19912/j.0254-0096.tynxb.2020-1276.

YANG C X, ZHANG Z M WANG Q, et al. The Effect of Tower Shadowing on Aerodynamic Loads on Blades and Rotors of Horizontal-Axis Wind Turbines Under Wind Shear [J]. Journal of Solar Energy, 2022, 43(08): 253–259. DOI: 10.19912/j.0254-0096.tynxb.2020-1276.

[7] CHEN Y，GRIFFITH D. Blade mass imbalance

identification and estimation for three-bladed wind turbine rotor based on modal analysis［J］. Mechanical Systems and Signal Processing，2023.

［8］ 杨旺春,梁雪,孙传宗.基于卷积神经网络的风电机组气动不平衡故障诊断方法研究[J].太阳能学报,2025,46(03):531-537. DOI:10.19912/j.0254-0096.tynxb.2023-1764.

YANG W C, LIANG X, SUN C Z. A Study on a Method for Diagnosing Aerodynamic Imbalance Faults in Wind Turbines Based on Convolutional Neural Networks [J]. Journal of Solar Energy, 2025, 46(03): 531–537. DOI: 10.19912/j.0254-0096.tynxb.2023-1764.

［9］CHEN M，GUO S，XING Z，et al．Diagnosis of a rotor imbalance in a wind turbine based on support vector machine［J］. AIP Advances，2024，14（4）.

［10］郁启华,张龙,唐细致,等.基于多尺度加权斜率熵和海星优化驱动 FMD-SVM 的风机叶片故障诊断方法[J/OL].机电工程,1-10[2026-05-25].

https://link.cnki.net/urlid/33.1088.TH.20251104.0937.006.

YU Q H, Zhang Long, Tang Xizhi, et al. A Wind Turbine Blade Fault Diagnosis Method Based on Multi-scale Weighted Gradient Entropy and Sea Star Optimisation-Driven FMD-SVM [J/OL]. Mechanical and Electrical Engineering, 1–10 [25 May 2026]. https://link.cnki.net/urlid/33.1088.TH.20251104.0937.006.

［11］ 苏连成,郭高鑫.基于信息融合的风电机组关键部件状态识别[J].信息与控制,2021,50(03):337-342+349.DOI:10.13976/j.cnki.xk.2021.0275.

Su Liancheng, Guo Gaoxin. Condition Monitoring of Key Components in Wind Turbines Based on Information Fusion [J]. Information and Control, 2021, 50(03): 337–342+349. DOI: 10.13976/j.cnki.xk.2021.0275.

[12] 程凯,王鹏宇,王晓东,等.基于数据融合的风电机组主传动链典型故障分层诊断方法[J].噪声与振动控制,2023,43(03):125-131+174.

CHENG K, WANG P Y, WANG X D, et al. A Hierarchical Diagnostic Method for Typical Faults in the Main Drive Train of Wind Turbines Based on Data Fusion [J]. Noise and Vibration Control, 2023, 43(03): 125–131+174.

［13］SETHI M R，HEMASUDHEER B，SAHOO S．Wind turbine blade fault detection through combined analysis of vibration and acoustic data［J］. Arabian Journal for Science and Engineering，2025：1-23.

［14］TURNBULL A，CARROLL J，MCDONALD A．Combining SCADA and vibration data into a single anomaly detection model to predict wind turbine component failure［J］. Wind Energy，2021，24（3）：197-211.

［15］JIANG G，JIA C，NIE S，et al．Multiview enhanced fault diagnosis for wind turbine gearbox bearings with fusion of vibration and current signals［J］. Measurement，2022，196：111159.

［16］王晓卫，王雪，王毅钊，等．基于图像信息熵与多元变分模态分解的电缆局放信号去噪方法［J］．电工技术学报，2024，39（13）：4100-4115，4152.

WANG X W，WANG X，WANG Y Z，et al．Cable partial discharge signal denoising method based on image information entropy and multivariate variational mode decomposition［J］. Transactions of China Electrotechnical Society，2024，39（13）：4100-4115，4152.

（责任编辑　XXX）