

王洪江,张楠,任娜,等.基于深度强化学习变分模态分解的风机叶片故障诊断方法[J].辽宁工程技术大学学报(自然科学版),2026,45(3):339-348.DOI:10.11956/j.issn.1008-0562.20250567

WANG Hongjiang,ZHANG Nan,REN Na,et al.Blade fault diagnosis of wind turbines based on deep reinforcement learning adaptive variational mode decomposition[J].Journal of Liaoning Technical University (Natural Science),2026,45(3):339-348.DOI:10.11956/j.issn.1008-0562.20250567

基于深度强化学习变分模态分解的风机叶片故障诊断方法

王洪江^{1,2}, 张楠², 任娜³, 张天⁴, 刘金圣⁵, 刘振宇^{1*}

(1. 沈阳工业大学 信息科学与工程学院, 辽宁 沈阳 110870; 2. 沈阳工程学院 计算机科学与技术学院, 辽宁 沈阳 110136;
3. 沈阳工业大学 人工智能学院, 辽宁 沈阳 110870; 4. 东北大学 软件学院, 辽宁 沈阳 110169;
5. 沈阳工程学院 电气工程学院, 辽宁 沈阳 110136)

摘要:为解决风机叶片在复杂工况下易产生裂纹、磨损等问题,针对传统振动信号分析方法的局限性,提出一种基于深度强化学习自适应变分模态分解的风机叶片故障诊断方法。该方法引入深度强化学习构建变分模态分解参数自适应优化框架,通过离散-连续混合动作空间与以平均包络熵和包络熵方差为约束的双目标奖励函数,实现模态数与惩罚因子的动态优化;基于包络熵筛选敏感模态,融合时域、频域及熵特征,结合支持向量机完成叶片故障分类。研究表明:该方法可将变分模态分解的平均包络熵降至2.21,方差控制在0.21~0.24,对叶片的识别准确率达96.4%。研究结论为提升风机叶片故障诊断的准确性和可靠性提供参考。

关键词: 风机叶片; 故障诊断; 深度强化学习; 变分模态分解; 近端策略优化算法; 包络熵

中图分类号:TK83

文献标志码:A

文章编号:1008-0562(2026)03-0339-10

Blade fault diagnosis of wind turbines based on deep reinforcement learning adaptive variational mode decomposition

WANG Hongjiang^{1,2}, ZHANG Nan², REN Na³, ZHANG Tian⁴, LIU Jinsheng⁵, LIU Zhenyu^{1*}

(1. School of Information Science and Engineering, Shenyang University of Technology, Shenyang 110870, China; 2. School of Computer Science and Technology, Shenyang Institute of Engineering, Shenyang 110136, China; 3. School of Artificial Intelligence, Shenyang University of Technology, Shenyang 110870, China; 4. College of Software, Northeastern University, Shenyang 110169, China; 5. School of Electrical Engineering, Shenyang Institute of Engineering, Shenyang 110136, China)

Abstract: To address the problem that wind turbine blades are prone to defects such as cracks and wear under complex operation conditions, and to overcome the limitations of traditional vibration signal analysis methods, this paper proposes a fault diagnosis method for wind turbine blades based on adaptive variational mode decomposition optimized by deep reinforcement learning. In this method, deep reinforcement learning is introduced to construct an adaptive optimization framework for variational mode decomposition parameters. The dynamic optimization of the mode number and penalty factor is realized through a discrete-continuous hybrid action space and a dual-objective reward function constrained by the average envelope entropy and the variance of envelope entropy. On this basis, sensitive modes are screened according to envelope entropy, the time-domain, frequency-domain and entropy features are fused, and the blade fault classification is completed using a support vector machine. The research results show that the proposed method can reduce the average envelope entropy of variational mode decomposition to 2.21, control its variance within the range of 0.21-0.24, and achieve a recognition accuracy of blade faults as high as 96.4%. The research conclusions provide a reference for

收稿日期: 2025-12-25 修回日期: 2026-02-08 接受日期: 2026-02-18 责任编辑: 黄琦

基金项目: 辽宁省科技厅重点研发项目(2024JH2/102500074)

作者简介: 王洪江(1977-),男,辽宁葫芦岛人,硕士,教授,主要从事电力视觉、算法优化方面的研究。E-mail: wanghj@sie.edu.cn

通信作者: 刘振宇(1973-),男,辽宁大连人,博士,教授,主要从事机器人导航及视觉伺服方面的研究。E-mail: liuzhenyu@sut.edu.cn

improving the accuracy and reliability of fault diagnosis for wind turbine blades.

Keywords: wind turbine blades; fault diagnosis; deep reinforcement learning; variational mode decomposition; proximal policy optimization algorithm; envelope entropy

0 引言

风机叶片是风电机组捕获风能的关键部件,其运行状态直接影响机组的发电效率与运行安全,是风电场运维管理过程中的重点监测对象^[1-3]。随着全球风电装机容量的持续增长,风电机组因传动链结构简化、运行可靠性高等优势得到广泛应用。然而,叶片长期暴露于强风、温差变化、雷击及腐蚀等复杂自然环境中,易发生裂纹、磨损、破损等故障,一旦未能及时识别,可能引发功率波动甚至设备失效^[4-5]。因此,研究面向风电机组叶片的高精度、高可靠性故障诊断方法,对降低运维成本、提升机组运行安全性具有重要的工程意义。

振动信号分析是风机叶片故障诊断中应用最为广泛的技术手段,其核心思想是通过振动信号开展特征提取与模式识别,实现对运行状态的判别。然而,该技术面临以下挑战:一是叶片振动信号具有明显的非线性和非平稳特性,且早期故障特征幅值较弱,易被环境噪声掩盖;二是风速波动和运行工况变化显著,导致诊断模型的泛化能力受到限制。上述因素共同制约了传统方法在复杂工况下的诊断精度。目前基于振动信号分析的风机叶片故障诊断方法主要分为三类,其中传统信号处理方法^[6]是叶片故障诊断的技术基础,其核心是通过振动信号的时域、频域及时频域特征解析提取故障信息。时域分析以峰值、峭度、脉冲指数等统计量为核心,直接反映信号幅值变化,但无法刻画频率特征;频域分析通过功率谱密度、谐波分析等手段揭示信号频率分布,却难以捕捉非平稳工况下的动态特征;时频分析则结合两者优势,典型方法包括小波变换^[7]、经验模态分解(empirical mode decomposition, EMD)^[8]、变分模态分解(variational mode decomposition, VMD)^[9]。小波变换需预设基函数,动态适配性有限。EMD依赖信号极值点筛选模态,易发生模态混叠。VMD虽提升了分解精度,但其核心参数依赖人工经验设定,难以适配多变的故障与工况。

智能优化辅助的信号处理方法^[10]可优化VMD等算法的参数,但易陷入局部最优,且对动态工况的适应性不佳。近年来,深度学习驱动的诊断方法在特征提取方面成为研究热点,但这类方法较依赖海量标注数据,且多聚焦于后端分类,在

小样本、弱特征场景下适应性不足。深度强化学习(deep reinforcement learning, DRL)^[11]融合深度学习的特征提取能力与强化学习的序列决策优化能力,通过智能体与环境的持续交互自主学习最优策略,无需依赖大量标注数据,且DRL以故障特征分离度最大化为目标设计奖励函数,可提升弱特征提取精度,其序列决策能力可适配风速波动下的动态工况。

针对现有方法的不足,作者提出一种基于深度强化学习优化变分模态分解(DRL-VMD)的风机叶片故障诊断方法。该方法融合DRL的自适应优化能力与VMD的高效分解能力,可提升故障特征的提取精度。主要创新点如下:提出基于DRL的VMD参数自适应优化方法,通过设计混合动作空间与双目标奖励函数,实现VMD参数对不同故障类型及工况的动态适配,解决传统参数依赖经验的局限,提升故障特征分离精度;构建基于深度强化学习优化特征模态分解的风电机组故障诊断方法,基于包络熵筛选敏感模态,融合多维度特征并结合支持向量机(support vector machine, SVM)实现非线性分类,形成全流程优化的故障识别方案。

1 基于DRL的VMD参数自适应优化

1.1 整体框架

基于DRL的VMD参数自适应优化方法框架见图1,以DRL智能体为决策核心,自主学习最优参数调整策略。信号输入模块采集风机叶片振动原始信号,经预处理后构建DRL智能体可感知的初始状态,智能体基于预设的初始参数,输出VMD的首次参数配置模态数 K 和惩罚因子 ∂ 。VMD分解模块依据该参数对振动信号进行模态分解,输出对应的IMF分量。反馈评估模块随即计算各IMF分量的包络熵以量化分解效果,再结合参数合理性判断生成奖励信号。通过整合当前参数、信号信息及熵指标,构建新一轮迭代的状态向量。DRL接收该状态向量与奖励信号后,输出下一轮参数调整动作 $(\Delta K, \Delta \partial)$,实现VMD参数的动态优化。VMD分解模块采用更新后的参数重新分解信号,开启新一轮循环。此迭代过程持续进行,直至连续多轮奖励值波动小于预设阈值,参数优化收敛,输出适配当前工况的VMD最优参数。




图1 基于DRL的VMD参数自适应优化框架

Fig.1 adaptive optimization framework for VMD parameters based on DRL

1.2 变分模态分解

变分模态分解是一种自适应、非递归信号处理算法^[12],其核心逻辑是通过构建并求解变分模型,将原始信号 f 分解为 K 个具有特定稀疏特性的本征模态函数(IMF),每个IMF均为具有特定中心频率的窄带分量^[13-14]。相比于经验模态分解,VMD在处理非线性及非平稳信号时具有更高的分解精度与抑制模态混叠能力^[15],在风机叶片振动信号分析领域表现优异^[16]。

VMD的本质是受限变分问题的最优解寻找过程,其目标是在保证各分量之和等于原始信号的约束下,使 K 个IMF的估计带宽之和最小^[17-18]。该过程涉及变分模型的构建与无约束化求解^[19-20],数学表达式为

$$\begin{cases} \min_{\{\mu_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * \mu_k(t) \right] e^{-j\omega_k t} \right\|^2 \right\}, \\ \text{s.t. } \sum_k \mu_k(t) = f(t) \end{cases} \quad (1)$$

式中: $\mu_k(t)$ 为信号分解的多个本征模态函数; ω_k 为每个本征模态函数的中心频率; t 为时间; $\delta(t)$ 为狄拉克分布函数; $f(t)$ 为输入的原始实值信号; j 为虚数单位; $*$ 为卷积运算符。

尽管VMD具有较强的时频分析能力,但其分解效果高度依赖模态数 K 及惩罚因子 ∂ 的选取。模态数 K 与惩罚因子 ∂ 的物理意义及对分解效果的影响见表1。在风速波动或故障类型演变的动态工况下,人工预设参数难以实现全局最优适配,易导致过分解或欠分解现象,从而制约弱故障特征提取的灵敏度^[21-22]。

表1 模态数 K 与惩罚因子 ∂ 的物理意义及对分解效果的影响Tab.1 physical meanings of modal number K and penalty factor ∂ , and their impact on the decomposition effect

参数	物理意义	对分解效果的影响	叶片故障诊断场景下的取值难点
K	分解得到的IMF分量个数	K 过小,则信号分解不充分,故障特征被掩盖; K 过大,则产生冗余分量,引入虚假特征	叶片振动信号频率成分随风速、故障类型动态变化,难以确定适配全工况的 K
	控制IMF分量带宽与平滑度	∂ 过小,则IMF带宽较宽,易发生模态混叠; ∂ 过大,则分量过度平滑,丢失故障细节特征	不同故障对应的振动特征带宽不同,单一 ∂ 无法兼顾各类故障

1.3 状态空间设计

针对风机叶片振动信号的VMD参数优化任务,构建以参数维度(K, ∂)、分解效果维度($E_1, E_2, \dots, E_{k_{\max}}$)、信号特征维度($R_{\text{peak}}, R_{\text{rms}}$)为核心的状态向量,以全面表征各模态分量的综合性能。

状态向量 S 定义为

$$S = (K, \partial, E_1, E_2, \dots, E_{k_{\max}}, R_{\text{peak}}, R_{\text{rms}}), \quad (2)$$

式中: $E_1, E_2, \dots, E_{k_{\max}}$ 为VMD分解后IMF分量的包络熵; R_{peak} 为原始振动信号的峰值因子; R_{rms} 为均方根因子。

包络熵作为风电故障诊断时量化信号混乱程度的关键指标,可有效区分含故障特征的有效分量与噪声分量,故障状态下对应IMF分量的包络熵显著增大。 R_{peak} 与 R_{rms} 作为风电振动信号的基础时域特征,可辅助反映信号整体冲击特性与能量分布,提供更全面的信号状态信息,计算式分别为

$$R_{\text{peak}} = \frac{A_{\text{max}}}{\sqrt{\frac{1}{N} \sum_{n=1}^N x^2(n)}}, \quad (3)$$

$$R_{\text{rms}} = \sqrt{\frac{\sum_{n=1}^N x^2(n)}{N}}, \quad (4)$$

式(3)、式(4)中: A_{max} 为信号最大值; $x(n)$ 为信号的采样序列; N 为信号的长度或样本数。

1.4 动作空间设计

动作空间以VMD参数调整量为核心,定义为混合类型动作向量 $\mathbf{A}=(\Delta K, \Delta\delta)$,其中, ΔK 对应模态数 K 的调整量; $\Delta\delta$ 对应惩罚因子 δ 的调整量。

模态数调整量 ΔK :由于模态数 K 为整数型参数,故 ΔK 设计为离散变量,取值为-1、0和1。其中, ΔK 取-1表示减少1个模态数; ΔK 取0表示保持模态数不变; ΔK 取1表示增加1个模态数。该设计可平衡参数调整的效率与稳定性,避免因模态数大幅波动分解效果发生突变。

惩罚因子调整量 $\Delta\delta$:由于惩罚因子 δ 为连续型参数, $\Delta\delta$ 设计为连续变量,从而实现精细微调,适配不同风电振动信号对惩罚因子的敏感需求,避免因调整步长过大使参数优化发生振荡。

1.5 奖励函数设计

以VMD分解后各IMF分量的包络熵为核心评估指标,构建基于平均包络熵与包络熵方差的双目标奖励函数。与仅优化平均包络熵的单目标相比,双目标设计能有效克服分解结果失衡的问题,避免出现部分IMF分量被过度优化导致的其他分量模态混叠加剧现象。

在单目标驱动下,寻优过程易出现非均衡收敛特性:优化过程倾向于通过调整VMD参数,一方面将大部分IMF分量的带宽过度压缩,呈现较低的包络熵;另一方面本应分布于多模态间的故障特征与背景噪声被过度集合至少数IMF分量中,造成频率成分混杂、边界模糊,呈现模态混叠的情况。该策略虽然可获得局部极值,但分量间均衡性较差,极易掩盖微弱的早期故障特征,降低特征提取的可靠性。

包络熵常用于度量信号的混乱程度。对于VMD来说,包络熵 E_i 越小,说明IMF分量中故障特征越突出,噪声干扰越弱,分解效果越好。包络熵的计算式为

$$E_i = - \sum_{j=1}^N P_j \log P_j, \quad (5)$$

式中, P_j 为经希尔伯特解调后得到的第 j 点包络幅值归一化序列。

奖励函数通过平均包络熵最小化与包络熵方差最小化双目标构建,即

$$R = \omega_1 R_1 + \omega_2 R_2, \quad (6)$$

式中: R_1 为平均包络熵; R_2 为包络熵方差; ω_1 、 ω_2 为加权系数。

R_1 直接反映IMF分量的整体噪声水平,其值越小,说明分解效果越好,计算式为

$$R_1 = \frac{c}{\frac{1}{k_{\text{max}}} \sum_{i=1}^{k_{\text{max}}} E_i}, \quad (7)$$

式中: $\frac{1}{k_{\text{max}}} \sum_{i=1}^{k_{\text{max}}} E_i$ 为 k_{max} 个IMF分量的平均包络熵; c 为缩放系数,用于确保该项奖励值处于合理区间。

R_2 反映各IMF分量分解质量的均匀性,其值越小,说明模态分离越均衡,越能避免部分分量噪声过多、特征丢失的情况,计算式为

$$R_2 = d \cdot \exp \left[- \frac{1}{k_{\text{max}}} \sum_{i=1}^{k_{\text{max}}} (E_i - \bar{E})^2 \right], \quad (8)$$

式中: $\frac{1}{k_{\text{max}}} \sum_{i=1}^{k_{\text{max}}} (E_i - \bar{E})^2$ 为 k_{max} 个IMF分量的包络熵的方差; d 为缩放系数; $\exp(\cdot)$ 确保方差越小,该项奖励值越大。

1.6 网络结构设计

针对VMD参数优化的混合动作空间与高维状态输入特性,选用近端策略优化(proximal policy optimization, PPO)算法构建DRL网络。PPO通过剪辑目标函数控制策略更新步长,避免训练振荡,对混合动作空间具有良好的适配性。其经典的Actor-Critic双网络结构可实现动作决策与状态价值评估。

Actor网络(策略网络):根据当前状态 $\mathbf{S}_t$ 输出动作,其输入层维度与状态向量 $\mathbf{S}$ 的维度一致,包含2个输出头:离散动作头,对应模态数调整量 ΔK ,该部分输出1个三维向量,通过Softmax函数转换为选择每个离散动作的概率;连续动作头,对应惩罚因子调整量 $\Delta\delta$,该部分输出1个标量。

Critic网络(价值网络):评估当前状态 S_t 的价值(即预期累积奖励),为Actor网络的策略更新提供基准。其输入与Actor网络相同,输出为1个标量,表示状态价值 $V(S_t)$ 。

Actor网络和Critic网络共享隐藏层,用于从高维状态中提取特征。隐藏层采用ReLU激活函数,采用Adam优化器。

2 基于深度强化学习优化特征模态分解的直驱风电机组故障诊断方法

2.1 整体流程

基于深度强化学习优化特征模态分解的直驱风电机组故障诊断具体步骤如下。

步骤1 对采集的叶片原始振动信号进行预处理,通过小波阈值去噪处理,剔除风场环境噪声、电磁干扰等冗余成分,得到聚焦叶片振动特性的有效信号。

步骤2 将预处理后的信号输入基于深度强化学习的VMD参数自适应优化模型,智能体基于信号特性动态调整VMD的模态数 K 与惩罚因子 α ,分别输出适配当前叶片信号的最优参数。

步骤3 利用最优参数对提纯信号进行VMD分解,得到多个IMF分量,通过包络熵排序筛选敏感模态,计算各IMF分量的包络熵并按熵值升序排列,选取靠前分量作为敏感模态。

步骤4 针对筛选出的敏感模态,从时域、频域、熵3个维度提取核心敏感特征,融合形成能够全面刻画叶片故障状态的特征向量。

步骤5 对特征向量进行标准化处理后,输入基于径向基核函数(radial basis function, RBF)构建的SVM分类器,通过网格搜索优化分类器参数并完成训练,建立特征与叶片故障的非线性映射关系,实现对叶片运行状态的精准识别,输出诊断结果。

2.2 叶片故障敏感特征

叶片故障会导致振动信号的幅值、频率分布及规律性发生显著变化。基于敏感模态,从时域(峰值因子、均方根因子)、频域(频率谱峰值)、熵(包络熵)维度提取核心敏感特征,确保特征对故障状态的高区分度。

时域特征直接反映叶片振动的幅值与能量变化,对冲击类、脉冲类故障敏感,计算简便且物

理意义明确。进一步提取峰值因子、均方根因子,以捕捉叶片的典型故障模式。

峰值因子用于量化信号中的瞬时冲击强度。叶片出现裂纹时,会产生瞬时冲击振动,导致信号峰值显著增大,峰值因子也随之升高,其计算式为

$$C_p = \frac{\max(|u_i(t)|)}{\sqrt{\frac{1}{N} \sum_{j=1}^N u_j^2(t)}} \quad (9)$$

式中: $u_j(t)$ 为经DRL优化筛选出的故障敏感模态序列; $\max(|u_i(t)|)$ 为敏感模态的最大瞬时振动幅值。

均方根因子 x_{rms} 反映信号的平均能量水平。叶片边缘磨损会导致结构阻尼发生变化,改变振动能量分布,均方根呈规律性波动。

频域特征反映信号的频率分布规律,对叶片故障导致的特征频率偏移敏感。对敏感模态信号进行快速傅里叶变换得到功率谱,提取功率谱峰值作为频域代表特征。该特征对应叶片振动系统的固有频率或故障特征频率,能有效识别因结构损伤导致的共振频率迁移或出现边频带现象。

熵特征可量化信号的不确定性与复杂性,有效区分正常与故障状态,对早期微弱故障敏感。对敏感模态信号提取包络序列,进而计算包络熵。叶片发生早期故障时,振动信号的调制现象加剧,包络序列的随机性增加,包络熵相应上升,从而实现复杂背景噪声下对微弱故障信息的辨识。

对每个敏感模态提取上述特征后,计算所有敏感模态的特征均值,形成四维特征向量。通过时域、频域、熵特征的互补,实现对叶片各类故障的精准刻画,为后续SVM分类提供全面、可靠的特征支撑。

2.3 基于SVM的叶片故障分类

SVM凭借在小样本、非线性分类任务中的优异泛化能力,以及结构简单、训练效率高的特点,适配风机叶片故障诊断场景。风机叶片的4种状态见图2。



(a) 正常状态 (b) 叶片裂纹 (c) 叶片磨损 (d) 叶片破损

图2 风机叶片的4种状态

Fig.2 four states of wind turbine blade

叶片故障特征向量中各维度指标的量纲与数值范围存在差异,直接输入SVM会导致模型对数值范围大的特征过度敏感,影响分类精度。故采用Z-score标准化方法对特征向量进行归一化处理,使所有特征取值范围均集中在 $[-1,1]$,确保各维度特征对分类结果的贡献权重均衡,即

$$x'_k = \frac{x_k - \mu_k}{\sigma_k}, \quad (10)$$

式中: x_k 为原始叶片故障特征向量的第 k 维特征值; μ_k 为训练集中第 k 维特征的均值; σ_k 为训练集中第 k 维特征的标准差。

SVM的核函数决定特征空间的映射方式,需适配叶片故障特征的非线性分布特性。其中,RBF核函数具有适应性强、参数少、计算复杂度低的优势,可灵活处理各类非线性分类问题,其表达式为

$$K(x, x') = \exp\left(-\frac{\|x - x'\|^2}{2\sigma^2}\right), \quad (11)$$

式中: $\|x - x'\|^2$ 为2个特征向量欧几里得距离的平方,用于度量不同叶片健康状态在特征空间中的相似度; σ 为径向基核函数的宽度参数,用于控制特征样本的局部影响范围。

3 实验分析

3.1 数据信息

实验数据来源于西北地区某风电场,选取3台1.5 MW 风电机组(编号分别为WT1、WT2、

WT3)作为数据采集对象,采集场景覆盖风电场典型运行工况,数据包含风机正常运行与异常状态的全工况声纹信息。采样频率为48 kHz,采样时长为每组10 s,每组数据包含10万个采样点。数据集共200组样本,按7:3随机划分为训练集与测试集。将10 s长信号切分为每组48段,最终得到训练集样本与测试集样本。具体样本分布如下。

正常状态(N):3台风机平稳运行时采集,共50组样本;叶片裂纹故障(C):WT1风机叶片前缘预制0.5 mm裂纹,共50组样本;叶片磨损故障(W):WT2风机叶片边缘磨损量为5 mm,共50组样本;叶片破损故障(L):WT3风机叶片根部破损,共50组样本。

3.2 对比方法

参数配置见表2。迭代训练100轮,模态数 K 的取值范围为 $[2,10]$,其下限确保分解能捕获至少包含基频与主要故障特征的模态,上限则用于避免产生过多的冗余模态。初始值设为该区间的中值6。

离散调整动作 $\Delta a \in \{-1, 0, 1\}$,在参数触及边界时自动失效。惩罚因子 ∂ 的调整区间为 $[100, 1\ 000]$,初始值设为550,其连续调整量 $\Delta \partial$ 定义为当前值的 $\pm 10\%$,即 $\Delta \partial \in [-0.1\partial, +0.1\partial]$,以确保对信号带宽进行精细、稳定的调节。为解决状态向量中各维度量纲差异大的问题,对特征向量进行Z-score标准化。

表2 参数配置
Tab.2 parameter configuration

类型	参数取值说明
强化学习超参数	采用PPO算法,学习率为 10^{-4} ,折扣因子为0.95,GAE参数为0.9,策略裁剪系数为0.2,批量大小为64,迭代训练100轮; c 为10, d 为5,权重 ω_1 为0.7, ω_2 为0.3
VMD优化参数	模态数 $K \in [2, 10]$,惩罚因子 $\partial \in [100, 1\ 000]$
SVM分类器参数	C 为10,核参数 $1/(2\sigma^2)$ 为0.5,迭代次数为50
小波去噪参数	采用DB4小波基进行3层分解,采用Sqtwolog 阈值规则

为验证DRL-VMD诊断方法的综合性能,设计多维度对比实验。除与固定参数VMD+SVM、DRL-VMD+BP神经网络进行对比分析外,同时选取当前主流智能优化VMD方法开展验证,包括粒子群优化VMD(particle swarm optimization variational mode decomposition, PSO-VMD)算法^[21]、鲸鱼优化算法VMD(whale optimization algorithm variational mode decomposition, WOA-

VMD)以及灰狼优化算法VMD(grey wolf optimizer variational mode decomposition, GWO-VMD)。

为确保实验的公平性与一致性,所有智能优化方法均以平均包络熵与包络熵方差的协同最小化为适应度函数,并在相同参数搜索空间内对VMD的关键参数进行自动寻优。各对比方法的参数配置见表3。

表3 对比方法的参数配置
Tab.3 parameter configuration of the comparison methods

方法	参数类型	参数值
固定参数 VMD+SVM	VMD	模态数 K 为 4, 惩罚因子 ϱ 为 600
PSO-VMD	PSO	种群大小为 20, 学习因子 c_1 、 c_2 分别为 1.5、1.7, 粒子群算法惯性权重为 0.6, 最大迭代次数为 20
WOA-VMD	WOA	种群大小为 20, 最大迭代次数为 20
GWO-VMD	GWO	种群大小为 20, 最大迭代次数为 20
DRL-VMD+BP 神经网络	BP 分类器	3 层 BP 神经网络, 输入层有 6 个神经元, 隐藏层有 32 个神经元, 输出层有 4 个神经元, 学习率为 10^{-4} , 迭代训练 200 轮, 激活函数为 ReLU 与 Softmax

3.3 优化目标权重消融实验与分析

为验证双目标奖励函数的有效性并确定最优权重分配, 设置多组权重进行比较。在保持 DRL-VMD 模型其余参数与训练条件一致的前提下, 设置 7 组权重组合进行对比, 包括 2 组单目标组合及 5 组双目标组合。每组实验独立训练 DRL 智能体, 并基于同一测试集评估其 VMD 分解质量与后续故障诊断性能, 结果见表 4。

表 4 不同权重组合下故障诊断性能对比
Tab.4 comparison of fault diagnosis performance under different weight combinations

权重组合(ω_1, ω_2)	平均包络熵	包络熵方差	诊断准确率/%
(1,0,0)	2.15	0.38	94.7
(0.9,0.1)	2.16	0.31	95.1
(0.7,0.3)	2.16	0.26	96.4
(0.5,0.5)	2.18	0.23	96.1
(0.3,0.7)	2.24	0.21	95.2
(0.1,0.9)	2.37	0.20	92.8
(0,1,0)	2.41	0.19	92.3

由表 4 可知, 在双目标组合中, 随着 ω_1 从 0.1 增至 0.9, 平均包络熵整体呈下降趋势, 包络熵方差则相应升高。其中, 极端偏向方差组合(0.1,0.9)的性能与单方差目标组合(0,1,0)相似, 对诊断准确率的提升效果有限; 极端偏向平均熵组合(0.9,0.1)未能克服均衡性差的缺陷, 诊断准确率低于相对更平衡的组合。权重组合(0.7,0.3)的平均包络熵处于较低水平, 方差控制良好, 诊断准确率最高, 综合性能最佳, 故确定 $\omega_1=0.7$ 、 $\omega_2=0.3$ 为最优权重配置。

通过上述分析可知, 赋予平均包络熵适度且较高的权重, 同时保留一定的方差约束, 能在有效抑制整体噪声与保障各模态分量均衡性之间取得最佳平衡, 使智能体学习到最优的 VMD 参数调整策略, 为后续故障诊断提供判别力更强的特征表示。

3.4 分解效果对比与分析

不同风机声纹信号分解包络熵对比见表 5。DRL-VMD+SVM 与 DRL-VMD+BP 在信号分解阶段均采用相同的方法进行自适应变分模态分解, 两者的分解结果(即各模态的包络熵)完全一致。

表 5 不同风机声纹信号分解包络熵对比
Tab.5 comparison of envelope entropy of different turbine voiceprint signals

风机编号(故障类型)	包络熵				
	固定参数 VMD	PSO-VMD	WOA-VMD	GWO-VMD	DRL-VMD+SVM/DRL-VMD+BP 神经网络
WT1(裂纹)	3.42±0.58	2.85±0.45	2.91 ± 0.48	2.95 ± 0.50	2.08 ± 0.21
WT2(磨损)	3.65±0.61	2.97±0.47	3.05 ± 0.52	3.10 ± 0.54	2.25 ± 0.24
WT3(破损)	3.61±0.59	2.93±0.46	3.00 ± 0.51	3.07 ± 0.53	2.29 ± 0.23
平均值	3.56±0.59	2.92±0.46	2.99 ± 0.50	3.04 ± 0.52	2.21 ± 0.23

注: 数据为均值±标准差。

由表 5 可知, 对于 WT1 的裂纹故障, DRL-VMD 所得包络熵远低于固定参数 VMD, 也明显优于 PSO-VMD、WOA-VMD 和 GWO-VMD。在 WT2 的磨损故障和 WT3 的破损故障方面, 也有相同的变化趋势。DRL-VMD 在均值和方差上均优于其他方法, 表明 DRL-VMD 对于不同类型的叶片故

障均具备良好的信号分解能力。这是由于 PSO-VMD、WOA-VMD 和 GWO-VMD 这类元启发式算法采用群体迭代搜索, 其优化效果较依赖于初始种群和算法参数, 在复杂的非平稳信号处理过程中容易陷入局部最优或收敛过早。而 DRL-VMD 框架将参数优化构建为序列决策过程, 智能体通过

与环境信号的持续交互试错,能学习到更深层次的优化策略。

从整体平均值来看,所有智能优化方法均显著优于固定参数VMD。固定参数VMD的包络熵均值高达3.56,方差均值为0.59,表明其分解效果受预设参数影响较大。相比之下,智能优化方法通过自适应搜寻参数,有效提升了分解质量,特

别是采用DRL-VMD方法,可使包络熵均值降至2.21、方差降至0.23,整体性能最优。

以WT1风机裂纹故障的典型样本为例,两种模态分解方法的时域、频谱对比分别见图3、图4。DRL-VMD分解的敏感模态可清晰呈现故障特征频率,而固定参数VMD分解的模态存在严重混叠,故障特征被噪声掩盖,与表5量化分析结果一致。




图3 两种模态分解方法在WT1风机裂纹故障样本的时域对比

Fig.3 time-domain comparison of two modal decomposition methods for WT1 turbine crack fault samples




图4 两种模态分解方法在WT1风机裂纹故障样本的频谱对比

Fig.4 frequency spectrum comparison of two modal decomposition methods for crack fault samples of WT1 wind turbine

3.5 故障诊断性能对比与分析

不同方法故障诊断性能对比见表 6。DRL-VMD+SVM 方法的准确率、召回率、精确率与 F1 分数分别高达 96.4%、95.8%、96.1% 和 0.960, 在所有评估指标上均取得最优值, 验证了 DRL-VMD+SVM 方法在风机叶片故障诊断任务中的有效性与优越性。

具体而言, 采用智能优化算法 (PSO、WOA、GWO) 的 VMD 方法, 其诊断性能较固定参数 VMD 均有明显提升。其中, PSO-VMD 表现最佳, 准确率达 89.2%, 与其取得相对最优的包络熵结果相吻合, 表明更好的信号分解质量能直接转化为更高的诊断精度。然而, 这 3 种传统优化方法的性能仍显著低于 DRL-VMD 框架, 准确率相差 7.2~10.6 个百分点。这揭示了传统元启发式算法的局限性, 即在解决复杂序列优化问题时, 其离线静态寻优策略难以应对。相比之下, DRL 在线交互学习机制能更精细、动态地适配信号特性。进一步分析 DRL 框架内部的不同配置可以发现, 分类器的选择对诊断性能影响显著。均采用 DRL 优化 VMD 参数的情况下, BP 神经网络作为分类器 (DRL-VMD+BP) 的准确率为 91.5%, 而 SVM 作为分类器的准确率高达 96.4%, 这表明 DRL-VMD 与 SVM 结合能更好地处理故障特征并提升泛化能力。

表 6 不同方法故障诊断性能对比
Tab.6 comparison of fault diagnosis performance among different methods

方法	准确率/%	召回率/%	精确率/%	F1 分数
固定参数 VMD+SVM	81.2	78.5	80.3	0.794
PSO-VMD	89.2	87.8	88.5	0.881
WOA-VMD	87.5	86.1	87.0	0.865
GWO-VMD	85.8	84.3	85.2	0.847
DRL-VMD+BP	91.5	89.7	90.6	0.901
DRL-VMD+SVM	96.4	95.8	96.1	0.960

SVM 表现更优的原因是其特性更适配本研究的应用场景, 能更好地平衡模型复杂度与泛化能力。一方面, 本研究可用于训练的分类样本数量相对有限。SVM 基于结构风险最小化原则, 其目标是最大化分类间隔而非仅仅最小化训练误差, 在小样本情况下具有更优的泛化能力, 能有效避免过拟合。相比之下, BP 神经网络基于经验风险最小化原则, 在训练数据不足时更易陷入过拟合,

导致测试性能下降。另一方面, 从叶片故障敏感特征中提取的融合特征向量为四维, 属于中低维度特征, SVM 能高效处理这类问题。而 BP 神经网络模型结构相对复杂, 对于当前任务可能过于冗余, 增加了模型复杂度和过拟合风险。

4 结论

提出一种基于深度强化学习优化变分模态分解的风机叶片故障诊断方法。通过参数自适应优化、精准特征提取与高效分类的协同设计, 实现对叶片运行状态的精准识别, 主要结论如下。

(1) 针对传统 VMD 参数的选取较依赖人工经验的问题, 构建包含信号特征的高维状态空间与离散连续混合动作空间, 提出基于 PPO 算法的 DRL-VMD 自适应优化框架。该框架通过智能体与环境信号的持续交互, 实现模态数与惩罚因子的动态适配。

(2) 引入兼顾平均包络熵与包络熵方差的双目标奖励函数, 显著提升信号分解的均衡性与弱特征提取能力。实验结果表明, 该方法可将信号分解的平均包络熵大幅降至 2.21, 方差控制在 0.23 左右, 对叶片运行状态的识别准确率达 96.4%, 较固定参数 VMD 方法提升 15.2 个百分点。

(3) DRL-VMD+SVM 方法在处理风电场实测的小样本、非线性声纹信号时, 识别精度与稳定性显著优于 PSO-VMD、WOA-VMD 等传统元启发式优化算法。结合 SVM 分类器的设计能更好地处理特征空间映射, 为复杂动态工况下风机故障的诊断提供了新思路。

参考文献 (References):

[1] MASITA K, HASAN A N, SHONGWE T, et al. Deep learning in defect detection of wind turbine blades: a review[J]. IEEE Access, 2025,13: 98399-98425.

[2] DERVILIS N, CHOI M, TAYLOR S G, et al. On damage diagnosis for a wind turbine blade using pattern recognition[J]. Journal of Sound and Vibration, 2014,333(6):1833-1850.

[3] 代元军, 赵超, 李保华, 等. 矩形槽机匣对轴流通风机气动性能和噪声的影响[J]. 辽宁工程技术大学学报 (自然科学版), 2023,42(6): 707-714.

DAI Yuanjun, ZHAO Chao, LI Baohua, et al. Influence of rectangular slot receiver on aerodynamic performance and noise of axial flow fan[J]. Journal of Liaoning Technical University (Natural Science), 2023,42(6): 707-714.

[4] LI Z X, JIANG Y, GUO Q, et al. Multi-dimensional variational mode

- decomposition for bearing-crack detection in wind turbines with large driving-speed variations[J]. *Renewable Energy*, 2018, 116: 55-73.
- [5] 殷孝唯,卢世昱,都治良,等. 矿山用风力发电机桨叶表面损伤图像识别分析[J]. *辽宁工程技术大学学报(自然科学版)*, 2022, 41(5): 439-445.
- YIN Xiaojie, LU Shiyu, DU Zhiliang, et al. Identification and analysis of damage image on blade surface of mine wind turbine[J]. *Journal of Liaoning Technical University (Natural Science)*, 2022, 41(5): 439-445.
- [6] 金晓航,孙毅,单继宏,等. 风力发电机组故障诊断与预测技术研究综述[J]. *仪器仪表学报*, 2017, 38(5): 1041-1053.
- JIN Xiaohang, SUN Yi, SHAN Jihong, et al. Fault diagnosis and prognosis for wind turbines: an overview[J]. *Chinese Journal of Scientific Instrument*, 2017, 38(5): 1041-1053.
- [7] SETHI M R, SUBBA A B, FAISAL M, et al. Fault diagnosis of wind turbine blades with continuous wavelet transform based deep learning model using vibration signal[J]. *Engineering Applications of Artificial Intelligence*, 2024, 138: 109372.
- [8] ZHENG J D, SU M X, YING W M, et al. Improved uniform phase empirical mode decomposition and its application in machinery fault diagnosis[J]. *Measurement*, 2021, 179: 109425.
- [9] JOSHUA A, KUMAR R S, SIVAKUMAR S, et al. An insight on VMD for diagnosing wind turbine blade faults using C4.5 as feature selection and discriminating through multilayer perceptron[J]. *Alexandria Engineering Journal*, 2020, 59(5): 3863-3879.
- [10] 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.
- [11] 陈万志,李昊哲,刘恒嘉,等. 融合 LSTM 和优化 SVM 的风力发电机组故障预测方法[J]. *辽宁工程技术大学学报(自然科学版)*, 2022, 41(4): 379-384.
- CHEN Wanzhi, LI Haozhe, LIU Hengjia, et al. Wind turbine fault prediction method based on LSTM and optimized SVM[J]. *Journal of Liaoning Technical University (Natural Science)*, 2022, 41(4): 379-384.
- [12] HABBOUCHE H, AMIRAT Y, BENKEDJOUH T, et al. Digital twin-based gearbox fault diagnosis using variational mode decomposition and dynamic vibration modeling[J]. *Measurement*, 2025, 246: 116669.
- [13] XIA Y K, WANG W T, LI X Y. Adaptive parameter selection variational mode decomposition based on Bayesian optimization and its application to the detection of ITSC in PMSM[J]. *IEEE Access*, 2024, 12: 38594-38614.
- [14] 张沛泓,李殿维,张喜乐. 基于变分模态分解的瓦斯浓度多尺度组合预测[J]. *辽宁工程技术大学学报(自然科学版)*, 2023, 42(1): 18-24.
- ZHANG Peihong, LI Dianwei, ZHANG Xile. Multi-scale combined prediction of gas concentration based on variational mode decomposition[J]. *Journal of Liaoning Technical University (Natural Science)*, 2023, 42(1): 18-24.
- [15] MEN Z H, CHEN Z, LI Y H, et al. Railway wagon bearing fault diagnosis method based on improved sparrow search algorithm optimizing variational mode decomposition and multi-level convolutional neural network[J]. *Review of Scientific Instruments*, 2024, 95: 045104.
- [16] CHEN X J, YANG Y M, CUI Z X, et al. Vibration fault diagnosis of wind turbines based on variational mode decomposition and energy entropy[J]. *Energy*, 2019, 174: 1100-1109.
- [17] MU L X, LIU D, WU S H, et al. A condition monitoring method via a new signal expansion strategy for the crystal lifting and rotating mechanism[J]. *IEEE Transactions on Semiconductor Manufacturing*, 2026, 39(1): 115-128.
- [18] MEI L. Improved system model for fault classification and diagnosis of power system based on artificial intelligence and BP neural network and its application[J]. *Journal of Electrical Engineering & Technology*, 2025, 20(6): 4087-4102.
- [19] XU C J, YANG J T, ZHANG T Y, et al. Adaptive parameter selection variational mode decomposition based on a novel hybrid entropy and its applications in locomotive bearing diagnosis[J]. *Measurement*, 2023, 217: 113110.
- [20] LU H, ZHANG W, CHEN Z M, et al. Rotating machinery early fault detection integrating variational mode decomposition and multiscale singular value decomposition[J]. *Measurement Science and Technology*, 2024, 35(12): 126128.
- [21] LI Y, MENG X Y, XIAO S D, et al. Multivariate variational mode decomposition and generalized composite multiscale permutation entropy for multichannel fault diagnosis of hoisting machinery system[J]. *Structural Health Monitoring*, 2023, 23(3): 1842-1874.
- [22] WANG S Z, SU X T, LI J H, et al. A synergistic fault diagnosis method for rolling bearings: variational mode decomposition coupled with deep learning[J]. *Electronics*, 2025, 14: 3714.