

基于改进的 SDP 点对称特征融合图像的电机故障诊断

罗 瑜¹, 樊 赫², 郎启发³

(1. 陕西工业职业技术学院 电气工程学院, 陕西 咸阳 712000;

2. 西北机电工程研究所, 陕西 咸阳 712099;

3. 太原理工大学 机械工程学院, 太原 030002)

摘要: 针对传统时频分析方法在复杂工况下电机故障信号处理中存在的抗噪能力弱、特征区分度低等问题, 提出一种基于改进对称点模式特征融合图像的电机故障诊断方法; 采用变分模态分解对故障信号进行自适应分解, 结合粒子群优化算法动态调整 SDP 镜像对称平面旋转角 θ 、时间间隔参数 l 、角度放大因子 ξ 等关键参数, 生成多模态信号融合的 SDP 图像; 并构建轻量化卷积神经网络模型对电机故障诊断进行了研究; 以变频三相异步电机为实验对象, 对正常、匝间短路、气隙偏心、转子断条四类工况采集 1 200 组振动信号样本进行验证; 结果表明, 所提方法在故障诊断中实现了 100% 的准确率, 优于支持向量机的 97.85%、随机森林 95.24%, 在 -6 dB 强噪声环境下仍保持 98.76% 的准确率, 验证了其鲁棒性。该方法通过参数优化与特征融合提升了噪声环境下的诊断可靠性, 为电机实时监测与智能诊断提供了有效解决方案。

关键词: 电机故障诊断; SDP 方法; VMD; 参数 PSO 寻优; 特征融合; CNN 模型

Motor Fault Diagnosis Based on Improved SDP Feature Fusion Images

LUO Yu¹, FAN He², LANG Qifa³

(1. School of Electrical Engineering, Shaanxi Polytechnic Institute, Xianyang 712000, China;

2. Northwest Institute of Mechanical and Electrical Engineering, Xianyang 712099, China;

3. School of Mechanical Engineering, Taiyuan University of Technology, Taiyuan 030002, China)

Abstract: Aiming at the weak anti-noise ability and low feature discrimination of traditional time-frequency analysis methods in motor fault signal processing under complex working conditions, a motor fault diagnosis method based on improved symmetric point mode feature fusion images is proposed. A variational mode decomposition is used to adaptively decompose fault signals, and a particle swarm optimization algorithm is used to dynamically adjust key parameters such as the rotation angle θ of the symmetric plane of the symmetrized dot pattern (SDP) image, the time interval parameter l , and the angle amplification factor ξ to generate the SDP image of multi-modal signal fusion. A lightweight convolutional neural network model is constructed to study motor fault diagnosis. Taking the variable frequency three-phase asynchronous motor as an experimental object, 1 200 sets of vibration signal samples are collected for verification under four working conditions: normal, inter-turn short circuit, air gap eccentricity and rotor broken bar. The results show that the proposed method achieves the accuracy of 100% in fault diagnosis, which is better than 97.85% of the support vector machine and 95.24% of the random forest. It still maintains the accuracy of 98.76% in a -6 dB strong noise environment, which verifies its robustness. This method improves diagnostic reliability in noisy environment through parameter optimization and feature fusion, and provides an effective solution for real-time monitoring and intelligent diagnosis of motors.

Keywords: motor fault diagnosis; SDP method; VMD; parameter PSO optimization; feature fusion; CNN model

收稿日期:2025-05-07; 修回日期:2025-06-23。

基金项目:陕西工业职业技术学院自然科学类科研项目(2024YKYB-001)。

作者简介:罗 瑜(1992-),女,硕士,讲师。

引用格式:罗 瑜,樊 赫,郎启发. 基于改进的 SDP 点对称特征融合图像的电机故障诊断[J]. 计算机测量与控制, 2025, 33(11): 149-157.

0 引言

随着工业设备智能化与复杂化程度的不断提升, 旋转机械(如电机、轴承、离心风机等)的故障诊断技术对保障设备安全运行、延长使用寿命具有重要意义^[1]。复杂工况和机械负载易导致电机轴承磨损、转子不平衡、定子绕组短路等故障^[2]。电机出现故障导致其性能下降, 甚至引发严重安全事故。因此, 对电机进行实时故障诊断, 提前发现潜在问题并采取预防措施, 已成为工业领域的重要研究课题。

传统的时频分析方法(如小波变换、经验模态分解等)在处理复杂工况下的信号时存在局限性, 在处理非线性、非平稳信号时存在抗噪能力不足、特征区分度低、模态混叠和特征模糊等局限性^[3-5]。近年来, 基于对称点模式(SDP, symmetrized dot pattern)的图像化表征方法因其直观性、对信号动态特征的强捕捉能力, 逐渐成为研究热点^[6-7]。SDP作为一种新型信号可视化技术, 通过将一维信号转换为二维极坐标图像, 能够直观地反映信号的幅值、频率及时序特征差异。文献[8]将发动机振动信号转换为SDP图像, 结合卷积神经网络(CNN)实现了99.14%的诊断准确率; 文献[5]通过SDP图像融合多测点信号, 显著提升行星齿轮箱故障分类精度。文献[1]提出多间隔非对称点模式(MADP), 结合自适应噪声完备集合经验模态分解(CEEMDAN)与CNN, 在强噪声环境(信噪比-6 dB)下实现了轴承故障93.3%的分类精度; 文献[6]将SDP与图像匹配技术结合, 通过主成分分析优化特征提取, 实现离心风机失速的实时监测。此外, 文献[4]提出基于密度聚类(DBSCAN)的ASDP-DBSCAN方法, 通过优化SDP转换参数显著提升噪声环境下的诊断鲁棒性。单一SDP图像方法难以全面表征多模态信号特征^[9-10], 导致全局一局部特征关联性不足^[11]; 传统特征提取方法(如曼哈顿距离^[3]、轨道图分析^[12])对噪声敏感, 限制复杂工况下诊断可靠性; 深度学习模型的超参数优化依赖人工经验, 缺乏自适应调整能力^[13-14]。

SDP方法性能高度依赖参数选择, 包括镜像对称平面旋转角(θ)、时间间隔参数(l)和角度放大因子(ξ)。现有研究多通过经验或多次试验确定参数, 缺乏系统优化机制, 导致图像特征表达能力受限^[15]。粒子群优化(PSO, particle swarm optimization)作为一种高效的全局搜索算法, 在参数优化领域表现出显著优势。引入SPO算法动态调整SDP参数, 可提升模型对噪声干扰的鲁棒性^[15-16]。此外, CNN凭借其局部感知和权值共享特性, 能够自动提取图像深层特征并实现高精度分类。文献[17]结合变分模态分解(VMD, variational mode decomposition)与SDP图像, 利用CNN

对往复压缩机故障实现了100%的诊断准确率; 文献[18]进一步将VMD-SDP-CNN应用于铁路转辙机, 验证了该方法在复杂工况下的鲁棒性。然而, 现有研究多直接使用原始SDP图像作为CNN输入, 未充分考虑参数优化对特征表达的影响, 可能导致分类性能下降。

基于上述分析, 针对电机故障问题, 本研究提出一种基于改进SDP点对称特征融合图像的电机故障诊断方法。通过VMD分解故障信号, 利用PSO算法优化SDP参数(θ, l, ξ), 将VMD分解故障信号转换为SDP图像; 增加图像的信息量; 构建轻量化CNN模型, 实现故障特征的自动提取与分类。

1 改进的SDP特征融合故障诊断方法

1.1 VMD信号分解

VMD用于将复杂的信号分解为若干个具有不同频率成分的模态, 称为固有模态函数(IMFs, intrinsic mode functions)。VMD在信号分解过程中能够保留原始信号中的重要信息, 并抑制无关成分或噪声, 使分解出的IMF分量更好地反映信号特性。使用VMD处理信号时, 可以自适应地匹配每个模式的中心频率和有限带宽, 并通过求解约束变分模型的最优解实现信号分解^[19]。对每个分量 $u_k(t)$ 进行希尔伯特变换, 得到信号的解析信号和频谱^[20]。每个解析信号乘以一个指数项 $e^{-jw_k t}$, 如下式:

$$\left(\delta(t) + \frac{j}{\pi t} \right) u_k(t) \quad (1)$$

$$\delta(t) = \begin{cases} 0 & t \neq 0 \\ \infty & t = 0 \end{cases}, \int_{-\infty}^{+\infty} \delta(t) dt = 1 \quad (2)$$

$$\left[\left(\delta(t) + \frac{j}{\pi t} \right) u_k(t) \right] e^{-jw_k t} \quad (3)$$

式中, $e^{-jw_k t}$ 是中心频率在复平面的相量描述, w_k 是中心频率。通过对信号进行调制并计算梯度平方 L^2 范数, 估计出模态分量的中心频率带宽, 将VMD转化为一个约束变分问题。在变分问题中, 约束条件为各分量之和等于待分离信号 f , 且各分量估计带宽之和最小, 受约束变分问题表示为:

$$\begin{aligned} \min_{\{u_k\}, \{w_k\}} & \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) u_k(t) \right] e^{-jw_k t} \right\|_2^2 \right\} \\ \text{s. t. } & \sum_k u_k(t) = f \end{aligned} \quad (4)$$

式中, $\delta(t)$ 为狄拉克脉冲函数, f 为输入信号; $u_k(t)$ 为信号分解得到的 k 个IMF分量; w_k 为第 k 个IMF分量的中心频率引入Lagrange乘子 $\lambda(t)$ 和惩罚系数 α 。将约束变分问题转换为非变分约束问题。通过目标函数与约束条件相结合, 构造包含目标函数和约束项的增广Lagrange表达式:

$$L(\{u_k\}, \{w_k\}, \lambda) =$$

$$\alpha \sum_k \| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) u_k(t) \right] e^{-jw_i t} \|_2^2 + \| f(t) - \sum_k u_k(t) \|_2^2 + [\lambda(t), f(t) - \sum_k u_k(t)] \quad (5)$$

为确定约束变分方程的最佳解, 引入了交替乘法算子来更新 $\hat{u}_k^{n+1}(\omega)$ 、 w_k^{n+1} 和 λ^{n+1} 。求解最优化的过程中, 变量更新公式为:

$$\hat{u}_k^{n+1}(\omega) = \frac{f(\omega) - \sum_{i \neq k} \hat{u}_i^n(\omega) + 0.5\hat{\lambda}(\omega)}{1 + 2\alpha(\omega - w_k)^2} \quad (6)$$

$$w_k^{n+1}(\omega) = \frac{\int_0^\infty \omega |\hat{u}(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}(\omega)|^2 d\omega} \quad (7)$$

$$\lambda^{n+1} = \lambda^n + \tau \left(\hat{f}(\omega) - \sum_k \hat{u}_k^{n+1}(\omega) \right) \quad (8)$$

式中, n 为迭代次数; $\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + 0.5\hat{\lambda}(\omega)$ 为保真系数, $\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + 0.5\hat{\lambda}(\omega)$ 为信号分解残差; 分解时各 IMF 分量得频率中心及带宽不断更新, 直到满足下式的迭代条件:

$$\sum_{i=1}^k \left(\frac{\|\hat{u}_i^{n+1}(\omega) - \hat{u}_i^n(\omega)\|_2^2}{\|\hat{u}_i^n(\omega)\|_2^2} \right) < \epsilon \quad (9)$$

最后, 对信号求解得到的模态 $\hat{u}_k^{n+1}(\omega)$ 进行逆傅里叶变换得 VMD 成功分解的各 IMF 分量模态。通过调整 K 值对原始信号进行 VMD 分解, 计算不同 K 值下各 IMF 的中心频率。比较不同 K 值高频与最低频 IMF 中心频率差值。当 K 值过小时, 高频分量可能被合并; K 值过大时, 中心频率相近冗余模态出现。分解残差需满足残差 $< 10^{-7}$ 的精度要求, 确保信号信息被充分提取。

1.2 SDP 信号转换

在振动信号特征提取领域, 传统方法主要基于时域、频域、时频域和复杂度域分析。近年来, 基于图像处理技术的发展, 部分学者提出将振动信号可视化后, 利用图像处理技术提取故障特征, 取得了一定成果。其中, 基于对称点模式 (SDP, symmetrized dot pattern) 方法作为一种新型图像生成技术, 凭借计算公式简洁、运算效率高的优势, 可将一维时间序列数据映射至极坐标系生成雪花状图像^[18]。该方法通过花瓣形态差异直观呈现不同信号特征, 为振动信号的可视化特征提取提供创新途径。

时域信号 $X = \{x_1, x_2, \dots, x_{n-1}, x_n\}$ 进行归一化处理, 通过对称点生成的方式将时域信号转化为极坐标下的 $S = \{r(i), \theta(i), \varphi(i)\}$, 如图 1 所示。

$$r(i) = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (10)$$

$$\theta(i) = \theta + \frac{x_{i+1} - x_{\min}}{x_{\max} - x_{\min}} \zeta \quad (11)$$

$$\varphi(i) = \theta - \frac{x_{i+1} - x_{\min}}{x_{\max} - x_{\min}} \zeta \quad (12)$$

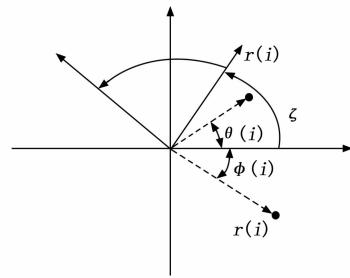


图 1 SDP 转换原理

式 (10) ~ (12) 中: x_{\max} 为信号的最大幅值、 x_{\min} 为信号的最小幅值、 x_i 为信号第 i 个样本点、 l 为时间间隔参数、 θ 为镜像对称平面旋转角、 ζ 为角度放大因子。在 SDP 方法中 θ 、 l 和 ζ 这 3 个参数的选择极为重要, 通过大量实验发现, 一般 ζ 要小于 θ , 取 $20^\circ \sim 50^\circ$ 最佳, l 的值在 $1 \sim 10$ 范围内最佳。

1.3 PSO 参数寻优

粒子群优化 (PSO, particle swarm optimization) 是一种基于群体智能的优化算法, 通过模拟群体中的个体间协作与信息共享机制来寻找问题的最优解。在 PSO 中, 每个粒子代表问题的一个可能解, 具有位置和速度属性^[21-22]。位置表示当前解, 速度则决定粒子下一步的移动方向和快慢。位置更新计算式为:

$$x_{i,t+1} = x_{i,t} + v_{i,t} \quad (13)$$

式中, $x_{i,t}$ 表示粒子 i 在时间 t 的位置, $v_{i,t}$ 表示粒子 i 在时间 t 的速度。粒子通过个体经验和群体经验来调整自己的行为, 个体经验由粒子自身的历最佳位置 (P_{best}) 决定, 群体经验由整个种群的最佳位置 (G_{best}) 决定。粒子根据适应度函数评估当前解的好坏, 并据此动态调整自己的速度和位置。通过不断的迭代, 粒子逐渐逼近问题的最优解。PSO 的核心在于粒子的速度和位置更新规则。速度更新公式结合了粒子的惯性、个体经验和群体经验, 位置更新公式则根据新的速度调整粒子的位置。速度更新计算式为:

$$v_{i,t+1} = w \cdot v_{i,t} + c_1 \cdot r_1 P_{\text{best}} - c_2 \cdot r_2 \cdot G_{\text{best}} \quad (14)$$

针对不同搜索问题, 调整全局和局部搜索能力, PSO 算法成功地应用于实际问题。本文 SDP 参数 PSO 寻优处理流程如图 2 所示。

PSO 适应度函数通过多维度图像几何特征 + 预训练分类代理指标联合优化, 实现花瓣均匀度、复杂度等指标直接关联故障机理, PSO 参数优化使 SDP 图像在噪声下仍保持高区分度, 克服传统 SDP 参数依赖经验的局限, 为智能诊断系统提供了自主优化能力。

1.4 CNN 分类网络

卷积神经网络 (CNN) 是一种专门用于处理具有网格结构数据的深度学习模型。通过卷积层、池化层和全连接层等组件提取特征并进行分类^[22]。其核心在于

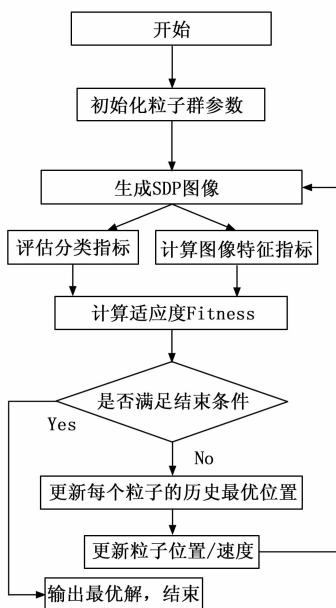


图 2 PSO 算法流程

通过卷积操作和池化操作构建层次特征表示，从而实现输入数据的有效表示学习和模式识别。

CNN 通常以输入层作为第一层，池化层通常设置在卷积层之后。经过多层卷积层和池化层的堆叠，最终通过全连接层，将特征表示映射到输出类别。卷积层是 CNN 核心部分，通过卷积核在输入数据上滑动提取局部特征。卷积层输入一个通道数为 C_{in} ，高度为 H_{in} 、宽度为 W_{in} 的 $C_{in} \times H_{in} \times W_{in}$ 张量，卷积核是通道数和卷积核大小的数学关系式，表示为 $C_{in} \times K \times K$ ，输出与输入一致 $C_{out} \times H_{out} \times W_{out}$ ，是一个为通道数 C_{out} ，高度为 H_{out} 、宽度为 W_{out} 的张量。卷积层的输出 O 由以下公式计算：

$$O_{c,i,j} = bias_c + \sum_{k=0}^{C_c-1} \sum_{m=0}^{K-1} \sum_{n=0}^{K-1} I_{k,i+s \cdot m, j+s \cdot n} \cdot K_{c,k,m,n} \quad (15)$$

式中， I 是输入张量， K 是卷积核， $bias_c$ 是第 c 各卷积核偏置， s 是步幅 (stride)， i, j 是输出特征坐标。输出特征图的尺寸由以下公式决定：

$$H_{out} = \left\lceil \frac{H_{in} + 2 \cdot p - K}{s} \right\rceil + 1 \quad (16)$$

$$W_{out} = \left\lceil \frac{W_{in} + 2 \cdot p - K}{s} \right\rceil + 1 \quad (17)$$

式 (16)、(17) 中， p 是填充 (padding) 大小， K 是卷积核大小， s 是步幅， i, j 是输出特征坐标。输出特征图的尺寸由以下公式决定：

池化层用于减少特征图的尺寸，降低计算量并防止过拟合。输入一个通道数为 C_{in} ，高度为 H_{in} 、宽度为 W_{in} 的 $C_{in} \times H_{in} \times W_{in}$ 张量，池化窗口为 $P \times P$ ，输出一个通道数 C_{out} ，高度为 H_{out} 、宽度为 W_{out} 的 $C_{out} \times H_{out} \times W_{out}$ 张量。池化层的输出计算公式为：

$$O'_{c,i,j} = \max_{m=0}^{P-1} \max_{n=0}^{P-1} I_{c,i+s \cdot m, j+s \cdot n} \quad (18)$$

$$O''_{c,i,j} = \frac{1}{P^2} \sum_{m=0}^{P-1} \sum_{n=0}^{P-1} I_{c,i+s \cdot m, j+s \cdot n} \quad (19)$$

式 (18) 为最大池化，式 (19) 是平均池化， s 是步幅 (stride)， P 是池化窗口大小。输出特征图尺寸计算如下式：

$$H_{out} = \left\lceil \frac{H_{in} - P}{s} \right\rceil + 1 \quad (20)$$

$$W_{out} = \left\lceil \frac{W_{in} - P}{s} \right\rceil + 1 \quad (21)$$

全连接层将卷积层或池化层的输出映射到输出类别。输入 N 维向量，通过 $N \times M$ 权重矩阵，输出 M 维向量。输出 O_j 由公式计算：

$$O_j = bias_j + \sum_{i=0}^{N-1} \mathbf{I} \cdot \mathbf{W}_{i,j} \quad (22)$$

式 (21) 中， \mathbf{I} 是输入向量， \mathbf{W} 是权重矩阵， $bias_j$ 是第 j 神经元偏置。在 CNN 中，卷积层通过在输入数据上滑动卷积核来提取局部特征，从而生成特征图。池化层降低了特征图的空间维度，降低了计算复杂度，并保留了最显著的特征。通过执行池化操作，CNN 可以保留关键的特征信息，并降低过拟合的风险。全连接层将提取的高层特征映射到最终的输出类别。

改进的 SDP 特征融合故障诊断方法通过 VMD 分解多模态信号，VMD 自适应分解有效分离故障特征与噪声，实现 SDP 融合全局—局部特征，利用 PSO 算法优化 SDP 参数 (θ, l, ξ) ，生成高区分度雪花图，增强抗干扰性；构建轻量化 CNN (2 层卷积) 实现低参数量 + 端到端分类，实现故障特征的自动提取与分类。

2 电机实验验证

2.1 改进的 SDP 特征融合故障诊断流程

改进的 SDP 点对称特征融合图像的电机故障诊断方法的流程如图 3 所示。

通过振动传感器采集电机四类工况 (正常、匝间短路、气隙偏心、转子断条) 的振动信号，研究过程的主要步骤如下：

- 1) 通过实验获取电机典型故障振动信号，并进行初步处理将故障原始信号进行 SDP 转换；
- 2) 利用 VMD 对实验原始故障信号进行分解，并将分解后的信号进行 SDP 转换；
- 3) 对转换后的 SDP 图像打标签进行编码，结合原始信号的 SDP 转换图，并进行训练图像集、测试图像集的划分；
- 4) 最后通过训练进行 CNN 分类模型训练，并导入测试图像集进行故障诊断分类测试验证。

2.2 电机故障实验

以型号为 YXVF90L-2 的变频三相异步电机作为实

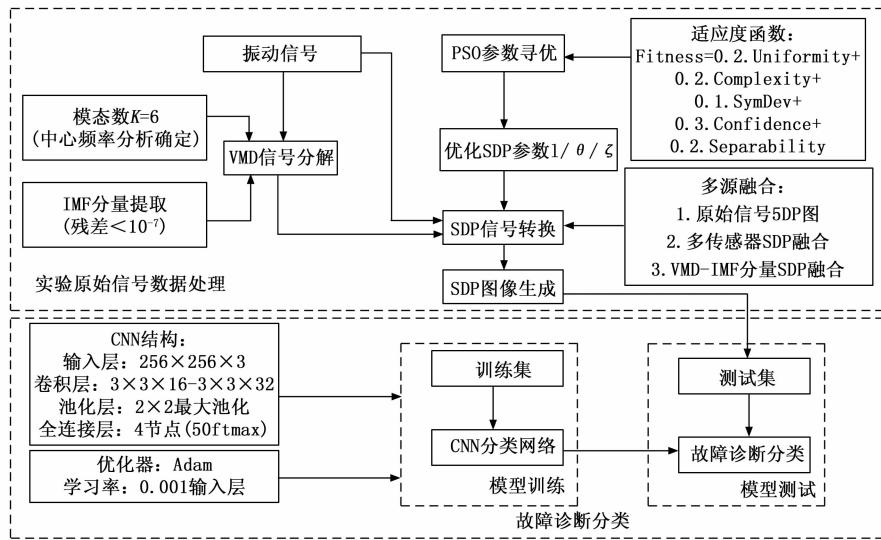


图 3 故障诊断流程

验对象进行实验验证。实验共设置了 3 种故障与正常状态 4 种工况, 具体故障设置见表 1。

表 1 电机故障设置

工况类型	标签	故障类型	编码
正常状态	1	正常	N
故障状态	2	匝间短路	SC
	3	气隙偏心	AE
	4	转子断条	RBB

正常状态 (N) 作为基准工况, 用于对比故障信号的特征差异。匝间短路 (SC) 为定子绕组局部短路导致电流分布不均, 产生高频谐波分量。气隙偏心 (AE) 是转子与定子间气隙不均匀, 导致电磁力不平衡。转子断条 (RBB) 是因为转子导条断裂导致磁场不对称, 产生边频带。实验设置采样时长为 1 秒, 采样频率为 1.024 kHz, 对电机 4 种工况各采集 300 组实验数据样本进行研究分析, 电机 4 种工况诊断信号如图 4 所示。

图 4 可知, 正常状态下电机的振动信号频谱稳定, 无明显异常频率成分, SC 状态振动信号中会出现与电源频率相关的倍频分量, 同时伴随电磁转矩脉动, AE 状态呈现明显的旋转频率成分, RBB 状态出现周期性冲击特征。

2.3 信号 VMD 分解

通过 VMD 对各种故障类型的原始实验信号进行自适应分解, 控制变量选取不同的 K 值将故障的原始信号分解成不同 IMF 分量, 对不同的 K 值的 IMF 的中心频率进行中心频率最大值比较分析, 确定最佳的 K 值为 6, 进行 IMF 分量信号提取。 $K=6$ 以故障 N 信号为例进行 VMD 分解, 结果如图 5 所示。

图 5 可知故障 N 的原始信号 VMD 分解得到的模态具体分布情况, 基于不分析计算可知第 1 个 IMF 中心频

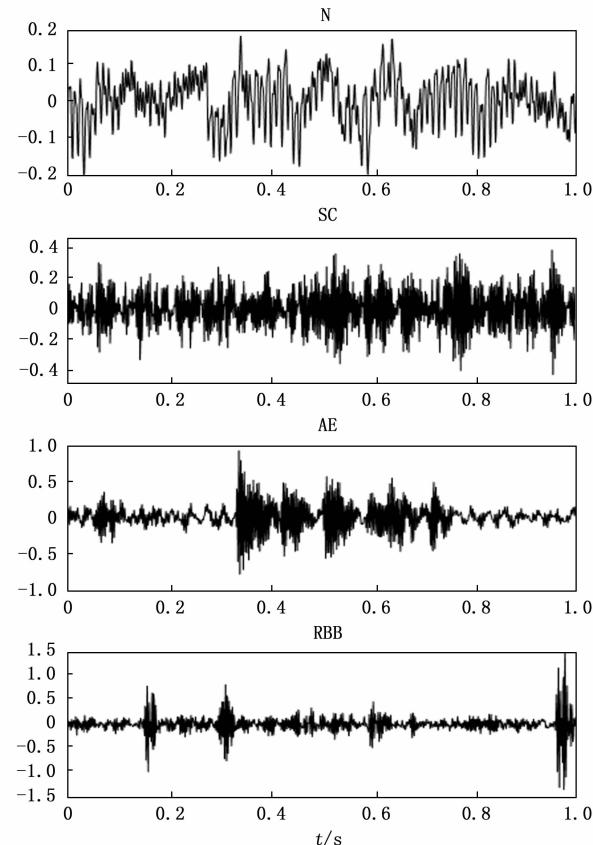
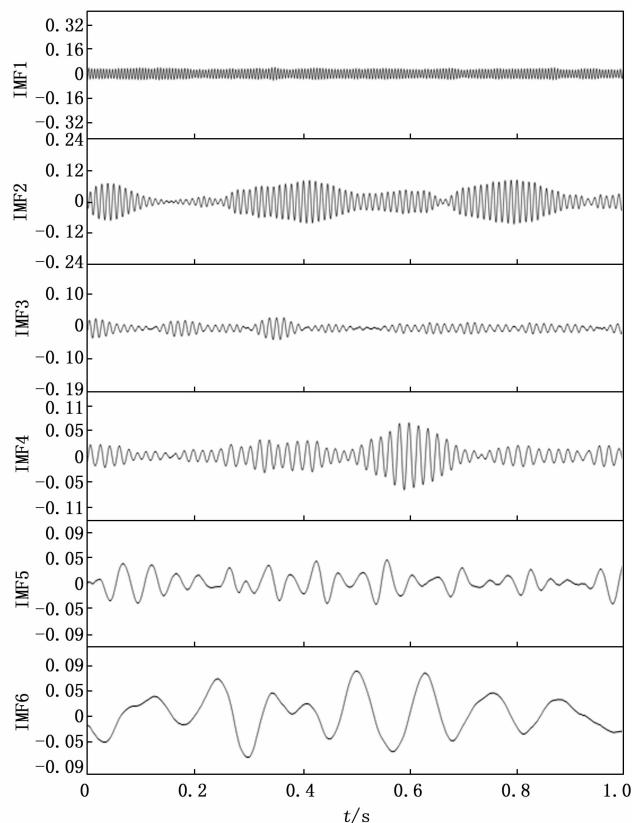


图 4 电机不同工况诊断信号

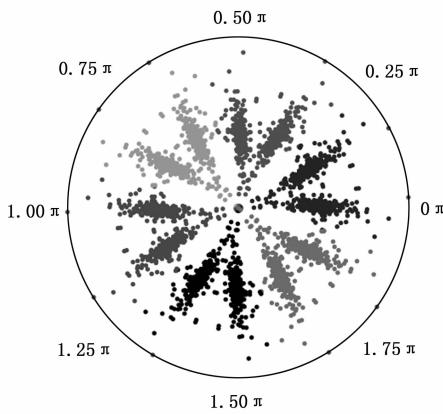
率为 174.805 Hz, 第六个 IMF 中心频率为 7.813 Hz, 对应能量峰, 且残差小于 10^{-7} 。机械故障诊断中可接受误差为 2%~3%, 满足要求。

2.4 实验信号 SDP 初始转换

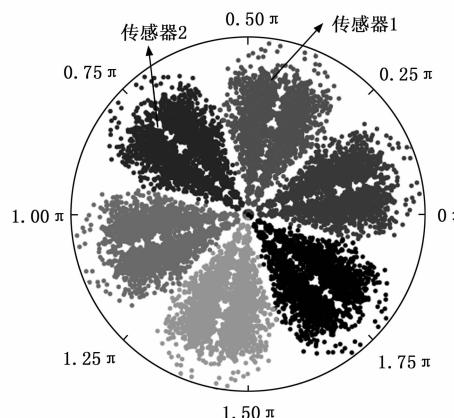
SDP 转换镜像对称平面旋转角 θ 影响图像扇形分布, 一般在 $30\sim60^\circ$ 取值, 初始转换取 45° 。角度放大因子 ξ 值越小扇形越窄, 取值推荐在 $20^\circ\sim50^\circ$, 初始转换

图 5 $K=6$ 以正常信号电机正常工况信号 VMD 分解

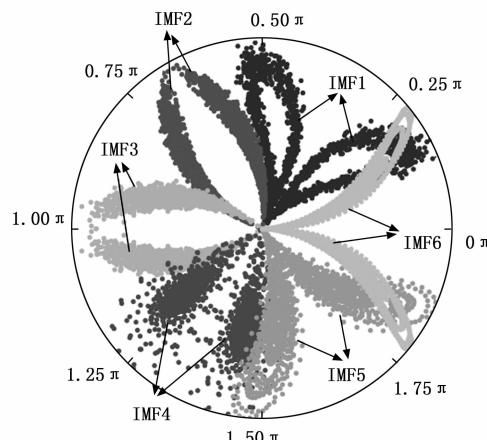
取 35° ，时间间隔参数 l 控制散点的密，在 $3 \sim 10$ 中进行选择，初始转换取 5，得到的 SDP 图像尺寸需与 CNN 的输入尺寸一致。以 N 类 6 组单通道实验原始信号进行 SDP 初始转换，结果如图 6 所示。

图 6 N 类 6 组单通道原始信号 SDP 转换

如图 6 所示可知 SDP 方法可将电机的一维时间故障信号转换为极坐标中的二维镜像对称雪花图，并且可直观反映电机故障信号幅度和频率的变化。SDP 将故障实验的传感器多通道信号进行融合，每个通道信号占 SDP 一个扇区。SDP 原始分解多通道故障信号以 N 类信号为例，融合结果如图 7 所示。

图 7 N 类多传感器原始信号 SDP 转换融合

如图 7 所示为多传感器实验信号 SDP 转换融合，逆时针开始分别为传感器 1、传感器 2、传感器 3 等以此类推。基于此融合思路可将 VMD 分解的 IMF 分量进行融合，达到故障信号特征级融合目的。以 N 类故障实验传感器 1 故障信号为例，进行 VMD 分解的 6 个 IMF 信号 SDP 转换融合，结果如图 8 所示。

图 8 N 类 VMD 分解的 IMF 信号 SDP 转换融合

通过将多组实验原始信号、多传感器通道信号及 VMD 分解的多模态信号进行 SDP 图像转换融合，实现故障信号的特征级融合，为进一步进行故障诊断提供充足信号信息，提高故障诊断精度和效率。

3 改进的 SDP 转换

3.1 PSO 参数寻优

以镜像对称平面旋转角 θ 为 $30^\circ \sim 60^\circ$ 。角度放大因子 ξ 在 $20^\circ \sim 50^\circ$ ，时间间隔参数 l 在 $3 \sim 10$ 中进行 PSO 参数寻求解，通过 SDP 极性空间图像展示故障信号频率和幅度变化，选择最佳的转换参数，便于提取故障信号特征进行进一步故障状态诊断识别。以 N 、SC、AE、RBB 四类故障的传感器 1 故障信号为例进行 PSO 寻优，最终参数选取见表 2。

表 2 PSO 参数寻优结果

工况类型	$\theta/^\circ$	$\xi/^\circ$	l
N	22.72	46.06	7
SC	33.09	14.14	3
AE	41.60	15.66	3
RBB	24.20	30.01	9

3.2 改进的 SDP 转换

通过 PSO 方法进行 SDP 图像转换的参数寻优, 目的是通过动态调整 SDP 参数, 生成更具区分度的 SDP 图像, 从而提升后续 CNN 等模型的故障分类性能。由于篇幅有限, 以 3.1 小节传感器 1 故障信号为例的寻优参数进行 SDP 转换图像, 展示每种工况 Matlab 求解转换 SDP 转换图像, 如图 9 所示。

图 10 可知 PSO 参数寻优后的 SDP 图像在四类故障中表现出显著差异。N 类故障信号优化后 SDP 图像如图 10a 所示, 呈现规则的放射状对称花瓣, 中心区域分布均匀, 无局部畸变。SC 类结果如图 10b 所示, 由于 ξ

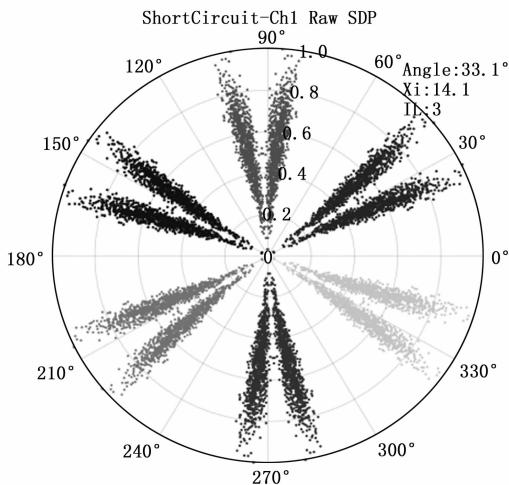
较小且 l 较短, 花瓣呈高密度簇状分布, 中心区域存在不规则“断裂”模式, 反映了短路电流引起的非平稳高频振荡。AE (图 10c) 类故障的 θ 较大导致扇形区域扩展, 花瓣沿特定方向拉长, 形成“彗尾”形态, 对应气隙不均引起的周期性偏心振动。RBB (图 10d) 故障信号的 l 较大使得散点间隔稀疏, 图像边缘呈现离散的“星点”分布, 表征断条瞬间的瞬态冲击信号。

PSO 参数寻优通过动态匹配 SDP 参数与故障信号特性, 显著提升图像的特征表达能力和抗噪鲁棒性。SDP 图像 PSO 优化后直观呈现不同故障的物理机制差异, 为 CNN 模型提供高区分度输入数据。

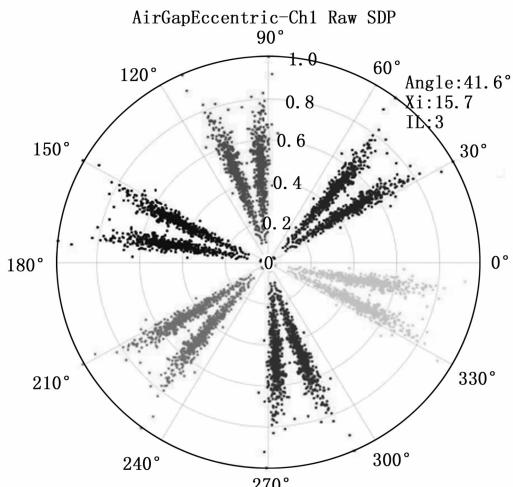
4 故障诊断分析

4.1 CNN 网络参数设置

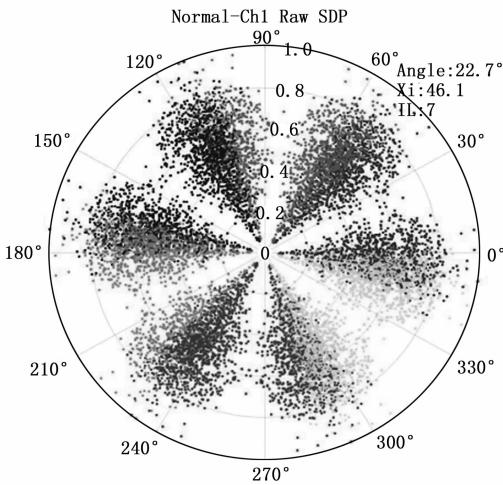
研究所用 CNN 网络输入层接受 256×256 的 RGB 图像, 卷积层 1 用 3×3 卷积核, 16 个滤波器, 卷积层 2 用 3×3 卷积核, 32 个滤波器。归一化层保证加速训练和提高稳定性, 激活函数层利用 ReLU1 激活函数引



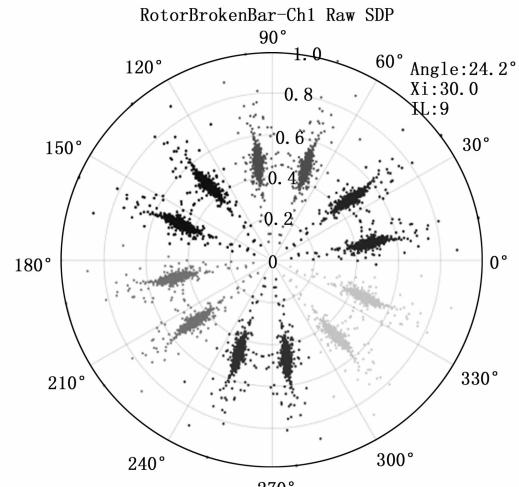
(a) PSO参数寻优的N类信号SDP转换图像



(c) PSO参数寻优的AE类信号SDP转换图像



(b) PSO参数寻优的SC类信号SDP转换图像



(d) PSO参数寻优的RBB类信号SDP转换图像

图 9 4 种工况 PSO 寻优参数的 SDP 图

入非线性。最大池化层为 2×2 的池化窗口, 步长为 2, 全连接层输出的 4 个节点对应 4 种类型故障, LR 为 0.001。CNN 网络模型具体参数见表 3。

表 3 CNN 网络模型具体参数

参数类别	参数设置	说明
输入层	[256, 256, 3]	输入图像的尺寸
卷积层 1	[3, 3]	卷积核
批量归一化	0.9	滑动平均动量参数
	0.000 05	防止除零的小常数
激活层 1	ReLU1	线性整流激活函数
池化层 1	[2, 2]	池化窗口大小
	2	滑动步长
全连接层	4	对应 4 种故障类型
训练参数	Adam	自适应矩估计优化器
	200	最大训练轮次
	32	批量大小
	测试集数据	30% 数据作为验证集

4.2 故障诊断

根据图 1.3 所示的 CNN 模型结构与表 4.1 的 CNN 参数设置, 按照 7 : 3 的训练测试比例对电机故障进行诊断分类分析, 模型训练验证的准确度及损失函数曲线如图 10 所示。

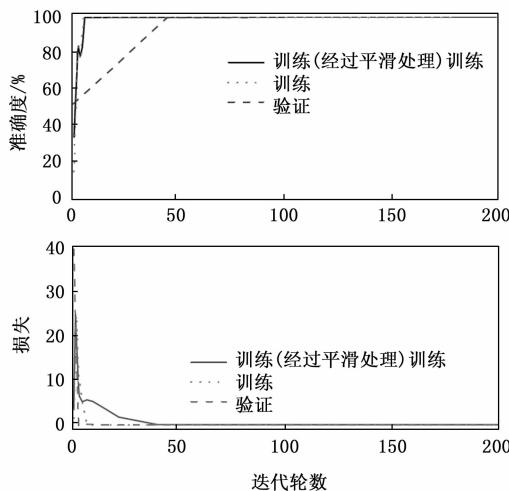


图 10 训练精度与损失函数曲线

由图 10 可知, 当迭代轮数达到 50 轮以后, 训练的准确度达到了 100%, 表明改进的 SDP 转换图像结合 CNN 网络模型对于电机的故障诊断具有可观准确度与显著实用性。

4.3 方法对比分析

为进一步验证基于改进的 SDP 图像结合 CNN 模型对电机故障诊断的实用性, 对不同方法进行对比试验验证, 选用 SVM、与随机森林机 KNN 作为对比方法模型进行验证, 改进的 SDP 图像转换的不同故障类型故障诊断结果整体平均准确度见表 11 所示。

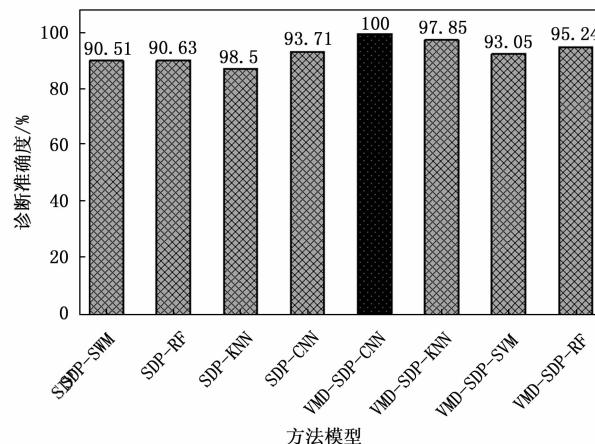


图 11 不同方法模型准确度对比

图 11 可知模型 VMD-SDP-CNN 的诊断准确度达到 100%, VMD-SDP-KNN 模型和 VMD-SDP-RF 模型诊断准确度也相对较高, 分别为 97.85% 和 95.24%。且通过 VMD 信号分解后的 SDP 图像的诊断分类准确度普遍高于单一 SDP 图像转换的诊断分类模型, 表明 VMD 分解及 PSO 参数寻优对电机故障信号分解有助于提高诊断准确度。为进一步验证所提方法的先进性, 增加与深度学习模型的对比实验, 采用相同的 1 200 组样本为数据集, 结果见表 4。

表 4 不同深度学习算法诊断性能对比

方法	准确率 /%	训练时间 /min	-6 dB 噪声下准确率 /%
ResNet-50/原始信号输入	96.32	48.2	82.15
LSTM/VMD 分解信号输入	95.78	52.7	87.33
Inception-v3/未优化 SDP 图像	97.85	63.5	89.42
本文方法	100	22.3	98.76

表 4 中, ResNet-50 直接处理电机实验原始振动信号, 长度为 1 024 个点; LSTM 输入 VMD 分解的 6 个 IMF 分量, 每分量 1 024 个点; Inception-v3 输入固定参数 SDP 图像。本文方法准确率 100%, 较 ResNet-50 提升 3.68%, 较 Inception-v3 提升 2.15%。分析原因可知 VMD 分解有效分离噪声与故障特征, PSO 优化的 SDP 图像显著增强特征可分性, 如 SC 故障的“断裂”形态、AE 故障的“彗尾”形态等; 在-6 dB 强噪声下, 本文所提方法准确率保持 98.76%, 远高于 ResNet-50 的 82.15%, 验证 VMD-PSO-SDP 方法的联合抗噪机制。

5 结束语

本文提出基于改进 SDP 点对称特征融合图像的电机故障诊断方法, 通过 VMD 分解故障信号、PSO 算法优化 SDP 参数, 结合轻量化 CNN 模型实现故障特征的自适应提取与分类。实验表明, 该方法在电机典型故障

诊断中实现 100% 准确率, 较传统模型提升 2.15% ~ 4.76%。

为验证所提方法的先进性, 增加与深度学习模型的对比实验, 采用相同的 1 200 组样本为数据集, 轻量化 CNN 模型 1.2 MB 参数量, 8.5 ms 级推理延时, 满足边缘设备实时监测需求。且 -6 dB 噪声下 98.76% 准确率, 噪声鲁棒性提升显著。

在接下来的研究中作者将进一步优化 PSO 算法的计算效率, 降低参数优化对人工经验的依赖; 同时验证方法在更多故障类型、噪声环境及跨设备场景下的泛化能力。

参考文献:

- [1] XIAOPING L, LIJIAN X, JIAN S, et al. Fault diagnosis of rolling bearings based on the improved symmetrized dot pattern enhanced convolutional neural networks [J]. *Journal of Vibration Engineering & Technologies*, 2023, 12 (2): 1897–1908.
- [2] 王建平, 马 建, 孟德安, 等. 基于 EMD-SDP 图像特征和改进 DenseNet 车用 PMSM 故障诊断 [J]. *汽车工程*, 2024, 46 (4): 703–716.
- [3] YONGJIAN S, SHAOHUI L, YALING W, et al. Fault diagnosis of rolling bearing based on empirical mode decomposition and improved Manhattan distance in symmetrized dot pattern image [J]. *Mechanical Systems and Signal Processing*, 2021, 159: 107817–107830.
- [4] LI H, WANG W, HUANG P, et al. Fault diagnosis of rolling bearing using symmetrized dot pattern and density-based clustering [J]. *Measurement*, 2020, 152: 107293–107306.
- [5] 崔宝珍, 彭智慧, 王浩楠, 等. 应用 SDP 点对称特征融合图像的行星齿轮箱故障诊断 [J]. *噪声与振动控制*, 2023, 43 (4): 82–87.
- [6] XU X, QI M, LIU H. Real-time stall detection of centrifugal fan based on symmetrized dot pattern analysis and image matching [J]. *Measurement*, 2019, 146: 437–446.
- [7] ZHU X, HOU D, ZHOU P, et al. Rotor fault diagnosis using a convolutional neural network with symmetrized dot pattern images [J]. *Measurement*, 2019, 138: 526–535.
- [8] 王运生, 王黎明. 基于 SDP 图像和深度卷积网络的发动机故障诊断 [J]. *噪声与振动控制*, 2023, 43 (5): 175–180.
- [9] XU X, QI M, LIU H. Real-time stall detection of centrifugal fan based on symmetrized dot pattern analysis and image matching [J]. *Measurement*, 2019, 146: 437–446.
- [10] ZHU X, HOU D, ZHOU P, et al. Rotor fault diagnosis using a convolutional neural network with symmetrized dot pattern images [J]. *Measurement*, 2019, 138: 526–535.
- [11] XU G X, LIU X H, WANG L S, et al. Real-time stall detection of centrifugal fan based on the analysis of symmetrized dot pattern and wavelet packet transform [J]. *Journal of Journal of Vibroengineering*, 2017, 19 (3): 1823–1832.
- [12] SHUKLA J, PANIGRAHI K B, BANSAL C R. Imaging time series technique with an adaptive particle swarm optimized CNN model for classification of faults in transmission line [J]. *Smart Grids and Sustainable Energy*, 2025, 10 (1): 11–11.
- [13] SANEEP K, SUNDARESWARAN K, NAYAK R S P, et al. State of charge estimation of lithiumion batteries using PSO optimized random forest algorithm and performance analysis [J]. *Journal of Energy Storage*, 2025, 114 (PB): 115879–115879.
- [14] DENG L, ZHAO C, YAN X, et al. A novel approach for bearing fault diagnosis in complex environments using PSO-CWT and SA-FPN [J]. *Measurement*, 2025, 249: 117027–117050.
- [15] WANG J, ZHANG C, JIAO F, et al. Parameters optimization for 2.5D needled Cf/SiC in longitudinal torsional ultrasonic-assisted laser milling on PSO-BP-PSO [J]. *CIRP Journal of Manufacturing Science and Technology*, 2025, 58: 87–106.
- [16] MIN H T, LEE J J, CHEONG Y D, et al. CNN-based fault classification using combination image of feature vectors in rotor systems [J]. *Journal of Mechanical Science and Technology*, 2024, (prepublish): 1–11.
- [17] 王海峰, 王则林. 基于 VMD-SDP 融合图像和 CNN 的往复压缩机故障诊断 [J]. *噪声与振动控制*, 2023, 43 (4): 116–121.
- [18] 宋雅坤, 冯庆胜, 肖 帅, 等. 基于 VMD-SDP-CNN 的铁路转辙机故障诊断 [J]. *Journal of Measurement Science and Instrumentation*, 2024, 15 (1): 1–12.
- [19] 王梦阳, 王华庆, 董 方等. 基于 EVMD-LNMF 的复合故障信号分离方法 [J]. *振动与冲击*, 2019, 38 (16): 146–152.
- [20] CHENG J, YU D, YANG Y. Research on the intrinsic mode function (IMF) criterion in EMD method [J]. *Mechanical Systems and Signal Processing*, 2006, 20 (4): 817–824.
- [21] MIN H T, LEE J J, CHEONG Y D, et al. CNN-based fault classification using combination image of feature vectors in rotor systems [J]. *Journal of Mechanical Science and Technology*, 2024, (prepublish): 1–11.
- [22] ZHANG L, HU Y, CHEN T, et al. Novel freight train image fault detection and classification models based on CNN [J]. *International Journal of Computational Science and Engineering*, 2023, 26 (5): 567–578.