

基于CNN-SVM融合算法的矿用充电机功率模块早期故障识别

许志鹏, 陈 虎

中煤科工(上海)新能源有限公司, 上海

收稿日期: 2026年7月18日; 录用日期: 2026年8月13日; 发布日期: 2026年8月17日

摘 要

针对矿用充电机功率模块早期故障辨识存在检测灵敏度偏低、故障特征易受环境噪声干扰、小样本数据集难以充分挖掘有效信息等现实痛点, 本文提出融合改进变分模态分解(IVMD)、多尺度注意力卷积神经网络(MS-CNN-Attention)与粒子群优化支持向量机(PSO-SVM)的一体化智能故障诊断模型。首先依托IVMD算法完成原始电气信号自适应分解, 结合排列熵(PE)筛选含有微弱故障信息的模态分量并完成信号重构, 实现故障特征信噪比优化; 其次搭建嵌入SE挤压激励注意力机制的多尺度卷积神经网络, 通过多尺寸卷积核并行提取多感受野故障特征, 借助通道动态加权机制强化关键故障特征表征效果; 最后将网络输出的高维特征输入经粒子群算法完成超参数寻优的SVM分类器, 完成功率模块早期故障精细化分类识别。仿真测试结果表明, 所提混合模型对四类典型早期故障的平均识别精度可达98.8%, 在高强度噪声工况下具备优良抗干扰性能, 模型单次推理耗时满足设备在线实时监测指标。研究成果可为矿山电力电子装备的预测性维保工作提供新的技术实现路径。

关键词

矿用充电机, 功率模块, 早期故障辨识, 改进变分模态分解, 卷积神经网络, 支持向量机, 预测性维护

Early Fault Identification of Power Modules in Mining Battery Chargers Based on CNN-SVM Fusion Algorithm

Zhipeng Xu, Hu Chen

China Coal Technology & Engineering (Shanghai) New Energy Co., Ltd., Shanghai

Received: July 18, 2026; accepted: August 13, 2026; published: August 17, 2026

文章引用: 许志鹏, 陈虎. 基于 CNN-SVM 融合算法的矿用充电机功率模块早期故障识别[J]. 建模与仿真, 2026, 15(8): 51-60. DOI: 10.12677/mos.2026.158122

Abstract

To solve the prominent problems including insufficient detection sensitivity, severe noise interference on fault features and inefficient utilization of limited small-scale datasets during early fault identification of power modules for mining chargers, an integrated intelligent diagnosis model combining Improved Variational Mode Decomposition (IVMD), Multi-scale Attention Convolutional Neural Network (MS-CNN-Attention) and PSO optimized Support Vector Machine (PSO-SVM) is proposed in this paper. Firstly, IVMD is adopted to adaptively decompose original electrical signals, and Permutation Entropy (PE) is used to screen sensitive modal components containing faint fault information for signal reconstruction, which improves the signal-to-noise ratio of fault features effectively. Then, an MS-CNN-Attention network embedded with Squeeze-and-Excitation (SE) attention is constructed. Multi-size convolution kernels are applied to extract multi-receptive-field features in parallel, and dynamic channel weighting is realized to enhance the representation capability of critical fault characteristics. Ultimately, high-dimensional features extracted by the neural network are imported into the SVM classifier whose hyperparameters are optimized via particle swarm optimization, realizing accurate classification of incipient faults in power modules. Simulation experiments verify that the proposed hybrid model achieves an average diagnostic accuracy of 98.8% for four categories of typical early faults, presents outstanding anti-noise robustness under harsh noisy conditions, and its single inference latency satisfies the requirement of real-time online monitoring. The research provides an innovative technical reference for predictive maintenance of mining power-electronic equipment.

Keywords

Mining Charger, Power Module, Early Fault Identification, Improved Variational Mode Decomposition, Convolutional Neural Network, Support Vector Machine, Predictive Maintenance

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 绪论

1.1. 研究背景与科学意义

伴随全球能源体系转型升级以及国内智慧矿山建设战略落地推进,煤矿井下辅助运输装备电动化、智能化已然成为行业迭代发展的主流方向。单轨吊作为井下关键性辅助运输设备,其动力单元运行稳定性直接决定井下采矿作业的生产效率与安全水平。矿用充电机作为单轨吊动力电池组的核心供能配套设备,内部功率变换器件的健康状态是保障整套运输系统连续稳定运行的先决条件。

矿井井下作业工况恶劣,长期处在高湿环境、机械强振动、粉尘富集以及供电网电压频繁扰动等复杂工况下,充电机核心功率器件 IGBT (绝缘栅双极型晶体管)长期处于高频通断工作状态,持续承受交变热应力与电磁应力。现有统计数据显示,电力电子变换器故障中约 31%由功率器件失效诱发。传统故障诊断技术多聚焦于器件短路、开路等破坏性突发故障的检测,此类故障发生后功率器件已彻底失效,极易造成装备非计划停机,严重时诱发井下起火、爆炸等安全生产事故[1]。

早期故障辨识技术立足于器件性能缓慢劣变的亚健康阶段(键合线疲劳老化、芯片参数漂移等),依托采集电气信号的细微畸变实现故障提前预警。依托该项技术可推动矿山设备运维模式由事后故障抢修向全周期预测性维护转型,在压缩设备运维成本的同时,夯实煤矿安全生产基础,同样是实现井下单轨吊

无人化作业、智能运维的关键技术支撑。

1.2. 国内外研究现状

1.2.1. 功率模块故障诊断主流技术

国内外学术界围绕功率半导体器件故障诊断已开展大量研究, 现有技术体系可划分为解析建模法、信号特征分析法与数据驱动智能诊断法三类[2]:

基于解析模型的诊断方法: 依托器件电路机理建立精准数理模型, 结合状态观测、参数辨识生成残差信号实现故障判别。但矿用电力系统非线性耦合特征突出、杂散参数繁杂, 精准解析模型搭建难度较大, 制约该方案在工程场景落地应用[3]。

基于信号处理的诊断方法: 以傅里叶变换、小波变换、希尔伯特黄变换等时频分析算法为工具, 从原始监测信号中剥离故障特征。该类算法在特定工况下具备可行性, 但特征提取高度依赖领域专家先验知识, 强噪声环境下难以捕获微弱早期故障分量[4]。

基于数据驱动的智能诊断方法: 伴随人工智能技术迭代, 机器学习、浅层神经网络与 SVM 算法逐步应用于故障识别。该方法无需依托精确物理建模, 但针对矿井非平稳工况、故障样本稀缺的现实条件, 普遍存在特征提取盲目性强、模型泛化性能不足等缺陷, 难以适配高精度诊断需求[5]。

1.2.2. 深度学习在故障诊断领域应用瓶颈

卷积神经网络凭借自主空间特征挖掘优势, 现已广泛应用于电力电子装备故障检测领域。但现有 CNN 架构普遍采用固定尺寸卷积核, 缺少对关键特征通道的权重优化策略, 针对早期故障引发的细微信号畸变识别灵敏度不足; 同时深度学习模型训练依赖海量标注样本, 与矿山设备故障样本采集难度大、小样本稀缺的实际工况形成矛盾, 限制了深度学习在矿用装备早期故障诊断中的规模化落地。

1.3. 本文研究内容与章节架构

针对矿用充电机功率模块早期故障识别现存短板, 本文融合信号预处理增强、深度特征提取与优化型机器学习分类思路构建智能诊断框架, 具体研究内容如下:

(1) 故障机理剖析与仿真建模: 系统解析多相交错并联 BUCK 拓扑下 IGBT 器件由正常工作至性能早期劣变的演化规律, 搭建高精度电路仿真模型, 为故障样本生成与算法性能验证提供数据来源。

(2) 微弱故障信号预处理研究: 引入改进变分模态分解算法, 联合排列熵判据完成原始信号自适应分解与有效分量重构, 实现噪声抑制与微弱故障特征增强。

(3) 多算法融合诊断模型构建: 搭建集成 SE 注意力模块的多尺度卷积神经网络完成多层次故障特征提取, 引入粒子群算法优化 SVM 超参数, 改善小样本场景下故障分类精度与模型稳定性。

(4) 多场景仿真验证与性能量化分析: 在变负载、多强度噪声等仿真工况下, 从故障识别准确率、抗干扰能力、实时运算效率三个维度量化评估所提融合模型综合性能。

本文架构按以下内容展开, 第一章梳理课题研究背景、研究价值与国内外研究进展; 第二章完成充电机主回路建模与功率器件早期故障机理分析; 第三章详细阐述 IVMD-MS-CNN-Attention-PSO-SVM 融合诊断模型的理论原理与实现流程; 第四章依托仿真数据集完成多模型对比试验与结果分析; 第五章总结全文研究成果, 指明后续研究拓展方向。

2. 充电机功率模块故障建模与机理分析

2.1. 矿用充电机主电路拓扑结构

大功率矿用充电机普遍选用多相交错并联 BUCK 拓扑架构, 该拓扑通过多路功率支路错相驱动运行,

能够有效缩减输出侧电流纹波幅值、减小滤波电感体积, 同时提升系统冗余容错能力, 适配井下安装空间受限、电磁兼容要求严苛的应用环境。

2.1.1. 拓扑工作原理

以三相交错并联 BUCK 电路为例, 每一相功率支路由 IGBT 开关器件、续流二极管与储能电感构成, 三路驱动脉冲相位依次错开 120° 。当开关管导通阶段, 输入直流电压向储能电感充电并为后端负载供电; 开关关断期间, 电感储存能量经由续流二极管形成续流回路, 维持负载持续供电。

2.1.2. 状态空间数学建模

在电感连续导通(CCM)工作模式下, 依托基尔霍夫电路定律建立系统平均状态空间模型, 选取各支路电感电流、输出滤波电容端电压作为状态变量, 系统状态方程见式(1):

$$\begin{cases} L_n \frac{di_{Ln}}{dt} = d_n V_{in} - v_o \\ C_o \frac{dv_o}{dt} = \sum_{n=1}^3 i_{Ln} - \frac{v_o}{R_L} \end{cases} \quad (1)$$

式中: d_n 为第 n 相开关占空比; R_L 为负载等效电阻。该模型量化表征理想工况下系统电气参数耦合规律, 是后续故障特征机理分析的理论基础。

2.2. IGBT 功率模块早期故障演化机理

IGBT 器件失效是由封装老化、半导体参数渐进漂移引发的连续性劣变过程, 早期故障集中体现为器件封装与内部电学参数的小幅偏移, 主要分为键合线疲劳劣变与芯片本体老化两类故障形式。

2.2.1. 键合线疲劳诱发栅极参数偏移

在周期性温度循环带来的交变热应力作用下, IGBT 内部铝质键合线根部易萌生微裂纹, 故障早期直观表现为栅极等效接触电阻小幅上升。栅极电阻增大会改变栅极输入电容充放电时间常数, 造成器件开通、关断延时与电压升降沿时间延长; 反映在外部电流波形上, 体现为开关瞬态变化速率下降、波形出现微秒级相位偏移。

2.2.2. 芯片老化导致饱和压降漂移

长期过载电流冲击会造成芯片内部载流子迁移性能衰减, 直观表现为 IGBT 集射极饱和压降 $V_{ce(sat)}$ 抬升。依据导通损耗计算公式 $P_{loss} = V_{ce(sat)} \cdot I_c \cdot d$, 饱和压降增大将持续提升器件导通功耗, 加剧芯片局部温升并形成温升-损耗恶化正反馈; 映射至电感输出电流中, 表现为稳态电流纹波直流分量下移、高频谐波成分出现规律性畸变。

2.3. 故障特征信号敏感性筛选

为实现早期故障精准捕获, 需从多路监测信号中筛选对器件参数漂移敏感度最高的特征量, 经机理分析确定三类有效监测信号:

- (1) 电感电流纹波信号: 作为功率变换过程的直接表征量, 电流信号包含开关基频及其倍频谐波分量, 器件早期劣变会破坏电流升降沿的对称特性, 是故障特征最主要载体;
- (2) 输出端电压畸变信号: 受输出滤波电容稳压作用影响, 电压故障特征幅值微弱, 但多相支路工作失衡会在输出电压中引入特定低频扰动分量;
- (3) 高频电磁辐射频谱: 器件开关瞬态特性变化将改变 MHz 频段电磁干扰频谱分布, 可作为辅助故障辨识依据。

2.4. 本章小结

本章完成矿用三相交错 BUCK 主电路数学建模, 确定设备正常工况电气基准参数; 从键合线老化、芯片性能退化两个维度剖析 IGBT 早期故障演化机理, 厘清器件内部参数劣变与外部电气波形畸变的对应关系。分析结果证实电感电流细微波动是提取早期故障信息的最优观测载体, 为下一章故障特征提取算法的设计提供物理理论支撑。

3. 早期故障识别方法研究

针对矿用场景下早期故障特征幅值微弱、易被环境噪声淹没的技术难题, 本章搭建由信号预处理增强、多尺度注意力特征提取、优化 SVM 分类三层架构组成的 IVMD-MS-CNN-Attention-PSO-SVM 融合诊断模型, 遵循“噪声抑制-特征挖掘-智能分类”层级化思路实现亚健康状态高精度识别。

3.1. 整体诊断框架设计

(1) 信号预处理增强层: 依托 IVMD 算法完成原始电感电流非平稳分解, 结合排列熵筛选有效模态分量重构降噪信号, 剥离随机噪声干扰、放大隐性故障特征;

(2) 深度特征映射层: 采用多分支并行卷积结构搭建 MS-CNN 网络, 搭配 SE 注意力模块自适应分配特征通道权重, 强化故障敏感特征表达效果;

(3) 智能分类决策层: 将卷积网络输出高维特征输入 SVM 分类器, 通过 PSO 算法优化惩罚系数与核参数, 提升小样本数据集下故障分类准确率与模型鲁棒性。

3.2. 基于 IVMD 的微弱故障信号增强算法

3.2.1. VMD 变分模型求解原理

变分模态分解通过迭代寻优求解受限变分方程, 引入二次惩罚因子 α 与拉格朗日乘子 $\lambda(t)$ 构造无约束增广拉格朗日函数见式(2):

$$\begin{aligned} \mathcal{L}(u_k, \omega_k, \lambda) = & \alpha \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \\ & + \left\| f(t) - \sum_{k=1}^K u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_{k=1}^K u_k(t) \right\rangle \end{aligned} \quad (2)$$

借助交替方向乘子法(ADMM)迭代更新模态分量 u_k 、中心频率 ω_k 与乘子 λ , 把原始时序信号拆分为若干带宽受限、频率稀疏的固有模态分量。

3.2.2. 基于排列熵的分量自适应重构策略

排列熵用于量化时序序列复杂程度, 可区分噪声分量、基波分量与故障特征分量。针对单阶模态分量 u_k , 先开展相空间重构, 统计重构向量排序模式的概率分布, 归一化排列熵计算公式见式(3):

$$H_e = -\frac{1}{\ln(m!)} \sum_{j=1}^{m!} P_j \ln P_j \quad (3)$$

结合对大量矿用充电机实际运行数据进行统计分析和故障机理研究, 本文设定了排列熵筛选阈值。当排列熵值低于阈值 T_1 时, 表明模态分量随机性强, 随机扰动占比过高, 判定为纯噪声分量予以剔除; 当排列熵值介于阈值 T_1 和 T_2 之间时, 表明分量以工频基波为主, 几乎不含故障信息, 亦予以剔除; 仅保留排列熵值高于阈值 T_2 的模态分量进行叠加重构, 以最大限度留存早期故障带来的瞬态波形畸变信息。其中, T_1 和 T_2 的取值通过对不同工况下(包括正常、不同程度故障及强噪声干扰)的电感电流信号进行

IVMD 分解并计算各模态分量的排列熵分布, 经多次实验验证确定, T_1 设定为 0.3, T_2 设定为 0.7, 该设置在保证有效降噪的同时, 能够有效保留微弱故障特征。

3.3. MS-CNN-Attention 深度特征提取网络

3.3.1. 多尺度并行卷积结构

MS-CNN 设置三条独立卷积分支, 各分支采用不同尺寸卷积核并行运算, 同步捕获信号全局变化趋势与局部瞬时脉冲特征, 兼顾长短期故障信息提取需求。第一分支采用小尺寸卷积核(卷积核大小为 3, 步长为 1), 主要用于捕获信号的局部瞬态特征; 第二分支采用中等尺寸卷积核(卷积核大小为 5, 步长为 1), 用于捕获中等尺度的时域特征; 第三分支采用大尺寸卷积核(卷积核大小为 7, 步长为 1), 用于捕获信号的全局趋势特征。所有卷积层均采用 ReLU 激活函数, 并在卷积后接批量归一化层和最大池化层(池化核大小为 2, 步长为 2)以降低维度并增强特征的鲁棒性。各分支的通道数根据网络深度和计算资源进行设定, 分别设置为 32、64、128。通过这种多尺度并行结构, 网络能够从不同感受野捕捉信号特征, 有效提升对微弱故障信号的敏感性。

3.3.2. SE 注意力机制原理

SE 模块依靠建模通道间依赖关系实现特征权重自适应调节, 划分为压缩(Squeeze)与激励(Excitation)两步运算: 压缩环节利用全局平均池化将各通道二维特征图压缩为一维全局表征向量; 激励环节依托双层全连接网络搭配 Sigmoid 激活函数学习各通道权重系数; 最终使用权重系数对原始特征加权, 抑制无效冗余特征、放大高贡献故障通道特征。

3.4. PSO 优化 SVM 分类模型

3.4.1. SVM 分类基本原理

支持向量机基于统计学习最小化结构风险准则, 以最优分类超平面最大化异类样本间隔为优化目标; 针对非线性不可分样本, 借助核映射将低维样本映射至高维特征空间实现线性分类, 其对偶优化目标函数如式(4):

$$\min_{\alpha} \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N y_i y_j \alpha_i \alpha_j K(x_i, x_j) - \sum_{i=1}^N \alpha_i \quad (4)$$

式中 $K(x_i, x_j)$ 代表核映射函数, α_i 为拉格朗日对偶乘子。

3.4.2. PSO 超参数寻优流程

SVM 分类精度受惩罚因子 C 与径向基核参数 g 影响显著, 本文选用粒子群优化算法实现双参数全局最优搜索, 粒子更新公式为式(5)、(6):

$$v_{id}^{t+1} = wv_{id}^t + c_1 r_1 (p_{id}^t - x_{id}^t) + c_2 r_2 (g_{id}^t - x_{id}^t) \quad (5)$$

$$x_{id}^{t+1} = x_{id}^t + v_{id}^{t+1} \quad (6)$$

式中: w 为惯性权重; c_1 、 c_2 代表学习系数; r_1 、 r_2 为 $[0,1]$ 区间随机系数。在本文中, 粒子群算法的关键超参数设定如下: 种群规模 M 设置为 50, 最大迭代次数为 100。惯性权重 w 从 0.9 线性递减至 0.4, 学习系数 c_1 和 c_2 均设置为 2。上述参数经过多次实验验证, 能够在保证收敛速度的同时, 有效避免陷入局部最优。

(1) 种群初始化: 随机生成 M 组粒子, 单个粒子向量对应一组 (C, g) 参数组合。其中, C 的搜索范围为 $[0.1, 100]$, g 的搜索范围为 $[0.01, 10]$;

(2) 适应度评价: 采用 10 折交叉验证分类准确率作为粒子适应度评价指标;

- (3) 迭代更新：依托个体最优 p_{best} 与全局最优 g_{best} 迭代更新粒子速度与位置；
- (4) 迭代终止：达到预设最大迭代步数或适应度连续多轮收敛时停止寻优，输出最优超参数。

3.5. 本章小结

本章逐层阐明 IVMD 降噪预处理、多尺度注意力卷积特征提取、PSO-SVM 智能分类的算法原理与实现细节。模型从原始信号降噪、深层特征筛选、小样本优化分类三个层级协同优化，有效破解早期微弱故障识别难、噪声干扰严重、小样本泛化差三类痛点，为后续仿真试验提供完整算法理论支撑。

4. 仿真实验与结果分析

依托 MATLAB/Simulink 搭建 150kW 矿用隔爆充电机仿真平台，通过修改 IGBT 器件内部参数模拟四类早期劣变工况，构建标准化故障数据集，通过多模型对照试验量化验证本文融合算法的综合诊断性能。

4.1. 仿真平台参数配置

仿真原型为三相交错并联 BUCK 型 150 kW 矿用充电机，仿真计算步长 1×10^{-7} s，信号采样频率 100 kHz，系统关键参数如表 1 所示。

Table 1. Key parameters of the mining charger simulation system
表 1. 充电机仿真系统关键参数

参数名称	符号	取值	单位
直流输入电压	V_{in}	660	V
额定输出电压	V_o	400	V
额定输出功率	P_n	150	kW
滤波电感	L	1.5	mH
输出滤波电容	C	2200	μ F
开关工作频率	f_s	4.5	kHz

4.2. 故障工况设置与数据集构建

通过微调 IGBT 器件内部电学参数复现早期老化故障，共设置 1 组正常工况与 3 类典型早期故障工况，每种工况采集 500 组电感电流样本，全样本集合计 2000 组；按照 7:3 比例随机划分训练集与测试集，故障工况设置细则：

- S0：标准正常工况，IGBT 所有参数保持出厂标称值；
- S1：键合线疲劳故障，栅极等效电阻提升至额定值 1.5 倍；
- S2：芯片老化故障，饱和压降 $V_{ce(sat)}$ 相较标称值抬升 0.5 V；
- S3：驱动回路元器件老化，驱动控制电压幅值下降 10%。

正常与故障工况下电感电流波形畸变程度极小，时域波形肉眼难以区分，对应波形见图 1。

4.3. IVMD 信号重构降噪效果分析

向原始采集电流叠加随机高斯噪声后开展 IVMD 分解与排列熵分量筛选重构，试验数据显示，经算法预处理后信号平均信噪比提升 13.2 dB，有效滤除矿井环境随机干扰，突出故障诱发的细微波形畸变，为后续卷积网络特征提取提供高质量输入数据。




Figure 1. Inductor current comparison between normal and fault conditions

图 1. 正常与故障工况电感电流对比

4.4. 故障识别性能对比试验

4.4.1. 混淆矩阵结果分析




Figure 2. Confusion matrix of the model test set

图 2. 模型测试集混淆矩阵

测试集混淆矩阵结果如图 2 所示，本文 IVMD-MS-CNN-Attention-PSO-SVM 融合模型对四类工况单类识别精度均高于 98%，整体平均诊断准确率达到 98.8%，各类故障错样本数量极少，模型类别区分能力优异。

4.4.2. 多算法横向对比

选取 BP 神经网络、基础 SVM、单一 CNN、传统 CNN-SVM 四种经典诊断算法作为对照组，从分类准确率、模型训练耗时、单样本推理时延三项指标开展对比，测试结果如表 2。

Table 2. Performance comparison of different fault diagnosis algorithms

表 2. 不同诊断算法性能指标对比

诊断模型	平均识别精度/%	训练耗时/s	单次推理耗时/ms
BP 神经网络	85.2	12.5	1.2
基础 SVM	88.6	8.4	0.8
单一 CNN	93.5	145.2	5.6
本文融合模型	98.8	168.5	6.2

对比结果表明：本文融合方案故障识别精度显著优于其余对比算法；尽管模型整体训练周期更长，但单样本推理时延仅 6.2 ms，完全满足矿用设备在线实时监测的运算时效要求。

4.5. 模型抗噪声鲁棒性验证

模拟井下电网电磁干扰环境，在待测信号中逐级叠加不同信噪比高斯白噪声，测试模型抗干扰性能，结果见图 3。当输入信号信噪比降至 15 dB 时，标准 CNN 模型诊断精度下滑 12.4%，本文融合模型精度仅下降 3.1%。得益于 IVMD 前置降噪与注意力机制自适应抑制无效噪声特征，所提算法在恶劣噪声环境下稳定性优势突出。




Figure 3. Recognition accuracy curves of various models under different SNRs

图 3. 不同信噪比下各模型识别准确率变化曲线

4.6. 本章小结

本章依托仿真数据集完成多维度性能测试, 试验结果证实: 经 IVMD 预处理可显著优化输入信号信噪比; 多尺度注意力网络可高效挖掘微弱故障特征; PSO 优化 SVM 可适配小样本分类场景。融合模型在识别精度、抗干扰能力、实时运算性能上综合表现最优, 可为矿用充电机智能运维提供可靠技术方案。

5. 结论与展望

5.1. 全文研究总结

围绕矿用充电机 IGBT 功率模块早期故障检测灵敏度不足、噪声干扰严重、小样本识别困难等工程难题, 本文构建 IVMD-MS-CNN-Attention-PSO-SVM 多级融合智能诊断模型, 结合机理推导、算法设计与仿真验证得到如下结论:

- 1) 信号降噪优化效果显著: 改进变分模态分解结合排列熵分量筛选策略可实现故障分量与噪声分离, 重构后信号信噪比整体提升约 13 dB, 实现微弱故障特征前置增强;
- 2) 特征提取性能优化: 多尺度卷积搭配 SE 注意力机制能够同步捕获电流时域全局趋势与局部瞬态畸变, 相较传统单尺度卷积网络, 故障敏感特征提取效率大幅提升;
- 3) 小样本分类性能突出: PSO 全局寻优 SVM 超参数有效改善小样本下分类边界拟合效果, 模型四类故障平均识别准确率 98.8%, 恶劣噪声工况鲁棒性优异;
- 4) 工程实时性达标: 模型单次样本推理耗时满足井下设备在线监测实时性规范, 具备现场落地应用潜力。

5.2. 现存不足与后续研究方向

本文算法在仿真数据集上取得优良诊断效果, 但受试验条件约束仍存在优化空间, 后续可从四方面深化研究:

- 1) 实物平台落地验证: 当前全部试验基于仿真数据完成, 后续搭建实体矿用充电机试验台, 在高温、高湿、电网畸变等真实井下工况下开展长期老化试验, 验证模型实物应用可靠性;
- 2) 模型轻量化改造: 采用网络剪枝、参数量化等轻量化压缩技术精简 MS-CNN 网络结构, 在保障诊断精度前提下降低模型算力开销, 适配矿用本安型控制器有限硬件资源;
- 3) 迁移学习跨机型适配: 引入迁移学习、元学习算法优化模型泛化能力, 打破模型对固定功率等级充电机的依赖, 实现多型号、多功率设备通用故障诊断;
- 4) 融合数字孪生技术: 将所提故障诊断算法与装备数字孪生体系结合, 依托设备全生命周期虚拟映射实现由故障事后识别向剩余寿命预测、主动预防性运维升级。

参考文献

- [1] 周伟杰. 煤矿用充电机设备故障检测技术[J]. 装备制造技术, 2024(4): 165-168.
- [2] 鲁光祝, 向大为. IGBT 功率模块状态监测技术综述[J]. 电力电子, 2011, 9(2): 5-10.
- [3] 徐盛友. 功率模块 IGBT 状态监测及可靠性评估方法研究[D]: [博士学位论文]. 重庆: 重庆大学, 2013.
- [4] 赵锐. 基于经验小波变换和 SVM 的电动汽车充电站变流器故障诊断研究[D]: [硕士学位论文]. 南京: 南京邮电大学, 2021.
- [5] 陈军. 基于 ISSA-BP 的 IGBT 老化状态预测方法研究[D]: [硕士学位论文]. 赣州: 江西理工大学, 2023.