

# 基于深度学习的电力设备故障诊断方法研究

殷超<sup>1</sup> 居尚<sup>2</sup> 施渊<sup>3</sup>

1. 中国能源建设集团江苏省电力设计院有限公司 江苏南京 210000;

2. 扬州浩辰电力设计有限公司 江苏扬州 225000;

3. 国网江苏省电力有限公司南通供电分公司 江苏南通 226001

DOI: 10.12238/ems.v7i3.12257

**[摘要]** 电力设备故障诊断是保障电力系统稳定运行的重要环节。随着深度学习技术的快速发展,将深度学习应用于电力设备故障诊断领域显示出巨大潜力,通过采集电力设备运行数据,利用卷积神经网络、循环神经网络等深度学习模型对设备状态进行实时监测和故障预警。研究表明深度学习模型能够有效提取电力设备运行特征,准确识别设备异常状态,相比传统诊断方法具有更高的准确率和鲁棒性,基于深度学习的故障诊断方法克服了传统方法对专家经验依赖性强的缺点,可实现电力设备故障的智能诊断和预测性维护,为电力系统的智能化运维提供有力支撑。

**[关键词]** 深度学习; 故障诊断; 特征提取; 预测性维护

电力设备是电力系统的重要组成部分,其运行状态直接关系到整个电力系统的安全稳定运行,传统的电力设备故障诊断方法主要依靠人工经验判断,存在诊断效率低、准确性不足等问题。近年来深度学习技术在图像识别、语音处理等领域取得重大突破,为电力设备故障诊断提供了新思路,深度学习模型具有强大的特征学习能力,可以自动从海量数据中提取深层特征,实现故障模式的精确识别。结合电力设备运行数据和深度学习算法,构建智能化故障诊断模型,能够有效提高诊断准确率和实时性,基于深度学习的故障诊断方法正成为电力设备状态监测和故障预警的重要研究方向,对提升电力系统运行可靠性具有重要意义。

## 1 深度学习在电力设备故障诊断中的应用现状

深度学习技术在电力设备故障诊断领域展现出强大潜力,目前已在变压器、断路器、电机等关键设备的故障检测中取得显著成果。变压器故障诊断方面,通过采集油色谱数据、局部放电数据等多源信息,采用深度卷积神经网络对故障特征进行深度挖掘,实现了绝缘老化、过热等典型故障的准确识别,在断路器故障诊断中基于深度学习的时序分析方法可精确捕捉机构动作特征,有效判断机械卡涩、绝缘失效等故障。电机故障诊断领域,结合振动信号和电流信号,使用循环神经网络对轴承损伤、定子绕组故障进行分析,显著提升了诊断准确率,输电线路故障诊断中,深度学习模型能够通过分析图像数据识别线路覆冰、导线断股等问题,深度学习还在配电设备监测、电缆故障定位等方面展开广泛应用。与传统故障诊断方法相比,深度学习方法具有自适应性强、诊断精度高、实时性好等优点,为电力设备状态评估提供了新思路,目前深度学习在电力设备故障诊断中的应用已从实验室研究逐步走向工程实践,但在模型泛化能力、计算效率、数据质量等方面仍需进一步提升和优化<sup>[1]</sup>。

## 2 深度学习故障诊断方法设计与实现

### 2.1 数据采集与预处理技术

电力设备故障诊断的数据采集主要围绕温度、振动、电流、电压等多维度进行,采用分布式传感器网络实时采集设备运行数据,通过高速数据采集卡将模拟信号转换为数字信号,在数据预处理阶段,首先进行降噪处理,采用小波变换方法消除随机干扰和工频干扰。对于采集到的异常数据和缺失数据,运用插值算法进行修正和填充,确保数据的连续性和可靠性,通过归一化处理将不同量纲的数据统一到相同尺度,有效避免量纲差异对模型训练的影响,为提高数据质量,设计数据清洗流程,剔除明显异常值和重复数据。针对数据不平衡问题,采用过采样和欠采样相结合的方式,平衡各类

故障样本数量,建立完整的数据标注体系,对故障类型进行精确标记,为后续模型训练提供高质量训练集,通过合理的数据分割策略将数据集划分为训练集、验证集和测试集,保证模型训练和评估的科学性。

### 2.2 深度学习模型构建

深度学习模型的构建需要根据电力设备故障特点和诊断需求进行针对性设计。模型采用多层神经网络结构,包含输入层、多个隐藏层和输出层,输入层节点数根据采集的特征维度确定,输出层对应不同故障类型,隐藏层采用卷积层和池化层交替设置的方式,逐层提取故障特征,其中卷积核大小和步长经过反复验证优化。为增强模型泛化能力,在网络中加入 dropout 层,有效防止过拟合现象,激活函数选择 ReLU 函数,避免梯度消失问题,加快模型收敛速度,损失函数采用交叉熵损失,优化器选用 Adam 算法,通过动态调整学习率提高训练效果。在模型训练过程中采用批量归一化技术,减少内部协变量偏移,提高训练稳定性,针对不同类型故障特征,设计多尺度特征提取模块,提升模型对复杂故障模式的识别能力,引入注意力机制,突出重要特征的权重,提高诊断准确率<sup>[2]</sup>。

### 2.3 特征提取与选择方法

特征提取环节采用多层次特征学习策略,从原始电力设备运行数据中提取时域特征、频域特征和时频特征。时域特征包含波形特征、统计特征和趋势特征,通过计算均值、标准差、峭度等统计量描述信号整体特性,频域特征通过傅里叶变换获取,重点关注频谱能量分布和谐波特征,时频特征则采用小波变换方法,实现信号的多分辨率分析。在特征选择阶段,结合相关性分析和主成分分析方法,去除冗余特征,筛选出对故障诊断贡献度高的特征集合,通过设置特征重要性阈值保留关键特征,降低数据维度,提高计算效率,建立特征评价指标体系,从可分性、稳定性和解释性等方面评估特征质量,确保所选特征能够有效反映设备故障状态。

### 2.4 故障模式识别算法

故障模式识别算法采用深度学习分类模型,通过多层非线性变换实现故障特征的自动识别,算法设计采用模块化结构,包含特征映射模块、分类决策模块和置信度评估模块。特征映射模块使用深度卷积网络提取高维特征,通过多层次特征融合增强特征表达能力,分类决策模块采用 softmax 分类器,输出各类故障的概率分布,置信度评估模块通过设置动态阈值,过滤低置信度预测结果,提高诊断可靠性。针对新型故障模式,设计增量学习机制,持续优化模型识别能力,算法还集成了故障定位功能,能够精确定位故障发生位置,

为维修人员提供精准指导, 考虑到实际应用场景, 优化算法计算复杂度, 确保诊断系统实时响应能力。

为提升算法的实用性和可靠性, 故障模式识别算法还设计了自适应特征学习机制和多模态信息融合策略, 自适应特征学习能够根据设备运行工况自动调整特征提取参数, 确保在不同工作状态下均能获得稳定的诊断效果。多模态信息融合策略整合了设备运行数据、历史维修记录和专家知识库信息, 构建完整的故障诊断知识体系, 算法通过建立故障演化模型, 分析故障发展趋势, 实现故障预警功能, 引入噪声抑制机制, 提高算法在复杂工业环境下的抗干扰能力。针对设备群组管理需求, 开发了协同诊断功能, 能够分析相关设备间的故障关联性, 提供系统级的故障诊断方案, 算法还具备诊断结果解释功能, 通过可视化技术直观展示故障特征和诊断依据提高诊断结果的可理解性和可信度<sup>[3]</sup>。

### 2.5 诊断结果分析与评估

诊断结果分析采用多维度评估体系, 从准确率、召回率、F1 值等方面全面评价诊断效果, 建立混淆矩阵, 详细分析各类故障的识别情况, 找出易混淆的故障类型, 有针对性地优化模型。通过 ROC 曲线分析模型在不同决策阈值下的性能表现确定最优工作点, 结合专家经验, 对诊断结果进行解释性分析, 验证诊断结果的合理性, 建立诊断结果可视化系统, 直观展示故障特征和诊断过程, 便于运维人员理解和使用。针对误诊断情况, 建立原因分析机制, 从数据质量、模型结构、参数设置等方面查找问题根源, 设计诊断结果反馈机制, 收集实际运行数据, 持续改进诊断模型, 通过建立长期评估机制跟踪模型诊断效果, 确保诊断系统持续稳定运行。

## 3 系统性能测试与优化

### 3.1 模型训练与验证

模型训练过程采用分阶段训练策略, 首先在大规模预训练数据集上进行初始化训练, 获取基础特征提取能力, 随后使用实际电力设备故障数据进行微调训练, 提升模型对特定故障类型的识别能力。训练过程中采用动态批量大小调整策略, 初期使用较小批量提高模型探索能力, 后期增大批量规模提升训练稳定性, 学习率采用余弦退火策略, 在训练初期较大学习率快速收敛, 后期降低学习率精细调整参数, 为防止过拟合, 实施早停策略, 当验证集损失连续多轮上升及时终止训练。引入交叉验证机制, 将数据集划分为多个子集进行轮换训练, 全面评估模型性能, 在验证阶段, 通过不同工况下的测试数据验证模型泛化能力, 包括设备负载变化、环境温度波动等多种情况, 针对验证中发现的问题, 及时调整模型结构和参数, 确保模型具有良好的适应性<sup>[4]</sup>。

### 3.2 诊断准确率分析

诊断准确率分析采用分层评估方法, 分别针对不同类型故障、不同故障程度和不同运行工况进行准确率统计。通过构建精确的评估指标体系, 包括单故障识别准确率、多故障并发识别准确率和故障程度评估准确率, 针对重点设备和关键部件, 进行重点准确率分析, 确保诊断可靠性, 建立故障样本库, 收集典型故障案例, 定期进行模型诊断能力测试, 通过对比分析不同时间段的诊断准确率变化评估模型性能稳定性。针对诊断准确率较低的故障类型, 深入分析原因, 可能是由于样本数量不足、特征提取不充分或模型结构不合理导致, 通过增加相应类型的训练样本、优化特征提取方法、调整模型结构等手段, 有针对性地提升诊断准确率, 建立准确率预警机制, 当准确率低于设定阈值时及时报警, 确保诊断系统可靠运行。

### 3.3 系统实时性能评估

实时性能评估重点关注系统响应速度、资源占用率和并

发处理能力三个方面, 通过设置不同规模的数据流测试系统在高负载情况下的处理能力, 记录数据采集、特征提取、故障诊断各环节的时间开销。采用分布式测试方案, 模拟多个测点同时采集数据的场景, 评估系统并行处理性能, 针对采样频率、数据传输速率、诊断周期等关键参数进行优化测试, 确定最佳工作参数, 建立性能监控平台, 实时记录 CPU 使用率、内存占用、网络带宽等系统资源指标, 分析系统运行瓶颈。通过压力测试评估系统在极端条件下的稳定性, 包括突发数据量增加、网络延迟波动等异常情况, 评估系统诊断结果的实时推送能力, 确保故障警报能够及时触达相关人员, 建立性能评估报告机制, 定期总结系统运行状况, 为后续优化提供依据<sup>[5]</sup>。

### 3.4 算法优化与改进

算法优化工作围绕计算效率提升和诊断性能改进两个方向展开, 在计算效率方面, 通过模型压缩和量化技术降低模型参数规模减少存储空间和计算开销, 采用模型剪枝方法, 去除对诊断结果贡献度低的网络连接, 简化模型结构。引入知识蒸馏技术, 将复杂模型的诊断能力迁移到轻量级模型中, 实现模型加速, 在诊断性能方面, 设计动态特征选择机制, 根据设备运行状态自适应调整特征提取策略, 优化损失函数设计, 增加对难分类样本的惩罚权重, 提高模型对复杂故障的识别能力。引入迁移学习方法, 利用相似设备的诊断经验, 提升新设备故障诊断效果, 通过集成多个子模型的诊断结果提高系统整体诊断可靠性, 建立算法版本管理机制, 记录各版本优化效果, 确保算法持续改进的可追溯性。

## 4 结语

深度学习技术为电力设备故障诊断带来新的发展机遇, 通过构建深度学习模型实现了电力设备运行状态的智能监测和故障预警。研究表明, 基于深度学习的故障诊断方法在特征提取、模式识别和预测性维护等方面具有显著优势, 可有效提高诊断准确率和工作效率, 未来随着深度学习算法的不断优化和计算硬件的升级, 智能化诊断技术将在电力设备状态监测中发挥更大作用, 深度学习与电力设备故障诊断的深度融合, 将推动电力系统向着更智能、更可靠的方向发展。

### [参考文献]

- [1] 宋文强, 沈登海. 基于深度极限学习机的燃气轮机气路故障诊断技术研究[J]. 北京化工大学学报(自然科学版), 2024, 51(04): 89-98.
  - [2] 葛卓, 夏华猛, 王凯亮, 等. 基于多域信息融合的深度学习轴承故障诊断方法[J]. 振动与冲击, 2024, 43(23): 47-55.
  - [3] 雷云鹏, 韩东, 涂鹏飞, 等. 基于深度学习的道岔转辙机故障诊断技术研究综述[J]. 城市轨道交通研究, 2024, 27(12): 345-350.
  - [4] 陈滨斐, 章黄勇, 马宏忠, 等. 基于深度学习的电力设备故障诊断方法研究综述[J]. 电气自动化, 2022, 44(01): 1-2+6.
  - [5] 代泽荟, 经权, 孟颖, 等. 基于多维信息融合的电力变压器故障诊断方法研究[J]. 电测与仪表, 2024, 61(10): 67-73.
- 作者简介: 殷超(1990.01-), 男, 汉族, 江苏泰州人, 硕士, 中级工程师, 研究方向: 电力系统及其自动化;  
居尚(1988.11-), 男, 汉族, 江苏高邮人, 本科, 中级工程师, 研究方向: 220千伏及以下变电站电气一次设计;  
施渊(1983.11-), 男, 汉族, 江苏南通人, 本科, 高级工程师, 研究方向: 电网建设。