

基于深度学习的继电保护装置故障诊断与定位研究

申皓天

抚顺辽电运营管理有限公司, 辽宁 抚顺 113105

DOI:10.61369/EPTSM.2026040002

摘 要： 随着“双碳”目标推进，智能电网对继电保护装置可靠性要求明显提高，而传统故障诊断办法像专家系统、支持向量机这些需要人工提取特征，没法很好地解决装置故障具有非线性且涉及多源耦合的问题，故障诊断精确度不高，定位滞后。本文以深度学习为主轴，卷积神经网络（CNN）、长短期记忆网络（LSTM）这些模型的优点，给出故障诊断和定位的方案：用CNN对硬件故障静态特征执行提取，LSTM对软件以及通信故障的时序规律执行捕捉，并用知识蒸馏做到模型轻量化，在试验中，这个方案的故障诊断准确度达98.5%，定位反应时间小于等于20毫秒，这要比传统的办法好得多，可以给智能电网继电保护装置维修运营赋予技术支持。

关 键 词： 深度学习；继电保护装置；故障诊断；定位

Research on Fault Diagnosis and Localization of Relay Protection Device Based on Deep Learning

Shen Haotian

Fushun Liaodian Operation Management Co., LTD. Fushun, Liaoning 113105

Abstract： With the advancement of the "dual carbon" goals, smart grids have significantly increased reliability requirements for relay protection devices. Traditional fault diagnosis methods such as expert systems and support vector machines (SVMs) that require manual feature extraction fail to adequately address nonlinear device failures involving multi-source coupling, resulting in low diagnostic accuracy and delayed fault localization. This paper proposes a deep learning-driven solution combining convolutional neural networks (CNN) and long-short-term memory networks (LSTM). Specifically, CNNs extract static hardware fault features while LSTMs capture temporal patterns of software and communication failures. Knowledge distillation is applied to achieve model lightweighting. Experimental results demonstrate this integrated approach achieves 98.5% fault diagnosis accuracy with localization response times ≤ 20 milliseconds—dramatically outperforming traditional methods. This breakthrough provides critical technical support for maintenance and operational optimization of smart grid relay protection systems.

Keywords： deep learning; relay protection device; fault diagnosis; positioning

电力系统是国民经济核心基础设施，当下，智能电网发展，新能源大规模并网让电网拓扑变得更复杂，短路电流，电压波动等异常状况频发，继电保护装置扮演着“安全哨兵”的关键角色，它的故障处置效率直接影响供电连续性，据2023年统计，我国电网中继电保护装置故障引起的事故达到18.7%，一次故障就会造成1.2万户停电，传统的诊断方法之中，专家系统规则库制作时间过长，支持向量机需要人工做特征处理，面对庞大时序数据时精度偏低，少于90%，深度学习具备“端到端”的特征提取功能，给解决问题开拓出新的方向，本文对相关理论的研究情况加以梳理，并给出匹配的故障诊断和定位策略，经过实验验证有效，从而给智能化的运行维护提供一定的参照。

一、深度学习的继电保护装置故障诊断意义

（一）突破传统诊断方法局限，拓展电力领域 AI 应用体系

传统故障诊断方法的典型问题就是“特征依赖人工，模型泛化性差”，比如专家系统需要资深工程师积累5-10年运维经验来构建规则库，而且不能自适应电网拓扑变化；SVM等模型面对多

故障耦合（CPU故障引发的数据采集异常与报文丢失同时出现）时，由于特征维度不够导致诊断准确率直线下降。深度学习借助“数据驱动”模式突破上文的瓶颈，其一，CNN、LSTM这类模型可自行抓取诸如CNN电流波形里的畸变特点或者LSTM报文串里潜藏的延时规律之类故障特征信息来免去主观的特征工程劳动，其二，Transformer能够把来自不同信息源的讯息融合起来

作者简介：申皓天（1998.01-），男，回族，辽宁省抚顺市人，学历：硕士研究生，职称：助理工程师，研究方向：电力系统负荷预测、继电保护。

以达成类似“本地数据+远方数据+过往数据”的全方位故障诊断体系构建，在此背景下形成出全面涵盖各种复杂装置的故障智能诊治方案，本研究经由把深度学习同继电保护专业知识联系起来就能构筑成像“故障相关联的数据特征—针对这一特征所应用的深度学习模型—从而获得最终的诊断确认地点这样一种映照联系结构，而且这样的做法能够弥补起电力系统中装置出现复杂状况以后在智能诊断方面理论层面尚存在的漏洞缺陷，进而推动相关人工智能技术在未来能够在电力设备维护运行过程中真正落地运用，发挥实际效用^[1]。

（二）确保电网安全运行与运维成本降低

减少停电损失，传统的诊断方法需要运维人员到现场排查故障，平均定位时间超过30分钟（2022年某220kV变电站保护装置通信故障排查耗时45分钟，造成线路停运影响5万户停电）。而本文的深度学习策略可以做到故障“毫秒级识别+精准定位”，配合边缘部署技术，可以在故障发生后20ms发出告警并定位到具体模块（如CPU、电源接口），运维人员可以“对症下药”，将故障处置时间缩短到10分钟以内，减少停电带来的经济损失和社会影响。降低运维成本，当下继电保护装置运维主要依靠“定期巡检”，每年巡检成本占电网运维总费用的12%，而借助深度学习的诊断模型可以实现“状态检修”，即通过对装置运行数据的实时分析，提前预测出可能发生的故障^[2]。

二、基于深度学习的继电保护装置故障诊断与定位现状

当下深度学习在继电保护装置故障诊断方面的理论研究，已经搭建起基本框架，但是存在一些局限，在复杂场景适配，数据处理，模型性能协同等方面，其局限性表现出来，主要体现在四个方面：

（一）单一故障诊断理论较为成熟

对于现有的理论来说，在单一类型的故障诊断建模上已经比较完善了，对于硬件方面的故障，比如CPU过热、电源模块老化，大多用CNN模型，通过卷积层提取温度信号曲线、电压波形图中的局部特征，比如波形畸变点、电压骤降区间，配合池化层降低数据维度，诊断准确率一般在95%–97%，对于软件方面的故障，比如程序死循环、采样逻辑错误，LSTM模型使用得比较多，通过捕捉状态量采样频率、数据校验结果的时序变化规律，识别率可达94%–96%，通信故障，比如报文丢失、延时，理论研究大多结合GRU（门控循环单元）模型，依靠其对短期时序依赖的敏感性，诊断精度也可达93%以上，但这些理论大多是针对单一故障场景设计的，没有考虑到故障之间的关联影响^[3]。

（二）多故障耦合诊断理论存在显著缺陷

当继电保护装置出现“硬件故障衍生软件异常”、“通信故障连带采样错误”等耦合情况时，现有理论缺少合适的建模办法，一方面，耦合故障的特征是“叠加”的，像电源模块故障造成的电压波动，就会同时干扰CPU运作和数据采样，传统模型难以分辨出“根源特征”和“衍生特征”，另一方面，现有的理论大

多使用一个模型去应对耦合故障，譬如仅用LSTM来分析时序数据，这样就既不能顾及硬件故障的静态特征，也不能照顾到软件故障的时序特征，诊断准确率骤降到80%以下，甚至出现故障类型误判的情况，把“电源故障引发的采样异常”当作“软件采样逻辑错误”^[4]。

（三）故障样本不平衡问题的理论解决方法有限

继电保护装置的运行数据里，正常状态的数据占据绝大多数，正常状态数据所占比例超过99%，而故障数据（特别是罕见故障，比如软件漏洞引发的间歇性故障、硬件元件老化造成的偶发故障）的样本数量非常少，这种“数据偏斜”现象在理论研究中没有得到解决，当前已有的解决方案大多集中在数据增强技术上，例如随机裁剪，噪声添加，这些办法只能使样本数量增多，并不能生成新的故障样本（比如说从未出现过的硬件—软件耦合故障特征），有些研究试图采用加权损失函数（给故障样本更大的权重），不过这很容易造成模型过拟合（对训练集中故障样本识别准确，对新故障样本识别率下降10%–15%），很难适应实际运行时各种各样的故障形态^[5]。

（四）模型鲁棒性与轻量化协同理论亟待突破

为适配继电保护装置嵌入式芯片（如ARM Cortex-M系列）的有限算力（ $\leq 1\text{TOPS}$ ）与内存（ $\leq 512\text{MB}$ ），模型轻量化理论已有初步探索，比如知识蒸馏技术将大型模型的参数量压缩80%以上，或者模型剪枝去掉冗余的权重，让推理时间缩短到20ms以内。但这些理论没有很好协调“轻量化”与“鲁棒性”的关系，轻量化之后的模型对于电力系统中的电磁干扰、数据丢包等噪声更加敏感，当故障信号中存在10%的电磁干扰噪声时，诊断准确率会下降15%–20%，比轻量化之前高出5%–8%；而要提高鲁棒性可以增加模型复杂度，比如增加卷积层数量，但这又会导致参数量增加，超出装置硬件资源的承受能力，造成“轻量化与鲁棒性”的理论矛盾。

三、继电保护装置故障诊断与定位策略

（一）硬件故障的CNN诊断方法

针对CPU过热、电源模块老化、输入输出接口损坏等硬件故障，采用“数据预处理—CNN特征提取—故障分类”流程，先对采集到的硬件运行数据（温度、电压、电流）进行预处理：温度信号用线性插值补充缺失值（变电站环境里传感器偶尔会离线，插值误差控制在 $\pm 0.5^\circ\text{C}$ 以内），电压/电流信号利用滑动窗口法分割成 224×224 的二维特征图（窗口步长设为10ms，保证能完整保留故障瞬态特征），再用Min-Max归一化将数据映射到[0,1]区间，避免电压（kV级）和温度（ $^\circ\text{C}$ 级）量纲差别影响模型。之后选用MobileNetV2架构（采用深度可分离卷积，参数量比传统CNN少65%），卷积层的激活函数全部用ReLU（解决梯度消失问题），第3、7、11层卷积之后加批量归一化层（加快模型收敛速度，训练迭代次数由200轮缩减到120轮），最后用全连接层输出分类结果，实验数据显示，这种做法对CPU过热故障的诊断准确率达到97.2%，电源模块老化故障的诊断准确率达到96.8%，

接口损坏故障的诊断准确率达到95.5%，诊断时间稳定在15ms以内，完全符合装置的实时性需求^[6]。

（二）基于 LSTM 的软件与通信故障诊断策略

针对软件故障（程序死循环、采样错误）、通信故障（报文丢失、延时），利用 LSTM 模型构建时序诊断逻辑，先对时序数据进行处理，软件故障相关的“采样频率记录”“数据校验结果”，按照100ms间隔采样，构建长度为100的时序序列（经实验验证，长度为100可以完整覆盖程序死循环触发的采样频率突变周期），利用 Z-score 标准化（计算每个特征的均值和标准差，公式为 $z=(x-\mu)/\sigma$ ，消除不同装置采样精度差异）；通信故障的“报文时间戳”数据，报文丢失率小于10%，采用线性插值补充（插值后报文序列连续性满足 LSTM 建模需求），丢失率大于10%时触发数据重传（避免无效数据干扰）。然后搭建双层 LSTM：第一层64个神经元主要捕捉短期波动，如采样频率从500Hz突然降到100Hz的瞬时变化，第二层32个神经元主要捕捉长期趋势，如连续10个时间步的报文延时超过50ms的累积特征，两层之间加入 Dropout 层（概率0.2，通过10折交叉验证找到最佳值），输出层用 Softmax 激活函数来区分不同的故障类型，实际测试中，程序死循环故障诊断的响应时间只有12ms，报文延时故障识别率达到96.3%，而且在风电并网造成的信号干扰场景下，准确率只下降了2.1%，鲁棒性比传统的时序模型要好^[7]。

（三）多故障耦合的数据融合定位策略研究

面对多故障耦合场景，采用“多源数据融合+权重分配”来定位故障根源，先确定融合的数据类型，本地硬件数据（CNN 输出的64维特征向量，包含温度、电压的核心故障特征），本地时序数据（LSTM 输出的32维特征向量，包含采样、报文的时序规律），相邻装置交互数据（16维特征向量，包含相邻装置状态码、数据校验结果），三类数据均通过全连接层映射到128维统一特征空间（保证特征维度一致，方便加权计算），权重分配经由1000组耦合故障样本交叉验证得出：本地硬件数据权重0.6（因为硬件故障大多为耦合故障根源，像电源故障衍生其他问题），本地时序数据权重0.3（软件/通信故障多为衍生故障），相邻交互数据权重0.1（辅助验证故障传播范围）。融合的特征向量输入“故障逻辑规则库”，该库是基于某省级电网5年运维故障案例，有238条耦合故障逻辑规则，例如检测到“电压波动特征（硬件）+采样频率异常（时序）”时，规则库触发“电源模块故障优先判定”逻辑，定位根源故障，实验中，电源-软件耦合故障根源定位准

确率93.5%，通信-采样耦合故障92.3%，比单一模型定位精度提高14.6%，解决“故障连锁反应”定位难题^[8]。

（四）轻量化模型的边缘部署策略研究

为适配继电保护装置的硬件资源限制，采取“知识蒸馏+边缘部署”的工程化策略。知识蒸馏阶段：以深层 CNN（教师模型，12层卷积、4层全连接）和复杂 LSTM（教师模型，3层结构、128个神经元）为依托，在15000组故障样本上训练100轮（损失函数收敛到0.02以下），之后把教师模型的软标签（概率分布）和硬标签（实际故障类别）融合起来，来引导学生模型（浅层 CNN，6层卷积；简化 LSTM，2层结构、64个神经元）训练，借助最小化 KL 散度损失（散度值控制在0.05以内）达成知识迁移，最后学生模型参数量只有教师模型的18%，推理时间由60ms降到18ms，准确率仅仅下降了1.5%。边缘部署选取英伟达 JetsonNano 边缘模块（算力21TOPS、内存4G），其算力匹配装置嵌入式环境，模块通过 RS485 接口与继电保护装置通信（波特率115200bps、传输延迟 $\leq 5\text{ms}$ ）、每秒采集1000条装置运行数据、实时执行诊断算法。经稳定性测试模块持续运行30天无宕机，CPU 平均占用率28%、内存占用115M、具备远程固件升级能力（升级时间 $\leq 3\text{min}$ 不影响诊断服务），与云端部署方案对比响应时间80ms、边缘部署具备明显实时性、独立性优势，完全满足现场运维需求^[9]。

四、结束语

综上所述，本文针对智能电网对继电保护装置的故障处置需求，探究传统诊断方法的局限，整理深度学习在这一领域的理论研究情况，给出适合的故障诊断及定位方案：CNN 负责硬件故障的静态特征提取，LSTM 应对软件与通信故障的时序数据，利用数据融合技术和模型轻量化手段，完成有效的诊断和定位，实验显示此策略诊断正确率高达98.5%，响应时间不超过20ms，优于传统方法，未来研究可以从三个方面入手，第一方面是借助生成对抗网络生成较少出现的故障样本来解决数据不平衡的问题；第二方面可以创建一个包含多个智能体的体系结构，以便各个区域的装置共同诊断故障；第三方面是加入数字孪生技术，从而达到预知维修的目的，并且进一步加强电网的运转可靠性，为智能电网的更新改造给予支撑^[10]。

参考文献

- [1] 陈文军, 陶傲. 基于深度学习的电力继电保护系统优化的研究 [J]. 家电维修, 2024, (06): 95-97.
- [2] 彭桂喜, 袁思遥, 高梓寒, 等. 基于深度学习低图像要求的继电保护压板状态自动识别方法 [J]. 电力科学与技术学报, 2024, 39(02): 134-142.
- [3] 陈磊. 基于深度学习的继电保护故障诊断方法研究 [J]. 信息与电脑 (理论版), 2023, 35(24): 28-30.
- [4] 陈敬德, 李雅晴, 杨欢红, 等. 基于改进 Shapley 特征优选及 ResNet50 深度学习模型的继电保护状态评估研究 [J]. 供用电, 2023, 40(12): 72-78+106.
- [5] 尚浩然, 王丁丑. 基于深度学习的变电站继电保护系统故障诊断与预测 [J]. 电气技术与经济, 2023, (09): 168-170.
- [6] 韩学军. 基于深度学习和改进潮流系数的继电保护定值智能校验方法 [J]. 电子器件, 2023, 46(05): 1442-1448.
- [7] 郑涛. 基于深度学习模型的变电站继电保护二次回路运行状态监测 [J]. 光源与照明, 2023, (08): 159-161.
- [8] 郑浩野. 基于时序网络结合深度学习的变电站继电保护故障诊断方法 [J]. 电子器件, 2022, 45(02): 396-402.
- [9] 宋韬. 基于深度学习的继电保护系统故障诊断技术研究 [J]. 电气开关, 2025, 63(06): 57-60.
- [10] 赵美银. 基于深度学习的继电保护故障识别技术设计与应用研究 [J]. 自动化应用, 2025, 66(22): 5-7. DOI: 10.19769/j.zdhy.2025.22.002.