

# 基于深度学习的电力系统继电保护故障识别与定位方法研究

宋泽炜 詹兆东

国网宁夏电力有限公司超高压公司 宁夏银川 750011

**摘要:** 电力系统安全稳定运行是能源供给核心, 继电保护故障识别与定位的准确性、时效性影响系统故障损失。传统方法依赖人工经验与固定阈值, 难适应新能源高渗透等复杂场景。深度学习凭借特征提取与模式识别能力, 为故障识别与定位提供新路径。本文综述其研究进展, 从原理、优化策略、应用逻辑及挑战等方面论述, 为继电保护智能化升级提供参考, 助力构建可靠故障处理体系。

**关键词:** 深度学习; 电力系统; 继电保护; 故障识别

## 引言

电力系统作为国民经济“能源动脉”, 其安全稳定运行至关重要, 但新能源大规模并网等使其拓扑复杂、故障模式多类型演化, 对继电保护要求更高; 继电保护核心是识别、定位并隔离故障, 传统方法基于电路理论, 存在故障特征提取依赖人工经验、对干扰因素适应性差、定位精度不高等局限性; 深度学习作为人工智能核心技术, 能自适应提取深层抽象特征, 完成复杂模式识别任务, 应用于继电保护可解决传统方法瓶颈; 本文基于相关成果, 阐述深度学习在继电保护故障识别与定位中的应用机制, 分析模型优化策略, 探讨关键问题与发展趋势, 为智能化发展提供支撑与参考<sup>[1]</sup>。

## 1 深度学习技术与电力系统适配性

### 1.1 深度学习技术框架

深度学习通过多层非线性变换自适应提取数据特征, 以神经网络为核心, 涵盖卷积神经网络(CNN)、循环神经网络(RNN)、长短期记忆网络(LSTM)、门控循环单元(GRU)、Transformer及深度置信网络(DBN)等。CNN擅长提取空间局部特征, 适用于处理网格结构数据; RNN建模时序依赖关系, 但有梯度问题; LSTM与GRU通过引入门结构, 解决了RNN的缺陷, 适用于长时序序列; Transformer基于自注意力机制, 并行处理并捕捉全局依赖; DBN通过堆叠限制玻尔兹曼机, 逐层提取深层特征, 适用于小样本建模<sup>[2]</sup>。

### 1.2 与电力系统继电保护的适配性

继电保护依赖故障暂态电气量, 如三相电压、电流等时序数据, 具有时序性强、特征隐含、干扰多等特点。深度学习与其适配性体现在: 其一, 自适应特征提取能力摆脱人

工依赖, 提升识别精度; 其二, 时序建模能力精准捕捉动态变化, 适应故障时序特性; 其三, 强抗干扰能力抑制电网波动影响, 提高鲁棒性; 其四, 并行计算能力满足实时性要求, 支撑快速故障隔离。

## 2 深度学习在继电保护故障识别中的应用与优化

### 2.1 故障识别任务与数据预处理

继电保护故障识别包括故障有无判断、类型分类、相别判断及严重程度评估。高质量数据预处理是前提, 涵盖数据采集、清洗、归一化与特征工程。采集环节通过故障录波装置等获取1kHz~10kHz频率的电气量数据; 清洗环节去除异常值、缺失值与噪声, 常用插值法、平滑滤波等; 归一化环节消除量纲差异; 特征工程环节构建时域、频域及时频域特征, 为模型训练提供有效输入<sup>[3]</sup>。

### 2.2 主流深度学习模型在故障识别中的应用

#### 2.2.1 卷积神经网络(CNN)及其变体

CNN及变体(如LeNet、AlexNet、ResNet)用于提取故障数据局部时空特征。将故障时序数据转为二维矩阵后, 通过卷积层、池化层提取局部特征, 再经全连接层分类。针对电力系统数据时序特性, 可用1D-CNN直接处理时序数据, 避免信息损失, 简化模型并提升效率。CNN在单一故障识别中准确率高, 但对多类型复合故障识别能力需提升。

#### 2.2.2 循环神经网络(RNN)及其变体

LSTM、GRU等RNN变体常用于处理长时序故障数据。故障暂态电气量数据有时序依赖关系, LSTM通过门控机制精准捕捉动态特征; GRU简化门控结构, 提升计算速度。这类模型适用于故障类型随时间演化的场景, 但处理高维数

据时计算复杂度高。

### 2.2.3 混合深度学习模型

为发挥不同模型优势,提出多种混合模型,如 CNN-LSTM、CNN-GRU、DBN-LSTM 等。CNN-LSTM 模型通过 CNN 提取局部空间特征,再由 LSTM 捕捉时序依赖关系,实现时空特征联合建模;DBN-LSTM 模型通过 DBN 预训练提取深层特征,再由 LSTM 进行时序建模与分类,提升对小样本数据的适应能力。混合模型在多类型、复合故障识别中性能更优。

## 2.3 故障识别模型的优化策略

### 2.3.1 数据增强技术

电力系统故障数据样本不均衡、获取成本高,易导致模型过拟合。数据增强技术通过变换现有数据生成新样本,扩大训练集规模,改善样本不均衡问题。常用方法包括时间轴拉伸/压缩、添加噪声、数据翻转、时序平移等,可提升模型泛化能力与鲁棒性。

### 2.3.2 模型结构优化

模型结构优化包括调整网络层数、优化卷积核大小与数量、选择激活函数及应用正则化技术等。网络层数需适中,避免特征提取不充分或过拟合;卷积核大小与数量需根据数据特征尺度优化;激活函数可选 ReLU 等改善非线性表达能力;正则化技术可抑制过拟合,提高泛化能力。

### 2.3.3 超参数优化

超参数(如学习率、batch size、迭代次数)影响模型训练效果。学习率需适中,避免训练震荡或陷入局部最优解;batch size 需平衡训练效率与稳定性;迭代次数需避免训练不足或过拟合。常用优化方法包括网格搜索、随机搜索、贝叶斯优化等,可根据模型特性与数据规模选择。

## 3 深度学习在继电保护故障定位的应用与路径

### 3.1 故障定位逻辑与挑战

继电保护故障定位核心是根据暂态电气量数据、电网拓扑与参数,确定故障具体位置,为抢修提供依据。挑战包括:电网拓扑复杂,信号传输受多种因素影响致定位精度下降;多电源系统中故障电流流向复杂,传统方法难精准判断;故障类型与电阻不确定影响特征稳定性,增加定位难度<sup>[4]</sup>。

## 3.2 深度学习故障定位路径

### 3.2.1 时序数据建模定位

以故障前后电压、电流等时序数据为输入,用深度学

习模型(如 LSTM、GRU、transformer)提取特征与位置关系,输出故障位置。如 LSTM 模型通过学习不同位置故障时序特征差异实现分类定位;transformer 模型用自注意力机制捕捉全局依赖关系,提升复杂拓扑下定位精度。此方法适应性强,但对数据同步性要求高。

### 3.2.2 时空特征融合定位

结合故障数据时空特性,用 CNN 提取空间特征,RNN/LSTM 提取时序特征,构建融合模型定位。如将多监测点数据构建时空矩阵,2D-CNN 提取空间特征,LSTM 捕捉时序特征,全连接层输出故障位置坐标。此方法定位精度高,适用于多监测点、复杂拓扑电网。

### 3.2.3 迁移学习定位

针对特定电网故障样本不足,迁移学习将源域(如相似电网、仿真数据)知识迁移到目标域(目标电网),实现小样本故障定位。如用仿真样本训练模型,再用少量实际样本微调参数,使模型适应实际电网。此方法解决实际样本稀缺问题,降低对大量真实数据依赖。

## 3.3 定位精度提升的关键技术措施

三项优化策略:通过融合电压、电流等多类型监测数据及故障录波装置、PMU 等多设备数据,利用深度学习特征融合能力提升故障定位精度;构建基于深度学习的电网拓扑自适应模型,将拓扑结构编码为特征向量与电气量数据联合输入,实现模型参数动态调整以适应拓扑变化;采用小波去噪、自适应滤波等预处理技术消除干扰,训练时引入干扰样本并选用对抗训练等鲁棒模型,增强系统抗干扰能力。

## 4 深度学习在继电保护应用的挑战与对策

深度学习在电力系统故障处理中面临诸多挑战:一是数据质量与样本稀缺,实际故障样本少且质量差,样本不均衡影响模型对罕见故障的识别精度;二是模型实时性与部署难,电力系统对实时性要求高,现场设备计算资源有限,难以部署复杂模型;三是模型可解释性差,其内部过程难以解释,限制了在实际工程中的应用;四是适应电网动态变化能力不足,模型易因电网状态变化而性能下降。针对这些挑战,可采取以下应对策略:提升数据质量并扩充样本,采用数据清洗、仿真建模等技术;实现模型轻量化与实时性优化,运用模型压缩、选择高效模型结构及硬件加速技术;增强模型可解释性,采用可解释性深度学习技术、构建混合模型及建立追溯机制;提升模型自适应能力,采用在线学习、增量学

习技术,构建基于强化学习的自适应模型并引入电网特征。

## 5 未来走向与前景预测

### 5.1 技术演进方向

#### 5.1.1 多模型集成与联合决策

未来,深度学习在继电保护领域的应用将趋向于多模型集成,整合 CNN 的空间特征捕捉、LSTM 的时序动态分析、transformer 的全局关联解析以及强化学习的自适应策略制定能力,构建多模型联合决策框架,以增强在复杂故障情境下的应对效能;同时,融合深度学习与传统继电保护技术,利用传统方法的稳定性和深度学习的智能化特性,实现两者的优势互补<sup>[5]</sup>。

#### 5.1.2 边缘智能与分布式架构

随着边缘计算技术的演进,深度学习模型将逐渐部署至边缘节点(如继电保护设备、智能终端),通过边缘端的本地计算能力,实现故障数据的即时处理,降低数据传输延迟,提升故障响应速度;此外,分布式架构将促进多节点间的协同决策,增强故障识别与定位的准确性。

#### 5.1.3 数字镜像与虚实融合训练

数字孪生技术通过构建电力系统的虚拟副本,实现物理与虚拟世界的实时同步,能够生成海量、高精度的故障模拟数据,为深度学习模型训练提供充足样本;同时,结合虚实融合训练方法,将模拟数据与真实故障数据相结合,提升模型的泛化能力和实际应用效果。

#### 5.1.4 安全增强与鲁棒性提升

鉴于电力系统的安全敏感性,未来深度学习模型将更加重视安全增强与鲁棒性设计,通过引入对抗训练、安全验证、容错机制等技术,提升模型对恶意攻击、数据篡改、外部干扰的抵御能力;同时,建立模型安全评估机制,确保模型在实际应用中的稳定性和安全性。

### 5.2 前景展望

深度学习技术为电力系统继电保护的智能化升级注入了强大动力,未来随着数据资源的积累、模型技术的精进、部署环境的优化,深度学习将在继电保护故障识别与定位中发挥更加广泛和深入的作用。通过构建“数据驱动+知识引导”的智能继电保护体系,实现故障的快速识别、精准定位和自适应处理,显著提升电力系统的安全稳定运行能力。同时,需加强产学研合作,加速深度学习技术的工程化应用,解决数据共享、模型部署、安全可信等现实问题;建立统一

的技术标准和评估体系,规范深度学习在继电保护中的应用;培养跨学科复合型人才,促进电力系统与人工智能领域的深度融合。相信随着技术的不断进步,深度学习将成为构建智能电网安全防御体系的关键技术,为能源互联网的高质量发展提供坚实支撑。

## 6 总结

电力系统继电保护故障识别与定位的精准化、实时化、自适应化是智能电网发展的核心诉求,深度学习凭借其强大的特征提取和模式识别能力,为突破传统方法的技术瓶颈提供了有效方案。本文全面梳理了深度学习在该领域的应用进展,分析了 CNN、LSTM、混合模型等主流技术的应用逻辑,探讨了数据预处理、模型优化、定位精度提升等关键技术环节,指出了数据质量、实时性、可解释性、自适应能力等核心挑战及应对措施。深度学习在继电保护故障识别与定位中的应用,实现了从“人工设计特征”到“数据驱动特征”的转变,显著提升了复杂故障场景下的识别精度和定位准确性。未来,通过多模型集成、轻量化部署、数字孪生训练、安全增强设计等技术革新,深度学习将进一步推动继电保护系统的智能化升级,构建高可靠、自适应、可解释的故障处理机制。同时,需充分认识到深度学习技术在实际工程应用中的局限性,加强与传统继电保护方法的融合,重视数据资源建设和人才培养,推动技术标准制定和工程化落地。相信随着研究的深入和技术的持续进步,深度学习将在电力系统继电保护领域发挥更大作用,为电力系统的安全稳定运行和智能电网的高质量发展提供坚实保障。

## 参考文献

- [1] 孟彬. 基于深度学习电力系统故障预测与智能诊断分析方法研究[J]. 电力设备管理, 2024(19):130-132.
- [2] 党洪涛. 基于深度学习的电力系统故障预测与诊断分析[J]. 电子技术, 2025,54(04):368-370.
- [3] 马保慧, 吴沂飞, 赵利民, 赵玉祥, 许董杰. 深度学习模型下电力系统检测与保护的预测技术分析[J]. 电气传动自动化, 2024,46(06):36-40.
- [4] 邓小凡. 基于深度学习的电力系统继电保护智能诊断与优化策略[J]. 光源与照明, 2025(06):78-80.
- [5] 胡昀, 鲁云云, 代海建. 深度学习下的电力系统继电保护故障诊断模型分析[J]. 电工技术, 2025(20):147-149.