

基于深度学习的配电网故障定位与识别方法研究

徐亦迅

长江勘测规划设计研究有限责任公司 湖北 武汉 430000

摘要: 本文旨在系统性地研究基于深度学习的配电网故障定位与识别方法。首先,深入分析了配电网故障的类型、特征及其对传统方法带来的挑战;其次,详细阐述了适用于故障诊断任务的主流深度学习模型,包括卷积神经网络(CNN)、循环神经网络(RNN)及其变体长短期记忆网络(LSTM)、图神经网络(GNN)以及Transformer架构,并探讨了它们在处理不同类型故障数据(如时序波形、拓扑结构)时的优势与适用场景;再次,构建了一个完整的基于深度学习的故障诊断框架,涵盖了数据预处理、特征工程、模型训练与优化等关键环节。所提出的深度学习方法能够有效提升故障诊断的准确率、鲁棒性和泛化能力,为构建智能化、自愈型的现代配电网提供了有力的技术支撑。

关键词: 配电网;故障定位;故障识别;深度学习

引言

随着我国新型城镇化进程加速与“双碳”战略目标推进,配电网正经历深刻变革。分布式电源大规模接入、电动汽车充电负荷激增及智能用电设备普及,使其从单向被动辐射状网络转变为多源双向主动的复杂能源互联网。这一转变虽提升能源利用效率,却极大增加运行不确定性与复杂性,对系统安全稳定运行提出更高要求。故障是威胁配电网可靠性的主要因素,快速准确定位和隔离故障对避免局部或大面积停电、减少经济损失和社会影响至关重要,实现故障精准快速定位与识别是配电网自动化、智能化核心任务,具有重大现实意义。长期以来,配电网故障诊断依赖阻抗法、行波法和基于规则/专家系统的方法,但这些方法存在局限性,如精度受多种因素影响、对硬件要求高、依赖经验知识库、特征有效性不足等,大多采用的手工设计特征无法全面有效表征故障本质信息,在强噪声或微弱故障时效果大打折扣。而深度学习作为人工智能前沿技术,能通过多层非线性变换从原始数据自动学习抽象鲁棒特征,在处理电力系统暂态信号方面优势明显,省去繁琐手工特征工程步骤,有望突破传统方法性能瓶颈。近年来,以CNN、RNN/LSTM、GNN等为代表的深度学习模型为解决配电网故障定位与识别难题开辟了全新路径。

1 配电网故障特性分析

1.1 配电网故障类型与特征

配电网中的故障主要分为两大类:短路故障和接地故障。短路故障包括三相短路、两相短路、两相接地短路和单相接地短路。其中,单相接地故障在中性点不接地或经消弧线圈接地系统中最为常见,约占所有故障的

80%以上。短路故障通常伴随着巨大的故障电流,特征明显,易于检测。接地故障特别是高阻抗接地故障(High-Impedance Fault, HIF),由于故障点接触不良(如导线坠落在干燥的沥青或沙地上),产生的故障电流非常微弱,甚至低于正常负荷电流,其波形特征不明显,且常伴有间歇性电弧,这给故障检测和定位带来了极大困难。故障发生后,会在系统中产生丰富的暂态和稳态电气量信息,主要包括故障电流、电压的幅值、相位、频率、谐波分量以及行波信号等。这些信号蕴含了故障类型、位置、严重程度等关键信息,是进行故障诊断的数据基础。

1.2 传统故障定位与识别方法综述

如前所述,传统方法主要包括:(1)阻抗法:通过测量故障点到保护安装处的视在阻抗来估算距离。其核心公式为 $Z = U/I$,其中 U 和 I 分别为测量点的电压和电流相量。该方法在简单辐射状网络中效果尚可,但在含分布式电源的有源配电网中,反向电流会严重影响计算结果^[1]。(2)行波法:利用故障瞬间产生的高频行波在输电线路上的传播特性。通过检测行波到达线路两端的时间差来计算故障距离。该方法理论上不受系统参数和过渡电阻影响,但对硬件要求苛刻,且在配电网末端分支处行波会发生复杂的折射和反射,增加了解析难度。(3)人工智能方法:早期研究尝试将人工神经网络(ANN)、模糊逻辑、专家系统等引入故障诊断。这些方法虽能处理一定程度的非线性,但受限于浅层网络结构和有限的训练数据,其泛化能力和特征提取能力远不及现代深度学习模型。

2 基于深度学习的故障诊断研究现状

近年来,国内外学者开始探索将深度学习应用于电

力系统故障诊断。早期工作主要集中在使用CNN处理故障录波数据,将其视为一维时间序列或二维时频图(通过小波变换、S变换等获得),取得了优于传统ANN的效果。随后,研究者们意识到故障信号的时序动态特性,开始引入LSTM、GRU等循环网络,以更好地捕捉故障发展过程中的前后依赖关系。最新的研究趋势则更加注重电网的物理结构。配电网本质上是一个图结构,节点代表母线或负荷点,边代表馈线。图神经网络(GNN)能够直接在图上进行信息传递和聚合,将节点的电气量特征与其邻居节点的状态相结合,从而更全面地理解故障在整个网络中的传播和影响。此外,Transformer凭借其强大的自注意力机制,在处理长序列依赖和并行计算方面展现出优势,也开始被应用于电力数据分析。尽管已有诸多探索,但现有研究仍存在一些不足:一是多数模型仅关注故障分类(识别),对精确到具体区段或杆塔的定位研究较少;二是对模型在噪声、数据缺失、拓扑变化等实际复杂工况下的鲁棒性验证不够充分;三是缺乏一个系统性的、端到端的诊断框架。本文的研究正是为了弥补这些不足。

3 适用于配电网故障诊断的深度学习模型

本章将详细介绍四种核心深度学习模型,并分析其在配电网故障诊断任务中的适用性。

3.1 卷积神经网络(CNN)

CNN最初为图像处理设计,其核心是卷积层和池化层。卷积层通过滑动的小型滤波器(卷积核)在输入数据上进行局部感知,自动学习局部特征;池化层则用于降维和增强特征的平移不变性。在配电网故障诊断中,可以将故障发生后的三相电流、电压波形(通常采样数千个点)视为一维信号,输入到1D-CNN中。卷积核能够有效提取波形中的突变、振荡、衰减等局部模式,这些模式与特定的故障类型和位置密切相关。通过堆叠多个卷积层,网络可以学习到从简单边缘特征到复杂故障模式的层次化表示^[2]。CNN的权值共享和局部连接特性使其参数量相对较少,训练效率高,非常适合处理大规模的时域波形数据。

3.2 循环神经网络(RNN)与长短期记忆网络(LSTM)

RNN专为处理序列数据而设计,其内部具有循环连接,能够将前一时刻的隐藏状态传递到下一时刻,从而具备记忆能力。然而,标准RNN在训练长序列时容易遭遇梯度消失或爆炸问题,难以学习长期依赖。LSTM是RNN的一种改进结构,通过引入“门”机制(输入门、遗忘门、输出门)来精确控制信息的流动。遗忘门决定

丢弃哪些旧信息,输入门决定更新哪些新信息,输出门则控制当前时刻的输出。这种精巧的设计使LSTM能够有效捕捉故障信号中跨越数百甚至数千个时间步长的动态依赖关系,例如故障电弧的周期性燃熄特性,这对于识别HIF等复杂故障至关重要。

3.3 图神经网络(GNN)

GNN是一类直接在图结构数据上进行操作的神经网络。其基本思想是“消息传递”(Message Passing):每个节点会聚合来自其邻居节点的信息,并结合自身状态来更新自己的表示。经过多轮迭代,每个节点的最终表示将包含其K阶邻居范围内的全局拓扑和特征信息。在配电网中,我们可以构建一个图 $G=(V,E)$,其中节点集V对应各个监测点(如FTU、DTU安装点),边集E对应连接这些点的馈线。每个节点的初始特征可以是该点测得的故障电气量(如电流有效值、零序电流等)。通过GNN的消息传递机制,一个远离故障点的节点也能接收到故障扰动沿网络拓扑传播过来的信息^[3]。因此,GNN能够将故障定位问题转化为一个节点分类问题——即判断哪个节点(或哪条边)最有可能是故障发生的位置。这种方法充分利用了电网的物理连接关系,具有很强的物理可解释性。

3.4 Transformer架构

Transformer模型完全摒弃了循环结构,转而依赖于“自注意力”(Self-Attention)机制。自注意力允许序列中的每个元素(如波形中的每个采样点)直接与序列中的所有其他元素进行交互,并根据它们的相关性动态分配权重。这意味着模型可以并行处理整个序列,并且无论距离多远,都能建立元素间的直接依赖关系。在故障诊断中,Transformer可以高效地处理超长的故障录波序列,并精准地识别出对故障判别最关键的几个时间片段(例如,故障初瞬的冲击点、电弧重燃点等)。其并行计算的特性也使其在处理大规模数据时比RNN更具速度优势。虽然Transformer最初用于自然语言处理,但其强大的序列建模能力使其在电力时序数据分析中同样前景广阔。

4 基于深度学习的故障诊断框架设计

为系统性地解决配电网故障定位与识别问题,本文设计了一个端到端的深度学习诊断框架。

4.1 数据采集与预处理

(1) 数据来源:通过电磁暂态仿真软件(如PSCAD/EMTDC、OpenDSS)搭建详细的配电网模型,模拟各种故障场景(不同故障类型、位置、过渡电阻、初相角、系统运行方式等),生成海量的故障录波数据。(2) 数

据格式：原始数据为高采样率（如10kHz）的三相电流、电压时域波形。（3）预处理：去噪采用小波阈值去噪等方法，滤除高频噪声。归一化是对所有样本进行Min-Max或Z-Score归一化，消除量纲差异，加速模型收敛。数据增强是通过添加高斯白噪声、随机裁剪、时间扭曲等方式扩充数据集，提高模型的鲁棒性。

4.2 特征表示与标签构建

4.2.1 特征表示

对于CNN/LSTM/Transformer，直接使用预处理后的时域波形作为输入。对于GNN，需要将波形数据转换为图节点的静态特征。一种常用方法是提取每个监测点波形的统计特征（如均方根值、峰值、谐波畸变率）或频域特征（如FFT系数）作为节点初始嵌入。

4.2.2 标签构建

一是故障识别：采用one-hot编码，标签维度等于故障类别数（如10类：3种短路+1种接地+无故障等）^[4]。二是故障定位：可以定义为多分类问题（每个可能的故障区段作为一个类别），或回归问题（预测故障距离）。在GNN框架下，通常采用节点级多标签分类，即为每个节点分配一个“是否为故障点”的概率。

4.3 模型选择与集成

根据任务需求和数据特点，可以选择单一模型或进行模型集成。例如，可以先用CNN提取波形的局部特征，再将这些特征序列输入LSTM以捕捉时序动态；或者将CNN的输出作为GNN节点的初始特征，融合局部波形信息与全局拓扑信息。本文重点对比了独立的CNN、LSTM、GNN以及CNN-GNN混合模型的性能。

4.4 模型训练与优化

（1）损失函数：对于分类任务，采用交叉熵损失函数；对于回归任务，采用均方误差（MSE）。（2）优化

器：选用Adam优化器，因其自适应学习率的特性，通常能获得更快的收敛速度。（3）正则化：引入Dropout、L2正则化等技术，防止模型过拟合。（4）超参数调优：通过网格搜索或贝叶斯优化等方法，寻找最优的学习率、批量大小、网络层数、神经元数量等超参数。

5 结语

本文系统研究基于深度学习的配电网故障定位与识别方法，得出重要结论：深度学习混合模型（如CNN-GNN）能从原始故障数据自动学习高判别性特征，提升故障识别准确率与定位精度，克服传统方法局限；所提方法对复杂工况适应能力强，工程应用前景良好；将故障信号时域/频域特征与配电网物理拓扑结构信息深度融合是提升诊断性能关键，GNN提供了有效框架。展望未来，配电网故障智能诊断仍具挑战，研究可从多方向展开：实际工程中某些罕见故障样本稀少，可利用迁移学习等解决小样本甚至零样本故障诊断问题；配电网拓扑和运行方式动态变化，模型需具备在线学习和自适应调整能力；将电力系统基本物理定律嵌入深度学习模型构建物理信息神经网络，可提升模型性能；还可融合多源异构数据构建更全面的故障诊断与预警体系。

参考文献

- [1]陈汉钧.基于深度学习的配电网故障定位方法验证分析[J].电子技术,2025,54(12):240-241.
- [2]吴世杰,仇越,沈晓雪.基于深度学习的配电网故障定位技术研究[J].电气技术与经济,2025,(12):157-160.
- [3]郝明俊.基于深度学习的配电网故障检测与定位方法研究[J].技术与市场,2025,32(12):105-109+115.
- [4]胡军军,谢强,王伟鹏,等.基于深度学习模型的配电网故障检测[J].信息与电脑,2025,37(22):40-42.