

Research on accurate fault location algorithm of overhead line based on machine learning

Ze Wang Jie Gao Kai Sun

State Grid Ningxia Electric Power Co., Ltd. Yinchuan Power Supply Company, Yinchuan, Ningxia, 750004, China

Abstract

In order to improve the accuracy and efficiency of overhead line fault location, this study explores the accurate fault location algorithm based on machine learning, so as to provide strong support for the reliable operation of the power system. This paper will discuss the research methods and data set construction, feature engineering and optimization strategies, and model training and validation process in detail. Experiments show that machine learning-based algorithms perform well in multiple failure types and complex environments. It is expected that this study will provide reference for the subsequent research in related fields, and promote the intelligence and modernization of the power system.

Keywords

machine learning; overhead line; fault location

基于机器学习的架空线路精确故障定位算法研究

王泽 高婕 孙凯

国网宁夏电力有限公司银川供电公司, 中国·宁夏 银川 750004

摘要

为了提高架空线路故障定位的准确性和效率,本研究探索基于机器学习的精确故障定位算法,从而为电力系统的可靠运行提供有力支持。本文将详细探讨算法的研究方法与数据集构建、特征工程与优化策略、模型训练与验证过程。实验表明,基于机器学习的算法在多种故障类型和复杂环境下表现出色。期望本研究为后续相关领域的研究提供参考和借鉴,促进电力系统的智能化和现代化。

关键词

机器学习; 架空线路; 故障定位

1 引言

作为电力传输系统的重要组成部分,架空线路承载着将电能从发电厂输送到用户端的关键任务。然而,由于自然环境的影响、设备老化或人为因素,架空线路时常会遇到短路、断线等故障,因此,如何快速、准确地定位故障点,及时恢复供电,成为电力部门面临的一项重要挑战。传统的架空线路故障定位方法在一定程度上提高了故障定位的速度和精度,但在实际应用中仍存在诸多局限性,机器学习技术的迅速发展则为解决上述问题提供了新的思路。机器学习算法可以通过大量的历史数据进行训练,自动学习故障特征并根据实时监测数据预测故障位置。相比传统方法,机器学习具备更强的泛化能力和更高的灵活性,能够在不同条件下保持稳定的性能,在面对非线性、多变量的复杂故障场景时,机器学习的优势更加明显。

【作者简介】王泽(1998-),男,回族,中国宁夏吴忠人,本科,助理工程师,从事输电线路运检研究。

2 架空线路精确故障定位的需求与方法现状

2.1 需求分析

在现代电力系统中,任何一条架空线路的故障都可能导致大面积停电,给工业生产和居民生活带来巨大影响,因此需要快速、准确地定位故障点,保证电力及时恢复。精确的故障定位不仅能够提高电力系统的可靠性,还能显著减少停电时间,降低维修成本,提升用户的满意度和电力企业的经济效益。从技术角度来看,精确故障定位有助于优化电网维护策略。传统的定期巡检方式效率低下且成本高昂,而基于实时监测和数据分析的故障定位技术可以实现预防性维护,提前发现潜在问题,避免故障发生^[1]。不仅如此,精确故障定位还可以帮助电力企业合理安排检修计划,避免不必要的停机和资源浪费,提高整体运营效率。

2.2 现有方法

目前,架空线路故障定位主要依赖于阻抗法、行波法和基于GPS同步采样的方法。阻抗法是最常用的故障定位方法之一,通过测量故障点前后电压和电流的变化,计算出

故障位置,但是该方法对线路参数的变化非常敏感,当线路长度较长或存在分支时,其定位精度会显著下降。行波法则利用故障发生时产生的暂态行波信号来确定故障位置,这种方法具有较高的定位精度,但需要精确的时间同步装置,并且在复杂环境中容易受到干扰。基于GPS同步采样的方法能够在多个监测点同步采集电压和电流数据,利用GPS提供的精确时间戳进行故障定位。尽管这种方法能够在较大范围内实现较为准确的定位,但其性能受限于卫星信号的质量和覆盖范围,在山区或城市高楼密集区,GPS信号可能不稳定,影响定位精度。

3 研究方法 with 数据集

3.1 机器学习模型选择

本研究综合考虑了多种因素,包括算法的性能、计算复杂度、适应性和可扩展性,最终选定了一种混合机器学习模型作为主要研究方向。

所采用的混合模型结合了卷积神经网络(CNN)的空间特征提取能力和长短期记忆网络(LSTM)的时间序列建模能力,并通过强化学习技术动态调整模型参数以应对复杂的环境变化和多变的故障模式。具体而言,CNN用于处理电流、电压波形等时序数据,能够有效捕捉其中的空间特征,如峰值、均值、方差等,而LSTM则擅长处理时间序列数据,可以模拟故障发生的动态过程,捕捉时域中的暂态变化。两者结合后,模型能够在不同时间尺度上全面理解故障特征,提高定位精度。为了增强模型的自适应性和鲁棒性,我们还引入了强化学习机制,通过实时反馈机制,模型可以根据历史数据和当前监测信息自动调整内部参数。例如,在面对新的故障类型或环境条件发生变化时,强化学习模块能够快速学习并适应新情况,确保模型在复杂环境中保持高性能。

3.2 数据收集与预处理

数据的质量和数量直接影响机器学习模型的性能。本研究从多个渠道收集了丰富的数据,包括模拟数据和真实世界数据。模拟数据是通过电力系统仿真软件生成的,涵盖了各种类型的故障场景和环境条件,这些数据可以帮助研究人员在控制条件下测试和验证模型的性能。例如,通过设定不同的故障位置、故障类型(如短路、断线等)和环境参数(如温度、湿度、风速等),可以生成大量具有代表性的样本用于模型训练和评估^[2]。真实世界数据则来自实际运行的架空线路,包括历史故障记录、传感器采集的实时数据以及维护人员的经验反馈。这些数据反映了真实的电网运行情况,具有较高的实用价值。

为提高数据的质量和可用性,在数据收集的基础上本研究还进行了详细的预处理工作,包括去噪处理,特征提取和标准化处理。去噪处理用于消除数据中的随机噪声和异常值,确保数据的准确性和一致性。特征提取是将原始数据转换为更具代表性的特征向量,以便于模型的学习和分类。标

准化处理主要将不同尺度的数据统一到同一量级,避免某些特征因数值过大或过小而影响模型的训练效果。

3.3 数据集构建

数据集涵盖了多种类型的故障场景,包括雷击导致的瞬态故障、多点同时故障、长距离输电线路故障和复杂电磁环境下的故障,不同类型和程度的故障可以全面测试模型的识别能力和泛化性能。数据集包含了不同地理位置和气候条件下的样本以反映实际电网的复杂性和多样性,本研究通过收集来自不同省份、不同季节的数据来确保模型在各种环境下都能保持稳定的性能。考虑到架空线路的长度、拓扑结构等因素,数据集中还包括了不同长度和复杂度的线路样本,进一步提升了数据的代表性。

4 特征选择和生成

4.1 特征选择

合适的特征既能提高模型的准确性又能减少计算复杂度,提升训练效率。本研究通过深入分析电流、电压波形以及环境因素等多维度数据,确定了对故障定位最为关键的特征。

电流和电压波形是故障定位中最直接的信号源,这些波形包含了丰富的故障信息,短路、断线等不同类型的故障会导致电流和电压的显著变化。通过对电流和电压波形进行详细分析,我们可以提取出诸如峰值、均值、方差、过零点等统计特征。环境因素同样不可忽视,温度、湿度、风速等外部条件会影响架空线路的运行状态,进而影响故障的发生和发展^[3]。例如,高温天气可能导致导线膨胀,增加线路的机械应力,强风则可能引发导线摆动,导致接触不良或断线。因此,将这些环境因素纳入特征集,可以更全面地反映故障发生的背景。地理位置和时间信息也是重要的特征,不同地区的电网结构和负载特性存在差异,某些地区可能更容易发生特定类型的故障。举例来讲,山区的架空线路受雷击影响较大,而城市中的线路则可能因建筑施工等原因导致外力破坏。地理位置信息的引入可以为模型提供更多的上下文支持,帮助其更好地理解故障发生的模式,时间信息则可以帮助捕捉故障的时间分布规律。

4.2 特征生成

小波变换是一种常用的时频分析工具,适用于处理非平稳信号。小波变换可以将电流和电压波形分解为多个尺度上的细节分量,从而捕捉到不同频率范围内的故障特征。在短路故障中高频分量通常更为显著,而低频分量则反映了系统的整体响应,对这些分量进行进一步分析后,我们可以提取出更加精细的特征(如小波系数的能量、熵等)。傅里叶变换则是另一种重要的频域分析方法,能够将时域信号转换为频域表示。本研究通过傅里叶变换分析电流和电压波形的频谱特性,识别出特定频率下的异常波动。在谐波干扰严重的环境中,只需分析频谱图中的谐波成分,就可以准确判

断故障的来源和类型。傅里叶变换还可以用于计算功率谱密度、相位角等特征，这些特征对于评估系统的稳定性和可靠性具有重要价值。除了数学变换，物理模型也可以为特征生成提供有力支持。例如，基于电磁理论的传输线模型可以模拟电流和电压在架空线路上的传播过程，帮助研究人员理解故障发生时的物理机制。本研究结合实际测量数据和物理模型生成了一系列新的特征，如阻抗变化率、行波传播速度等，这些特征能够更直观地反映故障的位置和严重程度。

5 模型训练与验证

5.1 实验设置

为了选择最优的超参数组合，本研究采用了网格搜索和随机搜索相结合的方法。网格搜索的方法可以系统地遍历预定义的参数空间，找到最佳的参数组合，随机搜索则可以在更大范围内进行探索，避免陷入局部最优解。在深度学习模型中，学习率、批量大小、隐藏层节点数等超参数对模型的收敛速度和最终性能有显著影响，通过多次实验，本研究最终确定了学习率为 0.001、批量大小为 64、隐藏层节点数为 128 的配置，使得模型在训练集上的损失函数达到最小值。交叉验证是防止过拟合的有效手段。本研究选择了 K 折交叉验证 (K=5)，将数据集划分为 5 个子集，轮流作为验证集，其余部分作为训练集，每次训练后计算模型在验证集上的性能指标，并取平均值作为最终评估结果^[4]。这种做法不仅提高了模型的泛化能力，还减少了单次划分带来的偶然性误差。为了模拟实际应用中的复杂环境，本研究还在训练过程中引入了多种噪声和异常情况。

5.2 结果分析

5.2.1 雷击导致的瞬态故障

雷击产生的暂态行波信号具有极高的频率和强度，容易与正常运行状态下的高频噪声混淆。混合模型利用小波变换从时频域中提取更精细的特征，显著提高了对雷击故障的识别能力。实验结果显示，在雷击故障场景下，混合模型的准确率达到 91.05%，召回率为 82.14%，F1 分数为 85.03%。这表明混合模型能够有效区分雷击信号和正常运行状态，减少误判。

5.2.2 多点同时故障

多个故障点同时发生时电流和电压波形的变化更加复杂，给模型的定位带来了挑战。混合模型借助电网的拓扑结构信息实现了更为精确的多点故障定位。实验结果显示，在多点故障场景下，混合模型的准确率为 88.68%，召回率为 75.63%，F1 分数为 79.66%。

5.2.3 长距离输电线路故障

长距离输电线路的故障定位难度较大，因为线路参数

随温度、湿度等环境因素变化。混合模型引入更多环境因素作为特征，如温度、湿度、风速等，因而增强了对环境变化的适应性。在此基础上利用优化算法优化特征组合，进一步提高了模型的定位精度。实验结果表明，混合模型在长距离输电线路故障场景下的准确率达到 92.41%，召回率为 85.37%，F1 分数为 86.96%。

5.2.4 复杂电磁环境下的故障

在强电磁干扰环境下行波信号容易受到噪声影响，导致模型误判。为此，我们在混合模型中引入更多的抗噪特征，提高了模型的抗干扰能力。强化学习还能根据实时反馈调整模型参数，确保其在复杂电磁环境下的稳定性。实验结果显示，在复杂电磁环境下的故障场景中，混合模型的准确率为 86.95%，召回率为 80.33%，F1 分数为 84.87%。可见混合模型能够在强电磁干扰环境下保持较高的定位精度。

表 1 列出了混合模型在各种故障场景下的关键性能指标。

表 1 三种模型在故障定位任务中的性能对比

故障场景	准确率 (%)	召回率 (%)	F1 分数 (%)	训练时间 (h)	测试时间 (s)
雷击导致的瞬态故障	91.05	82.14	85.03	35.5	112
多点同时故障	88.68	75.63	79.66	49.8	156
长距离输电线路故障	92.41	85.37	86.92	61.7	188
复杂电磁环境下的故障	86.95	80.33	84.87	53.1	180

6 结语

通过引入机器学习技术，本文为架空线路故障定位提供了创新性的解决方案。研究不仅提高了故障定位的精度和效率，还增强了对复杂环境的适应能力，从而有力地支持了电力系统的稳定运行。未来的研究可以着眼于进一步优化模型结构以降低计算成本，探索无监督或半监督学习方法以减少对大量标注数据的依赖，并结合物联网与大数据分析实现更加智能化的电网运维。

参考文献

- 谢闻远.基于复合神经网络的架空线路故障诊断分析[J].电气技术与经济, 2023(6):132-134.
- 电气工程.基于机器学习的电力电缆故障诊断及定位算法研究[D].[2024-12-04].
- 徐干,刘中凯,付开强.基于机器学习算法的10kV配网断线故障定位方法研究[J].仪器仪表用户, 2024, 31(3):77-79.