

引用格式:舒佳蕾,陈依林,曹虹,等.基于图注意力网络的配电网故障行波定位方法[J].电力科学与技术学报,2025,40(1):85-91.

Citation: SHU Jialei, CHEN Yilin, CAO Hong, et al. A fault traveling wave localization method for distribution networks based on graph attention networks[J]. Journal of Electric Power Science and Technology, 2025, 40(1): 85-91.

基于图注意力网络的配电网故障行波定位方法

舒佳蕾¹, 陈依林¹, 曹虹², 王书扬², 刘佳琪²,
贺椿程¹, 丁熙¹, 张雨桐¹, 邓丰¹

(1.长沙理工大学电气与信息工程学院,湖南长沙410114; 2.中国电力科学研究院有限公司,北京100192)

摘要:拓扑变化会改变故障信号特征,传统配电网行波故障定位方法基于固定拓扑设计,通过时域或频域等单一特征信息判断故障位置,拓扑变化条件下定位准确率低,为此,提出基于图注意力网络的故障定位方法。首先,定量分析故障行波在时域与频域中的分布特性,发现单一时域或频域信息难以有效区分不同故障位置,故提出基于小波变换的故障行波全景信息表现形式;随后,将测点和架空线作为图的节点与边,以行波全景信息为节点特征,构建图数据,建立基于图注意力网络的故障定位方法,通过挖掘节点特征、网络拓扑结构信息与故障位置之间的关联关系,实现配电网故障定位,提升方法对拓扑变化的适应能力。仿真结果表明:所提方法定位准确率高达98.8%,不受过渡电阻、噪声等因素影响,对拓扑变化具有较强的适应能力。

关键词:配电网;故障定位;行波全景波形;图注意力网络;拓扑变化

DOI: 10.19781/j.issn.1673-9140.2025.01.009 中图分类号: TM721 文章编号: 1673-9140(2025)01-0085-07

A fault traveling wave localization method for distribution networks based on graph attention networks

SHU Jialei¹, CHEN Yilin¹, CAO Hong², WANG Shuyang², LIU Jiaqi²,
HE Chun Cheng¹, DING Xi¹, ZHANG Yutong¹, DENG Feng¹

(1.School of Electrical & Information Engineering, Changsha University of Science & Technology, Changsha 410114, China;

2.China Electric Power Research Institute, Beijing 100192, China)

Abstract: Topology change will change the fault signal characteristics. The traditional fault traveling wave localization method for distribution networks is based on the fixed topology design. Through the single feature information of the time or frequency domain, the fault is located, and the localization accuracy is low under the topology change conditions. For this reason, a fault localization method based on a graph attention network is proposed. First, the distribution characteristics of fault traveling wave in time and frequency domains are quantitatively analyzed, and it is found that it is difficult to effectively distinguish different fault locations with a single time or frequency domain information, so the panoramic information representation of fault traveling wave based on wavelet transform is proposed. Then, the measurement points and overhead lines are taken as the nodes and edges of the graph. The panoramic information of traveling waves is used as the node features to construct the graph data, so as to establish the fault localization method based on the graph attention network and locate the fault of the distribution network by mining the correlation between the node features, the information of the network topology, and the fault location, thus enhancing the adaptability of the method to topological changes. Simulation results show that the method has a high localization accuracy of 98.8%. It is not affected by transition resistance, noise, and other factors and has a strong adaptive ability to topology changes.

Key words: distribution network; fault localization; panoramic waveform of traveling wave; graph attention network; topological change

收稿日期:2024-02-08;修回日期:2024-04-17

基金项目:国家自然科学基金(52377073);2023年国家级大学生创新训练计划(S202310536025)

通信作者:邓丰(1983—),女,博士,教授,主要从事电力系统继电保护等研究;E-mail:df_csust@126.com

配电网是连接电力系统和用户的中间环节,起到电能分配的重要作用^[1-2],因此,维护配电网的安全稳定运行是至关重要的。传统故障定位方法(如矩阵法、行波法等)在结构不发生变化的网络中具有简单易实现的优点,但拓扑发生改变时需重新生成网络矩阵或数据库,大大增加了计算成本,因此,急需研究针对拓扑变化的配电网故障定位方法。

传统配电网故障定位方法主要有注入法、阻抗法和行波法^[3-4]。阻抗法通过利用线路参数与故障时节点电压电流等量测值计算故障线路阻抗,从而估计故障点与量测节点之间的位置。文献[5]提出基于线路首末端零序电流、电压分布特征的故障定位方法,该方法可以较好地适应信号量测环境,但受系统运行方式、过渡电阻影响较大。注入法是通过外加信号注入线路进行故障定位。文献[6]提出基于S注入法的故障定位方法,其灵敏度高,但信号易受外界因素影响而能量减弱。阻抗法和注入法的定位结果易受系统运行方式、过渡电阻和外界等因素影响。

行波法基于检测的初始行波或折、反射行波的波头信息确定故障位置,不受系统运行方式影响,并对过渡电阻具有较强鲁棒性^[7],一般可分为单端和双端法^[8]。单端法利用故障行波初始波头及反射波波头到达同一观测点的时间差来进行故障定位。文献[9]利用小波变换法提高了单端行波法的故障定位精度,但是单端法存在波速影响的问题。双端法利用故障行波初始波头到达线路首末两端观测点的时间差进行故障定位,因此对两端时间测量同步要求高^[10]。针对传统单端、双端行波方法的缺陷,文献[11]提出了基于行波全景波形的行波定位方法,通过对一定时间窗内行波信号进行小波变化,提取时频故障信息,方法简单易行,具有较高的灵敏度和可靠性,但拓扑变化时基于相似度的阈值整定方法难以适应。

人工智能算法具有处理复杂信息的能力,其被运用于解决配电网故障定位问题^[12]。文献[13]提出一种基于Dijkstra算法的混联配电网故障定位方法,但当拓扑结构发生变化时,其算法不能依据变化后故障信号特征有效辨故障位置。文献[14]采用图神经网络(graph neural network, GNN)通过注意力机制,聚焦相邻节点的影响差异,从而提升方法在网络重构等条件下的适应能力,但所挖掘的时域电压电流信息易受过渡电阻、系统运行方式等因素的影响。

针对以上问题,本文基于行波全景波形和图

注意力神经网络(graph attention network, GAT)建立一种对拓扑变化具有良好适应性的故障定位方法。首先,从时域和频域角度对不同故障位置的行波信号进行分析,发现单一的利用故障行波信号的时域或频域信息难以精确区分故障位置,为此,提出故障行波全景波形表示形式,通过时频域全景信息提升不同故障位置信号间的差异;随后,建立GAT模型,将全景波形作为节点特征输入,使模型在训练过程中能够充分挖掘行波全景波形蕴含的丰富故障信息,并通过节点间的注意力机制增强方法对网络拓扑变化的适应性和抗干扰能力;最后,应用训练好的模型完成配电网单相接地故障的精准定位。仿真结果表明:在多工况条件下的数据中,所提方法准确率高达98.8%,能够适应拓扑结构变化和准确检测故障位置,且具有良好的抗噪性能。

1 行波全景波形

1.1 行波时域和频域信息分析

配电线路发生故障时故障点会产生故障行波,其中蕴含大量时-频域故障信息^[15-16]。从时域分析,行波波形是故障点产生的初始行波在波阻抗不连续点发生折反射,各次行波浪涌按时序先后叠加而成,故障点传输路径以及折、反射过程的不同都会导致同一检测点检测到的行波幅值和波形存在差异,但是情景下行波信号时域信息差别很小,使得单一基于时域或频域的方法难以辨别故障位置。

现以某10 kV配电网为例,其拓扑结构如图1所示,在母线与馈线处安装行波检测装置,分别在线路L₁、L₁₃上距离最左侧母线1的1 km处位置(f_1 、 f_2)设置接地故障,且母线1处的量测设备收录到的时域行波如图2所示。

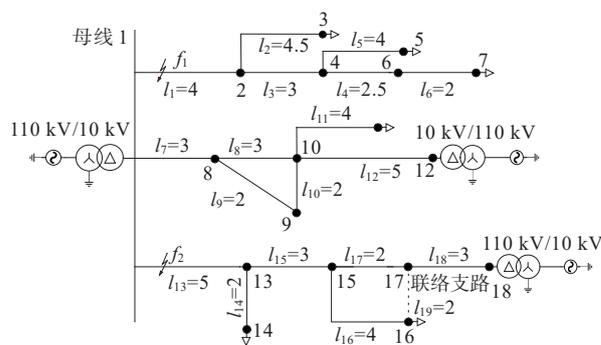


图1 10 kV配电网拓扑结构(长度单位:km)

Figure 1 10 kV distribution network topology (Length in kilometers)

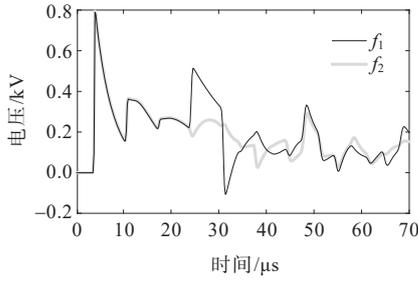


图 2 故障行波时域分布

Figure 2 Distribution of fault traveling wave in time domain

由图 2 可知,2 种时域行波波波形差别较小,在时间窗前 20 μs 中波形基本一致,这是由于故障点 f_1 、 f_2 相对检测点位置、路径相同,2 点产生的故障行波折射反射传输路径基本一致。中间段差异明显部分集中在 30 μs 附近,但存在区间小,难以精确捕捉;40 μs 后部分波形则由于二者变化趋势与幅值分布相似,也难以区分。由此可知,部分条件下不同故障位置的行波时域分布差异较小,难以简单区分,从而使得故障定位存在困难。

从频域分析可知,故障行波是一个宽频带阶跃信号,可采用功率谱密度(power spectral density, PSD)来表述故障行波信息。PSD 可以反映单位频带内信号功率随频率的变化情况,体现某一频率的能量密度,直观展示信号在频域内的分布情况。本文采用周期图法进行功率谱密度估计,周期图法是将随机信号 $x(n)$ 的 N 个采样点 $x_N(n)$ 经傅里叶变换后得到 $X(e^{j\omega})$,再取其幅值平方除以 N 作为功率谱密度 $P_X(e^{j\omega})$,其表达式如下:

$$X(e^{j\omega}) = \sum_{i=0}^{N-1} x_i e^{-j\omega i} \quad (1)$$

$$P_X(e^{j\omega}) = \frac{1}{N} |X(e^{j\omega})|^2 \quad (2)$$

根据式(1)、(2)对 f_1 、 f_2 产生的故障行波进行 PSD 估计,结果如图 3 所示,可知 2 个行波信号的频域分布绝大部分是非常接近的。

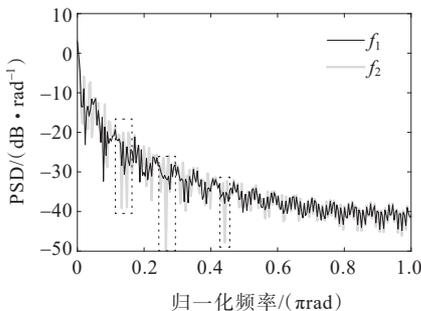


图 3 功率谱密度估计

Figure 3 Power spectral density estimation

2 个行波信号的频域分布区别主要集中在个别频带,如图 3 中方框标识所示,然而这些频段区间短小,难以精确捕捉。由此可知,某些情况下不同故障位置的行波的频域分布差异较小,难以区分故障位置。

1.2 全景波形的故障信息分析

由上述分析可知,单一时域或频域行波信息差异小,难以确定故障位置,因此,本文提出采用行波全景波形对故障行波进行分析。截取一段时间窗的故障行波时域波形并利用连续小波变换对其进行多尺度分解,得到的行波时频域波形即定义为行波全景波形,如图 4 所示。

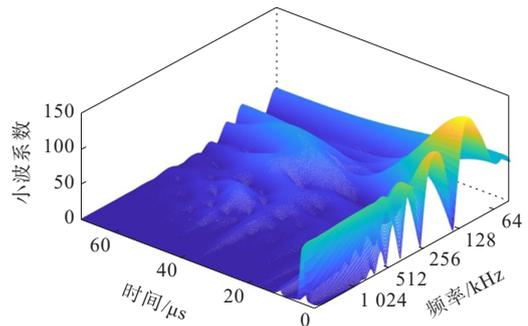


图 4 全景波形

Figure 4 Panoramic waveform

基于本文的前期研究发现,行波全景波形不仅能反映故障行波的时域信息,还可展现行波兆赫兹级别的频域信息,蕴含了频率-幅值-极性等多尺度故障信息,可从中获得网络拓扑结构、故障点位置、故障过渡电阻以及故障类型等丰富故障信息,因此,可通过故障行波全景波形辨别不同故障位置,实现故障定位。

现采用行波全景波形对 f_1 、 f_2 这 2 点产生的故障行波进行分析,由图 2 所示行波数据得到行波全景,如图 5 所示,比较图 5(a)、(b)可知, f_1 、 f_2 产生的故障行波全景波形存在明显差异,且主要集中在 3 个部分。

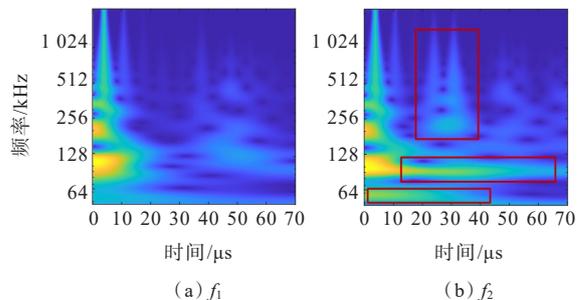


图 5 f_1 、 f_2 的全景波形

Figure 5 Panoramic waveforms of f_1 and f_2

如图5(b)中方框标识部分,这3个区域内 f_2 产生的故障行波全景波形的小波系数都远高于 f_1 产生的故障行波全景波形的小波系数。这验证了采用蕴含丰富故障信息的行波全景波形分析足以区分不同故障位置。

2 图注意力网络的基本原理

2.1 图神经网络

GNN是一种将神经网络运用于图的学习模型,通过发掘图结构数据中的节点或边等特征,实现分类、回归任务^[17]。故障定位可视为节点分类问题,可通过区分节点类别实现故障定位,因此,可将GNN融合配电网拓扑结构以及相应的电气信息来探究配电网中母线馈线节点特征^[18-19]。

2.2 图注意力网络

GAT是在传统GNN基础上衍生出的变体,通过引入注意力机制,增强节点信息更新过程中对邻居节点重要程度信息的考虑。注意力机制是一种信息处理机制,优势在于选择性关注重要部分,进而增强方法对网络拓扑变化的适应性和抗干扰能力。注意力机制的数学表达式为

$$\text{Attention}(Q, S) = \sum \langle Q, S \rangle \cdot S \quad (3)$$

式中, S 为需要处理的信息源,即邻居节点的特征向量; Q 为已知信息,即目标节点特征。

GAT将注意力机制引入到GNN的邻居节点聚合过程中,通过图注意力层(graph attention layer, GAL)学习获得各个邻居节点特征的权重,从而在聚合邻居节点时对邻居节点特征进行加权求和^[16]。GAL的输入和输出特征向量分别为

$$\mathbf{h} = \{h_1, h_2, \dots, h_N\}, h_i \in \mathbf{R}^F \quad (4)$$

$$\mathbf{h}' = \{h'_1, h'_2, \dots, h'_N\}, h'_i \in \mathbf{R}^{F'} \quad (5)$$

式中, \mathbf{h} 、 \mathbf{h}' 分别为GAL的输入和输出特征向量; N 为节点数; F 、 F' 分别为输入和输出的节点特征数。

如图6所示,假设中间节点为 v_i ,其有3个一阶邻居节点。为了更好地分配权重,通过softmax对节点之间的相关度 e_{ij} 进行归一化处理,得到注意力系数为

$$a_{ij} = \text{soft max}(e_{ij}) = \frac{\exp\{L(\alpha[\mathbf{W}h_i, \mathbf{W}h_j])\}}{\sum_{v_k \in N(v_i)} \exp\{L(\alpha[\mathbf{W}h_i, \mathbf{W}h_k])\}} \quad (6)$$

式中, L 为激活函数LeakyReLU; α 为计算2个节点相关度的函数; \mathbf{W} 为权重参数矩阵; $N(v_i)$ 为节点 v_i

的所有邻居节点集合。

得到注意力系数矩阵后计算节点 v_i 的输出特征向量,计算公式为

$$\mathbf{h}'_i = \sigma\left(\sum_{v_j \in N(v_i)} a_{ij} \mathbf{W}h_j\right) \quad (7)$$

式中, \mathbf{h}'_i 为该层节点 v_i 的新的特征向量; σ 为ReLU激活函数。

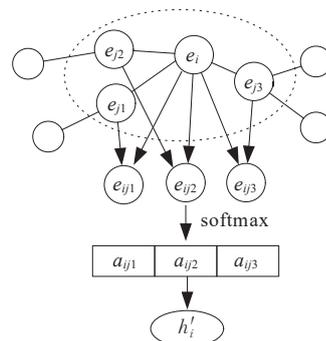


图6 图注意力层

Figure 6 Graph attention layer

当多头注意力机制分别计算 M 个相互独立的注意力头的注意力后,通过拼接或取平均操作来更新节点特征,以获得更全面的信息,从而增强模型稳定性,其数学表达式为

$$\begin{cases} \text{拼接: } \mathbf{h}' = \parallel_{k=1}^K \sigma\left(\sum_{v_j \in N(v_i)} a_{ij}^k \mathbf{W}^k h_j\right) \\ \text{平均: } \mathbf{h}' = \sigma\left(\frac{1}{K} \sum_{v_j \in N(v_i)} a_{ij}^k \mathbf{W}^k h_j\right) \end{cases} \quad (8)$$

式中, K 为注意力头数量; \parallel 表示拼接操作; a_{ij}^k 、 \mathbf{W}^k 分别为第 k 组注意力机制的权重系数和学习参数。

$K=2$ 的多头注意力机制的工作过程如图7所示,通过2组相互独立的多头注意力机制,使注意力权重分配更加明确,并降低过拟合风险。

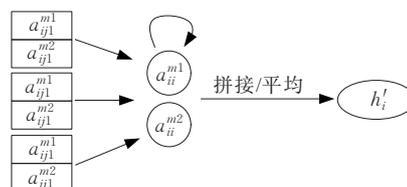


图7 多头图注意力机制

Figure 7 Multi-head graph attention mechanism

由上述分析可知,GAT通过注意力机制动态计算邻居权重。因此,当图拓扑结构发生变化时,注意力机制可以依据不同相邻节点的影响程度,自适应地调整节点间的权重系数,进而提升方法在应对配电网拓扑结构变化上的能力。

3 GAT模型

3.1 GAT模型输入分析

GAT是一种处理图数据的图深度学习方方法,需要将配电网抽象为由节点和边构成的图,由于是在母线和馈线处安装行波检测装置,故以母线和馈线作为节点,以传输线作为边得到图网络,然后通过描述图中节点和边的连接关系的邻接矩阵向GAT模型输入配电网拓扑结构信息,测点的故障行波全景波形作为节点特征输入。

GAT模型如图8所示,配电网拓扑结构对应输入中的邻接矩阵,每个节点相应的全景波形对应节点特征。通过3个GAL层完成邻居节点特征聚合得到新的节点特征,再通过头数为8的多头注意力操作方式更新节点特征,最后输出得到每个节点是否为故障状态。

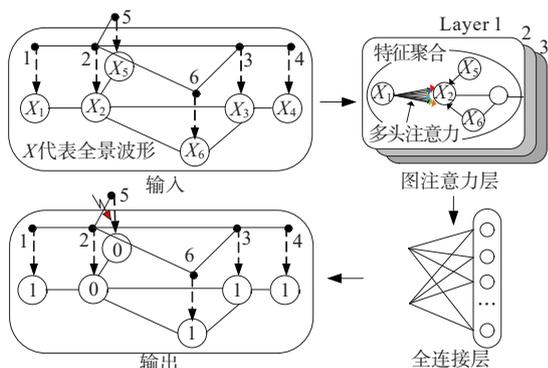


图8 GAT模型示意

Figure 8 GAT model

3.2 数据优化与改进过程

1) 行波信号的处理。母线处采集到行波信号后经连续小波变换得到全景波形,并运用OpenCV中函数对进行维度处理得到节点特征矩阵。

2) 样本处理。母线上安装的行波检测装置采集的是时域数据,配电网中的故障会被尽快切除,因此,非故障样本数量远远大于故障样本数量,从而导致训练模型不够准确。由于基于GAT模型的配电网故障定位问题是二分类问题,为此模型采用带权重的二分类交叉熵损失函数,即

$$\left\{ \begin{array}{l} L = -\frac{1}{b} \sum_{k=1}^b [\gamma y_k \log p_k + (1 - \gamma) \cdot \\ \quad (1 - y_k) \log (1 - p_k)] \\ p_k = 1 / (1 + e^{-y}) \end{array} \right. \quad (9)$$

式中, L 为计算得到的损失值; b 为训练样本数; y_k 为

正样本标签; p_k 为模型判别样本为正样本的概率; γ 为正样本的权重系数。

3) 数据的处理。采用最大-最小归一化方法,将输入特征量限定为 $[0, 1]$,表达式为

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (10)$$

式中, x 为输入样本中的特征向量; x' 为标准化之后的特征向量; $\max(x)$ 、 $\min(x)$ 为样本的最大和最小值。

4 仿真分析

4.1 建立数据库

在PSCAD中搭建10 kV配电网仿真模型(图1),在母线与馈线处安装行波检测装置,采样率为5 MHz,样本数为8 092,截取故障发生后150 μ s时间窗的行波数据。设置不同的模型参数进行仿真分析,如表1所示。

表1 故障仿真样本参数设置

Table 1 Parameters for simulation samples of fault

投入位置	过渡电阻/ Ω	初相角/ $^\circ$
每条支路从其左侧节点起,每隔200 m处设置1个故障(共289个故障点)	10、50、100、200、500、1 000、1 500	1.5、30、60、90

4.2 模型效果分析

本文采用F1-score对GAT模型进行评估^[20-21],其计算公式为

$$\left\{ \begin{array}{l} F_1 = 2pr / (p + r) \\ p = T_1 / (T_1 + T_2) \\ r = T_1 / (T_1 + T_3) \end{array} \right. \quad (11)$$

式中, F_1 为 p (精确率)和 r (召回率)的调和平均数,值越大模型检测准确度越高; T_1 、 T_3 分别为正样本预测为正、负的样本数量; T_2 为负样本预测为正的样本数量。

将文4.1中所建的数据集按8:1:1比例划分训练集、测试集和验证集,使用GAT模型进行检测,测试集准确率达98.8%。

1) 故障过渡电阻的影响。每个故障点设置7种故障过渡电阻的接地故障,检测结果如表2所示,随着故障过渡电阻的增大,模型的检测准确度略有下降,这是因为故障过渡电阻增大后,行波信号会减小,但是在故障过渡电阻为1 500 Ω 的条件下模型仍有较高的检测准确度。此外,不同故障过渡电阻下模型的检测准确度均在98%以上,表明本文所提方法模型不受故障过渡电阻的影响。

表 2 不同故障过渡电阻的检测准确率

Table 2 Detection accuracy with different fault transition resistance

电阻/ Ω	准确率/%	电阻/ Ω	准确率/%
10	99.58	500	98.61
50	99.36	1 000	98.29
100	99.17	1 500	98.04
200	98.82		

2) 故障初相角的影响。每个故障点设置 4 种故障过渡电阻的接地故障,检测结果如表 3 所示,不同故障初相角下模型的检测准确度均在 97% 以上,可知本文所提方法不受故障初相角影响。

表 3 不同故障初相角的检测准确率

Table 3 Detection accuracy with different initial phase angles of fault

故障初相角/ $^{\circ}$	准确率/%	故障初相角/ $^{\circ}$	准确率/%
1.5	97.37	60	99.12
30	98.64	90	99.41

3) 噪声干扰的影响。在配电网实际运行中,考虑检测得到的故障特征数据中往往混杂有大量干扰噪声,为验证模型在噪声干扰下的可靠性,分别添加 25、30、35 和 45 dB 的高斯噪声,检测结果如表 4 所示,在噪声的影响下,模型的检测准确度略有下降,但仍均高于 96%,表明 GAT 模型具有较强的抗噪声能力。

表 4 不同故障噪声的检测准确率

Table 4 Detection accuracy for different fault noises

噪声/dB	准确率/%	噪声/dB	准确率/%
25	96.12	35	97.04
30	96.37	45	98.56

4.3 模型在拓扑变化下的适应能力分析

为测试模型在拓扑变化下的适应能力,对图 1 所示配电网拓扑结构进行 4 种变化^[18]:①断开 L_9 支路;②断开 L_{16} 支路;③断开 L_9 、 L_{16} 支路;④闭合联络支路 L_{19} 。直接用原拓扑结构训练好的模型对 4 种拓扑变化后的故障信号进行测试,结果如表 5 所示,在 4 种拓扑结构变化的情景下,模型的检测准确度均在 94% 以上,表明所提方法能够基于注意力机制自适应地调整不同节点之间的权重系数,从而在未经训练过的新拓扑中准确定位故障位置,对拓扑变化表现出良好的适应能力。

表 5 不同拓扑结构的检测准确率

Table 5 Detection accuracy with different topologies

拓扑结构	准确率/%	拓扑结构	准确率/%
断开 L_9	95.35	断开 L_9 、 L_{16}	94.47
断开 L_{16}	96.12	连接 L_{19}	96.71

5 结语

现有故障定位方法利用单一故障特征量,且难以适应配电网拓扑结构变化,本文提出了一种行波全景波形与 GAT 相结合的配电网故障定位方法,开展以下工作:

1) 从时域和频域 2 个维度定量分析故障行波信息分布特性,发现部分故障位置的行波信号间的时、频域差异性不显著,难以有效区分。通过截取一段时间窗的行波时域波形,运用连续小波变换进行多尺度分解得到故障行波全景波形,其蕴含充分的故障信息,可展示不同故障位置信号间的差异性。

2) 建立基于全景波形和 GAT 的故障定位模型,深入挖掘故障行波全景波形与网络拓扑结构、故障位置的关联信息,并通过注意力机制挖掘不同节点的重要程度,自适应调整不同节点间权重,有效提高定位模型对拓扑变化的适应能力。

3) 仿真结果表明:所提方法不受过渡电阻、故障初相角以及噪声等因素影响,对网络拓扑变化具有较强的适应能力,拓扑变化场景中的定位准确率达到 94% 以上。

参考文献:

- [1] 戴雪婷,李辉,何柏娜,等.配电网拓扑分析与线路参数辨识研究[J].电力科学与技术学报,2023,38(4):46-56.
DAI Xueting, LI Hui, HE Baina, et al. Research on topology analysis and line parameter identification of distribution network[J]. Journal of Electric Power Science and Technology, 2023, 38(4):46-56.
- [2] BAKKAR M, BOGARRA S, C R COLES F, et al. Multi-layer smart fault protection for secure smart grids[J]. IEEE Transactions on Smart Grid, 2023, 14(4):3125-3135.
- [3] 胡一鸣,史鸿飞,张玉龙,等.基于行波全景故障特征自辨识的高阻接地故障检测方法[J].供用电, 2023, 40(4):39-46+54.
HU Yiming, SHI Hongfei, ZHANG Yulong, et al. High impedance fault detection method based on traveling wave full waveform fault characteristics self-identification[J]. Distribution & Utilization, 2023, 40(4):39-46+54.

- [4] 郭舒毓. 基于行波原理的配电网高精度故障定位技术研究及应用[D]. 武汉:华中科技大学,2021.
GUO Shuyu. Research and application of high-precision fault location technology in distribution network based on traveling wave theory[D]. Wuhan: Huazhong University of Science and Technology,2021.
- [5] 俞小勇,李克文,吴丽芳,等. 计及相位偏移的小电阻接地系统电压梯度测距方法[J]. 电力系统保护与控制, 2024,52(23):65-73.
Yu Xiaoyong, Li Kewen, Wu Lifang, et al. Voltage gradient ranging method for low resistance grounding system considering phase shift [J]. Power system protection and control, 2024,52 (23) : 65-73.
- [6] 郝建强.S注入法的配电网故障定位的研究[J]. 电力学报,2011,26(2):124-126.
HAO Jianqiang. Research on fault location in distribution network on S injection method[J]. Journal of Electric Power,2011,26(2):124-126.
- [7] 黄博,李文亮,徐学帅,等. 35 kV 中压配电网单相接地故障行波定位方法研究[J]. 电网与清洁能源, 2023, 39 (1):58-63.
HUANG Bo, LI Wenliang, XU Xueshuai, et al. A study on the traveling wave location method of single-phase grounding fault in 35 kV medium voltage distribution network[J]. Power System and Clean Energy, 2023, 39 (1):58-63.
- [8] 罗小杰. 基于自适应形态滤波与多端行波法的配电网故障定位技术研究[D]. 广州:华南理工大学,2022.
LUO Xiaojie. Fault location technology for distribution network based on adaptive morphological filters and multi-end traveling wave method[D]. Guangzhou: South China University of Technology,2022.
- [9] 雷杨,杨帆,杨志淳,等. 基于离散小波变换的配网故障单端行波波头提取研究[J]. 电工技术,2023(23):75-77+80.
LEI Yang, YANG Fan, YANG Zhichun, et al. Research on the extraction of single-ended wavehead of fault in distribution network based on discrete wavelet transform [J]. Electric Engineering,2023(23):75-77+80.
- [10] 唐志国,李阳. 基于改进无参尺度空间经验小波变换的变压器高频电流局放噪声抑制研究[J]. 高压电器, 2024, 60(1):144-153.
TANG Zhiguo, LI Yang. Research on partial discharge noise suppression of transformer based on improved parameterless scale space empirical wavelet transform[J]. High Voltage Apparatus, 2024, 60(1): 144-153.
- [11] 邓丰,李欣然,曾祥君,等. 基于波形唯一和时-频特征匹配的单端行波保护和故障定位方法[J]. 中国电机工程学报,2018,38(5):1475-1487.
DENG Feng, LI Xinran, ZENG Xiangjun, et al. Research on single-end traveling wave based protection and fault location method based on waveform uniqueness and feature matching in the time and frequency domain[J]. Proceedings of the CSEE,2018,38(5):1475-1487.
- [12] 陈辉,周羽生,刘诗涵,等. 基于改进和声算法的含 DG 配电网故障定位[J]. 电力科学与技术学报,2018,33(2):123-128+134.
CHEN Hui, ZHOU Yusheng, LIU Shihan, et al. Fault location of distribution network with distributed generation based on an improved harmony algorithm[J]. Journal of Electric Power Science and Technology,2018, 33(2):123-128+134.
- [13] 朱利锋. 基于Dijkstra算法的混联配电网故障定位方法[J]. 电子设计工程,2023,31(10):97-100+105.
ZHU Lifeng. Fault location method of hybrid distribution network based on Dijkstra algorithm[J]. Electronic Design Engineering,2023,31(10):97-100+105.
- [14] DE FREITAS J T, COELHO F G F. Fault localization method for power distribution systems based on gated graph neural networks[J]. Electrical Engineering, 2021, 103(5):2259-2266.
- [15] 梅龙军. 基于行波全景波形的配电网单相接地故障选线方法研究[D]. 长沙:长沙理工大学,2021.
MEI Longjun. Research on single-phase-to-ground fault line selection method for distribution network based on traveling wave panoramic waveform[D]. Changsha: Changsha University of Science & Technology,2021.
- [16] DONG H, YU G, JIANG Q. Time-frequency-multisqueezing transform[J]. IEEE Transactions on Industrial Electronics,2024,71(4):4151-4161.
- [17] 李佳玮. 基于图神经网络的配电网故障定位方法[D]. 北京:北京交通大学,2022.
LI Jiawei. Distribution network fault location based on graph neural network[D]. Beijing: Beijing Jiaotong University,2022.
- [18] 叶智鹏. 基于图注意力网络的配电网单相故障检测研究[D]. 福州:福建工程大学,2022.
YE Zhipeng. Research on single-phase fault detection of distribution network based on graph attention network abstract[D]. Fuzhou: Fujian University of Technology, 2022.
- [19] WANG Z, JIANG W, XU J, et al. Grid2Vec: learning node representations of digital power systems for anomaly detection[J]. IEEE Transactions on Smart Grid, 2024, 15 (5):5031-5042.
- [20] LIU Y, LI Z, YAN Y, et al. Identification method for single-line-to-ground faults with line break based on phasor measurement in distribution networks[J]. Journal of Modern Power Systems and Clean Energy, 2023, 11(3): 907-916.
- [21] XU Y, JABER V, MERT K, et al. An adaptive-importance-sampling-enhanced bayesian approach for topology estimation in an unbalanced power distribution system [J]. IEEE Transactions on Power Systems, 2022, 37(3): 2220-2232.