

DOI: 10.13382/j.jemi.B2306731

基于 GrapSAGE 算法的配电网故障定位方法*

洪翠 吴奕炜 高伟 郭谋发

(福州大学电气工程与自动化学院 福州 350108)

摘要:本文提出一种基于 GraphSAGE (graph sample and aggregate)算法的配电网故障定位方法。以对系统侧母线电压进行形态学黑帽运算的结果启动故障定位算法;利用 GSA 模型自主挖掘网络拓扑和零序电流特征,根据节点特征和标签建立函数映射,评估线路运行状态从而实现故障定位。基于 PSCAD/EMTDC 仿真平台搭建 IEEE33 节点模型,测试结果表明所提配电网故障定位方法可行且有效。并且配电网拓扑变化时,该方法无需重新训练模型即能获得可靠的故障定位结果,验证了方法的鲁棒性和对拓扑变化的适应性。

关键词:配电网故障定位;图学习算法;形态学黑帽运算;GSA 算法;拓扑结构变化

中图分类号: TM76; TN98 **文献标识码:** A **国家标准学科分类代码:** 470.4054

Fault location method in distribution network based on GrapSAGE algorithm

Hong Cui Wu Yiwei Gao Wei Guo Moufa

(College of Electrical Engineering and Automation, Fuzhou University, Fuzhou 350108, China)

Abstract: A fault location method based on GraphSAGE (graph sample and aggregate, GSA) algorithm is proposed in this paper. The morphological black hat operation is performed on the power-side bus voltage of the distribution network as the fault detection criterion to start the fault location algorithm. The GSA model is used to independently mine topology and zero sequence current features, and function mapping is established according to node features and labels to evaluate the running state of the line to achieve fault location. Based on the PSCAD/EMTDC simulation platform, an IEEE 33-node simulation model is constructed to acquire data resources and validate the proposed method. Reliable fault location results are obtained by applying the proposed method. Furthermore, in distribution networks with topological changes, the model can obtain reliable fault localization results without retraining, which verifies the robustness and adaptability of the method to topological changes.

Keywords: fault location in distribution network; graph learning algorithm; morphological black hat operation; algorithm of GSA; topology changing

0 引言

快速准确地定位并隔离故障,有助于提升配电网的供电可靠性和系统运行稳定^[1-3]。传统配电网故障检测、定位主要依据阈值设定或逻辑判断的方法,并结合配电网自动化信息实现^[4]。文献[5]在采用相模变换后选定特征量进行灰色关联度分析计算,确定故障类型;文献[6]采用小波变换提取故障特征信息,与设定阈值对

比实现故障有效检测。这些方法通常只适用于拓扑固定的配电网,且计算有一定的复杂性。近年来,深度学习由于其出色的特征表达能力和非线性拟合能力,成为配电网故障定位的研究热点^[7-9]。文献[10]利用卷积深度置信网络自主提取配电网单相接地故障特征,实现故障定位;文献[11]首先利用小波包变换分解电量信号,分解结果转成像素矩阵输入 AlexNet 网络用于配电网故障区段辨识,提升了定位结果的准确度。这些方法中的模型仍未能考虑到配电网拓扑信息,只在拓扑不变时方法

收稿日期:2023-07-14 Received Date: 2023-07-14

* 基金项目:福建省自然科学基金(2021J01633)项目资助

才能保持较高的准确率。图深度学习能充分考虑节点空间的关联性,并因其在特征提取中充分嵌入拓扑信息的优势而受到了国内外广泛关注^[12-14],图神经网络(graph neural network, GNN),充分考虑节点和边关联性实现拓扑信息聚合传递^[12],主要有图卷积神经网络(graph convolutional network, GCN)^[15]、GraphSAGE^[16](简称 GSA)和图注意力网络(graph attention network, GAT)^[17]等。配电网作为一种典型的图结构网络^[18],若以图神经网络对其进行故障特征提取,必能更充分考虑电气节点的空间关联性,适应拓扑变化。文献[19]用 GCN 对配电网故障进行预测;文献[20]基于时空特征图卷积提取配电网的拓扑、时序和节点属性特征,再对配电网运行状态进行估计,具有良好的准确性。文献[21]利用 GSA 网络识别电力系统的异常数据,能有效检测出隐藏的异常数据,为电力系统异常检测提供了方向。

本文设计一种基于 GSA 模型的配电网故障定位方法,并利用形态学黑帽运算(morphological black hat)处理电压信息实现故障启动。其中 GSA 模型采用归纳式学习框架^[16]生成表示未知节点特征,故障定位的准确率较高,且在应用于新拓扑实现故障定位时,无需重新训练。将本文方案用在基于 PSCAD/EMTDC 搭建的 IEEE 33 节点配电网模型的仿真结果表明,方案学习能力优异且鲁棒性较强。

1 图卷积神经网络和 GSA 算法

1.1 图卷积神经网络

GCN 是最基础的、应用最为广泛的图学习算法之一,能自适应提取深层特征^[22-23],其基本结构如图 1 所示。

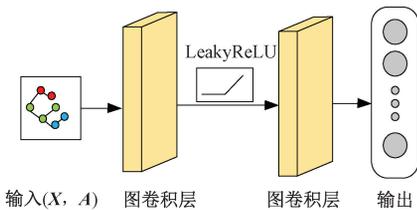


图 1 图卷积神经网络结构

Fig. 1 Structure of the graph convolution network

其中,输入信息经过两层全连接图卷积层后输出,每一层输出都作为下一层的输入,图卷积层间的激活函数采用 LeakyReLU。

$$\text{LeakyReLU} = \begin{cases} x & (x > 0) \\ \alpha & x(x \leq 0) \end{cases} \quad (1)$$

卷积层使用如下特征映射:

$$\mathbf{H}^{(i+1)} = f(\mathbf{H}^{(i)}, \mathbf{A}''^i) \quad i = 0, 1, \dots, L \quad (2)$$

式中: \mathbf{H} 为节点特征矩阵, f 表示激活函数, \mathbf{A}'' 表示规范化后的邻接矩阵, L 表示图卷积层数量。

$$\mathbf{A}'' = \mathbf{D}^{-\frac{1}{2}} \tilde{\mathbf{A}} \mathbf{D}^{-\frac{1}{2}} \quad (3)$$

$$\tilde{\mathbf{A}} = \mathbf{A} + \mathbf{I}_N \quad (4)$$

其中, $\tilde{\mathbf{A}}$ 是在邻接矩阵的基础上增加一条自连接边,以保留自身信息,增强自身信息表达能力, \mathbf{D} 为节点度矩阵^[24]。

当激活函数如式(1)所示时,GCN 卷积层间信息传递规则为:

$$f(\mathbf{H}^{(i)}, \mathbf{A}''^i) = \text{LeakyReLU}(\mathbf{A}''^i \mathbf{H}^{(i)} \mathbf{W}^{(i)}) \quad (5)$$

式中: \mathbf{W} 表示可训练的学习权重矩阵。

式(5)将规范化的邻接矩阵 \mathbf{A}'' 与输入节点特征矩阵 $\mathbf{H}^{(i)}$ 、权重矩阵 $\mathbf{W}^{(i)}$ 相乘,再经过非线性激活函数变化得到下一个图卷积层的输入数据。将式(3)代入式(5)可得:

$$f(\mathbf{H}^{(i)}, \mathbf{A}''^i) = \text{LeakyReLU}(\mathbf{D}^{-\frac{1}{2}} \tilde{\mathbf{A}} \mathbf{D}^{-\frac{1}{2}} \mathbf{H}^{(i)} \mathbf{W}^{(i)}) \quad (6)$$

可见,整个训练过程是将规范化的邻接矩阵与节点特征矩阵做内积,再乘以学习权重矩阵,最后进行激活函数的非线性变化,得到特征提取结果。

作为卷积神经网络在非欧空间的一种扩展,GCN 不仅能通过图卷积层自适应提取图结构中的高维特征,还能考虑拓扑间的连接关系,特别适于处理图数据^[25]。应用 GCN 不但可利用图卷积架构建立电力系统数据与节点状态之间映射关系,同时还能考虑节点间的拓扑信息,将自身节点特征融合更新当前节点特征,从而能更全面地获取电力系统信息。并且,它能充分考虑配电网的物理连接关系,根据线路运行状态划分出不同类别而实现故障定位,提升定位准确率。

1.2 GraphSAGE 算法

一旦配电网结构改变,GCN 需对整张图形重新学习以更新节点特征,资源消耗巨大。GSA 算法是在 GCN 基础上对聚合方式进行扩展而形成,遇到配电网结构改变时,GSA 可采用归纳学习的方式,将对已有拓扑图进行学习模型应用于改变拓扑图的节点标签预测。GSA 算法的学习流程如图 2 所示。

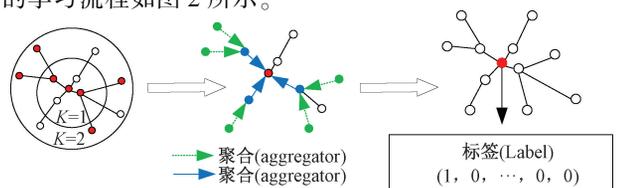


图 2 GSA 算法的学习流程

Fig. 2 The learning process of GSA algorithm

GSA 算法的学习过程主要包括了采样和聚合两部分。采样阶段,首先选取一个中心点,然后随机选取该点一阶邻域($K=1$),再以邻域节点为起点随机选择它们的一阶邻域($K=2$),迭代次数增加后,将获取越来越多的图远端节点信息;聚合阶段,从边缘的节点开始,向中心一层一层地更新节点信息,利用邻域节点信息更新目标节点信息。图 2 中,虚线箭头表示从最外层向中间层聚合,实线箭头表示中间层向中心节点聚合。最后,根据邻域节点信息得出中心节点特征,图 2 中用标签表示中心节点特征。

GSA 算法核心在于聚合邻域节点的方法。文献[16]中提出了 3 种聚合函数,分别是平均聚合、最大池化聚合和 LSTM 聚合。本文采用最大池化聚合方式,该聚合方式先对上一层每个节点的信息进行非线性激活,然后对所得结果进行最大池化操作。其实现过程如下:

$$H_v^k = \max(\sigma(W_{\text{pool}} \cdot H_{u_i}^k + b)) \quad (7)$$

式中: b 为偏置常数, σ 表示激活函数,pool 表示池化操作。

可见,GSA 并不局限于学习每个节点的特征表示,而是学习一类聚合器,从而提升了模型的泛化能力与收敛速度。并且,GSA 注重通过不同的聚合方式完成邻域节点对中心节点信息更新,以归纳的方式对不可见节点进行聚合^[26],提升了算法的学习能力。当配电网拓扑发生改变或拓扑中加入新的节点时,可以根据聚合直接给出学习结果,无需对整个网络重新迭代。对拓扑内增加新节点甚至新拓扑进行表征学习和分类预测无需重复训练模型,增加了模型的泛化能力,提升算法性能。

文献[16]中还指出,GSA 算法对于稀疏图处理能保持较高的精度并能显著降低训练和推断计算复杂度。配电网常用结构为辐射状,大部分节点仅有上下游之间的连接,是一种典型的稀疏图,采用 GSA 算法学习故障特征实现故障定位有着自然的优势。

2 基于电压黑帽运算结果的故障启动判据

利用数学形态学的黑帽运算对输入信号进行处理,能增强输入信号的突变特征。因此,本文考虑以数学形态学处理电源母线侧电压的时序信号,并将计算结果作为配电网故障的启动判据。

2.1 数学形态学

数学形态学(mathematical morphology, MM)本质上是采用集合论的方法对集合进行加、减和取最大值运算^[27],利用特定结构单元与图像相互运算,提取图像的形态特征。其中的形态黑帽运算可以有效突出边缘信息,对应一维函数信号的突变。

腐蚀和膨胀是数学形态学计算的基础,其他所有运

算都是基于这两个操作的组合或级联^[28]。

膨胀运算:

$$(X \oplus S)(m) = \max(X(m-n) + S(n)), m-n \in D_x \quad (8)$$

腐蚀运算:

$$(X \ominus S)(m) = \min(X(m+n) - S(n)), m+n \in D_x \quad (9)$$

其中, $X(m)$ 为输入信号,其定义域为 D_x ; $S(n)$ 为特定结构单元,其定义域为 D_s , 并 $D_s \subseteq D_x$; m, n 分别为输入信号和特定结构单元的采样点序号。

可见,利用 $S(n)$ 扫描 $X(m)$ 即实现了上述膨胀和腐蚀运算。形态学中,开运算是对输入信号先腐蚀后膨胀处理:

$$X \circ S = (X \ominus S) \oplus S \quad (10)$$

闭运算是对信号先膨胀后腐蚀处理:

$$X \cdot S = (X \oplus S) \ominus S \quad (11)$$

由此,得到形态学黑帽运算公式:

$$E = \text{blackhat}(X, S) = X \cdot S - X \quad (12)$$

其中,特定结构单元 S 采用扁平状结构:

$$S = \{1, 1, 1\} \quad (13)$$

2.2 黑帽运算结果

图 3 为 IEEE33 节点配电系统的拓扑示意图,电压等级 10 kV。其中虚线表示联络备用线,在原始拓扑中未连接。为更接近于实际情况,在网络末端接入了分布式电源,电源中性点采用谐振接地运行方式,并将消弧线圈过补偿度设置为 5%。

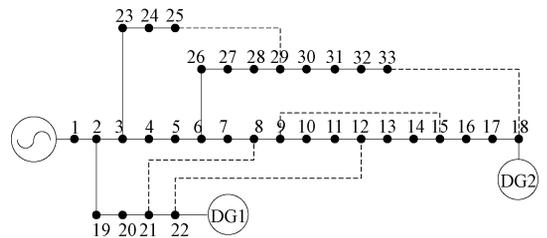


图 3 IEEE33 节点系统模型

Fig. 3 The IEEE 33 model

以节点 5、6 间线路在 2 s 时发生 A 相单相接地故障为例分析。当故障为近乎于金属性接地(接地点过渡电阻 $R_g = 0.01 \Omega$) 时,系统首端节点 1 处非故障相(B、C 相)电压的波形和黑帽计算结果如图 4 所示,显见计算结果在故障时刻未有明显变化;同时,该处的故障相(A 相)电压波形的黑帽计算结果如图 5(a) 所示,其在故障发生时刻有明显的突变。

上述故障点,当接地点过渡电阻不同时分别求取系统首端节点 1 处的故障相电压的黑帽运算结果,如图 5 所示。可见,一旦网络中发生接地故障,系统侧故障相电

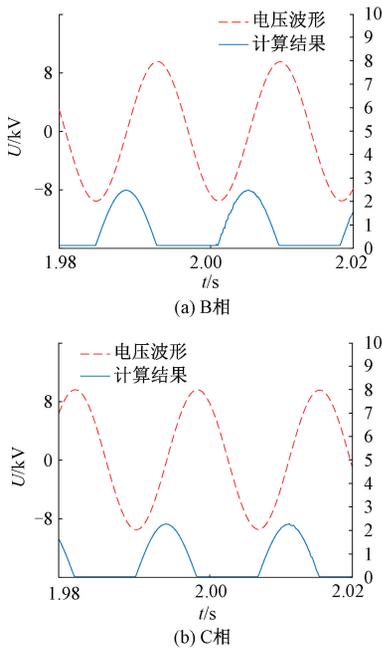


图 4 网络首端的非故障相电压及其形态学黑帽运算结果
Fig. 4 The non-fault phase voltage at the head of the network and its morphologic black hat results

压幅值会有所下降,但当故障点过渡电阻阻值增大时,电压波形的变化变得不很明显,但其形态学黑帽计算获得输出结果在故障发生时刻仍有明显突变,表明仍可通过其对单相接地故障实现有效检测,进而有效启动故障定位算法。

3 基于 GSA 算法的配电网故障定位方案

3.1 定位方案设计

设计基于 GSA 算法的配电网故障定位方案,工作流程如下:

- 1) 基于配电网电源侧母线电压的形态学黑帽运算结果,检测是否有配电线路发生单相接地故障,实现故障启动;
- 2) 启动故障定位方案,以零序电流和拓扑邻接矩阵作为定位模型输入,基于 GSA 算法判断每条线路的运行状态;
- 3) 根据各配电线路运行状态,定位故障线路。

3.2 输入和输出

GSA 的输入与 GCN 相同,包含邻接矩阵 A 和特征矩阵 X ,其邻接矩阵表示配电网的拓扑连接关系,其特征矩阵则表示节点的电气信息。

从图论出发,当不考虑内部元件与线路特性时,可将配电网抽象为节点与边的图结构^[18]。当以配电网中的

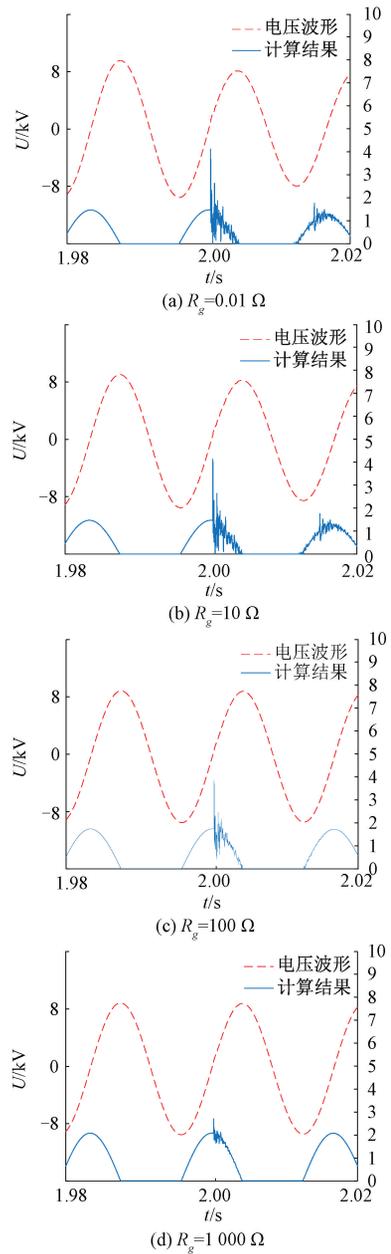


图 5 网络首端的故障相电压及其形态学黑帽运算结果
Fig. 5 The fault phase voltage at the head of the network and its morphologic black hat results

电缆或架空线路作为图中的连接边时,各节点的特征向量表示为:

$$\mathbf{x} = [I_{1zero}, I_{2zero}, \dots, I_{Nzero}]^T, X \in R^{N \times M} \quad (14)$$

其中, \mathbf{x} 为节点特征向量,支路零序电流作为支路首端节点的特征向量, N 表示节点个数, I_{Nzero} 包含该节点的 M 个采样点时序数据,本文取 $M=40$ 。

在实际中对于电缆线路可以采用零序电流互感器采集零序电流,而架空线路采用三相电流互感器采集三相电流再计算零序电流。

图 6 为一包含拓扑连接信息和某一采样周期内各线路输出标签信息的简单配电网络示意图。其中,图的节点即为电气节点,用数字 1~8 表示;各线路的输出状态以 0、1 表示,0 表示该线路运行正常,1 表示该线路存在故障。输出标签为 $\{0,0,0,0,0,1,1\}$ 时,代表节点 3、4 和节点 6、7 间线路发生故障,其他线路正常运行。

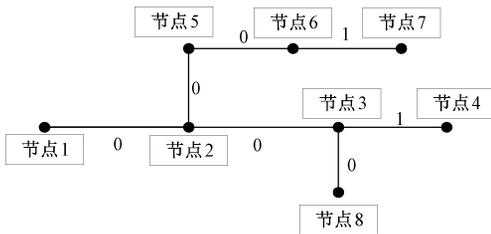


图 6 某采样周期内配电网拓扑标签

Fig. 6 Topology and its label data within a certain sampling period of a distribution network

3.3 训练与测试

基于 GSA 的配电网故障定位方案中,GSA 模型训练流程如图 7 所示。以图 3 所示 IEEE33 标准节点配电网仿真模型为研究对象,该系统共有 33 个节点,32 条线路,对其中每条线路设定发生单相接地故障,获取故障数据以构建训练测试所需的数据资源。采样频率为 1 kHz,共采集 2 000 个样本,按 8 : 1 : 1 的比例划分训练集、验证集和测试集。

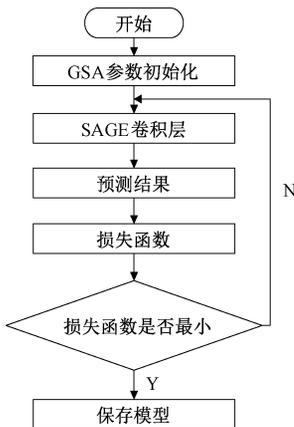


图 7 GSA 模型训练流程

Fig. 7 Flow charts of the GSA model training

由于样本中故障线路远少于正常运行线路,故采用带权重的损失函数,增加故障样本权重:

$$\text{Loss} = -\frac{1}{t} [w_j \log(p_j) + (1 - w_j) \log(p_k)] \quad (15)$$

式中: t 为单次训练的线路数量, w_j 为正常样本的权重, $(1-w_j)$ 为故障样本权重, p_j, p_k 分别是判断为正常样本和故障样本的概率值。

GSA 模型与 GCN 模型对比的训练过程如图 8 所示,可见,GSA 模型的损失函数计算结果更低。

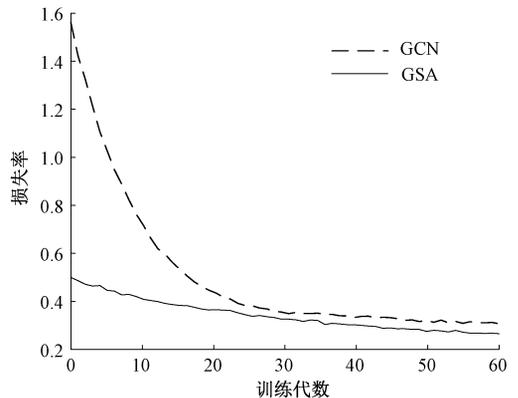


图 8 模型训练过程

Fig. 8 Training process of GSA and GCN Model

3.4 模型评价

采用 F1-score 来对配网故障定位方法进行评估,计算公式为:

$$\begin{cases} F_1 = 2 \frac{pr}{p+r} \\ p = \frac{T_1}{T_1 + T_2} \\ r = \frac{T_1}{T_1 + T_3} \\ F_{1-ave} = \frac{\sum F_1}{N} \end{cases} \quad (16)$$

式中: T_1 表示正确预测样本; T_2 表示所有待测样本; T_3 表示正样本但预测结果为负样本; N 表示测试样本总个数。

本文对每个测试样本求 F1-score,再求平均值评判测试集的定位精度,F1-score 兼顾精确度 (p) 和召回率 (r),并考虑了配电网中故障样本和非故障样本的不平衡性,F1-score 的值越大则故障判别精度越高,模型性能越好。

4 方案对比与验证

4.1 与机器学习方法的对比

采用卷积神经网络 (convolutional neural network, CNN)、多层感知机 (multi-layer perceptron, MLP) 和图神经网络中 GCN 和 GSA 算法实现配电网单相接地故障定位。这些机器学习方法的模型参数与输入量如表 1 所示,各模型训练时间及定位效果如表 2 所示。并且,表 1 中参数为经过搜索后的最优参数组合。

表 1 CNN, MLP, GCN 和 GSA 模型的最优参数组合

Table 1 Optimal parameter combination of CNN, MLP, GCN and GSA models

模型	学习率(lr)	最大迭代次数	Batch_size	dropout	输入量
CNN	0.01	80	64	0.5	X
MLP	0.01	80	64	0.6	X
GCN	0.005	80	64	0.6	X,A
GSA	0.005	80	64	0.6	X,A

表 2 基于 CNN、MLP、GCN 和 GSA 的定位模型对比

Table 2 Comparison of the fault location models based on CNN, MLP, GCN and GSA

模型	单相接地故障定位精度/%	训练时间/s
CNN	92.68	46.87
MLP	92.41	27.85
GCN	94.04	76.91
GSA	97.06	57.09

可见,GSA 模型虽然训练时间略长于其他 3 种算法,但定位准确率为最高。CNN 和 MLP 模型因其输入特征并不包含图拓扑信息,网络更新计算相对简单,故训练时间较短;但这两种模型虽在单相接地故障定位时也有较好的定位精度,可一旦拓扑有变化,模型原有定位功能基本失效,必须重新花费时间再训练,这部分将在 4.4 节中介绍。

4.2 图神经网络方法的适应性分析

1)对故障点过渡电阻的适应性

以 IEEE33 节点系统为例,增大线路发生接地故障时的过渡电阻,在弱故障特征情况下进一步验证本文算法,并将其与基于 GCN 算法模型的适应性进行对比,结果如表 3 所示。

表 3 基于 GCN 和 GSA 定位模型的过渡电阻适应性对比

Table 3 Comparison of the fault location models based on GCN and GSA when R_g is different

模型	$R_g = 100 \Omega$ 接地故障	$R_g = 1\ 000 \Omega$ 接地故障
GCN	93.97%	92.97%
GSA	96.25%	95.36%

可见,故障点过渡电阻增大后,虽然线路故障电流与正常运行电流的差异减小,但基于 GSA 算法的定位模型仍保持较高的故障定位精度。

2)对噪声及采样不同步的适应性

对采集的单相接地故障数据加入 20 dB 高斯白噪声,对不同模型的抗噪性能进行评估结果如表 4 所示。

表 4 中,两种图神经网络模型均能对噪声具有良好的适应性,保持较高的定位准确率。

表 4 噪声情况下基于 GCN 和 GSA 定位模型的对比

Table 4 Comparison of the fault location models based on GCN and GSA when it is noisy

模型	20 dB 噪声干扰
GCN	93.19%
GSA	96.97%

考虑采样不同步对模型性能的影响。在故障样本中随机选取 1~3 个节点,延迟半个周波采集其零序电流信号,此时模型定位结果如表 5 所示。从表中可以看出部分节点数据延时采样后对模型的定位精度基本没影响,这是因为 GSA 模型能从邻域节点聚合表示中心节点,作为中心节点的信息补充,当延时采样导致部分数据不完整时,模型仍能保持较高的定位精度。

表 5 采样延迟时基于 GCN 和 GSA 定位模型的对比

Table 5 Comparison of the fault location models based on GCN and GSA when sampling is delay

延时采样节点数/个	定位精度/%
1	97.29
2	96.82
3	96.73

4.3 对电弧性故障的定位性能

单相接地故障常以电弧接地形式出现,电弧接地故障具有非线性电阻接地的特点^[29-30],Emanuel 电弧模型^[31]如图 9 所示。

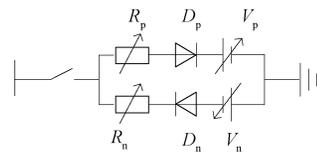


图 9 Emanuel 模型

Fig.9 Emanuel model

将上文中单相接地故障改为 Emanuel 电弧故障,其参数如表 6 所示,分别采用基于 GCN 和 GSA 算法的定位模型实现故障定位,定位精度如表 7 所示。

表 6 Emanuel 模型参数设置

Table 6 Parameter settings of the Emanuel model

参数	数值	参数	数值
R_p/Ω	5~10	V_p/kV	1.2~1.5
R_n/Ω	5~10	V_n/kV	1.2~1.5

对电弧故障的定位结果表明,基于图神经网络算法的定位模型对于电弧类非线性阻值接地故障定位准确性仍能保持较高水平,且 GSA 算法模型能更能胜出一筹。

表 7 基于 GCN 和 GSA 定位模型对电弧故障定位性能对比

Table 7 Comparison of the fault location models based on GCN and GSA under arc faults

模型	电弧故障
GCN	91.03%
GSA	95.41%

4.4 当拓扑变化时的定位性能

改变投切线路来变化网络拓扑,再利用上述已经训练好的模型来检验其对新拓扑中发生故障的定位精度。图 3 所示拓扑,以联络备用线连接节点 12、22 并断开节点 6、11 间连接,设置为拓扑 2;将节点 25、29 间通过联络备用线连接,断开线路 T6_26、T26_27、T27_28 和 T28_29,连接节点 9、15,并断开节点间原连接线路,设置为拓扑 3。对拓扑 2 和拓扑 3,分别利用已经训练好的基于 GCN 和 GSA 算法的定位模型对新拓扑进行故障定位,并进一步与基于 CNN 和 MLP 的定位模型进行对比,结果如表 8 和图 10 所示。

表 8 拓扑变化后的各类模型定位性能对比

Table 8 Comparison of these fault location models after topology changes (%)

模型	原拓扑	变化后的拓扑 2	变化后的拓扑 3
CNN	94.04	75.31	71.20
MLP	90.82	67.62	69.67
GCN	96.56	83.92	80.38
GSA	97.60	94.93	93.30

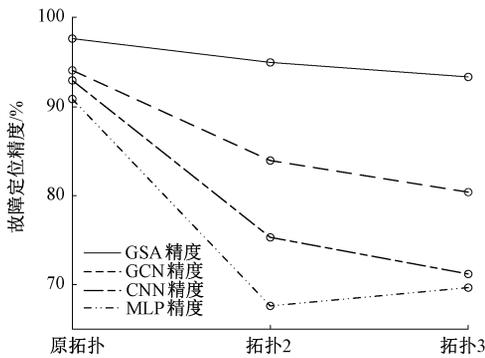


图 10 不同定位模型在拓扑变化时的定位精度
Fig. 10 Location accuracy of these fault location models under different topology

从表 8 和图 10 中可以看出,基于 CNN、MLP 的定位模型,其特征学习只有用在拓扑不变的配电网时才有较高的准确率,由于此类模型并未融入节点连接关系,一旦拓扑变化,两种算法的定位功能基本失效;将已训练好的 GCN 模型用在拓扑改变的情况下进行故障定位,准确率亦有大幅降低;但是基于 GSA 算法的故障定位模型,因

算法自身的特点较好地适应了拓扑变化,在拓扑改变的情况下仍保持了较高的故障定位准确率。可见,GSA 算法适合于拓扑变化情况下的故障定位任务,只需将初始拓扑作为训练集,无需重复训练模型,在拓扑改变时仍保持较高准确率。

尽管 GCN 在融合拓扑结构和节点信息方面的表现出色,但在处理未经训练的新拓扑时,故障定位精度会下降,主要因为它对有训练过的拓扑结构依赖性较强;GSA 算法通过节点采样和聚合生成节点的特征表示,这种采样和聚合方式使 GSA 能够更灵活地适应不同拓扑的特征,能更好地适应拓扑变化,有效提升了其对未知拓扑应用时的泛化性能,在应对未经训练的新拓扑时更具优势。

4.5 实验验证

以图 11 所示配电网物理仿真实验系统获得实验数据,验证所提算法有效性。

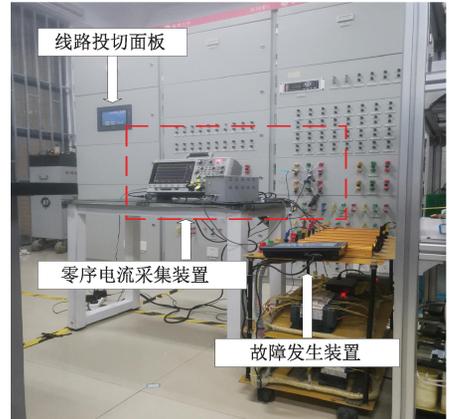


图 11 物理仿真实验系统

Fig. 11 The physical simulation system

实验系统所模拟 10 kV 配电网拓扑如图 12 所示。

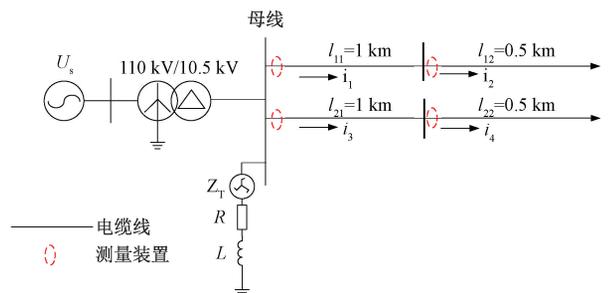


图 12 配电网实验模型

Fig. 12 Distribution network experiment model

该物理仿真系统线电压为 380 V,馈线采用 π 型等效模型,按与 10 kV 系统等效的原则设计线路参数^[32],如表 9 所示。设定不同的故障位置、类型、接地阻值,故

障的配置信息如表 10 所示,分别开展实验模拟故障场景,共采集 96 个故障样本进行测试,算法定位结果如表 11 所示。

表 9 物理仿真系统的线路参数

Table 9 Line parameters of the physical simulation system

线路类型	线路阻抗/ Ω	线路电感/mH	对地电容/ μF
架空线路(0.5 km)	0.54	0.255	0.035
架空线路(1 km)	1.08	0.510	0.070

表 10 故障配置参数

Table 10 Failure configuration information

配置类型	参数	数量
故障位置	区段 1、2、3、4	4
故障类型	(A/B/C)G	3
故障电阻	0、10、50、100、200、500、700、1 000	8

表 11 实验定位精度

Table 11 Experimental location accuracy

模型	定位精度/%
CNN	83.54
MLP	86.11
GCN	88.89
GSA	91.67

可见,虽然 4 种模型应用实验数据时的故障定位结果较使用仿真数据时均有所下降,但本文提出基于 GSA 算法的配电网故障定位模型仍有较高的准确率。究其原因在于 GSA 模型确实能更准确地提取电气与拓扑特征,而根据所提取特征信息定位故障所在位置。

5 结 论

本文基于 GraphSAGE(GSA)算法设计配电网故障定位方法。该方法利用数学形态学黑帽运算增强突变边缘特征以有效检出故障发生时刻;以图神经网络提取节点特征,实现故障线路定位。完成训练后的定位模型不但可以良好应对短路点过渡电阻变化、采样不同步、存在噪声影响及电弧型故障,并在拓扑变化的网络中获得了较好的定位效果。IEEE33 节点配电网模型被用于验证本文提出算法的性能,过仿真分析与实验验证可得如下结论:

1)形态学黑帽运算能增强数据突变特征,能更有效检测出故障发生时刻,准确地启动故障定位算法;

2)基于 GSA 算法的配网故障定位方法,基本不受故障点过渡阻抗和噪声干扰、采样延迟的影响,具有良好的鲁棒性;对电弧类非线性阻值接地故障的定位仍然发挥

稳定;此外,其对中心节点的信息聚合方式,使它在配电网拓扑发生变化后即使并未重新训练模型仍可保持较高的故障定位准确率。

3)本文 GSA 模型通过了配电网物理仿真实验系统的实验数据验证,模型性能发挥稳定,为实际应用奠定了优良基础。

参考文献

- [1] 葛少云,张成昊,刘洪,等.考虑微能源网支撑作用的配电网弹性提升策略[J].电网技术,2019,43(7):2306-2317.
GE SH Y, ZHANG CH H, LIU H, et al. Resilience enhancement strategy for distribution network considering supporting role of micro energy grid [J]. Power System Technology, 2019, 43(7): 2306-2317.
- [2] 洪翠,付宇泽,郭谋发,等.改进多分类支持向量机的配电网故障识别方法[J].电子测量与仪器学报,2019,33(1):7-15.
HONG C, FU Y Z, GUO M F, et al. Improved multi-class support vector machine based fault identification method for distribution network[J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(1): 7-15.
- [3] 袁川来,廖庸邑,孔玲爽,等.时间约束的改进分层模糊 Petri 网的配电网故障诊断方法[J].电子测量与仪器学报,2020,34(3):126-134.
YUAN CH L, LIAO Y Y, KONG L SH, et al. Improved hierarchical fuzzy Petri net with temporal constraints for distribution network fault diagnosis [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(3): 126-134.
- [4] 刘科研,董伟杰,肖仕武,等.基于电压数据 SVM 分类的有源配电网故障判别及定位[J].电网技术,2021,45(6):2369-2379.
LIU K Y, DONG W J, XIAO SH W, et al. Fault identification and location of active distribution network based on SVM classification of voltage data [J]. Power System Technology, 2021, 45(6): 2369-2379.
- [5] 童晓阳,张绍迅.基于灰色关联度的配电网故障区段定位与类型识别方法[J].电力系统自动化,2019,43(4):113-118,145.
TONG X Y, ZHANG SH X. Grey relational degree based fault section location and type recognition method for distribution network [J]. Automation of Electric Power Systems, 2019, 43(4): 113-118,145.
- [6] 刘科研,叶学顺,李昭,等.基于多分辨率小波变换的配电网高阻接地故障检测方法[J].高电压技术,2023,49(10):4247-4256.
LIU K Y, YE X SH, LI ZH, et al. Detection method of

- high resistance grounding fault in distribution network based on multi-resolution wavelet transform [J]. *High Voltage Engineering*, 2023, 49(10): 4247-4256.
- [7] POURBABAEE B, ROSHTKHARI M J, KHORASANI K. Deep convolutional neural networks and learning ECG features for screening paroxysmal atrial fibrillation patients [J]. *IEEE Transactions on Systems, Man & Cybernetics: Systems*, 2018, 48(12): 2095-2104.
- [8] 刘畅宇, 王小君, 尚博阳. 基于渐进式认知发现的新型配电网故障定位方法[J/OL]. *高电压技术*: 1-12.
LIU CH Y, WANG X J, SHANG B Y. Detection method of high resistance grounding fault in distribution network based on multi-resolution wavelet transform [J/OL]. *High Voltage Engineering*: 1-12.
- [9] 和敬涵, 罗国敏, 程梦晓, 等. 新一代人工智能在电力系统故障分析及定位中的研究综述[J]. *中国电机工程学报*, 2020, 40(17): 5506-5516.
HE J H, LUO G M, CHENG M X, et al. A research review on application of artificial intelligence in power system fault analysis and location [J]. *Proceedings of the CSEE*, 2020, 40(17): 5506-5516.
- [10] LI J M, CHU S C, SHAO X, et al. A single-phase-to-ground fault location method based on convolutional deep belief network [J]. *Electric Power Systems Research*, 2022, 209: 108044.
- [11] 侯思祖, 郭威, 王子奇, 等. 基于小波 AlexNet 网络的配电网故障区段定位方法[J]. *电测与仪表*, 2022, 59(3): 46-57.
HOU S Z, GUO W, WANG Z Q, et al. Fault segment location method for distribution network based on wavelet AlexNet network [J]. *Electrical Measurement & Instrumentation*, 2022, 59(3): 46-57.
- [12] 郭梦轩, 管霖, 苏寅生, 等. 基于改进边图卷积网络的电力系统小干扰稳定评估模型[J]. *电网技术*, 2022, 46(6): 2095-2103.
GUO M X, GUAN L, SU Y SH, et al. Small-signal stability assessment model based on improved edge graph convolutional networks of power system [J]. *Power System Technology*, 2022, 46(6): 2095-2103.
- [13] 李佳玮, 王小君, 和敬涵, 等. 基于图注意力网络的配电网故障定位方法[J]. *电网技术*, 2021, 45(6): 2113-2121.
LI J W, WANG X J, HE J H, et al. Distribution network fault location based on graph attention network [J]. *Power System Technology*, 2021, 45(6): 2113-2121.
- [14] SCARSELLI F, GORI M, TSOI A C, et al. The graph neural network model[J]. *IEEE Transactions on Neural Networks*, 2009, 20(1): 61-80.
- [15] THOMAS N K, MAX W. Semi-supervised classification with graph convolutional networks [J]. *Statistics*, 2016, 2.
- [16] HAMILTON W L, YING R, LESKOVEC J. Inductive representation learning on large graphs [J]. *Statistics*, 2017.
- [17] VELIČKOVIĆ P, CUCURULL G, CASANOVA A, et al. Graph attention networks [J]. *arXiv preprint arXiv: 1710.10903*, 2017.
- [18] 贾惠彬, 李明舒, 张国云. 一种基于图论剪枝算法的多分支配电网行波故障定位算法[J]. *电测与仪表*, 2017, 54(1): 27-32.
JIA H B, LI M SH, ZHANG G Y. A traveling wave fault location method for distribution network based on pruning algorithm and graph theory [J]. *Electrical Measurement & Instrumentation*, 2017, 54(1): 27-32.
- [19] 杨华, 李喜旺, 司志坚, 等. 基于图神经网络的配电网故障预测[J]. *计算机系统应用*, 2020, 29(9): 131-135.
YANG H, LI X W, SI ZH J, et al. Accident prediction of power distribution network based on graph neural network [J]. *Computer Systems & Applications*, 2020, 29(9): 131-135.
- [20] 陈源奕, 王玉彬, 杨强. 基于时空特征图卷积网络的配电网实时状态估计方法[J]. *高电压技术*, 2021, 47(7): 2386-2395.
CHEN Y Y, WANG Y B, YANG Q. Real-time state estimation method for distribution networks based on spatial temporal feature graph convolution network [J]. *High Voltage Engineering*, 2021, 47(7): 2386-2395.
- [21] CHEN C, LI Q, CHEN L, et al. An improved GraphSAGE to detect power system anomaly based on time-neighbor feature [J]. *Energy Reports*, 2023, 9: 930-937.
- [22] 洪翠, 邱仕达, 高伟. CEEMDAN 与 GCN 结合的配电变压器故障诊断[J]. *电子测量与仪器学报*, 2022, 36(12): 86-96.
HONG C, QIU SH D, GAO W. Fault diagnosis of distribution transformer based on CEEMDAN and GCN [J]. *Journal of Electronic Measurement and Instrumentation*, 2022, 36(12): 89-96.
- [23] PARK J. Physics-induced graph neural network: An application to wind-farm power estimation [J]. *Energy*, 2019, 187: 115883.
- [24] 陈立帆, 张琳琳, 宋辉, 等. 基于图卷积神经网络的输电线路自然灾害事故预测[J]. *电网技术*, 2023, 47(6): 2549-2557.
CHEN L F, ZHANG L L, SONG H, et al. Natural

- disaster accident prediction of transmission line based on graph convolution network [J]. Power System Technology, 2023, 47(6): 2549-2557.
- [25] 廖文龙, 于贇, 王煜森, 等. 基于图卷积网络的配电网无功优化[J]. 电网技术, 2021, 45(6): 2150-2160.
LIAO W L, YU Y, WANG Y S, et al. Reactive power optimization of distribution network based on graph convolutional network [J]. Power System Technology, 2021, 45(6): 2150-2160.
- [26] 贺苗苗, 郭卫斌. 基于 KNN 与矩阵变换的图节点嵌入归纳式学习算法[J]. 计算机科学, 2021, 48(3): 201-205.
HE M M, GUO W B. Inductive learning algorithm of graph node embedding based on KNN and matrix transform [J]. Computer Science, 2021, 48(3): 201-205.
- [27] 张运驰, 高厚磊, 袁通, 等. 突变量与形态学相结合的配电网故障时刻检测方法[J]. 电力系统保护与控制, 2022, 50(12): 54-62.
ZHANG Y CH, GAO H L, YUAN T, et al. A fault time detection method in a distribution network based on a sudden change of current and mathematical morphology [J]. Power System Protection and Control, 2022, 50(12): 54-62.
- [28] 郝颖, 冬雷, 王丽婕, 等. 基于数学形态学去噪的光伏发电电异常数据识别算法[J]. 中国电机工程学报, 2022, 42(21): 7843-7855.
HAO Y, DONG L, WANG L J, et al. An algorithm for identifying abnormal data of photovoltaic power cut-off based on mathematical morphology denoising [J]. Proceedings of the CSEE, 2022, 42(21): 7843-7855.
- [29] 任伟, 薛永端, 杨帆, 等. 中性点不接地配电网电弧接地故障建模与分析[J]. 电网技术, 2021, 45(2): 705-712.
REN W, XUE Y D, YANG F, et al. Modeling and analysis of arc grounding faults in isolated neutral distribution network [J]. Power System Technology, 2021, 45(2): 705-712.
- [30] 杨耿杰, 许晔, 高伟, 等. 基于能量谱相似度自适应聚类的配电网接地故障区段定位方法[J]. 电力自动化设备, 2021, 41(3): 25-32.
YANG G J, XU Y, GAO W, et al. Grounding fault section location method of distribution network based on adaptive clustering of similarities between energy spectra [J]. Electric Power Automaton Equipment, 2021, 41(3): 25-32.
- [31] EMANUEL A E, CYGANSKI D. High impedance fault arcing on sandy soil in 15 kV distribution feeders: Contributions to the evaluation of the low frequency spectrum [J]. IEEE Transactions on Power Delivery, 1990, 5(2): 676-686.
- [32] LIN J H, GUO M F, ZHENG Z Y. Active location method for single-line-to-ground fault of flexible grounding distribution networks [J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 1.

作者简介



洪翠(通信作者), 分别在 1994 年、2000 年和 2014 年于福州大学获得学士、硕士、博士学位, 现为福州大学副教授, 主要研究方向为配电网及其主设备故障诊断。

E-mail: hongcui@fzu.edu.cn

Hong Cui (Corresponding author) received her B. Sc., M. Sc., and Ph. D. degrees from Fuzhou University in 1994, 2000 and 2014, respectively. Now she is an associate professor in Fuzhou University. Her main research interests include fault diagnosis of distribution network and its main equipment.