

DOI: 10.19783/j.cnki.pspc.240021

基于一维卷积和图神经网络的配电网故障区段定位方法

何小龙¹, 高红均¹, 黄媛¹, 高艺文², 王仁浚¹, 刘俊勇¹

(1. 四川大学电气工程学院, 四川 成都 610065; 2. 国网四川省电力公司, 四川 成都 610041)

摘要: 快速、准确地定位故障区段对配电网的安全运行至关重要。传统故障定位方法容错率低、耗时长, 多数深度学习算法对拓扑变动的泛化性不足。基于此, 提出了一种基于一维卷积神经网络(one-dimensional convolutional neural network, 1D-CNN)和图神经网络(graph neural network, GNN)的配电网故障区段定位方法。该方法将配电网原始信息与 GNN 等深度学习算法相结合进行建模。首先利用基于注意力的时空图卷积网络从不同的时空尺度上对遥测数据进行故障特征提取, 使用图注意力网络来融合多源遥信数据。然后, 利用 1D-CNN 来调整特征输出维度以实现节点特征到故障支路的映射。最后, 通过增设全连接网络来输出故障区段定位结果。依托于 Matlab/Simulink 平台搭建 10 kV 中性点不接地配电网系统进行仿真和测试。结果表明, 所提方法具有优越的定位性能, 能够灵活适用于各类低、中、高阻性接地故障场景, 对系统拓扑变动具有强大的泛化能力以及对故障数据不完备的鲁棒性好。

关键词: 配电网; 故障区段定位; 一维卷积; 图神经网络; 拓扑变动; 数据不完备

Fault section location for a distribution network based on one-dimensional convolution and graph neural networks

HE Xiaolong¹, GAO Hongjun¹, HUANG Yuan¹, GAO Yiwen², WANG Renjun¹, LIU Junyong¹

(1. College of Electrical Engineering, Sichuan University, Chengdu 610065, China;
2. State Grid Sichuan Electric Power Company, Chengdu 610041, China)

Abstract: Quickly and accurately locating the fault section is crucial for the safe operation of a distribution network. Traditional fault location methods have low fault tolerance and take a long time, and most deep learning algorithms have insufficient generalization to topological changes. Thus a fault section location method for a distribution network based on a one-dimensional convolutional neural network (1D-CNN) and a graph neural network (GNN) is proposed. This method combines the original information of the distribution network with deep learning algorithms such as GNN for modeling. First, an attention-based spatial-temporal graph convolutional network (ASTCGN) is used to extract fault features from telemetry data at different temporal and spatial scales. The graph attention network (GAT) is used to fuse multi-source remote signaling data. Then, 1D-CNN is used to adjust the feature output dimension to realize the mapping of node features to fault branches. Finally, the fault section location results are output by adding a fully-connected network (FCN). A 10 kV neutral ungrounded distribution network system for simulation and testing is built based on the Matlab/Simulink platform. It is verified that the proposed method possesses superior positioning performance, can be flexibly applied to various low, medium, and high resistance grounding fault scenarios, and has strong generalizability to system topology changes and good robustness to incomplete fault data.

This work is supported by the National Natural Science Foundation of China (No. 52077146).

Key words: distribution network; fault section location; 1D-CNN; GNN; topology change; incomplete data

0 引言

配电网作为电力输送的最后一环枢纽, 其供电可靠性关乎着广大用户的用电质量^[1-2]。在配电网运

行过程中, 由于电气设备老化、外部干扰等引发电力故障, 导致供电中断^[3-4]。因此, 准确快速地定位故障对于保障供电可靠性和配电网安全运行具有重要意义。

目前国内外研究主要基于配电自动化技术, 通过采集馈线终端单元(feeder terminal unit, FTU)的遥信和遥测数据进行配电网故障区段定位^[5]。利用

基金项目: 国家自然科学基金项目资助(52077146); 四川省科技计划项目资助(2023NSFSC1945)

FTU 上传的遥测数据进行故障定位的方法主要有根据暂态零模电流偏态系数^[6]、暂态零序电流方向^[7]等电气量关系作为判据来定位故障区段。利用 FTU 上传的遥信数据进行故障定位的方法主要有矩阵算法^[8-9]和智能优化算法^[10-11]。当 FTU 上传数据发生畸变(误报或漏报)时,上述方法很容易出现误判或漏判的情况^[7,12]。当配电网发生故障时,除了 FTU 能够上传故障数据之外,配电变压器终端单元(transformer terminal unit, TTU)、故障指示器等监测设备也会将各自采集的故障数据上传至配电网主站。因此,不少学者提出了基于主站多源遥信数据融合的故障区段定位方法。文献[13]根据改进的 D-S 证据理论来融合故障指示器信息、配电变压器报警信息和用户停电投诉信息,建立相应的网络树状图进行故障定位。文献[14]利用 FTU 上传的过流信息和电压分布特征作为双层判据,根据断路器跳闸和终端过流信息来建立通用 Petri 网模型,通过托肯分布的变迁演化来确定故障区段。文献[15]建立网络树状图来描述具有子父节点关系的配电网拓扑结构,根据模糊集来分析各层节点的隶属度从而实现故障定位。上述方法可以将故障定位范围缩小至更精细的区段,但是运算较为繁琐,不利于快速定位故障区段。

随着电力一次和二次设备感知和量测技术的进步,以及通信系统的升级改造,打通了数据传输的接口壁垒,为配电网故障定位提供了多源丰富的数据资源^[16]。基于数据驱动的深度学习方法通过离线训练的方式进行故障特征与判别结果之间映射关系的非线性拟合,实现对故障区段的在线快速决策。文献[17]利用堆栈自编码器 and 长短期记忆网络(long short-term memory, LSTM)建立配电网故障定位模型,该模型对量测数据的需求不高,但需要通过迁移训练来提高拓扑泛化性能。文献[18]仅利用两个测点的电气量信号作为输入,建立起基于迁移学习和卷积神经网络相结合的配电网故障定位模型,对多种故障因素的影响具有良好的鲁棒性。但基于欧式空间数据挖掘的深度学习方法对数据质量的依赖性强,并且难以揭示空间维度信息,导致在保证定位准确率的同时难以兼顾对网络拓扑变动的泛化性^[13]。

针对上述问题,本文提出一种基于一维卷积神经网络(one-dimensional convolutional neural network, 1D-CNN)和图神经网络(graph neural network, GNN)的配电网故障区段定位方法。首先通过基于注意力的时空图卷积网络(attention based spatial-temporal graph convolutional network, ASTGCN)^[19]和图注意力网络(graph attention network, GAT)^[20]分别对可观

测节点的遥测和遥信数据进行数据挖掘,实现故障特征的提取与融合;然后利用 1D-CNN 对故障特征进行维度变换,完成建模对象从节点到边的调整;最后将故障特征通过全连接网络(fully-connected network, FCN)进行降维映射,从而输出故障区段定位结果。算例仿真实验结果表明,本文所提方法利用为数不多的可观测节点故障数据便可实现对故障区段的准确定位,并且能够有效应用于各类低、中、高阻性接地故障环境,以及对系统拓扑变动和故障数据不完备的泛化性强,与多种传统故障区段定位方法和数据驱动方法相比,本文方法具有更优越的性能。

1 配电网故障区段定位建模

1.1 多源故障信息

对于配电网的拓扑结构,数据采集与监视控制系统(supervisory control and data acquisition system, SCADA)可以满足全局拓扑可观性,配电网拓扑从变电站延伸至台区的区域能够实现完全辨识。如图 1 所示,配电网拓扑单线图中主要的电气运行设备或监测装置包括断路器、分段开关、配电变压器、故障指示器、联络开关等,线路则是由电缆线或架空线构成,通常在出口断路器和部分分段开关上安装 FTU 等量测装置,也在部分配电变压器上安装 TTU 以监视设备运行状态。

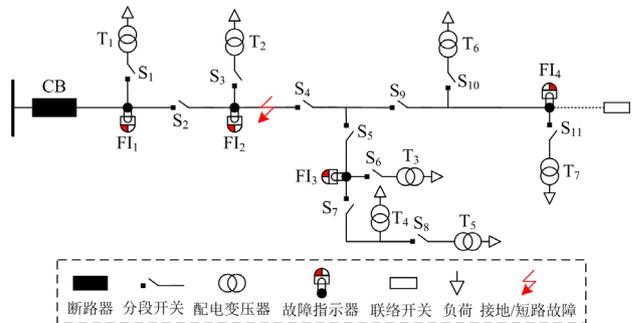


图 1 配电网拓扑单线图

Fig. 1 Distribution network topology single diagram

在配电网发生相间短路故障(以下简称短路故障)后,FTU 会对比提前设定好的阈值和所采集到的电流信号,判断电流是否越限,一旦越限则会以遥信形式产生过流信息;另一方面,开关保护装置动作也会以遥信形式产生过流保护动作信息。故障上游的开关跳闸以后,下游台区的配电变压器都会因失电而停电,配电变压器失电信息会通过 TTU 上传至配电网主站的用户信息采集系统^[21]。除此之外,具有“二遥”功能的暂态录波故障指示器在故障定

位中也发挥着重要作用。在发生短路故障后,从系统侧到故障点之间的线路都会流过短路电流,如果排除设备故障等因素,则该段线路上安装的故障指示器会检测到过流信息而产生翻牌亮灯动作,并就地采集录波数据上传至配电网主站。

我国中低压配电网普遍采取小电流接地运行方式,当发生单相接地故障(以下简称接地故障)时,电气运行设备的绝缘能够耐受由于非故障相对地电位升高所造成的冲击危害,在开关不跳闸的情况下留有一定的时间裕度来维持系统正常运行,所以通常而言,接地故障发生后可供上传的遥信数据较少。但是由于接地故障属于不对称故障,所以系统中会存在较为明显的零序电流,当故障指示器检测到零序电流突变量达到阈值后,随即触发录波并与配电网主站进行信息交互。因此主站可以主动分析故障指示器的录波数据来定位接地故障区段,另外还可以采集 FTU 的遥测数据进行辅助分析。

1.2 建模框架

配电网可以抽象成节点与边连接的图模型,其拓扑结构可以用邻接矩阵 A 进行描述,故可将配电网的原始信息用以图结构数据 $G(X, A)$ 进行表征,其中 X 为节点特征矩阵。将图 1 中的配电网转换成图模型拓扑,如图 2 所示,以断路器、分段开关、联络开关、故障指示器、配电变压器为节点,将配电网的电力线路划分为多个区段,各个区段进行编号标识。

本文将配电网原始信息 $G(X, A)$ 与 GNN 等深度

学习算法相结合进行故障区段定位建模,其整体框架如图 3 所示。本文利用 GNN 对配电网拓扑结构和多源故障信息进行特征提取,GNN 可以将拓扑信息嵌入到模型学习中,能够学习到节点特征和空间信息蕴含的深层次特征规律,因此与传统深度学习方法相比,GNN 对图结构数据异常甚至极端变化的鲁棒性更强^[22]。由于配电网电气量运行数据在时间和空间上存在强耦合关系,在时间维度上具有前后联系,所以本文采用 ASTGCN 对时序遥测数据进行数据挖掘,以此提取具有时空特性的故障特征;遥信数据均以离散数值的编码形式呈现,各变量之间不存在时间关联性,因此采用基于节点领域信息聚合的 GAT 来融合多源遥信数据。

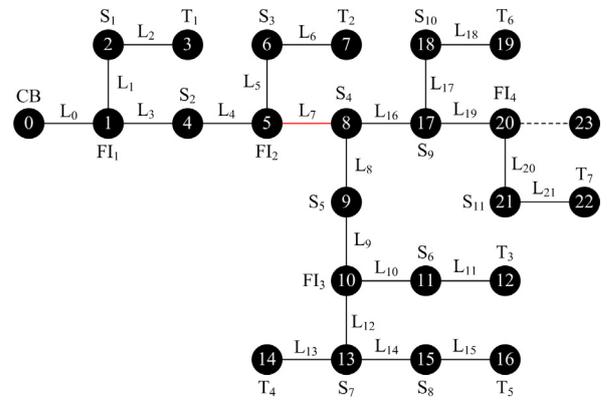


图2 配电网图模型拓扑

Fig. 2 Distribution network diagram model topology

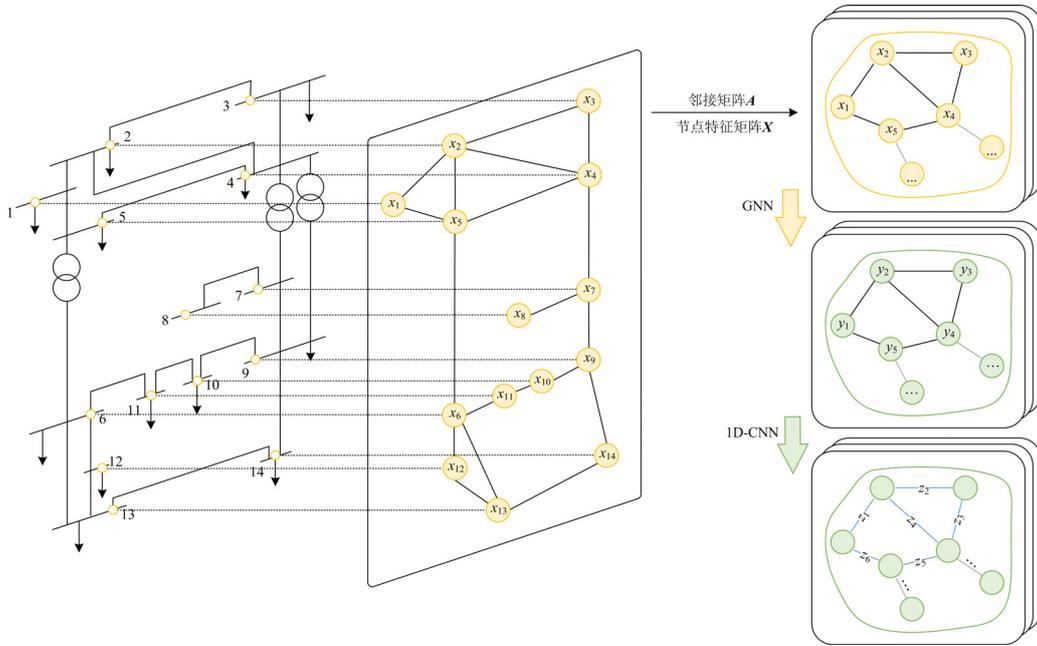


图3 故障区段定位建模框架

Fig. 3 Modeling framework for fault section localization

在现有绝大多数基于 GNN 实现配电网故障区段定位的研究中^[23-25]，均以特征提取后的节点信息作为故障区段的决策依据，而区段定位实则归属于边分类任务，而非节点分类任务，其建模对象应该向边的角度出发。因此本文利用具有强大非线性特征映射能力的 1D-CNN 将 GNN 提取的节点故障特征映射至边特征，以实现网络建模对象的调整。

2 配电网故障区段定位模型

2.1 基于 1D-CNN 和 GNN 的配电网故障区段定位模型设计

本文设计的基于 1D-CNN 和 GNN 的配电网故障区段定位模型如图 4 所示，该模型由故障特征提

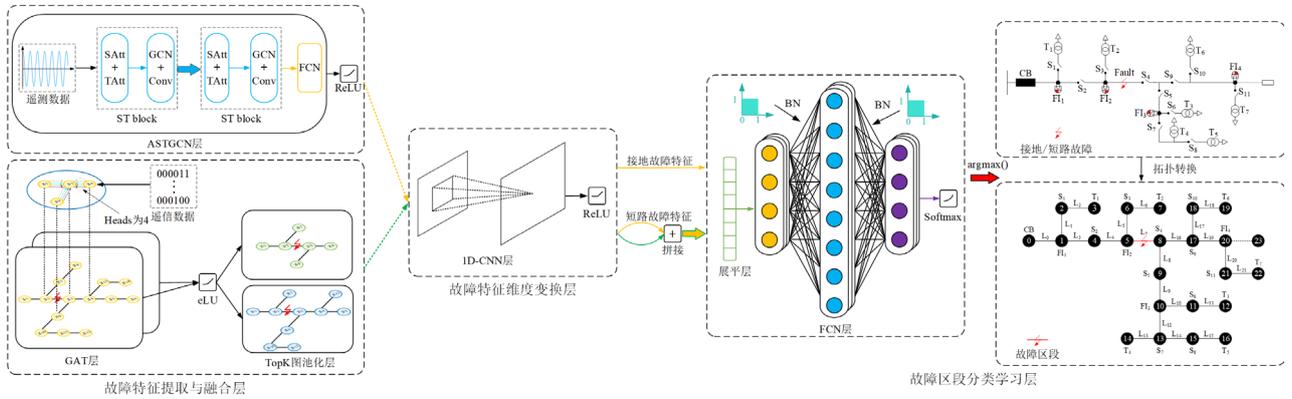


图 4 基于 1D-CNN 和 GNN 的配电网故障区段定位模型示意图

Fig. 4 Distribution network fault section location model diagram based on 1D-CNN and GNN

2.2 基于 GNN 的特征提取与融合层

2.2.1 时空注意力机制

ASTGCN 层由两个时空模块(spatial-temporal block, ST block)和一个 FCN 串联构成。ST block 包含时空注意力层(spatial attention, SAtt; temporal attention, TAtt)和时空卷积层(graph convolution, GCN; convolution, Conv)。在时间维度上，不同时间步的遥测数据之间存在前后相关性，采用注意力机制赋予遥测数据不同的权重，时间注意力矩阵 E 的表达式为

$$E = V_c \cdot \sigma((X^T \cdot U_1)U_2(U_3 \cdot X) + b_c) \quad (1)$$

式中： $X \in \mathbb{R}^{n \times c \times t}$ 为遥测数据，其中 n 为图的节点个数， c 为节点特征维度， t 为遥测数据的采样时间步数； $V_c \in \mathbb{R}^{n \times n}$ 和 $b_c \in \mathbb{R}^{n \times n}$ 分别为可学习的权重矩阵和偏置项； $U_1 \in \mathbb{R}^n$ 、 $U_2 \in \mathbb{R}^{c \times n}$ 、 $U_3 \in \mathbb{R}^c$ 为时间注意力层中可学习的线性变换矩阵； $\sigma(\cdot)$ 为激活函数。

在空间维度上，不同位置的电气节点之间具有很强的动态联系，利用注意力机制捕捉各节点之间

取与融合层、故障特征维度变换层、故障区段分类学习层这三大组成部分。在故障特征提取和融合层构建的 ASTGCN 层从不同时空尺度上提取遥测数据的故障特征，利用 GAT 融合多源遥信数据；在故障特征维度变换层中，为了将节点特征映射至故障支路，利用 1D-CNN 处理故障特征提取与融合层得到的序列数据，实现故障特征的维度变换；故障区段分类学习层主要起到对故障特征进行学习从而实现故障定位的作用，将调整维度后的故障特征展平并输入至 FCN 层进行故障区段映射的拟合，FCN 层的输出经 Softmax 函数激活后，分类得到故障定位结果。

的空间关联性，空间注意力矩阵 S 的表达式为

$$S = V_s \cdot \sigma((X \cdot E' \cdot W_1)W_2(W_3 \cdot X \cdot E')^T + b_s) \quad (2)$$

式中： E' 为经 Softmax 函数归一化后的时间注意力矩阵； $V_s \in \mathbb{R}^{n \times n}$ 和 $b_s \in \mathbb{R}^{n \times n}$ 分别为可学习的权重矩阵和偏置项； W_1 、 W_2 、 W_3 为空间注意力层中可学习的线性变换矩阵， $W_1 \in \mathbb{R}^n$ 、 $W_2 \in \mathbb{R}^{c \times n}$ 、 $W_3 \in \mathbb{R}^c$ 。

2.2.2 基于 ASTGCN 的时空故障特征提取

ASTGCN 的时空卷积结构如图 5 所示，输入的遥测数据经时空注意力机制动态调整后，采用切比雪夫多项式作为卷积核的图卷积方法来捕获遥测数据的空间相关性特征。图卷积方法的特征提取计算表达式为

$$X_{GCN} = \sigma\left(\sum_{k=0}^{K-1} \theta_k (T_k(2L/\lambda_{\max} - I_n) \odot S')X\right) \quad (3)$$

式中： $T_k(\cdot)$ 为 k 阶的切比雪夫多项式； K 为切比雪夫多项式的项数； θ_k 为多项式对应的系数向量； L 为图拉普拉斯矩阵； λ_{\max} 为 L 的最大特征值； I_n 为 n 阶单位矩阵；“ \odot ”为哈达玛积； S' 为经 Softmax 函数归一化后的空间注意力矩阵。

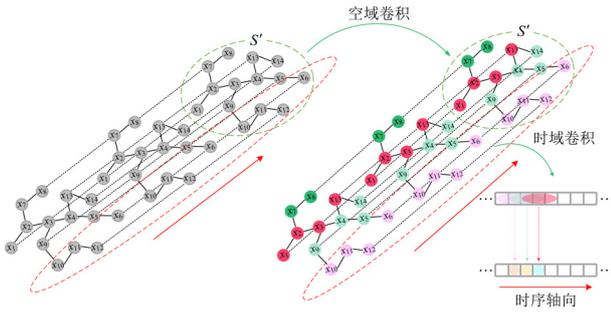


图5 ASTGCN的时空卷积结构

Fig. 5 Architecture of spatial-temporal convolution of ASTGCN

在空域卷积聚合邻域节点信息的基础上, 在时序轴向上引入二维卷积操作来合并邻近时间步的信息, 得到能够反映动态时空特性的序列特征 \mathbf{X}_{Conv} 。

$$\mathbf{X}_{\text{Conv}} = \sigma(\Phi \otimes \sigma(\mathbf{X}_{\text{GCN}})) \quad (4)$$

式中: “ \otimes ” 为二维卷积运算; Φ 为时域卷积核, 其滑动步长为 1。

将两个时空模块进行叠加, 进一步提取更具代表的动态时空关联性故障特征, 最后增加 FCN 环节以调整输出特征的维度。

2.2.3 基于 GAT 的多源遥信数据融合

GNN 在每一步迭代中将节点的特征向量更新为本身特征向量与其邻居节点特征向量的加权和, 从而实现了节点特征的传递。GAT 作为 GNN 主流的变体之一, 基于节点状态的不同, 通过引入注意力机制差异化地为邻域节点分配权重, 从而实现节点特征的聚合和更新, 相较于其他 GNN 的主流变体模型, 其具有更强的适应能力和灵活性。

GAT 的节点特征更新机制的具体过程如图 6 所示, 依次进行注意力系数计算和特征聚合操作。为表征节点和邻域节点之间的联系, 根据学习注意力权重的思想, 利用可训练的参数矩阵来学习节点与相邻节点的相关重要性。经过 Softmax 函数归一化后的节点 i 与邻域节点 j 的注意力系数 α_{ij} 计算表达式为

$$\alpha_{ij} = \frac{\exp(\text{Leaky ReLU}(\mathbf{a}^T [\mathbf{W}\mathbf{x}_i \parallel \mathbf{W}\mathbf{x}_j]))}{\sum_{g \in N(i)} \exp(\text{Leaky ReLU}(\mathbf{a}^T [\mathbf{W}\mathbf{x}_i \parallel \mathbf{W}\mathbf{x}_g]))} \quad (5)$$

式中: \mathbf{x}_i 为节点 i 的特征; g 表示节点 i 的邻域节点, $g \in N(i)$; Leaky ReLU 为非线性激活函数; \mathbf{a} 和 \mathbf{W} 分别为可学习的线性变换权重向量和权重矩阵; “ \parallel ” 表示拼接操作。

GAT 通过引入多头注意力机制对邻域节点信息进行聚合, 实现了节点特征更新权重矩阵的参数自适应匹配。如图 6 反映了在集成 3 个注意力机制

的条件下, 使用归一化后的注意力系数加权求和得到相应节点的线性组合特征, 该组合特征不仅包含节点自身特征还融合了所有邻域节点的特征, 第一层 GAT 采取拼接操作来完成对节点特征的更新, 如式(6)所示。

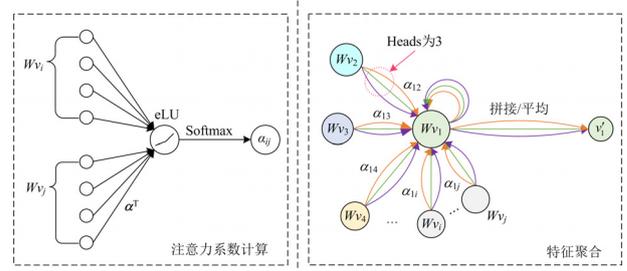


图6 GAT的节点特征更新机制示意图

Fig. 6 Node features update mechanism diagram of GAT

$$\mathbf{x}'_i = \left\| \sigma \left(\sum_{j \in N(i)} \alpha_{ij}^k \mathbf{W}^k \mathbf{x}_j \right) \right. \quad (6)$$

式中: K 为注意力机制数; α_{ij}^k 和 \mathbf{W}^k 分别为第 k 个注意力机制下的注意力系数和权重矩阵。

第二层 GAT 取平均操作, 如式(7)所示。

$$\mathbf{x}'_i = \sigma \left(\frac{1}{K} \sum_{j \in N(i)} \alpha_{ij}^k \mathbf{W}^k \mathbf{x}_j \right) \quad (7)$$

在每层 GAT 后加入 TopK 图池化层, 图 7 反映了在比率 α 为 0.5 下的 TopK 图池化示意图, 即根据各个节点的重要度值对原始图结构数据 $\mathbf{G}(\mathbf{X}, \mathbf{A})$ 按照一定的比率 α 进行切片操作, 最后只保留相对重要的节点。

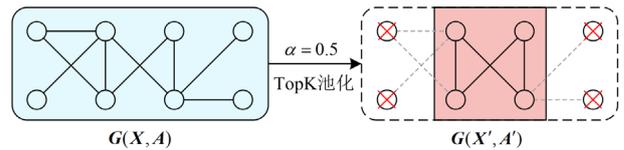


图7 TopK图池化示意图

Fig. 7 Diagram of TopK graph pooling

2.3 基于 1D-CNN 的故障特征维度变换层

1D-CNN 的输入通常为处理一维或多维(存在多个输入通道时)的序列数据, 通过一维卷积运算来实现特征提取和维度变换。图 8 为 1D-CNN 调整 GNN 提取出的故障特征维度的框架原理图。

在图 8 中, 故障特征 \mathbf{X} 作为 1D-CNN 的输入数据, $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_l]^T$ 且 $\mathbf{X} \in \mathbb{R}^{l \times c_1}$, 卷积核组 \mathbf{K} 由 c_2 个维度为 $h \times c_1$ 的卷积核堆叠而成, $\mathbf{K} \in \mathbb{R}^{c_2 \times h \times c_1}$, 输出特征 $\mathbf{X}' \in \mathbb{R}^{l_2 \times c_2}$, 其中 c_1 和 c_2 分别为输入数据和输出特征的通道数; l_1 和 l_2 分别为输入数据和输

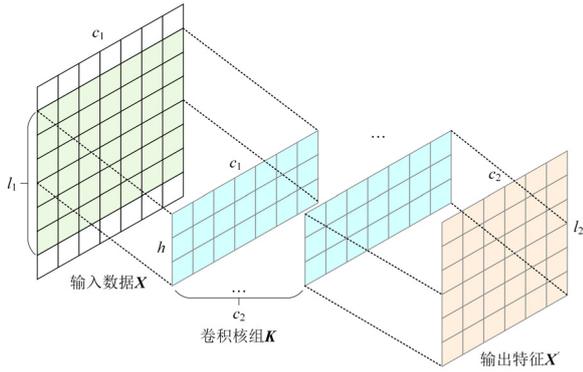


图 8 1D-CNN 框架原理图

Fig. 8 Schematic diagram of 1D-CNN framework

出特征的序列长度; h 为卷积核大小。整个 1D-CNN 运算过程可以概括为: 卷积核 K_i 沿着输入数据 X_i 序列轴向上滑动, 每次平移都会对相应序列窗内的元素进行加权求和, 然后对卷积运算后的数据进行非线性映射提取特征, 最后将各卷积核提取的特征 X'_i 进行拼接操作, 得到调整好的输出特征 X' 。序列数据经一维卷积的运算表达式^[26]为

$$\begin{cases} X'_i = \sigma(X_i * K_i + b_i), i = 1, 2, \dots, c_2 \\ X' = X'_1 \parallel X'_2 \parallel \dots \parallel X'_{c_2} \end{cases} \quad (8)$$

式中, “*” 表示一维卷积运算符。

为保证输出序列长度不变且特征维度对应为故障支路, 将卷积核滑动步长设置为 1, 在特征维度方向上首尾各增加一行零输入向量进行填充。

2.4 基于 FCN 的故障区段分类学习层

对于接地故障定位模型, FCN 层的输入仅包含维度变换后的时序故障特征, 对于短路故障定位模型, 将经过 1D-CNN 维度变换后的时序故障特征和离散故障特征拼接起来作为短路故障定位模型 FCN 层的输入, 为了符合 FCN 层的输入格式, 故障特征在送入 FCN 层之前需将其展平。将包含 3 个线性层的 FCN 作为故障定位模型的最后一环, 用于对提取到的高维故障特征映射至蕴含故障区段信息的低维空间进行分类学习。其中, 为了加速模型的收敛速度, 减少训练所消耗的时间成本, 在线性层中引入批量归一化(batch normalization, BN)模块, 标签为故障所在区段序号, 在输入优化器之前自动转换为所对应故障区段的 one-hot 编码, 最后一个线性层输出值经过 Softmax 函数后得到的最大激活值(argmax)即为故障定位结果。

3 算例验证

3.1 数据样本构造

本文根据四川省某地市供电公司的某条 10 kV

馈线拓扑单线图, 依托于 Matlab/Simulink 平台搭建改进后的 10 kV 中性点不接地配电网系统仿真, 配电网拓扑结构转换形式如图 9 所示。考虑到目前我国配电网自动化程度普遍较低, SCADA 的水平难以满足全局广域监测, 本文假设在出口断路器、分段开关、配电变压器等所在的关键节点安装 FTU 和 TTU, SCADA 系统仅能采集到关键节点的运行数据, 在馈线分支等关键节点上配置一定数量的故障指示器。断路器 CB 配置过流保护和量测终端; 配置有过流保护的分段开关节点标记为绿色线条; 安装有 FTU 的分段开关以蓝色填充标识, 在紫色填充的配电变压器上安装 TTU; 安装有故障指示器的节点以红色填充标识。

配电网的原始拓扑结构如图 9(a)所示, 以断路器、分段开关、联络开关、故障指示器、配电变压器为节点, 电气线路作为边, 将其转换为节点与边连接如图 9(b)所示的图模型拓扑, 电气线路长度均为 1 km, 线路参数见表 1^[27]所示。对于接地故障, 考虑在开关不跳闸的情况下进行仿真, 因此将不会上传故障信息的配电变压器并入上一级的分段开关或故障指示器节点, 得到的简化接地故障拓扑如图 9(c)所示。对于短路故障, 开关跳闸后会导致下游台区的配电变压器停电, 没有安装 TTU 的配电变压器不会上传失电信息。除此之外, 没有配置 FTU 或过流保护的开关不会上传过流信息或保护动作信息, 因此将上述类型的开关合并作为线路和配电变压器并入上一级开关或故障指示器节点, 得到简化后的短路故障拓扑, 如图 9(d)所示。

表 1 电气线路参数

Table 1 Electrical line parameters

相序	电阻/($\Omega \cdot \text{km}^{-1}$)	电感/($\text{mH} \cdot \text{km}^{-1}$)	电容/($\mu\text{F} \cdot \text{km}^{-1}$)
正序	0.531	0.960	0.938
零序	0.234	3.550	0.0965

为了模拟故障发生时的不同工况环境, 本文将故障类型、故障位置、过渡电阻和负荷水平作为可变参数, 采用随机抽样的方式产生不同的故障场景, 故障场景可变参数的具体设置情况如附录 A 表 A1 所示。系统负荷水平选取 24 个时段的历史负荷数据, 负荷水平的选取按照时序进行遍历抽样。

在配电网发生接地或短路故障后, 配电网主站能够采集到 FTU 和故障指示器的遥测数据。设置遥测数据的采样频率为 1 kHz, 采样时间窗口取故障前 0.05 s 和故障后 0.15 s 共计 0.2 s 的时间段, 并将不能上传录波数据的节点输入特征置零, 每个时间步的数据包括节点的三相电压和电流。将具有时间序列属性的遥测数据 $X_{\text{ASTGCN}} = \{V_a, V_b, V_c, I_a, I_b, I_c\}$

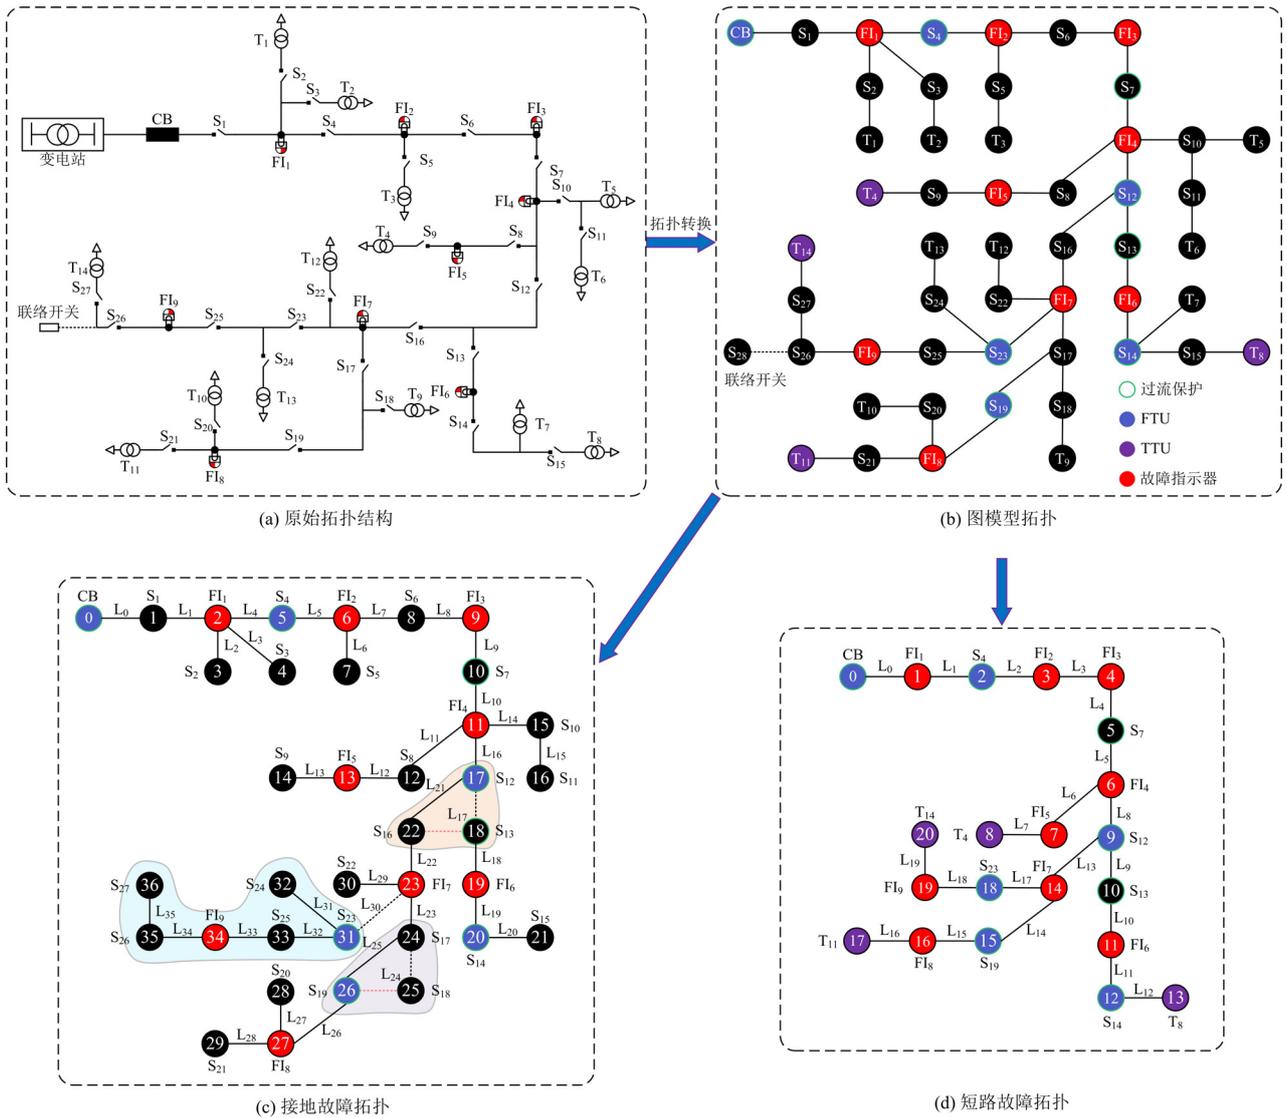


图 9 配电网拓扑转换示意图

Fig. 9 Distribution network topology conversion diagram

作为 ASTGCN 的输入, 以此来提取具有时空特性的故障特征。在配电网发生短路故障后, FTU、TTU 和故障指示器分别会向配电网主站上传保护动作信息、FTU 检测到的过流信息、配电变压器失电信息、故障指示器翻牌动作信息等遥信数据。故障指示器翻牌动作信息以 0-1 离散值的形式进行编码, 翻牌动作记为 1, 未产生翻牌动作则记为 0。将装设了 FTU 的开关在故障时产生的保护动作和过流信息同样以 0-1 离散数值的形式进行编码, 电流越限或保护动作记为 1, 反之则记为 0。对于台区安装了 TTU 的配电变压器, 配电变压器失电信息编码形式同上所述, 失电状态记为 1, 正常状态记为 0。遥信数据 $X_{GAT} = \{FI_a, FI_b, FI_c, Trans_{Lose}, Switch_{Action}, Current_{Over}\}$ 以

0-1 编码形式的离散数值作为 GAT 的节点特征输入, 以此来融合多源遥信故障数据。

在图 9(c)所示的配电网系统中的 36 个区段上设置不同故障场景的接地故障, 并分别在不同故障类型下生成每组各 100 种图数据; 在图 9(d)所示的配电网系统中的 20 个区段上设置不同故障场景的短路故障, 并分别在不同故障类型下生成每组各 50 种图数据。

安装在户外的 FTU 和故障指示器易受外部环境和机械设备等引起的噪声干扰, 为了使数据更加真实可靠, 并提高模型对噪声的抗干扰能力, 对上传的遥测数据加入标准差为 3% 的随机高斯噪声。节点特征的各项具有不同的量纲, 如果不进行数

据预处理,很有可能由于数值差异过大而导致难以收敛。为了规避量纲不一致的影响,采用 Z-score 标准化的方法对遥测数据进行归一化处理。

$$\hat{x} = \frac{x - \bar{x}}{\sigma} \quad (9)$$

式中: x 为原始数据; \bar{x} 为原始数据的均值; σ 为原始数据的标准差。

3.2 模型效果评估

本文基于 Pytorch 环境搭建深度学习框架,在 Pytorch Geometric Library 上开发 ASTGCN 模型和 GAT 模型。测试计算机的配置为: Intel Core i9-13900KF 3.00 GHz CPU、64 GB RAM 和 NVIDIA GEFORCE RTX 4090 24 G GPU。

3.2.1 模型测试与训练

为了消除样本之间的相关性,从总样本中随机抽取生成的图数据,并按照 8:1:1 的比例将其划分成训练集、验证集、测试集。模型的训练采用自适应动量(adaptive momentum, Adam)优化器,使用交叉熵损失函数计算模型误差。为了展示本文所提基于 GNN 的配电网故障定位模型的训练效果,附录 A 图 A1 列出了在训练过程中接地故障和短路故障定位模型的训练损失、验证集准确率、训练集准确率来反映训练效果的数值变化情况,由图可知,随着离线训练迭代次数的不断增加,一方面,训练损失不断下降最后趋于平稳,另一方面,模型的训练精度不断攀升,之后整体呈现出逐渐升高伴有略微波动的趋势,当训练次数达到预设周期时,接地和短路故障定位模型已经收敛,并且在线决策精度接近 100%,可以满足实际工程应用中对配电网故障定位的精度要求。

3.2.2 模型特征提取效果可视化

为了更直观地反映模型特征提取的效果,采用 t 分布随机近邻嵌入(t -SNE)对本文提出的故障区段定位模型中的测试集原始输入数据及各层网络输出数据进行降维并映射至二维平面,从而实现可视化高维度数据在特征空间的分布情况。

构建故障定位模型的原始输入数据和各层关键网络输出数据经 t -SNE 降维归一化后的特征分布情况如图 10、图 11 所示,图中代表故障区段的特征采用星型形状标识并用不同颜色加以区分。

从图 10 中可以看出,原始输入数据在特征空间中混叠在一起,难以区分。经过故障特征提取与融合层进行时序特征提取后,不同故障区段的聚类效果明显,再经过故障特征维度变换层进行节点到边特征映射后,呈现逐渐明显的聚合形状,最后经故障区段分类学习层非线性变换得到层次分明的分

类效果。

由图 11 可知,原始输入数据映射至二维平面上也呈现杂乱无章的分布情况,但依次经过 ASTGCN 层和 GAT 层组成的故障特征提取与融合层和故障特征维度变换层后,特征逐渐呈现清晰分明的趋势,通过故障区段分类学习层后,代表不同故障区段的特征分类聚合效果明显。

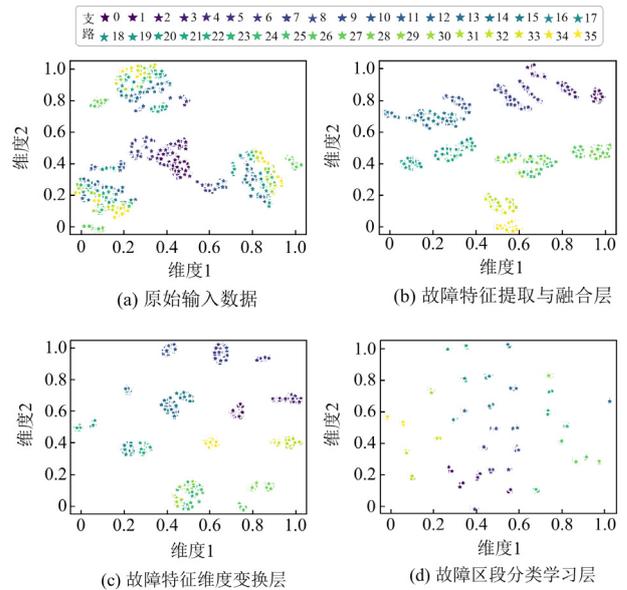


图 10 接地故障定位模型输出数据降维可视化

Fig. 10 Visualization of dimensionality reduction for output data of grounding fault location model

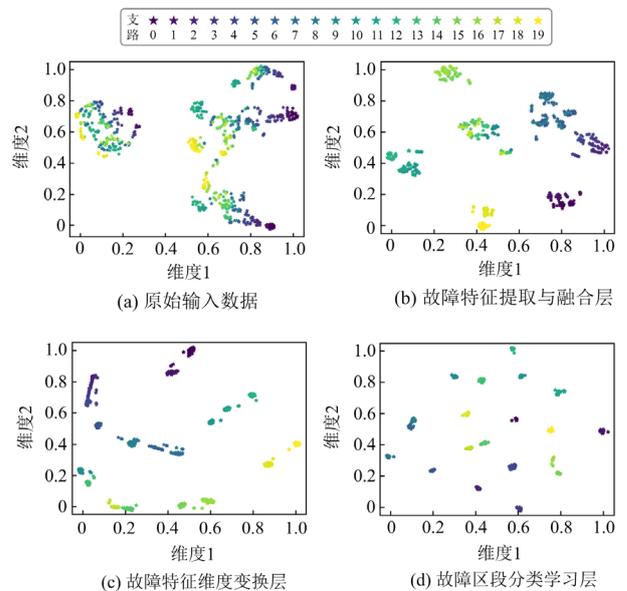


图 11 短路故障定位模型输出数据降维可视化

Fig. 11 Visualization of dimensionality reduction for output data of short-circuit fault location model

通过分析模型特征提取效果的可视化呈现, 原始输入数据经过构建故障定位模型各层网络后, 都能逐层呈现不断清晰的分类聚合效果, 说明了本文所提故障定位模型具有强大的特征提取能力, 并且各层网络设计合理, 能够逐步拟合电气特征量到故障区段之间的映射关系, 从而实现精确定位故障区段。

3.3 拓扑变动下模型泛化能力评估

在配电网运行中, 由于检修或故障等需要对开关进行倒闸操作, 所以难免会造成系统拓扑结构频繁变动。考虑到在短路故障拓扑中已合并不可观测开关, 难以满足配电网重构的条件, 但是在接地故障简化拓扑中仍存在大量开关可以进行倒闸操作, 因此为了评估本文所提接地故障定位模型在拓扑变动下的适应能力, 分别在故障性重构和经济性重构情况下对模型进行测试, 并选用以下 5 种深度学习算法进行对比: 1D-CNN、STGCN、LSTM、循环神经网络(recurrent neural network, RNN)以及深度神经网络(deep neural network, DNN), 1D-CNN 的网络架构为[卷积+池化+卷积+池化+3 层全连接], 卷积核大小为 3, 池化层大小为 2。STGCN 模型的网络架构为[图卷积+1 维卷积+池化+3 层全连接], 卷积核大小均为 3, 池化层大小为 4。RNN 和 LSTM 的网络架构均为[2 个 RNN/LSTM 层+1 个线性层], 其中将线性层最后一个时间断面的输出作为分类激活值。DNN 结构包含 3 个线性层的全连接网络, 并引入 Dropout 模块以缓解过拟合。对于上述深度学习算法, 各模型均采用 Adam 优化器和交叉熵损失函数, 选取 Softmax 作为分类输出的激活函数。如图 9(c)中圈出部分所示, 考虑在配电网重构的情况下对系统拓扑做以下 3 种变化。

1) 断开开关 S_{12} 和开关 S_{13} 之间的 L_{17} 支路, 连接 S_{13} 和 S_{16} 。

2) 在 1) 的基础上断开开关 S_{17} 和开关 S_{18} 之间的支路 L_{24} , 连接开关 S_{18} 和开关 S_{19} 。

3) 在 2) 的基础上, 开关 S_{23} 跳闸, 即断开故障指示器 FI_7 和开关 S_{23} 之间的支路 L_{30} 。

1) 和 2) 属于经济性重构, 节点数量没有发生变化, 只是改变了支路的连接方式, 3) 直接删减了部分节点, 属于故障性重构^[24], 分别按上述重构方式在所有区段上设置不同类型并涵盖已训练阻性(0.1~500 Ω)和未训练高阻性(500、600、700、800、900、1000 Ω)的单相接地故障, 且在不同的故障场景下生成多组数据对模型进行测试。为了对不同

基线方法的接地故障定位性能进行全面评估, 本文采用整体准确率(A_{cc})和均方根误差(e_{RMSE})来作为故障定位模型面对系统拓扑变动的泛化性能评估指标。 A_{cc} 和 e_{RMSE} 的计算表达式分别为

$$\begin{cases} a_{cci} = \frac{n_{right,i}}{n_{total,i}} \\ A_{cc} = \frac{1}{N} \sum_{i=0}^N a_{cci} \\ e_{RMSE} = \sqrt{\frac{1}{N} \sum_{i=0}^N (1 - a_{cci})^2} \end{cases} \quad (10)$$

式中: a_{cci} 为第 i 组测试样本的准确率; $n_{right,i}$ 为第 i 组测试样本定位正确的数量; $n_{total,i}$ 为第 i 组测试样本定位总数; N 为测样样本总组数。

对所有类别的故障测试样本进行验证后得到的评估指标 A_{cc} 和 e_{RMSE} 如图 12 所示, 由图中不同模型的评估结果可知, 在经济性重构的两种情况下, 本文所提模型的整体表现最好。除此之外, STGCN 模型也具有较好的评估结果, 与本文模型的性能差异较小, 可见本文模型和 STGCN 模型都将邻接矩阵与节点特征相结合来提取故障数据的时空特征, 系统拓扑的变化会相应地反映在模型的输入邻接矩阵中, 使得模型能够提取更深层次的数据结构信息, 可以对拓扑变动进行自适应调整^[24]。除此之外, 本文模型能从包含已训练阻性和未训练高阻性的复杂多变故障环境下保持良好的定位效果, 充分说明了该模型能够从故障数据中捕捉到有利于准确定位的判别信息^[16]。对于 LSTM、1D-CNN 和 RNN 模型, 伴随着系统拓扑的改变, 各模型的 A_{cc} 均有较大幅度的下降, 且在含有高阻接地故障的环境中 e_{RMSE} 较大, 以上模型均是仅对时间序列数据提取故障特征, 对配电网拓扑连通关系的刻画不足, 难以揭示系统拓扑结构的改变, 导致对拓扑变动的泛化能力较差。DNN 的 A_{cc} 相较于其他模型略逊一筹, 并且其 e_{RMSE} 相对较大, 这是由于 DNN 在输入时需要将数据展平, 淹没了量测数据的时序特性, 使得 DNN 更难以从高维原始输入数据中降维挖掘表征故障机理的特征^[16], 面对未知故障场景的泛化性能弱。

在故障性重构的情况下, 本文模型的评估指标都要显著优于其他基线方法, STGCN 模型在故障性重构下的 A_{cc} 大打折扣, 但 e_{RMSE} 上升明显, 一方面, 可以说明增添了时空注意力机制的 ASTGCN 模型拓宽了空间特征提取的感受域, 使之能够更敏锐地感知到拓扑变化; 另一方面, 1D-CNN 与 ASTGCN 相结合进行故障特征提取的效果显著, 对

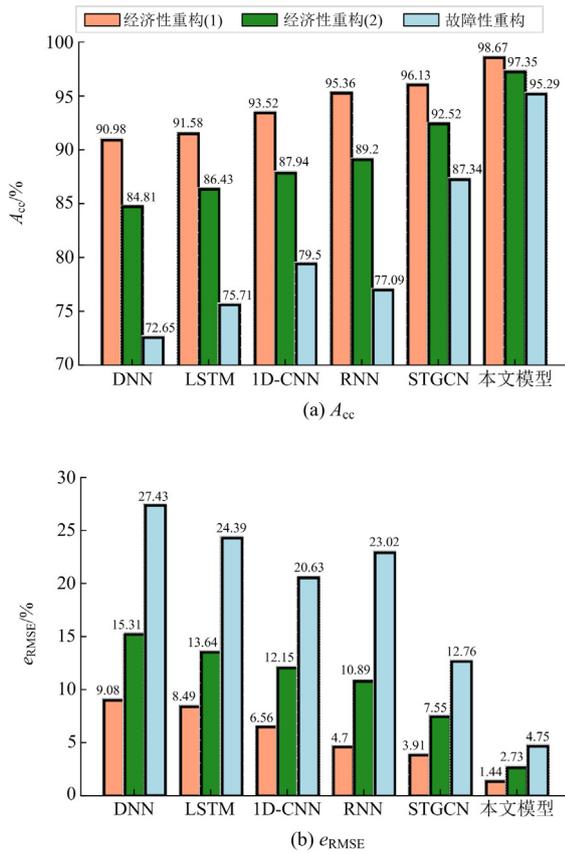


图 12 配电网重构下的评估结果

Fig. 12 Evaluation results under distribution network reconfiguration

于拓扑剧烈变动和未知高阻带来的异常数据具有极强的鲁棒性。其余 4 种基于欧式数据挖掘的深度学习模型由于对数据质量的依赖性强^[25]，当需要处理

变化较大的非欧式空间数据时，其提炼有效特征的能力显著下降，这使得其受数据异常和拓扑变动的的影响较大，其 e_{RMSE} 都呈现出急剧攀升的现象，并且 A_{cc} 大幅下跌。

从总体上来看，随着配电网系统拓扑变化程度的增加，以及面对存在高阻接地故障所带来电气量信号削减和突变的极端异常情况下^[27]，本文所提模型的各项指标相较于其他基线方法没有太大的波动起伏，并且优势逐渐凸显，这充分说明了所提模型能够灵活地适应于各类低、中、高阻性接地故障场景，对于系统拓扑变动具有强大的泛化能力，在拓扑频繁变动的配电网中具有更好的应用前景。

3.4 故障数据不完备下模型性能表现

相较于遥测数据，遥信数据在通信传输过程中更容易受到环境干扰而发生畸变，导致上传到主站的故障数据存在误报或漏报^[5]。另外，如果大功率负荷突然接入很有可能使得 FTU 误报过流信息或保护动作信息、故障指示器误报过流翻牌动作信息，对于继电保护装置，可能会发生保护拒动或者误动作，所以短路故障定位模型对于数据不完备的鲁棒性是评估其泛化性能的关键指标。

在图 9(d)中的区段 L_{18} 处设置短路故障，考虑在遥测数据完备，FTU、故障指示器和 TTU 上传的遥信数据存在不同程度的误报或漏报的情况下生成多组样本，对本文所提的短路故障定位模型进行测试，并与多种基于主站多源遥信数据融合的故障定位方法作为对比：改进 D-S 证据^[13]、Petri 网^[15]、模糊集^[15]。对不同方法进行测试后得到的定位结果如表 2 所示。

表 2 不同方法在数据畸变场景下的定位结果

Table 2 Localization results of different methods in data distortion scenarios

算例场景	故障指示器 翻牌动作信息	FTU 过流信息	开关 保护动作信息	配电变压器 失电信息	定位结果			
					本文方法	改进 D-S 证据	模糊集	Petri 网
1	FI ₅ 误报	—	—	—	L ₁₈	L ₁₈	L ₁₈	L ₁₈
2	FI ₅ + FI ₆ 误报	—	—	—	L ₁₈	L ₁₈	L ₁₈	L ₁₈
3	—	S ₂₃ 漏报	S ₂₃ 漏报	—	L ₁₈	L ₁₈	L ₁₄ 、L ₁₇ 、L ₁₈	失效
4	—	S ₂₃ 漏报	S ₂₃ 漏报 + S ₁₂ 误报	—	L ₁₈	L ₁₈	L ₁₄ 、L ₁₇ 、L ₁₈	L ₁₇
5	—	—	—	T ₈ 误报	L ₁₈	L ₁₈	L ₁₈	L ₁₈
6	—	—	—	T ₈ + T ₁₁ 误报	L ₁₈	L ₁₈	L ₁₄ 、L ₁₇ 、L ₁₈	L ₁₈
7	FI ₅ 误报	S ₂₃ 漏报	S ₂₃ 漏报	T ₈ 误报	L ₁₈	L ₁₈	L ₁₄ 、L ₁₇ 、L ₁₈	失效
8	FI ₅ + FI ₆ 误报	S ₂₃ 漏报	S ₂₃ 漏报 + S ₁₂ 误报	T ₈ + T ₁₁ 误报	L ₁₈	L ₁₁ 、L ₁₄ 、L ₁₇	L ₁₄ 、L ₁₇	L ₁₄ 、L ₁₇

从表 2 中可以看出，在故障数据存在不同程度的畸变场景下，传统方法出现了误判或失效的情况，但是本文所提方法仍能准确定位故障区段，表明所

提模型能够充分利用遥测数据和遥信数据，可以有效克服故障数据畸变所带来的不良影响，提高故障定位容错率。

4 结论

本文提出了一种基于 1D-CNN 和 GNN 的配电网故障区段定位方法, 通过搭建 10 kV 中性点不接地配电网系统仿真展开研究, 并结合传统方法和多种深度学习算法进行对比测试, 得到如下结论。

1) 本文提出的配电网故障定位方法利用为数不多的可观测节点故障信息便可将故障区段定位范围精确定位至断路器、分段开关、故障指示器、配电变压器之间, 并且可以定位至包含未知状态节点的区段; 该方法对量测终端和故障指示器的配置水平要求不高, 可适用于配电自动化程度较低的配电网系统。

2) 面对包含有未训练高阻性接地故障, 以及伴随着系统拓扑变动的故障场景下, 本文所提接地故障定位模型相较于多数深度学习模型, 有着更显著

和稳定的定位性能, 能够灵活适应于各类低、中、高阻性接地故障环境, 具有强大的拓扑泛化能力。

3) 1D-CNN 的引入可以成功实现节点特征到边特征的非线性映射, 完成网络建模对象的调整; 1D-CNN 与 GNN 相组合形成的特征提取器可以有效提炼出表征故障演化机理的特征, 从而实现高精度故障定位。

4) 对于遥信数据存在不同程度畸变的情况下, 相较于多种传统方法, 所提短路故障定位方法的容错率更高, 能够有效克服数据畸变所带来的不良影响, 对故障数据不完备具有良好的鲁棒性。

后续将研究一种多图并行训练策略来提高模型离线训练效率, 并考虑如何将图网络技术运用于解决弧光接地故障、不同拓扑结构电网等复杂故障场景下的故障区段定位问题。

附录 A

表 A1 故障场景可变参数设置

Table A1 Variable parameter settings for fault scenarios

参数类型	参数取值	参数数量
故障类型	单相接地故障(Ag、Bg、Cg)、两相短路故障(AB、AC、BC)、两相短路接地故障(ABg、ACg、BCg)、三相短路接地故障(ABCg)	10
故障位置	从 5%到 95%(步长为 5%)	19
过渡电阻/ Ω	0.1、1、5、10、15、20、25、50、75、100、200、300、400、500	14
负荷水平/MW	1.49、1.32、1.19、1.23、1.24、0.98、1.31、2.22、3.45、3.56、3.68、2.31、2.57、3.17、3.46、3.28、3.41、2.49、2.92、2.58、2.55、2.34、1.94、1.82	24

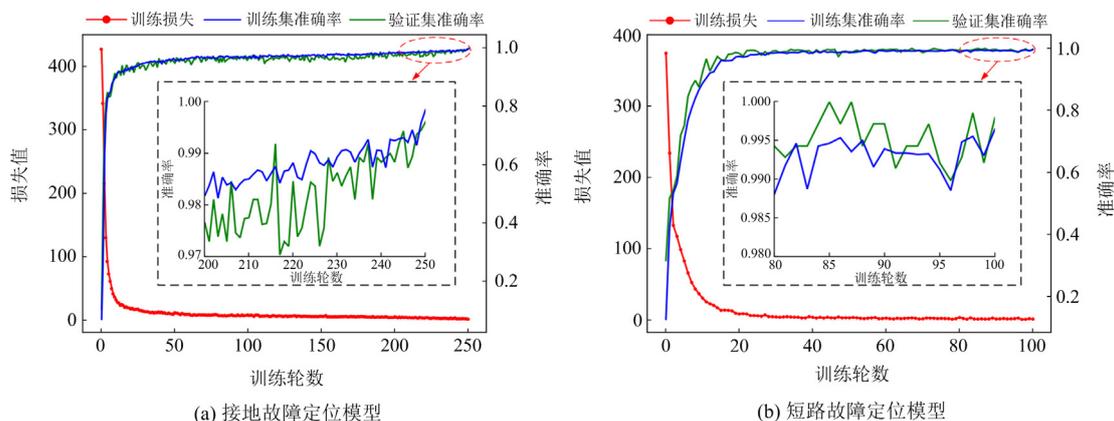


图 A1 模型训练曲线

Fig. A1 Model training curve

参考文献

[1] 张志华, 刘健, 张小庆, 等. 面向供电可靠性的城市配电网单相接地故障处理配置策略研究[J]. 供用电, 2022, 39(9): 27-34.
ZHANG Zhihua, LIU Jian, ZHANG Xiaoqing, et al. Research on strategy of single-phase grounding fault

treatment in urban distribution network for power supply reliability[J]. Distribution & Utilization, 2022, 39(9): 27-34.
[2] 缪惠宇, 史明明, 费骏韬, 等. 计及综合能源系统接入影响的配电网可靠性评估方法[J]. 电测与仪表, 2022, 59(10): 23-31.
MIAO Huiyu, SHI Mingming, FEI Juntao, et al. Reliability

- assessment method of distribution network considering the impact of integrated energy system access[J]. *Electrical Measurement & Instrumentation*, 2022, 59(10): 23-31.
- [3] 白星振, 宋昭杉, 葛磊蛟, 等. 含分布式电源的复杂配电网相间故障定位等效解耦模型[J]. *电力建设*, 2022, 43(2): 45-53.
BAI Xingzhen, SONG Zhaoshan, GE Leijiao, et al. An equivalent decoupling model for fault location in complex distribution network with distributed generation[J]. *Electric Power Construction*, 2022, 43(2): 45-53.
- [4] 梅飞, 陈子平, 裴鑫, 等. 基于矩阵算法的有源配电网故障定位容错方法[J]. *电力工程技术*, 2022, 41(6): 109-115.
MEI Fei, CHEN Ziping, PEI Xin, et al. Fault-tolerant method for fault location of active distribution network based on matrix algorithm[J]. *Electric Power Engineering Technology*, 2022, 41(6): 109-115.
- [5] 郑涛, 马龙, 李博文. 基于馈线终端装置信息畸变校正的有源配电网故障区段定位[J]. *电网技术*, 2021, 45(10): 3926-3935.
ZHENG Tao, MA Long, LI Bowen. Fault section location of active distribution network based on feeder terminal unit information distortion correction[J]. *Power System Technology*, 2021, 45(10): 3926-3935.
- [6] 黄飞, 陈纪宇, 戴健, 等. 基于特征暂态零模电流偏态系数的有源配电网单相故障定位方法[J]. *电力系统保护与控制*, 2022, 50(20): 12-21.
HUANG Fei, CHEN Jiyu, DAI Jian, et al. Single-phase fault location method for an active distribution network based on the skewness coefficient of characteristic transient zero-mode current[J]. *Power System Protection and Control*, 2022, 50(20): 12-21.
- [7] 周放歌, 肖仕武. 基于零序电流分布的有源配电网接地故障定位[J]. *电网技术*, 2022, 46(5): 1820-1832.
ZHOU Fangge, XIAO Shiwu. Grounding fault location of active distribution network based on zero sequence current distribution[J]. *Power System Technology*, 2022, 46(5): 1820-1832.
- [8] 郭利爽, 李凤婷, 赵新利, 等. 基于子网络划分的含DG配电网故障区段定位[J]. *电力系统保护与控制*, 2020, 48(7): 76-84.
GUO Lishuang, LI Fengting, ZHAO Xinli, et al. Fault section location for distribution network with DG based on sub-network partition[J]. *Power System Protection and Control*, 2020, 48(7): 76-84.
- [9] 梁英达, 田书, 刘明杭. 基于相量校正的多源配电网故障区段定位[J]. *电力系统保护与控制*, 2023, 51(1): 33-42.
LIANG Yingda, TIAN Shu, LIU Minghang. Fault section location of multi-source distribution network based on phasor correction[J]. *Power System Protection and Control*, 2023, 51(1): 33-42.
- [10] 杨国华, 冯骥, 柳萱, 等. 基于改进秃鹰搜索算法的含分布式电源配电网分区故障定位[J]. *电力系统保护与控制*, 2022, 50(18): 1-9.
YANG Guohua, FENG Ji, LIU Xuan, et al. Fault location of a distribution network hierarchical model with a distribution generator based on IBES[J]. *Power System Protection and Control*, 2022, 50(18): 1-9.
- [11] 高锋阳, 李昭君, 袁成, 等. 量子计算和免疫优化算法相结合的有源配电网故障定位[J]. *高电压技术*, 2021, 47(2): 396-406.
GAO Fengyang, LI Zhaojun, YUAN Cheng, et al. Fault location for active distribution network based on quantum computing and immune optimization algorithm[J]. *High Voltage Engineering*, 2021, 47(2): 396-406.
- [12] 李振钊, 王增平, 张玉玺, 等. 基于升维线性规划的主动配电网故障区段定位方法[J]. *电力系统自动化*, 2021, 45(24): 122-132.
LI Zhenzhao, WANG Zengping, ZHANG Yuxi, et al. Fault section location method for active distribution network based on linear programming with ascending dimension[J]. *Automation of Electric Power Systems*, 2021, 45(24): 122-132.
- [13] 高湛军, 李思远, 彭正良, 等. 基于网络树状图和改进D-S证据理论的配电网故障定位方法[J]. *电力自动化设备*, 2018, 38(6): 65-71.
GAO Zhanjun, LI Siyuan, PENG Zhengliang, et al. Fault location method of distribution network based on tree structure diagram and improved D-S evidence theory[J]. *Electric Power Automation Equipment*, 2018, 38(6): 65-71.
- [14] 高正中, 许焕奇, 雷倩, 等. 基于Petri网和双层判据的配电网故障定位方法[J]. *工矿自动化*, 2016, 42(8): 37-42.
GAO Zhengzhong, XU Huanqi, LEI Qian, et al. Fault location method for distribution network based on Petri net and double criterions[J]. *Industry and Mine Automation*, 2016, 42(8): 37-42.
- [15] 魏然, 张磐, 高强伟, 等. 基于网络树状图的低压配电网故障研判仿真分析[J]. *电力系统保护与控制*, 2021, 49(13): 167-173.
WEI Ran, ZHANG Pan, GAO Qiangwei, et al. Simulation analysis of low-voltage distribution network fault diagnosis based on tree structure diagram[J]. *Power System Protection and Control*, 2021, 49(13): 167-173.
- [16] 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 Jinghan, LUO Guomin, CHENG Mengxiao, 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.
- [17] 尚博阳, 罗国敏, 茹嘉昕, 等. 基于有限量测信息的多分支配电线路故障定位方法[J]. 高电压技术, 2023, 49(6): 2308-2319.
- SHANG Boyang, LUO Guomin, RU Jiabin, et al. Fault location method of multi-branch distribution lines based on limited measurement information[J]. High Voltage Engineering, 2023, 49(6): 2308-2319.
- [18] 孟子超, 杜文娟, 王海风. 基于迁移学习深度卷积神经网络的配电网故障区域定位[J]. 南方电网技术, 2019, 13(7): 25-33.
- MENG Zichao, DU Wenjuan, WANG Haifeng. Distribution network fault area location based on deep convolution neural network with transfer learning[J]. Southern Power System Technology, 2019, 13(7): 25-33.
- [19] 庄颖睿, 肖谭南, 程林, 等. 基于时空图卷积网络的电力系统暂态稳定评估[J]. 电力系统自动化, 2022, 46(11): 11-18.
- ZHUANG Yingrui, XIAO Tannan, CHENG Lin, et al. Transient stability assessment of power system based on spatio-temporal graph convolutional network[J]. Automation of Electric Power Systems, 2022, 46(11): 11-18.
- [20] 叶智鹏. 基于图注意力网络的配电网单相故障检测研究[D]. 福建: 福建工程学院, 2023.
- [21] 汪文达, 张伟. 基于多源非健全信息融合的配电网主动故障研判方法[J]. 电气传动, 2021, 51(12): 47-51.
- WANG Wenda, ZHANG Wei. Active fault diagnosis method for distribution network based on multi-source imperfect information fusion[J]. Electric Drive, 2021, 51(12): 47-51.
- [22] 吴博, 梁循, 张树森, 等. 图神经网络前沿进展与应用[J]. 计算机学报, 2022, 45(1): 35-68.
- WU Bo, LIANG Xun, ZHANG Shusen, et al. Advances and applications in graph neural network[J]. Chinese Journal of Computers, 2022, 45(1): 35-68.
- [23] CHEN Kunjin, HU Jun, ZHANG Yu, et al. Fault location in power distribution systems via deep graph convolutional networks[J]. IEEE Journal on Selected Areas in Communications, 2020, 38(1): 119-131.
- [24] 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 Jiawei, WANG Xiaojun, HE Jinghan, et al. Distribution network fault location based on graph attention network[J]. Power System Technology, 2021, 45(6): 2113-2121.
- [25] HU Jiayang, HU Weihao, CHEN Jianjun, et al. Fault location and classification for distribution systems based on deep graph learning methods[J]. Journal of Modern Power Systems and Clean Energy, 2023, 11(1): 35-51.
- [26] 赵恺, 石立宝. 基于改进一维卷积神经网络的电力系统暂态稳定评估[J]. 电网技术, 2021, 45(8): 2945-2957.
- ZHAO Kai, SHI Libao. Transient stability assessment of power system based on improved one-dimensional convolutional neural network[J]. Power System Technology, 2021, 45(8): 2945-2957.
- [27] 何小龙, 高红均, 高艺文, 等. 基于 GA 优化 BP 神经网络的有源配电网高阻接地故障选线方法[J]. 智慧电力, 2023, 51(4): 54-61.
- HE Xiaolong, GAO Hongjun, GAO Yiwen, et al. High resistance grounding fault line selection method for active distribution network based on GA optimized BP neural network[J]. Smart Power, 2023, 51(4): 54-61.

收稿日期: 2024-01-08; 修回日期: 2024-05-16

作者简介:

何小龙(1999—), 男, 硕士研究生, 研究方向为人工智能在配电网故障诊断中的应用; E-mail: 787438918@qq.com

高红均(1989—), 男, 通信作者, 博士, 副教授, 博士生导师, 研究方向为配电自动化、配电网规划运行、综合能源系统优化与市场交易等。E-mail: gaohongjun@scu.edu.cn

(编辑 姜新丽)