

DOI: 10.19783/j.cnki.pspc.211042

基于图神经网络的智能变电站二次回路故障定位研究

张宸滔^{1,2}, 郑永康¹, 卢继平², 张豪³, 任辉⁴, 杨帜²

(1. 国网四川省电力公司电力科学研究院, 四川 成都 610041; 2. 输配电装备及系统安全与新技术国家重点实验室(重庆大学), 重庆 400044; 3. 国网四川省电力公司检修公司, 四川 成都 610042;
4. 中国电力科学研究院有限公司南京分院, 江苏 南京 210003)

摘要: 为提高智能变电站二次回路故障定位的准确率与可移植性, 提出了一种基于图神经网络的智能变电站二次回路故障定位方法。依据智能变电站配置文件制作图数据库, 得到二次设备之间的连接关系。结合二次设备告警信号表征, 提出了一种二次设备节点的信息表征作为图神经网络的输入。利用图神经网络的理论建立了故障定位模型。以某 220 kV 智能变电站的二次回路为基准, 利用故障图生成模型改变组网方式、订阅关系及网络配置产生不同二次回路故障构成算例。通过实验比较了所提定位方法与其他模型的准确率, 实验结果表明该方法有较高的定位精度及较好的鲁棒性。

关键词: 图神经网络; 智能变电站; 二次回路; 故障定位

Fault location of secondary circuits in a smart substation based on a graph neural network

ZHANG Chentao^{1,2}, ZHENG Yongkang¹, LU Jiping², ZHANG Hao³, REN Hui⁴, YANG Zhi²

(1. State Grid Sichuan Electric Power Co., Ltd. Research Institute, Chengdu 610041, China; 2. State Key Laboratory of Power Transmission Equipment & System Security and New Technology (Chongqing University), Chongqing 400044, China;
3. Maintenance Branch, State Grid Sichuan Electric Power Co., Ltd., Chengdu 610042, China;
4. Nanjing Branch, China Electric Power Research Institute Co., Ltd., Nanjing 210003, China)

Abstract: To improve the accuracy and portability of secondary circuit fault location in smart substations, a graph neural network-based smart substation secondary circuit fault location method is proposed. From the substation configuration description file, a graph database is established to obtain the connection relationship between the secondary equipment. Combined with the alarm signal representation of the secondary equipment, a kind of information representation of the secondary equipment node is proposed as the input of the graph neural network. Graph neural network theory is used to establish the fault location model. Taking the secondary circuits of a 220 kV smart substation as a benchmark, using the fault generation model to change the networking mode, a subscription relationship and network configuration is used to generate different secondary circuits faults. The experiment compares the accuracy of the proposed fault location model with other models and the experimental results show that this method has higher fault location accuracy and better robustness.

This work is supported by the Science and Technology Project of State Grid Corporation of China (No. 5108-202018037A-0-0-00).

Key words: graph neural network; intelligent substation; secondary circuits; fault location

0 引言

二次设备的安全可靠是智能变电站稳定运行的

有力保障, 利用二次系统中的故障信息对设备的运行状态进行判别与预测是智能化运维的基础^[1-6]。

目前智能变电站中各种二次设备故障的原因主要由技术人员依据故障处理经验及装置的报文信息辅助判别^[6-8], 但由于二次系统网络复杂且缺乏有效手段分析故障特征之间的关联性, 难以对故障进行

基金项目: 国家电网公司科技项目资助(5108-202018037A-0-0-00); 国网四川省电力公司科技项目资助(521997190004)

快速定位及分析, 故实现二次设备故障的精确定位至关重要^[9-12]。

在传统故障分析方面, 文献[13]提出了基于 Petri 网模型的面向通用对象变电站(Generic Object Oriented Substation Event, GOOSE)回路故障诊断方法, 但是对于复杂的二次系统网络还需人工搭建模型, 这导致了工作量庞大且复杂。文献[14-15]分别采用举证表和枚举法, 基于二次系统通信链路交叉的特点穷举出网络故障的范围, 由于受限于二维表的表示形式, 这类方法只能依赖单一的故障特征, 无法精确判断故障出现的具体位置及故障原因。文献[16]利用故障树的分析方法建立了二次设备故障与告警信号之间的关联, 增加了对故障特征的分析, 但是对于设备出现关联告警信号或在网络中同时出现大量告警信号的情况依然无法精确分析故障原因。

随着人工智能技术在电网中的应用, 文献[17]利用融合集成学习的方法进行二次设备状态评估, 文献[18]利用语义构建词向量进行二次回路虚段子连接, 在故障定位方面, 文献[19-20]利用深度置信网络(Deep Belief Network, DBN)对故障状态特征进行提取, 分别实现了智能变电站通信网络故障定位及电网故障类型辨识, 其相比于传统故障分析方法准确度和鲁棒性更强, 但是二次系统的故障往往只涉及某几个间隔, 而深度学习建模需要对整个变电站的二次系统进行训练, 存在样本难以获取且模型很难依据拓扑结构及故障特征进行变化的情况。文献[21]尝试融合专家经验与人工智能的方法对故障进行识别, 但是其置信度依赖对历史数据的统计分析, 在二次回路历史故障数据中相同的故障特征与故障类型映射关系会随着网络拓扑而改变, 另外征兆阈值和限值的选取需要进行多次修正, 不适用于二次回路数据大量累积并更新的情况。

综上所述, 当前的故障诊断方法存在以下问题:

(1) 二次设备的故障类型众多, 但现有方法利用的故

障特征较少且故障特征之间的关联性较弱; (2) 针对历史文本数据的特征提取, 对故障精确定位帮助较少; (3) 传统分析方法还依据网络拓扑结构, 深度学习的方法则放弃了将此因素纳入考量, 导致故障特征的变化及网络拓扑结构的改变均会影响模型的准确性。

针对二次系统故障定位存在的以上问题, 本文提出基于图神经网络的故障定位方法, 从图的视角对二次系统进行了研究。首先基于对二次回路故障的分析依据智能变电站 SCD 配置文件建立了二次回路, 而后在二次回路的故障特征信息的基础上提出了二次回路故障特征的表征方式。本文利用图神经网络(Graph neural network)搭建了二次回路故障诊断模型, 通过对不同模型的比较及算例分析, 证明了图神经网络能够更好地提取不同网络结构下的二次回路故障信息。

1 二次回路故障分析与建模

1.1 二次回路故障分析

二次回路中的元件根据其功能可分为信源、中继设备、信宿和连接元件^[22-23]。当二次回路中任意设备出现故障时, 二次回路通信网络的潮流分布会发生改变^[24], 同时因设备的运行状态及网络拓扑的改变使得相关设备发出告警信号。由于当某一设备发生故障时, 二次回路中与之相关联的设备均会产生告警信号, 造成了二次回路故障定位困难。如图 1 所示, 线路间隔不同光纤断链, 既有可能造成本间隔内设备产生告警信号, 也有可能造成本间隔外设备产生告警信号, 且告警信号往往涵盖了间隔中的多个设备, 因此仅仅根据设备的告警信息无法精确定位故障。另一方面, 由于不同智能变电站的组网方式不同, 甚至同一变电站内不同电压等级的间隔组网方式也会变化, 这造成了不同设备之间连接关系的变化, 改变了运维人员的排查范围。

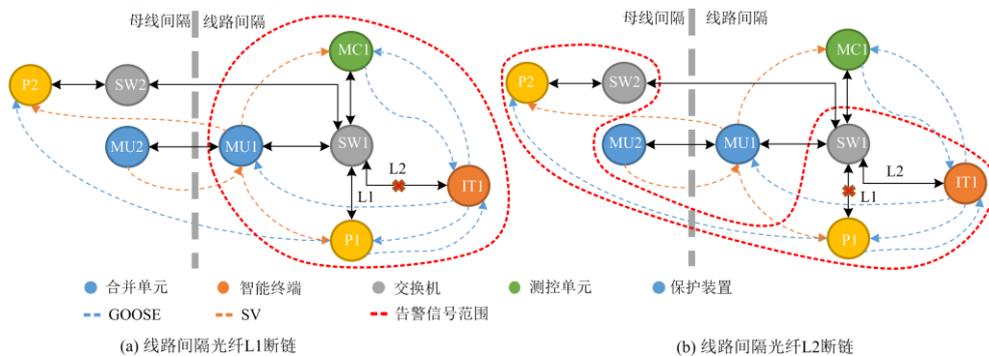


图 1 相同间隔内发生故障告警信号范围示意图

Fig. 1 Alarm signal range for faults occurring within the same interval

1.2 二次回路图数据库的建立

根据上节所述, 一个完整的二次回路应包含设备种类、设备连接关系、设备报文订阅关系及设备相关联的告警信号等信息。智能变电站配置文件 (Substation Configuration Description, SCD) 记录了智能变电站通信网络配置、智能装置配置与数据对象及属性等信息, 通过建立基于 IEC61850 的语义化模型对 SCD 文件的信息进行抽取而后以节点和边的形式存储于 neo4j 图数据库中。

在图数据库中遍历图不同 IED 关联的 ExtRef 节点可得到不同 IED 之间的虚端子订阅关系, 对于不同 IED 之间的物理回路, 可通过遍历不同 PhysConn 节点^[15]或建立 SPCD、SLCD 文件^[25-26]而后遍历 Port 节点获得。将虚连接的内容以边属性的形式存储至对应物理回路中, 最终可得二次回路的物理回路与虚回路对应关系。部分节点的对应关系如图 2 所示, 其中棕色代表 IED 节点, 黄色代表端口节点, 红色边代表 GOOSE 传输链路, 蓝色边代表 SV 传输链路。其中某条边关系的数据如表 1 所示, 表示其编号为 135 988, 开始节点编号为 14 752, 结束节点编号为 8 193, 边的连接值为 L11 号光纤, 种类为 GOOSE。

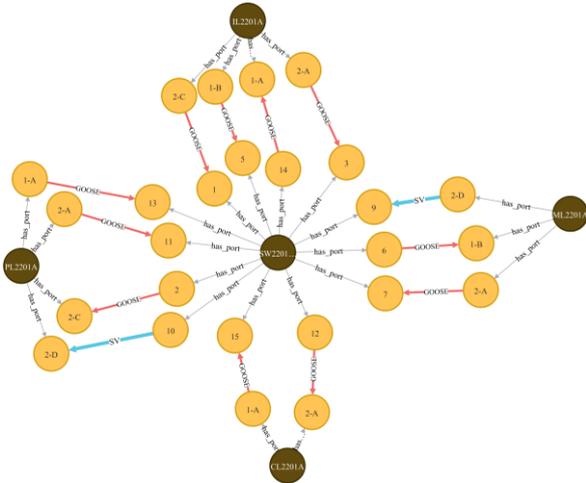


图 2 neo4j 中存储的二次回路可视化

Fig. 2 Visualization of the secondary circuits stored in neo4j

在故障发生时, 通过解析 GOOSE 和 MMS 报文的 MAC-Address、APPID 等信息在图数据库中依据路径 “IED-AccessPoint-LDevice-LN0-GSEControl” 及 “SubNetwork-ConnectedAP-GSE” 查询得到报文对应的装置, 同时依据报文中的 FCDA 信息结合路径 “IED-Server-LDevice-LN-DataSet-FCDA-DOI” 查询得到告警信号的具体信息, 其中某一告警信号节点属性值如表 2 所示, 表示其节点编号为 5 689, 节

点类别为 DOI, 节点属性中名称为 Alm4, 描述为定值自检出错。

表 1 图数据库中某关系的存储格式

Table 1 Storage format of a relationship in the graph database

属性	值
identity	135 988
start	14 752
end	8 193
link	L11
type	GOOSE
properties	{"content": "gocb0": "直控 2, IV 母 PT 地刀分出口, IV 母 PT 地刀合出口, IV 母 PT 隔刀分出口, IV 母 PT 隔刀合出口, IV 母甲地刀分出口, IV 母甲地刀合出口"...}

表 2 图数据库中某节点的存储格式

Table 2 Storage format of a node in the graph database

属性	值
identity	5 689
labels	DOI
properties	{"name": "Alm4", "desc": "定值自检出错"}

2 二次回路故障信息表征

当二次回路发生故障时, 设备的告警信号主要有: (1) 信宿通信状态告警: 如果过程层网络通信的信宿在指定时间内没有接收到订阅报文, 则判断为该条报文传输异常; (2) 设备运行状态告警: 设备会监测自身运行状态及端口的发送与接收光功率, 如果设备自身异常则会产生相应告警, 如自检信息异常, GOOSE/SV 断链等, 如果端口功率超出或低于设定阈值, 则发出对应光口功率告警; (3) 中继设备流量监测告警^[27]: 交换机对报文流量进行监测, 当通信网络潮流分布变化时, 交换机对应端口会发出低流量告警。二次设备的故障告警信号主要分布在 “G1” 和 “S1” 访问点下的 “dsAlarm”、“dsWarning” 与 “dsComm” 数据集中。

2.1 二次回路故障信息表征

本文将故障数据样本集建模为故障图数据 $G=(X, V, E)$, 并将故障定位问题定义为图分类问题。其中 V 为故障设备的集合, $|V|=n$, E 为表示故障设备间连接关系的邻接矩阵, X 为故障设备特征矩阵。

考虑到不同智能变电站内的报文数量不同, 不同设备端口数量不同及不同组网方式下二次设备连接关系的变化, 对故障图中其中某一节点 v 的故障特征 x 由式(1)表征。

$$x = \text{Concat}(\text{Encoding}, \text{Port}_1, \dots, \text{Port}_{n_{\text{ET}}}, A, C) \quad (1)$$

式中: $n_{\text{ET}}=1, \dots, N_{\text{ET}}$ 为故障设备种类编号, N_{ET} 为

设备种类数量；*Encoding* 为故障设备独热编码； $Port_{n_{ET}}$ 为设备 n_{ET} 的端口特征； A 为装置总告警； C 为反映装置 SV/GOOSE 断链的告警信号。装置 v 发生任意告警，如装置自检告警，装置对时异常等， $A=1$ 。装置 v 产生 SV/GOOSE 断链或通信中断告警时， $C=1$ 。

其中设备端口特征 $Port_{n_{ET}}$ 融合了该端口所连对侧设备所有报文信息及端口信息，如式(2)所示。

$$Port_{n_{ET}} = [\sum_{\forall N_{(v)}=n_{ET}} (\sum_{i=1}^{N_R} R_{n_{ET}}^v + \sum_{i=1}^{N_F} F_{n_{ET}}^v), \sum_{\forall N_{(v)}=n_{ET}} P_{receive}^v, \sum_{\forall N_{(v)}=n_{ET}} P_{deliver}^v], \quad (2)$$

$$n_{ET} = 1, \dots, N_{ET}$$

式中： $R_{n_{ET}}^v$ 为节点 v 该端口的报文接收状态集合； N_R 为报文接收状态集合大小； $F_{n_{ET}}^v$ 为节点 v 该端口的报文流量状态集合； N_F 为报文流量状态集合大小； $P_{receive}^v$ 、 $P_{deliver}^v$ 为节点 v 端口接收与发送功率状态集合； $N_{N(v)}$ 为节点 v 的邻居的设备种类编号。

端口报文接收状态集合 R^v 与端口流量状态集合 F^v 为

$$\begin{cases} R^v = message_1, message_2, \dots, message_n \\ F^v = message_1, message_2, \dots, message_m \end{cases} \quad (3)$$

式中： $message_n$ 第 n 条报文的接收状态； $message_m$ 表示第 m 条报文的交换机的流量监测状态。如果节点接收到第 n 条报文， $message_n=1$ ，否则 $message_n=0$ 。如果交换机监测到第 m 条报文流量过低， $message_m=1$ ，否则 $message_m=0$ 。

2.2 故障图生成模型

由于网络分析仪存储空间有限，且在智能变电站实际运维过程中记录的故障数据通常只包含实际故障设备的站控层网络的告警信号，因此存在故障样本告警信号缺失的情况，另一方面由于某些设备可靠性较高，积累故障样本所需时间较长，本文利用构建的图数据库生成故障样本。

在整个二次回路中输入外界影响因素(即组件随机故障、网络拓扑调整、网络组件配置等)，根据二次回路内设备、端口、光纤的运行状态形成故障图数据 $G=(X, V, E)$ ，故障生成流程如附图 1 所示。

3 基于图神经网络的二次回路故障定位模型

3.1 图神经网络模型

图神经网络作用于非欧氏空间的图数据，目前在物理结构机器学习^[28]、蛋白质结构识别^[29]、知识图谱理解^[30]中均有应用。图神经网络的目标是学习

每个节点的隐层状态 h_v ，该隐层状态可以用于产生节点的输出 o_v ；定义 f_v 为节点的信息汇集函数，其作用于所有节点并根据输入邻居特征更新节点信息；定义 g 为局部输出函数，其描述了如何产生输出。由此可定义 h_v 与 o_v 的表达式为

$$h_v = f(x_v, x_{co[v]}, h_{ne[v]}, x_{ne[v]}) \quad (4)$$

$$o_v = g(h_v, x_v) \quad (5)$$

式中， x_v 、 $x_{co[v]}$ 、 $h_{ne[v]}$ 、 $x_{ne[v]}$ 分别为节点 v 的特征、节点边的特征、节点 v 邻居的状态及特征。

本文将二次回路的故障定位问题定义为图分类问题，对于某一故障图数据 g_i ，图神经网络的输入为图数据中所有故障节点特征 X 及故障节点的邻接矩阵 E ，其中某一故障节点的特征 x 由式(1)一式(3)所得，图神经网络的输出为故障编号。在信息传递上，本文将节点信息汇集函数定义为邻居节点状态之和，而后叠加跳跃式连接(skip connection)，最后得到模型不同层之间的信息传递函数如式(6)所示，节点信息汇聚函数如式(7)所示。

$$h_v^l = \sigma(W_l \cdot h_v^{l-1} + W_r \cdot AGG(h_v^{l-1}, \forall v \in N(v))) \quad (6)$$

$$AGG(h_v^{l-1}, \forall u \in N(v)) = \sum_{u \in N(v)} h_u^{l-1} \quad (7)$$

式中： h_v^l 、 h_v^{l-1} 为中心节点 l 层和 $l-1$ 层状态； W_l 为中心节点权重矩阵； W_r 为邻居节点信息权重矩阵； $N(v)$ 为节点 v 的邻居节点集合； $\sigma(\cdot)$ 代表激活函数，比如 $\text{ReLU}(\cdot) = \max(0, \cdot)$ 。

在经过多次信息传递得到第 L 层节点的输出状态 $o_v^L = h_v^L$ 之后，将图中所有节点信息经过全局池化函数后得到整张图的信息表征 r ，如式(8)所示。

$$r = \max_{n=1}^{N_v} o_v^L \quad (8)$$

式中： N_v 为节点数量； o_v^L 为第 L 层隐藏层节点的输出状态。

在提取得到整图的信息表征 r 后利用一个全连接层神经网络作为分类器，其激活函数选用 Sigmoid 函数，分类器输出分类结果 y ，模型整体结构如图 3 所示。利用二分类交叉熵(Binary Cross Entropy)可以衡量模型的性能，如式(9)所示。

$$\begin{cases} l(z, y) = \text{mean}(l_0, \dots, l_{N-1}) \\ l_n = -(y_n \cdot \log(z_n) + (1 - y_n) \cdot \log(1 - z_n)) \end{cases} \quad (9)$$

式中： N 为样本数量； z_n 为预测第 n 个样本为正例的概率； y_n 为第 n 个样本的标签。

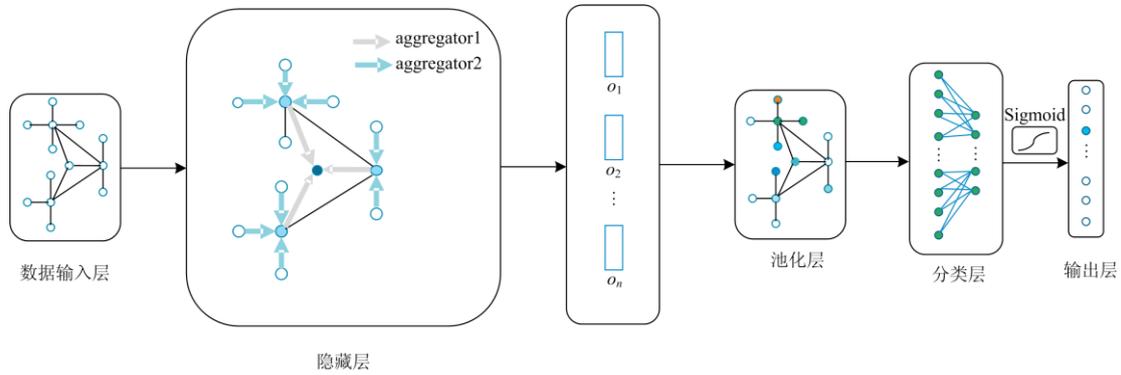


图3 图神经网络模型结构

Fig. 3 Structure of graph neural network

3.2 基于图神经网络的二次回路故障定位框架

基于上述内容, 本文建立了基于图神经网络的二次回路故障定位的基本框架, 如附图2所示。

(1) 依据历史故障数据中不同故障事件集发生的最小时间间隔 t (一般为报文生存时间的两倍以上) 划分一段时间内的告警信号, 形成告警信号集合 S_1, S_2, \dots, S_n ;

(2) 对于每一组告警信号集合 S_i , 在构建好的图数据库中结合告警信号搜索关联的故障设备, 计算故障设备形成的连通图个数 n ;

(3) 将与告警信号集合 $S_i \{A_j, A_{j+1}, \dots, A_{j+k}\}$ 相邻的告警信号 $\{A_{j-1}, A_{j-2}, \dots\}$ 及 $\{A_{j+k+1}, A_{j+k+2}, \dots\}$ 依次加入 S_i , 并判断连通图个数 n 是否增加, 若 n 不变则继续加入, 若 n 增加则停止加入, 并更新告警信号集合 S_i ;

(4) 根据告警信号集合 S_i 判断是否能利用现有知识库推理得到故障原因及位置, 如果不能则启动实施诊断程序;

(5) 将非连通图拆分为连通子图 G_1, G_2, \dots, G_n 后逐一生成故障图 $G_i = (X, V, E)$;

(6) 将得到的故障图送入已离线训练好的 GNN 故障定位模型进行故障定位;

(7) 若得到的定位结果为设备故障, 则结合站控层告警信号进一步分析故障原因, 否则依据故障图返回定位结果, 并将定位结果与故障图存入历史数据库中。

4 算例分析

4.1 算例简析

本文根据某 220 kV 智能变电站的 SCD 文件生成图数据库, 为方便不同模型的对比, 限定故障范围为两个线路间隔、两个主变间隔及一个母线间隔,

通过故障生成模型进行故障采样, 采样了 110 kV、220 kV 侧不同的组网方式下的二次回路故障。其中故障类型包括不同种类设备自身故障、不同设备之间的光纤及光口故障、不同种类设备板卡故障、不同设备之间光纤连接错误、不同设备链路配置错误等共 30 种故障类型, 具体故障类型见附表 1, 故障数量设置为一至三重故障。共采样了 1 078、800、800 组单一故障、双重故障、三重故障数据, 将三者组合制作作为数据集, 如表 3 所示。其中, I、II、III 分别代表单一故障、双重故障、三重故障数据。

表3 不同故障组成的算例

Table 3 Cases composed by different types of faults				
数据集	图数量	分类数	平均节点数目	平均边数量
I	1 078	30	3.6	2.92
I+II	1 878	30	5.47	5.12
I+II+III	2 678	30	7.08	7.13

4.2 模型优化细节及不同模型对比

本文设置了不同的模型深度(1,2,3), 不同的通道维数(64,128,256,512), 不同的聚合函数(add, mean, max, GCN), 不同的学习率(0.005~0.02), 不同的训练批次(32,64,128), 全连接层的层数(1,2,3), 全连接层维度(64,128,256), 不同的神经元丢弃率(0.2~0.8), 以及不同的全局池化(global pooling)函数(add, mean, max)来搜寻模型的最优超参数。训练过程中输出层的阈值设置为 0.9, 即输出层的神经元大于 0.9 时对应位置元素为 1, 否则为 0。本文的 GNN 模型基于 Pytorch 框架实现, 训练平台为 Tesla T4 GPU。训练过程中, 本文将训练样本按照 8:1:1 的比例分为训练集、验证集与测试集, 其中模型的超参数由验证集确定, 其中数据集(I+II+III)的最优超参数如表 4 所示。

表 4 数据集(I+II+III)的最优超参数

Table 4 Optimal hyperparameters of the data set (I+II+III)

模型深度	训练批次	初始学习率	通道维数
3	64	0.01	256
神经元丢弃率	全局池化函数	聚合函数	全连接层参数
0.5	Max	Add	(1,128)

本文设置了支持向量机(SVM)、随机森林(RF)、全连接神经网络三个基准模型作为对比, SVM 和 RF 的超参数通过 5 折交叉验证决定, 全连接神经网络的超参数由样本量的 10% 的验证集决定。需要注意的是由于每个故障图数据节点不同, 为保持以上模型输入维数保持不变, 本文将图样本中无特征的节点作全 0 填充(padding)处理。不同模型在不同数据集上的准确率如表 5 所示。其中对于多重故障的样本, 只有当故障种类全部预测正确时才计算正确率。对于神经网络模型, 进行 5 次实验后记录其均值与方差。

表 5 不同模型在不同数据集上的准确率

Table 5 Accuracy of different models in different data set

模型	数据集(I)	数据集(I+II)	数据集(I+II+III)
PCA+SVM	0.817±0.007	0.761±0.008	0.754±0.008
PCA+RF	0.676±0.022	0.601±0.030	0.586±0.008
DNN	0.889±0.012	0.765±0.032	0.762±0.045
GNN	0.988±0.011	0.886±0.035	0.884±0.033

从表 5 中可以看出, GNN 模型一直保持着最高的准确率, 随着同一样本中故障数量的增加, 不同模型的准确率均有不同程度的下降。

4.3 不同干扰下模型的性能分析

为了测试模型的鲁棒性, 本文设置了两种干扰: (1) 链路告警信号的丢失: 每条链路所产生的告警信号丢失概率为 $P_{linkloss}$; (2) 设备告警失效: 每台设备无法上传告警信号的概率为 $P_{equiploss}$ 。根据文献[31]对设备及链路可靠性的计算, 本文设定 $P_{linkloss} = 0.01$, $P_{equiploss} = 0.001$, 表 6 显示了在测试集中加入不同干扰对于模型准确率的影响。

表 6 不同干扰对模型准确率的影响

Table 6 Influence of different interferences on the accuracy of the model

模型	干扰 I	干扰 II	干扰 I+II	无干扰
DNN	0.721	0.706	0.688	0.762
DNN 对比无干扰情况下准确率下降	0.041	0.056	0.074	—
GNN	0.866	0.847	0.829	0.88
GNN 对比无干扰情况下准确率下降	0.014	0.033	0.051	—

从表 6 中可以看出, GNN 模型对于不同干扰准确率下降的幅度更小, 鲁棒性更高。表 7 模拟了在训练数据集中加入干扰的情况, 更加符合实际, 可以看出两者准确率基本与表 6 一致, 且数据干扰对 GNN 模型的影响同样小于对 DNN 的影响。

表 7 训练数据带不同干扰对于模型准确率的影响

Table 7 Impact of different interferences in training on the accuracy of the model

模型	干扰 I+II	无干扰
DNN	0.658	0.762
DNN 对比无干扰情况下准确率下降	0.104	—
GNN	0.841	0.88
GNN 对比无干扰情况下准确率下降	0.039	—

4.4 案例分析

为了进一步说明模型的定位效果, 本文对模型的定位结果进行举例说明。

(1) 当直采网跳组网结构中发生主变间隔合并单元-母线保护装置光纤链路断链及中心交换机与主变间隔交换机相连的光口故障时, 受影响的链路及告警信号范围如图 4 所示, 其中保护装置无法接收 SV 报文而产生 SV 告警、端口接收功率低并同时产生 SV 总告警信号及装置总告警信号, 合并单元则报装置闭锁和合并单元告警总信号, 同时由于中心交换机无法接收间隔交换机发送的报文, 由主变间隔至母线间隔的报文传递均会产生流量告警, 故障图中的节点特征如式(10)所示。

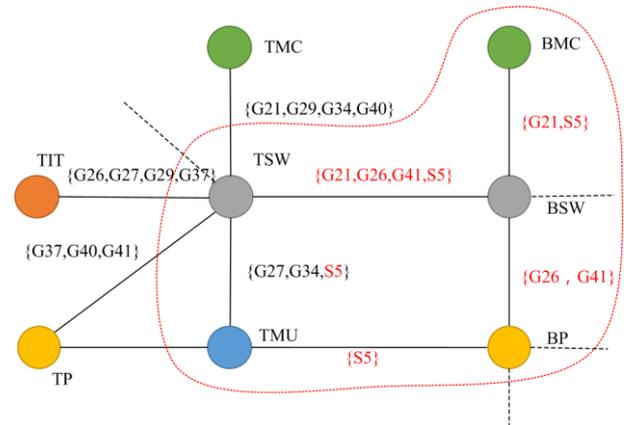


图 4 双重故障发生时告警信号范围与受影响的链路
Fig. 4 Alarm signal range and affected links when double-faults occurs

当输出层阈值为 0.9 时, 两种模型输出如式(11)和式(12)所示, 由于输出维度较大, 式中只展示了输出值保留两位小数后大于 0 的部分。

$$\begin{cases} x_{BP} = \text{Concat}([1, 0, 0, 0, 0], [0, 0, 0], \dots, \\ \quad \text{Port}_3 = [1, 1, 0], \dots, \text{Port}_5 = [2, 0, 0], [1, 1]) \\ x_{TMU} = \text{Concat}([0, 0, 1, 0, 0], [0, 0, 0], \dots, \\ \quad [0, 0, 0], [1, 1]) \\ x_{BMC} = \text{Concat}([0, 0, 0, 1, 0], [0, 0, 0], \dots, \\ \quad \text{Port}_5 = [2, 0, 0], [1, 0]) \\ x_{TSW} = \text{Concat}([0, 0, 0, 0, 1], [0, 0, 0], \dots, \\ \quad \text{Port}_5 = [4, 1, 0], [0, 0]) \\ x_{BSW} = \text{Concat}([0, 0, 0, 0, 1], [0, 0, 0], \dots, \\ \quad \text{Port}_5 = [3, 1, 1], [0, 0]) \end{cases} \quad (10)$$

$$\mathbf{O}_{\text{GNN}} = \begin{bmatrix} \text{MU-P} & \text{MU-SW} & \text{SW-SW} \\ 0.93 & \dots & 0.02 & \dots & 1.0 \end{bmatrix} \quad (11)$$

$$\mathbf{O}_{\text{DNN}} = \begin{bmatrix} \text{MU-P} & \text{SW-MU} & \text{SW-SW} & \text{MU.Board} \\ 0.99 & \dots & 0.33 & 0.49 & \dots & 0.11 \end{bmatrix} \quad (12)$$

从式(11)、式(12)可以看出, 在设定阈值为 0.9 的情况下, GNN 模型能够正确判断出两类故障, 而 DNN 模型只能判断出合并单元-保护装置光口(光纤)故障, 如果调低阈值则 DNN 模型可能出现交换机-合并单元光口(光纤)故障的误判, 且会造成模型整体准确率的下降。如果采用传统的交叉比对法, 所得故障范围如式(13)所示。

$$\mathbf{Y}_{\text{Cross}} = [\text{TSW} \quad \text{TSW-BSW} \quad \text{BSW}] \quad (13)$$

由式(13)可见, 交叉比对法所定位的故障范围除了定位到光纤与端口, 还将范围扩大至设备自身, 且同时发生的另一处故障由于举证值太小而被忽略。

(2) 网采网跳结构中线路保护 CPU 故障, 而站控层无相关告警信号时, 受影响的链路及告警信号范围如图 5 所示。其中线路智能终端与母线保护无法接收 GOOSE 报文产生 GOOSE 断链告警, 相关链路产生流量告警信息, 由此产生的节点特征如式(14)所示。

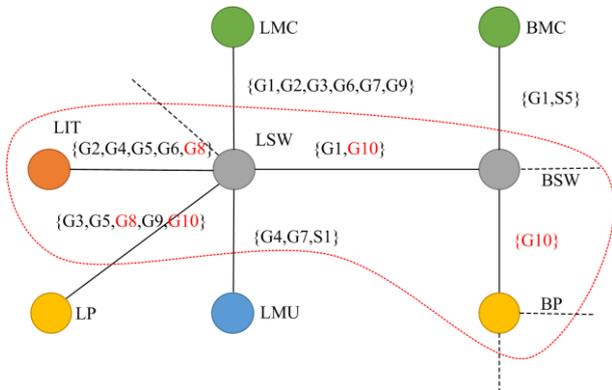


图 5 保护告警型号丢失时告警信号范围与受影响的链路

Fig. 5 Alarm signal range and affected links when the protection alarm is lost

两种模型的预测结果如式(15)、式(16)所示, GNN 模型在告警信号缺失的情况下正确判断出了故障, 而 DNN 则漏判了故障, 在识别出故障类型为保护本体故障后, 根据网络分析仪对 MMS 报文的侦测结果可以定位故障为线路保护 CPU 故障, 且线路保护上送站控层告警出现问题。

$$\begin{cases} x_{\text{LIT}} = \text{Concat}([0, 1, 0, 0, 0], [0, 0, 0], \dots, \\ \quad \text{Port}_5 = [1, 0, 0], [1, 1]) \\ x_{\text{LSW}} = \text{Concat}([0, 0, 0, 0, 1], [0, 0, 0], \\ \quad \text{Port}_2 = [2, 0, 0], \dots, [0, 0, 0], [0, 0]) \\ x_{\text{BSW}} = \text{Concat}([0, 0, 0, 0, 1], [0, 0, 0], \dots, \\ \quad \text{Port}_5 = [1, 0, 0], [0, 0]) \\ x_{\text{BP}} = \text{Concat}([1, 0, 0, 0, 0], [0, 0, 0], \dots, \\ \quad \text{Port}_5 = [1, 0, 0], [1, 1]) \end{cases} \quad (14)$$

$$\mathbf{Y}_{\text{GNN}} = \begin{bmatrix} \text{IT} & \text{P} & \text{SW-SW.Connect} \\ 0 & \dots & 1 & \dots & 0 \end{bmatrix} \quad (15)$$

$$\mathbf{Y}_{\text{DNN}} = \begin{bmatrix} \text{IT} & \text{P} & \text{SW-SW.Connect} \\ 0 & \dots & 0 & \dots & 0 \end{bmatrix} \quad (16)$$

而传统的交叉分析法得到的故障范围如式(17)所示, 其将定位范围扩大至间隔交换机及保护板卡故障。

$$\mathbf{Y}_{\text{Cross}} = [\text{LSW} \quad \text{LSW-LP} \quad \text{LP.Board} \quad \text{LP}] \quad (17)$$

5 结论

针对智能变电站二次回路故障定位传统方法难以处理大量高维数据, 深度学习可移植性差的问题, 本文提出了一种基于图神经网络的智能变电站故障定位方法。首先构建了智能变电站二次回路的图数据库, 而后建立了二次设备节点特征的表征方式, 作为图神经网络的输入。针对历史数据库信息记录不全, 难以快速积累故障样本等问题, 利用图数据库生成故障后构建训练集, 而后依据图神经网络搭建了故障定位模型, 并给出了故障定位框架。

依据不同组网方式下的故障算例结果显示, 本文所提出的图神经网络故障定位模型相较于传统机器学习及深度学习的方法更能精准定位故障, 并且具有较好的鲁棒性, 对今后以图的视角研究和推进智能变电站智能运维具有重要的意义。

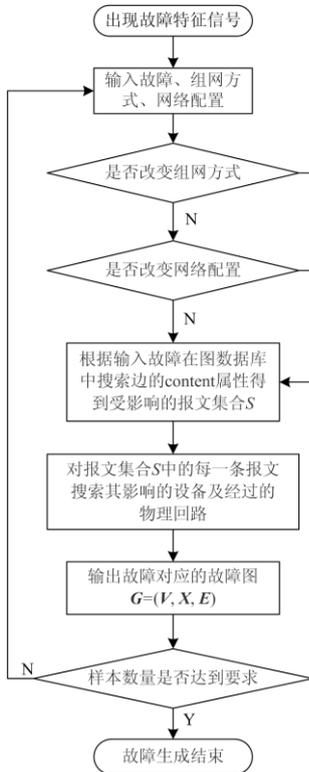
本文对告警信号的表征采用的是离散式表征法, 今后的研究能否将告警信号的语义信息采用分布式表征法进行表示来提高模型的性能有待进一步研究; 另一方面对于二次系统网络本文采用同质图进行建模, 如果采用异质图是否是更好的表征模式同样值得进一步研究。

附录

附表 1 故障分类

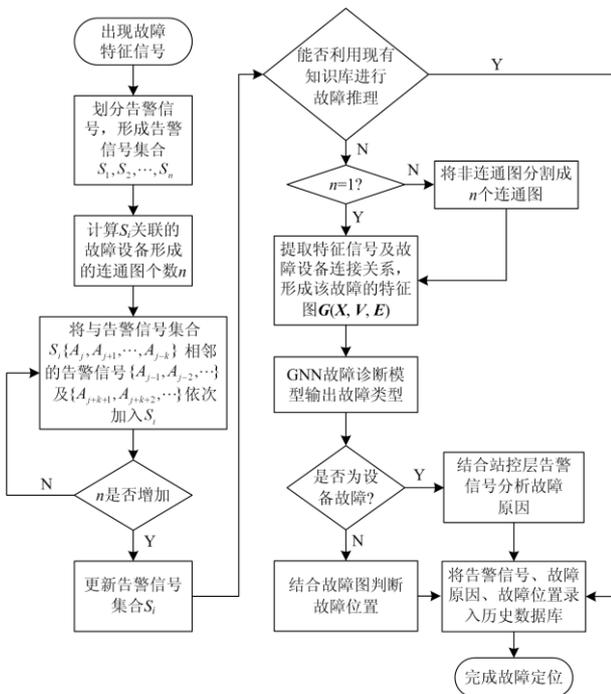
Attached Table 1 Classes of faults

故障类别	故障分类	故障类别	故障分类
装置本体故障	P		IT-P
	IT		IT-SW
	MU		MC-SW
	MC	装置光口 (光纤)故障	MU-SW
	SW		MU-MU
装置接线错误	IT-P.Connect		MU-P
	IT-SW.Connect		P-SW
	MU-SW.Connect		SW-SW
	MU-MU.Connect		P.Config
	MU-P.Connect	装置配置 错误	IT.Config
	P-SW.Connect		MU.Config
	P-IT.Connect		MC.Config
	P-MU.Connect		P.Borad
	SW-MC.Connect	装置板卡 故障	IT.Borad
	SW-SW.Connect		MU.Borad



附图 1 故障生成流程图

Attached Fig. 1 Fault generation flowchart



附图 2 二次回路故障定位的基本框架

Attached Fig. 2 Basic structure of secondary circuit fault location

参考文献

[1] 王同文, 谢民, 孙月琴, 等. 智能变电站继电保护系统可靠性分析[J]. 电力系统保护与控制, 2015, 43(6): 58-66.
WANG Tongwen, XIE Min, SUN Yueqin, et al. Analysis of reliability for relay protection systems in smart substation[J]. Power System Protection and Control, 2015, 43(6): 58-66.

[2] TAVAKOLI M, NAFAR M. Human reliability analysis in maintenance team of power transmission system protection[J]. Protection and Control of Modern Power Systems, 2020, 5(4): 1-13.

[3] 张炜, 梁俊斌, 覃剑. 基于多智能体的变电站机器人巡检远程集控系统[J]. 电力信息与通信技术, 2020, 18(12): 9-16.
ZHANG Wei, LIANG Junbin, QIN Jian. A remote centralized control system of substation robot inspection based on MAS[J]. Electric Power Information and Communication Technology, 2020, 18(12): 9-16.

[4] 朱建斌, 李宝伟, 倪传坤, 等. 一种应用于第三代智能变电站主设备就地模块的研究及开发[J]. 高压电器, 2020, 56(12): 226-234.
ZHU Jianbin, LI Baowei, NI Chuankun, et al. Research and development of a local module applied to the main equipment of the third generation intelligent substation[J]. High Voltage Apparatus, 2020, 56(12): 226-234.

[5] 李书山, 刘宏君, 吴忠福, 等. 智能变电站二次系统可靠性建模及分析[J]. 电测与仪表, 2020, 57(21): 61-69.
LI Shushan, LIU Hongjun, WU Zhongfu, et al. Reliability modeling and analysis of secondary system in

- smart substation[J]. *Electrical Measurement & Instrumentation*, 2020, 57(21): 61-69.
- [6] 李新海, 徐宝军, 罗其锋, 等. 变电站微环境智能控制系统的研究与应用[J]. *供用电*, 2020, 37(11): 75-82.
LI Xinhai, XU Baojun, LUO Qifeng, et al. Research and application of microenvironment intelligent control system in substation[J]. *Distribution & Utilization*, 2020, 37(11): 75-82.
- [7] 蒲天骄, 乔骥, 韩笑, 等. 人工智能技术在电力设备运维检修中的研究及应用[J]. *高电压技术*, 2020, 46(2): 369-383.
PU Tianjiao, QIAO Ji, HAN Xiao, et al. Main features and key technologies of digital substation[J]. *High Voltage Engineering*, 2020, 46(2): 369-383.
- [8] 王治民, 陈炯聪, 任雁铭, 等. 网络通信记录分析系统在数字化变电站中的应用[J]. *电力系统自动化*, 2010, 34(14): 92-95.
WANG Zhimin, CHEN Jiongcong, REN Yanming, et al. Application of network communication recorder and analyzer in digital substations[J]. *Automation of Electric Power Systems*, 2010, 34(14): 92-95.
- [9] 刘渝根, 陈超, 杨蕊菁, 等. 基于小波相对熵的变电站直流系统接地故障定位方法[J]. *高压电器*, 2020, 56(1): 169-174.
LIU Yugen, CHEN Chao, YANG Ruijing, et al. Location method of ground fault in DC system of substation based on waveletrelative entropy[J]. *High Voltage Apparatus*, 2020, 56(1): 169-174.
- [10] 尹相国, 张文, 路致远, 等. 面向智能变电站二次设备的故障诊断方法研究[J]. *电测与仪表*, 2020, 57(3): 39-45.
YIN Xiangguo, ZHANG Wen, LU Zhiyuan, et al. Research on fault diagnosis method for secondary equipment of intelligent substation[J]. *Electrical Measurement & Instrumentation*, 2020, 57(3): 39-45.
- [11] 李宽宏. 变电站二次设备防误风险管控系统实现方案[J]. *电力系统自动化*, 2020, 44(17): 95-101.
LI Kuanhong. Implementation scheme of risk management and control system for anti-misoperation of secondary devices in substation[J]. *Automation of Electric Power Systems*, 2020, 44(17): 95-101.
- [12] 刘健, 张志华, 王毅钊. 基于电压信息的配电网断线故障定位[J]. *电力系统自动化*, 2020, 44(21): 123-131.
LIU Jian, ZHANG Zhihua, WANG Yizhao. Voltage information based line-broken fault location for distribution network[J]. *Automation of Electric Power Systems*, 2020, 44(21): 123-131.
- [13] 周红阳, 黄佳胤, 张弛, 等. 基于Petri网的智能变电站GOOSE回路故障诊断[J]. *南方电网技术*, 2017, 11(6): 49-56.
ZHOU Hongyang, HUANG Jiayin, ZHANG Chi, et al. Petri net based fault diagnosis for GOOSE circuits of smart substation[J]. *Southern Power System Technology*, 2017, 11(6): 49-56.
- [14] 戴志辉, 鲁浩, 刘媛, 等. 基于改进D-S证据理论的智能站保护二次回路故障诊断方法[J]. *电力系统保护与控制*, 2020, 48(9): 59-67.
DAI Zhihui, LU Hao, LIU Yuan, et al. A fault diagnosis method for the secondary circuits of protection systems in smart substations based on improved D-S evidence theory[J]. *Power System Protection and Control*, 2020, 48(9): 59-67.
- [15] 高磊, 杨毅, 刘琦, 等. 基于举证表的智能变电站过程层通道故障定位方法[J]. *电力系统自动化*, 2015, 39(4): 147-151.
GAO Lei, YANG Yi, LIU Yu, et al. Proof table based fault location method for process level channel in smart substations[J]. *Automation of Electric Power Systems*, 2015, 39(4): 147-151.
- [16] 王洪彬, 徐亨, 童晓阳, 等. 基于结构熵权法与故障树的智能变电站保护系统扰动度在线评估方法[J]. *电网技术*, 2019, 43(5): 1772-1787.
WANG Hongbin, XU Heng, TONG Xiaoyang, et al. The online disturbance degree assessment method of protection systems in intelligent substation based on the structure entropy weight method and fault trees[J]. *Power System Technology*, 2019, 43(5): 1772-1787.
- [17] 叶远波, 黄太贵, 谢民, 等. 基于多模型融合集成学习的智能变电站二次设备状态评估[J]. *电力系统保护与控制*, 2021, 49(12): 148-157.
YE Yuanbo, HUANG Taigui, XIE Min, et al. A state assessment method for intelligent substation secondary equipment based on multi-model ensemble learning[J]. *Power System Protection and Control*, 2021, 49(12): 148-157.
- [18] 范卫东, 冯晓伟, 董金星, 等. 基于历史数据语义相似度的智能变电站虚端子自动连接[J]. *电力系统保护与控制*, 2020, 48(17): 179-186.
FAN Weidong, FENG Xiaowei, DONG Jinxing, et al. Automatic matching method of a virtual terminal in intelligent substation based on semantic similarity of historical data[J]. *Power System Protection and Control*, 2020, 48(17): 179-186.
- [19] 孙宇嫣, 蔡泽祥, 郭采珊, 等. 基于深度学习的智能变电站通信网络故障诊断与定位方法[J]. *电网技术*, 2019, 43(12): 4306-4314.

- SUN Yuyan, CAI Zexiang, GUO Caishan, et al. Fault diagnosis and positioning for communication network in intelligent substation based on deep learning[J]. Power System Technology, 2019, 43(12): 4306-4314.
- [20] 杨雯, 尹康涌, 鲍奕宇, 等. 基于深度置信网络的电网故障类型辨识[J]. 电力工程技术, 2021, 40(2): 169-177.
- YANG Wen, YIN Kangyong, BAO Yiyu, et al. Fault types identification of power grid based on deep belief network[J]. Electric Power Engineering Technology, 2021, 40(2): 169-177.
- [21] 钱虹, 郑子彬, 冯裕卿, 等. 基于故障样本的滚动轴承故障诊断置信规则库研究[J]. 电力科学与技术学报, 2020, 35(1): 144-150.
- QIAN Hong, ZHENG Zibin, FENG Yuqing, et al. Research of confidence rule base for fault diagnosis of rolling bearing based on faulty sample[J]. Journal of Electric Power Science and Technology, 2020, 35(1): 144-150.
- [22] 张延旭, 蔡泽祥, 龙翩翩, 等. 智能变电站通信网络实时故障诊断模型与方法[J]. 电网技术, 2016, 40(6): 1851-1857.
- ZHANG Yanxu, CAI Zexiang, LONG Pianpian, et al. Real-time fault diagnosing models and method for communication network in smart substation[J]. Power System Technology, 2016, 40(6): 1851-1857.
- [23] 李辉, 张孝军, 潘华, 等. 面向智能变电站通信网络可靠性研究[J]. 电力系统保护与控制, 2021, 49(9): 165-171.
- LI Hui, ZHANG Xiaojun, PAN Hua, et al. Research on a reliability evaluation method of a communication network for an intelligent substation[J]. Power System Protection and Control, 2021, 49(9): 165-171.
- [24] 刘玮, 王海柱, 张延旭. 智能变电站过程层网络报文特性分析与通信配置研究[J]. 电力系统保护与控制, 2014, 42(6): 110-115.
- LIU Wei, WANG Haizhu, ZHANG Yanxu. Study on message characteristics and communication configuration of process layer network of intelligent substation[J]. Power System Protection and Control, 2014, 42(6): 110-115.
- [25] 高磊, 杨毅, 苏麟, 等. 智能变电站二次系统物理回路建模方法及设计实现[J]. 电力系统保护与控制, 2016, 44(24): 130-139.
- GAO Lei, YANG Yi, SU Lin, et al. A modeling approach and design implementation of secondary system physical circuit for smart substation[J]. Power System Protection and Control, 2016, 44(24): 130-139.
- [26] 郝晓光, 耿少博, 任江波, 等. 智能变电站二次电缆回路建模方法研究与应用[J]. 电力科学与技术学报, 2020, 35(4): 161-168.
- HAO Xiaoguang, GENG Shaobo, REN Jiangbo, et al. Research and application of modeling method of secondary cable loop in intelligent substation[J]. Journal of Electric Power Science and Technology, 2020, 35(4): 161-168.
- [27] 席禹, 邹俊雄, 蔡泽祥, 等. 基于报文识别与流量管控的智能变电站保护控制信息安全防护方法[J]. 电网技术, 2017, 41(2): 624-629.
- XI Yu, ZOU Junxiang, CAI Zexiang, et al. Information security protection method for smart substation communication network based on message identification and flow control[J]. Power System Technology, 2017, 41(2): 624-629.
- [28] SANCHEZ-GONZALEZ, HEES N, SPRINGENBERG T, et al. Graph networks as learnable physics engines for inference and control[J]. arXiv: 1806.01242, 2018.
- [29] FOUT A, BYRD J, SHARIAT B, et al. Protein interface prediction using graph convolutional networks[C] // NIPS'17: Proceedings of the 31st International Conference on Neural Information Processing Systems, December 4, 2017: 6530-6539.
- [30] WANG Z, LV Q, LAN X, et al. Cross-lingual knowledge graph alignment via graph convolutional networks[C] // Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing, October 30th-November 2nd, 2018, Brussels, Belgium: 349-357.
- [31] 许鹏程, 林建森, 林缔, 等. 改进严重度模型下计及二次系统影响的电网风险评估[J]. 电力工程技术, 2021, 40(2): 212-219.
- XU Pengcheng, LIN Jiansen, LIN Di, et al. Grid risk assessment based on the improved severity model considering the influence of secondary system[J]. Electric Power Engineering Technology, 2021, 40(2): 212-219.

收稿日期: 2021-08-07; 修回日期: 2021-09-24

作者简介:

张宸滔(1997—), 男, 硕士研究生, 研究方向为智能变电站二次系统故障定位等; E-mail: zhangchentao123@gmail.com

郑永康(1977—), 男, 通信作者, 博士, 教授级高级工程师, 研究方向为电力系统继电保护等。E-mail: zyk555@163.com

(编辑 葛艳娜)