

DOI: 10.19783/j.cnki.pspc.231630

# 基于图半监督与多任务学习的配电网故障区段与类型统一辨识

梁栋<sup>1,2</sup>, 赵月梓<sup>1,2</sup>, 贺国润<sup>1,2</sup>, 陈海文<sup>1,2</sup>

(1. 河北工业大学创新研究院, 河北 石家庄 050222; 2. 省部共建电工装备可靠性与智能化国家重点实验室(河北工业大学), 天津 300401)

**摘要:** 为解决深度学习类配电网故障辨识方法在量测不足和标记率低时准确率不高的问题, 提出了基于图半监督与多任务学习的故障区段与类型统一辨识方法。首先, 设计了故障区段与类型统一辨识的图神经网络架构, 在图嵌入层中融入网络拓扑和线路参数信息, 以充分挖掘不同位置、类型的故障特征。其次, 采用多任务注意力网络构建了故障区段定位和类型辨识两个任务, 以提取故障的多重信息, 实现不同任务间知识转移。再次, 将图嵌入特征与无标签样本的编码压缩特征进行融合, 得到新的多任务共享特征, 以充分利用未标记数据, 增强模型泛化能力。最后, 通过算例测试表明, 所提方法的故障辨识精度优于传统神经网络, 且在实时量测少、标签率低及不同量测噪声条件下具有更好的鲁棒性。

**关键词:** 半监督学习; 多任务学习; 图神经网络; 故障辨识; 配电网

## Unified identification of fault section and type for distribution networks based on graph semi-supervised and multi-task learning

LIANG Dong<sup>1,2</sup>, ZHAO Yuezi<sup>1,2</sup>, HE Guorun<sup>1,2</sup>, CHEN Haiwen<sup>1,2</sup>

(1. Innovation Research Institute of Hebei University of Technology, Shijiazhuang 050222, China; 2. State Key Laboratory of Reliability and Intelligence of Electrical Equipment (Hebei University of Technology), Tianjin 300401, China)

**Abstract:** There is an issue of low accuracy in deep learning-based fault identification methods for power distribution networks in conditions of insufficient measurements and low labeling rates. Thus a unified identification method of fault section and type is proposed based on graph semi-supervised and multi-task learning. First, a neural network architecture is designed for unified identification of fault section and type. This architecture integrates network topology and line parameter information into the graph embedding layer to effectively extract features of faults at different locations and types. Secondly, the fault section location and type identification tasks are constructed using a multi-task attention network. This is to extract multiple pieces of fault information and enable knowledge transfer between different tasks. Thirdly, graph embedding features and encoded compressed features of unlabeled samples are integrated to obtain new multi-task shared features, such that unlabeled samples can be fully used and the model's generalizability can be enhanced. Finally, case studies demonstrate that the proposed method surpasses traditional neural networks in fault identification accuracy and shows better robustness in conditions of insufficient real-time measurements, low labeling rates and various types of measurement noise.

This work is supported by the Natural Science Foundation of Hebei Province (No. E2021202053).

**Key words:** semi-supervised learning; multi-task learning; graph neural network; fault identification; distribution network

## 0 引言

配电网与用户紧密相连, 是保障用户可靠供电

**基金项目:** 河北省自然科学基金项目资助(E2021202053); 天津市自然科学基金项目资助(22JCQNJC00160); 河北工业大学创新研究院石家庄市科技合作专项基金项目资助(SJZZXB23006)

的关键环节。然而, 配电网结构复杂、运行环境恶劣、故障发生概率高, 若故障得不到及时处理, 将会严重影响用户可靠供电<sup>[1]</sup>。故障处理包括故障定位、隔离和供电恢复等环节, 其中故障类型辨识与区段定位是故障隔离和供电恢复的基础, 具有重要意义。由于配电网放射状结构和有限的量测配置, 若将输电网故障类型辨识及定位方法直接应用于配电网则效果较差。

配电网故障区段定位方法通常分为三类：基于测量信号法<sup>[1-5]</sup>、基于注入信号法<sup>[6-7]</sup>和基于人工智能的方法。其中，测量信号法包含基于稳态测量信号的阻抗法<sup>[1-2]</sup>、谐波法<sup>[3]</sup>和基于暂态测量信号的小波法<sup>[4]</sup>、行波法<sup>[5]</sup>等。表1列举了上述方法的缺点，其中基于测量信号法、注入信号法易受可观性、网络参数、故障类型及负荷波动等因素的影响；而基于传统神经网络的人工智能方法易受随机环境及标记数据不足的影响<sup>[8]</sup>。

表1 传统故障定位方法的缺点

Table 1 Disadvantages of traditional fault location methods

故障定位方法	缺点
基于阻抗的方法	需要全网络参数可观、对参数敏感、受故障类型、分布式电源接入及网络不平衡等影响
行波法	对量测装置要求高、经济性差
注入信号法	易受故障阻抗影响、经济性差
传统人工智能方法	易受随机环境影响和标记数据不足的影响

故障类型辨识对于快速处理故障具有重要作用，故障类型辨识方法可分为基于特征提取的方法和基于神经网络的方法。文献[9]通过使用Clarke变换和S变换提取故障特征，并采用模糊逻辑和模糊H网相结合的混合模型实现故障类型辨识；文献[10]采用Karenbauer变换将三相电流变换为0、 $\alpha$ 、 $\beta$ 模分量，根据各分量在故障前后的幅值畸变度对故障进行初步分类，然后选择不同的特征量进行灰色关联度计算确定故障类型；文献[11]提出了基于有功电流注入的故障相位辨识方法；文献[12]通过对故障后的暂态电流进行Hilbert-Huang变换并构建时频能量矩阵，使用卷积神经网络(convolutional neural network, CNN)进行故障分类。

准确的配电网故障类型辨识及定位依赖于完善的量测配置。近年来，微型相量测量单元(micro-phasor measurement units,  $\mu$ PMU)发展迅速，为配电网故障精确感知创造了条件<sup>[13]</sup>。文献[14]根据故障监测域内相电流是否突变或差动电流是否超过阈值来缩小故障查找范围，再根据不平衡电流故障定位算法来确定故障位置；文献[15]基于 $\mu$ PMU行波故障采集模块搭建基准时间特征矩阵和故障时间特征矩阵，通过分析故障前、后特征矩阵进行故障选线及定位；文献[16]利用末端节点注入电流后线路两端节点电压变化量与末端节点量测电压变化量间的关系，提出了基于线路末端节点电压差值的故障定位方法。然而，由于配电网规模巨大，若大规模部署 $\mu$ PMU将导致巨额投资，而采用有限 $\mu$ PMU配置往往导致上述方法准确率偏低。

基于人工智能的配电网故障辨识与定位方法

具有效率高、准确度高和鲁棒性强的优点<sup>[17-18]</sup>，一直受到广泛关注。图神经网络(graph neural network, GNN)将神经网络与图数据相结合，利用GNN融合网络拓扑结构提高了模型精度和鲁棒性。基于GNN的方法聚集了节点的空间信息，以逐层的方式提取和聚合特征<sup>[19]</sup>，对于配电网故障定位效果优异<sup>[20]</sup>。然而，现有基于人工智能的故障辨识方法在低可观性、低标签率条件下效果较差，且未对故障位置及故障类型统一辨识<sup>[21]</sup>。

针对以上问题，本文设计了配电网故障区段与类型统一辨识的图神经网络架构，在充分挖掘不同位置、类型故障特征的基础上，基于多任务注意力网络构建了故障区段定位和类型辨识两个任务分支，以提取故障的多重信息，实现不同任务间正向知识转移；进而在网络中引入自编码器，通过对无标签样本进行编码与重构，将图嵌入特征与无标签样本的编码压缩特征进行融合，得到新的多任务共享特征，以充分利用未标记数据，增强模型的泛化能力。通过典型算例测试，验证了所提方法在低可观性、低标签率、分布式电源接入、测量噪声等因素的影响下具有较高的故障辨识精度。

## 1 配电网故障定位及类型辨识问题描述

配电网短路故障类型包括：单相接地、两相相间短路、两相接地短路、三相相间短路和三相接地故障。本文将故障类型辨识及定位看作多分类问题，且通过多任务学习同时完成故障类型辨识和区段定位两个任务。

对于含 $n$ 个节点的配电网，发生某短路故障后，利用 $s(s < n)$ 个可观测节点的三相电压幅值、相角量测构造样本，第 $p$ 个样本所包含的节点特征矩阵 $\mathbf{X}^p$ 如式(1)所示，其中对不可观测节对应行赋零，表示为

$$\mathbf{X}^p = [(\mathbf{U}_1^p)^T (\mathbf{U}_2^p)^T \cdots (\mathbf{U}_n^p)^T]^T \in \mathbb{R}^{n \times 6}, p = 1, \dots, N \quad (1)$$

式中： $\mathbf{U}_i^p \in \mathbb{R}^{1 \times 6} = [U^a \ \theta^a \ U^b \ \theta^b \ U^c \ \theta^c]$ 为第 $p$ 个样本中第 $i$ 个节点的三相电压幅值、相角量测； $N$ 为样本数量。

对数据集中每个样本设置两类标签，即故障位置标签和故障类型标签，分别表示为

$$y_1^p \in \{1, \dots, c_1\}, p = 1, \dots, M \quad (2)$$

$$y_2^p \in \{1, \dots, c_2\}, p = 1, \dots, M \quad (3)$$

式中： $y_1^p$ 为第 $p$ 个样本的故障区段标签； $c_1$ 为可能的故障位置数量； $y_2^p$ 为第 $p$ 个样本的故障类型标签； $c_2$ 为可能的故障类型数量； $M$ 为数据集中具有标签的样本数量， $M < N$ 。

至此, 故障类型辨识及定位已转化为多分类问题, 然而, 受到配电网稀疏观测与低标签率的影响, 传统基于有监督学习的分类器无法直接使用。

## 2 配电网故障区段与类型统一辨识

本文提出一种具有三阶段的图多任务神经网络框架, 其结构图如图 1 所示, 阶段 I、阶段 II 构成监督学习部分, 阶段 III 为无监督学习部分。

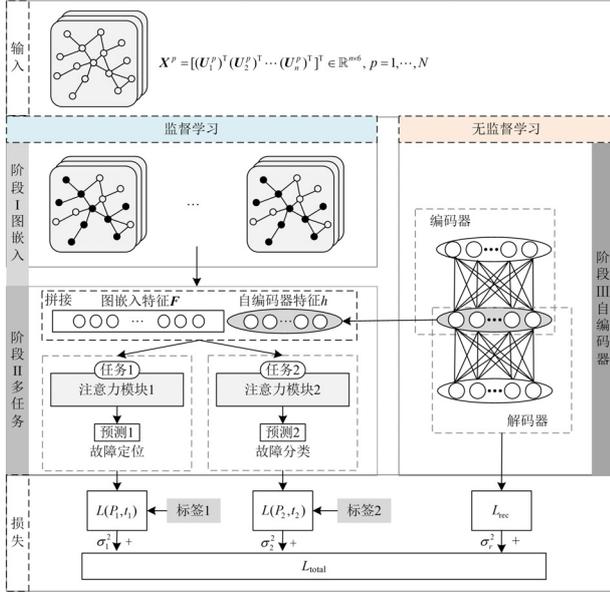


图 1 基于图半监督和多任务学习的神经网络结构

Fig. 1 Neural network structure based on graph semi-supervised and multi-task learning

阶段 I 为图嵌入阶段, 采用基于拼接聚合的 GNN 模型, 以聚合与拼接的形式增强网络不可观测节点的信息嵌入能力。

阶段 II 采用多任务注意力网络(multi-task attention network, MATN)<sup>[22]</sup>, 对阶段 I 嵌入的全局特征分配不同任务的注意力机制, 进而在标签监督下完成故障定位及故障类型辨识。

阶段 III 通过自编码器<sup>[23]</sup>学习原始输入特征的有效表示, 最小化重构损失并反向传播于监督学习的分类任务, 提高有限标签下模型的性能及泛化能力。

### 2.1 阶段 I: 图嵌入阶段

GNN 作为一种强大的深度学习框架, 已经在处理复杂图结构数据方面取得了显著成就。GNN 将目标节点的邻居信息聚合到目标节点, 通过不断扩大聚合范围完成信息提取, 具有很强的全局信息提取能力。本文在图嵌入阶段采用具有聚合与拼接功能的 GNN, 通过邻接聚合与特征拼接的方式为不可观

测节点生成嵌入向量, 增强对不可观测节点的图嵌入能力, 具体思路如下。

将含  $n$  个节点、 $m$  条支路的配电网抽象为节点和边构成的图, 用  $G=(V, E)$  表示, 其中  $V$  为所有节点集合,  $V=\{v_1, v_2, \dots, v_n\}$ ;  $E$  为所有边的集合,  $E=\{e_1, e_2, \dots, e_m\}$ , 其中  $e_{ij}=(v_i, v_j)$  表示节点  $v_i$  与  $v_j$  之间的边。图的邻接矩阵为  $A \in \mathbb{R}^{n \times n}$ , 表示节点间的连接关系; 图的节点特征矩阵为  $X^p \in \mathbb{R}^{m \times 6}$ , 其中  $U_v \in \mathbb{R}^{6}$  为节点  $v$  的特征向量。

为了更好地反映配电网的实际连接情况, 使用归一化的无自环网络节点导纳矩阵  $A_Y \in \mathbb{R}^{n \times n}$  代替  $A$  作为邻接矩阵, 其  $i$  行  $j$  列元素  $a_{ij}$  为

$$a_{ij} = \begin{cases} Y_{ij} / \sum_{k \neq i} Y_{ik}, & (v_i, v_j) \in E \\ 0, & \text{其他} \end{cases} \quad (4)$$

式中,  $Y_{ij}$  为节点  $v_i$  与  $v_j$  之间的互导纳。

基于该邻接矩阵, GNN 第  $l$  层聚合规则为

$$\mathbf{h}^{(l)}(v) = \text{Agr}(\{\mathbf{h}^{(l-1)}(u) | u \in \mathcal{N}(v)\}) \quad (5)$$

式中:  $\mathbf{h}^{(l)}(v)$  为 GNN 第  $l$  层节点  $v$  的特征向量;

$\mathcal{N}(v)$  为节点  $v$  的邻居节点集合;  $\mathbf{h}^{(l-1)}(u)$  为 GNN 第  $l-1$  层节点  $u$  的特征向量;  $\text{Agr}(\cdot)$  为聚合函数, 如式(6)所示。

$$\text{Agr}(\{\mathbf{h}^{(l-1)}(u) | u \in \mathcal{N}(v)\}) = \frac{1}{|\text{Adj}[v]|} \sum_{u \in \mathcal{N}(v)} \mathbf{h}^{(l-1)}(u) \cdot a_{uv} \quad (6)$$

式中:  $|\text{Adj}[v]|$  为节点  $v$  的邻居节点数,  $a_{uv}$  为  $A$  的  $u$  行  $v$  列所对应的元素, 表示节点  $v$  与其邻居节点  $u$  的特征系数。

对每个节点  $v$ , 在聚合邻居节点的特征之后, 进行特征转换得到新的节点特征, 表示为

$$\mathbf{h}^{(l)}(v) = \text{ReLU}(\mathbf{W}^{(l)} \cdot [\mathbf{h}^{(l-1)}(v) \parallel \mathbf{h}^{(l)}(v)] + \mathbf{b}^{(l)}) \quad (7)$$

式中:  $\mathbf{W}^{(l)}$  和  $\mathbf{b}^{(l)}$  分别为  $l$  层的权重矩阵和偏置向量;  $\parallel$  表示两个向量拼接;  $\text{ReLU}(\cdot)$  为激活函数,  $\text{ReLU}(x) = \max(0, x)$ 。

### 2.2 阶段 II: 多任务学习阶段

若对故障区段定位与类型辨识两个任务分别独立设计神经网络, 则切断了两个任务之间的联系, 无法充分利用故障位置和故障类型的关联性。因此本文采用 MATN 构建故障区段定位和类型辨识两个任务, 以提取故障的多重信息, 实现不同任务间正向知识转移, 利用相关任务的关联信息来提高所有任务的泛化能力, 达到从数据集提取更多特征的目的。

本文基于共享硬参数隐藏层的 MATN, 通过硬

参数隐藏层实现底层参数共享, 然后通过特定注意力模块完成不同任务的输出。图 2 为 MTAN 结构, 经过图嵌入阶段后, 所得的图嵌入特征通过 MTAN 进行多任务分类。MTAN 由全局共享特征层及每个任务独立的注意力模块组成, 每个子任务的注意力机制模块能够自动决定共享特征对于任务的重要程度, 在不同任务之间进行泛化的同时为每个单独的任务定制区别特征, 达到多任务训练的效果。

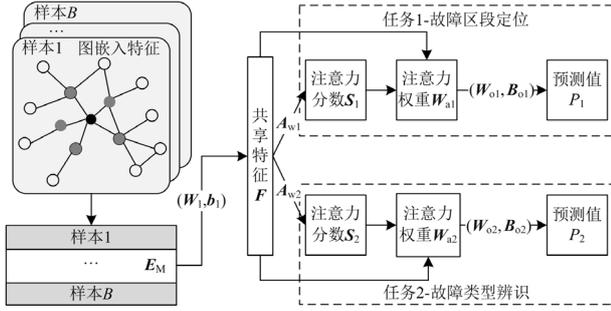


图 2 MTAN 结构

Fig. 2 Structure of the MATN

如图 2 所示, 获取各节点的图嵌入特征矩阵后, 首先将其重塑为行向量, 再经过一层全连接神经网络, 得到共享特征, 表示为

$$\mathbf{F} = \text{ReLU}(\mathbf{E}_M \mathbf{W}_1 \oplus \mathbf{b}_1) \quad (8)$$

式中:  $\mathbf{E}_M \in \mathbb{R}^{B \times E}$  为阶段 I 输出的图嵌入特征向量,  $B$  为批次样本数量;  $\mathbf{W}_1 \in \mathbb{R}^{E \times B}$  为神经网络权重矩阵,  $E$  为特征维度;  $\mathbf{b}_1 \in \mathbb{R}^{B \times 1}$  为偏置向量;  $\mathbf{F} \in \mathbb{R}^{B \times B}$  为共享特征矩阵;  $\oplus$  为将  $\mathbf{b}_1$  向量维度扩张至  $\mathbb{R}^{B \times B}$  后再按元素相加。

进一步, 计算每个样本关于任务 1(故障定位)与任务 2(故障类型)的注意力分数  $\mathbf{S}_1$ 、 $\mathbf{S}_2$ , 分别表示为

$$\begin{cases} \mathbf{S}_1 = \mathbf{F} \mathbf{A}_{w1} \\ \mathbf{S}_2 = \mathbf{F} \mathbf{A}_{w2} \end{cases} \quad (9)$$

式中:  $\mathbf{A}_{w1}$ 、 $\mathbf{A}_{w2} \in \mathbb{R}^{B \times 1}$  为注意力权重向量;  $\mathbf{S}_1$ 、 $\mathbf{S}_2 \in \mathbb{R}^{B \times 1}$ 。

两个任务的注意力输出权重矩阵表示为

$$\begin{cases} \mathbf{W}_{a1} = \mathbf{F} \odot \text{Softmax}(\mathbf{S}_1) \\ \mathbf{W}_{a2} = \mathbf{F} \odot \text{Softmax}(\mathbf{S}_2) \end{cases} \quad (10)$$

式中:  $\text{Softmax}(\mathbf{S}_i) = e^{S_i} / \sum_{c=1}^B e^{S_c}$ ,  $S_c$  为对应样本注意力分数;  $\odot$  为将  $\text{Softmax}(\cdot)$  向量维度扩张至  $\mathbb{R}^{B \times B}$  后再按元素相乘。

两个任务的预测值为  $\mathbf{P}_1$ 、 $\mathbf{P}_2$ , 表示为

$$\begin{cases} \mathbf{P}_1 = \text{Dropout}(\mathbf{W}_{o1} \mathbf{W}_{a1} + \mathbf{B}_{o1}) \\ \mathbf{P}_2 = \text{Dropout}(\mathbf{W}_{o2} \mathbf{W}_{a2} + \mathbf{B}_{o2}) \end{cases} \quad (11)$$

式中:  $\text{Dropout}(\cdot)$  为丢弃函数;  $\mathbf{W}_{o1} \in \mathbb{R}^{B \times c_1}$ 、 $\mathbf{W}_{o2} \in \mathbb{R}^{B \times c_2}$  分别为任务 1、2 的输出权重矩阵;  $\mathbf{B}_{o1} \in \mathbb{R}^{c_1}$ 、 $\mathbf{B}_{o2} \in \mathbb{R}^{c_2}$  分别为任务 1、2 的输出偏置向量。

MATN 结构通过特征共享和联合优化, 共同作用于模型更新, 提升模型泛化能力, 降低出现过拟合的概率, 有效提升模型性能。

### 2.3 阶段 III: 无监督自动编码与重构阶段

配电网训练数据中存在大量故障特征数据没有被标记的情况, 本文应用自编码器, 通过对无标签样本进行编码与重构, 并将编码特征与图嵌入特征拼接, 增强模型的特征学习效率与泛化能力。此阶段为无监督学习, 用于进一步增强模型的准确率。

自编码器由编码器与解码器构成, 输入维度等于输出维度, 其结构如图 3 所示。

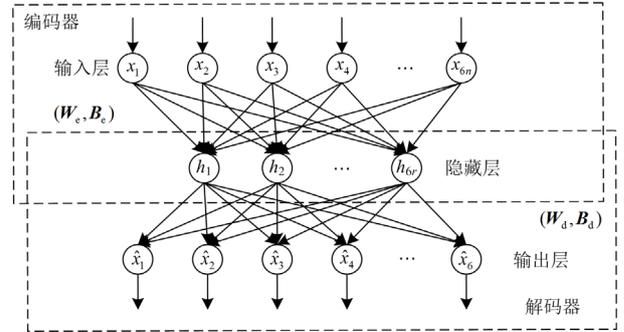


图 3 自编码器结构

Fig. 3 Structure of an auto-encoder

对任意无标签样本, 其原始输入向量为  $\mathbf{X} = [\mathbf{x}_1 \mathbf{x}_2 \cdots \mathbf{x}_n]^T \in \mathbb{R}^{6n \times 1}$ , 通过编码器编码为隐藏层向量  $\mathbf{h} \in \mathbb{R}^{6r \times 1}$ , 表示为

$$\mathbf{h} = \text{ReLU}(\mathbf{W}_e \mathbf{X} + \mathbf{b}_e) \quad (12)$$

式中,  $\mathbf{W}_e \in \mathbb{R}^{6r \times 6n}$  和  $\mathbf{b}_e \in \mathbb{R}^{6r \times 1}$  分别为编码层的权重矩阵和偏置向量,  $r < n$  为隐藏层的维度, 即隐藏层向量  $\mathbf{h}$  可表示对原始输入的特征压缩提取。

解码层将隐藏层特征向量的编码解码为重构特征  $\hat{\mathbf{x}} = [\hat{\mathbf{x}}_1 \hat{\mathbf{x}}_2 \cdots \hat{\mathbf{x}}_{6n}]^T$ , 表示为

$$\hat{\mathbf{x}} = \mathbf{W}_d \mathbf{h} + \mathbf{b}_d \quad (13)$$

式中,  $\mathbf{W}_d$  与  $\mathbf{b}_d$  分别为解码层的权重矩阵和偏置向量。

在加入阶段 III 的自编码器后, 将阶段 I 的中图嵌入特征 ( $\mathbf{E}_M$  的各行) 与自编码器隐藏层压缩特征  $\mathbf{h}$  进行拼接, 再经过一层全连接神经网络, 得到新的共享特征, 表示为

$$\mathbf{F}' = \text{ReLU}(\mathbf{E}'_M \mathbf{W}'_1 \oplus \mathbf{b}'_1) \quad (14)$$

式中:  $\mathbf{E}'_M$  为图嵌入特征与自编码器特征拼接后的

批特征矩阵;  $W'_1$ 、 $b'_1$  分别为相应维度的神经网络权重矩阵和偏置向量。

## 2.4 损失函数

不确定性加权在多任务中起着非常重要的作用, 其能够根据各个任务的重要性和可靠性调整对每个任务的关注度, 从而动态调整多任务学习过程。模型使用同方差不确定性加权的方法, 通过估计不确定性参数进而调整各任务的权重<sup>[24]</sup>。

分类器任务 1 为故障定位, 任务 2 为故障类型辨识, 其损失函数分别为  $L_{t1}$ 、 $L_{t2}$ , 表示为

$$L_{t1} = \exp(-\log(\sigma_1^2)) \times L(P_1, t_1) + \log(\sigma_1^2) \quad (15)$$

$$L_{t2} = \exp(-\log(\sigma_2^2)) \times L(P_2, t_2) + \log(\sigma_2^2) \quad (16)$$

式中:  $L(P_1, t_1)$ 、 $L(P_2, t_2)$  分别为任务 1、任务 2 的原始损失;  $\sigma_1^2$ 、 $\sigma_2^2$  分别为方差不确定性参数。

自编码器的重构损失  $L_{rec}$  表示为

$$L_{rec} = \text{MSE}(\hat{\mathbf{x}}, \mathbf{x}) \times \frac{1}{\sigma_r^2} + \log(\sigma_r^2) \quad (17)$$

式中:  $\sigma_r^2$  为重构损失的方差不确定性参数;  $\text{MSE}(\cdot)$  为均方误差, 表示为

$$\text{MSE}(\hat{\mathbf{x}}, \mathbf{x}) = \frac{1}{6n} \sum_{i=1}^{6n} (\hat{x}_i - x_i)^2 \quad (18)$$

式中,  $\hat{x}_i$  与  $x_i$  分别表示重构向量及原始输入向量。

总损失  $L_{total}$  表示为

$$L_{total} = L_{t1} + L_{t2} + L_{rec} \quad (19)$$

通过应用不确定性加权方法自适应调整三种损失叠加权重, 允许模型在处理不同任务时关注嵌入其中的最相关特征, 从而可以根据每个任务的需求自适应地关注输入特征的不同部分, 提高分类精度。

## 3 仿真分析

### 3.1 故障数据集和模型参数设置

使用 IEEE 123 节点配电系统进行故障仿真, 其拓扑结构及量测配置情况如图 4 所示。该系统共 128 条母线, 将开关、调压器关联节点视为同一节点, 因此只对 119 条母线进行故障仿真, 每个节点设置 11 种短路故障, 包括 A、B、C 相单相接地短路故障, A-B、A-C、B-C 相间短路故障, A-B、A-C、B-C 两相接地短路故障及三相相间短路故障、三相接地短路故障。

充足的训练样本是深度学习类方法有效实施的前提, 由于分布式电源出力的间歇性和强波动性特征, 实际中难以获取充足和丰富的配电网故障样本数据, 样本丰富度不足。针对该问题, 本文对各节点注入功率的概率分布进行学习, 进而通过蒙特卡

洛抽样来获得大量样本参与训练。考虑到配电网有功、无功负荷具有不对称性及多峰性, 采用单一的高斯分布拟合度较低, 因此本文用高斯混合模型建模并抽样生成 49 446 个节点有功、无功负荷样本<sup>[25]</sup>, 将其平均分配到 119 条母线及每条母线的 11 种故障类型中, 并使用 OpenDSS<sup>[26]</sup>进行配电网故障仿真, 故障电阻取 0.001~10  $\Omega$ 。最终得到 49 446 条数据样本, 提取配置量测节点的三相电压幅值和相角, 生成训练集、验证集和测试集。

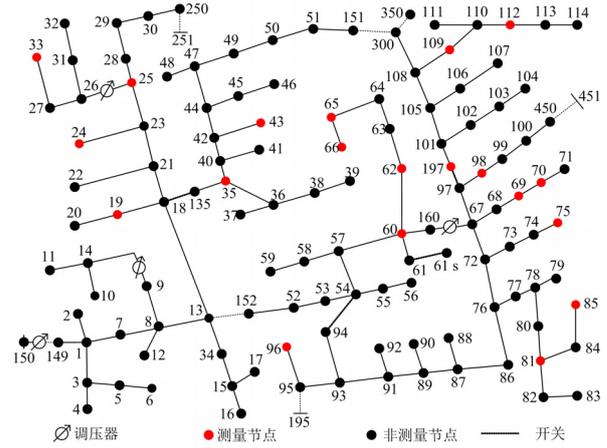


图 4 IEEE 123 节点配电网单线图

Fig. 4 Single-line diagram of the IEEE 123-bus distribution network

采用图 1 所示模型结构, 输入的节点数据经过三层 GNN 进行图嵌入学习, 图嵌入特征经过 MTAN 进行多任务分类, 输出两个任务的分类预测值, 其中任务 1 对 119 个故障位置进行分类, 任务 2 对 11 种故障类别进行分类; 自编码器对无标签样本数据进行编码与重构, 重构损失与分类损失经加权合并后反向传播, 更新训练整个网络中所有可训练参数, 学习率取 0.0003。

### 3.2 不同可观测水平下模型效果分析

本节测试了量测节点数量对故障定位精度的影响, 在可观测母线数目为 100、80、60、40、20 的情况下分别训练分类器模型, 并与全连接神经网络(fully connected neural network, FCNN)分类器、CNN 分类器进行对比, 测试集的测试结果如表 2、表 3 所示。

表 2 不同方法故障区段定位精度

Table 2 Fault location accuracy of different methods

方法	可观测母线数				
	100	80	60	40	20
FCNN	96.9	96.7	95.1	92.8	87.8
CNN	99.2	98.9	97.8	96.7	88.6
所提方法	99.3	99.2	98.6	97.8	92.7

表 3 不同方法故障类型辨识精度

Table 3 Fault type identification accuracy of different methods

方法	可观测母线数				
	100	80	60	40	20
FCNN	97.9	98.2	97.4	96.3	96.0
CNN	98.7	97.8	97.7	97.2	96.1
所提方法	98.7	98.6	98.6	98.1	97.7

测试结果表明,与基于 FCNN、CNN 的多任务分类器相比,所提方法具有更高的故障定位和故障类型辨识精确度,且在可观测度较低时,所提方法表现更好。

### 3.3 不同标记率下模型效果分析

本节对所提出方法在低标记率条件下的鲁棒性进行测试。图 5、图 6 及表 4、表 5 展示了在不同标记率下,所提方法与传统多任务分类器的对比情况。阶段 I+II 监督学习、阶段 I+II+III 半监督学习、FCNN 和 CNN 四种方法的对比结果表明,阶段 III 通过自动编码器使整个框架形成半监督学习架构,

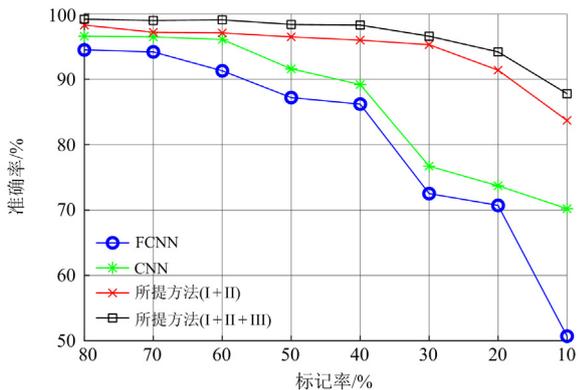


图 5 不同标记率下的故障区段定位精度

Fig. 5 Fault type identification accuracy of different label rates

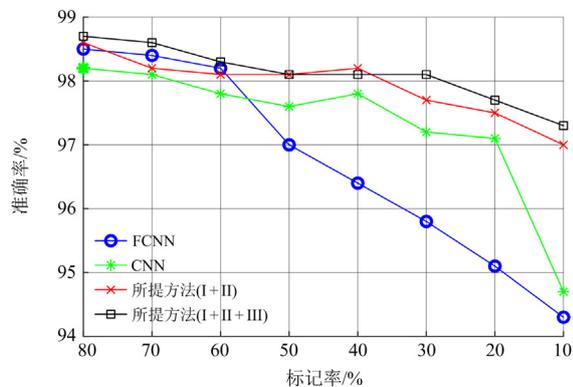


图 6 不同标记率下的故障类型辨识精度

Fig. 6 Fault type identification accuracy of different label rates

表 4 不同标记率下的故障区段定位精度

Table 4 Fault location accuracy of different label rates

方法	标记率							
	80	70	60	50	40	30	20	10
FCNN	94.5	94.2	91.3	87.2	86.2	72.5	70.7	50.7
CNN	96.6	96.5	96.1	91.6	89.2	76.7	73.7	70.2
所提方法(I+II)	98.3	97.2	97.1	96.5	96.0	95.3	91.4	83.7
所提方法(I+II+III)	99.2	99.0	98.9	98.4	98.3	96.6	94.2	87.8

表 5 不同标记率下的故障类型辨识精度

Table 5 Fault type identification accuracy of different label rates

方法	标记率							
	80	70	60	50	40	30	20	10
FCNN	98.5	98.4	98.2	97.0	96.4	95.8	95.1	94.3
CNN	98.2	98.1	97.8	97.6	97.8	97.2	97.1	94.7
所提方法(I+II)	98.6	98.2	98.1	98.1	98.2	97.7	97.5	97.0
所提方法(I+II+III)	98.9	98.7	98.3	98.1	98.1	98.1	97.7	97.3

通过充分利用未标记数据,精度高于单纯使用监督学习,且在标签率较低的情况下仍具有较好的泛化能力。

### 3.4 考虑分布式电源接入的影响

本节对所提方法在分布式电源接入条件下的鲁棒性进行测试。在 123 节点系统中接入 6 个光伏并进行故障仿真,最大输出功率为 500 kW,重新构造测试集进行测试,测试结果如表 6 所示。

表 6 接入分布式电源后故障辨识精度

Table 6 Fault type identification accuracy connected to DG

故障辨识类别	可观测母线数				
	100	80	60	40	20
区段定位	98.8	98.3	98.2	95.4	91.7
类型辨识	98.7	98.1	97.9	97.8	96.7

对比表 2、表 3 可知,分布式电源的接入在一定程度上降低了故障辨识的精度,这是由于分布式电源出力的波动性特征导致训练集中缺乏与测试集相似的样本,样本丰富度不足;但所提方法仍能保证故障区段定位精度超过 90%、故障类型辨识精度超过 96%。

### 3.5 考虑测量噪声的影响

为了验证噪声对精度的影响,本节在测试集样本中添加高斯噪声,其信噪比(signal-to-noise ratio, SNR)为 25~60 dB,标记率设为 100%,测试精度如表 7 所示。由表 7 可知,所提方法对于噪声具有较强的鲁棒性,SNR 降低导致识别故障类型的准确率降低幅度更小。

表 7 不同 SNR 下的故障辨识精度

Table 7 Fault identification accuracy under different SNRs

故障辨识 类别	SNR/dB								%
	60	55	50	45	40	35	30	25	
区段定位	99.2	98.7	98.4	97.8	96.8	93.8	84.5	80.3	
类型辨识	98.9	98.6	98.7	98.2	98.1	97.4	95.0	93.3	

## 4 结论

针对现有深度学习类配电网故障辨识方法在量测不足和标记率低时准确率不高的问题, 提出了基于图半监督与多任务学习的配电网故障区段与类型统一辨识方法, 得出了以下结论:

1) 利用多任务学习实现故障类型辨识和故障定位的统一建模, 提取任务多重信息的同时提升故障区段定位及类型辨识精度;

2) 在系统低可观、低标记率及测量噪声等情形下, 所提方法均能达到较高的故障区段定位及故障类型辨识精确度, 相比传统的多任务分类器具有较好的鲁棒性。

后续研究将考虑性能更优的半监督与多任务学习方法, 在更低可观测率、标记率等情况下进一步提高故障区段定位及故障类型辨识精确度。

## 参考文献

- [1] 齐郑, 黄朝晖, 陈艳波. 基于零序分量的阻抗法配电网故障定位技术[J]. 电力系统保护与控制, 2023, 51(6): 54-62.  
QI Zheng, HUANG Zhaohui, CHEN Yanbo. Impedance fault location technology for a distribution network based on a zero-sequence component[J]. Power System Protection and Control, 2023, 51(6): 54-62.
- [2] 苏晨博, 刘崇茹, 李志显, 等. 基于阻抗法的大规模风电场等值方法研究[J]. 电测与仪表, 2022, 59(6): 90-97.  
SU Chenbo, LIU Chongru, LI Zhixian, et al. Research on equivalent method of large-scale wind farm based on impedance method[J]. Electrical Measurement & Instrumentation, 2022, 59(6): 90-97.
- [3] 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 Keyan, DONG Weijie, XIAO Shiwu, 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.
- [4] 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 Sizu, GUO Wei, WANG Ziqi, et al. Fault segment location method for distribution network based on wavelet AlexNet network[J]. Electrical Measurement & Instrumentation, 2022, 59(3): 46-57.
- [5] 李练兵, 孙腾达, 曾四鸣, 等. 基于多端行波时差的配电网故障定位方法[J]. 电力系统保护与控制, 2022, 50(3): 140-147.  
LI Lianbing, SUN Tengda, ZENG Siming, et al. Fault location method for distribution networks based on traveling wave time difference[J]. Power System Protection and Control, 2022, 50(3): 140-147.
- [6] 齐郑, 庄舒仪, 刘自发, 等. 基于并联电阻扰动信号的配电网故障定位方法分析[J]. 电力系统自动化, 2018, 42(9): 195-200.  
ZHENG Qi, ZHUANG Shuyi, LIU Zifa, et al. Analysis of distribution network fault location method based on shunt resistance disturbance signal[J]. Automation of Electric Power Systems, 2018, 42(9): 195-200.
- [7] 李浩, 张禄亮, 栾云飞, 等. 基于子系统划分和注入电流比的配电网故障定位方法[J]. 电力系统保护与控制, 2023, 51(8): 63-72.  
LI Hao, ZHANG Luliang, LUAN Yunfei, et al. Fault location method for a distribution network based on subsystem division and injection current ratio[J]. Power System Protection and Control, 2023, 51(8): 63-72.
- [8] LI W, DEKA D, CHERTKOV M, et al. Real-time faulted line localization and PMU placement in power systems through convolutional neural networks[J]. IEEE Transactions on Power Systems, 2019, 34(6): 4640-4651.
- [9] 王思明, 童安蓉. 混合模糊 H 网在配电网故障识别中的应用[J]. 电力系统及其自动化学报, 2016, 28(10): 74-79.  
WANG Siming, TONG Anrong. Application of hybrid fuzzy H net to recognition of fault types for distribution network[J]. Proceedings of the CSU-EPSA, 2016, 28(10): 74-79.
- [10] 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 Xiaoyang, ZHANG Shaoxun. A grey correlation-based method for fault segment location and type identification in distribution networks[J]. Automation of Electric Power Systems, 2019, 43(4): 113-118, 145.
- [11] GUO M F, CAI W Q, ZHENG Z Y, et al. Fault phase selection method based on single-phase flexible arc suppression device for asymmetric distribution networks[J]. IEEE Transactions on Power Delivery, 2022, 37(6): 4548-4558.
- [12] GUO M F, YANG N C, CHEN W F. Deep-learning-based

- fault classification using Hilbert-Huang transform and convolutional neural network in power distribution systems[J]. IEEE Sensors Journal, 2019, 19(16): 6905-6913.
- [13] 邢晓东, 石访, 张恒旭, 等. 基于同步相量的有源配电网自适应故障区段定位方法[J]. 电工技术学报, 2020, 35(23): 4920-4930.  
XING Xiaodong, SHI Fang, ZHANG Hengxu, et al. Adaptive section location method for active distribution network based on synchronized phasor measurement[J]. Transactions of China Electrotechnical Society, 2020, 35(23): 4920-4930.
- [14] 张健磊, 高湛军, 王志远, 等. 基于有限  $\mu$  PMU 的主动配电网故障定位方法[J]. 电网技术, 2020, 44(7): 2722-2731.  
ZHANG Jianlei, GAO Zhanjun, WANG Zhiyuan, et al. Fault location method for active distribution based on finite  $\mu$ PMU[J]. Power System Technology, 2020, 44(7): 2722-2731.
- [15] 邓丰, 李鹏, 曾祥君, 等. 基于 D-PMU 的配电网故障选线和定位方法[J]. 电力系统自动化, 2020, 44(19): 160-167.  
DENG Feng, LI Peng, ZHENG Xiangjun, et al. D-PMU-based fault routing and location method for distribution networks[J]. Automation of Electric Power Systems, 2020, 44(19): 160-167.
- [16] 谢李为, 李勇, 罗隆福, 等. 基于节点电压差值的配电网故障定位方法[J]. 电力系统保护与控制, 2023, 51(6): 106-116.  
XIE Liwei, LI Yong, LUO Longfu, et al. A novel fault location method employing node voltage difference value for a distribution network[J]. Power System Protection and Control, 2023, 51(6): 106-116.
- [17] 孙志达, 杨涛, 吴栋萁, 等. 基于多源信息和遗传算法的配电网故障定位模型[J]. 智慧电力, 2021, 49(12): 104-110.  
SUN Zhida, YANG Tao, WU Dongqi, et al. Fault location model for distribution networks based on multi-source information and genetic algorithm[J]. Smart Power, 2021, 49(12): 104-110.
- [18] 吉兴全, 张朔, 张玉敏, 等. 基于 IELM 算法的配电网故障区段定位[J]. 电力系统自动化, 2021, 45(22): 157-166.  
JI Xingquan, ZHANG Shuo, ZHANG Yumin, et al. Fault zone localisation in distribution networks based on IELM algorithm[J]. Automation of Electric Power Systems, 2021, 45(22): 157-166.
- [19] CHEN K, HU J, ZHANG Y, et al. Fault location in power distribution systems via deep graph convolutional networks[J]. IEEE Journal on Selected Areas in Communications, 2019, 38(1): 119-131.
- [20] 张雷, 李晓影, 张沛, 等. 基于组合神经网络的配电网故障定位方法[J]. 电力系统及其自动化学报, 2023, 35(9): 87-94.  
ZHANG Lei, LI Xiaotong, ZHANG Pei, et al. Fault location method for distribution network based on combined neural network[J]. Proceedings of the CSU-EPSA, 2023, 35(9): 87-94.
- [21] 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.
- [22] LIU S, JOHNS E, DAVISON A J. End-to-end multi-task learning with attention[C] // 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 15-20, 2019, Long Beach, CA, USA: 1871-1880.
- [23] ZHANG Y, YANG Q. A survey on multi-task learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2021, 34(12): 5586-5609.
- [24] CIPOLLA R, GAL Y, KENDALL A. Multi-task learning using uncertainty to weigh losses for scene geometry and semantics[C] // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA: 7482-7491.
- [25] MCLACHLAN G J, RATHNAYAKE S. On the number of components in a Gaussian mixture model[J]. Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery, 2014, 4(5): 341-355.
- [26] DUGAN R C, MCDERMOTT T E. An open source platform for collaborating on smart grid research[C] // 2011 IEEE Power and Energy Society General Meeting, July 24-28, 2011, Detroit, MI, USA: 1-7.

收稿日期: 2023-12-21; 修回日期: 2024-02-27

作者简介:

梁 栋(1990—), 男, 博士, 讲师, 研究方向为配电系统态势感知与运行控制; E-mail: liangdong@hebut.edu.cn

赵月梓(1998—), 男, 硕士研究生, 研究方向为配电网的故障识别与保护; E-mail: 940751773@qq.com

陈海文(1994—), 男, 通信作者, 博士, 讲师, 研究方向为配用电大数据分析 with 智能用电。E-mail: haiwen.c@hebut.edu.cn

(编辑 许 威)