

基于边缘计算和深度学习的有限信息配电网 单相接地故障区段定位

张大波¹, 李雪婷², 陶维青¹

(1. 新能源利用与节能安徽省重点实验室(合肥工业大学), 安徽 合肥 230009;
2. 国网山东省电力公司济宁供电公司, 山东 济宁 272000)

摘要: 目前围绕量测条件受限的配电网展开的故障定位研究较少, 且传统的主站集中式故障定位系统在实时性与安全性等方面存在不足。针对上述问题, 提出一种基于边缘计算和深度学习的单相接地故障区段定位方法。首先, 构建基于分区修正的边缘计算单元配置多目标优化模型。该模型通过分区修正方法降低了故障定位系统的通信时延, 提升了数据传输安全性, 进而保障配电网安全运行。其次, 将基于数据驱动的智能算法应用于配电网故障区段定位, 选择易获取的相电流稳态有效值在故障前后的变化量作为故障特征, 利用全连接型深度神经网络学习样本特征与标签间的映射关系, 得到离线训练好的定位模型并储存在边缘节点以实现快速故障定位。最后, 以 IEEE33 节点系统为例进行仿真。算例结果表明该模型在分布式电源接入、高阻故障、噪声干扰以及拓扑改变等情况下均具有良好表现。

关键词: 配电网有限量测; 单相接地故障; 故障区段定位; 深度学习; 边缘计算; 分布式电源

Single-phase ground fault section location in distribution networks with limited information based on edge computing and deep learning

ZHANG Dabo¹, LI Xueting², TAO Weiqing¹

(1. Anhui Province Key Laboratory of Renewable Energy Utilization and Energy Saving (Hefei University of Technology), Hefei 230009, China; 2. Jining Power Supply Company, State Grid Shandong Electric Power Co., Ltd., Jining 272000, China)

Abstract: At present, there are few studies on fault location in a distribution network with limited measurement conditions. In addition, the traditional centralized fault location system of a master station has shortcomings in real-time and security. Thus, a single-phase ground fault section location method based on edge computing and deep learning is proposed. First, a multi-objective optimization model of edge computing unit configuration based on partition correction is constructed. The model reduces the communication delay of a fault location system and improves the security of data transmission by the partition correction method, thus ensuring the safe operation of the network. Second, a data-driven intelligent algorithm is applied to the fault section location. The variation of the steady-state effective value of the phase current before and after the fault is selected as the fault feature. A fully connected deep neural network is used to learn the mapping relationship between sample features and labels, and an offline trained location model is obtained and stored at the edge nodes to achieve fast fault location. Finally, the IEEE 33-bus system is taken as an example for simulation. The example shows that the model performs well with distributed generation access, high resistance fault, noise interference and topology change.

This work is supported by the Natural Science Foundation of Anhui Province (No. 2208085UD07).

Key words: distribution network with limited measurement; single-phase ground fault; fault section location; deep learning; edge computing; distributed generation

0 引言

我国的中低压配电网主要采用中性点非直接接

地方式^[1], 该接地系统下发生单相接地故障时故障特征微弱。随着分布式电源(distributed generation, DG)大规模接入, 配电网潮流逐渐转变为双向流动, 系统拓扑结构与运行工况愈加复杂, 加剧了故障区段定位的难度^[2-4]。在实际配电网中, 量测条件参差

不齐, 部分配电网装有精确量测设备, 通过信息处理技术对高精度故障信号进行特征提取, 能够形成高效准确且适用于有源配电网的故障区段定位方法。但不容忽视的是, 在许多城市和农村配电网中, 出于成本考虑并未配置先进的量测设备, 此类配电网可称为有限信息配电网^[5]。然而, 围绕有限信息配电网开展的故障定位研究相对较少。

目前已存在多种故障区段定位方法^[6], 按照定位过程中所需信号的不同, 大致可分为稳态法^[7]、暂态法^[8]以及注入法^[9]几大类。稳态法的主要思想是基于测量点处的电压和电流得到故障回路的阻抗, 其与馈线单位长度阻抗的比值即为故障点与测点间的距离。文献[10]利用同步相量测量单元(phasor measurement unit, PMU)获取稳态零序信号, 结合线路零序参数建立故障测距方程, 但 DG 接入时容易造成故障信息的畸变。文献[11]在多分支配电网中利用故障前后的电流与电压信息实现故障定位, 并根据双端量测数据排除伪故障点, 但该方法对通信条件要求较高。稳态法原理简单易于实现, 但其定位精度受限于系统结构复杂性、线路参数均匀性以及测量误差等因素。此外, DG 渗透率的提升削弱了稳态故障特征, 也在一定程度上造成定位精度的下降。暂态法在故障区段定位中得到了广泛应用, 行波法是其中的典型代表。文献[12]提出一种基于多端行波时差的故障定位方法, 结合节点矩阵有效判定故障线路, 并通过三端行波测距法消除行波波速不确定性造成的误差。文献[13]将行波法与小波变换相结合进行故障定位, 该方法在仿真模型中具有良好表现。目前, 基于行波信号的定位技术在长距离、少分支的输电网中已比较成熟, 但由于配电网含有许多分支, DG 接入又加剧了其拓扑复杂性, 因此行波法在配电网中的应用相对较少。文献[14]运用注入法, 在故障支路末端节点注入电流, 通过对比馈线不同位置电压的变化量实现精确定位, 但增设注入设备使系统成本明显升高。随着算法、算力的提升, 基于人工智能的定位方法^[15]逐渐演化为研究热点。文献[16]针对谐振接地系统定位精度不足的现状, 利用自编码器自适应提取零序电流与零序电压特征, 基于 BP 神经网络实现故障定位, 但该方法未考虑 DG 的接入。文献[17]利用信号图像(signal-to-image, SIG)算法对时域故障信号进行处理, 将其转换到图像域后输入离线训练好的 SIG-CNN 模型, 得到准确的故障定位结果。文献[18]提出一种基于深度图卷积网络(graph convolutional network, GCN)的故障定位方法, 仿真证明该方法能较好地适应配电网拓扑的改变, 并对测量数据丢失

和噪声干扰具有一定的鲁棒性, 但仅考虑了节点处发生故障的情况。上述人工智能算法属于深度学习领域, 其应用基础为数量充足的电力数据, 即通过数据驱动进行故障定位。基于数据驱动的智能算法数据处理水平优越, 能够有效挖掘故障信息, 利用深度学习实现有限信息配电网故障区段定位不失为一个可行方向。故障定位方法各有其优缺点, 但上述大多文献对量测条件提出了较高要求。

此外, 在现有的主站集中式故障定位系统中, 故障数据需要全部上传至云端进行处理, 提高了通信带宽要求, 加重了主站计算负担, 降低了故障响应速度以及系统安全可靠。这是故障定位研究面临的另一个难题, 而边缘计算为海量故障信息的处理提供了新的思路。文献[19]将边缘计算与机器学习相结合, 基于节点的负序电压变化和零序电流投影实现故障定位, 但在边缘分区的边界处存在定位盲区。文献[20]设计了基于云边协同的故障定位系统, 并通过仿真验证了其相较于主站集中式系统的优势。文献[21]提出一种边缘计算单元优化配置方法, 缓解了通信压力, 有利于实现配电网故障快速处理。因此, 研究主站与边缘侧相协同的故障定位系统具有重要意义。

本文提出了基于边缘计算和深度学习的有限信息配电网故障区段定位方法。首先, 建立基于分区节点数修正的边缘设备配置优化模型; 其次, 选取相电流稳态有效值在故障前后的变化量作为故障特征, 该信号获取途径简单, 仅要求配电网中装有电流互感器; 再次, 将基于数据驱动的智能算法应用于配电网故障区段定位, 并分析了其可行性, 虽然利用的故障信息仅有电流互感器的量测值, 但数据驱动方法仍能从大量样本中深度挖掘其潜在规律, 弥补了量测条件的不足; 最后, 利用全连接型深度神经网络学习样本特征与标签间的映射关系, 避免了阈值整定, 提升了定位灵敏性。

1 基于分区修正的边缘计算单元配置优化模型

应用边缘计算的优势主要如下^[20]: 配电网发生故障后, 在边缘侧即可实现对故障区段的辨识进而决策切除故障, 降低了通信时延, 减轻了主站的计算负担, 提升了故障处理速度; 定位模型被同时储存在主站与边缘节点, 二者互为备用, 只有在全部边缘和主站均遭受攻击的极端情况下, 故障定位才会完全失效。因此, 配电网的供电可靠性与安全性得到了提升。

1.1 目标函数

本节结合实际, 综合考虑通信实时性、系统经济性、安全性和均衡性等因素以构造目标函数。

1.1.1 通信实时性

在配电网故障区段定位中, 尽量缩短定位时间可大大提高系统的安全性和供电可靠性。通信实时性随分区数的增多而提高, 通信时延 $T^{[22]}$ 为

$$T = T_a + T_b + T_c + T_d \quad (1)$$

式中: T_a 表示发送数据所需时间; T_b 表示在信道中传播数据的时延; T_c 表示分组在路由器中的排队等待时延; T_d 为分组处理时延, 其值较小可忽略。

$$\begin{cases} T_a = \frac{P}{v_1} \\ T_b = \frac{D}{v_2} \\ T_c = \frac{R\theta}{\mu(\mu - \theta)} \end{cases} \quad (2)$$

式中: P 为传输的数据包的容量大小; D 为数据传输的距离即信道长度; v_1 为网络的通信速度; v_2 为数据在通信介质中的传播速度; R 为路由总个数; θ 为数据进入系统的速率; μ 为路由器传输速率。在计算信道长度 D 时, 通过均分处理, 各分区中的通信距离可由式(3)近似估算。

$$\begin{cases} D = 2 \times \left(\frac{k}{n} \times \bar{d} \right) \\ \bar{d} = \frac{d_1 + d_2 + \dots + d_k}{k} \\ d_i = \frac{d_{i,1} + d_{i,2} + \dots + d_{i,\varepsilon}}{\eta_i} \end{cases} \quad (3)$$

式中: n 为分区数; k 为通信节点个数即终端数量; \bar{d} 为分区内终端之间进行通信传输的平均信道长度; d_i 为节点 i 的平均通信距离; η_i 为节点 i 的连接度, 即与节点 i 连接的线路数目; $d_{i,\varepsilon}$ 表示与节点 i 相连的第 ε 条通信路径的长度。

由式(1)一式(3)得到通信时延的计算公式, 如式(4)所示。

$$T = \frac{P}{v_1} + \frac{2 \times \left(\frac{k}{n} \times \frac{d_1 + d_2 + \dots + d_k}{k} \right)}{v_2} + \frac{R\theta}{\mu(\mu - \theta)} \quad (4)$$

1.1.2 分区经济性

经济性也是影响边缘分区的重要指标, 可以从建设投资与运维费用两个方面进行考虑, 配电网增设边缘设备后的费用 E 可用公式表示为

$$E = E_c + E_t + E_v \quad (5)$$

式中: E_c 为引入边缘计算单元及其配套设施所需费用; E_t 为系统其余配电设备的投资费用; E_v 为系统运行维护费用。当配电网的整体架构确定后, E_t 和 E_v 基本保持不变, 而 E_c 与边缘数成正比, 即 $E_c = ns$, 其中 s 为增设单个边缘设备所需费用。不难得出, E 随分区数的增加而增大, E 又可表示为

$$E = ns + E_t + E_v \quad (6)$$

1.1.3 安全性与均衡性

图 1 为分区边界节点的保护示意图, 其中 f 为故障点, Bus 为网络节点。

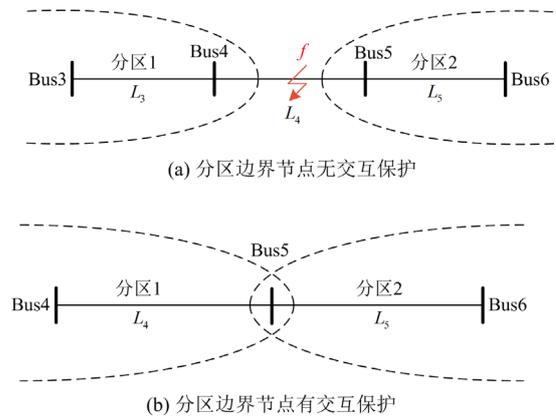


图 1 分区边界节点的保护示意图

Fig. 1 Protection of partition boundary nodes

如图 1(a)所示, 当位于分区边界的线路 L_4 发生故障时, 系统并不能将故障线路隔离。图 1(b)为分区边界节点的交叉保护示意图, 由图可知, 分区 1 和分区 2 中的边缘节点均可获取节点 Bus5 的量测信息, 因此线路 L_4 或 L_5 发生故障时均不会出现定位盲区, 从而提升了配电网的安全可靠性。对于分区数为 n 的 k 节点系统, 若要实现交互保护, 则各分区中包含的节点总数 $K = k + (n - 1)$ 。

对配电网进行分区时, 还应考虑各边缘管辖区域的均衡性。如果分区间的规模差距较大, 则不同边缘设备承担的计算任务就会失调, 进而增加故障定位所需时间。本小节通过式(7)计算方差 δ 来判别分区是否均衡, 其中, W_i 为边缘分区 i 包含的节点数; \bar{W} 为总节点划分到 n 个分区中的平均数。 δ 的值越小代表分区越均衡。

$$\begin{cases} \delta = \frac{1}{n-1} \sum_{i=1}^n |W_i - \bar{W}|^2 \\ \bar{W} = \frac{1}{n} \sum_{i=1}^n W_i \end{cases} \quad (7)$$

通过以上探讨, 明确了影响边缘分区的 3 个重

要因素, 分别为 T 、 E 、 δ 。由于三者量纲不同, 因此在构造目标函数之前需进行归一化处理, 得到数学模型如式(8)所示。

$$\min F = x_T \frac{T - T_{\min}}{T_{\max} - T_{\min}} + x_E \frac{E - E_{\min}}{E_{\max} - E_{\min}} + x_\delta \frac{\delta - \delta_{\min}}{\delta_{\max} - \delta_{\min}} \quad (8)$$

式中: x_T 、 x_E 、 x_δ 为赋给各个分区评价指标的权重, 可通过层次分析法求取^[23]; T_{\max} 、 T_{\min} 分别为选取不同分区数时通信时延的最大值和最小值; E_{\max} 、 E_{\min} 、 δ_{\max} 、 δ_{\min} 同理。

1.2 约束条件

1.2.1 分区数约束

根据文献[24], 对于含有 k 个节点的系统, 其分区数的上限可近似取 \sqrt{k} , 且最小分区数通常取 2。但考虑到后续运用遗传算法求解目标函数时, 应使种群具有多样性, 因此最大分区数设为 $1.5\sqrt{k}$, 分区数约束如式(9)所示。

$$2 \leq n \leq 1.5\sqrt{k} \quad (9)$$

1.2.2 通信时延约束

上文给出了通信时延的计算公式, 如式(4)所示。为尽量缩短故障定位消耗的时间, 需要对通信网络的时延进行约束, 一般情况下, 最大时延 T_{\max} 不应超过 5 ms, 通信时延的约束条件如式(10)所示。

$$T \leq T_{\max} \quad (10)$$

1.3 求解算法

1.3.1 边缘管辖区域划分

按照上文所述方法, 在改进后的 IEEE 33 节点系统中进行边缘分区, 其拓扑结构如图 2 所示。式(4)中的各参数见表 1, 其中 c 为光速。

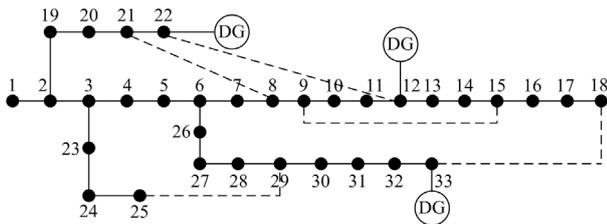


图 2 IEEE 33 节点系统

Fig. 2 IEEE 33-bus system

表 1 参数设置

Table 1 Parameter setting

参数	数值
P_l /Byte	200
v_1 /(Mbit/s)	150
v_2	$0.8c$
θ /(packets/s)	50
μ /(Mbit/s)	50

求解目标函数之前, 需要选取目标函数中各指标的权重。假设以安全性和均衡性为基准, 通信实时性比其略微重要, 经济性的重要程度介于上述两者之间, 则 3 个指标间的关系可利用 1-9 比例标度直观表示为: $x_T/x_\delta = 3$, $x_E/x_\delta = 2$ 。参照文献[23]求得各指标的权重为 $x_T = 0.5$ 、 $x_E = 0.333$ 、 $x_\delta = 0.167$ 。

利用遗传算法对分区规划目标函数进行迭代求解, 得到分区数以及各分区中的节点数目。在此基础上, 即可进入对边缘管辖范围的具体划分, 此时需要借助聚类算法。由于谱聚类能够处理多种形式的样本集包括结构稀疏的数据, 优点显著, 因此选用该算法完成分区任务。谱聚类算法的关键在于构建网络的 Laplace 矩阵。对于待分区的配电网, 首先由拓扑结构得到其邻接矩阵 J , J 的定义为: 若网络中两节点 a 、 b 直接相连, 则 $j_{ab} = 1$, 否则 $j_{ab} = 0$ 且 $j_{aa} = 0$ 。再构造一个对角线元素为各节点连接度的对角矩阵, 称为度矩阵 D , Laplace 矩阵 L 的定义为

$$L = D - J \quad (11)$$

求解 L 的特征向量并进行谱分析, 就能得到网络节点在特征向量空间的分布, 从而实现聚类的目的。谱聚类算法运用了降维思想, 通过映射, 高维样本的聚类可以在低维空间借助其他算法来实现, 本文选取 K-means 聚类。

以图 2 所示的 IEEE 33 节点系统为例, 其第一小非平凡特征向量中各元素的排列分布如图 3 所示。由图 3 可知, 仅考虑第一小非平凡特征向量时 IEEE 33 节点系统不具有显著的社团结构, 此时可引入第二小非平凡特征向量以提高谱聚类的特征维数^[25]。图 4 为第一和第二小非平凡特征向量中各元素的分布, 其中横、纵坐标的值分别对应第一、第二小非平凡特征向量。结合谱聚类与 K-means 算法的聚类结果如图 5 所示, 依据聚类结果, 该系统共有 3 个边缘分区, 各聚类的中心已在图中标注, 与其相邻的节点 3、12、29 即可选为边缘节点。

根据以上分析, 可以利用谱聚类与 K-means 算法将配电网节点划分到不同区域, 实现方法如下。

1) 观察配电网的拓扑结构, 得到其邻接矩阵 J 与度矩阵 D , 并根据式(11)求得 Laplace 矩阵 L 。

2) 求解 L 的特征值并对其进行排序。若 L 有多个零特征值, 则系统中连通分支的个数即为零特征值的个数, 与其相应的特征向量可以作为分区依据; 如果 L 有且仅有一个零特征值, 则进入步骤 3)。

3) 取 L 的第一、第二小非零特征值, 求出其对应的特征向量, 聚类样本即为第一、第二小非平凡特征向量。

4) 得到聚类样本后, 利用 K-means 算法将网络

节点划分到相应的边缘分区，并将各分区的聚类中心选为边缘节点。

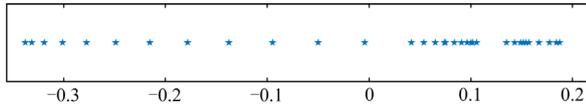


图3 第一小非平凡特征向量分布图

Fig. 3 Distribution graph of the first smallest non-trivial eigenvector

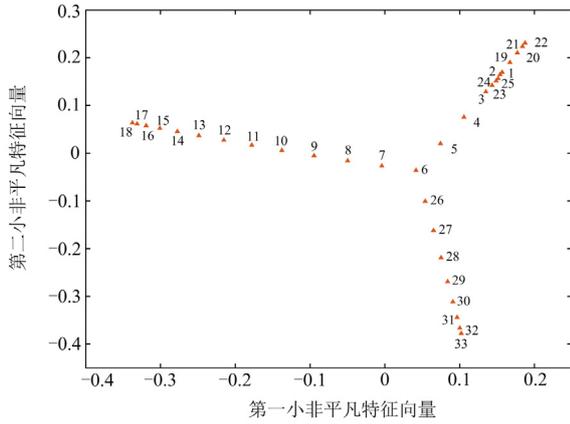


图4 第一和第二小非平凡特征向量分布图

Fig. 4 Distribution graph of the first and second smallest non-trivial eigenvector

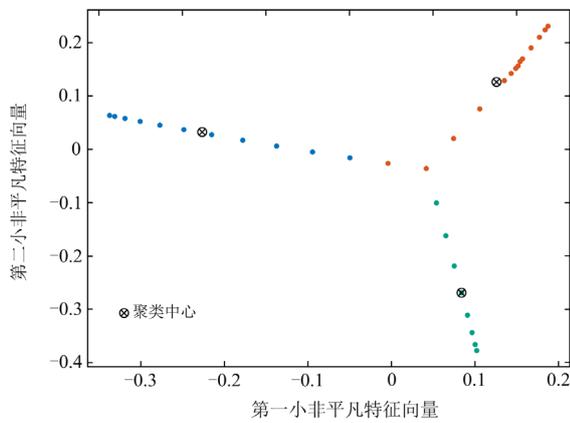


图5 IEEE 33 节点系统聚类结果

Fig. 5 Clustering result of IEEE 33-bus system

1.3.2 分区修正

为实现交互保护，对于具有 n 个分区的 k 节点系统，其分区节点数之和 $K = k + (n-1)$ ，遵循此原则对目标函数进行求解。但在划分边缘管辖区域时，聚类样本中仅包含 k 个节点，因此需要对聚类得到的分区结果作出一定修正。设根据目标函数求解出各分区中的节点数分别为 W_1, W_2, \dots, W_n ，而聚

类得到的分区节点数分别为 G_1, G_2, \dots, G_n 。在完成对 k 节点系统的聚类后，其结果应依据 W_1, W_2, \dots, W_n 进行修正，令 $W = \{W_1, W_2, \dots, W_n\}$ 、 $G = \{G_1, G_2, \dots, G_n\}$ ，基于分区节点数修正的目标函数如式(12)所示。

$$F = \min \sum_{i,j=1}^n |W_i - G_j| \quad (12)$$

决策变量的选取规则如式(13)所示。

$$\begin{cases} W' = \{W - W_i\}, W_j \in W' \\ G' = \{G - G_j\}, G_i \in G' \end{cases} \quad (13)$$

每个分区还应满足式(14)条件。

$$\forall Zone_i, \exists Node_{cross} \in Zone_i \cap Zone_j, i \neq j \text{ 且 } i, j \in n \quad (14)$$

式中： $Zone_i$ 为分区 i 的节点集合； $Node_{cross}$ 为边界交叉节点。

根据边缘管辖区域划分结果，IEEE 33 节点系统的分区示意图如图 6 所示。

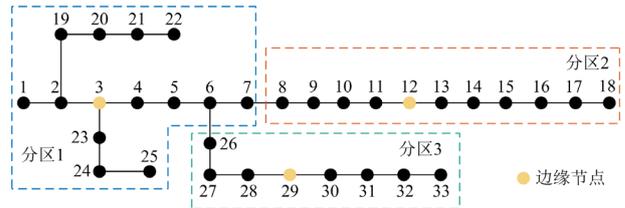


图6 IEEE 33 节点系统分区结果

Fig. 6 Partitioning result of IEEE 33-bus system

聚类结果显示分区 1、2、3 中的节点数目分别为 14、11、8，而在考虑交互保护和均衡性的基础上对目标函数进行求解，可得分配到各分区的节点数依次为 12、12、11。利用式(12)与式(13)进行分区修正，并根据式(14)确定节点 5、7 为分区交叉节点，最终的边缘管辖区域划分结果如图 7 所示。

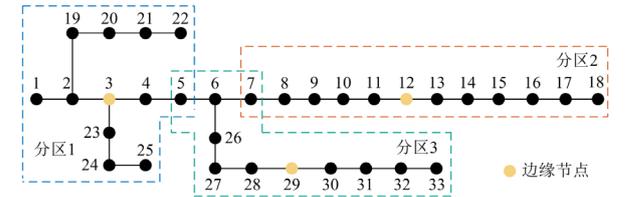


图7 IEEE 33 节点系统经修正后的分区结果

Fig. 7 Partitioning result of IEEE 33-bus system after correction

在目标函数求解结果的基础上对配电网节点进行合理划分，不仅能消除故障定位盲区，而且能使不同分区间的节点数目与边缘计算单元的负担尽可能均衡。

1.4 通信时延对比

对于 IEEE 33 节点系统，由式(9)可确定其分区

数的取值范围为[2,8], 根据式(4)求解系统在不同分区数目下的通信时延, 并绘制曲线, 如图 8 所示。

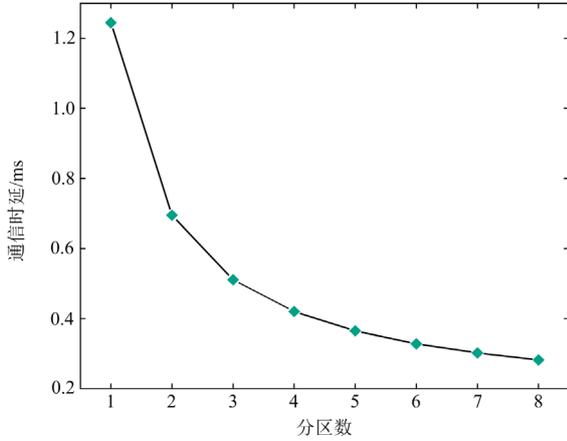


图 8 不同分区数目下的通信时延

Fig. 8 Communication delay under different number of partitions

由图 8 可知, 系统分区后的通信时延相较于分区前有了明显的减小, 且分区数越多时延越短, 对故障定位越有利。但随着分区数目的上升, 通信时延下降的速度逐渐平缓, 而且增设分区的同时也会引起建设成本的上漲。综合考虑上述因素, 设置 3 个分区是较为理想的选择, 既提升了通信效率, 又不会对成本造成较大负担。

2 基于深度学习的配电网故障区段定位

2.1 神经网络结构及原理

由于全连接型神经网络对函数的拟合能力强, 所以本文基于此网络构建故障区段定位模型, 为简洁起见, 下文称其为神经网络。

2.1.1 神经网络数学模型

神经网络包含输入层、隐含层和输出层 3 层结构, 图 9 为含有 3 个隐含层的神经网络模型。

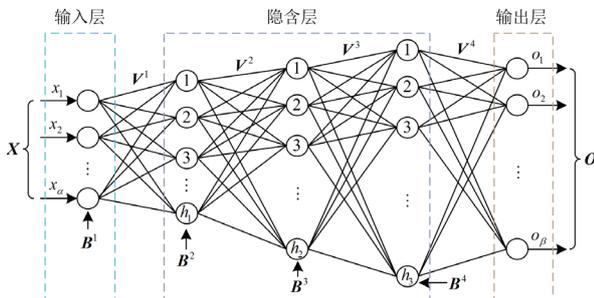


图 9 神经网络模型

Fig. 9 Model of deep neural network

图 9 中: B^l 、 V^l 分别为相邻层之间的偏置向量和权重矩阵, $l=1, 2, 3, 4$; h_1 、 h_2 、 h_3 分别为 3 个

隐含层具有的神经元个数; 输入向量 $\mathbf{X}=[x_1, x_2, \dots, x_\alpha]^T$, 其维数与样本中特征量的个数保持一致; 输出向量 $\mathbf{O}=[o_1, o_2, \dots, o_\beta]^T$, 其维数等于分类数即标签个数。第 l 层神经网络的输出可用式(15)表示。

$$f_\tau^l(\mathbf{Y}^l) = A(\mathbf{V}^l \mathbf{Y}^l + \mathbf{B}^l) \quad (15)$$

式中: f_τ^l 表示第 l 层神经网络的传递函数; \mathbf{Y}^l 表示其输入向量; A 为该神经网络选用的激活函数; τ 表示待优化的模型参数, $\tau = [\mathbf{B}, \mathbf{V}]$ 。

2.1.2 激活函数

激活函数可以学习数据中的复杂关系, 在模型训练过程中起着不可忽视的作用。考虑采用 Relu 函数作为隐含层的激活函数, 其定义如式(16)所示。

$$\text{Relu}(x) = \begin{cases} x & x > 0 \\ 0 & x \leq 0 \end{cases} \quad (16)$$

若 Relu 函数的输入大于 0, 就能有效避免梯度消失问题; 而当输入小于等于 0 时, 函数的零输出特性可以提升网络的稀疏程度, 增强模型的泛化能力。因此, Relu 为激活函数的较优选择。

故障定位模型的本质是一个多分类模型, 所以将 softmax 函数作为输出层的激励函数。softmax 函数的输出向量中均为 0~1 之间的实数, 且归一化后的和为 1, 因此可将函数的输出视为多分类结果对应的概率, 最大的概率值对应故障区段。函数的计算方法如式(17)所示, 其中, $\mathbf{X}=[x_1, x_2, \dots, x_k, \dots, x_\alpha]^T$, \mathbf{X} 为 softmax 函数的输入向量; $\text{softmax}_\kappa(\mathbf{X})$ 表示分类为 κ 的概率。

$$\text{softmax}_\kappa(\mathbf{X}) = \frac{e^{x_\kappa}}{\sum_{i=1}^{\alpha} e^{x_i}} \quad (17)$$

2.1.3 损失函数

损失函数能够反映实际模型偏离理想模型的程度, 交叉熵损失函数如式(18)所示。

$$f_{\text{loss}} = -\sum_{i=1}^{N_r} y_i \log y_{\text{predict}_i} \quad (18)$$

式中: N_r 为样本总数; y_i 为第 i 个样本对应的标签的真实分布; y_{predict_i} 为对样本 i 进行预测后 softmax 函数输出结果的分布。

假设故障线路的编号为 l_j , 则 softmax 函数输出的第 l_j 个值与 1 越相近, f_{loss} 的值越小。深度学习模型的超参数可通过反向传播不断进行修正, 其修正幅度与 f_{loss} 的大小成正比。

2.2 特征与标签选取

当配电网不具备高精度量测设备时, 可利用的

故障信息有限。通常情况下，配电网的配电终端均装有电流互感器，能可靠获取电流有效值信息并上传至配电自动化系统主站，因此本文选取的样本特征为全网各节点的电流有效值在故障前后的差值。对于一个 k 节点系统，其样本特征 C 如式(19)所示。

$$C = [\Delta I_{1A}, \Delta I_{1B}, \Delta I_{1C}, \dots, \Delta I_{kA}, \Delta I_{kB}, \Delta I_{kC}] \quad (19)$$

式中， ΔI_{kA} 、 ΔI_{kB} 、 ΔI_{kC} 代表节点 k 的三相电流稳态有效值在故障前后的改变量，每个样本特征 C 具有 $3k$ 个特征量。

建立多分类模型输出分类标签，标签即为故障馈线对应的编号，并以编号 0 表示馈线未发生故障。

2.3 评价标准

定位准确的标准为实际故障区段的编号与 softmax 函数的输出一致，本文引入准确率 P_{acc} 作为衡量故障定位模型有效性的指标，如式(20)所示。

$$P_{acc} = \frac{1}{N_t} \sum_{i=1}^{N_t} \{Q_i = Q_{predict_i}\} \quad (20)$$

式中： N_t 为测试集中包含的样本数量； Q_i 为测试样本 i 所对应的真实故障区段编号； $Q_{predict_i}$ 为对样本 i 进行预测后得到的故障区段编号；当上述两编号相同时， $\{Q_i = Q_{predict_i}\} = 1$ ，反之为 0。

2.4 故障区段定位流程

1) 离线训练得到基于深度神经网络的故障定位模型。首先，设置不同的故障条件，如改变过渡电阻、故障位置、故障类型以及负荷水平等，通过模拟仿真获取足够数量的故障样本。其次，通过改变系统的负荷水平以及添加随机噪声，生成一定数量的非故障样本，其标签对应的线路编号为 0。最后，利用全部样本训练得到离线训练模型。

2) 模型在线应用。边缘分区中各电流互感器的量测信息只需上传至相应的边缘节点，其中存储着基于深度学习的故障区段定位模型。边缘计算单元首先求得三相电流的实时量测值在故障前后的变化量，然后将计算结果输入定位模型进行故障区段识别。若输出标签对应的线路编号为 0，则代表该分区内未发生故障，继续监测后续上传的数据；若成功定位到故障区段，边缘节点将进行故障处理并把结果上传至主站。

3) 边缘节点与主站对故障的协同处理。若某分区内确有故障发生，边缘节点将迅速隔离故障并把处理结果同步至主站，主站进一步做出故障决策，及时恢复非故障区域的供电，主站还可将定位结果可视化，便于运维人员巡查。

3 算例分析

3.1 样本生成

在 Matlab/Simulink 搭建仿真模型，其参数大致参照 IEEE 33 节点系统，并根据研究内容作了相应改动。仿真模型如图 2 所示，分别在节点 12、22 以及 33 接入分布式电源，且容量均为 1.0 MW。

由上文可知，IEEE 33 节点系统被划分为 3 个分区，在每个分区中各选取 10 条线路，设置故障条件进行模拟仿真。以分区 2 为例，生成故障样本时需遍历的仿真参数见表 2，各分区之间的参数差异仅在于选取的故障区段有所不同，每个分区可以得到的故障样本数为： $6 \times 10 \times 6 \times 5 \times 3 = 5400$ 个。同时通过仿真得到相同数量的非故障样本，与故障样本共同构成对模型进行训练、验证和测试的总样本集，其中训练集、验证集与测试集的比例为 8:1:1。

表 2 分区 2 故障仿真参数

参数类型	参数值	参数数量
过渡电阻/ Ω	1~500 之间随机选取 (7,8)、(8,9)、(9,10)、(10,11)、	6
故障区段	(11,12)、(12,13)、(13,14)、 (14,15)、(15,16)、(16,17)	10
故障点位置/km	0.01、0.1S _i 、0.3S _i 、0.5S _i 、 0.7S _i 、0.9S _i	6
负荷水平	标准值 $\pm 10\%$	5
故障类型	AG、BG、CG	3

3.2 故障区段定位结果验证

本文在 Python 的 Tensorflow 环境中搭建定位模型，将分区 1—3 对应的模型分别命名为 M1—M3。

3.2.1 算法选择对模型故障定位效果的影响

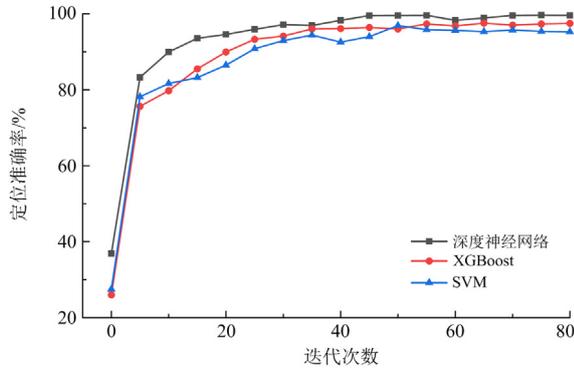
为评估深度学习模型的故障定位效果，本节利用上文得到的样本集对其进行仿真验证，同时对比了支持向量机(support vector machines, SVM)和 XGBoost 算法。不同算法下的仿真结果见表 3，其中， P_{accI} 、 P_{accII} 、 P_{accIII} 分别表示分区 1、2、3 的定位准确率。

表 3 不同算法下的定位准确率

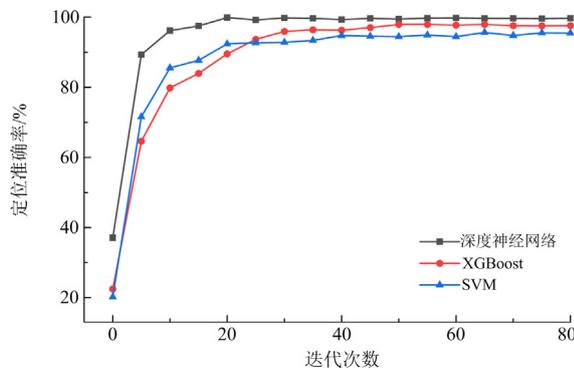
算法	P_{accI}	P_{accII}	P_{accIII}	%
SVM	95.3	95.5	95.4	
XGBoost	97.5	97.6	97.6	
神经网络	99.6	99.7	99.7	

由表 3 可知，相比于浅层机器学习算法，深度学习神经网络模型的故障区段定位效果最好，在 3 个分

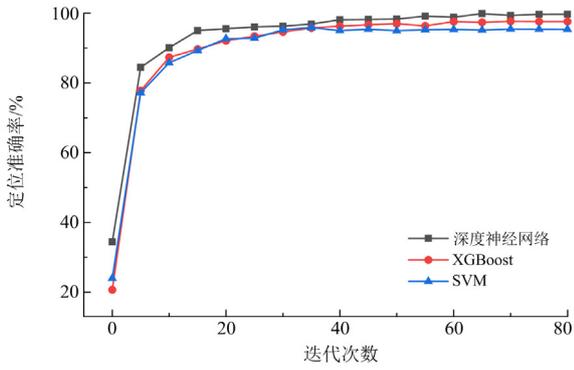
区中的定位准确率均能达到 99.5%以上, 证明了本文所提方法的可行性。模型 M1—M3 在不同算法下的定位精度如图 10 所示。



(a) 不同算法下M1的定位准确率



(b) 不同算法下M2的定位准确率



(c) 不同算法下M3的定位准确率

图 10 不同算法下模型的定位准确率

Fig. 10 Location accuracy of the model under different algorithms

3.2.2 样本数量对模型故障定位效果的影响

为验证样本数量与定位效果间的关系, 分别为深度学习模型选取 1000、3000、5000、7000、10 000 个样本作为总数据集, 样本划分仍然采用 8:1:1 的比例。图 11 为模型 M2 在不同样本数量下的

仿真结果。

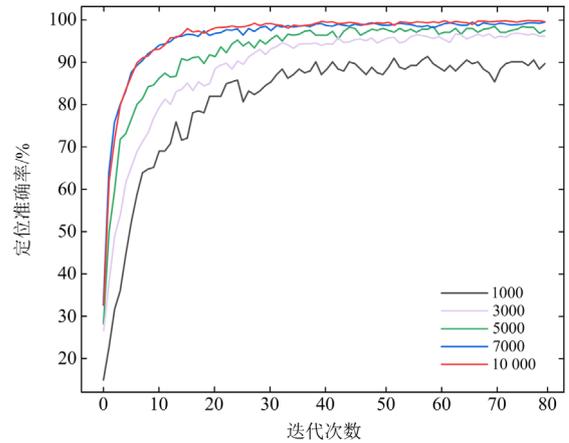


图 11 不同样本数量下模型 M2 的定位准确率

Fig. 11 Location accuracy of model M2 under different sample sizes

由图 11 可知, 模型 M2 的定位准确率和收敛速度均随着数据量的增大而逐渐提升, 但提升速度越来越缓慢。模型的有效性在样本数量增至 7000 个时已得到较好的体现, 定位精度可达到 99%以上, 之后再增加样本数量对定位准确率并未产生显著影响。

3.3 故障定位方法的适应性分析

3.3.1 抗噪声干扰的性能

在配电网的实际量测环境中, 通信信道一般会不可避免地遭受噪声干扰, 且噪声含量随信噪比的增大而降低。本小节通过为样本特征添加不同信噪比的高斯白噪声来验证模型的抗干扰性能, 表 4 为噪声干扰下模型 M1—M3 的定位结果。

表 4 噪声干扰下的定位准确率

Table 4 Location accuracy under noise interference			
信噪比/dB	$P_{\text{accI}}/\%$	$P_{\text{accII}}/\%$	$P_{\text{accIII}}/\%$
60	99.60	99.70	99.70
50	99.60	99.70	99.70
40	98.39	98.50	98.52
30	96.28	96.40	96.39
20	89.59	90.02	89.97

由表 4 可知, 当信噪比在 30 dB 以上时, 模型的定位准确率受噪声的干扰较小; 而信噪比一旦低于 30 dB, 定位精度将有较大幅度的下降。由于实际电网中的信噪比通常高于 40 dB, 而此时的定位精度仍有 0.98, 证明了本文方法在低噪配电网中能够有效定位故障区段。

3.3.2 配电网重构下的性能

在配电网的运行过程中, 有时会通过改变部分开关的状态来达到平衡负载和提高系统可靠性等目

的。考虑两种配电网重构的情景：(1) 闭合节点 8 和节点 21 之间的联络开关，其余联络开关断开；(2) 闭合节点 18 和节点 33 之间的联络开关，其余联络开关断开。

通过仿真为重构情景(1)和(2)分别生成故障样本和非故障样本各 720 个，每种重构情景下，模型 M1—M3 将分别得到一个具有 1440 个样本的测试集，将其输入到在原拓扑中训练好的模型，进行仿真后得到重构情景(1)的定位准确率 P_{acc_1} 和重构情景(2)的定位准确率 P_{acc_2} ，如表 5 所示。

表 5 网络重构后各分区的定位准确率
Table 5 Location accuracy of each partition after network reconfiguration

模型	P_{acc_1}	P_{acc_2}
M1	87.1	99.0
M2	90.9	80.4
M3	85.8	91.2

根据表 5 可知，在上述两种重构情景下各模型的定位准确率均产生了不同程度的下降，但始终不低于 80%。重构情景(1)中，模型 M3 的定位精度下降幅度最大，达到了 13.9%；重构情景(2)中，受拓扑变化影响最大的是模型 M2，其定位准确率下降了 19.3%，而模型 M1 对此重构情景表现出了较高的稳定性，准确率可维持在 99.0%。

由于在离线训练阶段并未考虑配电网发生重构，仿真结果表明深度神经网络模型对于未知的拓扑变化具有一定的适应能力。若要提高模型在网络重构下的性能，可考虑在训练集中加入不同重构情景下的故障样本和非故障样本。

3.3.3 高阻故障下的性能

为评估深度神经网络模型定位高阻故障的能力，令每个分区在 500~1000 Ω 的过渡电阻范围内生成故障样本，并分为 500~600 Ω 、600~700 Ω 、700~800 Ω 、800~900 Ω 、900~1000 Ω 共 5 个阻值区间。在每一区间内，为故障区段上每个类型的故障生成 18 个样本。

进一步将过渡电阻范围拆分为两部分，用集合形式表示为

$$\left\{ R_{\Omega 1} \mid 20i < R_{\Omega 1} < 20i + 10, 25 \leq i \leq 49 \text{ 且 } i \in \mathbb{Z} \right\}$$

$$\left\{ R_{\Omega 2} \mid 20i + 10 < R_{\Omega 2} < 20(i + 1), 25 \leq i \leq 49 \text{ 且 } i \in \mathbb{Z} \right\}$$

每个小区间的长度为 10 Ω 。将 $R_{\Omega 1}$ 作为训练集中的样本， $R_{\Omega 2}$ 则作为测试集中的样本，这样做的目的是测试模型的通用性。表 6 为不同过渡电阻下模型 M1—M3 的定位精度，并给出 M2 在不同阻值

范围内其定位准确率的变化曲线，如图 12 所示。

表 6 不同过渡电阻下各分区的定位准确率

Table 6 Location accuracy of each partition under different transition resistances

过渡电阻/ Ω	$P_{acc1}/\%$	$P_{accII}/\%$	$P_{accIII}/\%$
(500,600)	99.60	99.70	99.70
(600,700)	99.60	99.67	99.65
(700,800)	99.51	99.56	99.56
(800,900)	99.32	99.35	99.36
(900,1000)	99.21	99.23	99.23

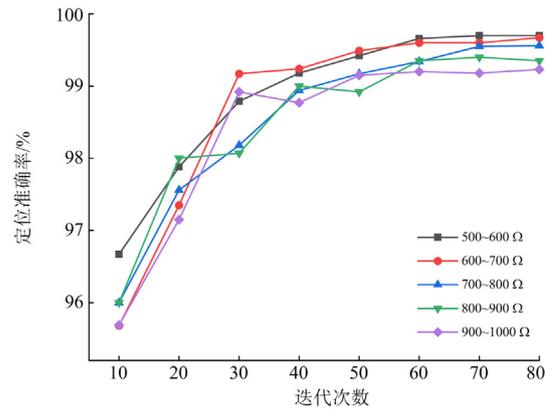


图 12 各种故障电阻范围内的高阻故障下模型 M2 的定位准确率

Fig. 12 Location accuracy of model M2 under high impedance faults within various fault resistance ranges

综上所述，即使加入高阻故障样本，模型的定位准确率在 500~1000 Ω 的故障电阻范围内仍不低于 99%，证明了本文所提方法能有效提取高阻故障特征。

3.3.4 不同 IIDG 渗透率下的性能

为进一步验证分布式电源渗透率大小对模型定位性能产生的影响，本小节进行如下仿真：设置逆变器型分布式电源(inverter interfaced distributed generation, IIDG)容量分别为 1.2 MW、1.4 MW、1.6 MW、1.8 MW 和 2.0 MW，在每个分区分别生成故障样本和非故障样本各 900 个，样本均匀覆盖不同的 DG 渗透率。将上述样本作为测试集输入深度神经网络模型，得到的故障定位准确率如表 7 所示。

表 7 IIDG 容量下各分区的定位准确率

Table 7 Location accuracy of each partition under different IIDG capacities

DG 容量/MW	$P_{acc1}/\%$	$P_{accII}/\%$	$P_{accIII}/\%$
1.2	99.60	99.70	99.70
1.4	99.57	99.68	99.67
1.6	99.50	99.63	99.63
1.8	99.46	99.55	99.55
2.0	99.35	99.43	99.44

由表 7 可知, 模型的定位准确率受 IIDG 渗透率变化的影响较小。即使在离线训练阶段仅考虑了 DG 容量为 1.0 MW 的情况下, 改变 DG 容量后定位精度仍可维持在较高水平, 其下降幅度不超过 0.3%。因此, 本文方法能较好地适应配电网中不同的 IIDG 渗透率。

3.3.5 不同故障初相角下的性能

为验证不同故障初相角下的定位性能, 本节令故障初相角分别为 0° 、 90° 和 180° , 遍历不同的过渡电阻、故障区段、故障位置以及故障类型生成故障样本, 得到各分区的定位准确率如表 8 所示。

表 8 不同故障初相角下各分区的定位准确率

Table 8 Location accuracy of each partition under different fault initial phase angles

故障初相角/ $^\circ$	$P_{\text{accl}}/\%$	$P_{\text{accll}}/\%$	$P_{\text{acclll}}/\%$
0	99.6	99.7	99.7
90	98.7	99.0	98.9
180	98.8	99.0	98.8

由表 8 可知, 与故障初相角为 0° 时相比, 故障初相角取 90° 、 180° 时模型的定位准确率稍有降低, 但仍可达到 98% 以上。证明了该方法基本不受故障初相角的影响, 能够满足配电网对故障区段定位精度的需求。

4 结论

本文提出了一种基于边缘计算和深度学习的配电网故障区段定位方法, 在量测条件受限的配电网中, 由于可利用的故障信息有限, 因此通过数据驱动方式, 将相电流稳态有效值作为样本特征, 训练深度神经网络进行故障定位。并将边缘计算融入配电网故障定位, 详细介绍了分区规划方法。本文主要结论如下:

1) 建立了基于分区节点数修正的边缘设备配置优化模型, 为边缘计算在配电网故障定位中的应用奠定了基础。故障数据只需上传至相应的边缘节点, 降低了通信时延, 缓解了主站的计算负担, 提升了故障定位的效率。此外, 主站与边缘节点均存储着故障定位模型, 二者可互为备用, 显著提高了供电安全性与可靠性。

2) 在训练深度神经网络模型的过程中, 样本特征选取相电流稳态有效值在故障前后的差值, 该特征量在装设有电流互感器的配电网中即可获得。虽然可利用的故障信息比较单一, 但基于数据驱动的智能算法仍能从大量样本中深度挖掘其潜在规律, 解决了量测条件受限的问题。

3) 全连接型深度神经网络可以有效学习样本特征与故障区段之间的映射关系, 且基于深度学习的故障定位方法无需进行阈值整定, 因此能够更好地适应非线性程度增大、运行方式多变的配电网。仿真结果表明该定位模型在逆变型分布式电源接入、高阻故障、噪声干扰以及拓扑改变等情况下均表现良好。

参考文献

- [1] ZHANG Zhixia, LIU Xiao. A summary of line selection in single phase earth fault system[J]. Lecture Notes in Electrical Engineering, 2014, 237: 483-490.
- [2] 李卫彬, 童欣, 黄超, 等. 基于分层定位模型的含 DG 配电网故障定位方法研究[J]. 电力系统保护与控制, 2022, 50(24): 160-166.
LI Weibin, TONG Xin, HUANG Chao, et al. A fault location method for a distribution network with DG based on a hierarchical location model[J]. Power System Protection and Control, 2022, 50(24): 160-166.
- [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] 王巍璋, 王淳, 尹发根. 基于可达矩阵和贝叶斯定理的含分布式电源的配电网故障区段定位[J]. 中国电力, 2021, 54(7): 93-99, 124.
WANG Weizhang, WANG Chun, YIN Fagen. Reachability matrix and Bayes' theorem based fault section location of power distribution network with distributed generation[J]. Electric Power, 2021, 54(7): 93-99, 124.
- [5] 郑一斌. 基于数据驱动建模的配电网故障区段定位研究[D]. 杭州: 浙江大学, 2021.
ZHENG Yibin. Research on data-driven fault section location in distribution network[D]. Hangzhou: Zhejiang University, 2021.
- [6] GURURAJAPATHY S S, MOKHLIS H, ILLIAS H A. Fault location and detection techniques in power distribution systems with distributed generation: a review[J]. Renewable and Sustainable Energy Reviews, 2017, 74: 949-958.
- [7] BUZO R F, BARRADAS H M, LEO F B. A new method for fault location in distribution networks based on voltage sag measurements[J]. IEEE Transactions on Power Delivery, 2021, 36(2): 651-662.
- [8] XIE Liwei, LUO Longfu, LI Yong, et al. A traveling wave-based fault location method employing VMD-TEO for distribution network[J]. IEEE Transactions on Power Delivery, 2020, 35(4): 1987-1998.

- [9] FURSE C M, KAFAL M, Razzaghi R., Shin Y.J. Fault diagnosis for electrical systems and power networks: a review[J]. IEEE Sensors Journal, 2021, 21(2): 888-906.
- [10] 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.
- [11] 葛维春, 张硕, 张艳军, 等. 基于 μ PMU同步量测数据的配电网故障定位方法[J]. 电力系统保护与控制, 2020, 48(4): 39-46.
GE Weichun, ZHANG Shuo, ZHANG Yanjun, et al. A novel method for fault location of distribution network based on μ PMU synchronized measurement data[J]. Power System Protection and Control, 2020, 48(4): 39-46.
- [12] 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.
- [13] MA Gang, JIANG Linru, ZHOU Kaihua, et al. A method of line fault location based on travelling wave theory[J]. International Journal of Control and Automation, 2016, 9(2): 261-270.
- [14] 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.
- [15] ZHENG Meng, BARATI M. A real-time fault localization in power distribution grid for wildfire detection through deep convolutional neural networks[J]. IEEE Transactions on Industry Applications, 2021, 57(4): 4316-4326.
- [16] LI Zijiang, LIN Shuyue, GUO Moufa, et al. A decentralized fault section location method using autoencoder and feature fusion in resonant grounding distribution systems[J]. IEEE Systems Journal, 2022, 16(4): 5698-5707.
- [17] YU Yang, LI Mengshi, JI Tianyao, et al. Fault location in distribution system using convolutional neural network based on domain transformation[J]. CSEE Journal of Power and Energy Systems, 2021, 7(3): 472-484.
- [18] 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.
- [19] 王冠华. 中性点灵活接地配电网单相接地故障定位研究[D]. 徐州: 中国矿业大学, 2021.
WANG Guanhua. Study on single phase to ground fault location in distribution network with flexible neutral grounding[D]. Xuzhou: China University of Mining and Technology, 2021.
- [20] PENG Nan, LIANG Rui, WANG Guanhua, et al. Edge computing-based fault location in distribution networks by using asynchronous transient amplitudes at limited nodes[J]. IEEE Transactions on Smart Grid, 2021, 12(1): 574-588.
- [21] 潘思宇, 刘宝柱. 面向配电网故障快速处理的边缘计算单元优化配置方法[J]. 电力建设, 2022, 43(3): 31-41.
PAN Siyu, LIU Baozhu. Optimal configuration method of edge computing units for rapid faults processing in distribution network[J]. Electric Power Construction, 2022, 43(3): 31-41.
- [22] STAHLHUT J W, BROWNE T J, HEYDT G T, et al. Latency viewed as a stochastic process and its impact on wide area power system control signals[J]. IEEE Transactions on Power Systems, 2008, 23(1): 84-91.
- [23] 邓雪, 李家铭, 曾浩健, 等. 层次分析法权重计算方法分析及其应用研究[J]. 数学的实践与认识, 2012, 42(7): 93-100.
DENG Xue, LI Jiaming, ZENG Haojian, et al. Research on computation methods of AHP wight vector and its applications[J]. Mathematics in Practice and Theory, 2012, 42(7): 93-100.
- [24] 何志勤, 张哲, 尹项根, 等. 集中决策式广域后备保护的分区模型与优化算法[J]. 电工技术学报, 2014, 29(4): 212-219.
HE Zhiqin, ZHANG Zhe, YIN Xianggen, et al. Partition model and optimization algorithm for wide-area backup protection based on centralized decision-making mode[J]. Transactions of China Electrotechnical Society, 2014, 29(4): 212-219.
- [25] 梁海平, 顾雪平. 基于谱聚类的黑启动子系统划分[J]. 电网技术, 2013, 37(2): 372-377.
LIANG Haiping, GU Xueping. Black-start network partitioning based on spectral clustering[J]. Power System Technology, 2013, 37(2): 372-377.

收稿日期: 2023-04-26; 修回日期: 2023-09-20

作者简介:

张大波(1979—), 男, 博士, 副教授, 研究方向为电网可靠性评估和规划调度; E-mail: zhangdb2004@163.com

李雪婷(1998—), 女, 通信作者, 硕士研究生, 研究方向为配电网故障定位。E-mail: 2962799715@qq.com

(编辑 魏小丽)