

引用格式:石昱烜,席燕辉,张伟杰.基于 GAF-ResNet50 的配电网故障区段定位[J].电力科学与技术学报,2025,40(2):122-130.

Citation:SHI Yuxuan, XI Yanhui, ZHANG Weijie.Distribution network fault segment location based on GAF-ResNet50[J]. Journal of Electric Power Science and Technology,2025,40(2):122-130.

基于 GAF-ResNet50 的配电网故障区段定位

石昱烜^{1,2},席燕辉¹,张伟杰¹

(1.长沙理工大学电气与信息工程学院,湖南长沙 410014;2.邵阳学院电气工程学院,湖南邵阳 422099)

摘要:配电线路是现代电力系统的组成部分,直接影响着供电的安全和稳定。配电网故障定位分为对故障点的精准定位与区段定位两种。针对配电网结构的复杂性,提出基于 GAF-ResNet50 的配电网故障区段定位方法。该方法通过格拉姆角场算法,将一维时间序列转换成二维(Gramian angular field, GAF)图像,并利用残差神经网络的框架,从 GAF 图像中提取信号更深层次的故障特征,精确地辨识故障区域。为验证该方法的有效性,在 MATLAB 平台上搭建 IEEE 13 节点的配电网模型,对其产生故障数据进行故障区段的定位仿真。研究结果表明:该方法能够快速、准确地进行故障区段定位,其精度在 98% 以上,且该方法对噪声具有良好的鲁棒性。

关键词:残差神经网络;配电网;格拉姆角场;域变换;故障定位

DOI:10.19781/j.issn.1673-9140.2025.02.013

中图分类号:TM933

文章编号:1673-9140(2025)02-0122-09

Distribution network fault segment location based on GAF-ResNet50

SHI Yuxuan, XI Yanhui, ZHANG Weijie

(1. School of Electrical & Information Engineering, Changsha University of Science & Technology, Changsha 410014, China;

2. School of Electrical Engineering, Shaoyang University, Shaoyang 422099, China)

Abstract: Distribution lines are an integral part of modern power system, which directly influence the safety and stability of power supply. Distribution network fault location can be classified into precise fault location and fault segment location. Considering the complexity of distribution network structure, this paper proposes a fault segment location method based on Gramian angular field (GAF)-ResNet50. The one-dimensional time series is converted into a two-dimensional GAF image by the GAF algorithm, and the deeper-level fault features of the signal are extracted from the GAF image by using the framework of residual neural network so that the fault areas can be identified more accurately. To verify the effectiveness of the proposed method, the study builds an IEEE 13-node distribution network model on the MATLAB platform to generate fault data and conduct the simulation of fault segment location. The simulation results show that the proposed method can quickly and accurately locate fault segments, with a positioning accuracy of more than 98%, and has good robustness to noise.

Key words: residual neural network; distribution network; Gramian angular field; domain transformation; fault location

配电网作为电网的重要组成部分,承担了为大部分电力用户供电的服务功能,是保障电力供应的关键环节之一,直接影响供电安全及电网可靠性。目前,配电网受用电量、分布式电源集成度、基础设施老化及自然灾害等因素的影响,其发生故障风险日益增加。对配电网故障进行定位显得尤为重要。

配电网故障定位分为对故障位置的精准定位和区段定位两种。配电网故障区段定位能快速实现故障区段的隔离、非故障区段的供电恢复,能提升用户的用电体验。故障区段定位技术一般通过采集电网现场设备馈线终端单元(feeder terminal unit, FTU)的实时故障信息来实现。常用的故障区段定

收稿日期:2023-04-04;修回日期:2023-09-11

基金项目:国家自然科学基金(52277078);湖南省自然科学基金(2022JJ30609)

通信作者:席燕辉(1979—),女,博士,教授,主要从事电力系统分析等方面的研究;E-mail:xiyanhui@126.com

位方法有矩阵法^[1-2]、智能算法^[3]等。矩阵法的原理是对由FTU传输的故障信息所构成的矩阵与配电网本身的网络拓扑结构描述矩阵之间进行矩阵运算处理来确定故障区段^[4]。该方法虽然速度快,但定位精度不高,容错率低。故障区段定位方法的智能算法有遗传算法^[5]、粒子群算法^[6]、蚁群算法^[7]、蝙蝠算法^[8-9]等。这些算法在FTU采集故障信息准确的前提下,定位效果较为理想,但它们容易陷入局部最优解,且存在“早熟收敛”等问题^[10]。

随着神经网络技术的不断发展,很多国内外研究学者将其运用于智能配电网的故障定位^[11]。与其他方法相比,基于神经网络的方法具有自学习和自适应的特点。文献[12]提出了利用人工神经网络(artificial neural network, ANN)对智能配电网中不同类型的故障进行分类和定位的建议。文献[13]提出了一种基于ANN的故障定位模型,该模型可实现对电力电缆故障位置的定位。但ANN易陷入局部最优解,且存在梯度消失问题^[14-15]。文献[16]提出了一种用于微电网故障检测和分类的长短时记忆网络(long short term memory, LSTM)方法。LSTM法在一定程度上解决了梯度消失问题^[17],但其自身结构复杂,且算法计算量大,耗时长^[18-19]。

计算机视觉算法在图像领域的快速发展启发了研究者新的思路^[20]。文献[21-22]提出了一种基于信号转为图片的卷积神经网络(signal-to-image convolutional neural network, SIG-CNN)的配电网故障定位方法。文献[23-24]提出了一种基于LeNet-5的新型卷积神经网络(convolutional neural networks, CNN)故障诊断方法。该定位方法将电压与电流时序数据转换成二维图像并对其进行处理,其定位精度大幅提高。

基于视觉的深度学习模型也已应用于配电网的故障定位,但该方法中的采用时序转换二维图像的步骤缺少了对关键特征的提取与对时间信息的深度挖掘^[25]。文献[26]使用格拉姆角场(Gramian angular field, GAF)方法,将行波线模分量编码为图像,在配电网故障定位方面取得较好的定位效果。文献[27]提出了一种基于GAF成像的SAT-CNN模型,该模型能准确地对输电线路故障进行分类和检测。相同的故障即使发生在不同区域中,其各自电流的故障分量变化也很小。但采用GAF对于时间序列进行编码,可挖掘一维信号中绝对的时间先后关系^[28-29],提取信号的波形特征^[30],辨识这些电流的微小变化,提高算法定位精度。

综上所述,本文提出了一种基于GAF-ResNet50的配电网故障区段定位方法。该方法基于GAF对配电网三相电流信号时序数据进行处理,将数据的时间序列在极坐标系中进行表示,有效地利用角度透视来确定不同时间戳内的时间相关性,从而提取更关键的特征和细节,提高配电网故障定位的精度。基于ResNet 50的深度网络,该方法有效解决了配电网加深造成的梯度消失问题,进一步提高了配电网故障定位的精度。

1 基于GAF-ResNet50的配电网故障定位模型

1.1 时间序列成像

格拉姆矩阵是一种将时间序列编码为图像的方法^[31]。它将一维时间序列信号转化成极坐标系中的表示形式,通过三角运算生成格拉姆矩阵,从而将一维时间序列转化为二维图像。

给定一维时间序列 $X = \{x_1, x_2, \dots, x_n\}$,其中, x_i 为第*i*点的采样值。为使该序列的内积不过度偏向序列中的最大值,将时间序列压缩到 $[-1, 1]$ 区间,即:

$$\tilde{x}_i = \frac{\left(x_i - \max_i(x_i)\right) + \left(x_i - \min_i(x_i)\right)}{\max_i(x_i) - \min_i(x_i)} \quad (1)$$

式中, $\tilde{x}_i$ 为缩放后的采样值。

进一步地,将缩放后的序列 $\tilde{X} = \{\tilde{x}_1, \tilde{x}_2, \dots, \tilde{x}_n\}$ 从笛卡儿坐标系映射到极坐标系中,将时间序列的缩放值 $\tilde{x}_i$ 与时间戳 t_i 分别映射到极坐标系中的角度 ϕ_i 与半径 r_i ,其映射表达式为

$$\begin{cases} \phi_i = \arccos(\tilde{x}_i), & -1 \leq \tilde{x}_i \leq 1 \\ r_i = \frac{t_i}{N}, & t_i \in N \end{cases} \quad (2)$$

式中, N 为常数因子,表示区间 $[0, 1]$ 的等分数,用于正则化极坐标系跨度。

式(2)的编码映射是一个双射,每一个笛卡儿坐标系中的时间序列点在极坐标系中都有且仅有一个点与其对应。与笛卡儿坐标系不同的是,极坐标系保证了这些数据绝对的时间先后关系。

将时间序列映射到极坐标系后,可以通过每个点之间三角函数的和或差来识别不同时间间隔内的时间相关性。在此基础上,构建格拉姆求和角场矩阵 g_{GASF} (Gramian angular summation fields, GASF)和格拉姆差分角场(Gramian angular difference fields, GADF)矩阵 g_{GADF} ,其表达式分别为

$$\mathbf{g}_{\text{GASF}} = [\cos(\phi_i + \phi_j)]_{n \times n} = \tilde{\mathbf{X}}^T \cdot \tilde{\mathbf{X}} - \sqrt{\mathbf{I} - \tilde{\mathbf{X}}^{T2}} \cdot \sqrt{\mathbf{I} - \tilde{\mathbf{X}}^2} \quad (3)$$

$$\mathbf{g}_{\text{GADF}} = [\sin(\phi_i - \phi_j)]_{n \times n} = \sqrt{\mathbf{I} - \tilde{\mathbf{X}}^{T2}} \cdot \tilde{\mathbf{X}} - \tilde{\mathbf{X}}^T \cdot \sqrt{\mathbf{I} - \tilde{\mathbf{X}}^2} \quad (4)$$

式(3)、(4)中, $\tilde{\mathbf{X}}$ 为时间序列 X 中元素 x_i 组成的 n 维向量 $\mathbf{x} = (x_1, x_2, \dots, x_n)^T$; $\mathbf{I}$ 是单位行向量。

GAF 提供了一种保持时间依赖性的方法。在该方法中, 随着时间增长, 序列点的位置也从坐标系的左上角逐渐移动到坐标系右下角。

本文采用 GAF 与 GASF 对配电网三相电流信号数据进行处理。BG 单相短路故障的 B 相电流数据如图 1 所示, 经过 GAF 转换后的图像如图 2 所示。




图 1 BG 单相短路故障的 B 相电流波形

Figure 1 Phase B current waveform diagram of single-phase-BG short circuit fault




图 2 B 单相短路故障的 B 相 GAF

Figure 2 GAF image of phase B of the single-phase-B short circuit fault

1.2 ResNet50 网络模型

研究发现, 随着网络深度的增加, 网络的训练效果变得越来越差, 即出现了深度网络中特有的梯度消失与爆炸问题。文献[32]提出了在网络中加入恒等连接的方式, 用残差学习来解决梯度消失问题的方法。

残差单元是深度残差网络的基本组成单元, 其

结构如图 3 所示。残差单元存在中间通路 with 右侧通路 2 条通路。其中, 中间通路由多个权值层组成, 从中可提取数据的高维特征; 右侧通路 (也被称为恒等连接) 可提供输出, 该输出与中间通路提取的高维特征相加, 可避免深度网络出现梯度消失问题。

ResNet50 网络有 4 组残差模块, 每组分别有 3、4、6、3 个残差模块, 每个残差模块里有 3 个卷积层。因此, 该网络的残差模块共有 48 层卷积层。另外, ResNet50 网络在最开始还有一个单独的卷积层。所以, 该网络由 49 层卷积层和 1 层全连接层构成, 其网络结构如图 4 所示。




图 3 残差单元结构

Figure 3 Residual element structure




图 4 ResNet50 网络结构

Figure 4 ResNet50 structure diagram

在图 4 中,实线圈起来的残差模块可直接进行求和运算;虚线圈起来的残差模块的输入和输出的特征图通道数是不同的,必须通过 1×1 的卷积运算改变其通道数后;才能进行求和运算。

1.3 基于 GAF-ResNet50 的配电网故障定位

配电网区段定位需要根据采集的信号进行分析,判断故障可能存在的区段或支路,这与神经网络的多分类问题类似。本文的神经网络的输出神经元个数为 5,即除无故障情况外,故障可能发生在 4 个区域中。如果某区段的输出为 0,则该区段处于正常状态;如果该区段输出为 1,则该区段处于故障状态。基于 GAF-ResNet50 的配电网故障定位算法流程如图 5 所示。先通过 GAF 将采集的配电网三相电流信号转换为二维图片信号;再利用 ResNet50 分类网络,对故障特征进行提取;最后,对故障区段进行分析与定位。




图 5 算法流程

Figure 5 Algorithm flowchart

2 试验结果

2.1 配电网模型

本文将应用 IEEE 13 节点配电网测试馈线来生成数据,该测试馈线数据也是国际公认和广泛研究的配电系统模型数据来源之一。该模型为小型 4.16 kV 配电网馈线模型,其负载较高,包括一个由三角形连接的单相单元组成的变电站电压调节器和多种相位的架空和地下线路。为生成故障数据,本文拟在其中的 645-633,632-633,671-680,692-675 这 4 个区段发生故障,其模型如图 6 所示。将该模型通过 MATLAB/Simulink 进行仿真,具体负载配置与线路配置数据分别见表 1、2。




图 6 IEEE 13 节点配电网馈线故障模型

Figure 6 Feeder fault model of IEEE 13-node distribution

表 1 负载配置数据表

节点	接线形式	Ph-1/ kW	Ph-1/ kVar	Ph-2/ kW	Ph-2/ kVar	Ph-3/ kW	Ph-3/ kVar
634	Y-PQ	160	110	120	90	120	90
645	Y-PQ	0	0	170	125	0	0
646	D-Z	0	0	230	132	0	0
652	Y-Z	128	86	0	0	0	0
671	D-PQ	385	220	385	220	385	220
675	Y-PQ	485	190	68	60	290	212
692	D-I	0	0	0	0	170	151
611	Y-I	0	0	0	0	170	80

表 2 线路配置表

开始节点	结束节点	线路编号	配置	长度/m
632	645	603	架空线路	152
632	633	602	架空线路	152
632	671	601	架空线路	610
633	634	—	三相变压器	—
645	646	603	架空线路	91
671	684	604	架空线路	91
671	680	601	架空线路	305
671	692	—	三相断路器	—
684	652	607	地下线路	244
684	611	605	架空线路	91
692	675	606	地下线路	152

2.2 数据生成

本文仅使用一个传感器收集电力信号。根据电路原理,将传感器安装在位于总线旁的节点 632 侧,收集 4 个区域的信号波动状况。通过该传感器,采集 A、B、C 三相电流数据作为数据集。在实际输电线路中,故障场景复杂多变。因此,该试验在生成模拟数据时考虑了故障类型、故障开始时间、故障初相角、故障电阻、故障位置、故障区域等参数的影响。

1) 故障类型。本文设置了 Ag, Bg, Cg, ABg, ACg, BCg, AB, AC, BC, ABC 共 10 种故障类型。

2) 故障开始时间。为更好地获取电流高频信息,采样频率设置为 20 kHz,故障开始时间设置为 0.017 s,间隔为 0.001 s。

3) 故障电阻。故障导致接地引起的阻抗 R 设置为

$$R \in \{0.01 \Omega, 0.10 \Omega, 1.00 \Omega, 10.00 \Omega, 20.00 \Omega, 30.00 \Omega, 40.00 \Omega, 50.00 \Omega, 60.00 \Omega, 70.00 \Omega, 80.00 \Omega, 90.00 \Omega, 100.00 \Omega\} \quad (5)$$

4) 故障距离。每个区域均有 9 个可能发生故障的地点,每个地点距起点的长度间隔均为 50 m,

具体如下:

$$L \in \{50 \text{ m}, 100 \text{ m}, 150 \text{ m}, \dots, 450 \text{ m}\} \quad (6)$$

5) 故障区域。本文设置了4个可能发生故障的区域,它们可表示为(其中,0表示无故障)

$$r \in \{0, 1, 2, 3, 4\} \quad (7)$$

本文共收集了46 332组三相电流数据($n=46\,332$,区域1只有B、C两相,所以在区域1中只有4种故障类型)。将数据集中80%的数据作为训练集的数据(共37 066组),其余20%的数据作为测试集中的数据(共9 266组)。

值得一提的是,中性点接地方式对故障特征的影响也较大。在小电力系统中,大多数采用中性点不接地的运行方式。只有当电压为6~35 kV时,

才会采取中性点经消弧线圈接地方式。电压为110 kV以上的电力系统,一般采取中性点直接接地的运行方式。本文研究的是4.16 kV的小系统,故只讨论中性点不接地的运行方式。

以单相接地故障为例,图7给出了4个区域分别发生故障时的三相电流波形图。其中,故障开始时间为0.017 s,结束时间为0.120 s,故障电阻为1.00 Ω 。由于区域1、2相隔较近,且这两者区域相邻,所以区域1、2的电流波形也相似。区域3、4的情况也与区域1、2的情况类似。

为更好地从时间角度分析数据,将图7所示的A、B、C三相电流数据转换为GAF图,并将其合并在一起,结果如图8所示。




图7 4个区域的单相故障电流

Figure 7 Single-phase fault current diagram for four regions




图8 4个区域单相短路故障GAF转换

Figure 8 GAF image converted from single-phase fault in four regions

从图7中可以看出,当区段交界处附近发生故障时,故障波形相似,难以区分。从图8中可以看出,对应故障相的GAF图与其他两相的故障图区别明显,对应故障相的GAF图颜色较深,纹理也有显著不同。这表明将时间序列数据转化成GAF图后,计算机能更好地识别故障。

2.3 试验结果

本试验采用 Windows 11 系统、NVIDIA GeForce RTX3060 Laptop GPU 和 AMD Ryzen 76800 H with Radeon Graphics 的电脑,仿真平台为 PyTorch 1.7.1。在数据训练过程中,采用动态学习的方法,初始学习率设置为 0.001,训练批次大小为 32,训练轮次为 8。

2.3.1 无噪声干扰

在理想环境下,考虑测量数据无噪声干扰地区情况。GAF-ResNet50网络测试数据的混淆矩阵如图9所示。




图9 GAF-ResNet50的混淆矩阵

Figure 9 Confusion matrix of GAF-ResNet50


从图9中可以看出,该定位方法具有较高的精度。其中,无故障的情况均能被精准识别;除区域3外,其他各区域的定位精度也都较高,只有个位数的错误。区域3和区域4相近,波形十分相似,导致区域3中有23例故障被错误地识别到了区域4中,在区域4中有7例故障被错误地识别到区域3中。

为证明 GAF-ResNet50 网络辨识故障的优越性,本文给出了 AlexNex 网络、DenseNet 网络、MobileNet 网络、LSTM 网络的测试混淆矩阵图,如图10所示。其中,输入 LSTM 网络的数据为一维时间序列数据,其他3个网络的输入数据是 GAF 图形数据。


从图10中可以看出,各网络均无法完全准确地对每个故障区域进行定位,且各网络的故障定位精度也各不相同。其中,所有网络都能对无故障情




(a) AlexNex 网络



(b) DenseNet 网络



(c) MobileNet 网络



(d) LSTM 网络

图10 各网络的混淆矩阵

Figure 10 Confusion matrix of each network

况进行准确识别。在区域1的故障定位中,除 AlexNet 网络外,其他网络均能对故障进行精确定位。当区域2发生故障时,LSTM网络表现最差,AlexNet 网络和 DenseNet 网络表现次之;只有 GAF-ResNet 网络和 MobileNet 网络在该区域的定位错误次数较少,分别为6次和3次。各网络对于区域3的故障定位均表现不佳,仅有 LSTM 网络和 GAF-ResNet50 网络表现相对好一些。DenseNet 网络能够对区域4的故障精确定位,而 LSTM 网络和 GAF-ResNet50 网络对该区域的故障定位存在少数错判。总体来看,GAF-ResNet50 网络对各个区域的故障定位都表现出了较高的准确度。

为进一步对比各网络的故障定位性能,引入准确率 A ,召回率 R ,精确率 P ,分数 F_1 这4个评判指标,其具体计算式分别如下:

$$A = \frac{n_{TP} + n_{TN}}{n_{TP} + n_{FP} + n_{TN} + n_{FN}} \times 100\% \quad (8)$$

$$R = \frac{n_{TP}}{n_{TP} + n_{FN}} \times 100\% \quad (9)$$

$$P = \frac{n_{TP}}{n_{TP} + n_{FP}} \times 100\% \quad (10)$$

$$F_1 = \frac{2PR}{P + R} \times 100\% \quad (11)$$

式中, n_{TP} 为正样本中被正确识别的样本数量; n_{TN} 为负样本被正确识别的数量; n_{FP} 为误报的负样本数量; n_{FN} 漏报的正样本数量。

GAF-ResNet50 网络与另外4类网络的性能评价结果分别见表3~7。

表3 GAF-ResNet50 网络评估结果

Table 3 GAF-ResNet50 evaluation results %			
故障区域	召回率	精确率	分数 F_1
无故障	100.00	100.00	100.00
区域1	99.29	100.00	99.65
区域2	100.00	99.72	99.86
区域3	99.81	98.92	99.36
区域4	98.92	99.81	99.36

表4 AlexNet 网络评估结果

Table 4 AlexNet evaluation results %			
故障区域	召回率	精确率	分数 F_1
无故障	100.00	100.00	100.00
区域1	98.36	99.88	99.12
区域2	99.95	99.34	99.64
区域3	99.38	97.02	98.19
区域4	97.05	99.39	98.20

表5 DenseNet 网络评估结果

Table 5 DenseNet evaluation results %			
故障区域	召回率	精确率	分数 F_1
无故障	100.00	100.00	100.00
区域1	98.48	100.00	99.23
区域2	100.00	99.38	99.69
区域3	99.90	97.34	98.60
区域4	97.40	99.90	98.64

表6 MobileNet 网络评估结果

Table 6 MobileNet evaluation results %			
故障区域	召回率	精确率	分数 F_1
无故障	100.00	100.00	100.00
区域1	99.53	100.00	99.76
区域2	100.00	99.81	99.90
区域3	99.23	98.06	98.64
区域4	98.08	99.24	98.65

表7 LSTM 网络评估结果

Table 7 LSTM network evaluation results %			
故障区域	召回率	精确率	分数 F_1
无故障	100.00	100.00	100.00
区域1	96.89	100.00	98.42
区域2	100.00	98.73	99.36
区域3	99.81	98.90	99.35
区域4	98.91	99.81	99.36

GAF-ResNet50网络具有最高的准确率99.64%,LSTM 网络和 MobileNet 网络的准确率分别为99.41%与99.34%,DenseNet 与 AlexNet 网络的准确率分别为99.23%与99.01%。由表3~7可知,在召回率和精确率方面,LSTM 网络在区域1中表现较差,MobileNet 网络和 DenseNet 网络则在区域3中的召回率和区域4中的精确率方面表现欠佳,而 AlexNet 网络只在区域2的故障定位上表现良好。只有 GAF-ResNet50 网络在各个区域的故障定位指标上都非常稳定且突出。综合这些评价指标,GAF-ResNet50 网络具有最好的故障区段定位效果。

2.3.2 噪声环境

在实际环境中,传感器收集的数据会包含噪声。为模拟现场实际环境,在原始数据集中添加信噪比分别为10、20、30、40 db的噪声与混合噪声(将10、20、30、40 db的噪声均匀地混合添加到原始数据集中)。在添加噪声后,不同算法的故障定位准确率见表8。

表 8 不同噪声环境下不同算法故障定位准确率比较
Table 8 Comparison of accuracy of different algorithms in noisy environment

网络	不同噪声环境下故障定位准确率/%				
	10 db	20 db	30 db	40 db	混合噪声
Alex	74.22	73.21	80.97	88.35	74.89
DenseNet	82.23	83.07	86.47	92.61	88.66
MobileNet	86.97	88.63	91.02	94.76	92.24
LSTM	87.48	90.41	92.42	93.18	93.11
GAF-ResNet50	87.95	90.77	93.64	95.47	93.28

由表 8 可知,各网络对噪声的干扰都十分敏感。AlexNet 网络、DenseNet 网络和 MobileNet 网络在分别受到 10、20、30 db 的噪声影响时,其准确率均明显下降;仅在受到 40 db 的高噪声干扰时,这些网络的定位准确率才有所提高。而当信噪比大于或等于 20 db 时,GAF-ResNet50 网络和 LSTM 网络的准确率均在 90% 以上,且随着信噪比的提高,两者的定位准确率均在稳步提升。最重要的是,GAF-ResNet50 网络在各种噪声比干扰下的定位准确率都高于 LSTM 网络的,其抗干扰能力明显优于其他网络的。

3 结语

本文提出了一种基于 GAF-Resnet50 的配电网故障区段定位方法,为配电网故障的智能定位提供了新思路。该方法先通过 GAF 将一维故障信号转换成二维图像信号;再利用 ResNet50 实现故障区域的定位;最后,为了验证该方法的有效性,在 MATLAB/Simulink 平台上建立配电网线路模型并进行仿真,该仿真结果表明了该算法的鲁棒性和可靠性,其在理想环境和噪声环境中的准确性等均优于其他算法的。随着越来越多的分布式电源并入配电网,配电网的拓扑结构与故障特征将更加复杂。因此,该算法在含分布式能源的配电网故障定位中的有效性将在后续研究中进一步研究。

参考文献:

[1] 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.

[2] 朱勇,陶用伟,李泽群,等.基于 FTU 的配电网故障快速定位的研究[J].能源与环保,2018,40(2):122-127.
ZHU Yong,TAO Yongwei,LI Zequn,et al.Study on fast fault location of distribution network based on FTU[J]. China Energy and Environmental Protection,2018,40(2): 122-127.
[3] 张雷,王光华,曹磊,等.基于 GAN 模型与随机森林算法的保护系统智能状态评价与预警[J].电力科学与技术学报,2021,36(6):104-112.
ZHANG Lei,WANG Guanghua,CAO Lei,et al.Smart status evaluation and early warning approach for highly-reliable protection systems based on GAN model and random forest algorithm[J]. Journal of Electric Power Science and Technology,2021,36(6):104-112.
[4] 黄天喜,李斌,刘武能,等.基于 Hausdorff Distance 算法的配电网故障区段定位方法[J].电力科学与技术学报,2022,37(5):115-123.
HUANG Tianxi,LI Bin,LIU Wuneng,et al.A fault section location method of distribution networks based on Hausdorff Distance algorithm[J]. Journal of Electric Power Science and Technology,2022,37(5):115-123.
[5] 李锰,王利利,刘向实,等.基于门当户对遗传算法的配电网多目标主动重构研究[J].电力系统保护与控制,2019,47(7):30-38.
LI Meng,WANG Lili,LIU Xiangshi,et al.Multi-objective active reconfiguration of distribution network based on the “properly matched marriage” genetic algorithm[J]. Power System Protection and Control,2019,47(7):30-38.
[6] 段颖梨,刘鹏华,段小妹.改进的粒子群算法在故障定位中的研究[J].通信电源技术,2020,37(5):22-25.
DUAN Yingli,LIU Penghua,DUAN Xiaomei. Research on improved particle swarm optimization algorithm in fault location[J]. Telecom Power Technology,2020,37(5): 22-25.
[7] 陶维青,肖松庆,李林,等.基于双精英蚁群算法的配电网故障区段定位[J].合肥工业大学学报(自然科学版),2020,43(12):1626-1632.
TAO Weiqing,XIAO Songqing,LI Lin,et al.Fault location of distribution network based on double elite ACO[J]. Journal of Hefei University of Technology (Natural Science),2020,43(12):1626-1632.
[8] 李贺,靳庆路,高善波.基于蝙蝠算法的含分布式电源配电网故障定位[J].电气技术,2017,18(1):34-38.
LI He,JIN Qinglu,GAO Shanbo. Fault location of distribution network with distributed generation based on bat algorithm[J]. Electrical Engineering,2017,18(1): 34-38.
[9] 王宇杉,王晨,王淑侠,等.基于 IWOA 的配电网故障定位方法[J].智慧电力,2024,52(11):98-105.
WANG Yushan,WANG Chen,WANG Shuxia,et al.Fault

- location method for distribution network based on improved IWOA[J]. Smart Power, 2024, 52(11): 98-105.
- [10] 陈婷. 智能算法在含分布式电源配电网故障定位中的应用综述[J]. 电气技术, 2020, 21(9): 1-6.
- CHEN Ting. Review of application of intelligent algorithm in fault location of distribution network with distributed power supply[J]. Electrical Engineering, 2020, 21(9): 1-6.
- [11] 李泽文, 曾祥君, 夏翊翔, 等. 高压交流输电线路故障行波定位技术综述[J]. 长沙理工大学学报(自然科学版), 2022, 19(3): 104-121.
- LI Zewen, ZENG Xiangjun, XIA Yixiang, et al. Review of traveling wave fault location technology for high voltage AC transmission lines[J]. Journal of Changsha University of Science & Technology (Natural Science), 2022, 19(3): 104-121.
- [12] USMAN M U, OSPINA J, FARUQUE M O. Fault classification and location identification in a smart DN using ANN and AMI with real-time data[J]. The Journal of Engineering, 2020, 2020(1): 19-28.
- [13] 孙廷玺, 方义治, 郑晓东, 等. 电力电缆局放在线监测神经网络自动识别精度的提升方法[J]. 高压电器, 2024, 60(7): 210-220.
- SUN Tingxi, FNAG Yizhi, ZHENG Xiaodong, et al. Improvement method of automatic identification accuracy of on-line monitoring neural network for partial discharge of power cable[J]. High Voltage Apparatus, 2024, 60(7): 210-220.
- [14] 王小星. 基于暂态行波的铁路电力电缆故障定位系统设计与实现[J]. 自动化技术与应用, 2021, 40(5): 28-31.
- WANG Xiaoxing. Design and implementation of railway power cable fault location system based on transient traveling wave[J]. Techniques of Automation and Applications, 2021, 40(5): 28-31.
- [15] KARMACHARYA I M, GOKARAJU R. Fault location in ungrounded photovoltaic system using wavelets and ANN[J]. IEEE Transactions on Power Delivery, 2018, 33(2): 549-559.
- [16] HOSSAIN M M, KOLLA S R. Fault detection and classification in microgrid using long short-term memory [C]//2022 IEEE International Conference on Electro Information Technology (eIT). Mankato, MN, USA. IEEE, 2022: 19-26.
- [17] 崔昊杨, 周坤, 胡丰晔, 等. 基于改进 LSTM 的电力设备状态融合预测模型[J]. 电测与仪表, 2023, 60(1): 10-15.
- CUI Haoyang, ZHOU Kun, HU Fengye, et al. State fusion prediction model of power equipment based on improved LSTM[J]. Electrical Measurement & Instrumentation, 2023, 60(1): 10-15.
- [18] 吴佳庆, 顾洁, 金之俭, 等. 基于长短期记忆网络和模糊 C 均值聚类的配电网故障预警方法研究[J]. 供用电, 2023, 40(10): 63-72.
- WU Jiaqing, GU Jie, JIN Zhijian, et al. Research on distribution network fault warning method based on long short-term memory network and fuzzy C-means clustering[J]. Distribution & Utilization, 2023, 40(10): 63-72.
- [19] DENG Y P, JIA H, LI P C, et al. A deep learning method based on long short term memory and sliding time window for type recognition and time location of power quality disturbance[C]//2018 Chinese Automation Congress (CAC). Xi'an, China. IEEE, 2018: 1764-1768.
- [20] WU Yunan, YANG Feng, LIU Ying, et al. A comparison of 1-D and 2-D deep convolutional neural networks in ecg classification[C]//Conference proceedings: Annual International Conference of the IEEE Engineering in Medicine and Biology Society. Annual Conference. 2018: 324-327.
- [21] 林园敏, 王鑫, 黄金钊, 等. 基于人工神经网络的智能配网实时故障图像识别系统[J]. 电网与清洁能源, 2024, 40(6): 130-136.
- LIN Yuanmin, WANG Xin, HUANG Jinzhao, et al. A real-time fault image recognition system of intelligent distribution network based on artificial neural network [J]. Power System and Clean Energy, 2024, 40(6): 130-136.
- [22] YU Y, LI M S, JI T Y, 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.
- [23] WEN L, LI X Y, GAO L, et al. A new convolutional neural network-based data-driven fault diagnosis method[J]. IEEE Transactions on Industrial Electronics, 2018, 65(7): 5990-5998.
- [24] 李卓, 王胤喆, 叶林, 等. 从感知-预测-优化综述图神经网络在电力系统中的应用[J]. 中国电力, 2024, 57(12): 2-16.
- LI Zhuo, WANG Yinzhe, YE Lin, et al. The application of graph neural networks in power systems from perspective of perception-prediction-optimization[J]. Electric Power, 2024, 57(12): 2-16.
- [25] LYU C G, HUO Z Q, CHENG X, et al. Distributed optical fiber sensing intrusion pattern recognition based on GAF and CNN[J]. Journal of Lightwave Technology, 2020, 38(15): 4174-4182.
- [26] HOU S Z, GUO W. Fault location method in nonsolid-earthed network based on spatial domain image fusion and convolution neural network[J]. Journal of Sensors, 2022, 2022(1): 8969479.

- loads of distribution transformer[J]. Journal of Electric Power Science and Technology, 2022, 37(1): 41-47.
- [22] 王茂海, 孙元章. 通用瞬时功率理论在三相不平衡负荷补偿中的应用[J]. 中国电机工程学报, 2003, 23(11): 56-59.
- WANG Maohai, SUN Yuanzhang. Application of universal instantaneous power theory to unbalanced load compensation[J]. Proceedings of the CSEE, 2003, 23(11): 56-59.
- [23] 李英量, 白博旭, 朱琦, 等. 基于电动汽车充电站的不平衡配电网自愈及优化运行[J]. 电力建设, 2024, 45(6): 37-46.
- LI Yingliang, BAI Boxu, ZHU Qi, et al. Self-healing and optimal operation of unbalanced distribution network based on electric vehicle charging station[J]. Electric Power Construction, 2024, 45(6): 37-46.
- [24] 韩平平, 潘薇, 张楠, 等. 基于负荷预测和非支配排序遗传算法的人工相序优化方法[J]. 电力系统自动化, 2020, 44(20): 71-78.
- HAN Pingping, PAN Wei, ZHANG Nan, et al. Optimization method for artificial phase sequence based on load forecasting and non-dominated sorting genetic algorithm[J]. Automation of Electric Power Systems, 2020, 44(20): 71-78.
- [25] 王思韡, 刘型志, 宣姝, 等. 基于线损等效的视在功率和功率因数计算方法研究[J]. 电测与仪表, 2024, 61(9): 65-70.
- WANG Siwei, LIU Xingzhi, XUAN Shu, et al. Research on apparent power and power factor calculation methods based on line loss equivalence[J]. Electrical Measurement & Instrumentation, 2024, 61(9): 65-70.
- [26] 周林, 张有玉, 刘强, 等. 三相不平衡度算法的比较研究[J]. 华东电力, 2010, 38(2): 210-215.
- ZHOU Lin, ZHANG Youyu, LIU Qiang, et al. Comparative study of three-phase unbalance algorithm[J]. East China Electric Power, 2010, 38(2): 210-215.
- [27] 朱明星, 李开金. 低压配电网三相不平衡度计算方法与应用[J]. 电测与仪表, 2019, 56(2): 41-46.
- ZHU Mingxing, LI Kaijin. Calculation method and application of three-phase unbalance in low voltage distribution network[J]. Electrical Measurement & Instrumentation, 2019, 56(2): 41-46.

(上接第130页 Continued from page 130)

- [27] FAHIM S R, SARKER Y, SARKER S K, et al. Self attention convolutional neural network with time series imaging based feature extraction for transmission line fault detection and classification[J]. Electric Power Systems Research, 2020, 187: 106437.
- [28] 郑炜, 林瑞全, 王俊, 等. 基于GAF与卷积神经网络的电能质量扰动分类[J]. 电力系统保护与控制, 2021, 49(11): 97-104.
- ZHENG Wei, LIN Ruiquan, WANG Jun, et al. Power quality disturbance classification based on GAF and a convolutional neural network[J]. Power System Protection and Control, 2021, 49(11): 97-104.
- [29] 赵妍, 孙延, 聂永辉. 基于格拉姆角差场和迁移残差网络的HVDC线路故障识别[J]. 电力建设, 2024, 45(8): 118-127.
- ZHAO Yan, SUN Yan, NIE Yonghui. HVDC line fault identification based on the gram angle difference field and transfer residual network[J]. Electric Power Construction, 2024, 45(8): 118-127.
- [30] 贺才郡, 李开成, 杨王旺, 等. 基于双通道GAF和深度残差网络的电能质量复合扰动识别[J]. 电网技术, 2023, 47(1): 369-379.
- HE Caijun, LI Kaicheng, YANG Wangwang, et al. Power quality compound disturbance identification based on dual channel GAF and depth residual network[J]. Power System Technology, 2023, 47(1): 369-379.
- [31] MIYAZAKI R, WANG T C, USUDA T S. Simplification of the gram matrix eigenvalue problem for quadrature amplitude modulation signals[J]. Entropy, 2022, 24(4): 544-562.
- [32] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA. IEEE, 2016: 770-778.