

DOI: 10.13382/j.jemi.B2407274

基于图像融合和双通道卷积神经网络的 配电网故障选线方法研究*

苏斌¹ 侯思祖¹ 郭威²

(1. 华北电力大学电气与电子工程学院 保定 071003; 2. 北方工业大学电气与控制工程学院 北京 100144)

摘要:针对传统的配电网故障选线方法受限于单一的故障诊断模型,提出一种基于图像融合和双通道卷积神经网络的配电网故障选线方法。研究目的是解决现有方法在面对高阻接地、噪声干扰、分布式电源接地、采样时间不同步等复杂工况时的准确性问题。首先,利用格拉姆角和场和格拉姆角差场将零序电流信号转成易于区分故障的二维图像,为图像处理提供了基础。其次,通过图像融合技术将 GASF 图像和 GADF 图像进行空间域图像融合,得到一张综合特征图像,充分利用了不同图像的特征,提高了特征表达的丰富性和有效性。接着,构建双通道卷积神经网络模型,其中一维卷积神经网络和 ResNet50 网络分别用于挖掘零序电流信号和格拉姆角场图像的特征。这种设计充分发挥了不同卷积神经网络在处理一维信号和二维图像时的优势。最后,将融合后的特征输入到 Sigmoid 函数实现故障线路的筛选。实验结果表明,该方法在各种复杂工况下的表现均优于传统方法,其准确率、Kappa 系数、马修斯相关系数、召回率分别达到了 99.97%、0.999 3、0.999 3、0.999 5。这些结果表明,该方法不仅具有较高的准确性,还具有良好的鲁棒性和稳定性,能够有效应对高阻接地、噪声干扰、分布式电源接地和采样时间不同步等实际应用中的挑战。提出的方法为配电网故障选线提供了一种新颖且高效的解决方案,具有重要的实际应用价值和广泛的推广前景。

关键词: 格拉姆角场;故障选线;图像融合;双通道卷积神经网络

中图分类号: TM726;TN011 **文献标识码:** A **国家标准学科分类代码:** 470.40

Research on distribution network fault line selection method based on image fusion and dual-channel convolutional neural network

Su Bin¹ Hou Sizu¹ Guo Wei²

(1. School of Electrical and Electronic Engineering, North China Electric Power University, Baoding 071003, China;

2. School of Electrical and Control Engineering, North China University of Technology, Beijing 100144, China)

Abstract: To address the limitations of traditional distribution network fault location methods, which rely on a single fault diagnosis model, a new fault location method for distribution networks based on image fusion and dual-channel convolutional neural networks is proposed. The aim of this study is to improve the accuracy of existing methods under complex conditions such as high-resistance grounding, noise interference, distributed power supply grounding, and unsynchronized sampling times. First, the zero-sequence current signals are converted into two-dimensional images using Gramian angular summation field (GASF) and Gramian angular difference field (GADF) techniques, providing a basis for image processing. Next, image fusion technology is employed to spatially fuse the GASF and GADF images, resulting in a comprehensive feature image that fully leverages the characteristics of different images, thereby enhancing the richness and effectiveness of feature representation. Subsequently, a dual-channel convolutional neural network model is constructed, where a one-dimensional convolutional neural network and a ResNet50 network are used to extract features from zero-sequence current signals and Gramian angular field images, respectively. This design takes full advantage of the strengths of different convolutional neural networks in processing one-dimensional signals and two-dimensional images. Finally, the fused features are input into a Sigmoid function to achieve fault line selection. Experimental results show that this method outperforms traditional methods under various complex conditions, with an accuracy rate, Kappa coefficient, Matthews correlation coefficient, and recall rate of 99.97%, 0.999 3, 0.999 3, 0.999 5.

收稿日期:2024-02-16 Received Date: 2024-02-16

* 基金项目:国家自然科学基金(623702210)项目资助

and 0.999 5, respectively. These results indicate that the proposed method not only has high accuracy but also exhibits good robustness and stability, effectively addressing challenges such as high-resistance grounding, noise interference, distributed power supply grounding, and unsynchronized sampling times in practical applications. The proposed method provides a novel and efficient solution for fault location in distribution networks, with significant practical application value and broad prospects for promotion.

Keywords: Gramian angular field; fault line selection; image fusion; dual-channel convolutional neural network

0 引言

在现代电力系统中,配电网的可靠性和稳定性是维护电力供应安全的关键^[1]。随着分布式发电资源(如太阳能、风能)的广泛接入,配电网的结构变得越来越复杂,故障检测与选线技术的重要性随之显著增加^[2]。传统的配电网故障选线方法主要基于电气量的测量,如电流、电压和它们的相位关系实现故障选线^[3]。传统方法简单有效,易于实施^[4],但在复杂或变化的网络条件下,如分布式发电广泛接入时,它们可能无法准确判定故障,或对故障的响应速度不够快,这限制了它们在现代电网中的应用效果^[5]。因此,随着电力系统的发展和技术的进步,对更高效、更智能的故障选线方法的需求日益增长^[6]。

在谐振接地系统中,有功方向法^[7]和行波法^[8]常用故障选线,但在处理高阻抗故障时,这两种方法都有其局限性。文献[9]通过变分模态分解法(variational mode decomposition, VMD)获取零序电流信号的工频分量,并利用工频分量的多尺度模糊熵均值作为选线判据,但是利用VMD分析信号时需要预先确定分解层数,若分解层数设置不恰当,将影响故障选线的准确性。文献[10]通过有源消弧装置向配网系统中注入特定频率信号实现故障选线,但是注入信号法需要额外的装置,价格昂贵,且容易影响配网的安全。文献[11-13]利用小电阻投入前后的故障特征量进行故障选线,在一定程度上提高了算法的耐高阻能力,但是对互感器的精度有较高的要求,且采样时间不同步时,故障诊断的准确率下降。文献[14]利用快速傅里叶变换提取信号特定的频率成分作为多层感知器模型的输入,通过推断衰减模式估计故障的位置,但是频谱泄露问题影响故障位置的判断。部分学者将极限学习机^[15]、BP神经网络^[16]、长短时记忆网络^[17]等机器学习算法引入到了配电网故障选线中,但是这些方法的准确度取决于特征向量的选择,依赖专家经验知识。文献[18]利用对称希尔伯特变换将零序电流信号转成雪花图,但是在系统发生高阻故障时,特征图变换不明显,影响故障选线的准确性。文献[19]利用排列上优化变分模态分解将零序电流信号转成二维图像,转化过程较为复杂,需要耗费大量的时间。文献[20-22]仅是挖掘特征图的特征,却忽略了零序电流信号本身的特征,会影

响故障选线的准确率。

针对以上问题,本文从数据挖掘和特征融合的角度出发,提出了一种基于图像融合和双通道卷积神经网络的配电网故障选线方法。该方法无需专家经验知识,可以同时挖掘零序电流信号的时序特征和信号转特征图的空间域特征。通过仿真、实测数据以及与主流方法的对比,建立了评价指标,验证了所提算法的优势。

1 零序电流信号的空间域特征表达方法

1.1 单相接地故障特征

当配电网发生单相接地故障时,系统的三相平衡被破坏,从而产生零序电流。在中性点不接地和中性点通过消弧线圈接地的系统中,零序电流的分布情况如图1所示。根据图1中显示,故障线路的零序电流与正常线路的零序电流在幅值和极性上有明显差异。具体而言,故障线路的零序电流等于所有正常线路零序电流的总和,且两者的极性相反。因此,通过比较零序电流信号的差异,可以实现故障线路的识别。

然而,实际应用中,由于故障条件的多变性和噪声的干扰,故障线路和正常线路的相位不一定严格相反,幅值规律也可能发生变化。为了确保在各种复杂条件下仍能准确诊断故障,需要提出一种更为鲁棒的故障诊断方法。这种方法不仅要考虑不同的工作条件,还需具备良好的抗干扰能力,以便在复杂环境中稳定运行,从而提高配电网的可靠性和安全性。

1.2 格拉姆角场变换

格拉姆角场(Gramian angular field, GAF)是一种时间序列数据的转换和表示方法^[23]。GAF通过将一维时间序列数据转换成二维图像来增加数据的维度和复杂性。这种转换使得时间序列数据可以利用丰富的图像处理技术进行分析。尽管GAF转换了数据的表示形式,它仍然保持了时间序列的基本特性,包括趋势和周期性。GAF提供了一种直观的方式来可视化时间序列数据,这有助于更好地理解数据的内在结构和关系。因此,本文利用GAF将零序电流信号转成空间域图像的形式。给定一个零序电流信号 $X = \{x_1, x_2, x_3, \dots, x_n\}$,将时间序列 X 归一化至 $[-1, 1]$ 之间表示为:

$$\tilde{x}_i = \frac{(x_i - \max(X)) + (x_i - \min(X))}{\max(X) - \min(X)} \quad (1)$$

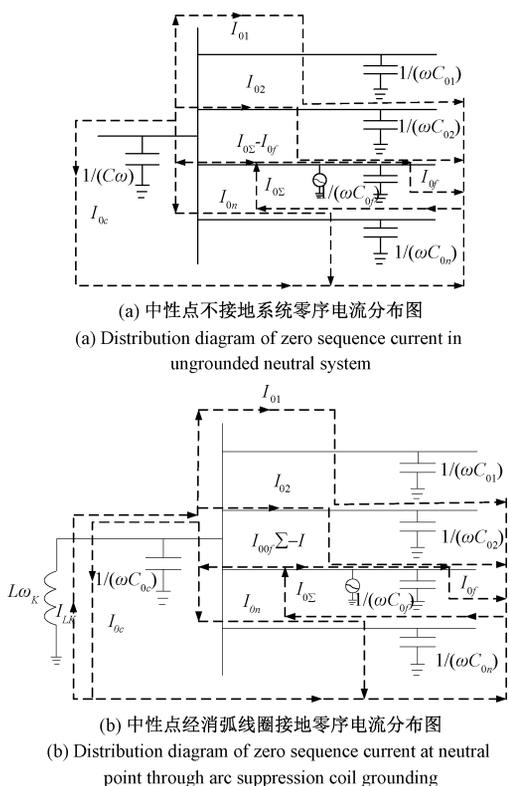


图 1 零序电流分布情况

Fig. 1 Distribution of zero sequence current

通过应用式(1),将标准化的零序电流信号从笛卡尔坐标系转换到极坐标系中,其中时间序列的幅值转换为极坐标角度的反余弦值,而对应的时间戳则作为极坐标的半径,如式(2)所示。

$$\begin{cases} \theta_i = \arccos(\tilde{x}_i), & -1 \leq \tilde{x}_i \leq 1, \tilde{x}_i \in \tilde{X} \\ r_i = t_i/n \end{cases} \quad (2)$$

式中:在极坐标表示中, θ_i 代表角度, r_i 代表半径, t_i 表示相应的采样时间点。通过 GAF 转换,可以分析不同时间点的角度来挖掘序列内部时刻之间的相关性。在这种转换中,格拉姆角场通过运用正弦和余弦函数的数学属性来生成两种类型的图像^[24]。具体而言,利用余弦函数定义的式(3)构建了格拉姆角和场(Gramian angular summation field, GASF),而利用正弦函数定义的式(4)创建了格拉姆角差场(Gramian angular difference field, GADF),为零序电流数据的进一步分析和理解提供了一种有效的方法。

$$\text{GASF} = \begin{pmatrix} \cos(\theta_1 + \theta_2) & \cdots & \cos(\theta_1 + \theta_n) \\ \vdots & \ddots & \vdots \\ \cos(\theta_n + \theta_1) & \cdots & \cos(\theta_n + \theta_n) \end{pmatrix} \quad (3)$$

$$\text{GASF} = \tilde{X}^T \cdot \tilde{X} - \sqrt{\mathbf{I} - \tilde{X}^2} \cdot \sqrt{\mathbf{I} - \tilde{X}^2}$$

$$\text{GADF} = \begin{pmatrix} \sin(\theta_1 - \theta_2) & \cdots & \sin(\theta_1 - \theta_n) \\ \vdots & \ddots & \vdots \\ \sin(\theta_n - \theta_1) & \cdots & \sin(\theta_n - \theta_n) \end{pmatrix} \quad (4)$$

$$\text{GADF} = \sqrt{\mathbf{I} - \tilde{X}^2}^T \cdot \tilde{X} - \tilde{X}^T \cdot \sqrt{\mathbf{I} - \tilde{X}^2}$$

式中: \mathbf{I} 表示单位行向量。本章定义内积 $\langle x, y \rangle = x \cdot y - \sqrt{1 - x^2} \cdot \sqrt{1 - y^2}$ 和 $\langle x, y \rangle = \sqrt{1 - x^2} \cdot y - x \cdot \sqrt{1 - y^2}$, 则格拉姆矩阵 \mathbf{G} 可以表示为:

$$\mathbf{G} =$$

$$\begin{pmatrix} \langle \tilde{x}_1, \tilde{x}_1 \rangle & \langle \tilde{x}_1, \tilde{x}_2 \rangle & \cdots & \langle \tilde{x}_1, \tilde{x}_n \rangle \\ \langle \tilde{x}_2, \tilde{x}_1 \rangle & \langle \tilde{x}_2, \tilde{x}_2 \rangle & \cdots & \langle \tilde{x}_2, \tilde{x}_n \rangle \\ \vdots & \vdots & \ddots & \vdots \\ \langle \tilde{x}_n, \tilde{x}_1 \rangle & \langle \tilde{x}_n, \tilde{x}_2 \rangle & \cdots & \langle \tilde{x}_n, \tilde{x}_n \rangle \end{pmatrix} \quad (5)$$

在 GAF 方法中,矩阵的主对角线元素能够捕捉原始时间序列的特征,而非对角线上位于第 i 行和第 j 列的元素揭示了时间序列中第 i 个时刻和第 j 个时刻之间的关联。以正弦信号为例,GASF 和 GADF 的转换流程如图 2 所示。

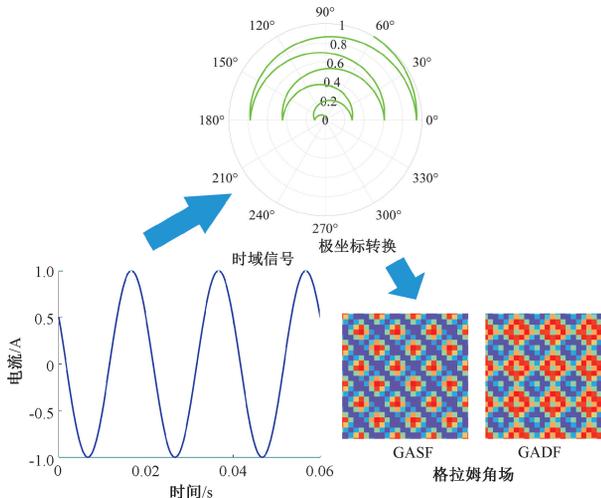


图 2 零序电流的 GAF 变换

Fig. 2 Transformation of zero sequence current using GAF

1.3 GASF 和 GADF 图像融合

将 GASF 和 GADF 作为独立输入让网络自行学习融合策略会增加模型的复杂度和训练成本。因此本文选择加权平均法进行图像融合提高算法的简单性和计算效率。图 3 展示了 GASF 与 GADF 矩阵的密度直方图。通过对图 3 的观察,可以看出 GASF 和 GADF 的密度直方图在分布特性上存在显著差异。具体来说,GASF 的密度直方图的密度值较 GADF 的更为分散。在 GASF 中,大

部分元素集中于-1附近,而 GADF 的元素分布则呈现出更均匀的特点。此外,GASF的对角线附近数据展现出明显的对称性,与之相对,GADF的对角线上的值为0,两侧数据表现为镜像分布。

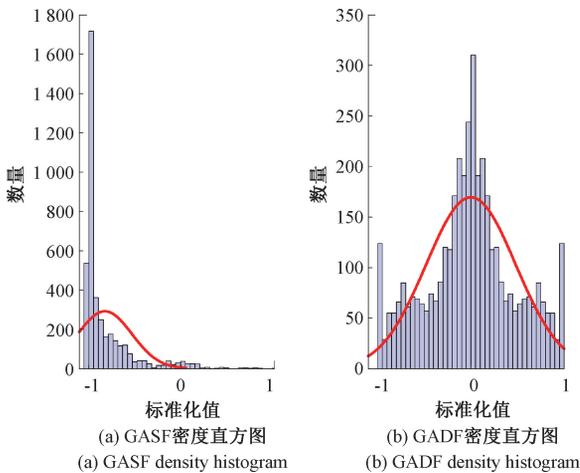


图3 GASF和GADF密度直方图

Fig. 3 The density histograms of the GASF and GADF

鉴于此,为了更高效地利用这些图像特征,在图像处理中采用加权平均方法对 GASF 和 GADF 形成的图像进行融合,该融合过程在图4中进行了详细展示,融合后的图像含有丰富的点线面及纹理特征等信息。

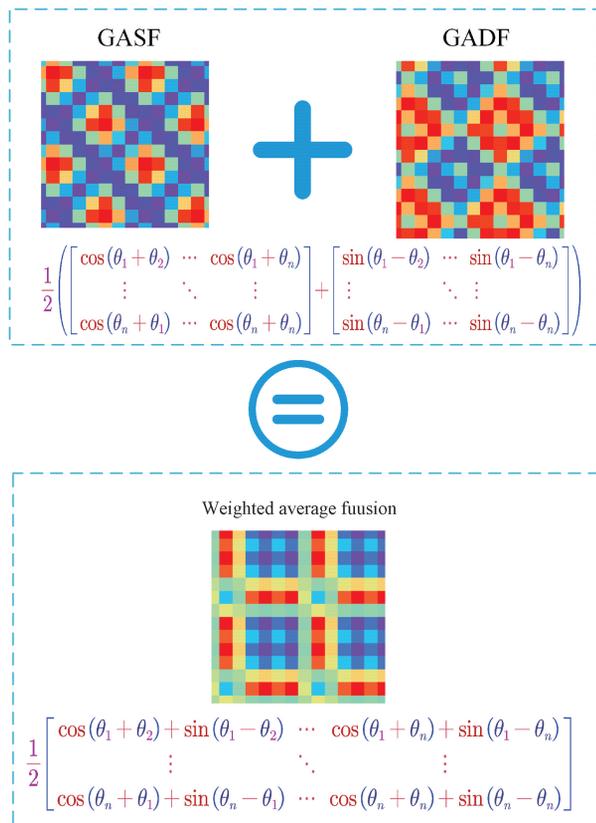


图4 GASF矩阵和GADF矩阵融合过程

Fig. 4 The density histograms of the GASF and GADF

2 基于双通道卷积神经网络的选线方法

2.1 一维卷积神经网络模型

卷积神经网络(convolutional neural network, CNN)是一种高效的图像处理架构,在计算机视觉领域扮演着至关重要的角色^[25]。这种网络通常包含几个关键层次:输入层负责接收图像数据;卷积层通过滤波器提取特征;池化层用于降低特征维度并减少计算量;全连接层将特征映射到输出空间;最后的输出层则用于生成最终的分类或预测结果。CNN及其变体因其在图像识别、分类和处理方面的高效性能而广泛应用。一维卷积神经网络(1D-CNN)是深度学习中的一种特殊类型,主要用于处理序列数据,如时间序列、信号数据或文本。在一维卷积网络中,卷积层通过在输入数据上滑动小窗口(卷积核)来工作。这些窗口捕捉序列中的重要特征,并将这些特征传递到网络的下一层。这种方法特别适用于时间序列数据,因为它可以识别随时间变化的模式和趋势。此外,1D-CNN通常池化层降低特征的维度并减少计算量。通过这种方式,网络能够聚焦于最重要的信息,提高处理效率和效果。因此,本文在处理一维零序电流信号时,通过1D-CNN实现故障有效信息的提取及非线性零序电流数

据的处理。

2.2 残差网络原理

残差网络(residual network, ResNet)是一种深度神经网络架构^[26],它通过引入“残差连接”(或跳跃连接)来解决深层网络训练中的退化问题。在传统的深层网络中,随着层数的增加,网络越来越难以训练,这主要是由于梯度消失或梯度爆炸问题导致的。残差网络通过在网络中添加直接连接前后层的短路连接来解决这一问题。残差块结构如图5所示。

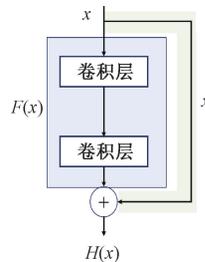


图5 残差块结构

Fig. 5 Structure diagram of residual block

其中, x 、 $H(x)$ 、 $F(x)$ 分别代表输入、输出、残差。每个残差块包含两个主要路径:一条是普通的卷积层序列,

另一条是跳跃连接,它直接将输入传递到块的末端。这种设计使得网络可以学习输入和输出之间的残差映射,而不是直接学习一个完整的映射。从本质上讲,网络在学习输入和输出之间的差异,而不是直接对其进行建模。这种残差学习框架有助于优化过程,允许神经网络更深,同时保持易于训练的特性。

2.3 双通道卷积神经网络的总体框架

零序电流信号受噪声、分布式电源及线路参数不平衡等多重因素干扰,与故障选线结果间呈现出高度的非线性关系,这就导致精确物理模型的构建面临挑战。因此,本文提出了一种基于双通道卷积神经网络的创新方

法,旨在自动提取一维零序电流信号和 Gramian 角域场图像的特征,通过数据驱动的方式实现更为精准的故障选线。本研究在开发平台上进行了系统性实验,使用的操作系统为 Windows 10 64 位,硬件配置包括酷睿 14 代 i7、16 GB 内存和 NVIDIA GeForce RTX4060 显卡。这一硬件环境为数据处理和模型训练提供了强大的计算能力,确保了实验的高效性和可靠性。基于图像融合和双通道卷积神经网络的配电网故障选线方法的具体实现流程如图 6 所示,主要包括以下几个处理步骤:

1) 信号采集模块

为了验证所提方法的有效性,本文搭建了一个配电

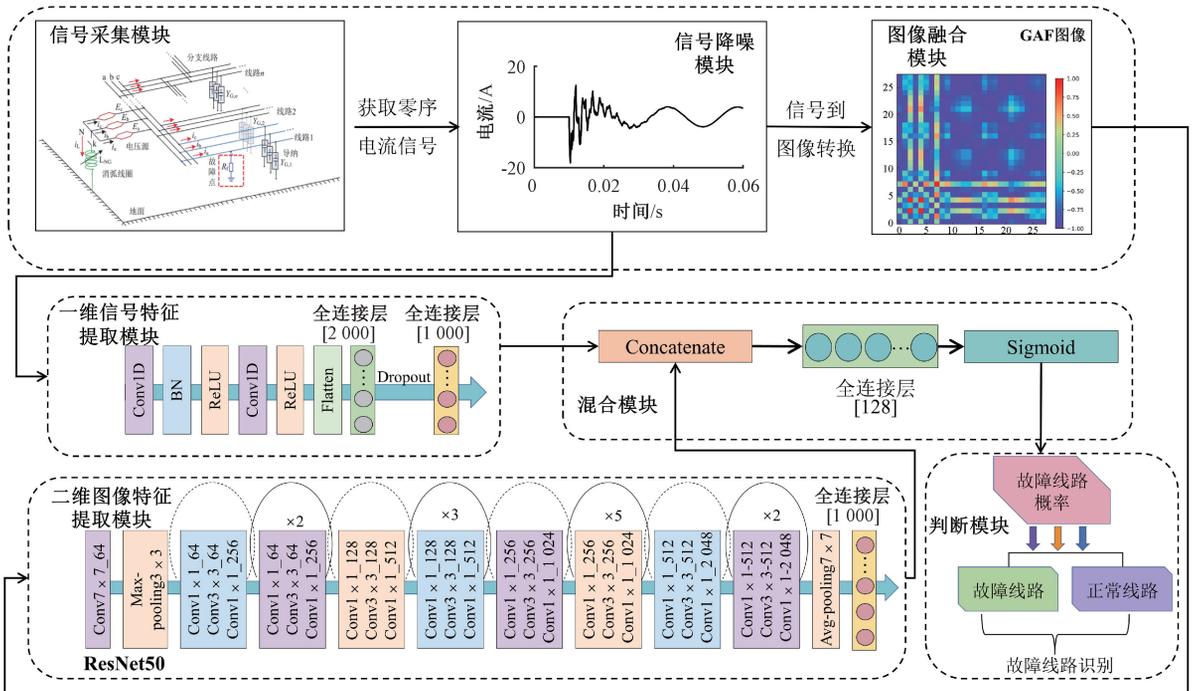


图 6 基于图像融合和双通道卷积神经网络的框架

Fig. 6 The density histograms of the GASF and GADF

网仿真模型。该模型能够模拟不同的故障类型、故障电阻、故障距离和故障初始时间,以全面评估方法的适应性和鲁棒性。在仿真过程中,特别考虑了噪声干扰、采样时间不同步等现实因素对故障诊断的影响。通过设置单相接地故障、相间短路故障等多种故障类型,调整不同的故障电阻值、故障发生距离以及故障初始时间,确保仿真数据的多样性和覆盖面。在仿真过程中加入噪声干扰,模拟真实配电网环境中的电磁干扰和设备噪声等因素,以评估方法在噪声环境下的鲁棒性。使用零序电流互感器采集各个线路的零序电流,采样频率为 10 kHz,选取故障前一个周期和故障后两个周期的信号作为待分析样本,从而全面捕捉故障发生前后的动态特征,确保数据的准确性和完整性。通过这样的仿真设置,可以全面检验所

提方法在各种复杂情况下的性能,确保其在实际应用中的有效性和可靠性。

2) 信号降噪模块

采用文献[27]提出的优良降噪平滑模型对零序电流信号。首先,利用互补集合经验模态分解(complementary ensemble empirical mode decomposition, CEEMD)技术对零序电流信号进行分解,从中提取出多个内禀模态函数。然后,构建一个目标函数,该函数结合了相似度与光滑度的关系,以筛选出最优的内禀模态函数,从而实现零序电流信号的降噪处理。该模型通过调控相似度与平滑度这两个关键参数,实现了比传统方法如小波阈值去噪和均值去噪更为显著的降噪效果。它巧妙避开了传统方法可能带来的信息损失或过度平滑的

问题,从而在保证信号真实性的同时,有效剔除了噪声干扰。

3) 图像融合模块

对降噪后的零序电流信号进行 GAF 转换,分别得到 GASF 和 GADF 两张特征图。这两种特征图能够有效地表示零序电流信号在时间序列上的变化和模式,从而捕捉到更丰富的故障信息。接着,通过加权平均方法对 GASF 和 GADF 特征图进行空间域图像融合处理,以综合两种图像的特征,提升特征图的表达能力。融合后的图像具有更全面的特征表示,能够更好地反映零序电流信号的特性。将融合后的图像作为深度学习模型待分析的样本,输入到双通道卷积神经网络中进行训练和测试,从而实现故障线路的精准识别和分类。通过这种方式,利用深度学习强大的特征提取和分类能力,有效提高故障选线的准确性和鲁棒性,确保在各种复杂环境下均能实现可靠的故障诊断。

4) 一维信号特征提取模块

尽管 Transformer 在捕捉全局依赖关系方面有优势,但其计算复杂度和资源消耗较高。相比之下,一维卷积神经网络在效率与性能之间找到了更佳的平衡点,能够在有限的计算资源下,体现出高效性和实用性。因此,本文采用一维卷积神经网络自主提取零序电流信号的特征。首先,使用两种尺寸各异的卷积核(分别是 32 个 5×1 与 64 个 3×1 的 Conv1D 层)来从信号中抽取特征。随后,引入批量归一化层(BN),旨在加速网络训练进程,同时防范梯度问题与过拟合现象。此外,网络集成 ReLU 激活层,旨在增强网络稀疏性与非线性,并间接助力抗过拟合。网络架构还包含展平层(Flatten)与两个全连接层,分别含有 2 000 个和 1 000 个神经元,以促进深层特征学习。最终,采用 Dropout 策略,通过随机丢弃神经元的方式,有效缩减模型复杂度,提升泛化能力。此设计策略旨在提高网络的效率和准确性,特别适用于一维信号处理任务。

5) 二维图像特征提取模块

借助 GASF、GADF 及图像融合技术,一维零序电流信号的时间序列关系被巧妙地转化为图像中的空间布局,极大地促进了模式识别与特征提取的直观性。随着深度学习模型深度递增,可能遭遇梯度不稳定及网络性能衰退等难题,这些均潜在地影响诊断效能。为此,引入如 ResNet50 等含残差连接的架构,不仅能够缓解上述问题,还显著增强了模型在深层图像特征挖掘方面的能力。本文选用 ResNet50 提取融合后的 GAF 图像特征,具体参数配置如表 1 所示。为了公平学习一维模块和二维模块特征,将 ResNet50 最后一层全连接层神经元个数设置为 1 000。

表 1 二维卷积神经网络各层参数配置

Table 1 Parameter configuration of each layer of 2D-convolutional neural network

网络层名	特征图大小	卷积核大小	步长
输入层	$32 \times 227 \times 227$	-	-
Conv1	$16 \times 227 \times 227$	$1 \times 227 \times 227, 64$	$1 \times 2 \times 2$
最大池化层	$8 \times 56 \times 56$	$3 \times 3 \times 3$	$1 \times 2 \times 2$
Conv2_x	$8 \times 56 \times 56$	$\begin{bmatrix} 3 \times 3 \times 3, 64 \\ 1 \times 3 \times 3, 64 \\ 1 \times 1 \times 1, 256 \end{bmatrix} \times 3$	$1 \times 1 \times 1$
Conv3_x	$4 \times 28 \times 28$	$\begin{bmatrix} 1 \times 1 \times 1, 128 \\ 1 \times 3 \times 3, 128 \\ 1 \times 1 \times 1, 512 \end{bmatrix} \times 4$	$1 \times 2 \times 2$
Conv4_x	$4 \times 14 \times 14$	$\begin{bmatrix} 1 \times 1 \times 1, 256 \\ 1 \times 3 \times 3, 256 \\ 1 \times 1 \times 1, 1\ 024 \end{bmatrix} \times 6$	$1 \times 2 \times 2$
Conv5_x	$4 \times 7 \times 7$	$\begin{bmatrix} 1 \times 1 \times 1, 512 \\ 1 \times 3 \times 3, 512 \\ 1 \times 1 \times 1, 2\ 048 \end{bmatrix} \times 3$	$1 \times 2 \times 2$
平均池化层	$1 \times 1 \times 1$	$4 \times 7 \times 7$	$1 \times 1 \times 1$
全连接层	$1 \times 1 \times 1$	1 000	$1 \times 1 \times 1$

6) 混合模块、故障线路判断模块

通过 Concatenate 混合模块,将一维信号特征提取与二维图像特征提取模块的输出特征进行有效融合。随后,该融合特征流经一个拥有 128 个神经元的全连接层,最终送入 Sigmoid 函数处理。Sigmoid 函数以其特有的平滑性,输出一个介于 0~1 区间的数值,直观反映了系统对线路故障发生可能性的评估概率,为后续的故障诊断决策提供了明确且量化的参考依据。

2.4 网络的训练过程

本文将一维卷积神经网络和二维卷积神经网络提取到的不同特征进行融合,充分发挥两种网络的优势,网络训练的具体步骤如下:

步骤 1) 初始化双通道卷积神经网络的权重参数;

步骤 2) 将一维零序电流信号通过 GAF 转换为特征图,作为二维卷积神经网络的输入,如图 6 所示。零序电流作为一维卷积神经网络的输入,通过前向传播过程提取信号的关键特征,并基于这些特征进行训练,最终实现对线路故障的有效判断。

步骤 3) 在训练网络的过程中,通过将模型的预测结果与实际数据进行对比,利用 Adam 优化器不断地进行权重调整,目的是为了减少网络的损失函数值。

步骤 4) 这一过程涉及对训练数据集中的所有样本反复执行步骤 2) 和步骤 3),持续进行直到网络的损失函数降至一个可接受的水平。训练完成后,使用独立的测试数据集来评估模型的有效性和准确度,从而验证网络的性能。

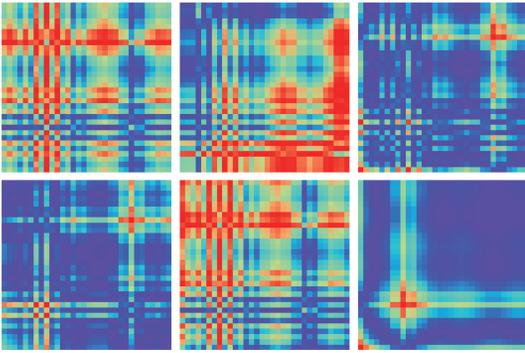


图 7 部分训练图片

Fig. 7 Some training pictures

3 仿真与分析

3.1 混合样本库及评价指标

为了验证选线方法的有效性,建立了辐射配电网、IEEE-34 节点仿真模型,通过两个仿真模型采集样本库。辐射配电网如图 8 所示,包含 5 条线路,线路 1~3 为纯架空线路,线路 4 为架空线-电缆混合线路,线路 5 为纯电缆线路,中性点采用消弧线圈接地方式。

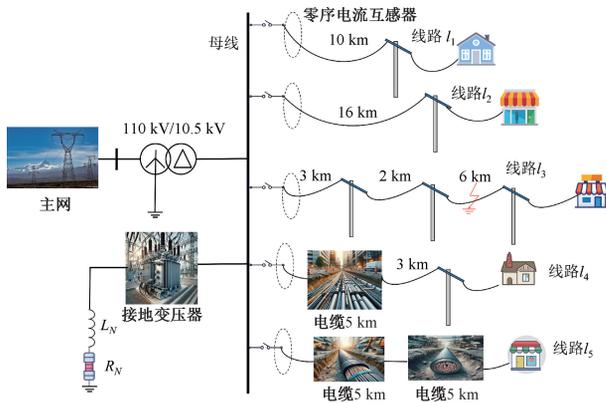


图 8 辐射状配电网

Fig. 8 Model of radial distribution network

单位长度架空线和电缆参数如式(12)和(13)所示。IEEE-34 节点仿真模型如图 9 所示,将整个网络的三相线路分成 5 个部分,将分布式电源接入节点 816、832、846,系统的额定电压设为 24.9 kV,中性点调整为不接地系统。架空线的正序和零序参数为:

$$\begin{cases} R_0 = 0.2850 \Omega/\text{km}, L_0 = 4.5600 \times 10^{-3} \text{ H}/\text{km} \\ C_0 = 0.0054 \times 10^{-6} \text{ F}/\text{km}, R_1 = 0.1250 \Omega/\text{km} \\ L_1 = 1.2500 \times 10^{-3} \text{ H}/\text{km}, C_1 = 0.0096 \times 10^{-6} \text{ F}/\text{km} \end{cases} \quad (6)$$

电缆线路的正序和零序参数为:

$$\begin{cases} R_0 = 2.7500 \Omega/\text{km}, L_0 = 1.1180 \times 10^{-3} \text{ H}/\text{km} \\ C_0 = 0.3390 \times 10^{-6} \text{ F}/\text{km}, R_1 = 0.2780 \Omega/\text{km} \\ L_1 = 0.2650 \times 10^{-3} \text{ H}/\text{km}, C_1 = 0.2800 \times 10^{-6} \text{ F}/\text{km} \end{cases} \quad (7)$$

利用辐射状配电网和 IEEE-34 节点模型采集样本数据,在不同的线路上设置单相接地故障点(AG\BG\CG\间歇性电弧故障),过渡电阻为 0~2000 Ω ,故障初始相角包括 0°、30°、60°、90°、120°、150°。辐射状配电网训练样本数量 6300 个,测试样本 2328 个;IEEE-34 节点仿真模型训练样本数量 1450 个,测试样本 653 个。在训练过程中,打乱样本,并利用准确率(Accuracy)、Kappa 系数(Kappa coefficient, KC)、马修斯相关系数(Matthews correlation coefficient, MCC)、召回率(Recall)对诊断模型进行评价如式(8)~(13)所示。

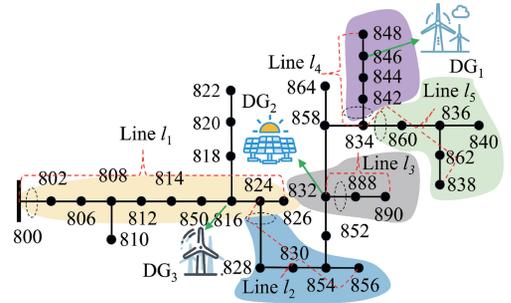


图 9 IEEE-34 节点配网模型

Fig. 9 Model of IEEE-34 distribution network

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad (8)$$

$$Recall = \frac{TP}{TP + FN} \quad (9)$$

$$MCC = \frac{TP \cdot TN - FP \cdot FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}} \quad (10)$$

$$KC = \frac{p_0 - p_e}{1 - p_e} \quad (11)$$

其中,

$$p_0 = \frac{TP + TN}{TP + FP + TN + FN} \quad (12)$$

$$p_e = \frac{(TP + FP) \cdot (TP + FN) + (TN + FP) \cdot (TN + FN)}{(TP + FP + TN + FN)^2} \quad (13)$$

式中:TP 为故障线路被正确判别为故障线路的样本数量;TN 为正常线路被正确判别为正常线路的样本数量;FP 为正常线路被错误判别为故障线路的样本数量;FN 为故障线路被错误判别为正常线路的样本数量。

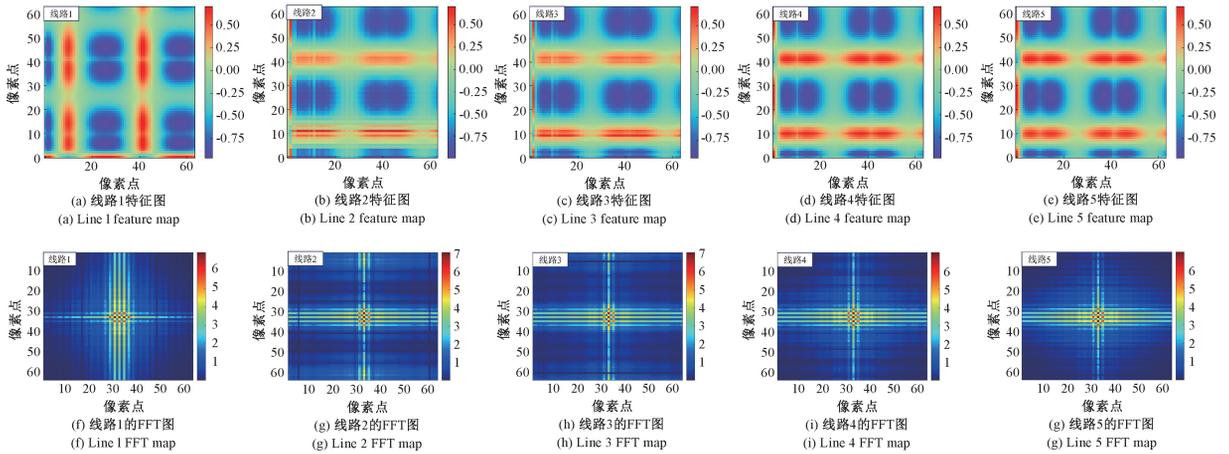


图 10 零序电流信号的 GAF 变换及二维傅里叶变换

Fig. 10 GAF transform and two-dimensional Fourier transform of zero sequence current signal

3.2 样本及模型训练过程分析

假设辐射状配电网线路 1 的 B 相发生 $100\ \Omega$ 单相接地故障,采集各线路的零序电流信号,通过 GASF 和 GADF 将零序电流信号转成特征图,并通过空间域图像融合将 GASF 图像和 GADF 图像融合,并利用二维傅里叶变换对融合后的图像进行分析,所得结果如图 10 所示。从图 10 可以看出,故障线路 1 其他正常线路的 GAF 融合图像明显不同,对图像进行二维傅里叶分析也可以看出,故障线路 1 的图像频谱特征与正常线路图像的频谱特征明显不同,因此通过 GASF 和 GADF 变换融合后的图像,可以作为深度学习的良好素材,结合一维零序电流信号,混合卷积神经网络经过训练后可以很好的区分正常线路和故障线路的特征,实现小电流系统单相接地故障选线。

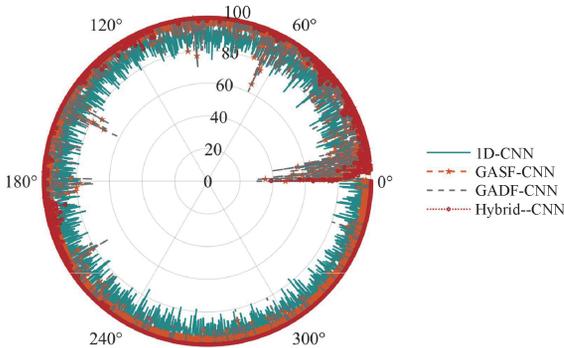


图 11 不同输入方式的训练过程

Fig. 11 Training process with different input methods

比较 4 种输入方式的故障选线模型训练过程,包括仅利用一维卷积神经网络提取零序电流信号的特征(1D-CNN)、仅将 GASF 作为卷积神经网络的输入(GASF-CNN)、仅将 GADF 作为卷积神经网络的输入(GADF-

CNN)、零序电流信号和融合图像作为双通道卷积神经网络的输入(Dual-CNN),所得结果如图 11 所示。从图 11 可以看出,1D-CNN 方式波动较为严重,整个网络没有收敛;GASF-CNN 和 GADF-CNN 的训练效果优于 1D-CNN,但是网络也有轻微波动,并且 GASF-CNN 的准确率没有达到 100%;相比其他 3 种输入方式,本文方法在训练 1 803 次以后可以稳定达到 100%,网络训练较为稳定且收敛速度快,优于其他方法。

3.3 模型验证结果分析

模型训练好以后,对测试样本进行分析,其中故障样本包括 1 452 个,正常样本包括 1 529 个,评价指标采用式(8)~(13),所得结果如图 12 所示。

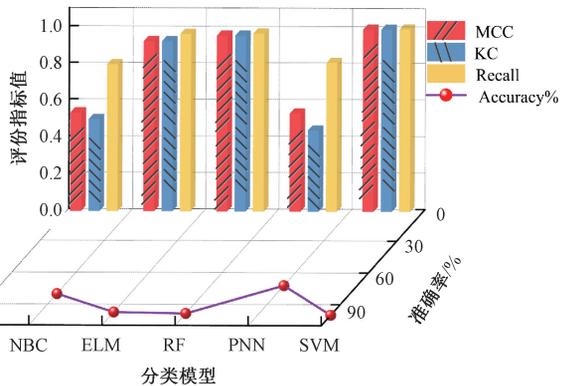


图 12 不同故障诊断模型的评价指标

Fig. 12 Evaluation index of different diagnosis models

从图 12 可以看出,若直接将零序电流信号作为支持向量机(support vector machine, SVM)的输入准确率最低,其次是仅利用一维卷积神经网络。GADF+CNN 的准确率可以达到 96.04%,其他指标也优于 GASF+CNN。本文提出的方法准确率、Kappa 系数、马修斯相关系数、召

回率分别为 99.97%、0.999 3、0.999 3、0.999 5,效果最佳,这是因为本文方法可以充分挖掘零序电流信号和特征图的特征,故障诊断效果优于单一故障诊断模型。

3.4 分类结果可视化

采用流行的 t-SNE (t-distributed stochastic neighbor embedding) 技术对双通道故障诊断模型进行特征可视化,得到的结果如图 13 所示。该技术通过将高维特征映射到二维空间,以便直观地观察数据点的分布情况,其中使用不同颜色区分故障线路和非故障线路。从图 13 可以看出,输入层的特征点分布混杂,正常线路的特征与故障线路的特征难以明确区分。然而,经过双通道卷积神经网络的训练,特别是在混合模块的全连接层输出的特征中,正常线路的特征和故障线路的特征分别显著聚集在一起。这种明显的聚类现象表明,经过网络训练后,特征的辨识度显著提高,展示了本文方法在故障特征提取和分类识别方面的有效性。通过这种可视化分析,能够直观地评估模型的表现,并验证其在实际应用中的可靠性和准确性。

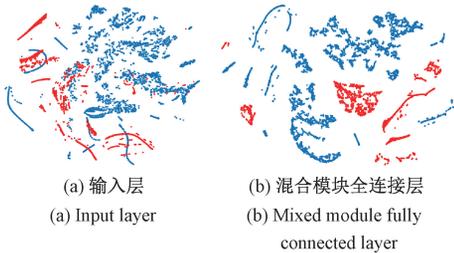


图 13 双通道卷积神经网络特征可视化结果
Fig. 13 Visualization results of dual-channel convolutional neural network feature

3.5 不同选线方法抗噪性测试

对比文献[1]和文献[21]提出的故障选线方法。其中文献[1]通过 D-S 论据理论将零序电流的能量、峰值和极性特征进行融合,将数值最大的线路判断为故障线路。文献[21]通过自适应噪声完备经验模态分解 (complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN) 将零序电流转成特征图,通过 GoogLeNet 网络进行图像辨识实现故障选线。采集 1 625 组高阻故障 (过渡电阻为 1 000~2 000 Ω),并在零序电流上叠加不同信噪比的噪声,所得结果如图 14 所示。从图 14 可以看出,基于 GoogLeNet 图像识别算法的性能优于仅从零序电流信号挖掘特征的方法,这是因为仅从零序电流信号挖掘特征存在故障信息丢失,难以满足各种故障工况。但是随着噪声强度的增加,基于 GoogLeNet 图像识别算法的准确率下降严重,这是因为在强噪声背景下,故障线路与正常线路的时频特征发生了改变。而本文方法建立了双通道网络,不但可以挖掘特征图特征,

还以充分挖掘零序电流信号本身的时序特征,因此在噪声干扰和高阻接地的情况下,依然可以保证较高的故障选线准确率。

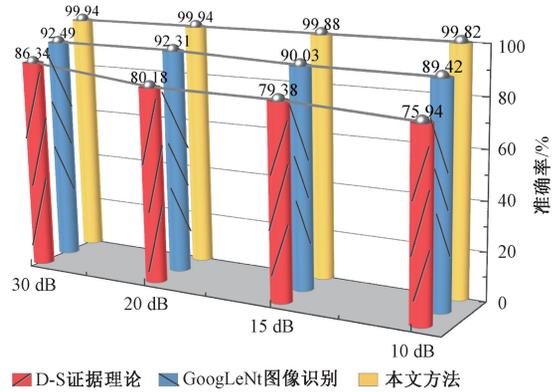


图 14 不同选线方法抗噪测试

Fig. 14 Different line selection methods for noise resistance testing

3.6 采样时间不同步测试

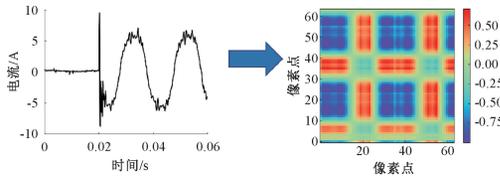
在现场实际工况下,存在各线路采样时间不同步的问题,以 IEEE-34 节点配网模型为例,对比极性选线法[5]、图像辨识选线法[20]、幅值选线法[28],所得结果如表 2 所示。文献[5]利用 Duffing 振子比较零序电流信号的极性实现故障选线,文献[28]通过改进锁相环锁定 5 次谐波幅值判断故障线路。当采样时间不同步时,会影响这两种方法选线的准确性。图像辨识方法相比传统的方法,有一定的抗采样时间不同步的能力,但是当采样时间进一步加大时,会影响特征图的比较。本文方法通过双通道卷积神经网络充分挖掘了零序电流信号和特征图的特征,具有较好抗采样时间不同步的能力。

表 2 采样时间不同步条件下故障诊断结果
Table 2 Fault diagnosis results under asynchronous sampling time conditions

采样时间不同步情况	故障线路	故障情况	选线方法	诊断结果
线路 1 零序电流信号滞后 1 ms	线路 2 (1.2 km)	0°, 100 Ω	极性选线法	×
			幅值选线法	×
			图像辨识法	√
			本文方法	√
线路 2 零序电流信号滞后 2 ms	线路 3 (2.8 km)	30°, 1 000 Ω	极性选线法	×
			幅值选线法	×
			图像辨识法	√
			本文方法	√
线路 3 零序电流信号滞后 4 ms	线路 5 (4.1 km)	90°, 2 000 Ω	极性选线法	×
			幅值选线法	×
			图像辨识法	×
			本文方法	√

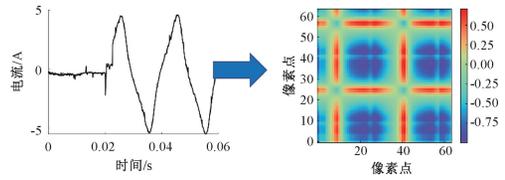
3.7 实测数据验证

为验证所提出的方法,选取了某变电所的配网故障数据进行测试。该电网的电压等级为 10 kV,包含 4 条不同类型的线路。在测试过程中,线路 1 的 B 相发生了单



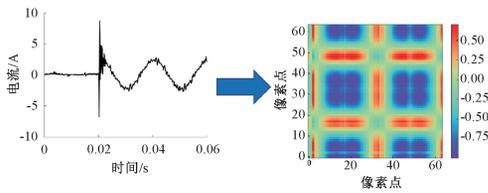
(a) 线路1零序电流和GAF图像

(a) Line 1 zero-sequence current and GAF image



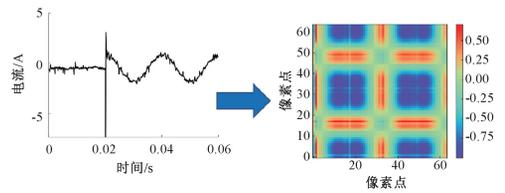
(b) 线路2零序电流和GAF图像

(b) Line 2 zero-sequence current and GAF image



(c) 线路3零序电流和GAF图像

(c) Line 13 zero-sequence current and GAF image



(d) 线路4零序电流和GAF图像

(d) Line 13 zero-sequence current and GAF image

图 15 不同线路的零序电流和 GAF 图像

Fig. 15 Zero sequence current and GAF images of different lines

通过这些数据,能够涵盖不同线路类型在故障发生时的电流特征以及对应的 GAF 图像,以全面评估方法在各种实际故障场景中的表现。对比各线路的零序电流信号和 GAF 特征图,有助于深入分析模型在不同线路和故障条件下的有效性和可靠性。从图 15 可以看出,单独依靠零序电流信号难以准确识别故障线路,因为不同线路的零序电流信号相似,难以区分。然而,通过对特征图的分析,可以明显观察到正常线路与故障线路之间的显著差异,这些差异在 Gramian 角域场图像中得到了充分体现。结合双通道卷积神经网络进行进一步分析,能够准确地从这些特征图中识别出故障线路。这表明,尽管零序电流信号本身存在一定的难度,但通过本文所提出的方法,在实际配电网的单相接地故障中依然能够有效地进行故障线路的选择和识别。该方法的成功应用验证了其在复杂实际场景中的适用性和准确性,展示了其在配电网故障诊断中的潜力。

4 结论

本文提出了一种基于图像融合和双通道卷积神经网络的配电网故障选线方法,利用辐射配电网、IEEE-34 节点仿真模型及实测数据进行验证。研究的核心思路在于通过 GASF 和 GADF 将零序电流信号转化为具有点线面及纹理特征的二维图像,并通过空间域图像融合方法充分利用这些图像的特征。采用的核心技术包括一维卷积

相接接地故障。采集了 4 条线路的零序电流信号,并对这些信号进行了 Gramian 角域场特征图的处理,结果如图 15 所示。

神经网络和 ResNet50 网络,用于挖掘零序电流信号的时序特征和信号转特征图的空间域特征。这一双通道卷积神经网络模型克服了传统配电网故障选线方法受限于单一故障诊断模型的不足,实现了更高的故障诊断准确性和鲁棒性。研究的难点在于如何在高阻接地、噪声干扰、分布式电源接地、采样时间不同步等复杂工况下,仍能保持高准确率和稳定性。实验结果表明,本文方法在各种复杂工况下表现优异,其准确率、Kappa 系数、马修斯相关系数、召回率均显著高于传统方法,证明了其在实际应用中的先进性和必要性。未来的研究将致力于进一步优化模型结构,提高计算效率,探索更多种类的信号特征和图像处理方法,以应对更加多样化的实际应用场景,进一步提升配电网故障选线的智能化和精确度。

参考文献

- [1] WEI X, YANG D, WANG X, et al. Faulty feeder detection based on fundamental component shift and multiple-transient-feature fusion in distribution networks [J]. IEEE Transactions on Smart Grid, 2021, 12(2): 1699-1711.
- [2] 韦明杰, 余越, 梁英, 等. 宽频信号在谐振接地有源配电网高阻故障选线中的应用[J]. 电力系统自动化, 2023, 47(19): 166-176.
- WEI M J, YU Y, LIANG Y, et al. Application of broadband signal in high-resistance fault line selection of resonant grounded active distribution network [J].

- Automation of Electric Power Systems, 2023, 47(19): 166-176.
- [3] 王毅,李曙,李松浓,等. 瞬时特征下极限学习机在接地故障诊断中的应用[J]. 电子测量与仪器学报, 2022, 36(1): 212-219.
WANG Y, LI SH, LI S N, et al. Application of ground fault diagnosis based on extreme learning machine under instantaneous characteristics [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(1): 212-219.
- [4] 袁川来,廖庸邑,孔玲爽,等. 时间约束的改进分层模糊 Petri 网的配电网故障诊断方法[J]. 电子测量与仪器学报, 2020, 34(3): 126-134.
YUAN C L, LIAO Y Y, KONG L S, et al. Improved hierarchical fuzzy Petri net with temporal constraints for distribution network fault diagnosis [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(3): 126-134.
- [5] 侯思祖,郭威. 基于改进 EEMD 与混沌振子的配电网故障选线[J]. 仪器仪表学报, 2019, 40(4): 77-87.
HOU S Z, GUO W. Fault line selection in distribution network based on modified EEMD and chaos oscillator[J]. Chinese Journal of Scientific Instrument, 2019, 40(4): 77-87.
- [6] GANIVADA P K, JENA P. A fault location identification technique for active distribution system [J]. IEEE Transactions on Industrial Informatics, 2022, 18(5): 3000-3010.
- [7] 徐丙垠,薛永端,冯光,等. 配电网接地故障保护若干问题的探讨[J]. 电力系统自动化, 2019, 43(20): 1-7.
XU B Y, XUE Y D, FENG G, et al. Discussion on several problems of earthing fault protection in distribution network [J]. Automation of Electric Power Systems, 2019, 43(20): 1-7.
- [8] 王建元,朱永涛,秦思远. 基于方向行波能量的小电流接地系统故障选线方法[J]. 电工技术学报, 2021, 36(19): 4085-4096.
WANG J Y, ZHU Y T, QIN S Y. Discussion on several problems of earthing fault protection in distribution network [J]. Transactions of China Electrotechnical Society, 2021, 36(19): 4085-4096.
- [9] 陈博帆,孙岩洲,王彬. 基于改进 SSA-VMD 和多尺度模糊熵的接地故障选线方法[J]. 国外电子测量技术, 2023, 42(1): 28-34.
CHEN B F, SUN Y Z, WANG B. Line selection of grounding fault based on improved SSA-VMD and multi-scale fuzzy entropy [J]. Foreign Electronic Measurement Technology, 2023, 42(1): 28-34.
- [10] 王志成,宋国兵,常仲学,等. 配电网单相接地故障时的对地参数实时测量和选线方法[J]. 电网技术, 2023, 47(9): 3762-3772.
WANG ZH CH, SONG G B, CHANG ZH X, et al. Real-time measurement of ground parameters and line selection for single-phase grounding faults of distribution network [J]. Power System Technology, 2023, 47(9): 3762-3772.
- [11] 汤涛,周宇,曾祥君,等. 基于过渡电阻评估的灵活接地系统暂态故障选线方法[J]. 电力系统自动化, 2023, 47(5): 171-179.
TANG T, ZHOU Y, ZENG X J, et al. Transient fault line selection method for flexible grounded system based on transition resistance evaluation [J]. Automation of Electric Power Systems, 2023, 47(5): 171-179.
- [12] 李建蕊,李永丽,王伟康,等. 基于零序电流与电压相位差变化的灵活接地系统故障选线方法[J]. 电网技术, 2021, 45(12): 4847-4855.
LI J R, LI Y L, WANG W K, et al. Fault line detection method for flexible grounding system based on changes of phase difference between zero sequence current and voltage [J]. Power System Technology, 2021, 45(12): 4847-4855.
- [13] 刘朋跃,邵文权,弓启明,等. 利用零序电流相位变化特征的灵活接地系统故障选线方法[J]. 电网技术, 2022, 46(5): 1830-1838.
LIU P Y, SHAO W Q, GONG Q M, et al. Fault line detection of flexible grounding system based on phase variation characteristics of zero-sequence current [J]. Power System Technology, 2022, 46(5): 1830-1838.
- [14] HAMIDI S M, AMELI A, GHAFOURI M, et al. A learning-based framework for locating faults on power grid lines based on distortion of traveling waves [J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 2514115.
- [15] 高文利,席东民,王晗,等. 基于特征融合与 ELM 的小电流接地选线新方法[J]. 电子测量技术, 2023, 46(13): 176-184.
GAO W L, XI D M, WANG H, et al. New method of small current grounding line selection based on feature fusion and extreme learning machine [J]. Electronic Measurement Technology, 2023, 46(13): 176-184.

- [16] 韩祥民, 刘晓波, 刘敏, 等. 基于改进 EEMD 与 GA-BP 的谐振接地故障选线方法[J]. 智慧电力, 2021, 49(12): 80-87.
HAN X M, LIU X B, LIU M, et al. Resonant grounding fault line selection method based on improved EEMD and GA-BP model [J]. Smart Power, 2021, 49(12): 80-87.
- [17] 应花梅, 邓长虹, 刘正谊. 基于多判据融合的 LSTM 单相接地故障选线方法[J]. 武汉大学学报(工学版), 2023, 56(6): 708-716.
YING H M, DENG CH H, LIU ZH Y. LSTM single-phase grounding fault line selection method based on multi-criteria fusion[J]. Engineering Journal of Wuhan University, 2023, 56(6): 708-716.
- [18] 郭威, 史运涛. 基于空间域图像生成和混合卷积神经网络的配电网故障选线方法[J]. 电网技术, 2024, 48(3): 1311-1328.
GUO W, SHI Y T. Fault line selection for distribution network based on spatial domain image generation and hybrid convolutional neural network[J]. Power System Technology, 2024, 48(3): 1311-1328.
- [19] 缪欣, 张忠锐, 郭威, 等. 基于信号图像化和 CNN-ResNet 的配电网单相接地故障选线方法[J]. 中国测试, 2024, 50(6): 157-166.
MIAO X, ZHANG ZH R, GUO W, et al. Single-phase ground fault line selection method for distribution network based on signal imaging and CNN-ResNet [J]. China Measurement & Test, 2024, 50(6): 157-166.
- [20] 郝帅, 张旭, 马瑞泽, 等. 基于改进 GoogLeNet 的小电流接地系统故障选线方法[J]. 电网技术, 2022, 46(1): 361-368.
HAO SH, ZHANG X, MA R Z, et al. Fault line selection method for small current grounding system based on improved GoogLeNet[J]. Power System Technology, 2022, 46(1): 361-368.
- [21] CHENG X, CUI B, HOU S. Fault line selection of distribution network based on modified CEEMDAN and GoogLeNet neural network [J]. IEEE Sensors Journal, 2022, 22(13): 13346-13364.
- [22] 雷静, 李晨婧, 郭亮, 等. 基于 GAF 与卷积神经网络的配电网故障选线新方法[J]. 电力系统及其自动化学报, 2023, 35(2): 53-62.
LEI J, LI CH J, GUO L, et al. Novel fault feeder selection method for distribution network based on GAF and convolution neural network [J]. Proceedings of the CSU-EPSS, 2023, 35(2): 53-62.
- [23] 刘科研, 周方泽, 周晖. 基于时序信号图像编码和生成对抗网络的配电网台区数据修复[J]. 电力系统保护与控制, 2022, 50(24): 129-136.
LIU K Y, ZHOU F Z, ZHOU H. Missing data imputation in a transformer district based on time series imaging encoding and a generative adversarial network [J]. Power System Protection and Control, 2022, 50(24): 129-136.
- [24] BAI Y, YANG J, WANG J, et al. Intelligent diagnosis for railway wheel flat using frequency-domain Gramian angular field and transfer learning network [J]. IEEE Access, 2020, 8: 105118-105126.
- [25] BUKHARI S B A, KIM C H, MEHMOOD K K, et al. Convolutional neural network-based intelligent protection strategy for microgrids [J]. IET Generation, Transmission & Distribution, 2020, 14(7): 1177-1185.
- [26] 周露珊, 赵磊, 李恒, 等. 基于轻量级密集残差网络的水下图像增强[J]. 电子测量与仪器学报, 2023, 37(1): 70-77.
ZHOU L SH, ZHAO L, LI H, et al. Underwater image enhancement based on lightweight dense residual network [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(1): 70-77.
- [27] 孙苗, 吴立, 周玉纯, 等. 水下钻孔爆破地震波信号的最优降噪平滑模型[J]. 华南理工大学学报(自然科学版), 2019, 47(8): 31-37.
SUN M, WU L, ZHOU Y CH, et al. Optimal denoising smooth model of underwater drilling blasting seismic wave signal [J]. Journal of South China University of Technology (Natural Science Edition), 2019, 47(8): 31-37.
- [28] ZHANG Z X, LIU X, PIAO Z L. Fault line detection in neutral point ineffectively grounding power system based on phase-locked loop [J]. IET Generation, Transmission & Distribution, 2014, 8(2): 273-280.

作者简介



苏斌, 2008 年于华北电力大学获得学士学位, 2015 年于华北电力大学获得硕士学位, 现为华北电力大学博士研究生, 主要研究方向为配电网故障诊断。

E-mail: subin1984@126.com

Su Bin received his B. Sc. degree from North China Electric Power University in 2008, the M. Sc. degree from North China Electric Power University in 2015. Currently, he is a doctoral candidate at North China Electric

Power University. His main research interests include fault diagnosis of distribution networks.



侯思祖, 1988 年于北京交通大学获得硕士学位, 现为华北电力大学教授、博士生导师, 主要研究方向为电网故障诊断与状态检测。

E-mail: 1647354604@qq.com

Hou Sizhu received his M. Sc. degree from Beijing Jiaotong University in 1988. Now he is a professor and Ph. D supervisor in North China Electric Power University. His main research interests include power grid fault diagnosis and machine condition monitoring.



郭威(通信作者), 2017 年于东北电力大学获得硕士学位, 2019 年于华北电力大学获得博士学位, 现为北方工业大学讲师, 主要研究方向为神经网络、故障诊断。

E-mail: xiaoshenghameng@163.com

Guo Wei (Corresponding author) received his M. Sc. degree from Northeast Electric Power University in 2017, the Ph. D. degree from North China Electric Power University in 2019. Now, he is a lecturer at North China University of Technology. His main research interests include neural networks and fault diagnosis.