

基于 GAF-ICNN 的配电网接地故障检测

汪勋婷¹, 陶伟龙², 王海伟², 张峰¹, 丁津津¹, 张倩³

(1. 国网安徽省电力有限公司电力科学研究院, 安徽 合肥 230001;

2. 国网安徽省电力公司合肥供电公司, 安徽 合肥 230000;

3. 安徽大学电气工程与自动化学院, 安徽 合肥 230601;)

摘要: 为解决配电网发生单相接地故障时故障特征不明显、故障数据集较小时造成故障定位准确率较低的问题, 提出了一种结合格拉姆角场(Gramian Angular Field, GAF)和深度学习的电网故障定位模型. 首先, 采用 GAF 的编码方式将原始零序电流信号转化为具有时间相关性的二维特征图像. 其次, 利用卷积神经网络(Convolutional Neural Networks, CNN)去提取故障特征, 同时为加强关键特征的提前能力, 引入注意力机制. 最后, 以特征图作为改进卷积神经网络(Improved Convolutional Neural Networks, ICNN)的输入进行自动特征提取, 从而实现不同故障类型的分类. 为了验证所提方法的有效性和优越性, 利用 Simulink 仿真模型生成故障数据, 并测试了 GAF-ICNN(Gramian Angular Field-Improved Convolutional Neural Networks)模型在不同过渡电阻、故障位置、故障相角等条件下均能准确实现故障定位. 在数据集较少的情况下, 相较于其它故障诊断方法, 所提出的模型对接地故障定位具有更好的泛化性能和识别效果.

关键词: 配电网; 零序电流; 故障检测; 格拉姆角差场; 卷积神经网络

中图分类号: TM773 文献标志码: A 文章编号:

Ground fault detection in distribution networks based on GAF-ICNN

Wang Xunting¹, Zhang Qian², Tao Weilong³, Wang Haiwei³, Zhang Feng¹, Ding Jinjin¹

(1. Electric Power Research Institute of State Grid Anhui Electric Power Co Ltd, Hefei 230001, China;

2. School of Electrical Engineering and Automation, Anhui University, Hefei 230001, China;

3. State grid Anhui electric power company Hefei power supply company, Hefei 230001, China)

Abstract: To solve the problem that the fault characteristics are not obvious and the fault data set is small when the single-phase grounding fault occurs in the distribution network, a fault location model combining Gramian Angular Field (GAF) and deep learning is proposed. Firstly, the original zero-sequence current signal is converted into a time-dependent two-dimensional feature image by GAF encoding. Secondly, Convolutional Neural Networks (CNNs) are used to extract fault features, while attention mechanisms are introduced to enhance the advance ability of key features. Finally, the feature graph is used as the input of Improved Convolutional Neural Networks (ICNN) for automatic feature extraction, which realizes the classification of different fault types. In order to verify the effectiveness and superiority of the proposed method, a Simulink simulation model was used to generate fault data. It is tested that the GF-ICNN (Gramian Angular Field-Improved Convolutional Neural Networks) model can accurately locate faults under different transition resistances, fault locations and fault phase angles. Compared with other fault diagnosis methods, the proposed model has better generalization performance and recognition effect in the case of less data sets.

Key words: Distribution network; Zero sequence current; Fault identification; Gramian Angular Field; Convolutional neural networks

收稿日期:

基金项目: 国网安徽省电力有限公司科技项目资助: 新型电力系统输配一体化风险评估及安全预警技术研究 (B312A0230008); 安徽省自然科学基金能源互联网联合基金资助: 基于低碳需求响应的新型电力系统输配协同资源优化配置技术研究 (2208085UD01)

作者简介: 汪勋婷 (1994-) 女, 安徽滁州人, 工程师, E-mail: wangxt1994@163.com; *张倩 (通信作者) 安徽大学教授, 博士生导师, E-mail: qianzh@ahu.edu.cn

配电网中大部分故障为单相接地故障, 约占故障总数的 80%^[1]. 在配电网中, 单相接地故障的电流较小且不稳定, 而非故障相的电压会显著升高, 导致电力设备出现欠压运行问题. 一旦故障线路不能及时拆除, 很容易对电缆绝缘设备造成损坏, 造成无法估量的危害^[2]. 因此, 及时精准的实现输电线路故障检测具有重要意义^[3].

大多数配电网单相接地故障定位可分为稳态信号分析和暂态信号分析. 在稳态信号法中, 产生的工频谐波信号通常用于特性分析^[4]. 文献[5]中, 提取了每条线路的五次谐波零序电流, 并通过相关性分析检测故障线路. 但需要的前提是接地电阻固定. 近年来, 基于故障暂态信号的特性分析成为相关研究的热点^[6-7]. 文献[8]提出了一种基于希尔伯特-黄变换的接地故障定位方法, 通过经验模态分解得到不同的高频信号, 然后通过信号的极性检测故障线. 由于判据的单一性, 该方法容易受到电网运行环境的干扰. 文献^[9]利用混沌粒子群优化的概率网络对暂态电流进行特征分析, 从而实现分区故障定位. 现有的接地故障定位方法以暂态零序电流或特定模态分量为分析对象. 然而, 这些方法容易受到噪声干扰, 在复杂的故障环境中难以应对.

深度学习算法在电力系统故障诊断问题上展现了更大的潜力. 卷积神经网络 (Convolutional Neural Networks, CNN) ^[10-11] 作为深度学习中的典型代表, 不依赖人工设计的特征提取环节, 通过海量数据训练, 自动提取输入数据特征并进行归纳分类. 文献[12]将支路的功率和关键特征值作为 CNN 输入, 通过迭代训练, 实现电力系统运行状态的评估. 文献[13]为了更好的提取故障信息的特征, 建立 CNN 和长短期记忆网络 (Long Short Term Memory networks, LSTM) 的混合模型, 用于复杂支路的故障电弧检测. 然而, 这些研究都是将 CNN 应用于一维信号, 在复杂的网络拓扑结构下无法很好的工作. 因为 CNN 这样的方法最初是为图像识别而提出, 并且二维图像和原始时序信号有着较大差异^[14-15].

为了克服这个挑战, 本文提出利用格拉姆角场 (Gramian Angular Field, GAF) ^[16-17] 将时序信号转换为图像数据, 保留了原始信号中关键信息的同时, 更有助于提取区别性特征.

同时为了最大化提取故障样本特征, 对 CNN 框架进行了改进, 引入注意力机制 (Convolutional Block Attention Module, CBAM) ^[18-19], 将更多注意力放在关键特征上, 减少从隐藏层提取的大量特征.

利用 ICNN 提取故障期间各个线路零序电流之间的关键特征, 从而精准的实现故障定位. 根据仿真结果表明: GAF-ICNN 模型具有良好的抗噪声性能, 且不受系统故障条件的影响.

1 格拉姆角场

一维信号仅展现单向相关性, 无法充分反映数据的局部时间关系. 本文提出的一种基于 GAF 的虚拟图像数据预处理方法可以充分利用计算机视觉

的优势.

第一步: 获取 m 个样本的零序电流采样序列 $X = \{x_1, x_2, \dots, x_n\}$. 每个时序样本是由各个采样时间点 x_n 组成, 其中 n 为采样点数.

第二步: 将时间序列数据的大小缩放到 $[-1, 1]$.

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

第三步: 将笛卡尔坐标系中的一维零序电流序列转换为极坐标系, 我们在极坐标系中表示重新缩放的时间序列, 将值编码为角余弦 ϕ_i , 时间戳编码为半径.

公式如下:

$$\begin{cases} \phi_i = \arccos(x_i), -1 \leq x_i \leq 1 \\ r_i = \frac{t_i}{N}, t_i \in \{0 \dots N\} \end{cases} \quad (2)$$

式中 t_i 为时间戳, N 为正则化极坐标跨度的常数因子.

第四步: 计算采样点间三角函数的总和, 以从不同角度识别它们的时间相关性. 得到 Gramian 角场, 如式(3)所示.

$$GAF = \begin{pmatrix} \cos(\phi_1 + \phi_1) & \cdots & \cos(\phi_1 + \phi_n) \\ \cos(\phi_2 + \phi_1) & \cdots & \cos(\phi_2 + \phi_n) \\ \vdots & \ddots & \vdots \\ \cos(\phi_n + \phi_1) & \cdots & \cos(\phi_n + \phi_n) \end{pmatrix} \quad (3)$$

$$GAF = X' \cdot X - \sqrt{I - X^2} \cdot \sqrt{I - X^2} \quad (4)$$

式中: I 是全为 1 的行向量 $[1, 1, \dots, 1]$; $\phi_i (i=1, \dots, n)$

是两个向量的夹角.

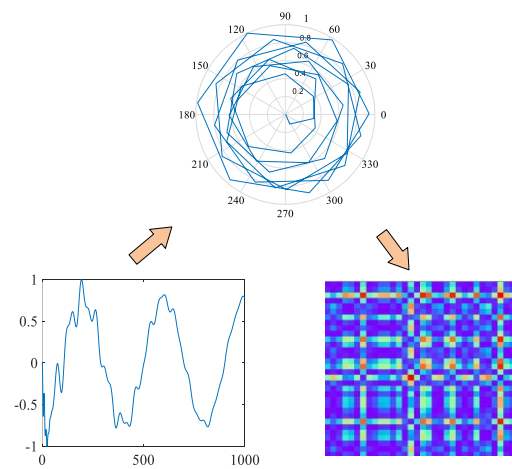


图 1 GAF 映射过程

Fig.1 GAF Mapping process

图 1 是一维时序数据转换为 GAF 图像的结果, 这样转换的优点是, 整个编码方法是双射的, 随着

时间的增加,相应的极坐标值将在跨度圆上的不同角度之间扭曲,与笛卡尔坐标系相比,GAF通过 r 坐标保持绝对时间关系。 $GAF_{(i,j)|i-j=k}$ 表示时间相关性是通过时间间隔 k 的方向所叠加,当 $k=0$ 时,对角线包含原始值/角度值信息。

基于上述 GAF 独特的点积和余弦计算方式,更好的保留了时序数据全局特征,尤其是针对电网故障数据呈现非线性关系时以及在捕捉时间序列中更为复杂的过程中,具有优越性.更加有利于深度学习网络进行深层次的特征提取。

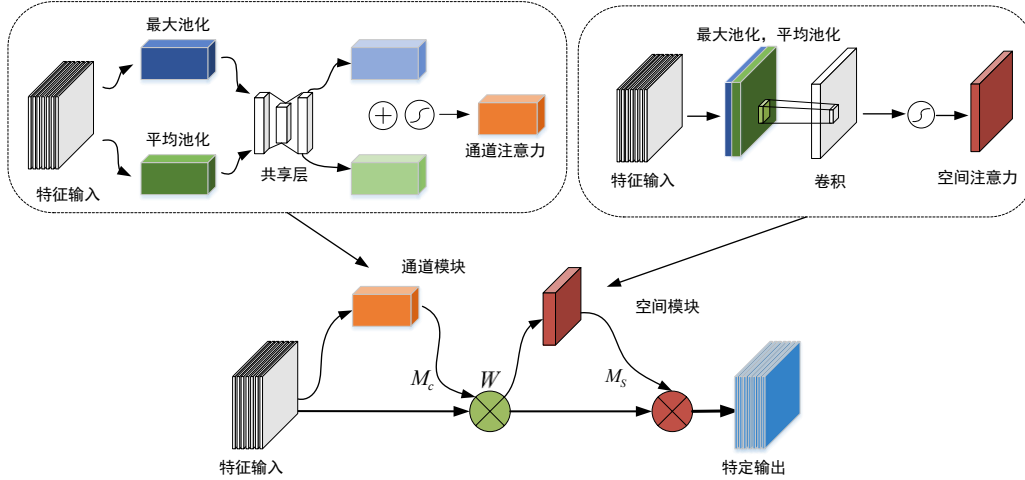


图2 注意力机制模型

Fig.2 Attention mechanism model

2 ICNN 框架结构

2.1 注意力机制

所有虚拟图像上都存在故障特征分布,但多数情况下目标特征只存在在图像的一部分上.然而,在CNN对特征进行提取时,会等效地处理图像的每个部分,从而导致难以关键特征难以被有效的聚焦。

近年来,在深度学习等各个领域上,CBAM得到广泛应用,它对人类的视觉处理机制学习模拟,依据重要程度增强有用特征,抑制干扰特征.将CBAM引入到CNN的各个特征提取层中,帮助神经网络学习权重分布,对数据进行加权学习,从大量信息中快速筛选出深层特征.其中注意力过程分为通道注意力模块与空间注意力模块,其模型结构如图2所示。

通道注意力模块:首先对输入执行平均池化和最大池化操作,然后送入一个多层感知器(MLP)中进一步处理.将MLP输出的特征进行加权操作,最后再经过sigmoid激活操作,生成通道注意特征图 M_c 。

$$M_c(X) = \sigma(MLP(AvgPool(X)) + MLP(MaxPool(X))) \quad (5)$$

空间注意力模块:对上一层的输入沿着通道轴再一次进行平均池化和最大池化生成空间注意特征图 M_s 。

$$M_s(W) = \sigma(f([AvgPool(W); MaxPool(W)])) \quad (6)$$

式中 W 为通道注意力模块的输入, f 为卷积操作。

本文在卷积层中嵌入了CBAM模块,CBAM可以增强不同线路故障数据间的差异性来提升

ICNN分类性能。

2.2 改进的卷积神经网络

ICNN本质是由多个特征滤波器对输入数据进行逐层卷积和池化计算,整体结构如图3所示。

用卷积核对原始图像分别进行过滤,生成一些特征映射图.为了减少冗余信息,池化层对上一层的信息进行压缩处理,去除非重要的特征参数.最后将提取的特征通过全连接层转换成一维向量,并将故障分类结果通过损失函数表达.数学表达式如下。

$$y^L = \sum K^L * w^{(L-1)} + b^L \quad (7)$$

$$\phi^L = w^{L-1} * \frac{1}{k} \quad (8)$$

式中, L 代表网络层数, y^L 是卷积操作后的输出特征面, w^{L-1} 是 $L-1$ 层的特征面, b^L 表示偏差, k 是池化系数, ϕ^L 是池化操作后的输出特征面。




图3 ICNN整体结构

Fig.3 Overall structure of ICNN

3 基于GAF-ICNN的电网故障定位整体流程图

基于上述对GAF和ICNN神经网络的原理介绍,构建GAF-ICNN故障诊断模型.下面给出配电网故障诊断策略的实现过程,流程图如图4所示。

(1)设置不同的故障条件,利用Simulink仿真生成不同的故障零序电流,作为网络训练的样本数据。

(2)由于原始的采样信号是一维时间序列,使用GAF算法将故障样本转换为二维扰动图像,作为CNN的输入。

(3)对 CNN 模型进行改进,设置多尺度特征提取模块,利用不同大小的卷积核多通道对输入进行特征提取;引入注意力机制,进一步提取有价值的信息.

(4)对模型参数训练,采用梯度下降法对权重参数进行更新,通过多次迭代得到 CNN 故障诊断模型.同时对模型进行测试,将配电网故障线路的数据通过 GAF 转换,然后输入到训练好的模型进行测试,验证模型的性能.

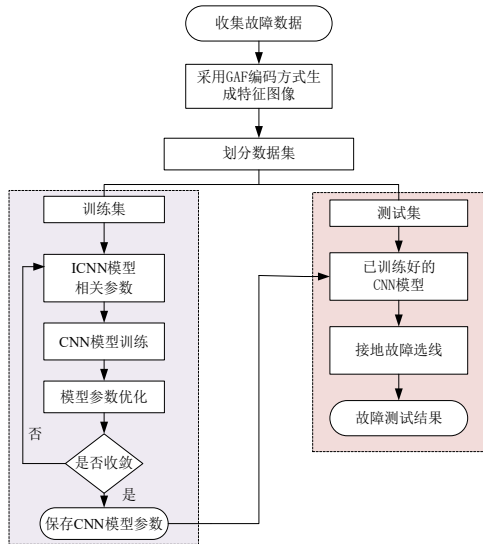


图4 故障定位流程图

Fig.4 Fault line selection flowchart

4 案例研究

4.1 仿真案例

为了评估本文所提 GAF-ICNN 算法的性能,通过 MATLAB 仿真生成大量暂态数据进行迭代训练.在 Simulink 模块中搭建 10kV 经消弧线圈接地配电网模型,系统接线图如图 5 所示.在这个系统中,共有 4 条馈线,这些馈线由电缆线和架空线组合而成.每条线路上都设置有若干个节点,总共有 23 个节点,22 条支路.

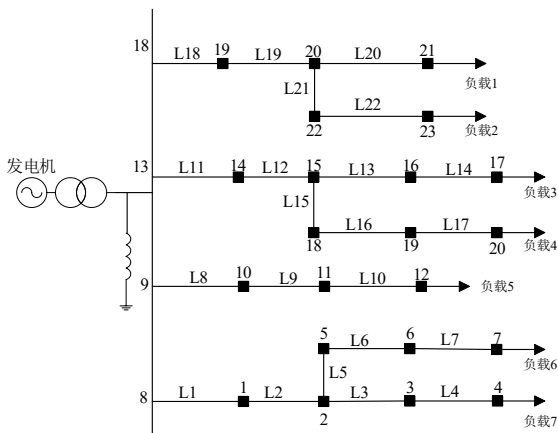


图5 10kV 经消弧线圈接地线圈

Fig.5 10KV grounding coil via arc suppression coil

为了模拟实际配电网发生的故障的情况,系统的采样频率设置为 50Hz.在不同节点设置故障点,故障类型为不同相的单相接地故障.故障阻抗取值

设置为 $[0.1\Omega,1000\Omega]$ 范围内.故障起始角为 0 度到 180 度之间.根据不同参数的排列组合,生成大量的零序电流时序数据,如表 1 所示.同时为了神经网络分类训练,对可能出现的故障位置和故障状态进行数字编码,如表 2 所示

表 1 训练样本

Table 1 Training sample

训练集	故障位置	类型	样本数量
1	L1	AG,BG,CG	3500
2	L9	AG,CG	2500
3	L12	AG	2500
4	L17	BG	2500
5	L19	CG	2000

表 2 故障样本标签

Table 2 Fault sample label

故障定位	标签
L1	1 (1 0 0 0 0)
L9	2 (0 1 0 0 0)
L12	3 (0 0 1 0 0)
L17	4 (0 0 0 1 0)
L19	5 (0 0 0 0 1)

表 3 ICNN 网络结构

Table 3 ICNN Network structure

结构	参数	通道数	输出通道
输入	100×100	1	100×100
卷积层	5×5×8	8	100×100
注意力机制			
池化层	2×2	8	50×50
卷积层	3×3×16	16	50×50
注意力机制			
池化层	2×2	128	6×6
全连接层	1024	1	1×1024
全连接层	512	1	1×512
输出	5	———	1×5

4.2 模型训练

将故障样本按 7:3 的比例随机分为训练样本和测试样本.网络的结构和参数对网络的性能有很大的影响.为了得到最佳的性能,在优化单个参数时,保持其它参数不变.在训练网络之前,将网络的学习率设置为 0.001;小批量,64;迭代次数为 20.训练过程如图 6,故障分类的准确率呈现单调递增趋势,并最终趋近于 100%.同时,训练样本的损失函数值近乎呈现单调递减趋势,最终接近于 0.由上述分析可得,在本文构建的结构下,模型的性能得到了显著提升,表明该网络结构能够有效地处理故障分类任务.ICNN 具有良好的分类性能,表 3 给出了 ICNN 的网络结构.

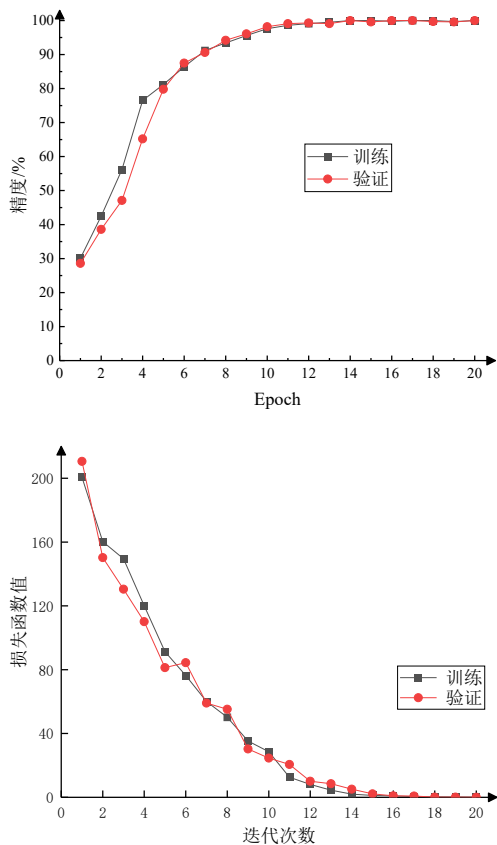


图 6 整个训练过程

Fig.6 The whole training process

4.3 基于 GAF 的可视化图像构建

当故障发生后,三相电流会发生畸变,导致零序电流的产生.每个采样瞬间,系统会记录大量数据点.数据之间的潜在相关性难以被揭示,除此之外,一维时间序列还无法有效区分有价值的信息与高斯噪声.神经网络的分类准确性受数据高斯分布影响,因为高斯分布的增加会导致高斯噪声与有价值信息难以分离.故本文为了能更直观的体现故障数据的共性和潜在关系,使用 GAF 图像代替单变量时间序列的方法.以线路 L1 和 L9 的单相接地故障为例, GAF 图像可以更有效地捕捉数据特征,转换结果如图 7 所示.




图 7 GAF 虚拟图像

Fig.7 GAF virtual image

图 7 清楚地显示了数据特征.故障特征覆盖了图像中的大部分区域.特征分布沿对角线对称,在极坐标

变换中保持绝对时间关系.这些图像不仅包含几个不同的特征,而且这些特征在图像中的位置是固定的.此外,不同线路的故障数据在图像中具有显著不同的特征分布.二维图像之间的局部特征可以快速被基于 ICNN 的训练模型提取,大大提高了故障诊断模型可靠性的潜力.

4.4 GAF-ICNN 模型的预测

为了评估所提方法的有效性,与其它传统方法的效果进行对比.1D-CNN^[20]:将一维原始电信号作为经典 CNN 的输入;GAF-CNN:GAF 二维图像作为传统 CNN 的输入;灰度图-ICNN^[21]:将一维原始信号转换为二维灰度图的形式再将灰度图作为 ICNN 的输入.神经网络的学习效率均设置为 0.1,批训练样本数为 50,迭代次数为 20.

如图 8 所示,在准确率的结果上,GAF-ICNN 只需经过少于 10 次的迭代就可以超过 95%,而其他方法在迭代次数超过 10 次后才趋于稳定.1D-CNN 的准确率上升较慢,最终不到 90%.GAF-CNN 和灰度图-ICNN 的训练准确率均高于 1D-CNN,但均低于 GAF-ICNN.上述对比分析说明,原始时序数据的信息丢失能通过 GAF 图像转换的方法被有效避免,此外,相较于一维图像,二维图像能更好地保留原始信号中的隐藏信息.这些改进能更好的提升网络识别的效果.




图 8 对比实验结果图

Fig.8 Compare the experimental results

每种数据驱动算法对故障类型的识别结果也不相同.为了验证 ICNN 模型的性能.选择 SVM^[22],BPNN^[23]和 KNN^[24]用来进行对比.故障位置混淆矩阵如图 9 所示.图中的 X 轴和 Y 轴分别表示故障线路的预测标签和真实标签.对角线是每条线的预测精度.从结果来看,所提出的 GAF-ICNN 模型具有最佳的分类性能,每个故障的分类率接近 100%,总体准确率达到 99.41%.其他数据驱动算法具有一定的波动性.这表明图像中的细微差别能够被基于 GAF-ICNN 的模型很好地捕捉,因此本文所使用的方法可以获得更精准的结果.

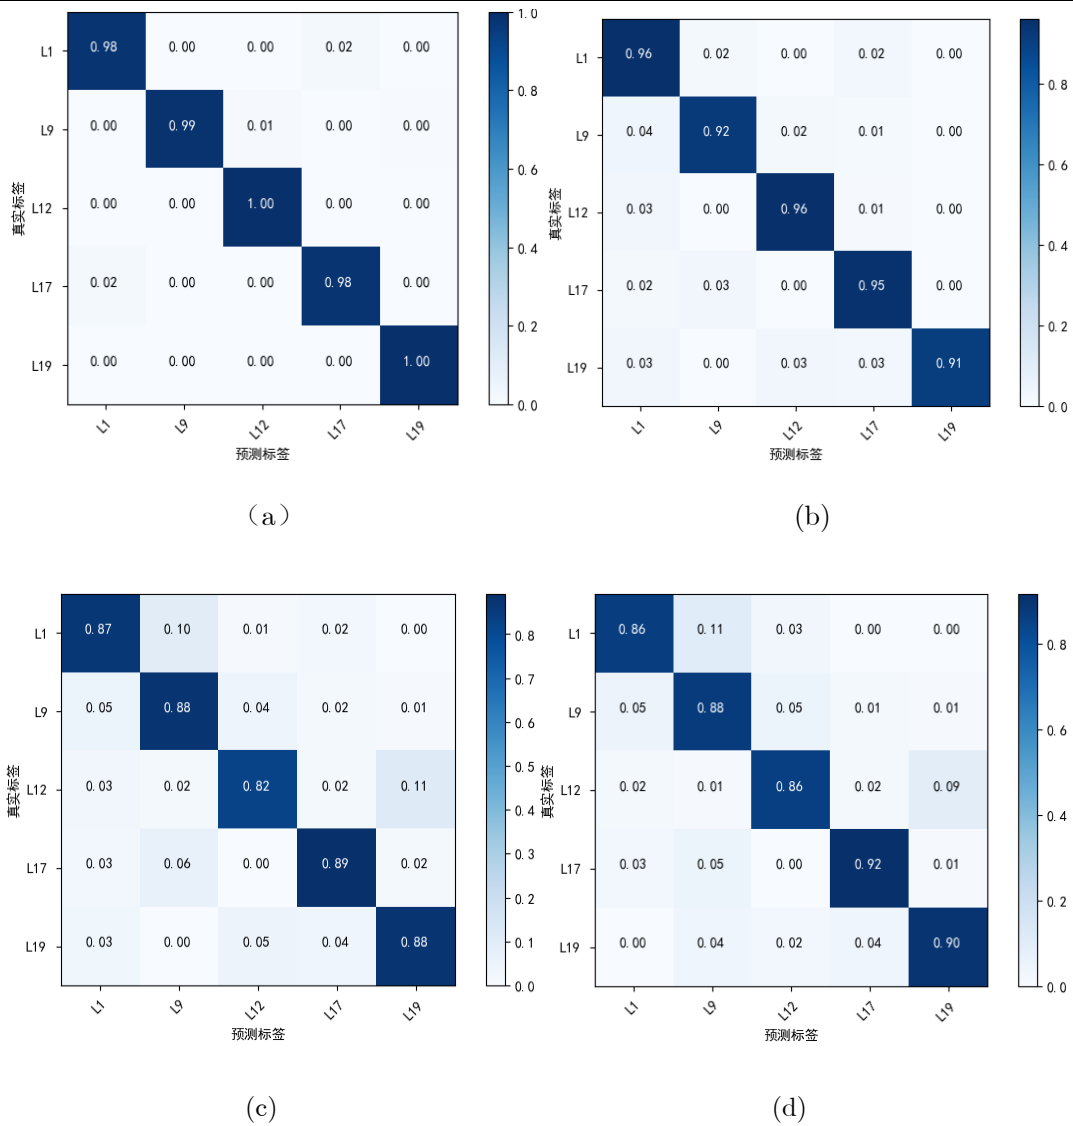


图9 不同混淆矩阵结果 (a)GAF-ICNN,(b) SVM,(c)KNN,(d)BPNN

Fig.9 Different confusion matrix results (a)GAF-ICNN,(b) SVM,(c)KNN,(d)BPNN

4.5 模型抗噪声能力评估

为了测试 GAF-ICNN 的抗干扰能力,本文和 SVM、RBF、BPNN 和 1D-CNN 模型进行对比.我们对收集到的原始数据分别添加不同的信噪比 15 dB、20 dB、25 dB、30 dB、35 dB、40 dB.信噪比越小,噪声越大.信噪比的计算公式见式 7.

$$SNR_{dB} = 10 \log_{10} \left(\frac{P_{signal}}{P_{noise}} \right) \quad (9)$$

式中, P_{signal} 为源信号, P_{noise} 为噪声信号.

图 10 不同模型的抗干扰能力测试结果显示,信噪比大小不同的情况下,GAF-ICNN 的预测精度和准确率均高于其他模型.基于 CNN 的模型准确率均要高于其它算法模型.但在没有 GAF 二维图像转换和 CNN 模型改进的情况下,传统的 1D-CNN 模型的准确率仍低于 GAF-ICNN.因此,结果表明 GAF-ICNN 模型具有较强的抗干扰性能.




图 10 环境噪声对比实验

Fig.10 Environmental noise contrast experiment

5 结论

本文提出了一种基于数据驱动的复杂配电网系统中故障诊断新方法——GAF-ICNN.搭建 10kV

配电网仿真模型及其拓扑结构改变后的模型,并在该模型上进行仿真实验,验证所提方法的有效性,结论如下:

1) GAF 算法将一维时域信号转换为图像域,能够确定故障特征在图像中的位置.这一过程使原始信号信息得以保留,故障特征更加明显.

2)对传统 CNN 引入注意力机制.进一步提取配电网中海量数据的深层次特征,提升了 GAF-ICNN 模型的预测性能.

3)在不同的故障条件下,文中所提方法均能准确实现故障定位,且具有良好的抗噪声性能.

参考文献:

- [1] 张大波,李雪婷,陶维青.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[J].电力系统保护与控制,2023,51(24):22-32.
Zhang Dabo, Li Xueting, Tao Weiqing. Location of single-phase grounding fault segment in limited information distribution network based on edge computing and deep learning [J]. Power System Protection and Control, 2019,51(24):22-32.
- [2] 张大波,王博欣,郭怀新,等.基于拓扑聚合的输电断面辨识方法与断面传输极限的研究[J].电力系统保护与控制,2022,50(05):33-42.
Zhang Dabo, Wang Boxin, Guo Huaixin, et al. Research on Transmission section Identification Method and transmission Limit of transmission Section based on topological aggregation [J]. Power System Protection and Control,2022,50(05):33-42.
- [3] 王宇,高吉普,林呈辉,等.基于多源数据融合的电网故障智能诊断方法研究[J].电子器件,2020,43(02):304-308.
Wang Yu, Gao Jipu, Lin Chenghui, et al. Research on intelligent diagnosis method of power grid fault based on multi-source data fusion [J]. Chinese Journal of Electron Devices, 2020, 43 (02): 304-308.
- [4] Liu, Ph, Huang, C.: Detecting Single-Phase-to-Ground Fault Event and Identifying Faulty Feeder in Neutral Ineffectively Grounded Distribution System. IEEE Trans. Power Del. 33(5), 2265-2273 (2018).
- [5] Zhang, ZX, Liu, X, Piao, ZL.: Fault line detection in neutral point ineffectively grounding power system based on phase-locked loop. IET Gener. Transm. Distrib. 8(2), 273-280 (2014).
- [6] 张玉玺,王增平,李振钊,等.基于特征频带暂态无功功率的配电网故障定位新方法[J].电力系统保护与控制,2023,51(01):1-11.
Zhang Yuxi, Wang Zengping, Li Zhenzhao, et al. A new fault location method for Distribution network based on transient reactive power of characteristic frequency band [J]. Power System Protection and Control, 2019,51(01):1-11.
- [7] 王天生,樊艳芳,刘群杰,等.基于多区域相位突变量信息的主动配电网接地故障定位方案[J].安徽大学学报(自然科学版),2020,44(01):57-63.
Wang Tiansheng, Fan Yanfang, Liu Qunjie, et al. Active distribution network grounding fault location Scheme based on multi-region phase mutation information [J]. Journal of Anhui University (Natural Science Edition), 2019,44(01):57-63.
- [8] Song, JZ, Li, YL, Zhang, YK: Faulty line detection method based on improved Hilbert-Huang transform for resonant grounding systems. Int. Trans. Electr. Energy Syst. 31(3), e12760 (2021)
- [9] 谢民,邵庆祝,王同文,等.基于 CPSO-PNN 及灰色关联度分析的电网分区故障诊断[J].安徽大学学报(自然科学版),2022,46(03):94-101.
Xie Min, Shao Qingqing, Wang Tongwen, et al. Fault diagnosis of power grid partition based on CPSO-PNN and grey correlation analysis [J]. Journal of Anhui University(Natural Science Edition), 2022, 46(03): 94-101.
- [10] 宁剑,任怡睿,林济铿,等.基于人工智能及信息融合的电力系统故障诊断方法[J].电网技术,2021,45(08):2925-2936.
Ning Jian, Ren Yirui, Lin Jikeng, et al. Fault diagnosis method of power system based on Artificial Intelligence and Information fusion [J]. Power Grid Technology, 2021,45 (08) : 2925-2936.
- [11] 张大海,张晓炜,孙浩,等.基于卷积神经网络的交直流输电系统故障诊断[J].电力系统自动化,2022,46(05):132-145.
Zhang Dahai, Zhang Xiaowei, Sun Hao, et al. Fault diagnosis of AC/DC transmission system based on convolutional neural network [J]. Automation of Electric Power Systems, 2022, 46(05): 132-145.
- [12] 朱燕芳,闫磊,常康,等.基于深度卷积神经网络的电力系统故障预测[J/OL].电源学报:1-14[2022-10-10].
Zhu Yanfang, Yan Lei, Chang Kang, et al. Power system fault prediction based on deep convolution neural network [J/OL]. Journal of Power Supply: 1-14 [2022-10-10].
- [13] 余琼芳,徐静,杨艺.基于 CNN_LSTM 模型的复杂支路故障电弧检测[J].中国安全生产科学技术,2022,18(04):204-210.
Yu Qiongfang, Xu Jing, Yang Yi. Based on CNN_ Arc detection of complex branch fault of LSTM model [J]. Journal of Safety Science and Technology, 2022, 18(04): 204-210.
- [14] 殷浩然,苗世洪,郭舒毓,等.基于 S 变换相关度和深度学习的配电网单相接地故障定位新方法[J].电力自动化设备,2021,41(07):88-96.
Yin Haoran, Miao Shihong, Guo Shuyu, et al. A new method for single-phase ground fault line selection in distribution

- networks based on S-transform correlation and deep learning [J]. *Electric Power Automation Equipment*, 2021, 41(07): 88-96.
- [15] 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. Classification of power quality disturbances based on GAF and convolutional neural network [J]. *Power System Protection and Control*, 2021, 49 (11): 97-104.
- [16] 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/OL]. *电网技术*: 1-10[2022-10-10]. He Caijun, Li Kaicheng, Yang Wangwang, et al. Power quality composite disturbance identification based on dual channel GAF and deep residual network [J/OL]. *Power System Technology*: 1-10 [2022-10-10].
- [17] 庞新宇, 仝钰, 魏子涵. 一种 GAF-CNN 行星齿轮箱故障诊断方法[J]. *北京理工大学学报*, 2020, 40(11): 1161-1167. Pang Xinyu, Tong Yu, Wei Zihan. A fault diagnosis method of GAF-CNN planetary gearbox [J]. *Transactions of Beijing Institute of Technology*, 2020, 40 (11): 1161-1167.
- [18] 董绍江, 裴雪武, 吴文亮, 等. 改进抗干扰 CNN 的变负载滚动轴承损伤程度识别[J]. *振动.测试与诊断*, 2021, 41(04): 715-722+831. Dong Shaojiang, Pei Xuewu, Wu Wenliang, et al. Damage degree identification of variable load rolling bearing with improved anti-interference CNN [J]. *Journal of Vibration, Measurement & Diagnosis*, 2021, 41(04): 715-722+831.
- [19] 王瑞婷, 王海燕, 陈晓, 等. 基于混合卷积与三重注意力的高光谱图像分类网络[J/OL]. *智能系统学报*: 1-11[2022-10-10]. Wang Ruiting, Wang Haiyan, Chen Xiao, et al. Hyperspectral image classification network based on mixed convolution and triple attention [J/OL]. *CAAI Transactions on Intelligent Systems*: 1-11 [2022-10-10].
- [20] 黎阳羊, 胡金磊, 赖俊驹, 等. 基于 1D-CNN-LSTM 混合神经网络模型的风电机组行星齿轮箱故障诊断[J]. *电气自动化*, 2021, 43(05): 20-22+26. Li Yangyang, Hu Jinlei, Lai Junju, et al. Fault diagnosis of planetary gearbox in wind turbines based on 1D-CNN-LSTM hybrid neural network model [J]. *Electrical Automation*, 2021-43 (05): 20-22+26.
- [21] 许同乐, 孟良, 孔晓佳, 等. 基于 EEMD 的 ICNN 故障诊断方法[J]. *北京邮电大学学报*, 2022, 45(02): 110-116. Xu Tongle, Meng Liang, Kong Xiaojia, et al. An ICNN fault diagnosis method based on EEMD [J]. *Journal of Beijing University of Posts and Telecommunications*, 2022, 45 (02): 110-116. DOI: 10.13190/j.job.2021-128.
- [22] 程志友, 袁昊辰, 杨韬. 基于复阻抗与支持向量机的电能质量扰动分类方法 [J]. *安徽大学学报(自然科学版)*, 2016, 40 (03): 58-64. Cheng Zhiyou, Yuan Haochen, Yang Tao. Power quality disturbance classification method based on complex impedance and support vector machine [J]. *Journal of Anhui University (Natural Science)*, 2016, 40 (03): 58-64. (in Chinese)
- [23] 刘会家, 冯铃, 艾璨. 基于 GA-ADAM 优化的 BPNN 配电网潮流计算[J]. *电子测量技术*, 2023, 46(24): 84-92. Liu Huijia, Feng Ling, Ai Can. BPNN distribution network power flow calculation based on GA-ADAM optimization [J]. *Electronic Measurement Technology*, 2023, 46 (24): 84-92. DOI: 10.19651/j.cnki.emt.2314035.
- [24] 陈新岗, 范益杰, 马志鹏, 等. 基于集成增强 KNN 的油纸绝缘原始拉曼光谱老化状态判别 [J]. *激光与光电子学进展*, 2023, 60(21): 338-344. Chen Xingang, Fan Yijie, Ma Zhipeng, et al. Identification of the Aging State of Oil Paper Insulation Raw Raman Spectroscopy Based on Integrated Enhanced KNN [J]. *Progress in Laser and Optoelectronics*, 2023, 60 (21): 338-344.