

DOI: 10.13382/j.jemi.B2205414

基于非对称卷积神经网络的电弧故障检测系统*

张婷 张认成 杨凯

(华侨大学机电及自动化学院 厦门 361021)

摘要: 串联电弧故障是引发电气火灾的重要原因,对其有效检测能确保线路的正常运行和电气设备的可靠工作。根据低压串联电弧故障的检测难点,提出了基于非对称卷积神经网络的识别模型,用于适应性地提取串联电弧故障信息。针对串联电弧故障种类多、信息隐蔽等问题,首先利用格拉姆角差场时域数据处理方法,将负载模拟的时域信号经过极坐标变换、三角变换后映射到二维矩阵中,以增加故障数据点的空间占有率和数据关联信息。之后,为了不增加时间开销,同时改善模型的识别效能,使用自适应非对称卷积、多通道离散注意力机制改进残差神经网络,作为低压线路中的串联电弧故障模型。最后,利用容器封装已训练好的故障识别模型,实现故障信息的快速分析。验证表明,所提方法对串联电弧故障的识别率达到99.95%,具有良好的识别效果。

关键词: 串联电弧故障检测;格拉姆角差场;残差神经网络;适应性非对称卷积;多通道注意力机制;在线检测系统

中图分类号: TN98; TH89 **文献标识码:** A **国家标准学科分类代码:** 460.40

Arc fault detection system based on asymmetric convolutional neural network

Zhang Ting Zhang Rencheng Yang Kai

(College of Mechatronics and Automation, Huaqiao University, Xiamen 361021, China)

Abstract: Series arc fault is an important cause of electrical fire, and effective detection can ensure the normal operation of lines and reliable work of electrical equipment. According to the difficulty of low voltage series arc fault detection, a recognition model based on asymmetric convolutional neural network is proposed to extract series arc fault information adaptively. To solve the problems of series arc faults with many types and hidden information, firstly, the time-domain data processing method of Gramian difference angular field is used to map the time-domain signals simulated by load into two-dimensional matrix after polar coordinate transformation and trigonometric transformation, so as to increase the space occupancy of fault data points and data association information. Then, in order not to increase the time cost and improve the recognition efficiency of the model, the residual neural network is improved by adaptive asymmetric convolution and multi-channel discrete attention mechanism as the series arc fault model in low-voltage lines. Finally, a container is used to encapsulate the trained fault identification model to realize the fast analysis of fault information. Verification shows that the recognition rate of series arc fault can reach 99.95%, and it has good recognition effect.

Keywords: series arc fault detection; Gramian difference angular field; residual neural network; adaptive asymmetric convolution; multichannel attention mechanism; on-line detection system

0 引言

低压配电系统中,由于线路或设备的绝缘老化、破裂或电气接触不良时,常常伴随故障电弧,进而引发火灾隐

患。串联电弧是指电流导通的回路中导体受到外力而导致断线,或由于振动导致金属接触不良产生的,即电弧串联于原回路中。此时电弧等效于一个非线性电阻,导致线路阻抗增大,电弧电压升高,回路电流减小。因此,传统的过流保护无法检测串联电弧故障。

收稿日期: 2022-04-24 Received Date: 2022-04-24

* 基金项目: 国家自然科学基金(52175508)、中央高校基本科研业务费专项资金(ZQN-1001)项目资助

目前,对于串联电弧故障的主要检测方法分为两类,其一是以人工特征提取和传统机器学习为模型的诊断方法。该方法通常需要对信号进行诸如快速傅里叶变换 (fast Fourier transform, FFT)、离散小波变换 (discrete wavelet transform, DWT)、经验模态分解 (empirical mode decomposition, EMD) 等一系列信号分析方法提取特征值,之后利用线性阈值分类,或采用支持向量机 (support vector machine, SVM)、人工神经网络 (artificial neural network, ANN) 等非线性模型对上述特征进行分类或聚类,达到识别电弧故障的特点。Ferracuti 等^[1]将用电线路中的时域周期性序列转换为递归图,采用线性判别方法诊断电弧故障;Yin 等^[2]利用双树复小波变换分解直流电弧故障信号,获取小波分量的奇异值,采用内核极限学习机实现故障信息的高精度检测;Eslami 等^[3]使用 Pearson 相关系数和主成分分析处理高阻抗电弧故障,最终采用支持向量机对上述故障信息进行分类处理;Han 等^[4]通过小波变换分析了阻性、感性以及容性负载的电弧故障频率特征,采用 3 层人工神经网络实现了电弧故障的识别;Jiang 等^[5]采用随机森林算法,对多负荷串联电弧故障进行特征选择,并根据深度神经网络搭建了电弧故障诊断模型。此类方法在直流供电系统中具有良好的故障识别能力。由于交流系统中负载多样,包含阻性、感性、容性及各种耦合方式的负载,其特征往往呈现出多样化,因而此类方法对交流系统的电弧故障检测不具有很好的泛化能力。

其二是以数据驱动为基础的深度学习电弧故障诊断方法。通常可以利用卷积神经网络 (convolutional neural network, CNN) 作为故障诊断方法,从模型内部挖掘电弧故障信号的信息分布,进而实现对电弧故障的有效判断。近年来,众多研究根据卷积神经网络进行了电弧故障和其他故障检测应用。文献[6]采用一种高频耦合传感器,将高频耦合信号按照时域序列转换为二维特征灰度图像,采用多层卷积神经网络,实现电弧状态和正常状态数据的分类;文献[7]利用小波变换分析典型负载的电流信号,通过改进的 AlexNet 模型识别故障电弧并输出检测结果;文献[8]将时域的半周期数据转换为二位灰度矩阵,利用自归一化卷积神经网络实现了阻性、感性和容性电弧故障的有效识别;Yang 等^[9]将滤波后的回路电流数据转换为图片数据,将其输入至二维卷积神经网络中,实现了交流电路中多类负载的识别;Wang 等^[10]对两种电弧故障的时域信号进行了分析,最终利用深度卷积神经网络实现了高精度的检测;Zhang 等^[11]将时域电弧故障信号转换为二维特征矩阵,采用生成式对抗网络实现碳化路径电弧故障的数据增强,最终采用少参数的深度卷积神经网络实现了电弧故障的有效识别。

尽管不同的卷积网络设置和卷积计算方法具有不同

的使用效果,但存在如下问题:

- 1) 故障信息点易被屏蔽,造成模型计算的误报和漏报故障较多;
- 2) 卷积算子的特征计算不具备适应性,对于故障诊断很难存在解释性;
- 3) 网络计算参数过大,无法满足在线验证的计算需求;

基于此,以负载电流信号的时域特征为切入点,首先利用格拉姆正交角差场编码处理时域信号,编码后的二维编码矩阵放大故障信息;然后提出了适应性的非对称卷积核提取电弧故障数据的连续信息和关联信息;之后通过多通道注意力机制改善卷积特征计算;最后经过 Docker 容器封装已训练好的电弧故障识别模型,采用一种基于 Python 语言的 Web 框架—Flask 框架来构建电弧故障数据在线验证的系统,实现对故障内容的在线检测。

1 算法原理

1.1 二维编码矩阵

格拉姆角差场 (Gramian difference angular field, GADF) 编码算法是一种可以将时间序列的角度信息编码成图像的技术^[12]。其实现过程如图 1 所示。

首先,给定有 n 个值的电流时间序列 $X = \{x_1, x_2, \dots, x_n\}$,用式(1)所示的归一化方法将 X 中所有的值压缩至区间 $[0, 1]$ 内:

$$\tilde{x}_i = \frac{x_i - \min(X)}{\max(X) - \min(X)}, i \in [0, n] \quad (1)$$

其中, \tilde{x}_i 表示将 X 归一化后的值。

然后,把缩放后的时间序列转化为极坐标时间序列 \tilde{X} 。将生成的值编码为角余弦 ϕ , 时间戳编码为半径 r 。数学定义如下:

$$\begin{cases} \phi = \arccos(\tilde{x}_i), 0 \leq \tilde{x}_i \leq 1, \tilde{x}_i \in \tilde{X} \\ r = \frac{t_i}{N}, t_i \in \mathbb{N} \end{cases} \quad (2)$$

式中: t_i 为 x_i 对应的时间戳, N 为正则化极坐标系生成空间的常数因子,用于规范极坐标系的跨度。这种极坐标表示方法对于给定的时间序列产生唯一的极坐标映射图,而且可以保持绝对的时间关系。

通过上述变换可将原始时间序列转换为沿对角线对称的特征图,由于特征图像蕴含时间相关信息,因此也可利用特征图对时间序列进行重构。通过考虑每个点之间的三角函数,可以利用角度来识别不同时间间隔内的时间相关性。格拉姆角差场 (GADF) 定义如下:

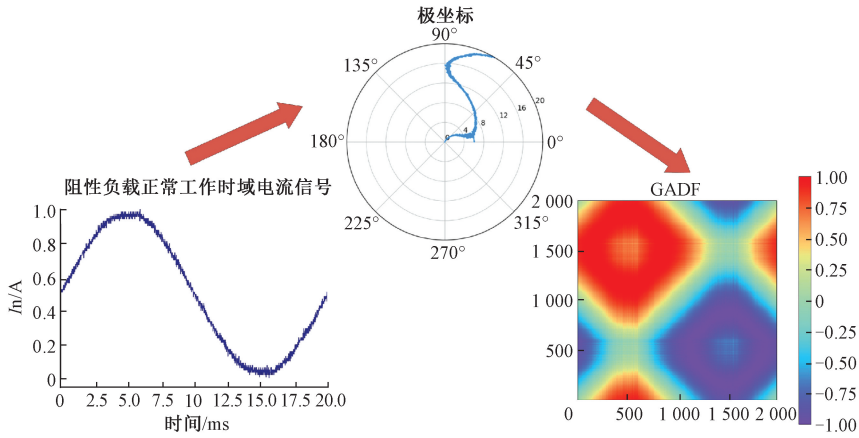


图 1 格拉姆角差场编码图

Fig. 1 Encoding map of Gramian Difference Angular Field

$$GADF = \begin{pmatrix} \sin(\phi_1 - \phi_1) & \cdots & \sin(\phi_1 - \phi_n) \\ \sin(\phi_2 - \phi_1) & \cdots & \sin(\phi_2 - \phi_n) \\ \vdots & \ddots & \vdots \\ \sin(\phi_n - \phi_1) & \cdots & \sin(\phi_n - \phi_n) \end{pmatrix} = \left(\sqrt{\mathbf{I} - \tilde{\mathbf{X}}^2} \right)^T \cdot \tilde{\mathbf{X}} - \tilde{\mathbf{X}}^T \cdot \sqrt{\mathbf{I} - \tilde{\mathbf{X}}^2} \quad (3)$$

式中: \mathbf{I} 为单位行向量。

GADF 方法经过极坐标变换、三角变换将归一化的时域信号映射到矩阵中, 可以将某一数据点涵盖的范围扩大, 增加故障数据点的空间占有率。根据式 (3) 矩阵可以看出, 若单点存在故障, 一维离散时间序列的故障占有率为 $O(1/n)$, 而在在矩阵空间中可以映射到 $O(2/n)$ 。该二维编码矩阵能有效地映射数据点之间的空间关系, 增加故障信息的特征提取范围。

GADF 编码方法从两个维度表征串联电弧故障的数据分布特征, 其中每一行具有 2 000 个数据点, 共 2 000 列, 列间数据为相邻的数据段。对照图 1 的特征提取过程, GADF 编码方法利用二维矩阵每一行的数据提取连续时间特征, 通过每一列的数据提取关联特征, 两种方式共同构成二维卷积的特征提取。通过二维卷积计算, 可以挖掘每段数据间的关联特征, 表征不同数据段之间的数据分布关系, 同时可以按行挖掘时域连续数据信息, 在增加数据间映射的同时, 减少了冗余, 使数据表述更加稀疏。

1.2 残差神经网络

CNN 已成功应用于图像处理、语义识别、姿态评估、行为预测、故障诊断等领域^[13]。它模仿生物视觉感知机制, 卷积核的大小相当于接受域。在卷积神经网络中, 一层中的一个单元只接收前一层中邻近单元的小部分作为输入, 随后的层可以将这些低级特征合并为高级特征, 从而扩大了感受野^[14]。基于所用电弧信息编码方式, 本文采用改进的二维卷积神经网络。

对于输入的单通道二维矩阵 \mathbf{I} , 有 k 个大小为 $h_f \times l_f$ 的滤波器, 步长 s 为 1, 则输出大小为 $H_{ip} \times L_{ip}$ 的特征图。每个滤波器的卷积运算公式如下:

$$O_k(h_{ip}, l_{ip}) = \sum_{i=0}^{h_f-1} \sum_{j=0}^{l_f-1} \mathbf{I}(s \times h_{ip} + i, s \times l_{ip} + j) \times W_k(i, j) + B_k \quad (4)$$

其中, O_k 表示第 k 个输出特征图; $h_{ip} = \{1, \dots, H_{ip}\}$ 和 $l_{ip} = \{1, \dots, L_{ip}\}$ 分别表示输出二维矩阵的行索引和列索引; \mathbf{W} 为权系数矩阵; B 是偏置系数。

本文采用全局均值池化(global average pooling)来替代卷积神经网络中传统的全连接层。其思想是为最后一个卷积层中分类任务的每个对应类别生成一个特征图, 取每个特征图的平均值, 并将结果向量直接输入 Softmax 层。使用全局平均池化的一个优点是, 通过加强特征图和类别之间的对应关系, 使它更适合于卷积结构。因此, 特征图可以很容易地解释为类别置信度图。另一个优点是在全局平均池化中没有需要优化的参数, 因此在这一层避免了过拟合。此外, 全局平均池化对空间信息进行求和, 从而对输入的空间平移具有更强的鲁棒性。

卷积神经网络的层数越深, 越有可能获得更好的泛化能力。但是当模型加深以后, 网络变得越来越难训练, 这主要是由于梯度弥散和梯度爆炸现象造成的^[14]。在较深层数的神经网络中, 梯度信息由网络的末层逐层传向网络的首层时, 传递的过程中会出现梯度接近于 0 或梯度值非常大的现象。为了解决上述问题, 通过在输入和输出之间添加一条跳跃直接连接, 可以让神经网络具有回退的能力。

残差神经网络^[15]通过在卷积层的输入和输出之间添加跳跃连接实现层数回退机制, 如图 2 所示, 输入 x 通过两个卷积层, 得到特征变换后的输出 $\mathcal{F}(x)$, 与输入 x 进行对应元素的相加运算, 得到最终输出 $\mathcal{H}(x)$:

$$\mathcal{H}(x) = x + \mathcal{F}(x) \tag{5}$$

其中, $\mathcal{H}(x)$ 叫做残差模块。由于被跳跃连接包围的卷积神经网络需要学习映射 $\mathcal{F}(x) = \mathcal{H}(x) - x$, 故称为残差网络。




图 2 残差模块
Fig. 2 Residual block

残差神经网络的优势主要有:1) 简化了学习过程, 增强了梯度传播残差结构因为导数包含了恒等项, 仍然能够有效的反向传播, 解决了梯度消散以及梯度爆炸等优化问题;2) 打破了网络的不对称性 残差网络可以通过跳层连接, 增强了梯度的流动, 残差网络的有效性, 更加体现在减轻了神经网络的退化;3) 增强了网络的泛化能力 残差结构其实是多个更浅的网络的集成, 网络的性能有很大提升。

2 实验及数据获取

本文根据国家标准 GB/T31143—2014《电器火灾监控系统第四部分: 故障电弧探测器》^[16] 搭建点接触式串联电弧故障试验平台, 用以模拟实际电气线路中的电弧故障, 实验原理如图 3 所示。该平台主要由点接触电弧发生装置、典型负载、电流采集探头和示波器组成。所使用的典型负载类型与功率如表 1 所示。

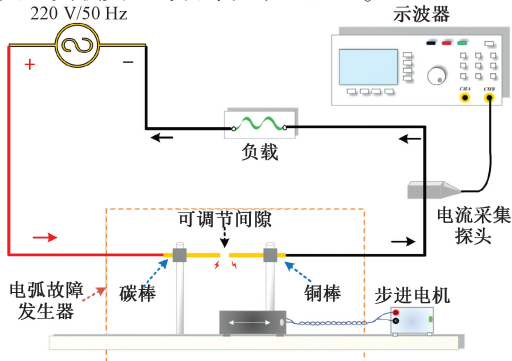


图 3 实验原理图
Fig. 3 Experimental schematic diagram

表 1 典型负载参数

Table 1 Typical load parameters

负载类型	负载名称	功率/W	功率因数
抑制性	吸尘器	1 200	—
	手电钻	750	—
开关性	调光灯	1 200	—
容性	可调功率	3 300	0.1~0.9
感性	负载箱		-0.9~-0.1
阻性			—

根据搭建好的实验平台, 分别采集阻性、容性、感性、抑制性以及开关性 5 类负载的电流信号, 其时域特征如图 4 所示。负载类型从上至下依次为: 阻性、感性、容性、抑制性、开关性。左侧“Arcing state”信号表示串联电弧故障状态, 右侧“Normal state”信号表示正常状态。




图 4 电流信号时域特征

Fig. 4 Time domain characteristics of current signal

正常工作状态下, 阻性负载波形为正弦波, 感性负载的波形特征类似于阻性负载, 容性负载波形发生畸变, 抑制性负载和开关性负载波形出现“平肩”现象。

发生串联电弧故障时, 阻性和感性负载出现不同程度的“平肩”现象, 容性负载不仅出现“平肩”, 而且波形畸变更严重; 抑制性负载的“平肩”处变化明显, 同时伴随有幅值变化, 开关性负载波形出现剧烈的毛刺, 也伴随有幅值波动。

在采集到的大量连续样本中, 对一维时间序列信号进行周期截取。每类负载分为正常工作 and 电弧故障两种

状态,共分为 10 类,电弧故障数据集总样本量为 10 000。然后通过格拉姆角差场编码方法对其进行升维处理,并对 10 类二维图像数据添加对应标签,如表 2 所示。最后将处理后的二维编码矩阵输入到改进后的神经网络模型中进行识别。

表 2 负载类型对应标签

Table 2 Labels corresponding to load types

负载类型	工作状态	标签
容性	电弧故障	0
	正常工作	1
感性	电弧故障	2
	正常工作	3
开关性	电弧故障	4
	正常工作	5
阻性	电弧故障	6
	正常工作	7
抑制性	电弧故障	8
	正常工作	9

3 模型搭建

3.1 模型改进

对于 GADF 编码数据,选择合适的卷积方法将会影响到分类器的诊断结果。同时,为了有效解释该方案的处理有效性,改善时域矩阵特征的提取效果,本文设计了一种适合于时域信号二维编码的适应性非对称卷积块,如图 5 所示。

若存在多个大小相互兼容的二维卷积核,且在相同的输入上以相同的步幅产生同一分辨率的卷积特征图,那么可以将它们的输出求和,实现这些卷积核在相应位置上的叠加,等效成为一个非对称的具有相同输出的卷积核,即二维卷积的可加性,可表达为如下形式:

$$I * K^{(1)} + I * K^{(2)} + I * K^{(3)} = I * (K^{(1)} \oplus K^{(2)} \oplus K^{(3)}) \quad (6)$$

其中, I 为一个矩阵, $K^{(1)}$, $K^{(2)}$ 和 $K^{(3)}$ 是具有兼容尺寸的两个二维卷积核, \oplus 表示对应位置的求和操作。卷积核叠加后,由于其兼容性,不会带来训练参数的增加。

假设卷积核大小为 $H \times W$, 通道数量是 D , 如果输入第 C 个通道的特征图, $F \in R^{H \times W \times C}$ 表示卷积核, $M \in R^{U \times V \times C}$ 表示输入, $O \in R^{R \times T \times D}$ 代表输出特征图。对于该层的第 i 个卷积核,对应的输出特征映射通道为:

$$O_{\dots,i} = \sum_{k=1}^C M_{\dots,k} * F_{\dots,k}^{(i)} \quad (7)$$

其中, $*$ 是二维卷积算子, $M_{\dots,k}$ 是 M 的第 k 个通道的尺寸为 $U \times V$ 的特征图, $F_{\dots,k}^{(i)}$ 代表 $F^{(i)}$ 的第 k 个通道的特征图,其尺寸为 $H \times W$ 。

对于一个卷积核 $F^{(i)}$, 一个特定点 y , 则输出 $O_{\dots,i}$ 可以由如下公式计算:

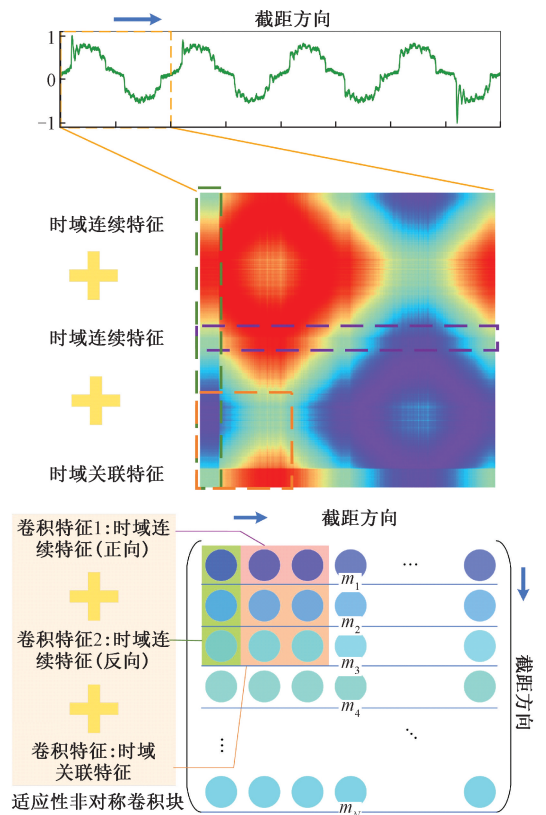


图 5 适应性非对称卷积块

Fig. 5 Adaptive asymmetric convolution block

$$y = \sum_{c=1}^C \sum_{h=1}^H \sum_{w=1}^W F_{h,w,c}^{(i)} X_{h,w,c} \quad (8)$$

其中, X 是输入 M 上相应的滑动窗口, 当两个卷积滑动滤波器产生的输出通道相加时, 若共同使用同样的卷积滑动窗口, 那么式(6)成立。

适应性卷积的设计初衷是为了更加有效的利用卷积层提取时域的深层信息。在图 5 的 3×3 卷积核中, 3×1 和 1×3 的卷积核是和 3×3 的卷积核兼容的。其中, 1×3 和 3×1 的卷积核用于获取单一数据点与其他数据点之间正弦角差值的连续时间信息, 3×3 的卷积核用于综合提取故障矩阵的数据关联信息。可以很容易的看出滑动窗口对应的卷积计算具有兼容性, 非对称的卷积核可以进行叠加计算。

该方法可以在不增加计算参数的情况下, 既能够有效挖掘一维信号的时间分布特征, 又可以增加卷积操作对电弧故障时域数据段关联数据的特征提取能力, 对比其他二维卷积方法, 可以有效提升电弧故障的识别准确率。

对于卷积神经网络来说, 其核心计算是卷积算子, 其通过卷积核从输入特征图学习到新特征图。从本质上讲, 卷积是对一个局部区域进行特征融合, 这包括空间上以及通道间的特征融合。对于通道维度的特征融合, 卷

积操作基本上默认对输入特征图的所有通道进行融合。由此,本模型在残差结构中嵌入多通道注意力机制,其优势在于关注通道之间的关系,希望模型可以自动学习到不同通道特征的重要程度,其结构如图 6 所示。

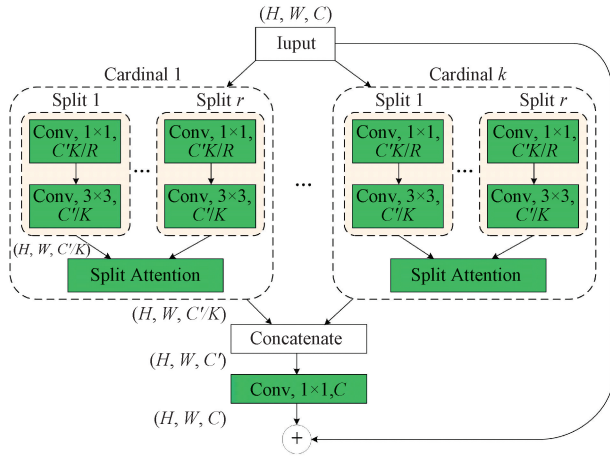


图 6 多通道注意力机制

Fig. 6 Multichannel attention mechanism

此方法将特征图分为多组,特征图组的数量由基数超参数 K 给出,将所得的特征图组称为基数组。引入了一个新的基数超参数 R ,该基数指基数组内的拆分数,因此要素组的总数为 $G=KR$ 。对每个单独的组应用一系列变换 $\{\mathcal{F}_1, \mathcal{F}_2, \dots, \mathcal{F}_c, \}$,则对于 $i \in \{1, 2, \dots, G\}$,每个组的中间量表示为 $U_i = \mathcal{F}_i(X)$ 。

通过对多个分割进行元素求和融合,可以获得每个基数组的组合表示。第 k 个基数群的表示如下:

$$\hat{U}^k = \sum_{j=R(k-1)+1}^{Rk} U_j \quad (9)$$

其中, $\hat{U}^k \in \mathbb{R}^{H \times W \times C/K}, k = 1, 2, \dots, K; H, W$ 和 C 表示块输出特征映射大小。嵌入信道统计的全局上下文信息可以通过跨空间维度 $s^k \in \mathbb{R}^{C/K}$ 的全局平均池计算。计算第 c 个如下:

$$s_c^k = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W \hat{U}^k(i, j) \quad (10)$$

基数群表示的加权融合 $V^k \in \mathbb{R}^{H \times W \times C/K}$ 是使用通道级软注意进行聚合的,其中每个特征映射通道都是使用分割上的加权组合生成的。第 c 个通道计算如下:

$$V_c^k = \sum_{i=1}^R a_i^k(c) U_{R(k-1)+i} \quad (11)$$

其中, $a_i^k(c)$ 表示软分配权重,定义如下:

$$a_i^k(c) = \begin{cases} \frac{\exp(\mathcal{G}_i^c(s^k))}{\sum_{j=1}^R \exp(\mathcal{G}_j^c(s^k))}, R > 1 \\ \frac{1}{1 + \exp(-\mathcal{G}_i^c(s^k))}, R = 1 \end{cases} \quad (12)$$

其中,映射 \mathcal{G}_i^c 表示 s^k 确定第 c 信道的每个分割的权重。

然后,将基数组表示形式沿通道维级联 $V = \text{Concat}\{V^1, V^2, \dots, V^k\}$ 。与标准残差块中一样,如果输入和输出特征图共享相同的形状,则使用快捷方式连接生成离散注意力机制模块的最终输出 $Y = V + X$ 。

本文所提多通道注意力模型引入多路表征、融合不同卷积核的特征;采用组卷积,将多路径结构转换为一个统一的操作;学习不同通道的权重系数进行组合,跨多个网络分支提供特征图。将通道上的注意力一般化为特征图组表示,可以使用统一的神经网络操作符进行模块化和加速。

3.2 识别结果分析

为了直观表达网络的神经网络的拟合结果,本文采用 t 分布改进非监督聚类方法 t -SNE^[17],通过该方法将测试集样本输入训练后的网络分析分类结果,进而实现模型的结果分析。利用 t -SNE 降维的网络输出结果如图 7 所示。




图 7 t -SNE 降维结果

Fig. 7 t -SNE dimension reduction result

从图 7 中可以看到不同负载的电弧故障类别的降维是具有不同分布的。大多数类别明显地彼此分离,而少量的点位于其他类的区域,是因为其特征与其他类的特征相似,图中已用圆圈框标注。进一步对测试集识别结果进行可视化,得到网络的分类混淆矩阵,如图 8 所示。

从混淆矩阵的结果可以看出,该网络的泛化性能较好,其识别率达到 99.95%,已满足电弧故障的识别要求。对比表 1 中各类负载对应的标签可知,仅有一个抑制性负载电弧故障(8)误判为正常工作(9)。

3.3 识别结果分析

为了验证适应性非对称卷积核的特征提取效果,本文对比了不同的卷积核权重对识别结果的影响,如表 3




图 8 分类结果混淆矩阵

Fig. 8 Classification result confusion matrix

所示。从表中数据可以看出,当卷积核的权重分别为 1/3 时,其准确率最高,为 99.5%。

表 3 适应性非对称卷积权重对比

Table 3 Comparison of adaptive asymmetric convolution weight

序号	Sqr_Conv	Ver_Conv	Hor_Conv	准确率/%
1	0.25	0.25	0.50	95.15
2	0.25	0.50	0.25	92.20
3	0.50	0.25	0.25	93.95
4	0.20	0.40	0.40	93.95
5	0.40	0.20	0.40	94.30
6	0.40	0.40	0.20	91.60
7	0.33	0.33	0.33	99.95

本文利用多通道的并行卷积、非对称的串行卷积和普通二维卷积 3 种训练方案训练电弧故障检测模型,其训练结果如表 4 所示。其中非对称卷积的权重为 1/3。通过对比表明,当采用 3×3 卷积核时,其训练结果准确率较高,而增加卷积核大小无法使训练模型有效关注到稀疏的卷积故障内容。但增加了适应性的非对称卷积算子后,其准确率与 3×3 非对称卷积核相同,均为 99.95%,证明了本文所提方法的有效性。

进一步的,将本文所用串联电弧数据输入到不同结构的卷积神经网络,得到其识别结果如表 5 所示。对比分析表明,更改结构并不能有效提升诊断模型的识别准确率,且网络的训练参数相对较多,会极大地增加诊断模型的训练时间和预测时间,说明本文所提网络可以实现串联电弧故障的有效检测。

表 4 适应性非对称卷积结果对比

Table 4 Comparison of adaptive asymmetric convolution result

预处理方案	卷积核大小	准确率/%	通道数比例
普通预处理	3×3	93.10	1
	5×5	90.55	
	7×7	78.00	
多通道卷积	3×3 1×3 3×1	90.35	1
	5×5 1×5 5×1	93.75	
	7×7 1×7 7×1	72.00	
适应性非对称兼容	3×3+1×3+3×1	99.95	1/3
	5×5+1×5+5×1	99.95	
	7×7+1×7+7×1	99.95	

表 5 不同神经网络识别结果对比

Table 5 Comparison of recognition results of different neural networks

模型	参数	准确率/%
ResNet18	7.0×10 ⁵	76.95
InceptionV1	2.9×10 ⁵	89.15
VGG16	2.8×10 ⁷	96.30
AA-ResNeSt(本文)	2.8×10 ⁵	99.95

4 系统构建

为了实现对所提模型的在线应用,本文采用基于 Python 语言的 Tensorflow2.4 框架开发,用于实现电弧故障格拉姆角差场矩阵信息的分类处理。其运行环境如表 6 所示。根据上述模型特点,采用一种基于 Python 语言的 Web 框架——Flask 框架来构建电弧故障数据在线验证的 API,实现验证算法和在线检测的初级功能。最后,利用 Docker 容器封装 Flask 应用,完成整个模型的在线部署环节。

表 6 模型在线部署环境

Table 6 Model online deployment environment

运行需求	设备或版本信息
CPU	AMD Ryzen 7 5800X
内存	32 G
显卡	NVIDIA RTX 3080 10 G
操作系统	Ubuntu 20.04

由于预测结果类别为 10 类,无需配置数据库,只需要在函数内部嵌入预测函数,即将输入的预测数据的预测结果进行降维处理,并将队列内的最大值索引匹配至类别列表处,以便导出结果。本文设置访问本机 IP127.0.0.1,端口为 5000,在浏览器中输入 127.0.0.1:5000 可以完成部署。

所设计终端界面包含提交和清除功能,可以在服务器端进行实时的在线验证。该界面如图 9 所示。

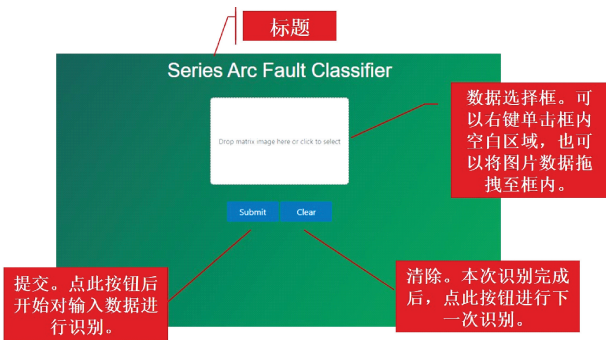


图 9 电弧故障检测系统界面

Fig. 9 Arc fault detection system interface

在 PC 端可以通过双击边框导入电弧故障的 GADF 编码矩阵,通过容器内部加载已训练的模型结构及参数,获取输入矩阵的实际标签,并加载至预测结果中。

以阻性电弧故障数据为例,系统对其识别结果界面如图 10 所示。将一张经过 GADF 编码后的串联电弧故障二维矩阵拖入所选框,点击 submit,系统后会快速响应识别,并在下方显示判断结果,以此来实现对串联电弧故障的识别可视化。

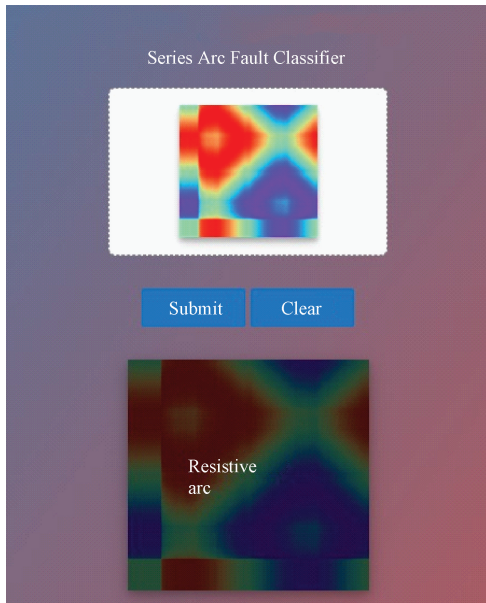


图 10 系统识别结果界面

Fig. 10 Interface for the system to identify result

电弧故障识别终端的响应时间如表 7 所示。从表中数据可以看出,在正确获取输入类别的同时,终端的响应时间相对较低,均低于 25 ms。对比不同的负载相应时间可以看出,阻性电弧故障的响应时间相对较高,主要是因为故障信息较为丰富,在推理过程中会占用更多的时间进行相应,其他类别的故障均可以控制在 20 ms 左右进行响应。

表 7 终端响应时间

Table 7 Terminal response time

负载类型	电弧故障/ms	正常工作/ms
阻性	21.5	21.8
感性	21.8	22.0
容性	23.5	20.7
开关性	19.8	20.5
抑制性	20.0	20.7

在与近期的交流电弧故障诊断方法比较中,从方法框架、特征提取方法、故障种类、检测精度等方面进行对比,对本文所提的 AA-ResNeSt 方法进行评价,如表 8 所示。在诊断能力方面,本文所提模型能够同时检测实验线路中的点接触和碳化路径电弧故障实验,其准确率超过 99.9%,同时,本文所提模型可以有效验证屏蔽性负载和抑制性负载,增加了负载的验证类别。对比方法 1^[18]和方法 2^[19],无需对电弧故障进行人工特征提取,仅需要对数据进行适应性排布便可提高识别精度。与 Chu 等^[20]的卷积神经网络方法相比,本文所提模型降低了实际过程的采样率,可以在数据输入过程中有效降低参数量。

通过上述内容表明,本文所提的验证终端能够有效的检测输入对象的分类结果,有效证明了拆分注意力模型对于电弧故障编码矩阵的优秀的泛化性能,也证明了在线上部署在线的电弧故障监测平台的可能性。

5 结 论

本文提出了一种基于适应性非对称神经网络电弧故障诊断模型。在数据处理方面,采用一种更改坐标系的时域数据处理方法——格拉姆角差场,通过该算子可

表 8 诊断方案对比

Table 8 Comparison of diagnostic schemes

序号	1 ^[18]	2 ^[19]	3 ^[20]	4 (AA-ResNeSt)
描述	FFT、CZY 和 DB4 与全连接神经网络的电弧故障诊断	基频分量与全连通神经网络	高频耦合传感器与卷积神经网络的设计	时域 GADF 编码与适应性非对称卷积核改进的离散注意力卷积神经网络
特征提取	由 FFT、CZY 和 DB4 组合特征数据	FFT 计算得到频谱分布	高频耦合传感器提取高频信号	模型自适应计算
负载类型	阻性、屏蔽性	阻性、感性、容性、开关性	阻性、屏蔽性、开关性	阻性、感性、容性、屏蔽性、开关性
故障诊断结果	99.85%	99.22% (3 919/3 950)	98.36% (1 377/1 400)	99.95% (1 999/2 000)

以将某一数据点涵盖的内容扩大,增加故障数据点的空间占有率,有效地映射数据点之间的空间关系,便于二维卷积神经网络的特征提取。

针对时域变换矩阵的数据分布特征和卷积核的可加性,本文采用适应性非对称的卷积核。利用其适应性提取矩阵内的连续时间特征、时间关联特征和空间特征,有效地提升了网络对低采样率故障的有效诊断。同时,在残差神经网络的基础上加入了多通道注意力机制,使得通道之间的信息交互成为可能,进一步提高了网络的准确率。通过验证表明,改进网络在降低模型参数的同时具有良好的泛化性能,可以有效地识别绝大多数工况下的串联电弧故障。

参考文献

- [1] FERRACUTI F, SCHWEITZER P, MONTERIU A. Arc fault detection and appliances classification in AC home electrical networks using recurrence quantification plots and image analysis [J]. *Electric Power Systems Research*, 2021, 201: 107503.
- [2] YIN ZH D, WANG L, ZHANG Y J, et al. A novel arc fault detection method integrated random forest, improved multi-scale permutation entropy and wavelet packet transform[J]. *Electronics*, 2019, 8(4): 396.
- [3] ESLAMI M, JANNATI M, TABATABAEI S S. An improved protection strategy based on PCC-SVM algorithm for identification of high impedance arcing fault in smart microgrids in the presence of distributed generation[J]. *Measurement*, 2021, 175: 109149.
- [4] HAN X Y, LI D K, HUANG L Z, et al. Series arc fault detection method based on category recognition and artificial neural network [J]. *Electronics*, 2020, 9(9): 1367.
- [5] JIANG J, LI W, WEN ZH, et al. Series arc fault detection based on random forest and deep neural network[J]. *IEEE Sensors Journal*, 2021, 21(15): 17171-17179.
- [6] 褚若波,张认成,杨凯,等. 基于多层卷积神经网络的串联电弧故障检测方法[J]. *电网技术*, 2020, 44(12): 4792-4798.
CHU R B, ZHANG R CH, YANG K, et al. A series arc fault detection method based on multi-layer convolutional neural network [J]. *Power System Technology*, 2020, 44(12): 4792-4798.
- [7] 余琼芳,胡亚倩,杨艺. 基于小波特征及深度学习的故障电弧检测[J]. *电子测量与仪器学报*, 2020, 34(3): 100-108.
YU Q F, HU Y Q, YANG Y. Arc fault detection based on wavelet feature and deep learning [J]. *Journal of Electronic Measurement and Instrumentation*, 2020, 34(3): 100-108.
- [8] 张婷,王海淇,张认成,等. 基于自归一化神经网络的电弧故障检测方法[J]. *仪器仪表学报*, 2021, 42(3): 141-149.
ZHANG T, WANG H Q, ZHANG R CH, et al. An arc fault detection method based on the self-normalized convolutional neural network [J]. *Chinese Journal of Scientific Instrument*, 2021, 42(3): 141-149.
- [9] YANG K, CHU R B, ZHANG R CH, et al. A novel methodology for series arc fault detection by temporal domain visualization and convolutional neural network[J]. *Sensors*, 2020, 20(1): 162.
- [10] WANG Y, HOU L M, PAUL K C, et al. ArcNet: Series AC arc fault detection based on raw current and convolutional neural network[J]. *IEEE Transactions on Industrial Informatics*, 2021, 18(1): 77-86.
- [11] ZHANG T, ZHANG R CH, WANG H Q, et al. Series AC arc fault diagnosis based on data enhancement and adaptive asymmetric convolutional neural network [J]. *IEEE Sensors Journal*, 2021, 21(18): 20665-20673.
- [12] 全钰,庞新宇,魏子涵. 基于 GADF-CNN 的滚动轴承故障诊断方法[J]. *振动与冲击*, 2021, 40(5): 247-253,260.
TONG Y, PANG X Y, WEI Z H. Fault diagnosis method of rolling bearing based on GADF-CNN [J]. *Vibration and Shock*, 2021, 40(5): 247-253,260.
- [13] GOODFELLOW I, BENGIO Y, COURVILLE A. *Deep Learning*[M]. The MIT Press, 2016.
- [14] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. *Nature*, 2015, 521(7553): 436.
- [15] HE K M, ZHANG X Y, REN SH Q, et al. Deep residual learning for image recognition [C]. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas: USA, 2016: 1063-6919.
- [16] 全国低压电器标准化技术委员会. 电弧故障保护电器 (AFDD)的一般要求;GB/T 31143—2014[S]. 北京: 中国标准出版社, 2014.
National technical committee on low voltage apparatus of standardization administration. General requirements of arc fault protection appliances (AFDD): GB/T 31143-2014 [S]. Beijing: Standards Press of China, 2014.
- [17] LAURENS V D M, HINTON G. Visualizing data using t-SNE[J]. *Journal of Machine Learning Research*, 2008, 9(2605): 2579-2605.
- [18] VU H D, CALDERON E, SCHWEITZER P, et al. Multi criteria series arc fault detection based on supervised feature selection [J]. *International Journal of Electrical Power & Energy Systems*, 2019, 113: 23-34.

- [19] WANG Y K, ZHANG F, ZHANG X H, et al. Series AC arc fault detection method based on hybrid time and frequency analysis and fully-connected neural network [J]. IEEE Transactions on Industrial Informatics, 2019, 15(12): 6210-6219.
- [20] CHU R B, SCHWEITZER P, ZHANG R CH. Series AC arc fault detection method based on high-frequency coupling sensor and convolution neural network [J]. Sensors, 2020, 20(17): 4910.

作者简介



张婷, 2019 年于青岛农业大学获得学士学位, 现为华侨大学硕士研究生, 主要研究方向为电弧故障检测技术。

E-mail: ztseven@stu.hqu.edu.cn

Zhang Ting received her B. Sc. degree from Qingdao Agricultural University in 2019.

Now she is a M. Sc. candidate at Huaqiao University. Her main

research interest includes arc fault detection technology.



张认成(通信作者), 1984 年于西安科技大学获得学士学位, 1989 年于合肥工业大学获得硕士学位, 1998 年于江苏理工大学获得博士学位, 现为华侨大学教授, 主要研究方向为电弧故障检测技术及装置、智慧消防技术。

E-mail: phzzrc@hqu.edu.cn

Zhang Rencheng (Corresponding author) received his B. Sc. degree from Xi'an University of Science and Technology in 1984, received his M. Sc. degree from Hefei University of Technology in 1989 and received his Ph. D. degree from Jiangsu University of Science and Technology in 1998. Now he is a professor at Huaqiao University. His main research interests include arc fault detection technology and equipment and intelligent fire technology.