

# 基于时频色谱图的串联故障电弧识别 \*

王毅<sup>1</sup>,罗章权<sup>1</sup>,李松浓<sup>2</sup>,陈涛<sup>2</sup>,侯兴哲<sup>2</sup>,付秀元<sup>3</sup>

(1.重庆邮电大学 通信与信息工程学院,重庆 400065;2.国网重庆市电力公司电力科学研究院,重庆 400014;

3.国家电投集团数字科技有限公司,北京 100080)

**摘要:**由于电力线老化损坏以及连接处松动会产生故障电弧,可能会意外引起严重的电气火灾。不同类型的负载所引起的故障电弧存在差异,导致住宅区故障电弧识别变得困难。提出了一种基于时频图和深度卷积神经网络的串联故障电弧识别的方法。通过故障电弧实验采集了负载正常工作和故障电弧的电流数据。单个负载半周期电流数据将通过连续小波变换转换为三维特征图像,然后将这些图像输入到改进的深度卷积神经网络中进行训练、测试。实验结果表明,单个负载正常和电弧状态识别的精度在 99.31%,对多个负载工作状态的识别准确率平均可以达到 99.2%。

**关键词:**串联故障电弧;时频图;深度卷积神经网络

中图分类号: TM501.2

文献标识码: A

DOI: 10.16157/j.issn.0258-7998.212349

中文引用格式: 王毅,罗章权,李松浓,等. 基于时频色谱图的串联故障电弧识别[J]. 电子技术应用, 2022, 48(8): 70–75.

英文引用格式: Wang Yi, Luo Zhangquan, Li Songnong, et al. Identification of series fault arc based on time-frequency chromatogram[J]. Application of Electronic Technique, 2022, 48(8): 70–75.

## Identification of series fault arc based on time-frequency chromatogram

Wang Yi<sup>1</sup>, Luo Zhangquan<sup>1</sup>, Li Songnong<sup>2</sup>, Chen Tao<sup>2</sup>, Hou Xingzhe<sup>2</sup>, Fu Xiuyuan<sup>3</sup>

(1. Communication and Information Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China;

2. Electric Power Research Institute of State Grid Chongqing Electric Power Company, Chongqing 400014, China;

3. State Power Investment Corporation Digital Technology Co., Ltd., Beijing 100080, China)

**Abstract:** The aging and damage of the power line and the loose connection will cause a fault arc, which may accidentally cause a serious electrical fire. There are differences in arc faults caused by different types of loads, which makes it difficult to identify arc faults in residential areas. This paper presents a method of series fault arc recognition based on time-frequency diagram and deep convolutional neural network. Through the arc fault experiment, the current data of the normal load and the fault arc are collected. The single load half-cycle current data will be converted into three-dimensional feature images through continuous wavelet transform(CWT), and then these images will be input into the improved convolutional neural network(CNN) for training and testing. The experimental results show that the accuracy of identifying the normal and arc status of a single load is above 99.31%, the accuracy of identifying the working status of multiple loads can reach 99.2% on average.

**Key words:** series fault arc; time-frequency diagram; convolutional neural network

## 0 引言

故障电弧是住宅区电气线路火灾的最重要的原因之一,它能产生极高的温度,并容易引燃周围的可燃材料<sup>[1]</sup>。据应急管理部消防救援局最新数据的统计,2020 年全国共接报火灾 25.2 万起,直接财产损失 40.09 亿元。其中,电气引发的较大火灾 36 起,在各类火灾中排名第一,高达 55.4%,大部分电气火灾是由故障电弧引起的。因此,识别故障电弧对减少火灾发生,提高居民财产安全有着重大的意义。

随着国内外对故障电弧火灾危险性认识的不断加

深,国内外分别制定了 GB14287 与 UL1699 标准<sup>[2-3]</sup>,标志着国内外故障电弧检测技术的发展进入了一个新阶段<sup>[4]</sup>。近年来,许多学者已经开始研究故障电弧。一些学者通过热、光、电磁辐射、电压等信息进行特征进行故障电弧检测<sup>[5-7]</sup>。由于故障电弧的位置是未知的,因此很难通过以上方法对住宅区故障电弧进行检测。相反,故障电弧电流测量的方便性使其成为了故障电弧检测的理想特征。Jiang<sup>[8]</sup>等人通过主成分分析算法将提取到的 9 个电流信号的时域和频域特征降维为 3 个特征,结合支持向量机(Support Vector Machine, SVM)进行故障电弧识别;龙官微<sup>[9]</sup>等人将电流信号的傅里叶系数、梅尔倒谱系数和小波特征作为特征量输入到深层神经网络,用

\* 基金项目:重庆市自然科学基金(cstc2016jcyjA0214)

于识别正常和故障电流; Wang<sup>[10]</sup>等人在通过电流的谐波分量占比、时域的积分、方差等特征对负载类型识别之后,再结合不同的神经网络进行故障电弧识别; 鲍光海<sup>[11]</sup>等人通过分析电弧熄灭重燃时高频剩余磁通的耦合信号,利用高阶统计量工具计算出耦合信号的峭度值并得出统一的阈值进行电弧识别。

以上都是采用简单的神经网络结构,这些结构都不能自动提取特征,需要人为地提取特征,再输入到模型中进行训练。但是,负载类型与连接方式多种多样,仅仅通过人为方式主观地提取特征,会使得故障电弧识别稳定性较差。余琼芳<sup>[12]</sup>等人基于 AlexNet 网络结构对故障电弧检测做了初步的尝试,预测准确率为 85% 左右; 其随后做了进一步的改进优化,识别率在 95.58% 左右<sup>[13]</sup>。本文通过深度学习模型网络对串联故障电弧进行检测,通过小波时频色谱图结合优化的卷积神经网络自动提取特征进行识别,并且在识别的精度上有了一定的提高。

## 1 电弧实验与数据采集

### 1.1 采集装置设计

串联电弧采集装置主要是根据 UL1699 国际标准的参数进行设计而成。在 220 V 交流电源供电下,通过调节铜杆和碳杆之间的距离以产生电弧,控制开关,接入不同类型的单个负载或者多个负载同时接入的正常工作和故障电弧状态采集并存储电流数据。实验装置如图 1 所示。

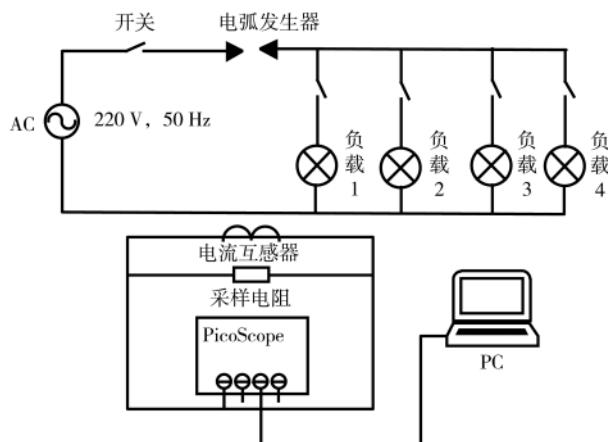


图 1 故障电弧采集装置

### 1.2 所需设备

**电弧发生器:** 是根据标准 IEC 62606 : 2013 标准设计的,它包括一个基座和两个电极,两个电极分别由碳棒和铜棒组成。

**电流互感器:** 输入 0~60 A, 输出 0~60 mA, 工作频率最高达 200 kHz, 精度±0.5%。

**采样电阻:** 100 Ω。

**示波器:** PicoScope 5442A, 带宽为 60 MHz, 采样率可

达到 1 GS/s, 垂直分辨率最高可以达到 16 bit。

PC : CPU 型号为 Intel® Core™ i3 - 10100F CPU@3.60 GHz, CPU 核为 8 核。

显卡: 型号为 RTX 2080Ti, 显存为 11 GB。

家用电器负载多种多样,但是相同类型的负载波形在时域和频域具有很大的相似特性。因此,选择了几种典型的负载进行了实验,相应负载的类型参数如表 1 所示。

表 1 典型电器负载类型及参数

负载编号	负载类型	负载名称	负载功率/W
1	电阻型	白炽灯	200
2	开关型	笔记本	60
3	开关型	调光灯	25
4	电感型	电吹风一挡	2 000
5	电阻型	电吹风二挡	2 000
6	电感型	电烙铁	60
7	电感型	电风扇	60
8	电阻型	烘干机	2 000

### 1.3 故障电弧电流数据采集

通过 PicoScope 连接电脑,并设置 100 kHz 的采样频率,采集并保存有效的实验波形数据。部分负载的实验波形数据如图 2 所示,前 2 个周期表示负载正常工作时的电流波形,后 2 个周期表示负载发生电弧故障时的电流波形。在图 2(b)和图 2(c)中,烘干机和白炽灯在正常情况下波形中没有尖峰。电弧发生故障时,电流具有明显的平肩现象。因为当电弧的间隙电压超过击穿电压,空气被击穿,立即产生电弧,之后持续燃弧,电流随电压而变化;当电弧电压小于击穿电压时,电弧熄灭,电流变为零,不断地循环重复就产生了平肩现象。图 2(a)中,电脑由于电容充放电特性,在正常情况下,会出现平肩现象。当发生电弧时,主要的电弧现象特征存在脉冲。对于电风扇负载正常工作时,波形是正弦波形状,发生电弧时,也是出现大量的脉冲。从图 2(e)和图 2(f)中可以得到,当多个负载并联同时工作时,正常状态下的电流波形是几个负载电流的叠加波形,当发生故障电弧时,会出现负载发生故障时的混合特征。

## 2 构造时频图像

### 2.1 连续小波变换

时间和频率是用来描述信号的两个最重要的特性。家用负载的线路发生故障时,电流会发生畸变,也主要体现幅值与频率的变化中。时频分析得出时间和频率的联合分布,能够反映信号能量中时间和频率的变换。此外,从统计角度来看,时频分布包含信号的完整信息,是信号识别的有效特征。连续小波变换的时频分布是一种常见的时频分布。CWT 的表达式如下:

$$\text{CWT}_x^{\psi}(\tau, s) = \frac{1}{\sqrt{s}} \int_{-\infty}^{+\infty} x(t) \Psi\left(\frac{t-\tau}{s}\right) dt \quad (1)$$

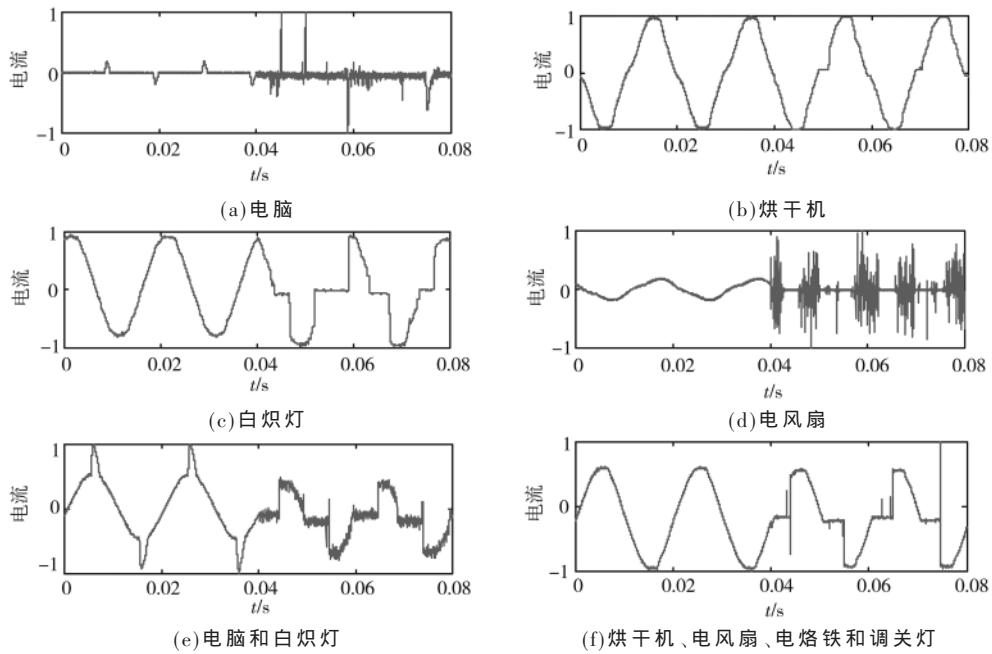


图 2 负载正常状态和故障状态下的电流波形

其中,  $x(t)$  表示原始信号,  $s$  为伸缩因子,  $\tau$  为平移因子,  $\Psi(t)$  表示小波母函数。针对故障电弧波形, 一般采用连续的小波母函数会使得分辨率更高。Morlet 小波能够得到平滑连续的小波振幅, 且具有虚部可以对相位有着更好的表达。因此, 选择 Morlet 小波对信号进行时频变换。

## 2.2 生成时频图

将采集到的有效电流数据导入到 MATLAB 中, 首先对数据进行归一化处理, 其次利用 MATLAB2019b 中 CWT 函数生成时频图。烘干机的时频色谱图如图 3 所示。图 3(b)中, 横坐标表示时间, 纵坐标表示频率, 颜色深浅表示幅值大小。当负载正常工作时, 电流没有发生畸变, 所对应的时频色谱图在高频分段主要是背景色蓝色, 低频分段出现其他颜色。说明正常工作时电流的高频分量几乎没有, 主要集中在低频分量上。当负载发生电弧故障时, 电流发生畸变现象, 与之对应的时频色谱

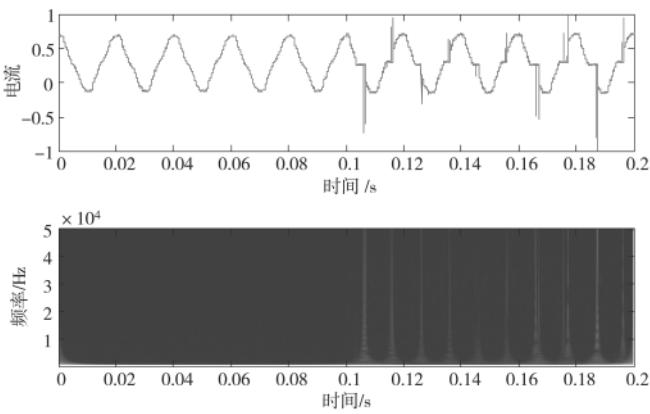


图 3 负载电流的时域波形和时频图

图不仅在低频分段出现与背景色不同颜色, 也出现在高频分段。说明负载发生故障时, 电流会出现高频分量。通过时频色谱图也可以看出, 时频图是信号的频率和幅值随时间的变化, 相比于原始信号更能完整地表达信号特征。

根据 UL1699 故障电弧检测标准<sup>[3]</sup>, 在 0.5 s 的时间内检测到 8 个半个电弧周期则视为线路发生电弧故障。对采集的不同电器不同工作状态有效电流信号进行分析, 选择半个周期为一组信号, 首先对其进行归一化处理, 然后进行 CWT 时频分析, 生成时频色谱图。各个电器的不同工作状态的时频色谱图如图 4 所示。从图中可以看出, 正常和电弧故障二者的时频色谱图都有着明显的区别。

## 3 深度卷积神经网络的基本模型

最近, 卷积神经网络已成为视觉任务的主要机器学习方法, 而 CNN 由于其强大的能力以及对平移和失真的不变性, 因此成为许多图像分类任务的最新模型<sup>[14]</sup>。CNN 的最大特色是能够同时提取有效特征并实现智能分类, 从而解决了特征提取和分类器选择难度大的问题。如图 5 所示, CNN 的大致模型是首先对输入的图片卷积池化等运算进行特征提取; 然后将特征输入到全连接层, 对这些特征进行整合分类; 最后输出预测结果。通常情况下为了提高准确度, 一般会有多层卷积层、池化层和全连接层。根据自己的任务设置适合的层数。

### 3.1 卷积

用  $X_i$  表示第  $i$  层的输入数据, 其中  $X_0$  表示最初的输入。卷积公式如下:

$$H_i = f(X_{i-1} * W_i + b_i) \quad (2)$$

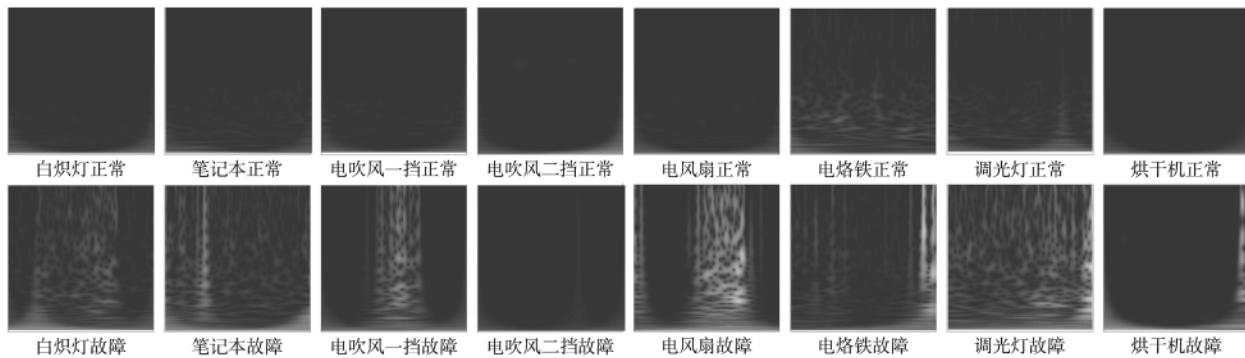


图 4 各个负载正常和故障的时频图

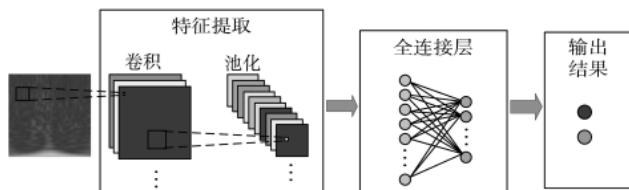


图 5 神经网络结构图

其中,  $H_i$  表示第  $i$  层卷积的结果, \* 表示卷积运算,  $W_i$  表示第  $i$  层卷积层的权值向量,  $b_i$  表示偏移量,  $f(x)$  表示这一层的激活函数。

### 3.2 池化

当前, 平均池化和最大池化是两种最常用的池化方法。由于最大池化是在池化窗口中选择最大值以形成输出特征, 它可以更好地保留有效信息并减少数据处理量, 因此它已成为现阶段使用最广泛的池化方法。则:

$$X_i = \max \text{pooling}(H_i) \quad (3)$$

其中,  $X_i$  表示池化的结果。

### 3.3 计算损失函数

通过多层卷积池化后得到特征图, 再将得到的矩阵图扩展为特征矢量输入到全连接层。通过 softmax 函数对 CNN 的输出进行归一化, 并计算损失函数。常见的损失函数有均方损失函数、交叉熵损失函数等。由于交叉熵损失函数当误差较大时, 权重更新速度快; 当误差小时, 权重更新慢, 因此选择此函数作为损失函数。一般情况 CNN 同时训练多个样本, 所以用单个样本的损失函数, 即每次训练的损失函数的均值进行衡量模型。其表达式如下:

$$J(W, b) = -\frac{1}{n} \sum_{i=1}^n [y_i \log \hat{y}_i + (1-y_i) \log (1-\hat{y}_i)] \quad (4)$$

其中,  $J(W, b)$  表示损失函数,  $n$  表示每次输入样本的数量,  $y_i$  和  $\hat{y}_i$  分别表示第  $i$  个样本真实值和预测值。

### 3.4 反向传播算法更新权重

反向传播算法的目标是找到最佳权重  $W$  和偏差  $b$  以最小化损失函数。根据式(4),  $J(W, b)$  是与  $W, b$  相关的函数, 因此反向传播算法根据负向梯度的方向更新权

重(即权重更新方法采用梯度下降算法)。计算公式如下:

$$W' = W - \alpha \frac{\partial J}{\partial W} \quad (5)$$

$$b' = b - \alpha \frac{\partial J}{\partial b} \quad (6)$$

式中,  $\alpha$  表示步长,  $\frac{\partial J}{\partial W}$  和  $\frac{\partial J}{\partial b}$  表示  $J(W, b)$  的偏导。从而可以通过反向传播算法来更新权重。最后设置一定的次数重复以上步骤, 得到训练后的 CNN。基本模型参数设置如表 2 所示。

表 2 模型参数设置

输入	图层类型	卷积核大小	卷积核的数量	输出
100×100×3	卷积层 1	3×3	32	100×100×32
100×100×32	池化层 1	2×2	32	50×50×32
50×50×32	卷积层 2	3×3	64	50×50×64
50×50×64	池化层 2	2×2	64	25×25×64
25×25×64	卷积层 3	3×3	64	25×25×64
25×25×64	池化层 3	2×2	64	12×12×64
12×12×64	全连接层 1			10×4×1
1024×1	全连接层 2			512×1
512×1	全连接层 3			2×1

## 4 模型优化

### 4.1 激活函数的选择

激活函数的主要作用是提供网络的非线性建模能力。如果没有激活函数, 那么该网络仅能够表达线性映射, 此时即便有再多的隐藏层, 其整个网络跟单层神经网络也是等价的。加入了激活函数之后, 深度神经网络才具备了分层的非线性映射学习能力<sup>[15]</sup>。ReLU 函数的表示较为稀疏, 因此 ReLU 函数通常用作 CNN 的激活函数。ReLU 函数的公式为:

$$f(x) = \max(0, x) \quad (7)$$

### 4.2 优化算法选择

如果超参数设置存在偏差, 则在使用随机梯度下降方法训练网络时, 很容易陷入局部最小值。为了解决这个问题, 比较 4 个优化算法, 分别是 SGD、Momentum、Adagrad 方法、Adam 方法, 它们对 CNN 的识别效果有影

响。图 6 显示了 4 种优化算法的准确度值曲线和损失函数曲线。从图 6 可以看出,SGD 和 Momentum 的识别精度在迭代开始时表现出很大的振荡,并且当迭代达到一定次数时,精度仍在不同程度上波动,这表明收敛速度太慢。虽然 Adagrad 算法可以快速收敛,损失函数曲线的总体下降趋势比较稳定。但是,当迭代达到第 20 次时,识别精度和损失函数的值会突然改变。相比之下,采用 Adam 算法的 CNN 的整体识别精度为 98.6%,同时收敛速度最快。它的损耗值迅速减小,并且保持稳定,没有振荡和突变。Adam 算法使得本文的 CNN 模型可以兼顾识别精度和收敛速度,使其在故障电弧识别中更具优势。

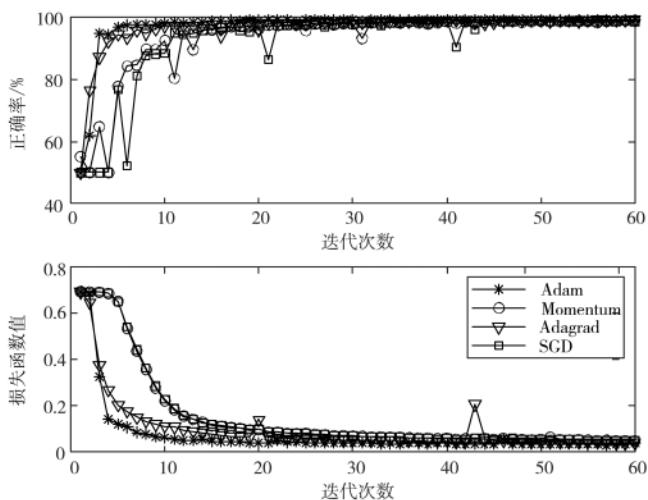


图 6 不同算法的正确率和损失函数曲线

#### 4.3 Dropout 和正则化

通常为了防止过度拟合,在传统的机器学习中提前停止是最简单有效的方法。一旦在验证数据集上性能开始下降,它将停止训练。在许多情况下,它可以有效防止过度拟合。

但是,如果数据集太小而不具有代表性,则很容易过度拟合验证数据集。减少过度拟合的另一种方法是在训练准则中添加正则项<sup>[16]</sup>。Dropout 是解决上述问题的好方法。它可以防止过度拟合,从本质上讲,它提供了一种方法来近似组合许多不同神经网络的效果。这里的 Dropout 是指在训练阶段均以一定的概率随机将该神经元权重置零。将 L2 正则化与 Dropout 结合起来,设置正则化参数为 0.001,Dropout 参数为 0.5。从图 7 中可以看出,正则化和 Dropout 两者结合起来的准确率比一般的 CNN 要高。

将模型优化后,对每个负载的识别正确性进行验证。将每种类型的测试集输入到网络中,负载识别率如表 3 所示。从表 3 中可以看出,对白炽灯、笔记本、电烙铁、电风扇,本文的算法的识别率达到 99.5% 以上,对于其他负载类型的最低的也能达到 97.67%,平均识别率达到 99.31%。

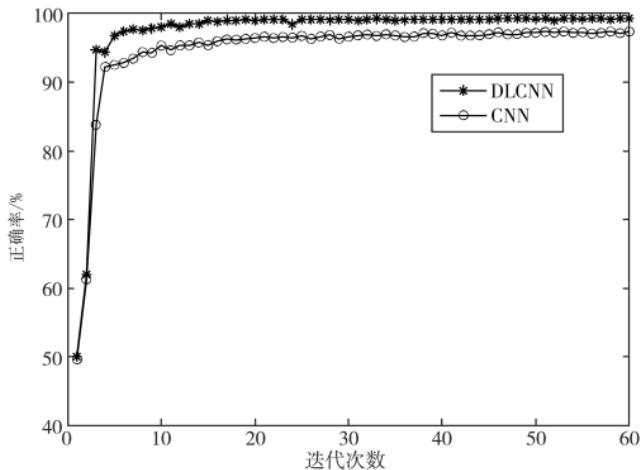


图 7 正确率曲线

表 3 单个负载识别率

负载	正常数据/个		故障数据/个		正确率/%
	训练集	测试集	训练集	测试集	
白炽灯	700	300	700	300	99.66
笔记本	700	300	700	300	99.83
调光灯	700	300	700	300	99.16
电吹风一挡	700	300	700	300	99.33
电吹风二挡	700	300	700	300	97.67
电烙铁	700	300	700	300	99.66
电风扇	700	300	700	300	99.83
烘干机	700	300	700	300	99.33

由于在实际情况中,一条干路上可能连接着多个用电负载。为了验证模型对故障电弧具有很强的检测能力,本文将没有经过训练的多负载并联的故障电弧进行识别。每种类型 300 个正常数据和 300 个故障数据进行测试,识别率如表 4 所示。从表中可以看出,在多负载的情况下,该模型的平均识别率高达 99.2%。说明本文的方法也能够对多负载故障电弧进行识别,从而能够减少很大的训练成本,对故障电弧检测有着一定的研究意义。

表 4 多个负载识别率

组合类型	正确率/%
笔记本和电烙铁	99.83
电风扇和电烙铁	99.5
电吹风 1 挡和白炽灯	99.33
电吹风 2 挡和白炽灯	98
烘干机、电风扇、电烙铁和调光灯	99.33

#### 4.4 方法对比

通过与近期文献中相关方法对比,从原理、适用范围、准确率等方面对本文方法进行了评价,如表 5 所示。

从表 5 中可以看出,文献[13]是通过小波变换结合原始波形作为输入到模型中进行训练和识别,但是没有对模型的开关型负载以及多负载发生故障电弧进行测

表 5 识别方法的对比

方法	原理	适用范围	准确率/%
文献[13]	将小波分量波形和原 始波形输入到 AlexNet 模型中训练	电阻型负载、 电感型负载、 阻感型负载、 无开类型和 多个负载类型	95.58
文献[10]	时域和频域特征进 行负载类型分类,再 输入到不同的网络中 训练	电阻型负载、 电感型负载、 阻感型负载、 无多个负载类型	99.22
本文	通过小波变换获取具 有时频特征的色谱 图,再输入到 CNN 中 并进行优化	电阻型负载、 电感型负载、 开关型负载、 多个负载类型	99.25

试验证。文献[10]中,首先要进行负载类型分类,然后根据分类结果进行电弧识别,那就要满足分类必须准确率达到100%;但是在实际中,如果受到环境或者负载变化的影响,可能对分类结果造成影响,从而导致故障电弧精度受到严重的影响。本文的方法不仅对多负载等多种混合型进行测试验证,而且在检测精度上也相比于其他两种方法要高。

## 5 结论

为了能够有效地研究串联故障电弧,本文首先搭建了一个实验平台,采集正常和发生故障电弧下的电流波形;其次,提出了利用电流波形的时频色谱图获取时域和频域的信息,设计了深度卷积神经网络,并通过Adam算法、Dropout、L2正则化的方法优化了传统的模型;最后,将该方法用于对不同的工作状态的负载进行自动特征提取与识别。实验结果证实了本文提出的方法在单个负载串联故障电弧检测的准确性。如果多个负载同时工作发生故障电弧时,该方法也能对其进行有效的识别,有效地减少了训练成本,说明了本研究对故障电弧的检测具有良好的通用性和可靠性。

## 参考文献

- [1] QU N,WANG J,LIU J,et al.An arc fault detection method based on current amplitude spectrum and sparse representation[J].IEEE Transactions on Instrumentation and Measurement,2019,68(10):3785–3792.
- [2] GB 14287.4–2014,电气火灾监控系统第4部分:故障电弧探测器[S].2014.
- [3] Underwriters Laboratories Inc.ANSI 1699 UL standard for safety for arc-fault circuit-interrupters[S].Third Edition,2017.
- [4] 张磊.故障电弧的识别及防护方法的研究[D].青岛:青岛理工大学,2015.
- [5] XIONG Q,JI S,ZHU L,et al.A novel DC arc fault detection

method based on electromagnetic radiation signal[J].IEEE Trans. Plasma Sci.,2017,45(3):472–478.

- [6] ZHAO S,WANG Y,NIU F,et al.A series DC arc fault detection method based on steady pattern of highfrequency electromagnetic radiation[J].IEEE Trans. Plasma Sci.,2019,47(9):4370–4377.
- [7] KIM J C,LEHMAN B,BALL R.Series AC arc fault detection using only voltage waveforms[C]//Proceedings of the 2019 IEEE APEC. Anaheim,CA,USA:IEEE,2019:2385–2389.
- [8] JIANG J,WEN Z,ZHAO M,et al.Series arc detection and complex load recognition based on principal component analysis and support vector machine[J].IEEE Access,2019,7:47221–47229.
- [9] 龙官微,穆海宝,张大宁,等.基于多特征融合神经网络的串联电弧故障识别技术[J].高电压技术,2021,47(2):463–471.
- [10] WANG Y,ZHANG F,ZHANG X,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.
- [11] 鲍光海,江润.基于磁通不对称分布的串联电弧故障检测研究[J].仪器仪表学报,2019,40(3):54–61.
- [12] 余琼芳,黄高路,杨艺,等.基于AlexNet深度学习网络的串联故障电弧检测方法[J].电子测量与仪器学报,2019,33(3):145–152.
- [13] 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.
- [14] 张顺,龚怡宏,王进军.深度卷积神经网络的发展及其在计算机视觉领域的应用[J].计算机学报,2019,42(3):453–482.
- [15] 裴航.基于模糊神经网络的电梯电气故障诊断研究[D].唐山:华北理工大学,2019.
- [16] 李健伟,曲长文,彭书娟,等.基于卷积神经网络的SAR图像舰船目标检测[J].系统工程与电子技术,2018,40(9):1953–1959.

(收稿日期:2021-11-17)

## 作者简介:

王毅(1981-),男,博士,副教授,主要研究方向:智能电网用电信息采集系统、电弧故障检测。

罗章权(1996-),通信作者,男,硕士研究生,主要研究方向:电弧故障检测,E-mail:1345605503@qq.com。

李松浓(1980-),男,博士,高级工程师,主要研究方向:用电信息采集系统。



扫码下载电子文档

## 版权声明

经作者授权，本论文版权和信息网络传播权归属于《电子技术应用》杂志，凡未经本刊书面同意任何机构、组织和个人不得擅自复印、汇编、翻译和进行信息网络传播。未经本刊书面同意，禁止一切互联网论文资源平台非法上传、收录本论文。

截至目前，本论文已经授权被中国期刊全文数据库（CNKI）、万方数据知识服务平台、中文科技期刊数据库（维普网）、DOAJ、美国《乌利希期刊指南》、JST 日本科技技术振兴机构数据库等数据库全文收录。

对于违反上述禁止行为并违法使用本论文的机构、组织和个人，本刊将采取一切必要法律行动来维护正当权益。

特此声明！

《电子技术应用》编辑部

中国电子信息产业集团有限公司第六研究所