

DOI: 10.19650/j.cnki.cjsi.J2007251

# 基于自归一化神经网络的电弧故障检测方法\*

张婷,王海淇,张认成,涂然,杨凯  
(华侨大学机电及自动化学院 厦门 361021)

**摘要:**电弧故障是电气火灾的重要原因。低压线路发生串联电弧故障时,回路电流波形的时域特征与正常工作状态类似,采用传统的特征提取方法无法完整表达时域信号的全部数据特征,限制了电弧故障的特征表达能力,导致检测结果的误报率和漏报率较高。针对此问题,提出基于自归一化卷积神经网络的电弧故障检测方法。该方法将采集到的不同种类负载的电流时间序列按照半周期截取,然后进行归一化处理,将灰度矩阵变换生成电弧故障及正常工作的二维图像;利用卷积神经网络提取电弧故障的灰度变换特征;通过全连接层拟合计算下采样信息实现电弧故障卷积特征的识别。验证表明,所提方法对电弧故障的识别率达到99.67%,优于传统卷积神经网络,具有良好的泛化性能。

**关键词:**串联电弧故障检测;灰度数据转换;自归一化卷积神经网络

中图分类号:TM501.2 TH89 文献标识码:A 国家标准学科分类代码:460.40

## An arc fault detection method based on the self-normalized convolutional neural network

Zhang Ting, Wang Haiqi, Zhang Rencheng, Tu Ran, Yang Kai

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

**Abstract:** The electric arc fault is an important cause of electrical fire. When the series arc fault occurs in the low-voltage circuit, the traditional feature extraction method cannot fully express all the data features of the time domain signal. The feature expression ability of arc fault is limited, which may bring high false alarm rate and miss alarm rate of detection results. To solve this problem, an arc fault detection method based on the self-normalized convolutional neural network is proposed. This method intercepts the current time series of different kinds of loads according to half period. Then, they are normalized. The two-dimensional images of arc faults and normal operation are generated by the grayscale data transformation. The gray transformation features of arc faults are extracted by using the convolutional neural network. The arc fault convolution features are identified by multi-layer full connection layer fitting calculation of the following sampling information. The evaluation shows that the accuracy of the proposed method is 99.67%, which is better than the traditional convolutional neural network and has good generalization performance.

**Keywords:** series arc fault detection; grayscale data conversion; self-normalized convolutional neural network

## 0 引言

电弧是指线路中不同电极间电压击穿绝缘介质时所产生的发光及放电现象。电器设备在使用过程中,由于线路松动、老化等原因,极易产生故障电弧。研究表明,当线路中产生故障电弧时,可瞬间产生20 000 K的高温<sup>[1]</sup>,极易燃烧线路周围的可燃物进而发生火灾。因而

有效检测线路中的电弧故障十分重要。

研究表明,串联电弧故障电流信号因其复杂性和多样性而难以检测,原因在于不同负载的电流在不同的工作状态下具有不同的特征。从以电信号为依据的电弧故障检测方法的应用层面来看,主要分为以下两个方面:

一是构建特征指标作为电弧故障的检测指标,即利用诸如快速傅里叶变换(fast Fourier transform, FFT)、离散小波分析(discrete wavelet transform, DWT)、高阶谱估

收稿日期:2020-12-16 Received Date: 2020-12-16

\* 基金项目:国家自然科学基金面上项目(52076084)资助

计 (higher-order spectral estimation) 等信号分析方法, 在时域、频域和时频域内计算电弧故障发生与正常工作时的序列差值, 然后与阈值进行比较。Koziy 等<sup>[2]</sup>采用离散小波变换对电流进行了 3 层分解, 并采用自适应阈值计算分解得到高频噪声的强弱幅度瞬态峰值。Calderon-Mendoza 等<sup>[3]</sup>利用卡尔曼滤波器计算得到两类状态变量, 利用决策块计算实际电流值和估计值之间的残差和状态变量的三阶差, 以此作为电弧故障的阈值检测。赵怀军等<sup>[4]</sup>通过采集用电回路的两个周期电流并计算电弧故障零休时间比例系数、滤除低频成份后的归一化绝对值最大互相关系数两类阈值, 实现了电弧故障的检测。鲍光海等<sup>[5]</sup>分析了电弧熄灭重燃时高频剩磁通耦合信号, 通过高阶统计量工具计算出耦合信号的峭度值, 利用上述阈值实现电弧故障的有效检测。Mortazavi 等<sup>[6]</sup>介绍了一种估算径向分布激励器高阻抗抗电弧故障位置的方法。谢国民等<sup>[7]</sup>利用 db4 小波对信号进行 5 层分解, 通过最大类间方差方法提取阈值, 计算该阈值与滤波后的信号的交点个数, 以此来判断是否发生电弧故障。

二是构建模式识别模型, 即采用支持向量机 (support vector machine, SVM)、神经网络 (neural network, NN) 等机器学习模型作为分类器, 然后对电弧故障发生时电信号的某类或多类特征进行分类。文献[8]利用小波变换计算得到电弧故障的时频域信息, 通过遗传算法改进的神经网络识别电弧故障。文献[9]以盒维数和关联维数作为故障电弧的特征向量, 采用最小二乘支持向量机作为识别模型对电弧故障进行检测, 该方法对几类常用负载具有良好的泛化性能; 文献[10]利用 Symmlets 小波基函数对正常工作和电弧故障状态下的电流波形进行 5 层小波分解, 将 5 个周期所有分解能量的均值和标准差作为 BP 神经网络的输入, 以此来判别电弧故障。文献[11]分析了电弧故障的时频域分量, 并讲样本状态大致分类为电阻、感-容和开关类别, 利用不同状态的时频分量和神经网络实现了电弧故障的有效检测。

然而, 第 1 类方法只能有效地检测某类特定的负载, 且易受到电路中其他负载的影响, 第 2 类方法虽然能够有效地检测多类负载存在的电弧故障, 但需要提取电弧故障信号的某类特征, 该过程十分依赖人工经验, 存在一定主观性, 同时特征提取过程并不能完全表征所有电弧类型, 因此存在一定的局限性。

近年来, 深度学习理论的不断发展为解决上述问题提供了可行的解决方法<sup>[12]</sup>。卷积神经网络 (convolutional neural network, CNN) 作为一种端到端的机器学习模型, 可以利用网络中的卷积运算表征数据的高维复杂特征, 充分挖掘数据内部规律。该方法有效避免了电弧故障的人工特征提取过程, 适合于大量数据的故障识别。

## 1 算法原理

### 1.1 灰度数据转换

对时间序列进行灰度数据转换, 进而可以利用二维卷积网络, 充分挖掘电弧故障经过转换的图像特征。信号的灰度数据转化首先需要在大量连续样本中选取一维时间序列信号, 选取方式为半波截取, 每个半波包含 1 024 个信号点, 即  $D = (d_1, d_2, \dots, d_{1024})$ 。灰度转换方法首先将采集到的一维时间序列信号进行归一化操作, 之后将其转化为灰度值, 灰度数据转换数学表达式为:

$$Z_{\text{gray}} = 255 \times \frac{D(i) - D_{\min}(i)}{D_{\max}(i) - D_{\min}(i)} \quad (1)$$

式中:  $D_{\max}(i)$  为序列  $D$  的最大值;  $D_{\min}(i)$  为序列  $D$  的最小值。

经过矩阵变换将  $1 \times N^2$  点的灰度数据序列转换为  $N \times N$  的二维灰度矩阵, 进而获得灰度数据图像。其转换方式如式(2)所示。

$$[d_1, d_2, \dots, d_{N^2}] \rightarrow \begin{bmatrix} d_1 & \dots & d_N \\ \vdots & \ddots & \vdots \\ d_{N^2-N+1} & \dots & d_{N^2} \end{bmatrix} \quad (2)$$

通过上述的数据变换方式, 可以对一维时域信号的波形数据重新排布, 生成的尺寸为  $32 \times 32$  的二维图像数据, 使其适用于卷积神经网络的识别处理。

### 1.2 自归一化卷积神经网络原理

#### 1) 卷积神经网络原理

CNN 是基于卷积运算与深度网络结构的前馈神经网络, 主要由卷积层、池化层、全连接层等组成<sup>[13]</sup>。

卷积层用来实现对输入数据的特征提取, 其内部包含多个卷积核, 每个卷积核都对应一个权重系数与一个偏差。其数学形式为:

$$Z_{i+1} = Z_i \otimes w_{i+1} + b_i \quad (3)$$

式中:  $Z_{i+1}$  为卷积计算得到特征图;  $Z_i$  为输入特征图;  $w_{i+1}$  为卷积核权重;  $b_i$  表示偏置量。卷积的工作原理如图 1 所示, 使用多个移动卷积核从图像中学习高维特征, 以水平和垂直方向沿着输入信号以一定的步进执行卷积运算。

池化层用于对卷积特征图的数据降维, 常用的池化操作为最大池化。该方法保留了图像特定范围内的最大值, 能够有效降低输出特征图的尺寸, 保留了图像中的纹理特征数据。

全连接层与传统前馈神经网络的隐含层相同, 主要用于对卷积和池化输出进行非线性拟合, 最后利用带有 Softmax 激活函数的全连接层计算准确率, 该函数的数学表达式为:

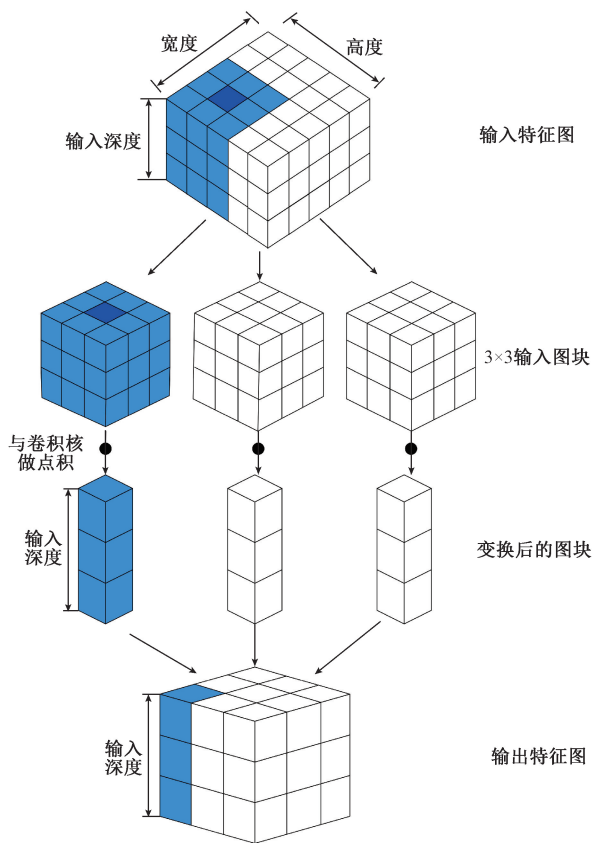


图 1 卷积的工作原理

Fig. 1 The principle of convolution

$$\text{Softmax}(y_i) = P(y = i | X) = \frac{e^{X^T w_i}}{\sum_{k=1}^K e^{X^T w_k}} \quad (4)$$

式中:  $P(y = i | X)$  表示输入为  $X$  时预测类别为  $i$  的概率;  $e^{X^T w_i}$  表示类别为  $i$  时网络的输出值, 通过  $\sum e^{X^T w_k}$  将函数归一化, 用以输出预测概率值。

### 2) 自归一化卷积神经网络

在 CNN 训练时, 通常利用批归一化 (batch normalization) 方法, 将神经元激活为零均值和单位方差。该方法通常使用线性整流函数<sup>[14]</sup> (rectified linear unit, ReLU) 作为激活函数, 其数学形式为:

$$f_{\text{ReLU}}(x) = \begin{cases} x, & x > 0 \\ 0, & x \leq 0 \end{cases} \quad (5)$$

批归一化会受到随机梯度下降 (stochastic gradient descent, SGD), 随机失活 (dropout)<sup>[15]</sup> 等多种方法的干扰, 会严重影响全连接层的前馈网络, 减慢网络的学习速度, 使得卷积网络的识别能力无法提升, 造成梯度爆炸、梯度消失等问题。本文采用扩展型指数线性单元激活函数 (scaled exponential linear units, SELU)<sup>[16]</sup> 作为卷积神经网络的激活函数, 该函数数学形式为:

$$f_{\text{SELU}}(x) = \lambda \begin{cases} x, & x > 0 \\ \alpha e^x - \alpha, & x \leq 0 \end{cases} \quad (6)$$

式中:  $\alpha \approx 1.6733$ ,  $\lambda \approx 1.0507$ 。

SELU 激活函数能够对神经网络进行自归一化, 其收敛速度会快于批归一化。经过此激活函数后, 网络的权重、偏置及激活的均值为 0, 标准差为 1。在 Lecun Normal 初始化条件下, 网络参数能够被初始化为高斯分布。该方法可以将网络训练时的均值和方差映射到预定义的区间内, 该区间如式 (7) 所示。

$$\begin{cases} \mu \in [-0.1, 0.1] \\ v \in [0.8, 1.5] \end{cases} \quad (7)$$

式中:  $\mu$  为均值,  $v$  为方差。

通过该区间可以避免网络出现梯度消失和梯度爆炸问题, 同时使用 AlphaDropout 作为随机失活函数, 可以使网络在 Dropout 后也能实现自归一化<sup>[17]</sup>。SELU 与 ReLU 的对比如图 2 所示。

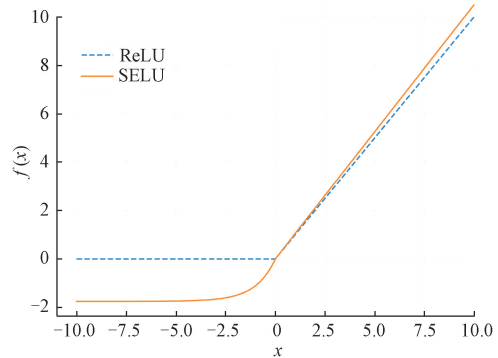


图 2 SELU 和 ReLU 对比

Fig. 2 Comparison SELU with ReLU

## 2 电弧故障实验数据分析

本文根据国家标准 GB/T 31143—2014《电器火灾监控系统第四部分:故障电弧探测器》搭建点接触式和碳化路径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、碳化路径电弧发生装置、可调功率负载箱、电流采集探头和示波器组成。

根据搭建好的实验平台, 分别采集阻性和不同功率因数负载的半波电流信号, 所需实验数据集如表 1 所示。实验数据包含点接触实验和碳化路径实验, 每组实验包含 100 个正常工作数据和 100 个电弧故障数据。

阻性时域半周期数据及其灰度转换如图 4 所示。图 4(a) 为阻性电弧故障半周期时域数据, 图 4(c) 为阻性正常工作半周期时域数据, 对比两类离散时间序列可以看出, 发生电弧故障时, 其时域波形的主要分布范围




图3 实验原理  
Fig. 3 Experimental schematic

表1 电弧故障实验数据集

Table 1 Experimental data set of arc faults

功率因数	电弧故障		正常工作	
	点接触	碳化路径	点接触	碳化路径
+0.1/-0.1	100/100	100/100	100/100	100/100
+0.2/-0.2	100/100	100/100	100/100	100/100
+0.3/-0.3	100/100	100/100	100/100	100/100
+0.4/-0.4	100/100	100/100	100/100	100/100
+0.5/-0.5	100/100	100/100	100/100	100/100
+0.6/-0.6	100/100	100/100	100/100	100/100
+0.7/-0.7	100/100	100/100	100/100	100/100
+0.8/-0.8	100/100	100/100	100/100	100/100
+0.9/-0.9	100/100	100/100	100/100	100/100
阻性	100	100	100	100

不变,在序列的前后均会出现“平肩”现象。同时由于平肩带来了序列的峰值数据偏移,也可以作为时域判别部分。其灰度转换图像如图4(b)和(d)所示。图像经过矩阵变换后,转换为 $32 \times 32$ 的灰度数据分布图,分别用于表征图4(a)和4(c)的时间序列。当发生“平肩”现象时,对应灰度图像的低值数据带被拉宽,进而使得高灰度值的亮带发生偏移和缩减。通过二维卷积的特征提取过程能够有效提取矩阵中的灰度值变化,由此特征可以表示阻性负载的电弧故障数据特征。

阻-感性时域半周期数据及其灰度转换如图5所示。当阻-感性负载发生电弧故障时,其波形变化与阻性负载类似,因而其二维灰度特征与阻性负载类似。

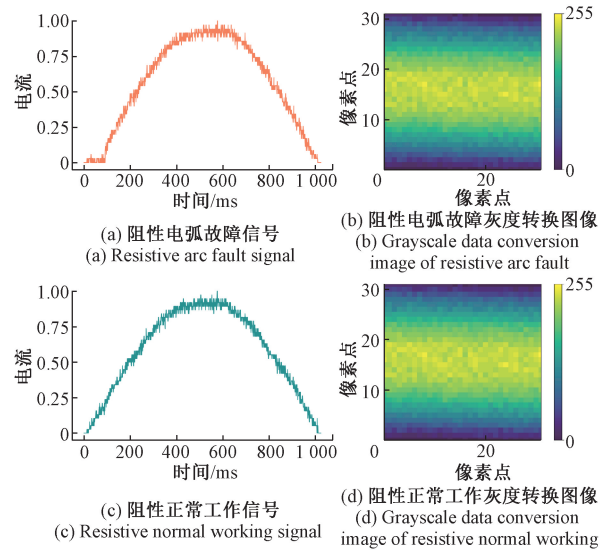


图4 阻性半波数据及灰度转换图

Fig. 4 Resistive half-wave data and grayscale conversion map

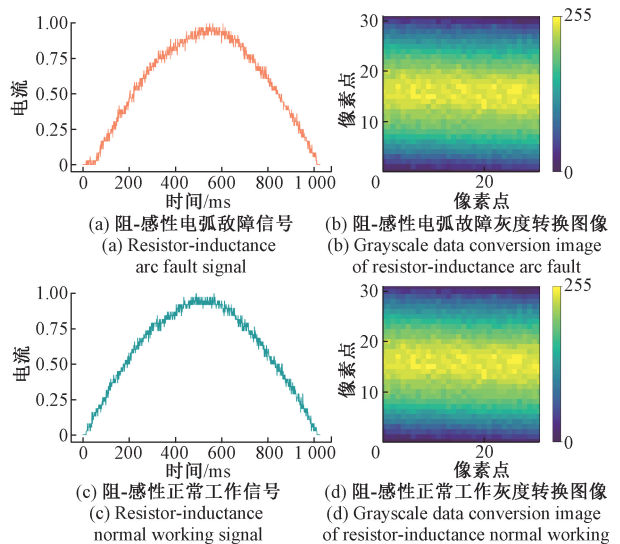


图5 阻感性半波数据及灰度转换图

Fig. 5 Inductive half-wave data and grayscale conversion map

阻-容性时域半周期数据及其灰度转换如图6所示。从图6(a)和(c)中的一维离散时间序列可以看出,阻-容性负载的正常工作半周期波形存在一定程度上的畸变,但主要成分仍然为正弦波。当发生电弧故障时,时域半波的前后部分出现“平肩”,伴随着畸变部分的放大。对应于图6(b)和(d)的灰度转换图像,该类负载除了拉宽了灰度图像中的边缘低值灰度带以外,由于更加严重的电弧故障波形畸变,导致了电弧故障的灰度变化相对正常工作状态下图像特征更加不平滑,利用卷积神经网络可以有效提取以上两类灰度变化特征。

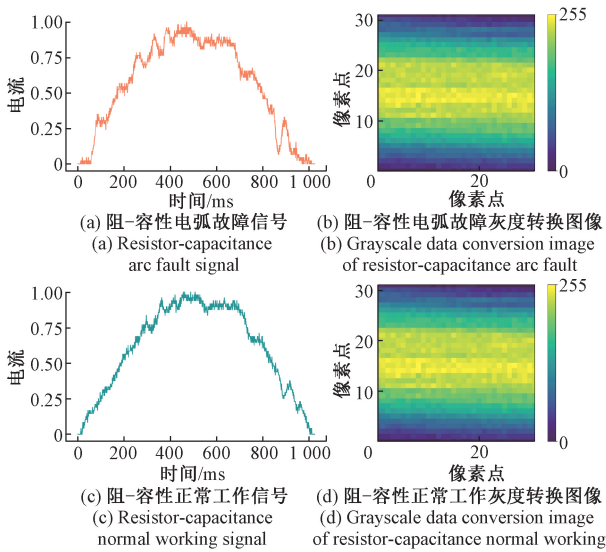


图 6 阻容性半波数据及灰度转换图

Fig. 6 Capacitive half-wave data and grayscale conversion map

综上所述,利用灰度矩阵变换可以实现在二维空间内表征电弧故障时域波形的一维数据分布变化,进而利用卷积层挖掘其图像特征,达到识别电弧故障的目的。

### 3 模型搭建及算法分析

#### 3.1 模型搭建

综合考虑电弧故障和正常工作的灰度转换数据特点,本文将采用自归一化卷积神经网络 (self-normalized convolutional neural network, SCNN) 识别电弧故障,模型结构如图 7 所示。对于电弧故障和正常工作的二分类识别任务,网络最后一层放置两个神经元,采用表 1 的数据要求构建 7 600 组灰度转换数据;将数据集按照 8:2 的比例分解为训练集、测试集两部分,将数据集打乱后输入卷积神经网络得到识别结果,其中标签 0 代表电弧故障,标签 1 代表正常工作。

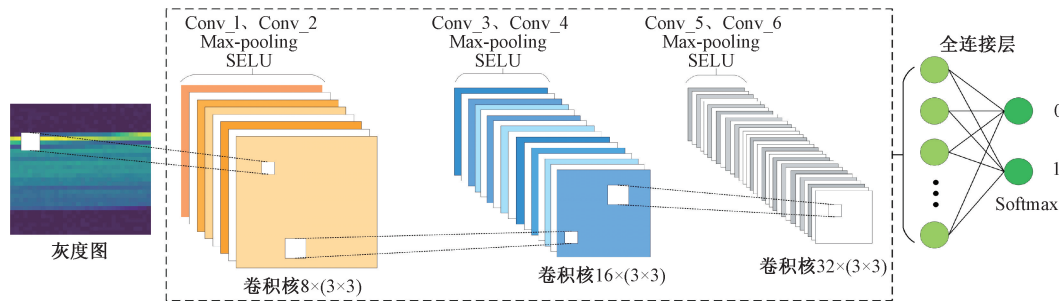


图 7 SCNN 模型结构

Fig. 7 Structure of the SCNN model

网络参数如表 2 所示。该网络采用两个带有  $3 \times 3$  卷积核的卷积层挖掘图像特征。网络通过最大池化操作挖掘图像的灰度边缘特征。经过 3 次卷积操作后,利用 5 层全连接网络拟合分类计算结果。每层网络设置 SELU 激活函数,同时利用 Lecun Normal 进行网络初始化。采用学习率为 0.000 3 的 Adam 优化器,批处理大小为 120,同时添加 L2 正则化防止模型过拟合。

#### 3.2 算法流程

本文使用 Google 开源深度学习框架 Tensorflow2 搭建基于 SCNN 的电弧故障识别模型,计算机硬件配置为:两片 Intel XEON (R) E5-2678v3 CPU,128 G 内存,4 张 NVIDIA GeForce GTX 1080Ti 11G GPU,算法流程如图 8 所示。

#### 3.3 实验结果

根据以上的算法方案,最终建立了基于 SCNN 的电弧故障识别模型,该模型的测试准确率曲线、代价函数曲线如图 9 所示。

表 2 SCNN 模型参数

Table 2 Parameters of the SCNN model

序号	层类型	激活函数	kernel	AlphaDropout	填充	步长
1	卷积	SELU	$8 \times (3 \times 3)$	-	same	1
2	卷积	SELU	$8 \times (3 \times 3)$	-	same	1
3	最大池化	-	-	-	same	2
4	卷积	SELU	$16 \times (3 \times 3)$	0.3	same	1
5	卷积	SELU	$16 \times (3 \times 3)$	-	same	1
6	最大池化	-	-	-	same	2
7	卷积	SELU	$32 \times (3 \times 3)$	0.5	same	1
8	卷积	SELU	$32 \times (3 \times 3)$	-	same	1
9	最大池化	-	-	-	same	2
10	全连接	SELU	1 024	0.5	-	-
11	全连接	SELU	256	0.4	-	-
12	全连接	SELU	64	-	-	-
13	全连接	SELU	16	-	-	-
14	全连接	SELU	2	-	-	-

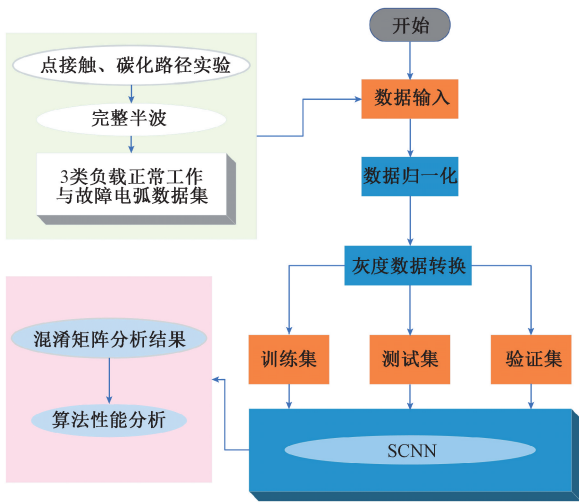




图 8 算法工作流程

Fig. 8 Flowchart of the algorithm work



(a) 测试准确率曲线  
(a) The curve of test accuracy



(b) 训练代价函数曲线  
(b) The curve of training cost function

图 9 SCNN 训练结果

Fig. 9 Training results of SCNN

从图 9 中可以看出:改进的 SCNN 在训练 250 轮之后训练准确率趋近于 1,同时,网络的代价函数曲线也在不断下降,说明此时网络仍在继续学习。在训练 1 500 轮之后,网络的识别率和代价函数曲线趋于不变,识别模型收敛。

模型的测试结果如图 10 的混淆矩阵所示。通过该混淆矩阵可知,模型对测试集的测试准确率为 99.67%,有 3 个样本被误识别为电弧故障,2 个样本被误识别为正常工作。





图 10 SCNN 具体识别结果

Fig. 10 Specific recognition results of SCNN

### 3.4 应用效果检测

为了对模型的实际应用效果进行测试,分别采集吸尘器、调光灯两类常用负载不同工况下的实验数据并输入 SCNN 模型进行训练和预测,用来判断本文模型对电弧故障识别的有效性。

吸尘器的归一化波形及识别结果如图 11 所示。吸尘器作为抑制性负载,发生电弧故障时的电流波形如图 11(b)所示和正常工作如图 11(a)所示时极为相似。当发生电弧故障时,电流的幅值会发生微小变化,但过零处的高频毛刺会变小,对应灰度转换图像的特征主要就在于暗色带的图像噪点。本实验将采集到的吸尘器波形数据输入搭建好的 SCNN 模型进行训练和预测,正常工



(a) 吸尘器正常工作预测结果  
(a) The normal predicted results of vacuum





图 11 吸尘器波形及识别结果

Fig. 11 Waveform and identification results of vacuum

作和电弧故障均可以实现精确识别。图 11 中预测标签“0”表示电弧故障，“1”表示正常工作。由下图可知，SCNN 模型能够有效预测该负载的电弧故障。

调光灯的归一化波形及识别结果如图 12 所示。调光灯属于屏蔽性负载,发生电弧故障如图 11(b)所示时,电流幅值会发生突变,“平肩”部分伴有部分高频分量的毛刺,但电弧故障信号过零处的整体变化趋于平稳,因而会在灰度转换图像的暗色带中出现个别噪点。由图 12 可知,SCNN 模型对调光灯两类工作状态均能有效检测。

### 3.5 算法性能对比

在机器学习模型中,除了模型的验证准确率外,召回率、精确率和 F-1 综合评价指标也可以有效评估识别算法。其中召回率用于表示正例样本被分为正例的比率;精确率用于表示预测的正样本中正样本所占的比例。根据上述 3 种评价标准即可计算 F-1 综合指标。其数学表达式形式如式(8)所示。

$$\begin{cases} f_{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \\ f_{Recall} = \frac{TP}{TP + FN} \\ f_{Precision} = \frac{TP}{TP + FP} \\ f_{F-1} = \frac{2 \times f_{precision} \times f_{Recall}}{f_{precision} + f_{Recall}} \end{cases} \quad (8)$$

式中:TP 为真正例,表示将正类预测为正类的样本数;TN 为真反例,表示将负类预测为负类的样本数;FP 表示假正例,表示将负类预测为正类的样本数;FN 表示假反例,表示将正类预测为负类的样本数。

在电弧故障识别任务中,除去上述评价指标外,还应




图 12 调光灯波形及识别结果

Fig. 12 Waveform and identification result of dimmer

该考虑误报率和漏报率,其数学表达式如式(9)所示。

$$\begin{cases} f_{FAR} = \frac{FP}{TN + FP} \\ f_{MAR} = \frac{FN}{TP + FN} \end{cases} \quad (9)$$

式中: $f_{FAR}$  为误报率(False alarm rate, FAR); $f_{MAR}$  为漏报率(Missing alarm rate, MAR),误报率用于表示正常工作样本被误识别为电弧故障的比例;漏报率用于表示电弧故障未被有效识别的样本所占比例。

在同一模型结构下不同改进方案的识别结果如表 3 所示。对比不同的改进方案,采用 SELU 激活函数的自归一化卷积神经网络具有最高的识别率,达到 99.67%,而未改进的卷积神经网络算法准确率为 98.95%。对比使用非对称卷积的 ACNet<sup>[18]</sup>算法和改进的 AC-SCNN 网络,SCNN 具有最高的识别率和稳定的识别表现。同时,

其误报率和漏报率都在 0.5% 以下。该方法能够有效识别不同负载的点接触和碳化路径电弧故障,改善了电弧故障

识别效果,有效的降低了电弧故障检测的误报率和漏报率。因而该识别模型具有好的更加良好的泛化性能。

表 3 电弧故障识别结果对比

Table 3 Comparison of arc fault identification results

%

序号	模型名称	准确率	召回率	精确率	F-1 指标	误报率	漏报率
1	ACNet	98.95	99.31	98.49	98.90	1.38	0.69
2	AC-SCNN	99.41	99.72	99.04	99.39	0.88	0.28
3	CNN	98.95	98.77	99.04	98.90	0.89	1.23
4	SCNN	99.67	99.59	99.73	99.66	0.25	0.41

基于 SCNN 的识别算法与其他文献中的识别算法对比如表 4 所示。本文提出的模型相对于 LS-SVM 和 DNNs<sup>[19]</sup> 方法,无需人工提取电弧数据的某一类或多类具体特征;相对于方法 1<sup>[20-22]</sup> 和方法 3<sup>[23]</sup> 的深度学习识别算法,有效地提高了电弧故障的识别率。综上所述,本文所提方法不需要进行人工特征提取,能够有效改善电弧故障的识别错误,提升准确率。

表 4 不同电弧故障识别算法比较

Table 4 Comparison of different arc fault recognition algorithms

序号	方法	识别率/%	是否需要特征提取
1	TDV-CNN	98.70	否
2	LS-SVM	98.33	是
3	AlexNet	85.25	否
4	DNNs	99.95	是
5	SCNN	99.67	否

## 4 结 论

为了有效识别线路中的串联电弧故障,本文综合运用灰度数据转换和 SCNN 构造电弧故障识别模型,主要结论如下:

在发生串联电弧故障时,阻性负载同阻-感性负载的半周期电流波形具有类似的数据分布,阻-容性负载则更容易发生波形畸变。利用时域波形及其二维灰度转换,可以有效表示电弧故障的时域变化特征。

自归一化卷积神经网络对于电弧故障识别任务识别率达到 99.67%,有效地降低了误报率和漏报率,具有良好的识别稳定性和泛化能力。

### 参考文献

[1] LEE R H. The other electrical hazard; Electric arc flash[J]. IEEE Transactions on Industry Applications, 1982, IA-18(3): 246-251.

[2] KQZiy K, GOU B, ASLAKSON J. A low-cost power-quality meter with series arc-fault detection capability for smart grid[J]. IEEE Transactions on Power Delivery, 2013, 28(3): 1584-1591.

[3] CALDERON-MENDOZA E, SCHWEITZER P, WEBER S. Kalman filter and a fuzzy logic processor for series arcing fault detection in a home electrical network[J]. International Journal of Electrical Power & Energy Systems, 2018, 107: 251-263.

[4] 赵怀军, 秦海燕, 刘凯, 等. 基于相关理论及零休特征融合的串联故障电弧检测方法[J]. 仪器仪表学报, 2020, 41(4): 218-228.

ZHAO H J, QIN H Y, LIU K, et al. A series fault arc detection method based on correlation theory and zero-break feature fusion[J]. Chinese Journal of Scientific Instrument, 2020, 41(4): 218-228.

[5] 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. BAO G H, JIANG R. Research on series arc fault detection based on asymmetric magnetic flux distribution[J]. Chinese Journal of Scientific Instrument, 2019, 40(3): 54-61.

[6] MORTAZAVI S H, MORAVEI Z, SHAHRTASH S M. A searching based method for locating high impedance arcing fault in distribution networks[J]. IEEE Transactions on Power Delivery, 2019, 34(2): 438-447.

[7] 谢国民, 刘宽. 基于形态学滤波和 OTSU 的串联故障电弧识别方法[J]. 电子测量与仪器学报, 2019, 33(5): 46-56.


XIE G M, LIU K. Series fault arc recognition method based on morphological filtering and OTSU[J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(5): 46-56.

[8] 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.



- [9] 杨凯, 张认成, 杨建红, 等. 基于分形维数和支持向量的串联电弧故障诊断方法[J]. 电工技术学报, 2016, 31(2): 70-77.  
YANG K, ZHANG R CH, YANG J H, et al. Series arc fault diagnostic method based on fractal dimension and support vector machine [J]. Transactions of China Electrotechnical Society, 2016, 31(2): 70-77.
- [10] 张士文, 张峰, 王子骏, 等. 一种基于小波变换能量与神经网络结合的串联型故障电弧辨识方法[J]. 电工技术学报, 2014, 29(6): 290-295, 302.  
ZHANG SH W, ZHANG F, WANG Z J, et al. Series arc fault identification method based on energy produced by wavelet transformation and neural network [J]. Transactions of China Electrotechnical Society, 2014, 29(6): 290-295, 302.
- [11] 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.
- [12] LU S, SIROJAN T, PHUNG B T, et al. DA-DCGAN: An effective methodology for dc series arc fault diagnosis in photovoltaic systems[J]. IEEE Access, 2019: 1.
- [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] SRIVASTAVA N, HINTON G, KRIZHEYSKY A, et al. Dropout: A simple way to prevent neural networks from overfitting[J]. Journal of Machine Learning Research, 2014, 15(1): 1929-1958.
- [16] PAN X Y, HU X H, ZHANG Y, et al. Identifying patients with atrioventricular septal defect in down syndrome populations by using self-normalizing neural networks and feature selection[J]. Genes, 2018, 9(4): 208.
- [17] LIU M, LIU G. Prediction of citrullination sites on the basis of mRMR method and SNN [J]. Combinatorial Chemistry & High Throughput Screening, 2019, 22(10): 705-715.
- [18] DING X H, GUO Y C, DING G G, et al. ACNet: Strengthening the kernel skeletons for powerful cnn via asymmetric convolution blocks [C]. 2019 IEEE/CVF International Conference on Computer Vision (ICCV), Seoul: Korea (South), 2019: 1911-1920.
- [19] SIEGEL J E, SHANE P, YONGBIN S, et al. Real-time deep neural networks for internet-enabled arc-fault detection [J]. Engineering Applications of Artificial Intelligence, 2018, 74: 35-42.
- [20] 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.
- [21] 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.
- [22] CHU R B, SCHWEITZER P, ZHANG R C. Series AC arc fault detection method based on high-frequency coupling sensor and convolution neural network [J]. Sensors, 2020, 20(17): 4910.
- [23] 余琼芳, 黄高路, 杨艺, 等. 基于 AlexNet 深度神经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.  
YU Q F, HUANG G L, YANG Y, et al. Series arc fault detection method based on AlexNet deep learning network[J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(3): 145-152.

#### 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. She is a master student at Huaqiao University. Her main research interest is 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. He is currently a professor at Huaqiao University. His main research interests include arc fault detection technology and equipment and intelligent fire technology.