

DOI: 10.13382/j.jemi.B1902579

基于小波特征及深度学习的故障电弧检测*

余琼芳^{1,2} 胡亚倩¹ 杨艺¹

(1.河南理工大学 电气工程与自动化学院 焦作 454003;

2.大连理工大学 北京研究院博士后科研工作站 北京 100000)

摘要:由线路绝缘层老化破损、电气接触不良等原因产生的串联故障电弧严重威胁着低压配电系统的电力安全。其电流小、温度高、隐蔽性强等特点更是给检测和识别带来了困难。基于此,提出一种基于小波特征及深度学习的串联故障电弧检测方法。通过搭建串联故障电弧实验平台,采集了典型阻性、阻感性、感性负载下的电流信号,对电流信号进行小波变换构造了训练集和测试集,通过改进的 AlexNet 模型识别故障电弧并输出检测结果。实验结果表明,采用该方法进行串联故障电弧识别的准确率约为 95.58%,比利用 AlexNet 模型要高出约 10.58%。

关键词:故障电弧;小波变换;深度学习;检测方法

中图分类号: TM501.2 **文献标识码:** A **国家标准学科分类代码:** 510.40

Arc fault detection based on wavelet feature and deep learning

Yu Qiongfang^{1,2} Hu Yaqian¹ Yang Yi¹

(1. School of Electrical Engineering and Automation, Henan Polytechnic University, Jiaozuo 454003, China;

2. Postdoctoral Programme of Beijing Research Institute, Dalian University of Technology, Beijing 100000, China)

Abstract: Series arc fault caused by aging damage of line insulation layer and poor electrical contact seriously threatens the power safety of low voltage distribution system. It is difficult to detect and extinguish series arc fault for its characteristics of small current, high temperature and strong concealment. Because of above reasons, a method based on wavelet feature and deep learning is proposed for detecting series arc fault. Firstly, series arc fault experimental platform was built to collect the current signals under typical resistive load, inductive load and resistive-inductive load. Secondly, after transformed by wavelet transform, collected signals were decomposed to construct training sets and test sets. Finally, the arc fault was identified by the improved AlexNet model, and the test results were output. The experimental results show that the accuracy of this method for serial arc fault identification is almost 95.58%, about 10.58% higher than using AlexNet model.

Keywords: arc fault; wavelet transform; deep learning; detection method

0 引言

电弧是由电极间绝缘介质被击穿所导致的辉光放电现象,常伴随有电极之间的局部挥发^[1]。而其中对线路及设备有破坏性的,主要由线路老化、电气连接处接触不良或短路等原因引起的电弧,一般被称为故障电弧^[2]。故障电弧是造成电气火灾的主要原因。电弧燃烧时,2~

10 A 的电弧电流即可导致温度升高 2 000℃~4 000℃,0.5 A 电流产生的热量就足以将线路附近的可燃物点燃^[3]。因此,在故障电弧发生早期做到及时检测和准确预测,能够有效降低由电气火灾造成的经济损失和人员伤亡。

根据故障电弧发生时与负载位置的不同,电弧可分为串联故障电弧、并联故障电弧和接地故障电弧^[4]。串联故障电弧受线路阻抗的影响,其回路电流值较小,通常

收稿日期: 2019-09-10 Received Date: 2019-09-10

* 基金项目: 国家自然科学基金(61601172)、中国博士后科学基金(2018M641287)资助项目

为 5~30 A,甚至更低,荧光灯在故障电弧发生时的电流有效值约为 0.1 A^[5]。达不到动作电流值,使得常规断路器装置无法在串联故障电弧发生时做到及时切断和保护线路。电弧突发性、隐蔽性、随机性等特征也给检测研究带来了困难。

在串联故障电弧的检测和辨识方面,众多学者进行了研究,已取得一些成果。一部分学者通过建立电弧数学模型,用计算机仿真技术替代复杂的实验。这种方法深入研究了电弧特性,但受应用条件和参数等限制,模型更多地停留在仿真阶段^[6]。串联故障电弧燃烧时伴随的弧声、弧光、温度、压力等物理现象,因易于检测被应用于故障电弧的识别,但多适用于开关柜和配电柜等固定设备的故障电弧检测,在低压配电路路中效果并不明显^[7]。目前,故障电弧研究方向主要是基于正常工作和电弧发生时电压、电流信号的分析,并且新的算法正不断被引进该研究方向。郭凤仪等^[8]对电流信号进行处理后,通过灰度-梯度共生矩阵的 15 种特征量得到负载为工控机和变频器的串联故障电弧特征向量,然后利用支持向量机实现对故障电弧的识别。黄伟翔等^[9]提取电流波形的傅里叶变换特征值,在 Hebb 神经网络负载分类的基础上确定该负载所用的 BP 神经网络参数,然后利用 BP 神经网络得出辨识结果。Jovanovic 等^[10]提出了一种基于单相有源电力滤波器(active power filter, APF)的方法,通过在数字控制中添加故障电弧检测功能来检测交流电气装置中的串联故障电弧。这些方法利用实验采集的电流、电压数据进行判断分析,已取得一定成效,但是一般都适用于某些特定的负载。在实际应用中,负载类型多种多样,负载数量也随之增加,这些方法在大数据处理方面都有一定的局限性。

2006 年, Hinton 团队^[11]提出深度学习,利用深度神经网络从大量的数据中自动地学习特征,其学习的特征丰富,表达目标的能力强。2012 年, Krizhevsky 等^[12]提出了 AlexNet 模型,以 120 万张 224×224 大小的三通道图片为训练集,输出一个 1 000 维向量,在 ImageNet LSVRC-2010 竞赛上实现了创纪录的检测准确率。Lee 等^[13]通过使用来自 PHD08 的实验数据,表明了 KCR-AlexNet 和 KCR-GoogLeNet 两个卷积神经网络的测试精度均超过 98%。其中, PHD08 是一个大型韩国字符数据库,有 2 350 个韩语字符类,每类 2 187 个字符样本,共计 5 139 450 个数据样本。这些均体现了深度学习在处理海量数据样本方面的独特优势。

串联故障电弧容易受负载特性的影响,特别是随着配电路路中非线性设备的增加,电路正常工作电流与故障电弧电流波形相近,且故障特征容易被湮没在负载电流中,大大增加了区分正常工作和故障电弧状态的难度。余琼芳等^[14]首次提出一种基于深度学习算法来检测串

联故障电弧的方法,通过将采集到的电阻性负载、电感性负载、阻感性负载情况下的 7 200 组电流数据输入 AlexNet 模型进行训练,得到辨识准确率在 85% 以上的测试结果。该方法利用深度学习自动挖掘电流信号数据的内在特征,不受负载类型的影响,又有较好的检测串联故障电弧效果。鉴于此,本文提出一种基于小波特征及深度学习的串联故障电弧检测方法,对采集到的电流信号进行离散小波变换,构造训练集和测试集,然后通过改进的 AlexNet 模型识别故障电弧特征并输出检测结果,进一步提高了辨识准确率。

1 基于小波变换的特征向量提取

故障电弧电流信号具有非平稳、随机性等特征^[15-16]。而小波变换可以在低频情况下提供高频分辨率和低时间分辨率,高频情况下提供高时间分辨率和低频分辨率,有利于处理故障电弧这一类突变信号。

引用小波变换 Mallat 算法的相关理论^[17],设在一串嵌套式闭子空间逼近序列 $\{V_j\}_{j \in Z}$ 中, W_{j-1} 为 V_{j-1} 在 V_j 的正交补空间,即 $V_j = W_{j-1} \oplus V_{j-1}$ 。序列空间 W_j 由小波函数 $\psi(t)$ 伸缩和平移生成;子空间 V_j 由尺度函数 $\varphi(t)$ 伸缩和平移生成。定义低通滤波器 h_n 和高通滤波器 g_n 为:

$$h_n = \sqrt{2} \int_{-\infty}^{+\infty} \varphi(t) \varphi(2t - n) dt \quad (1)$$

$$g_n = \sqrt{2} \int_{-\infty}^{+\infty} \psi(t) \varphi(2t - n) dt \quad (2)$$

定义 $\bar{h}_n = h_{-n}$, $\bar{g}_n = g_{-n}$ 。用 \bar{h}_n 和 \bar{g}_n 对信号进行小波分解,其分解算法为:

$$c_{j-1,k} = \sum_{n \in Z} c_{j,n} \bar{h}_{n-2k}, k \in Z \quad (3)$$

$$d_{j-1,k} = \sum_{n \in Z} c_{j,n} \bar{g}_{n-2k}, k \in Z \quad (4)$$

式中: $c_{j-1,k}$ 表示小波分解空间 V_{j-1} 的第 k 个尺度系数; $d_{j-1,k}$ 表示小波分解空间 W_{j-1} 的第 k 个小波系数。

作为离散小波变换的快速算法——Mallat 算法,其分解结构如图 1 所示。重复使用一组高通滤波器和低通滤波器,信号被逐步分到不同的频带。设采样频率为 f_s ,第 n 层分解后, $[0, f_s/2^{n+1}]$ 为近似信号的频带范围, $[f_s/2^{n+1}, f_s/2^n]$ 为细节信号的频带范围。原始信号序列 $c_{j,k}$ 经过 1, 2, ..., n 层的分解,最终分解为一维向量 s , 表示为

$$s = (c_{j-n,k} \quad d_{j-n,k} \quad \cdots \quad d_{j-2,k} \quad d_{j-1,k}) \quad (5)$$

Daubechies 系列小波具有正交性、紧支性较好,对不规则信号敏感等特点^[18]。基于此,本文利用 MATLAB R2016a 的小波工具箱,选用 db9 和 db10 作为小波基函数。考虑到分辨率和计算速度的影响,对实验采集的原始电流信号做 6 层小波分解。db9 小波对原始信号做 6

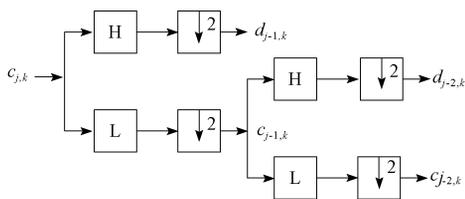


图 1 多尺度小波分解

Fig.1 Multiscale wavelet decomposition

层分解,得到 $(c6 \ d6 \ d5 \ d4 \ d3 \ d2 \ d1)$ 这样的一维向量,包含了信号从低频到高频的不同频带信息。同理,利用 db10 小波对原始信号做 6 层分解,又得到一维向量。最终,将 db9 分解得到的向量、db10 分解得到的向量与原始信号组成一个 $3 \times 10\ 000$ 矩阵,作为深度学习模型的样本。

2 基于深度学习的故障电弧检测

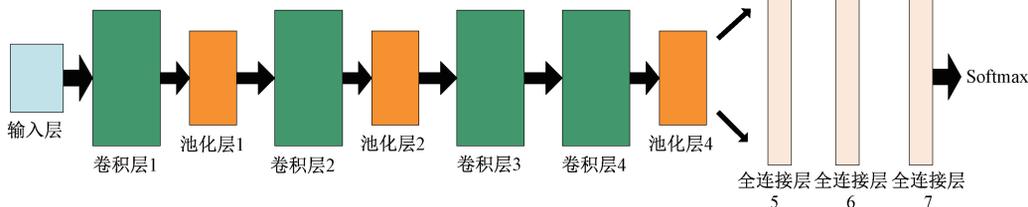


图 2 改进的 AlexNet 模型结构

Fig.2 Structure of improved AlexNet model

表 1 改进的 AlexNet 对每一层的配置

Table 1 Improved AlexNet configuration of each layer

图层类型	卷积核大小	池化层	零填充	步长	输出特征矩阵大小
输入层					$3 \times 10\ 000 - 1$
卷积层 1	3×3		1	2	$2 \times 5\ 000 - 96$
池化层 1	1×5	最大池化	1	5	$1 \times 1\ 000 - 96$
卷积层 2	3×3		1	2	$1 \times 500 - 256$
池化层 2	1×5	最大池化	1	5	$1 \times 100 - 256$
卷积层 3	3×3		1	2	$1 \times 50 - 384$
卷积层 4	3×3		1	2	$1 \times 25 - 256$
池化层 4	1×5	最大池化	1	5	$1 \times 5 - 256$
全连接层 5					$1\ 280 \times 1 - 1$
全连接层 6					$1\ 280 \times 1 - 1$
全连接层 7					$2 \times 1 - 1$

2.2 ReLU 激活函数

模型在所有的卷积层和全连接层之后,都应用了 ReLU 函数,如图 3(a)所示。该函数与 Sigmoid 和 Tanh 等激活函数相比,在随机梯度下的训练时间更短。图 3(b)中,Sigmoid 函数可以将一个实数映射到 $(0, 1)$ 的区

2.1 改进的 AlexNet 模型结构

近年来,深度学习被广泛地应用在图像识别、目标检测、人脸识别等方面。AlexNet,作为一种深度神经网络,可以模拟复杂的非线性关系,具有强大的特征学习和特征表达能力^[19]。因模型输入样本是一个 $3 \times 10\ 000$ 的二维矩阵,对 AlexNet 模型做出了改进,使得模型的深度结构更适合学习样本数据中的特征。

改进后 AlexNet 模型的结构如图 2 所示,它主要包含 7 层。前 2 个卷积层和第 4 个卷积层后面都接的是池化层,而第 3 个卷积层和第 4 个卷积层是直接相连的。池化层 4 的输出结果会输入进 3 个全连接层。全连接层 7 的输出被送到 Softmax 函数,以判定类型是故障还是正常。此外,根据训练样本的数据类型,模型的配置参数,如卷积核大小、步长、权重和偏置等,都做出了相应改进。改进后的 AlexNet 模型对每一层的配置参数如表 1 所示。

间。但计算反向传播求误差梯度时涉及除法运算,Sigmoid 函数计算量大且其导数从零开始又很快趋近于零,容易造成梯度消失。Tanh 函数取值范围如图 3(c)所示为 $[-1, 1]$,均值为 0,在实际应用中比 Sigmoid 效果要好,但同样容易造成梯度消失。

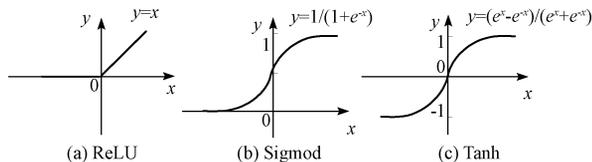


图 3 激活函数曲线

Fig.3 Activation function curve

2.3 局部响应归一化

4 个卷积层都包含了局部归一化操作(local response normalization, LRN)。它使得特征图中的相邻特征局部竞争,同时同一位置的不同特征图的特征也进行比较,响应比较大的值变得更大,响应比较小的值变得更小,抑制反馈较小的神经元,增强了模型的泛化能力^[20-21]。其表达式为:

$$b_{x,y}^i = \frac{a_{x,y}^i}{\left(k + \alpha \sum_{j=\max(N-1,i+n/2)}^{\min(N-1,i+n/2)} (a_{x,y}^j)^2\right)^\beta} \quad (6)$$

式中： $a_{x,y}^i$ 代表第 i 层位置 (x,y) 上的值，是上一层输出结果； k 是偏移量，默认为 1； α 是刻度因子，根据训练结果调整为 0.001/9.0； β 为指数，根据实验结果改成 0.75； n 是同一位置上临近卷积核数目，值为 8； N 代表卷积核的总数目。

2.4 最大池化

池化层通常被设置在卷积层之后，通过对特征矩阵的局部区域进行池化操作，降低卷积层输出特征矩阵的维度。假设 $l+1$ 层为池化层， l 层为卷积层，可通过式(7)计算该层的输出特征矩阵，其中 $p(x)$ 为池化操作。

$$pool^{l+1} = p(conv^l) \quad (7)$$

常用的池化操作有均值池化和最大池化。基于特征值提取误差的考虑，选用最大池化操作，即用过滤器矩阵把卷积层输出矩阵沿 X 轴和 Y 轴方向划分为一个个小块，取每小块中的最大值，形成一个由最大值元素组成的矩阵，原理如图 4 所示。



图 4 最大池化原理

Fig.4 Principle of max-pooling

3 串联型故障电弧采集

3.1 串联故障电弧检测标准

1999 年，美国推出了故障电弧断路器 AFCI 产品的工业级标准—UL 1699^[22]。一直以来，我国都致力于制定故障电弧检测装置的安装和检查标准。2014 年，在公安部沈阳消防研究所和上海电器研究所的领导下，发布了 GB14 287.4-2014《电气火灾监测系统 第 4 部分：电弧故障探测器》^[23] 和 GB/T31143-2014《电弧故障检测装置的一般要求》^[24]。

3.2 故障电弧波形数据采集

参照 GB14 287.4-2014 提出的测试方法，搭建了 220 V、50 Hz 条件下的低压交流串联故障电弧发生装置，装置示意图如图 5 所示。电弧发生装置主要由静止电极、活动电极、侧面调节器、滑块、绝缘夹具和固定底座等组成。静止电极选用一根直径为 6 mm 的石墨电极棒，活动电极选用一根 6 mm 铜棒，两个电极分别被固定在绝缘夹钳上，通过侧面调节器调节两者之间的距离。

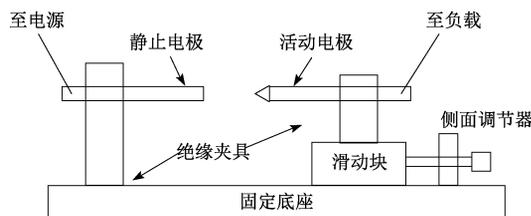


图 5 电弧发生装置示意图

Fig.5 Arc generating device

串联故障电弧实验平台的接线如图 6 所示，其实物如图 7 所示。电源采用的是 220 V 交流电，采样电阻选用 100W1P 的水泥电阻，示波器使用 TiePieSCOPE HS801 五合一虚拟综合测试仪。在模拟故障电弧时，先将静止电极与活动电极紧密接触，然后电弧发生装置接入到用电线路中并通电，使整个电路导通，通过调节侧面调节器手动控制两个电极之间距离，将原本接触的电极缓慢分开，从而产生电弧。一般情况下，开关动作和插头插拔等操作会产生电弧或者电火花，但这类电弧并不属于故障电弧。考虑到这点，在电弧发生装置上并联了一个开关。采集故障电弧电流信号时，开关处于断开状态；采集负载正常运行的电流信号时，通过操作开关来模拟设备或线路正常运行时由开关动作产生电弧或电火花的情况，以此区分正常运行的电流和发生故障电弧的电流。此种方法在国内外文献中未见报道。

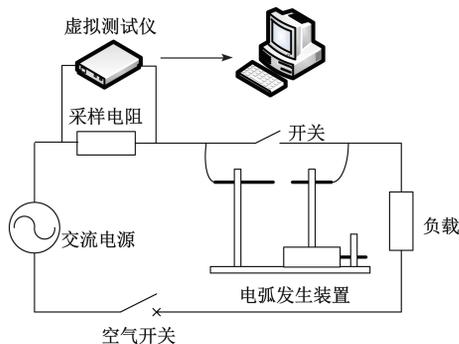


图 6 串联故障电弧实验接线

Fig.6 Series arc fault experiment wiring diagram

随着全球电气化、信息化程度不断加深，供电网负载端联结的电器产品种类不断增多，联结形式繁杂，且在使用中还会频繁改变，使得在实验室这种有限条件下模拟各种类、各联结方式负载情况下的故障电弧发生状态不太现实，而电网终端的负载情况及负载变化情况又往往是故障电弧发生的主要影响因素或决定因素。因此，有必要对目前常用负载特征进行归类。一般来说，作为家用电网终端负载的电器产品有 PC、电视机、电冰箱、洗衣机、空调、电风扇、电吹风、微波炉、电磁炉、抽油烟机等，从基本负载角度看，大多数为阻感性负载，而且感性



图 7 串联故障电弧实验平台实物

Fig.7 Physical map of series arc fault experiment platform

很小;工业电网终端电器产品如电机、电钻等亦大多为阻感性负载,与家用电器相比感性可能略大。这些负载或这些负载的各种组合形式在电路上基本都可以用等效的阻感性负载来代替(因容性很小在此先不做考虑)。基于以上种种考虑,在故障电弧发生实验中,本文采用 3 种典型负载,即纯阻性负载、纯感性负载、阻感性负载,来模拟现实中的各种电网终端负载。实验负载如表 2 所示。为更好地模拟现实情况,负载选用 200 W 白炽灯,0.1 H 电感线圈,串联的 200 W 白炽灯和 0.1 H 电感线圈。200 W 白炽灯阻值为 242 Ω,阻抗角为 0°,模拟纯阻性负载;0.1 H 电感线圈接近纯电感,阻抗角接近 90°,模拟感性强的负载;串联白炽灯和电感线圈使之兼具电感性和电阻性,阻抗角为 9.39°,模拟阻抗角介于 0°~90°的线性负载。

表 2 实验负载及参数

Table 2 Experimental loads and parameters

负载属性	实验负载	负载参数	数据采集	
			正常 (样本数)	故障 (样本数)
阻性负载	白炽灯	200 W	1 200	1 200
感性负载	线圈	0.1 H	1 200	1 200
阻感性负载	白炽灯+线圈	200 W+0.1 H	1 200	1 200

在采样频率为 50 kHz、采样时间为 0.2 s 的情况下,采用 TiePieSCOPE HS801 五合一虚拟综合测试仪采集 3 种负载正常运行和故障电弧发生时的回路电流信号。然后,对采集到的数据进行筛选。一次采样 10 个周期的电流信号,当检测到的故障电弧半周波数大于或等于 8 时,判断电路中存在故障电弧。最后,利用 MATLAB 软件算法对数据做进一步小波处理,保存为 mat 格式文件,并将 mat 文件转为.npy 文件以供模型调用。

3.3 电流信号波形分析

3 种负载情况下电路正常运行和发生故障电弧的实验电流信号如图 8 所示。对比后发现,故障电弧电流信号和正常运行电流信号差异明显。正常运行时,电流波形都为正弦波,具有很好的对称性。而故障电弧发生时,

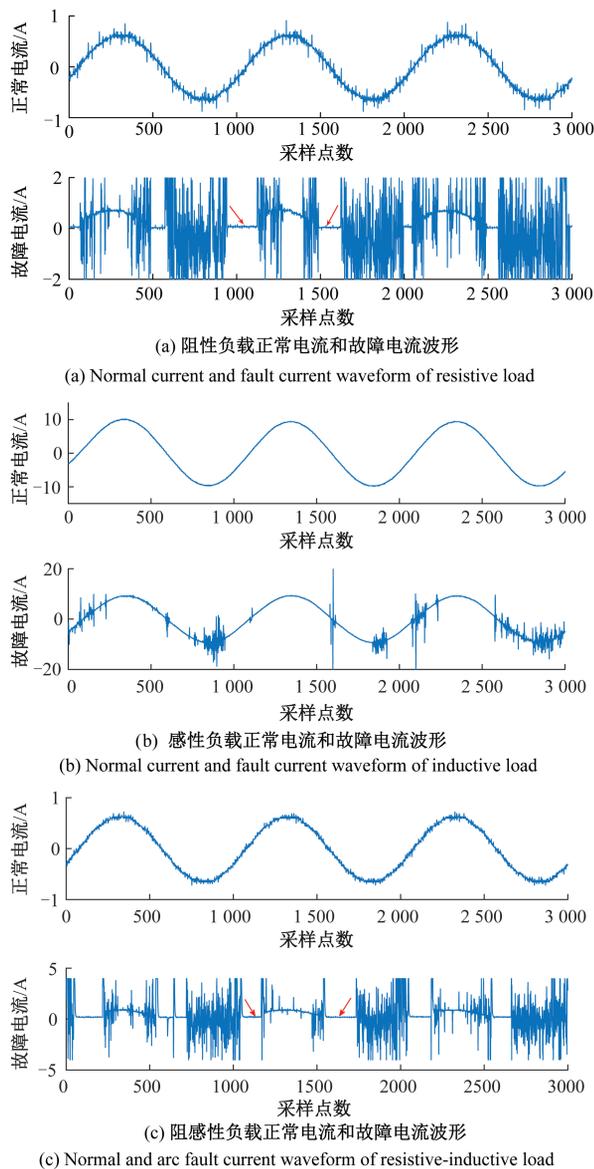


图 8 3 种负载的正常电流和故障电流波形

Fig.8 Normal current and fault current waveforms of three kinds of loads

电流波形变成无规则的波形,对称性遭到破坏。

如图 8(a) 标注的那样,故障电流波形过零点附近存在“平肩现象”^[25],平肩上有高频干扰信号,过零点后的电流上升坡度非常陡峭。而图 8(b) 由于电感储能作用,在外部电压不足以维持电流通路时,储存在电感中的能量被释放,维持电弧继续燃烧。因此电感负载下的电流波形基本保持为正弦波,平肩现象几乎没有。图 8(c) 故障电弧的重燃和熄灭同样都表现的较为明显。同时波形中存在一些冲击畸变,原因是负载中电感有放电过程,但阻性负载会消耗掉大部分的电感负载释放的能量,因而阻感性负载与阻性负载波形相似。

4 实验结果及分析

主机采用 intel (R) Core (TM) I7 - 7700HQ 处理器, 16.00 GB 运行内存。在 Ubuntu16.04 系统下, 利用 Pycharm Community 2.018.2 版软件的 tensorflow-gpu 配置构建改进的 AlexNet 模型。模型通过实际标签和预测标签值进行对比误差求解出残差, 再根据链式求导法则, 将残差通过求解偏导数逐步向上传递, 从而调整权重以及偏置。最终发现在学习率为 0.001, dropout 为 0.5, 每批次 100 个样本的情况下, 训练和测试效果比较好。

损失函数是模型学习的一个重要参数, 被用来衡量模型预测的好坏。损失值越小, 模型越好。通过计算实际标签和预测的标签之间的交叉熵平均值可以得出训练损失函数。损失函数如式 (9) 所示。

$$a_i = \frac{\exp(x_i)}{\sum_k \exp(x_k)} \tag{8}$$

$$\text{cost} = -\frac{1}{2} \sum_i y_i \log(a_i) \tag{9}$$

式中: x_i 代表全连接层 7 输出向量中的第 i 个元素; y_i 代表实际标签向量中第 i 个元素。

由于标签向量是由 0,1 组成, 因此最大值 1 所在的索引位置就是类别标签, 索引位置一样表示预测与真实标签匹配。预测标签最大值的索引位置将与对应的实际标签最大值索引位置比较, 得到一个 True or False 矩阵, 代表本轮预测的正确与否, 最后计算 true 的比例求得准确率。

从 7 200 个样本中随机选取 6 000 个作为深度神经网络的训练样本, 迭代 60 次后, 训练结束。模型训练准确率和损失函数的变化如图 9 和 10 所示。

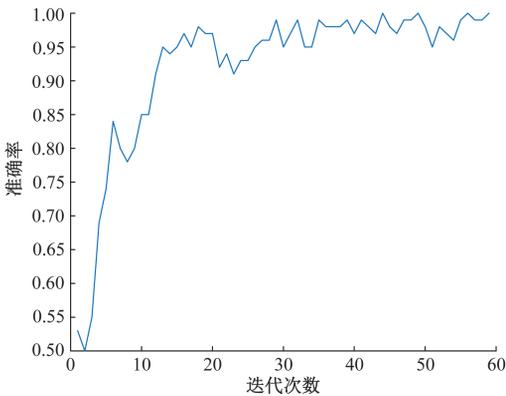


图 9 训练准确率变化

Fig.9 The change of training accuracy rate

用自适应矩估计 (adaptive moment estimation, Adam) 算法训练改进的 AlexNet 网络, 随着迭代次数的增加, 训

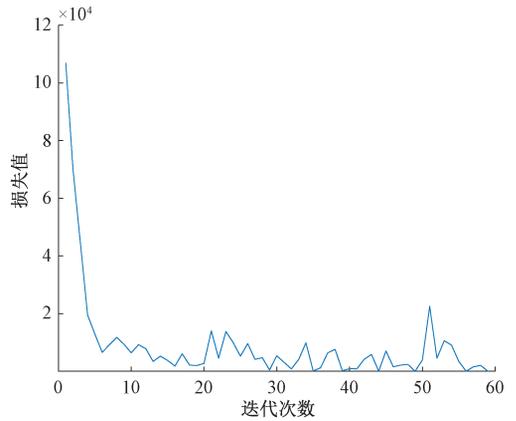


图 10 训练损失值变化

Fig.10 The change of training loss value

练准确率呈整体上升的趋势, 训练损失值呈整体下降的趋势。如图 9 所示, 准确率在迭代 26 次后基本收敛, 最高具有 100% 的学习准确率。图 10 损失值迭代 26 次后基本稳定在 4 000 左右。

图 11 所示为 1 200 个测试样本随机打乱后输入训练好的模型得到的测试结果。从图 11 可知, 测试结果总体维持在 95.58% 左右。然而, 从图 12 所示可以看出不同负载的测试结果不一样。感性负载测试样本的准确率平均值为 0.877 5, 阻感性负载测试样本的准确率平均值为 0.992 5, 阻性负载测试样本的准确率平均值为 0.997 5。比起感性负载, 阻性负载和阻感性负载的测试准确率相对较高。

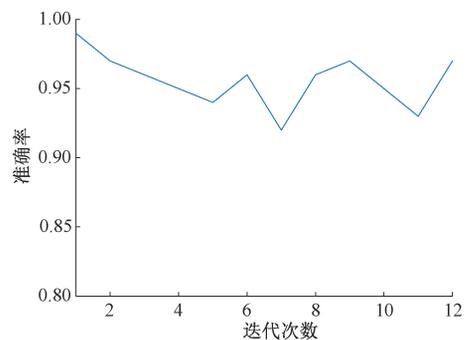


图 11 改进的 AlexNet 模型测试样本输出结果

Fig.11 Test sample output of improved AlexNet model

相同的串联故障电弧实验数据下, 直接将实验数据输入改进后的 AlexNet 模型进行训练, 并对训练好的网络进行测试, 其结果如表 3 所示。总体测试结果表明, 将实验数据直接输入 AlexNet 模型和将实验数据做小波变换后输入改进的 AlexNet 模型, 两种方法都具有良好的故障电弧检测性能。但是, 本文所提出方法得到的测试结果准确率要更高, 性能要优于前一种方法。

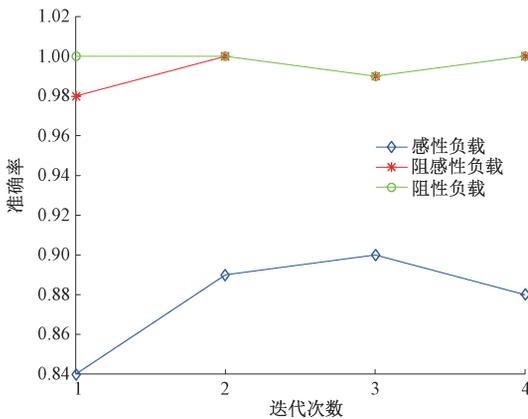


图 12 不同负载测试样本的输出结果

Fig.12 Output results of different loads' test samples

表 3 两种方法测试结果对比

Table 3 Comparison of test results of the two methods

批次	AlexNet 测试 准确率/%	小波特征 AlexNet 测试 准确率/%	批次	AlexNet 测试 准确率/%	小波特征 AlexNet 测试 准确率/%
1	78	99	7	87	92
2	78	97	8	89	96
3	88	96	9	85	97
4	80	95	10	88	95
5	89	94	11	83	93
6	89	96	12	89	97

5 结 论

利用深度学习能从大量样本中自动学习数据本质特征的能力和 小波变换多分辨率分析特性,本文提出了一种基于小波特征及深度学习的串联故障电弧检测新方法。参照 GB14 287.4-2014 标准,对 220 V 配电系统下的 3 种典型负载进行电流信号采样,分析故障电弧电流特性后,以小波分解后特征向量作为改进的 AlexNet 模型输入。实验结果表明,该方法具有较高的低压串联故障电弧识别准确率,为故障电弧检测的研究提供了新的思路,在实际故障电弧检出、火灾预测和消防安全方面具有较高的理论意义,为我国大数据时代下智能消防的构建与实现奠定一定的理论基础和实验经验。

参考文献

[1] GREGORY G D, SCOTT G W. The arc-fault circuit interrupter, an emerging product [C]. IEEE Industrial and Commercial Power Systems Technical Conference, 1998: 928-933.

[2] 赵景波,唐勇伟,张磊. 基于改进小波变换的故障电弧检测方法的研究 [J]. 电机与控制学报, 2016, 20(2): 90-97.
ZHAO J B, TANG Y W, ZHANG L. Improved wavelet transform algorithm of anti spectrum aliasing based on adding odd extraction before a node [J]. Electric Machines and Control, 2016, 20(2): 90-97.

[3] 金勇,马光辉. 航空电弧断路器的研究及应用 [J]. 航空制造技术, 2014(14): 92-94.
JIN Y, MA G H. Research and application of the arc-fault circuit breaker in airplane [J]. Aeronautical Manufacturing Technology, 2014 (14): 92-94.

[4] 杨凯,张认成,杨建红,等. 基于分形维数和支持向量机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.

[5] 刘晓明,徐叶飞,刘婷,等. 基于电流信号短时过零率的电弧故障检测 [J]. 电工技术学报, 2015, 30(13): 125-133.
LIU X M, XU Y F, LIU T, et al. the arc fault detection based on the current signal short time zero crossing rate [J]. Transactions of China Electrotechnical Society, 2015, 30(13): 125-133.

[6] 王启龙,王博文,管红立,等. 低压交流串联故障电弧模型及实验 [J]. 电力系统及其自动化学报, 2018, 30(2): 26-29,35.
WANG Q L, WANG B W, GUAN H L, et al. Model and experiment of low-voltage AC series fault arc [J]. Proceedings of the Chinese Society of Universities for Electric Power System and Automation, 2018, 30(2): 26-29,35.

[7] 王建华,张国钢,耿英三,等. 智能电器最新技术研究及应用发展前景 [J]. 电工技术学报, 2015, 30(9): 1-11.
WANG J H, ZHANG G G, GENG Y S, et al. The latest technology research and application prospects of the intelligent electrical apparatus [J]. Transactions of China Electrotechnical Society, 2015, 30(9): 1-11.

[8] 郭凤仪,邓勇,王智勇,等. 基于灰度-梯度共生矩阵的串联故障电弧特征 [J]. 电工技术学报, 2018, 33(1): 71-81.
GUO F Y, DENG Y, WANG ZH Y, et al. Series arc fault Characteristics based on gray level-gradient co-occurrence matrix [J]. Transactions of China Electrotechnical Society, 2018, 33(1): 71-81.

- [9] 黄伟翔, 张峰, 张士文. 基于 Hebb 与 BP 神经网络组合的故障电弧辨识方法[J]. 电气自动化, 2018, 40(4): 84-87.
HUANG W X, ZHANG F, ZHANG SH W. Fault arc identification method based on combination of Hebb and BP neural networks[J]. Electrical Automation, 2018, 40(4):84-87.
- [10] JOVANOVIĆ S, CHAHID A, LEZAMZ J, et al. Shunt active power filter-based approach for arc fault detection[J]. Electric Power Systems Research, 2016, 141: 11-21.
- [11] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.
- [12] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[C]. Advances in Neural Information Processing Systems 25, 2012: 1097-1105.
- [13] LEE S, SUNG Y, KIM Y, et al. Variations of AlexNet and GoogLeNet to improve korean character recognition performance [J]. Journal of Information Processing Systems, 2018, 14(1): 205-217.
- [14] 余琼芳, 黄高路, 杨艺, 等. 基于 AlexNet 深度学习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 fault arc diagnosis technology based on cycle analysis method[J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(3): 145-152.
- [15] ARTALE G, CATALIOTTI A, NUCCIO V C S, et al. A set of indicators for arc faults detection based on low frequency harmonic analysis [C]. 2016 IEEE International Instrumentation and Measurement Technology Conference, 2016: 1-6.
- [16] 刘丽智, 刘艳丽, 殷煜炜, 等. 基于关联维数与小波包-AR 谱的串联故障电弧特征研究[J]. 电子测量与仪器学报, 2018, 32(9): 108-116.
LIU L ZH, LIU Y L, YIN Y W, et al. Research on series fault arc characteristics based on correlation dimension and wavelet packet-AR spectra[J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(9): 108-116.
- [17] 李媛. 小波变换及其工程应用[M]. 北京:北京邮电大学出版社, 2010: 1-103.
LI Y. Wavelet Transform and Its Engineering Application[M]. Beijing: Beijing University of Posts and Telecommunications Press, 2010: 1-103.
- [18] 罗新, 牛海清, 来立永, 等. 粒子群优化自适应小波神经网络在带电局放信号识别中的应用[J]. 电工技术学报, 2014, 29(10): 326-333.
LUO X, LIU H Q, LAI L Y, et al. Application of adaptive wavelet neural network based on particle swarm optimization algorithm in online PD pattern recognition[J]. Transactions of China Electrotechnical Society, 2014, 29(10): 326-333.
- [19] DING L, LI H, HU C, et al. Alexnet feature extraction and multi-kernel learning for object-oriented classification[C]. ISPRS TC III Mid-term Symposium “Developments, Technologies and Applications in Remote Sensing”, 2018: 277-281.
- [20] PARK B, OH S, KIM I. Face alignment using a deep neural network with local feature learning and recurrent regression[J]. Expert Systems with Applications, 2017, 89: 66-80.
- [21] SUN K, LAN C, XING J, et al. Human pose estimation using global and local normalization [C]. IEEE International Conference on Computer Vision, 2017: 5599-5607.
- [22] UL1699, Arc-fault circuit-interrupts[S]. America:1999.
- [23] 全国消防标准化技术委员会火灾探测与报警分技术委员会. GB14287.4—2014, 电气火灾监控系统第4部分: 故障电弧探测器[S]. 北京:中国标准出版社, 2014.
SAC/TC113/SC6. GB14287.4—2014, Electrical fire monitoring system part 4: Fault arc detectors [S]. Beijing: China Standard Press, 2014.
- [24] 全国低压电器标准化技术委员会. GB/T31143—2014, 电弧故障保护电器 (AFDD)的一般要求[S]. 北京:中国标准出版社, 2014.
SAC/TC189. GB/T31143—2014, General requirements for arc fault detection devices (AFDD) [S]. Beijing: China Standard Press, 2014.
- [25] ZENG K, XING L, ZHANG Y, et al. Characteristics analysis of AC arc fault in time and frequency domain[C]. 2017 Prognostics and System Health Management Conference, 2017: 288-292.

作者简介

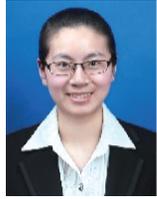


余琼芳, 分别在 1999 年和 2004 年于河南理工大学获得学士学位和硕士学位, 2013 年于燕山大学获得博士学位, 现为河南理工大学副教授, 大连理工大学北京研究院在站博士后, 主要研究方向为检测技术与自动化、智能检测与控制、信息融合、深度学习等。

E-mail: yuqf@hpu.edu.cn

Yu Qiongfang received B.Sc. and M.Sc. both from Henan Polytechnic University in 1999 and 2004, and Ph.D. from Yanshan University in 2013, respectively. Now she is an

associate professor at Henan Polytechnic University and a postdoctoral fellow in the Postdoctoral Programme of Beijing Research Institute of Dalian University of Technology. Her main research interests include detection technology and automation, multi-sensor data fusion and deep learning.



胡亚倩, 2017 年于河南理工大学获得学士学位, 现为河南理工大学硕士研究生, 主要研究方向为现代检测技术与装置。

E-mail: 1482485433@ qq.com

Hu Yaqian received her B.Sc. degree from Henan Polytechnic University in 2017. Now she

is a M.Sc. candidate at Henan Polytechnic University. Her main research interest includes modern testing technology and device.



杨艺, 分别在 2004 年和 2007 年于河南理工大学获得学士学位和硕士学位, 2017 年于北京航空航天大学获得博士学位, 现为河南理工大学讲师, 主要研究方向为测控技术、深度学习、自适应动态规划与强化学习等。

E-mail: yangyi@ hpu.edu.cn

Yang Yi received B. Sc. and M. Sc. both from Henan Polytechnic University in 2004 and 2007, and Ph. D. from Beihang University in 2017, respectively. Now he is a lecturer at Henan Polytechnic University. His main research interests include measurement and control technology, deep learning, adaptive dynamic programming and reinforcement learning.