

DOI: 10.19650/j.cnki.cjsi.J2412981

基于轻量卷积和模型优化的电弧故障检测方法*

刘艳丽¹, 王浩¹, 张帆²

(1. 辽宁工程技术大学电气与控制工程学院 葫芦岛 125105; 2. 国网葫芦岛供电公司电力调度控制中心 葫芦岛 125003)

摘要:在电动汽车电路系统中,直流串联电弧故障通常发生在接触点松动或线路连接损坏处,会引起火灾、爆炸等事故。为进行电动汽车中的串联型电弧故障研究,首先,搭建了电动汽车电弧故障实验平台,详细分析了不同工况下干路电流波形变化的原因与规律。由于电弧故障检测的高实时性需求,本研究采用了轻量型的卷积操作,即深度可分离卷积,基于深度可分离卷积搭建了电弧故障检测网络,实现了电动汽车电弧故障的检测与故障线路的判别。然后,针对低维度空间中深度可分离卷积特征提取能力受限的问题,本研究对其进行了改进,提出了特征表达能力更加优越的卷积操作:分组可分离卷积。最后,采用了递进式的阶梯结构,从网络浅层至深层,分组可分离卷积内每组的卷积核数量逐渐下降,在保证检测精度的前提下,实现了网络架构的精简与优化。进一步地,对检测模型进行了卷积核尺寸调优,并在结构中添加了轻量化注意力机制。在模型的训练过程中,应用了动态学习率调整策略。通过一系列的模型优化措施,系统性地增强了模型的运行效率与检测精度。模型的检测准确率达到96.76%,同时具有较好的泛化和抗干扰能力。

关键词:电动汽车;轻量型卷积操作;深度可分离卷积;分组可分离卷积;模型优化

中图分类号: TM501.2 TH89 **文献标识码:** A **国家标准学科分类代码:** 510.40

Arc fault detection method based on lightweight convolution and model optimization

Liu Yanli¹, Wang Hao¹, Zhang Fan²

(1. Faculty of Electrical and Control Engineering, Liaoning Technical University, Huludao 125105, China;

2. Power Dispatching Control Center, State Grid Huludao Power Supply Company, Huludao 125003, China)

Abstract: In electric vehicle circuit systems, DC series arc faults frequently occur at loose contact points or damaged line connections, leading to hazards such as fires and explosions. To study series arc faults in electric vehicles, an experimental platform specifically designed for electric vehicle arc faults was established. The causes and patterns of changes in the main current waveforms under various operating conditions were analyzed in detail. Given the stringent real-time requirements for arc fault detection, this study employed a lightweight convolution operation known as depthwise separable convolution to develop an arc fault detection network. This network achieved the detection of arc faults and the identification of fault lines in electric vehicles. To address the limitations of depthwise separable convolution in feature extraction in low-dimensional spaces, this study made improvements and proposed a convolutional operation with superior feature expression: group separable convolution. Ultimately, a progressive ladder structure was implemented, where the number of convolutional kernels within each group of the group separable convolution gradually decreases from the shallow layers to the deeper layers of the network. This approach streamlined and optimized network architecture while ensuring detection accuracy. Further enhancements involved optimizing the convolution kernel size within the detection model and integrating a lightweight attention mechanism into the architecture. A dynamic learning rate adjustment strategy was also applied during the model's training process. Through these optimization measures, both operational efficiency and detection accuracy were systematically improved. The model achieved a detection accuracy rate of 96.76% and exhibited good generalization and anti-interference capabilities.

收稿日期:2024-06-23 Received Date: 2024-06-23

* 基金项目:国家自然科学基金项目(52104160)、辽宁省教育厅科技创新团队项目(LJ222410147064)资助

Keywords: electric vehicle; lightweight convolutional operation; depthwise separable convolution; group separable convolution; model optimization

0 引言

近年来,随着电动汽车技术的迅猛进步、社会对安全问题关注度的日益增长、相关法规与标准体系的持续健全,以及市场需求对于产品安全性能的不提高,越来越多的研究学者将目光聚焦于电动汽车中电弧故障的深入探索与分析。Naidu 等^[1]通过监测汽车 42 V 直流网络中电弧故障发生时电流的变化率与预设的阈值的大小,能够有效探测到因导线夹挤、切断、载荷下接头松动等引发的电弧故障。Emrani 等^[2]研究了混合动力汽车中的电弧故障,提取了混合动力汽车电流信号的时域和频域共 12 个特征,并将这些多元特征输入到随机森林算法完成了电弧故障的检测。郭琳等^[3]使用小波包分解技术,对故障前后的直流电流信号进行了重构及特征提取,以能量比为特征参数,对直流电弧故障进行了有效判别。Xia 等^[4]提出了一种结合了加窗傅里叶变换技术和支持向量机模型的电弧检测算法,并通过预检测技术,降低了对直流电弧故障的误识别率。Shaffer 等^[5]采用双层滤波架构对电弧电流信号进行滤波,然后将滤波后信号的 Hurst 指数作为特征值,进行电动汽车电弧故障检测。任城龙^[6]研究了 24 V 直流系统中的故障电弧检测问题,通过电阻负载实验获取电弧与电压、电流之间的关系并总结了时域和频域分析方法。杨凯等^[7]针对真车电弧故障难以开展的问题,提出一种借助小功率电机与负载系统模拟故障的方法,以便快速开展大量实验,研究电弧故障特性。

针对电动汽车的电弧故障的研究还不同某些传统领域那样广泛,但现有的知识和技术创新可以为解决这一挑战提供宝贵借鉴。

电弧故障的检测技术多采用从时频域特性入手的策略。具体而言,就是细致分析电弧故障引发的电压与电流信号在时间与频率维度上的显著性变化,并精心挑选出这些变化中的关键特征,通过设置阈值或者将特征输入至先进的机器学习算法中,以此来进行故障的智能识别与分类。王毅等^[8]利用经验小波变换提取时频域特征分量的复合熵值与时域敏感特征组成的多域高维特征,再通过主成分分析降维,输入到概率神经网络完成故障电弧的检测。Han 等^[9]采用核主成分分析方法,实现电压、电流信号与谐波、噪声的有效分离,并采用基于萤火虫算法优化的支持向量机来识别电弧故障。唐圣学等^[10]通过计算电流信号脉冲因子,利用阈值比较法来检测故障电弧。在此基础上,提取了电流小波能量熵特征,结合极限学习机对微弱的故障电弧进行辨识。Ahn 等^[11]通过信号

的周期特征分析和零范围密度分析,有效地进行了系统噪声和电弧噪声的区分以及电弧故障检测。Jiang 等^[12]将火线和中性线通过电流互感器来耦合不对称磁通,提取到的耦合信号不受多负载电路的影响,避免了电弧故障信号与其他类型信号的混叠问题。Gao 等^[13]针对逆变电路三相电机中复杂谐波下串联电弧故障难以识别的问题,采用经验小波变换分解前端电流,构建吸引子轨迹矩阵并计算奇异值获取了故障特征,通过使用优化的支持向量机进行电弧故障识别。王俊法等^[14]针对串联电弧故障检测判据选择难、阈值设置难的问题,在传统基于电流检测方法的基础上融合使用电压信息,提出了一种电压电流能量信息融合的交流电弧故障检测方法。江永鑫等^[15]引入了 T 检验和方差贡献率形成了一种改进完整集合经验模态分解 (complete ensemble empirical mode decomposition, CEEMD) 方法,进一步提出一种基于改进 CEEMD 和随机森林的串联故障电弧识别方法。

上述研究结合了信号分析技术和经典机器学习方法进行电弧故障检测,但该方法受到主观性制约。特别是在信号复杂或微弱时,人工选取分析方法、构建特征的难度较大。因此,发展减少主观性、尤其是自动化特征提取的技术,对于提升故障检测的准确性和可靠性至关重要。

深度学习理论的快速发展有力推动了其在故障诊断领域的实际应用拓展。与人工选取特征参数相比,深度学习能够自动发现和提取数据中的潜在特征,适应不同的数据和任务,并减少人为主观性的干扰。Wang 等^[16]以原始的电流信号为输入,建立了一个一维的卷积神经网络 ArcNet,并在树莓派上对算法的实时性和准确性进行了验证。Zhang 等^[17]采用生成对抗网络对故障数据进行增强,并利用了自适应非对称卷积神经网络,提升了低采样频率下的电弧故障辨识能力。张婷等^[18]通过灰度数据转换将一维电流时序转换为二维图像,利用自归一化卷积神经网络识别电弧故障特征。Paul 等^[19]调整了 EffNet 模块的构造,使其能够处理一维的电流数据,提出了一种基于 EffNet 模块的轻量级串联电弧故障检测算法 Efficient-ArcNet。Ning 等^[20]同样基于 EffNet 模块提出了一种轻量级电弧故障检测算法,并针对时域特性优化了 EffNet 模块的首尾卷积层。Tang 等^[21]提出了一种基于轻量级一维卷积神经网络电弧故障检测模型,使用了深度可分离卷积对模型进行改进。

深度学习因具备自我学习特性,能自动抽取电流信号特征,免除了人工特征辨识的步骤,有效缩减了人力和时间成本,同时增强检测精确度。它随数据积累及模型

优化迭代,能不断增强检测效果,灵活应对多样化的电弧故障场景。但传统的深度学习框架计算密集,大规模模型地实施面临实时性挑战及嵌入式系统部署难题。近年来,一系列轻量化神经网络模型的涌现为该领域带来转机。这些模型不仅是人工智能研究的热点,也是实现电弧故障快速检测的关键技术突破,极大促进了检测效率与实用性。文献[19-21]中虽已探索采用轻量级策略,然而它们所提出的检测模型并未专门设计以适应于本研究聚焦的电动汽车电弧故障检测场景。

针对电动汽车中串联电弧故障的检测问题,本研究搭建了电动汽车电弧故障模型系统,使用深度学习策略,提出了基于卷积神经网络电弧故障检测算法。本研究的主要贡献包括:

1) 引用了轻量级卷积运算,即深度可分离卷积,并深入分析了其在低维度空间操作时的局限性。基于此分析,对深度可分离卷积改进,提出了一种性能更为优越的轻量级卷积方法,命名为分组可分离卷积。

2) 在构建检测网络后,采用了阶梯式架构设计策略,从网络的浅层至深层,分组可分离卷积内每组中卷积核的数量由多到少,在确保检测精度的同时,精简了网络结构。然后,优化了卷积核尺寸,添加了轻量级的注意力机制到网络架构中,在训练流程中实施了动态学习率调整策略。这些综合性的优化措施显著地提升了模型的整体性能。

1 串联电弧故障实验

1.1 实验系统与实验方案设计

本研究搭建了一套专用于模拟电动汽车电弧故障的实验系统,系统的结构布局如图1所示。主系统由锂离子电池组供电,负载部分主要包括一款型号为JY72V200W的无刷直流电机与其配套控制器JY36,车载空调系统以及PTC加热单元。车载空调部分由直流电

机5GU-5K、直流电机调速器DC6-90V15AMAX与直流风机共同实现。PTC加热单元整合了4条额定功率为80W的PTC加热棒来模仿车内的加热机制,其实际功率受控于热敏电阻的居里点温度与外部电压条件。为模拟真实驾驶条件下汽车所承受的动态阻力,配置了1台磁粉制动器PB-40,经传动皮带与无刷电机相连。分别使用LHB-T1电压传感器和LHB-Y2电流传感器进行电压和电流的采集,采样频率为50kHz。所收集的电气参数数据经由数据采集卡传输至计算机系统中进行后续分析处理。

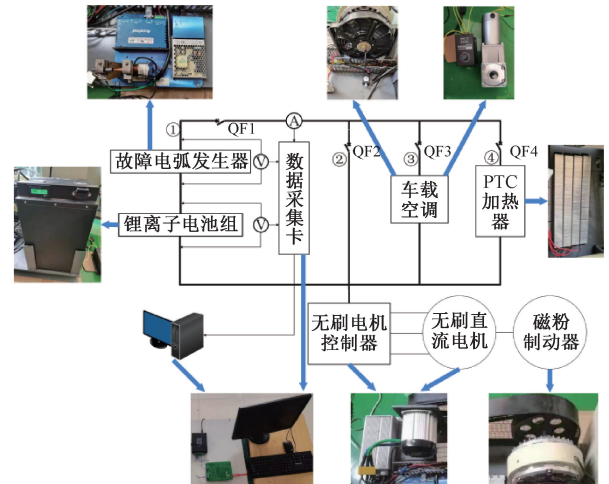


图1 电动汽车电弧故障实验平台

Fig. 1 Experimental platform for the fault arc of electric vehicles

实验方案设计如表1所示。实验中通过旋钮调节无刷直流电机的回路电流来控制其转速,通过调节调速器旋钮至不同刻度位置,可控制空调系统中电机转速的多级变化。使用开关控制实验中PTC加热棒的投入个数。鉴于电弧故障的突发性和不确定性,实验中分别将电弧故障发生器放置于主电路位置①及各分支电路位置②、③、④处。

表1 电动汽车电弧故障实验方案

Table 1 Experimental scheme for arc fault in electric vehicles

组别	负载类型	电机回路电流/A	空调转速	PTC 功率	发生器位置	电路状态
1~6	电机	10/15	无	无	①	正常/无振动电弧/振动电弧
7~42	电机+空调	10/15	刻度 10/刻度 20	无	①,②,③	正常/无振动电弧/振动电弧
43~78	电机+PTC 加热器	10/15	无	160 W/320 W	①,②,④	正常/无振动电弧/振动电弧

实验用电弧故障发生器可见文献[22]。实验中,通过改变发生器的工作方式来产生不同类型的电弧故障。具体如下:

1) 通过音圈电机拖动移动电极与静止电极分开一小段距离后,保持间隙距离恒定,以此来模拟电动汽车内电

气接触点断开后产生电弧故障的情形。

2) 音圈电机拖动移动电极做周期性匀速运动,使动静电极间的距离不断变化,以此模拟松动的电气接触点由于外部振动不断接触又分离的情形。在进行振动实验时,振幅设置为450 μm,振动频率为15 Hz。

1.2 实验结果分析

无刷直流电机在独立运行状态下的回路电流图形如图 2 所示。在电机运行与电弧故障的共同作用下,干路电流呈现出一种独特的周期性现象。无振动条件下产生电弧故障时,触点分断后,回路电流也随之断开。随触点间电压渐增直至跨越放电阈值,间隙被击穿,电路导通。由于电机具有启动特性,电路导通后电机再次启动会存在一个较大的启动电流,所以电流曲线中会出现尖峰现象。然后,电机转速迅速恢复至正常水平,电流减小,系统向稳定状态过渡。不过,由于电流的快速减小,电弧电阻和电压逐渐增加,反馈作用于电机电压下降,促使电流进一步减小,最终致使电弧难以自持而熄灭。电弧消失导致电流中断,电机随之减速,又因反电动势的作用,间隙电压无法即刻回升至电源电压水平,而是经历一个爬升的过程,直至达到间隙击穿点。如此,完成一次完整的循环。




图 2 电机单独运行时的回路电流波形

Fig. 2 Loop current waveform when the motor is operating alone

在振动条件下,随着移动电极朝固定电极接近,弧间距离逐渐减小,间隙电压逐渐增加达到击穿电压后,电弧重燃。当触点经历闭合后再分离,且间距扩大至某一临界点时,电弧熄灭,致使干路电流回落至零。当移动电极再次向静止电极移动,间隙电压达到电弧击穿电压后,完成一次循环。电流周期变化的频率接近电弧故障发生器的振动频率。

综上所述,在无振动和振动条件下,电机作为负载时,干路电流波形中均存在周期现象。由于现象的起因存在差异,导致了周期现象中干路电流波形的不同。

当空调或 PTC 加热器在工作时,由于与电机并联运行,在振动和无振动条件下,干路电流一直处于连续状态。由图 3 可知,空调支路故障时,无振动状态下干路电流中的谐波含量增多,振动条件下产生周期性特征,此特征的周期频率与振动频率有关。由图 4 可知,PTC 支路故障后,由于 PTC 加热器为阻性负载且运行功率较小,在 PTC 加热器支路燃弧前后,干路电流的周期性及谐波特征均不明显。

由于负载状态的多样性和个别负载工作时其特征信息的隐蔽性,通过传统的时频域特征提取的方法进行多种工作状态判别的困难度较高,通过对信号特征的研究




图 3 电机和空调并联运行时的干路电流波形

Fig. 3 Trunk current waveform when the motor and the air conditioner are in parallel




图 4 电机和 PTC 加热器并联运行时的干路电流波形

Fig. 4 Trunk current waveform when the motor and the PTC heater are in parallel

针对性的开发相应的识别算法又会消耗大量的时间和精力。于是,本研究运用了深度学习技术,搭建了卷积神经网络。通过利用该网络的自我学习能力,自动实现信号特征的提取,并最终实现对系统不同工作状态的有效识别。

2 轻量型的电弧故障检测模型

由于电弧故障检测具有较高的实时性要求,大规模的卷积神经网络难以满足需求。本研究通过引入轻量型的卷积操作,设计了电弧故障检测模型。

由于本研究进行的是监督学习,于是如表 2 所示,在进行网络训练前,按电弧故障的位置对不同状态下的数据样本进行了标记。如此,模型训练完成后,通过将模型的输出与标签进行对比,判断是否发生了电弧故障以及故障位置。

表 2 系统不同运行状态的划分及其标签

Table 2 The division of various operating states of the system and their corresponding labels

系统运行状态	标签
正常运行(电机,电机+PTC,电机+空调)	0
干路故障(电机+PTC,电机+空调)	1
电机回路故障(电机,电机+PTC,电机+空调)	2
PTC 加热器支路故障(电机+PTC)	3
空调支路故障(电机+空调)	4

2.1 基于深度可分离卷积的电弧故障检测模型

深度可分离卷积 (depthwise separable convolution, DSConv) 是一种高效的卷积运算方式,常用于卷积神经网络中以减少计算成本和参数数量,同时保持较好的模型性能。这种卷积可以分解为 2 个更简单的步骤:深度卷积 (depthwise convolution, DWConv) 和逐点卷积 (pointwise convolution, PWConv),其结构如图 5 所示。

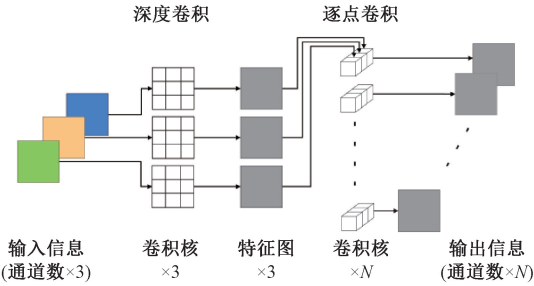


图 5 深度可分离卷积结构

Fig. 5 Depthwise separable convolution structure diagram

如图 5 所示, DWConv 不会改变通道的数量,对于输入的每个通道信息,使用一个单独的卷积核对其进行卷积,输出信息的通道数量和输入信息一致,且不同的输出特征图之间没有联系。

PWConv 也被称为 1×1 卷积,在 DWConv 之后执行,使用一组 1×1 大小的卷积核,作用于 DWConv 输出的所有通道上,整合不同通道中的特征信息。此操作可以改变输出特征图的深度,即增加或减少通道的数量,同时因为卷积核尺寸小,计算成本相对较低。

表 3 中展示了常规的卷积 (convolution, Conv) 与 DSConv 在结构和规模上的差异,由于本研究的检测对象为一维的电流数据,所以运用了一维卷积。卷积核尺寸为 5×1,将 32 维的数据升维到 64 维,DSConv 的参数量仅为 Conv 的 21.56%。

表 3 常规卷积与深度可分离卷积对比

Table 3 Comparison of conventional convolution and depthwise separable convolution

卷积	结构	参数量/k
Conv	5×1×32×64	10.240
DSConv	5×1×32 (DWConv)	2.208
	1×1×32×64 (PWConv)	

综上所述, DSConv 相比 Conv 极大的降低了计算资源的需求,这种方法能极好的应用于移动设备和资源受限的环境中。

基于 DSConv 搭建了检测模型,模型的结构如图 6 所示。




图 6 基于深度可分离卷积的检测模型结构

Fig. 6 Structural diagram of the detection model based on depthwise separable convolution

将 1 000×1 长度的电流数据输入到特征提取层进行特征提取,该层由 1 个 Conv 层、5 个 DSConv 层、5 个最大池化层和 1 个自适应平均池化层组成,每个卷积层后放置批归一化层和 ReLU 激活函数。特征提取层的输出结果经展开层转换为一维向量后传递给分类层。分类层包括 2 个全连接层,数据经过全连接 (fully connected, FC) 层后使用 Softmax 函数进行分类。训练时,学习率为 0.001, batch_size 为 100,每轮训练 100 次。

模型训练完毕后,检测结果的混淆矩阵如图 7 所示。模型的整体准确率为 93.27%。不同状态的下的检测准确率为 90.98% (系统正常运行)、93.59% (干路故障)、94.48% (电机支路故障)、91.17% (PTC 支路故障)、97.97% (空调支路故障)。

		真实类				
		系统正常运行	干路故障	电机支路故障	PTC支路故障	空调支路故障
预测类	标签 0	1744 90.98%	5 0.39%	0 0.00%	56 8.52%	7 1.09%
	1	13 0.68%	1198 93.59%	105 5.42%	0 0.00%	3 0.47%
	2	2 0.01%	74 5.78%	1831 94.48%	1 0.02%	0 0.00%
	3	150 7.82%	3 0.23%	2 0.01%	599 91.17%	3 0.47%
	4	8 0.42%	0 0.00%	0 0.00%	1 0.02%	627 97.97%

图 7 基于深度可分离卷积的模型检测结果混淆矩阵

Fig. 7 Confusion matrix of the model detection results based on depthwise separable convolution

由于 PTC 支路故障时干路电流中故障信号特征的隐蔽性,系统正常运行状态和 PTC 支路故障状态会产生较多样本的相互误判。当电机与其他负载并联运行时,由于电机的工作功率较高,工作原理复杂,干路故障后,干路电流的主要特征取决于电机负载,所以干路故障和电机支路故障也存在样本的相互误判情况。

2.2 基于分组可分离卷积的电弧故障检测模型

通过搭建基于 DSConv 的轻量型电弧故障检测模型能够进行电弧故障的识别和故障位置的判断。但

DSConv 具有其局限性,DSConv 中的 DWConv 阶段是对每个输入通道应用单独的卷积核,无法进行通道数量的扩展,因此在低维空间工作时,由于通道数量较少,导致卷积核的数量受到限制,无法充分提取输入信息特征,影响了模型的表达能力和准确性。为了解决此问题,本研究将 DSConv 中的 DWConv 改进为分组卷积 (group convolution, GConv),改进后的结构被命名为分组可分离卷积 (group separable convolution, GSConv)。

GConv 的操作图如图 8 所示,其中,输入通道被分成几个不交叉的组,每组使用独立的卷积核进行计算,之后将各组结果合并。DWConv 是 GConv 的一个特例,其中分组数等于输入通道数,且每个组只有 1 个卷积核,专注于在每个通道内部的空间信息提取。

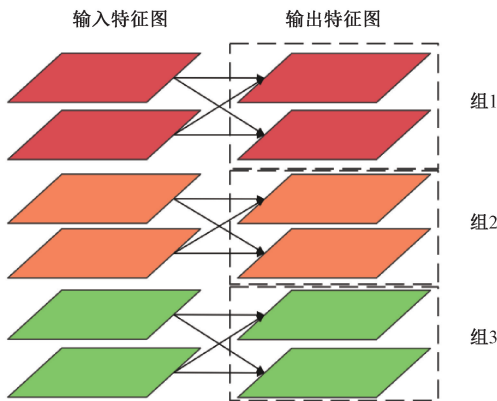


图 8 分组卷积结构

Fig. 8 Structure diagram of group convolution

在 DWConv 的设定下,卷积中卷积核的数量是不可更改的。而将 DWConv 更换为 GConv 后,同样使分组个数等于输入信息通道数,但卷积核的个数可变,一个通道可以使用多个卷积核进行卷积。例如,当每个分组中的卷积核个数为 2 时,GSConv 的结构如图 9 所示。输入信息共 3 个通道,GConv 阶段,每个通道使用 2 个或更多的卷积核进行卷积,充分提取信息特征。然后使用 PWConv 进行输出信息的整合并根据需求进行信息深度的变换。

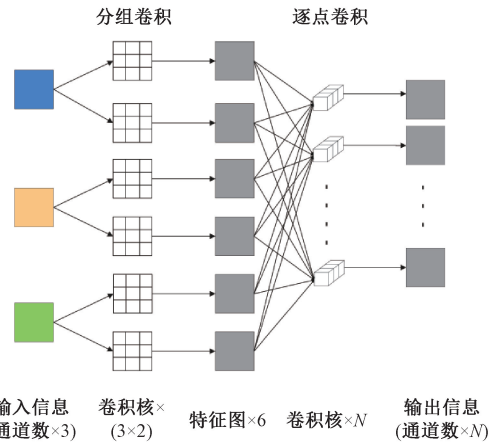


图 9 分组可分离卷积结构

Fig. 9 Structure diagram of group separable convolution

基于 GSConv 搭建了检测模型,暂将 GConv 中每组的卷积核个数设置为 2,模型的参数如表 4 所示。

表 4 基于分组可分离卷积的检测模型的参数设置

Table 4 Parameter settings of the detection model based on the group separable convolution

网络结构	卷积核尺寸	输出信息尺寸	参数量/k
Conv	5×1×1×32	1 000×32	0.160
Max pooling1	2×1	500×32	
GSConv1	5×1×(32×2) (GConv) 1×1×(32×2)×64 (PWConv)	500×64	0.320 4.096
Max pooling2	2×1	250×64	
GSConv2	5×1×(64×2) (GConv) 1×1×(64×2)×64 (PWConv)	250×64	0.640 8.192
Max pooling3	2×1	125×64	
GSConv3	5×1×(64×2) (GConv) 1×1×(64×2)×96 (PWConv)	125×96	0.640 12.288
Max pooling4	2×1	62×96	
GSConv4	5×1×(96×2) (GConv) 1×1×(96×2)×96 (PWConv)	62×96	0.960 18.432
Max pooling5	2×1	31×96	
GSConv5	5×1×(96×2) (GConv) 1×1×(96×2)×128 (PWConv)	31×128	0.960 24.576
Adaptive Avg pooling		1×128	
Flatten		128	
FC (128, 5)	128×5	5	0.645

将基于 DSConv 和 GSConv 构建的检测模型的训练过程进行对比,结果如图 10 所示。可知,使用 GSConv 后,模型的检测精度显著提升。




图 10 不同检测模型的训练过程对比

Fig. 10 Comparison of the training processes for the different detection models

3 模型优化过程

本研究基于 GSConv 搭建了电弧故障模型,为了提高模型对于电弧故障检测任务的适应度,对检测模型进行了逐步优化。

3.1 卷积核数量和尺寸优化

使用 GSConv 是为了解决 DSConv 中, DWConv 在网络浅层、特别是卷积核数量较少时,特征提取能力无法充分发挥的问题。在已搭建的完成的检测模型中,从浅到深各卷积层中输入和输出信息的通道数量由少到多。在信息通道数量较多的情况下 DSConv 的特征提取性能能够得到有效的发挥。所以,在网络深层的卷积层中可以考虑继续使用 DSConv。

本研究对 GSConv 中每组的卷积核数量进行了阶梯型调整。首端常规卷积后的 5 个 GSConv 层, GSConv 中每组的卷积核个数分别为 3、2、2、1、1。当个数为 1 时, GSConv 也就更换为了 DSConv。如此,兼顾了模型的计算效率与特征表达能力,有效地平衡了模型学习能力与资源消耗。

经过数次训练对比后,模型结构调整前后检测模型的比较如表 5 所示。对卷积核数量进行阶梯型调整后,检测模型在保持检测准确率的基础上其参数量降低为调整前的 72.30%。

表 5 卷积核数量的阶梯型调整效果对比

Table 5 Comparison of the step-type adjustment effects of the number of convolution kernels

	准确率/%	参数量/k
结构调整前	94.29	74.277
结构调整后	94.18	53.701

卷积核的尺寸直接影响着神经网络的局部特征提取能力、感受野大小、计算成本及模型的表达能力。较小的卷积核聚焦于捕捉细腻的局部特征,适合处理需要精确边缘和纹理信息的任务,但可能限制了对更大范围上下文的理解;较大的卷积核能够捕获更广泛的上下文信息,有利于全局特征的学习,但可能丢失局部特征且计算开销更大。选择合适的卷积核尺寸是平衡特征精细度、模型理解能力及效率的关键,对网络性能优化至关重要。所以,本研究对卷积核的尺寸进行了优化。

首先使用了 3 个不同尺度的卷积核,其尺寸分别为 5×1 、 15×1 、 25×1 ,进行卷积核尺寸的大范围粗选,结果如图 11 所示。




图 11 不同尺寸卷积核下检测模型的准确率对比
Fig. 11 Comparison of detection model accuracy under convolution kernel of different sizes

由图 11 可知,使用较大尺寸的卷积核可以提高检测模型的准确率。然而,随着卷积核尺寸的增加,模型准确率的提升会逐渐达到一个上限。因此,进一步对比了不同尺寸 (15×1 附近) 的卷积核对检测模型的影响,具体结果如表 6 所示。

表 6 不同尺寸的卷积核对模型性能的影响分析
Table 6 Analysis of the impact of model performance by convolution kernels of different sizes

卷积核尺寸	准确率/%	参数量/k
11	94.63	57.157
13	95.23	58.309
15	95.74	59.461
17	95.68	60.613
19	95.71	61.765

卷积核的尺寸增加,模型的参数量也随之提升。分别以准确率和参数量为第 1 和第 2 选择标准,确定了模型的卷积核尺寸为 15×1 。

3.2 注意力机制优化

在深度学习中,注意力机制模仿了人类在处理信息时

聚焦于某些部分的能力,它使模型能够动态地聚焦于输入数据中最重要的部分,而不是均匀地分配计算资源给所有输入。注意力机制的核心思想是自动加权输入信息,强调相关性强的部分,弱化或忽略不相关的信息,从而提高模型处理复杂任务的能力。本研究继续从轻量的角度出发,选择了高效通道注意力机制 (efficient channel attention, ECA) 对模型进行优化,ECA 的核心思想如下:

1) 高效轻量:ECA 模块避免了传统注意力机制中复杂的降维和升维操作,采用一维卷积来捕捉通道间的相关性,显著减少了计算成本。

2) 局部交互:通过使用全局平均池化(global average pooling, GAP) 得到每个通道的全局特征后,应用一个与通道数相关的一维卷积核进行局部通道间的交互,这保留了通道间的重要信息,同时限制了模块复杂度。

3) 自适应卷积核大小:ECA 机制引入了一种自适应方式来确定一维卷积核的尺寸,确保了既能捕捉到足够的上下文信息,又不至于增加过多的计算负担。

ECA 的具体操作流程如图 12 所示。首先对输入特征图的每个通道应用全局平均池化,这步操作将每个通道的特征图压缩为一个标量,形成一个全局特征向量,代表了整个图像或特征图的通道级统计信息。然后利用一个一维卷积核对该全局特征向量进行卷积操作。这个卷积核的大小是通过非线性映射与输入通道数动态关联的,旨在捕捉局部通道间的依赖关系。卷积后的结果通过 Sigmoid 激活函数处理,生成每个通道的注意力权重。这些权重反映了各个通道对于后续任务的重要性。最后,将得到的注意力权重与原始特征图逐通道相乘,实现对输入特征的加权调整,强化重要特征,抑制不重要特征。图 12 中, H 、 W 、 C 分别为特征图的高度、宽度和通道数。 k 为卷积操作中卷积核的尺寸,可根据通道数的大小自适应的进行调整。 σ 代表 Sigmoid 激活函数。




图 12 ECA 模块的工作原理

Fig. 12 Working schematic diagram of ECA module

将 ECA 模块添加到每 2 个卷积操作之间,可以显著提升模型的检测性能,ECA 模块添加前后的模型性能对比如图 13 所示。同时添加 ECA 模型后,模型的参数量仅增加 34。

在进行了模型结构调整、卷积核尺寸调整和添加 ECA 模块后,优化后的模型参数如表 7 所示。




图 13 添加 ECA 模块前后检测模型的准确率对比
Fig. 13 Comparison of detection model accuracy before and after addition of ECA module

表 7 优化后的检测模型参数

Table 7 Parameters of the optimized detection model

网络结构	卷积核尺寸	输出信息尺寸	参数量/k
Conv	15×1×1×32	1 000×32	0.480
ECA	3×1		0.003
Max pooling1	2×1	500×32	
GConv	15×1×(32×3)		1.440
ECA	3×1		0.003
PWConv	1×1×(32×3)×64	500×64	6.144
ECA	3×1		0.003
Max pooling2	2×1	250×64	
GConv	15×1×(64×2)		1.920
ECA	5×1		0.005
PWConv	1×1×(64×2)×64	250×64	8.192
ECA	3×1		0.003
Max pooling3	2×1	125×64	
GConv	15×1×(64×2)		1.920
ECA	5×1		0.005
PWConv	1×1×(64×2)×96	125×96	12.288
ECA	3×1		0.003
Max pooling4	2×1	62×96	
GConv	15×1×(96×1)		1.440
ECA	3×1		0.003
PWConv	1×1×(96×1)×96	62×96	9.216
ECA	3×1		0.003
Max pooling5	2×1	31×96	
GConv	15×1×(96×1)		1.440
ECA	3×1		0.003
PWConv	1×1×(96×1)×128	31×128	12.288
Adaptive Avg pooling		1×128	
Flatten		128	
FC(128,5)	128×5	5	0.645

整体而言,添加 ECA 模块能够显著增强模型的检测性能。然而,在训练过程的某些阶段,观察到个别时刻的准确率指标反而略低于未集成 ECA 模块之前的模型。这一现象可归因于较高的学习率设置,导致参数更新时的步长较大。虽然较高的学习率加速了对最优解的探索过程,但也导致了准确率曲线的明显振荡,进而可能导致训练结束时输出的模型内部参数并非最优。为了避免偶然性,在进行不同模型间的对比时,需要多次训练和观察。此外,这种振荡现象也影响了最终检测模型的选择。

3.3 动态学习率调整策略优化

将学习率分别调整至 0.000 5 和 0.000 1,并对模型进行训练,其训练过程如图 14 所示。




图 14 不同学习率下模型的训练过程对比
Fig. 14 Comparison of the training processes of the models with different learning rates

在降低了学习率之后,模型的检测准确率有所下降。当学习率设定为 0.001 时,尽管参数更新的步长较大,使得准确率曲线呈现出显著的波动性,但较高的学习率有助于加速收敛进程,在训练初期能更快地逼近最优解。然而,当减少学习率时,虽然这增加了模型收敛的稳定性,却也减慢了训练速度,要求更多的迭代轮次以达到理想的性能水平,并且增加了陷入局部最小值而难以脱困的风险。例如当学习率降至 0.000 1 时,模型表现出了陷入局部最优的现象。

为了优化模型的训练过程,引入了动态学习率调整策略。该策略使得模型能够在训练初期利用较高的学习率快速接近最优解区域;在训练后期,学习率自动减小,允许模型对参数进行精细化调整,逐步逼近最优解。这样不仅保证了收敛的速度,还提升了模型的泛化能力和最终的准确性。动态学习率调整策略对模型训练过程的改善效果如图 15 所示。

在应用动态学习率调整策略时,初始学习率设定为 0.001,并以准确率作为检测指标。若准确率在连续 10 次训练中未能显著提升(提升率小于 0.1%),则将学习率乘以 0.1 进行衰减。此策略不仅确保了模型在训练初期能够迅速响应并捕捉到数据中的显著特征,还在训练的中后期,当模型性能提升开始趋于平缓时,通过逐步减小学习率来促进模型的精细调整。此外,学习率的自




图 15 添加动态学习率调整策略前后的模型训练过程对比
Fig. 15 Comparison of model training process before and after adding dynamic learning rate adjustment strategy

动调整机制能够更高效地利用计算资源,避免了手动微调学习率所带来的额外时间和复杂性。

本研究聚焦于 DSCConv 在低维度空间操作时其性能受限的问题,提出了性能更优的 GSConv 操作,并以此为基础构建了电弧故障检测的模型。为了进一步优化该模型,调整 GSConv 中的卷积核数量,采用阶梯结构,在网络的浅层采用 GSConv,在深层则转用 DSCConv,如此在保持了模型特征表达能力的同时降低了资源消耗。此外,通过调整卷积核的尺寸以及引入 ECA 模块,进一步提升了模型的整体性能。为了改善训练流程,运用了动态学习率调整策略。经过这一系列的优化措施,检测模型的参数数量为 59 495,整体的检测准确率为 96.76%。

4 模型性能验证

4.1 模型泛化性分析

在进行振动电弧故障实验研究的过程中,首先将振动频率设定为 15 Hz,并完成了模型的训练阶段。随后,为了进一步评估该模型在新环境下的适应性能,在单电机负载工作时进行了不同电流强度及不同振动频率条件下的电弧故障实验。新获取的数据直接用作测试样本,具体结果如表 8 所示。实验结果表明,该模型可以对未参与训练的不同电流和振动频率下的样本数据进行有效识别,展示出较好的泛化能力。

表 8 不同负载电流和振动频率下的模型性能分析

Table 8 Analysis of model performance at different load current and vibration frequencies

电流/A, 振频/Hz	检测精度/%	电流/A, 振频/Hz	检测精度/%
10, 10	97.08	15, 10	97.21
10, 20	98.96	15, 20	99.13
12, 10	96.88	17, 10	96.87
12, 15	98.09	17, 15	98.12
12, 20	99.27	17, 20	99.42

4.2 模型抗扰性分析

当负载被接入电路时,会引起干路电流的变化,这种变化可能会对检测模型的判定产生影响。图 16 中,展示了在电机运行期间接入空调或 PTC 加热器后干路电流的变化情况和模型的检测结果。

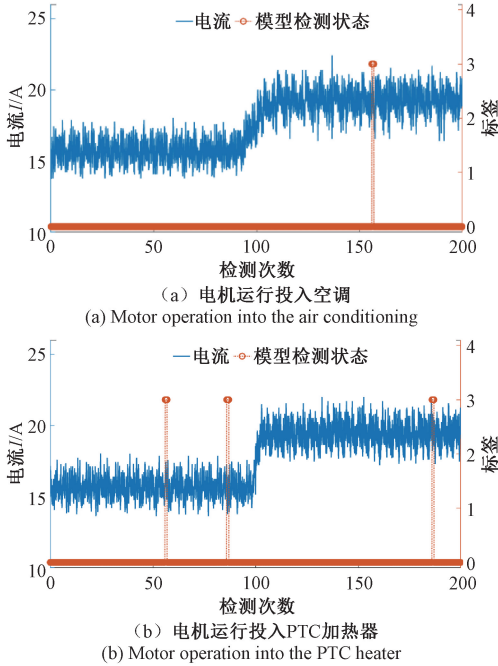


图 16 电机运行时投入其他负载后的电流变化和模型检测结果

Fig. 16 The current changes and model detection results when other loads are added to the running motor

由于空调的调节通过旋钮控制,如图 16(a)所示,空调投入运行后,电流的变化呈现一个渐进的过渡过程。PTC 加热器的启停由开关控制,如图 16(b)所示,PTC 加热器投入后,电流的变化速率较快。经过实际验证,负载的接入并未对检测模型的稳定性和准确性造成负面影响,从而证实了该模型具备优良的鲁棒性。

另外,图 16 中可见在系统正常运行状态下,模型出现了误判的情况。由于 PTC 支路故障特征的微弱性,导致个别正常信号(标签 0)被错误地识别为 PTC 支路故障状态(标签 3)。这种情况在实际应用中,如电动汽车的正常运行期间,会带来不利影响。为了避免这种误判带来的潜在风险,可以采用多次检测确认的方式,例如,连续进行 5 次检测,只有在至少 3 次检测中模型判定为故障状态时,才最终确认系统中发生了电弧故障。

在电动汽车的加速或减速过程中,电机的工作状态动态变化,于是对电机功率持续增长的正常运行工况进行了验证。结果如图 17 所示,即便在电机功率持续提升的操作模式下,检测模型仍可保持较高的准确度。




图 17 电机持续增大功率时的电流变化情况和模型检测结果
Fig. 17 The current changes and model detection results when the motor continuously increases the power

4.3 不同检测模型的对比分析

将本文构建的轻量型电弧故障检测模型命名为 LAFNet(lightweight arc fault detection model)。表 9 中,将优化后网络模型中的卷积结构全部更换为 Conv 或者 DSConv,生成的模型分别为 Model-1 和 Model-2。注意力机制、学习率调整策略等优化保持不变。与采用 Conv 结构的检测模型相比,本研究提出的检测模型在保持相近准确率的同时,其网络规模仅相当于常规卷积检测模型的 11.69%,这充分体现了该检测模型的轻量化特性。然而,若完全使用 DSConv 来构建模型,则会导致检测准确率的下降。

表 9 基于不同卷积结构的检测模型性能对比

Table 9 Performance comparison of detection models based on different convolutional structures

模型	基础结构	准确率/%	参数量/k
Model-1	Conv	96.80	508.985
Model-2	DSConv	95.78	41.891
LAFNet	GSCConv DSConv	96.76	59.495

文献[16]提出了电弧故障检测模型 ArcNet,其基础为常规的卷积神经网络。文献[19]的同样进行了电弧故障检测模型的轻量化研究。通过集成 EffNet 模块,构建了 Efficient-ArcNet 模型。文献[21]基于 DSConv 构建了电弧故障检测模型 Li-DtNet。将本文提出的检测模型 LAFNet 中的特征提取层进行修改,替换为上述文献中所使用的结构。将不同检测模型进行对比,结果如表 10 所示。

通过对比,ArcNet 的参数量较高,为 LAFNet 的 260.82%。轻量型的检测模型 Efficient-ArcNet 和 Li-DtNet 模型规模较小,但检测的准确率低于 LAFNet。相较于 LAFNet,Efficient-ArcNet 和 Li-DtNet 具有相对简洁的网络结构,但应用于电动汽车电弧故障的检测中,其

表 10 不同检测模型的性能对比

Table 10 Performance comparison of the different detection models

检测模型	准确率/%	参数量/k
ArcNet ^[16]	94.69	155.173
Efficient-ArcNet ^[19]	92.69	59.301
Li-DtNet ^[21]	90.12	46.469
LAFNet	96.76	59.495
Efficient-ArcNet-1	95.28	61.061
Li-DtNet-1	93.19	74.661

特征表达能力略显不足。在 Li-DtNet 的基础上添加 2 个卷积层,对 Efficient-ArcNet 进行卷积核尺寸优化和添加动态学习率调整策略,生成的模型分别为 Efficient-ArcNet-1 和 Li-DtNet-1。调整后的模型其检测的准确率明显提高,但依旧要低于 LAFNet,而模型的参数却高于了 LAFNet。

综上,通过对比验证了本研究提出的电动汽车电弧故障检测模型结构的合理性、一系列优化措施的正确性和必要性。

5 结 论

本研究对电动汽车中的串联电弧故障进行了较为全面的模拟,包括搭建多分支实验电路,使用不同类型的负载、改变生弧方式和生弧位置等,并详细分析了在负载性质、生弧方式等多因素影响下干路电流波形变化的本质原因。

采用了卷积神经网络技术来应对电弧故障的诊断挑战。为了增强模型的诊断效率,运用了 DSCConv 策略,设计出一种轻量型的电弧故障检测模型。鉴于 DSCConv 在处理低维数据时存在的性能局限,本研究对其进行了改进,提出了 GSConv。GSConv 增强了模型在特征表达层面的能力,进一步增强了电弧故障的识别精度。

最后,本研究通过优化轻量级检测模型的架构及卷积层尺寸,并在网络结构中添加了 ECA 模块,在训练过程中实施了动态学习率调整策略,从而有效提升了模型的运行效率和检测准确性。

参考文献

[1] NAIDU M, SCHOEPEF T J, GOPALAKRISHNAN S. Arc fault detection scheme for 42-V automotive DC networks using current shunt [J]. IEEE Transactions on Power Electronics, 2006, 21(3) : 633-639.


[2] EMRANI A, POURHOMAYOUN M. Applying machine learning techniques to recognize arc in vehicle 48

electrical systems [C]. 2017 IEEE 18th Workshop on Control and Modeling for Power Electronics (COMPEL), 2017, 1-4.

- [3] 郭琳,柯希彪,汤引生,等. 新能源汽车电弧故障检测方法 & 测试系统设计 [J]. 绝缘材料, 2018, 51(11) : 74-79.
- GUO L, KE X B, TANG Y SH, et al. Design of arc fault detection method and test system for new energy automobiles [J]. Insulating Materials, 2018, 51(11) : 74-79.
- [4] XIA K, ZHANG Z H, LIU B ZH, et al. Data-enhanced machine recognition model of DC serial arc in electric vehicle power system [J]. IET Power Electron, 2020, 13(19) : 4677-4684.
- [5] SHAFFER B, ABULLAH Y, WANG J, et al. On-line detection of dc arc faults using hurst exponents for hybrid-electric vehicles [C]. 2020 IEEE Energy Conversion Congress and Expositio (ECCE), 2020 : 6372-6378.
- [6] 任城龙. 新能源汽车检测技术的应用研究 [J]. 时代汽车, 2021(11) : 110-111.
- REN CH L. Research on the application of new energy vehicle testing technology [J]. Auto Time, 2021(11) : 110-111.
- [7] 杨凯,庄宏航,董毓利,等. 电动汽车驱动电机与负载模拟系统建模及电弧故障仿真研究 [J]. 电子测量与仪器学报, 2024, 38(1) : 237-245.
- YANG K, ZHUANG H H, DONG Y L, et al. Modeling of electric vehicle driving motor and load simulation system and arc fault simulation research [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(1) : 237-245.
- [8] 王毅,刘黎明,李松浓,等. 基于经验小波变换复合熵值与特征融合的电弧故障检测 [J]. 电网技术 : 2023, 47(5), 1912-1919.
- WANG Y, LIU L M, LI S N, et al. Arc fault detection based on empirical wavelet transform composite entropy and feature fusion [J]. Power System Technology, 2023, 47(5), 1912-1919.
- [9] HAN C X, WANG ZH Y, TANG AI X, et al. Recognition method of AC series arc fault characteristics under complicated harmonic conditions [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70 : 3509709.
- [10] 唐圣学,刁旭东,陈丽,等. 光伏发电系统直流串联微弱故障电弧检测方法研究 [J]. 仪器仪表学报, 2021, 42(3) : 150-160.
- TANG SH X, DIAO X B, CHEN L, et al. Study on detection method of weak series DC fault arc in PV power

- generation systems [J]. Chinese Journal of Scientific Instrument, 2021, 42(3): 150-160.
- [11] AHN J B, JO H B, RYOO H J. Real-time DC series arc fault detection based on noise pattern analysis in photovoltaic system[J]. IEEE Transactions on Industrial Electronics, 2023, 70(10): 10680-10689.
- [12] JIANG R, BAO G H, HONG Q T, et al. Machine learning approach to detect arc faults based on regular coupling features [J]. IEEE Transactions on Industrial Informatics, 2023, 19(3): 2761-2771.
- [13] GAO H, WANG Z, HAN C, et al. Feature extraction method of series arc fault occurred in three-phase motor with inverter circuit [J]. IEEE Transactions on Power Electronics, 2022, 37(9): 11164-11173.
- [14] 王俊法, 胡伟, 王玮, 等. 电压电流能量信息融合的低电压交流电弧故障检测 [J]. 电子测量与仪器学报, 2024, 38(3): 55-66.
- WANG J F, HU W, WANG W, et al. Low voltage AC arc fault detection based on energy information fusion of voltage and current [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(3): 55-66.
- [15] 江永鑫, 陈丽安, 郭梦倩, 等. 基于改进 CEEMD 和 RF 的低电压串联故障电弧识别方法 [J]. 电力系统保护与控制, 2024, 52(1): 97-108.
- JIANG Y X, CHEN L AN, GUO M Q, et al. Identification method of low voltage series fault arc based on improved CEEMD decomposition and RF [J]. Power System Protection and Control, 2024, 52(1): 97-108.
- [16] 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, 2022, 18(1): 77-86.
- [17] 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.
- [18] 张婷, 王海淇, 张认成, 等. 基于自归一化神经网络的光弧故障检测方法 [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.
- [19] PAUL K C, ZHAO T F, CHEN CH, et al. Efficient-ArcNet: Series AC arc fault detection using lightweight convolutional neural network [C]. 2021 IEEE Energy Conversion Congress and Exposition (ECCE), 2021: 1327-1333.
- [20] NING X, SHENG D J, ZHOU J W, et al. Arc_EffNet: A novel series arc fault detection method based on lightweight neural network [J]. Electronics, 2023, 12(22): 4617.
- [21] TANG AI X, WANG ZH Y, TIAN SH G, et al. Series arc fault identification method based on lightweight convolutional neural network [J]. IEEE Access, 2024, 12: 5851-5863.
- [22] LIU Y L, LYU ZH Y, ZHANG S Y, et al. Feature extraction and detection method of series arc faults in a motor with inverter circuits under vibration conditions [J]. IEEE Transactions on Industrial Electronics, 2024, 71(6): 6294-6303.

作者简介



刘艳丽, 2004 年于辽宁工程技术大学获得学士学位, 2007 年于辽宁工程技术大学获得硕士学位, 2017 年于辽宁工程技术大学获得博士学位, 现为辽宁工程技术大学副教授, 主要研究方向为电接触理论及其应用、电气故障诊断。

E-mail: liuyanli19810919@163.com

Liu Yanli received her B. Sc. degree, M. Sc. degree, and Ph. D. degree all from Liaoning Technical University in 2004, 2007 and 2017, respectively. Now she is an associate professor in Liaoning Technical University. Her main research interests include electrical contact theory and its applications, electrical fault diagnosis.



王浩 (通信作者), 2022 年于辽宁工程技术大学获得学士学位, 现为辽宁工程技术大学硕士研究生, 主要研究方向为电接触与电弧理论。

E-mail: 2607589522@qq.com

Wang Hao (Corresponding author) received his B. Sc. degree from Liaoning Technical University in 2022. Now he is a M. Sc. candidate at Liaoning Technical University. His main research interests include electrical contact and arc theory.



张帆, 2020 年于东北电力大学获得学士学位, 2023 年于辽宁工程技术大学获得硕士学位, 现工作于国网葫芦岛供电公司的电力调度控制中心, 主要研究方向为电接触与电弧理论。

E-mail: zhangfan19981029@163.com

Zhang Fan received his B. Sc. degree from Northeast Electric Power University in 2020 and M. Sc. degree from Liaoning Technical University in 2023. Now he is working in power dispatching control center of State Grid Huludao power supply company. His main research interests include electrical contact and arc theory.