

DOI: 10.13382/j.jemi.B2307117

基于多卷积和结构搜索的电弧故障检测模型*

刘艳丽¹ 王浩¹ 李佳原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 葫芦岛 125003)

摘要: 串联型电弧故障主要由电路中电气接触点接触不良引起,是引发电动汽车电气火灾的主要原因之一,直接威胁着车内人员的生命安全。为对其进行研究,论文搭建了电动汽车直流串联型电弧故障实验平台,获取了系统处于不同工作状态下的电源端电压信号,分析了电弧故障对电源端电压的影响。在构建检测模型时,论文使用了卷积神经网络,引入轻量型的卷积操作并考虑了其在实际应用中的局限性。将常规卷积和轻量化卷积操作结合,构建了电弧故障检测的初步模型。接着以网络的规模和准确率为评估指标,通过具有精英保留策略的遗传算法对模型的外部结构和内部参数进行搜索。最终建立了适合电动汽车的电弧故障检测(arc fault detection, AFD)的检测模型 AFDNet。该模型的检测准确率达到 93.73%,在嵌入式设备 Jetson Nano(JN)中的运行时间为 10.82 ms。模型建立后,论文在网络的规模、准确性及实时性方面,将搜索算法的搜索结果与其他的网络结构进行比较,验证了搜索算法所得结果的合理性。并通过与其他检测方法对比,证明了电动汽车电弧故障检测模型 AFDNet 性能的优越。

关键词: 电动汽车;电弧故障检测;轻量化卷积;遗传算法;精英保留策略

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 model based on multi-convolution and structure search

Liu Yanli¹ Wang Hao¹ Li Jiayuan¹ Zhang Fan²

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

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

Abstract: The series arc fault is mainly caused by poor contact of the electrical contact points in the circuit, which is one of the main causes of electric vehicle fires, directly threatening the life safety of the occupants. In order to study it, an experimental platform for DC series arc fault of electric vehicles was established. The voltage signals of the power supply terminal were obtained under various working conditions, and the impact of arc faults on the power supply terminal voltage was analyzed. When constructing the detection model, the paper used a convolutional neural network, introduced a lightweight convolution operation, and considered its limitations in practical applications. Combining conventional convolution and lightweight convolution operations, a preliminary model for arc fault detection was constructed. Then, with the scale and accuracy of the network as the evaluation index, the genetic algorithm with elite preservation strategy was used to search for the external structure and internal parameters of the model. Finally, the model AFDNet suitable for arc fault detection (AFD) of electric vehicles was established. The detection accuracy of the model is 93.73%, and the running time on the embedded device Jetson Nano (JN) is 10.82 ms. After establishing the model, the paper compared the search results of the algorithm with other network structures in relation to network size, accuracy, and real-time performance, verified the validity of the results obtained by the search algorithm. By comparing AFDNet with other detection methods, it was proven that the performance of the electric vehicle arc fault detection model was superior.

Keywords: electric vehicle; arc fault detection; lightweight convolution; genetic algorithm; elite preservation strategy

0 引言

近年来,电动汽车行业迅速发展,但电动汽车火灾事故也随之增多。2022 年全国接报的电动汽车火灾事故多达 1.8 万余起,而电弧故障是引发电动汽车火灾事故的主要原因之一。电动汽车在行驶过程中,外部碰撞、道路颠簸等情况会导致其电气接触点接触不良,进而引发串联型电弧故障。直流电弧不存在自然过零点,一旦产生难以自行熄灭,局部温度可达数千摄氏度,如果不及时诊断和熄灭,极易造成电气火灾事故。

在电动汽车电弧故障研究领域中,Emrani 等^[1]提取了混合动力汽车电流信号的时域和频域共 12 个特征,结合随机森林算法完成串联型电弧故障检测。Liu 等^[2]基于 VGG16 网络设计了电动汽车充电系统中直流串联电弧故障的检测方法。Xia 等^[3]为了提高电动汽车电弧故障的检测效率,采用了预检测算法和一种基于噪声扰动的数据增强模型。Abdullah 等^[4]提出一种基于两级滤波和赫斯特指数估计的电动汽车直流电弧故障检测方法,并将该方法在 DSP 上实现。相较于光伏系统、家庭供电系统等,目前电动汽车领域故障电弧研究成果较少,缺少成熟的电弧故障检测方法。

在其他的直流电弧故障研究领域中,一些研究人员通过人工提取信号中的故障特征开发了电弧故障检测算法。唐圣学等^[5]计算了回路电流的小波能量熵,结合极限学习机(ELM)辨识微弱电弧故障。李智华等^[6]通过理论分析、仿真和实验,分析了光伏系统中不同位置、不同类型的故障电弧信号在传播过程中的变化情况。Miao 等^[7]通过赫斯特指数(Hurst exponent, H)结合经验模态分解(empirical mode decomposition, EMD)对电流信号进行滤波和特征提取,通过支持向量机(support vector machine, SVM)算法实现串联电弧故障检测。Gao 等^[8]利用改进的经验小波变换(improved empirical wavelet transform, IEWT)获得回路电流各分量的复合多尺度排列熵,通过 salp 群优化的孪生支持向量机(twin support vector machines, TWSVM)实现串联电弧故障检测。杨洋等^[9]针分别从时域、频域及时间尺度等多个维度提取电流特征量,利用机器学习分类模型进行电弧故障识别。孟羽等^[10]通过对故障电弧电流信号进行随机共振处理,增大了光伏系统电流信号在燃弧前后的差异。Cai 等^[11]对干路电流信号进行变分模态分解,从模态分量中提取多个统计指标作为信号特征,利用皮尔逊相关分析对特征进行筛选,最后结合 SVM 进行故障诊断。

文献[5-11]将信号分析方法与阈值方法或传统的机器学习算法相结合来检测 SAF。由于必须人为地确定信号分析方法、特征向量的构造方法和分类器,此类方法具

有较强的主观性。而且当信号特征较复杂或较微弱时,人为提取信号特征困难,直接影响了检测准确率。

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。邱婷婷等^[12]针对单一时间尺度特征受到环境变化的干扰导致检测精度降低的问题,提出了一种多时间尺度小波和长短时记忆自编码器电弧故障检测方法。陈思磊等^[13]使用包络微分算子增强故障电弧特征,并采用半监督学习模型融合该特征辨识直流故障电弧和生弧材料。Zhang 等^[14]利用改进的生成对抗网络增加故障数据,通过自适应非对称卷积神经网络提高了卷积层对电弧故障的特征提取和诊断能力。Wang 等^[15]提出了一种基于卷积神经网络电弧故障检测模型 ArcNet,并将该模型在树莓派 3B 中实现。Paul 等^[16]提出了一种基于 effnet 的轻量级串联电弧故障检测算法 Efficient-ArcNet,并使用树莓派 4B 进行了算法性能评估。Lu 等^[17]提出一种具有对抗数据增强的轻量级 CNN 模型,并采用 CompactRIO-9030 进行了实时性测试。Sung 等^[18]提出一种基于迁移学习的低能量电弧故障检测网络 TL-LEDarcNet,提高了低能量电弧故障的检测效率,并通过 NVIDIA Jetson Nano 对网络性能进行了实时性测试。文献[12-18]基于深度学习的方法建立了电弧故障检测模型。虽然这些方法具有较好的识别性能和泛化性能,但模型的参数依旧是通过人工手动设置,具有一定的主观性。而且文献[12-14]没有对模型的规模进行评价,并不知晓模型是否能够部署到嵌入式的设备中,是否能够满足检测时间的要求。文献[15-18]将检测模型部署到了嵌入式设备中,但模型的检测性能有待提升。

电弧故障会引起电路中的电流异常,上述文献以干路电流作为分析对象,不过通过电压、电磁波等信号也可以进行电弧故障检测。Amiri 等^[19]将电源端电压作为分析对象,提出一种基于递归图的光伏系统串联电弧故障检测方法。贾科等^[20]解析了串联电弧故障的热特性,建立了故障前后线路电流与电缆表皮温度的映射关系曲线,通过判断故障映射相比正常映射的偏移程度来检测故障。Xing 等^[21]以电源端电压的时频图像为输入,利用卷积神经网络结合长短时记忆网络提取信号的静态特征,完成电弧故障诊断。王尧等^[22]使用 Vivaldi 天线进行电弧电磁辐射信号测量,从而进行电弧故障的检测和定位。

论文以电源端的电压信号为检测对象,从深度学习的角度出发,使用了网络结构搜索策略,建立了一个电动汽车直流串联电弧故障检测模型 AFDNet,并将模型部署到了嵌入式设备中进行了性能评估。论文的主要学术贡献和创新点如下:

1) 提出了一个串联型电弧故障检测模型,命名为AFDNet。AFDNet将常规卷积和轻量化卷积操作相结合,相较于单纯使用常规卷积或轻量化卷积的检测模型,AFDNet具有更强的检测性能。

2) 使用精英保留策略优化的遗传算法对模型的外部结构和内部参数进行搜索,提高了模型对于电弧故障检测的适应性。相比于人工进行网络结构调整,自动搜索将节省大量的时间和人力资源,可在一定程度上避免研究人员主观意识对模型性能的影响。

1 串联电弧故障实验

1.1 实验系统和实验方案

实验平台如图1所示。系统的主电路由一个锂离子电池组供电。系统负载部分主要由无刷直流电机JY72V200W及其控制器JY36、车载空调和PTC加热器组成。车载空调由直流电机5GU-5K、直流电机调速器DC6-90V15AMAX和直流风机共同模拟。PTC加热器模拟的是电动汽车中的加热源,共四根加热棒,每根加热棒的额定功率为80W,实际工作时,其功率与热敏电阻的居里温度及外加电压有关。磁粉制动器PB-40通过传送皮带与无刷直流电机连接,给工作中的无刷电机施加阻力,模拟电动汽车在真实道路上行驶的情形。通过电流传感器LHB100A5VY2和两个电压传感器LHB500V5VT1分别采集干路电流、电弧电压和电源端电压信号,采集的信号通过数据采集卡传输至计算机,信号的采样频率为50kHz。

实验方案如表1所示。根据电动汽车内实际的负载

表1 实验方案

Table 1 Experimental protocol

组别	负载类型	无刷电机回路电流	空调电机转速	PTC投入数量	电弧发生器位置	运行状态
1~4	电机	15 A/20 A	无	无	②	正常/故障
5~8	空调	无	旋钮刻度 20/40	无	③	正常/故障
9~12	PTC加热器	无	无	2根/4根	④	正常/故障
13~36	电机+空调	15 A/20 A	旋钮刻度 20/40	无	①,②,③	正常/故障
37~60	电机+PTC加热器	15 A/20 A	无	2根/4根	①,②,④	正常/故障

1.2 实验数据分析

以电机、空调、PTC加热器单独运行为例,发生电弧故障前后的电源端电压波形如图2所示。无刷直流电机JY72V200W和空调中的直流电机5GU-5K都属于电机类负载,而且电机前端的控制器或调速器与电机配合工作,其工作原理和控制过程较为复杂。当发生电弧故障时,电机的稳定运行过程被破坏,负载受到的影响又被反馈到系统中,进而影响了电源端的电压信号,如图2(a)和(b)所示。相比之下,当PTC加热器工作时,由于其是

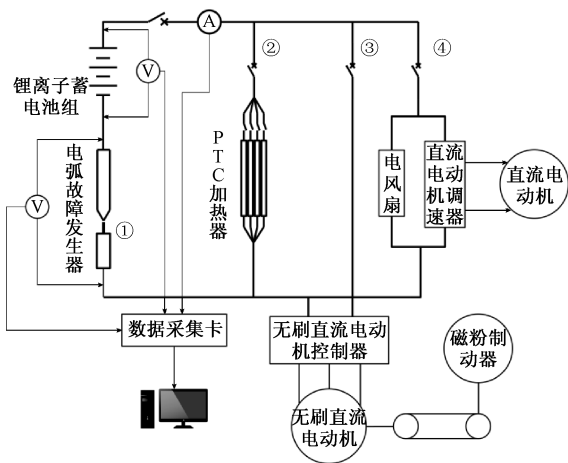


图1 实验平台

Fig. 1 Experimental platform

使用情况,分别进行了单负载和多负载运行实验。由于电动汽车中不可同时运行加热和制冷操作,多负载并联运行实验中,没有出现空调和PTC加热器并联运行的情况。在进行变量的调节时,通过调节无刷直流电机JY72V200W调速旋钮和磁粉制动器投入系统的阻力来调整无刷电机的回路电流,模拟电动汽车在道路上以不同速度行驶的情况。通过调节直流电机调速器DC6-90V15AMAX的调速旋钮,调整空调制冷功率大小。通过调节PTC加热器投入数量设置制热功率大小。由于负载类型的多样性和电弧故障产生位置的随机性,实验中单负载运行时,将电弧故障发生器置于图1中的各支路位置②、③或④,多负载运行时,分别将电弧故障发生器置于干路位置①和各支路位置②、③或④。

阻性负载且运行功率较小,发生电弧故障后,PTC加热器受到的影响较小,系统整体运行较为平稳,导致电源端的电压波形在故障前后无明显变化,如图2(c)所示。

进一步观察电压信号在故障前后的变化情况。选取了平均值、方差和峭度分别探究信号的平均水平、波动程度和尖峰程度。表2中特征参数在燃弧前后的比值也反映了对于图2的分析结果。当电机和空调单独运行时,故障发生后电压信号的波动程度增加,信号中的增添了明显的尖峰特征。而PTC加热器单独运行时,特征比值




图 2 故障前后的电源端电压波形对比
Fig. 2 Comparison of the voltage waveform of the power supply end before and after the fault

接近 1, 故障特征较微弱。

表 2 故障前后的特征值比值

Table 2 Ratio of the characteristic values before and after the fault

	电机	空调	PTC 加热器
平均值	1. 013 4	0. 997 0	0. 997 6
方差	3. 255 3	1. 493 5	1. 028 3
峭度	1. 679 5	1. 587 1	1. 111 0

2 方法原理介绍

通过对图 2 和表 2 的分析可知, 通过传统的人工提取信号特征的方式进行电动汽车电弧故障检测具有一定

的困难。因此, 论文基于深度学习强大的信号特征提取和自学习能力, 以电源端电压为数据样本, 首先结合常规卷积和轻量型卷积搭建了一个待搜索的网络模型。然后使用网络搜索技术对网络的结构和参数进行搜索, 根据搜索结果建立了完整的电动汽车电弧故障检测模型 AFDNet。最后对搜索结果的合理性和模型的性能进行了验证。检测模型的搭建流程如图 3 所示。




图 3 检测模型的搭建流程

Fig. 3 The construction process of the detection model

另外, 本文使用深度学习方法进行监督学习。在获得实验数据后, 首先对数据进行标记, 如表 3 所示。对不同类型的实验数据进行划分并打上标签, 将数据输入深度学习模型中进行训练时, 模型会根据自己输出的标签与原数据标签的对比去调整模型内部的参数, 尽可能的使模型输出的标签与原数据标签保持一致。模型训练完毕后, 没有参与模型训练且提前打好标签的测试数据被输入模型中进行检测, 将模型输出的标签与原测试数据标签进行比较, 从而得出检测的准确率。

表 3 标签设置

Table 3 Label settings

负载类型	状态	标签
电机	正常	0
	故障	1
空调	正常	0
	故障	1
PTC 加热器	正常	0
	故障	1
电机+空调	正常	0
	故障	1
电机+PTC 加热器	正常	0
	故障	1

2.1 常规卷积操作

卷积操作是卷积神经网络中的核心操作。常规的卷积操作如图 4 所示, 卷积核通过在输入数据上滑动并进行逐元素相乘再求和的方式, 从而提取出数据的特征信息。另外, 可以通过修改卷积核的个数, 改变信息的通道数量。

本文搭建的是一维的卷积神经网络, 对一维的电压数据进行处理。图 5 中, 通过修改卷积核的尺寸和进行卷积操作时的移动方向, 使卷积操作能够适用于一维的




图 4 常规卷积操作

Fig. 4 Operation of the conventional convolution




图 7 深度卷积操作

Fig. 7 Operation of the depthwise convolution

数据。

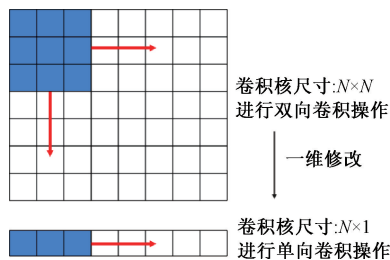


图 5 卷积操作的一维修改

Fig. 5 One-dimensional modification of the convolution operation

2.2 移动翻转瓶颈卷积

移动翻转瓶颈卷积 (mobile inverted bottleneck convolution, MBConv) 是一种轻量型的卷积操作,其结构如图 6 所示。



图 6 MBConv 结构

Fig. 6 The structural diagram of the MBConv

MBConv 中的卷积操作主要包含 3 个步骤:

1) 首先使用逐点卷积 (pointwise convolution, PW) 扩充输入信息的通道数量。PW 的操作与常规卷积相同,不过其卷积核大小为 1×1 。将 PW 的输出通道数与输入通道数的比值定义为扩张比例。

2) 通道扩张后使用了深度卷积 (depthwise convolution, DW),其操作如图 7 所示。与图 4 中常规卷积的操作方式不同,DW 进行的是逐通道卷积,无法对通道数进行拓展。一个卷积核对应一个通道,卷积运算在每个通道之间独立运行,输出信息各通道之间没有关联。由于 DW 没有改变通道数量的能力,当输入通道数较少时,DW 只能在低维度上工作,因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。步骤 1) 的通道扩充操作保证了的 DW 的性能能够得到充分地发挥。

3) 为了避免网络结构过于庞大,在 MBConv 的末端

使用一个 PW 进行数据压缩,把高维特征映射到低维空间。

另外,为增强卷积神经网络的特征表示能力,在 DW 和后端的 PW 间加入了 SE (squeeze-and-excitation) 注意力机制。它能够通过学习动态权重来调整特征图中不同通道的重要性,从而使网络能够更好地关注重要特征。

MBConv 使用了残差连接,将输入信息和卷积操作的输出信息进行融合,使网络能够更容易地学习到数据中的细节和上下文信息。但由于电动汽车电弧故障检测对实时性的要求较高,所以本文提出的是一个浅层网络,网络参数数量相对较少,信息流动比较直接,不存在深层网络中的梯度消失问题。而且当卷积层的输入和输入通道数不一致时,使用残差连接时需要使用 PW 来调整通道数,这会额外的增大网络规模。

Dropout 通过随机丢弃神经元的输出,减少过拟合、防止共适应,提高模型的鲁棒性。但此种操作相当于模型的每次训练都是在不同的子网络上进行,导致模型的学习速度变慢。并且在本文实际的网络训练中,使用 Dropout 会对网络的准确率产生影响。

于是本文在使用 MBConv 时删除了残差连接和 Dropout。修改后的 MBConv 如图 8 所示。在每个卷积层后放置 BN (batch normalization) 层和 ELU 激活函数。




图 8 修改后的 MBConv 结构

Fig. 8 Structural diagram of the modified MBConv

2.3 基于精英保留策略优化的遗传算法

相比于人工进行网络结构调整,自动搜索将节省大量的时间和人力资源,可避免研究人员主观意识的干扰和观察次数不足造成的偶然性。论文在网络的搭建过程中,使用了基于精英保留策略的遗传算法对网络的外层结构 (卷积层数量) 和内部参数 (卷积核尺寸、扩展比例) 进行搜索。

遗传算法是一种受生物进化理论启发的优化算法,

通过模拟基因的遗传、变异和适应性筛选等过程,不断迭代地优化解决问题。在传统的遗传算法中,每一代的个体都会经过选择、交叉和变异等操作生成新的个体,取上一代的个体形成新的种群。这种方式可能导致优秀的个体被较差的个体取代,降低种群的整体质量。为解决这一问题,在遗传算法中加入了精英保留策略,在每一代中保留当前种群中表现最好的个体,不参与选择、交叉和变异操作,直接复制到下一代种群中,这样就保留了种群中的优秀个体,防止其在进化过程中被淘汰,使遗传算法能够更好地保持种群的多样性和进化的方向,避免陷入局部最优解。

论文在使用基于精英保留策略的遗传算法搜索网络结构时,具体的搜索过程包括如下几个步骤:

1) 初始化种群:首先,随机生成一组初始网络结构作为种群,这些网络结构包括不同的卷积层数量、卷积核尺寸和扩展比例。

2) 评估适应度:针对种群中的每个网络结构,利用评估指标(网络的准确率和参数量)对其性能进行评估,得到每个网络结构的适应度。

3) 精英保留策略:在选择父代进行繁殖时,保留种群中表现最好的一部分结构(即精英),确保优秀基因的传递。

4) 遗传操作:采用遗传算子(交叉和变异)对种群进行进一步优化。交叉操作可以融合父代结构的优点,变异操作则引入新的可能性。

5) 生成新种群:通过遗传操作得到新的网络结构个体,形成新一代种群。

6) 重复优化:反复进行评估、选择、交叉和变异操作,直到达到预设的迭代次数或收敛条件。

通过这样的自动搜索过程,避免了人工调整过程中主观性干扰和观察次数不足所带来的偶然性,具体的搜索结果会是一个经过优化的网络结构,适应于特定的应用场景,能够取得更好的性能表现。

3 构建网络模型

3.1 网络外层结构搜索

虽然理论中 MBCConv 是一种轻量化的卷积操作,但实际应用时 MBCConv 中的 DW 通常不能充分利用现代加速器(GPU、TPU 等),导致其在网络的浅层运行缓慢,不过在放置于网络后端十分有效^[23]。

于是网络待搜索的卷积结构如表 4 所示。网络的前 3 层使用了常规卷积,提取特征的同时将提升信息的维度,保证了后续 MBCConv 性能的充分发挥。常规卷积层后使用两个卷积块,每个卷积块中包含 2 个 MBCConv。在每个卷积层后放置一个尺寸为 2 的最大池化层,常规卷

积和 DW 的卷积核尺寸暂设为 7×1 , MBCConv 中的扩展比例为 3。

在 CNN 中,网络深度的增加可以增强模型的表达能力,从而提高网络的性能,但网络训练和推理过程所需的时间和计算资源也会增加,不利于检测模型在嵌入式设备中的部署,还可能会导致梯度消失、梯度消失爆炸和过拟合等问题。搜索过程中,保留了每个卷积块中的第 1 个卷积层 MBCConv-1,通过对第 2 个卷积层 MBCConv-2 的取舍得到不同结构的网络。使用遗传算法共进行 200 次搜索,通过精英保留策略,能够将每次搜索完成后性能较为理想的网络结构进行保留,逐步求得性能最为理想的网络外层结构。

表 4 待搜索的卷积结构

Table 4 Convolution structure to be searched

layers	Structure of layers	Filter Size
Layer1	Conv1	$7 \times 1 \times 1 \times 32$
Layer2	Conv2	$7 \times 1 \times 32 \times 48$
Layer2	Conv3	$7 \times 1 \times 48 \times 64$
Block1		$1 \times 1 \times 64 \times 192$ (PW)
	MBCConv1-1	$7 \times 1 \times 192$ (DW)
		$1 \times 1 \times 192 \times 96$ (PW)
		$1 \times 1 \times 96 \times 288$ (PW)
Block2	MBCConv1-2	$7 \times 1 \times 288$ (DW)
		$1 \times 1 \times 288 \times 96$ (PW)
		$1 \times 1 \times 96 \times 288$ (PW)
	MBCConv2-1	$7 \times 1 \times 288$ (DW)
Block2		$1 \times 1 \times 288 \times 128$ (PW)
		$1 \times 1 \times 128 \times 384$ (PW)
	MBCConv2-2	$7 \times 1 \times 384$ (DW)
		$1 \times 1 \times 384 \times 128$ (PW)

此外,由于增减卷积层对网络规模的影响较大,在进行网络外层结构搜索时,在搜索算法中设置了限制条件来平衡网络规模和准确率,限制条件如下:

1) 当前网络的检测准确率高于记录中的最优网络,且当前网络与记录中最优网络的参数量之差低于 50 000。

2) 当前网络与记录中最优网络准确率之差大于 0.5%。

当两个限制条件至少满足其一时,当前网络便更新为最优网络。

开始搜索前,需选取合适的数据参与网络的训练和测试。样本数据的长度与检测的实时性和准确性有关。较短的样本可以提高检测频率,但会导致样本中特征信息不足进而降低模型的检测准确率;过长的样本虽然能保证的信息特征的完整性,但会影响检测效率。因此,在实际应用中需要根据具体情况选取合适的样本长度,以达到最佳的检测效果。使用待搜索的网络对不同长度的

样本数据进行训练和测试,结果如表 5 所示,可见最适合的样本长度为 500 个时间序列点。

表 5 不同长度样本的效果对比

Table 5 Effect comparison for samples of different lengths

样本长度	准确率/%
1 000	93.24
750	93.20
500	93.16
250	89.79

网络训练时,使用 Adam 优化器和交叉熵损失函数 (CrossEntropy Loss)。将数据集以 75:15:10 的比例划分为训练集、验证集和测试集。学习率为 0.01, batch_size 为 100,每次循环中训练 100 轮。经过搜索,得到 Block1 和 Block2 中 MBCConv 的数量均为 1。

3.2 卷积核尺寸搜索

卷积核主要在网络中承担着特征提取的作用。不同尺寸的卷积核的感受野大小不同,尺寸较小的卷积核可以捕获更细微的特征,例如边缘、纹理等。尺寸较大的卷积核具有较大的感受野,可以感知更广阔的上下文信息。而且卷积层的输入信息经卷积操作输出后信息的特征分布会改变,不同层次的特征需要不同尺寸的卷积核来进行有效的提取。如果每个卷积层都使用相同尺寸的卷积核,网络可能无法充分捕捉到不同尺度的特征,从而影响模型的表达能力。

论文定义了卷积核尺寸的搜索范围为[3 5 7 9 11 13 15],搜索位置是网络前端的标准卷积层和后端 MBCConv 中的 DW。与网络外层结构搜索不同,在进行卷积核尺寸搜索时,从浅层开始进行逐层搜索,如此降低了搜索的复杂度,使遗传算法的精英保留策略和进化过程能够得到充分应用,使搜索过程更加高效。如果进行全局搜索,需要从 16 807(7⁵) 个结果中进行挑选,而逐层搜索每层只需要对 7 个搜索项中进行筛选。通过搜索,从浅到深卷积层适用的卷积层尺寸如表 6 所示。

表 6 各卷积层所适用的卷积核尺寸

Table 6 Suitable convolution kernel size for each convolutional layer

Structure of layers	Filter Size
Conv1	5×1
Conv2	7×1
Conv3	5×1
MBCConv1	15×1
MBCConv2	13×1

3.3 扩展比例搜索

扩张比例是 MBCConv 前端逐点卷积输出通道数与

输入通道数的比值,决定着逐点卷积输出通道的数量,进而影响网络的规模。为探究网络规模与检测准确率的平衡,定义扩张比例的搜索范围为[1 2 3 4 5],通过搜索,网络末端两个 MBCConv 中的最佳扩张比例分别为 3 和 2。

搜索完成后,AFDNet 完整的网络结构和参数设置如图 9 和表 7 所示。一维的电压数据进入网络的特征提取层进行数据特征提取,特征提取层由卷积层和池化层组成,通过搜索算法构建。特征提取层的输出结果进入分类层,其由全连接层构成,对结果进行分类处理。




图 9 AFDNet 网络结构

Fig. 9 The network structure of the AFDNet

表 7 AFDNet 的参数设置

Table 7 The parameter setting of the AFDNet

Structure of layers	Filter Size	Output shape	Params
Conv1	5×1×1×32	500×32	160
Max pooling1	2×1	250×32	
Conv2	7×1×32×48	250×48	10 752
Max pooling1	2×1	125×48	
Conv3	5×1×48×64	125×64	15 360
Max pooling1	2×1	62×64	
MBCConv1	1×1×64×192 (PW)		12 888
	15×1×192 (DW)	66×96	2 880
Max pooling1	1×1×192×96 (PW)		18 432
	2×1	33×96	
MBCConv2	1×1×96×192 (PW)		18 432
	13×1×192 (DW)	37×128	2 496
AdaptiveAvg pooling	1×1×192×128 (PW)		24 576
		1×128	
Flatten		128	
FC (128, 64)	128×64	64	8 256
FC (64, 2)	64×2	2	130

4 算法和网络性能验证

4.1 搜索结果的合理性验证

网络的外层结构经遗传算法搜索后,深层的两个卷积块中均保留了一个 MBCConv,为了验证其合理性,在原搜索结果 AFDNet 的基础上添加额外的 MBCConv。表 8 中,AFDNet x-2 表示在第 x 个 MBCConv 后再添加一个 MBCConv。

表 8 AFDNet 外层结构的合理性验证

Table 8 Verification of the rationality of AFDNet's outer structure

网络	准确率/%	参数量
AFDNet	93.73	125 250
AFDNet 1-2	93.11	196 578
AFDNet 2-2	93.75	203 586
AFDNet 1-2,2-2	93.96	274 914

由表 8 可知,继续增添卷积层,网络参数量的提升较大,网络的检测准确率未见明显提高。虽然 AFDNet 2-2 和 AFDNet 1-2,2-2 较 AFDNet 准确率有微小提升,但网络的参数量却增加了 62% 和 119%。由此可见,经搜索算法搜索得出的网络外部结构较为合理。

由搜索结果可知,MBConv1 中卷积核的尺寸为 15×1 ,达到了搜索范围的最大值。在表 9 中,AFDNet 17 在 AFDNet 基础上将 MBConv1 中 DW 的卷积核的尺寸修改为 17×1 ,AFDNet 7 中常规卷积和 DW 的卷积核尺寸皆为 7×1 。

表 9 卷积核尺寸合理性验证

Table 9 Verification of the rationality of convolutional kernel size

网络	准确率/%	参数量
AFDNet	93.73	125 250
AFDNet 7	93.10	128 770
AFDNet 17	93.23	125 634

由表 9 可知,参数量方面,3 个网络的差异不大,而 AFDNet 具有最高的准确率。

论文通过提高或降低 MBConv 中的扩展比例来探究通过搜索算法所得出的扩展比例的合理性。经网络搜索,AFDNet 后端两个 MBConv 中的扩展比例分别为 3 和 2,AFDNet $x-y$ 将 MBConv x 中的扩展比例修改为 y 。由表 10 可知,与使用其他扩展比例组合的网络相比,算法的原始搜索结果 AFDNet 具有最高的准确率。

表 10 扩展比例合理性验证

Table 10 Verification of the rationality of extension scale

网络	准确率/%	参数量
AFDNet	93.73	125 250
AFDNet 1-4	92.51	140 290
AFDNet 1-2	92.93	111 234
AFDNet 2-3	93.53	154 146

4.2 多卷积搭配工作的合理性验证

表 11 中,将 AFDNet 后端两层轻量化卷积 MBConv 替换为常规卷积,生成常规卷积神经网络 Convnet。将 AFDNet 前端的第 2 和第 3 个的常规卷积层替换为 MBConv 层生成网络 MBConvnet。MBConvnet 的第 1 层依

旧使用常规卷积,是由于需要使用常规卷积先进行信息的升维,保证后续 MBConv 的正常工作。修改后卷积层的参数与修改前保持一致。

网络的单个样本检测时长通过将网络部署到 JN (Jetson Nano) 中所得,JN 是英伟达 (NVIDIA) 推出的一款嵌入式设备,可实现高性能的深度学习推断和计算机视觉应用。

表 11 网络性能验证

Table 11 Validation of the network performance

网络	准确率/%	参数量	检测时间/ms
AFDNet	93.73	125 250	10.82
Convnet	92.85	287 298	262.74
MBConvnet	93.16	129 042	15.64
Convnet-1	91.69	164 418	247.65
MBConvnet-1	92.62	118 242	15.46

由表 11 可知,即使使用了更多数量的 MBConv,由于扩展比、卷积核等影响,MBConvnet 相比 AFDNet 网络的参数量却提升了。常规卷积网络 Convnet 比 AFDNet 网络参数量增加了 129%。MBConvnet 和 Convnet 的检测时长都要高于 AFDNet。通过修改卷积核尺寸或扩展比例,降低了 MBConvnet 和 Convnet 的规模生成网络 MBConvnet-1 和 Convnet-1,其中 MBConvnet-1 的参数量要少于 AFDNet。但修改前后 MBConvnet-1 和 Convnet-1 的检测时间没有明显降低,可知网络的外部结构极大程度影响着其运行效率,证明了论文将常规卷积和轻量化卷积结合使用的合理性。并且由于 MBConvnet 和 Convnet 的网络参数是通过人工设置,其检测的准确率要低于 AFDNet。

4.3 不同工况下的电压状况和算法性能

电动汽车在运行时,驾驶人员会根据具体情况对负载的工作功率进行调整。向系统投入 3 根 PTC 加热器,采集到的数据直接使用模型进行检测,结果如图 10 所示。

理想情况下,系统正常运行时,模型对电压进行检测后输出的结果为 0,产生故障后,模型的输出结果为 1。由于电压信号在故障前后的变化微弱,整体上模型能对其进行有效的检测,但故障前后各发生了一次误判。如果系统正常运行时发生这种单次误判的现象,系统会被意外断电,进而可能造成严重的后果。此单次误判的情况可以通过循环检测进行避免,循环检测的操作流程如图 11 所示。图中 k 和 a 分别表示每次循环中检测次数和模型检测到电弧故障的次数。每次循环共进行 3 次判断,如果有 2 次及以上模型判断为故障状态,则认为系统中产生电弧故障。

电机负载的投切,对应实际中电动汽车的启停,电压端电压在电机投入或在系统中切除时会会有一个短暂而剧

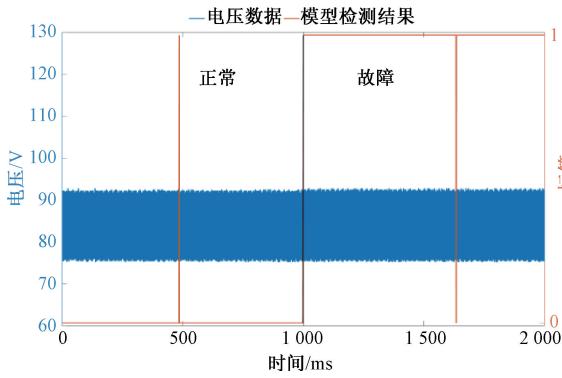


图 10 3 根 PTC 加热器运行下的模型检测结果

Fig. 10 Model test results under the operation of 3 PTC heaters

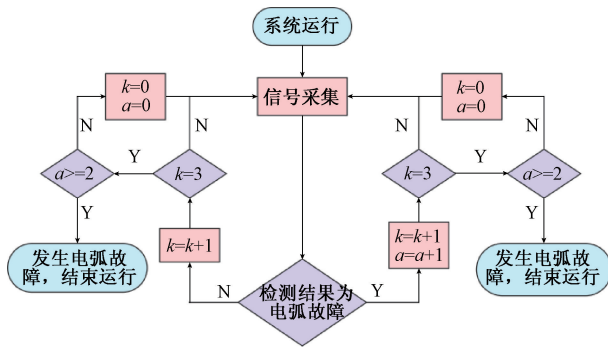


图 11 循环检测流程

Fig. 11 Flow chart of the cycle detection

烈的变化。图 12 中,电机投入工作时,电压幅值迅速上升又下降,后逐渐快速地恢复到正常值。电机从系统切除时,电压波形会有一个短时间的紊乱。电压的剧烈变化会使模型产生误判,但由于持续时间较短,此影响可以通过循环检测进行避免。相较于电机,空调和 PTC 加热器进行投切时,电压端电压没有明显变化,不会对检测造成较大影响。




图 12 电机投切时的电压变化情况

Fig. 12 Voltage change during the motor switching

实验中发现,电池包在不同电量下,系统工作时电压端电压的幅值大小不同。通过实验采集了不同电量下的实验数据,构建了数据集,使用模型进行检测,结果如表

12 所示。电池包的电量和电池包的输出电压的平均值成正比,电量的变化不会对模型的检测构成影响。

表 12 不同电池包电量下的电压幅值和模型性能

Table 12 Voltage amplitude and model performance under different battery pack levels

电池包电量/%	电压平均值/V	准确率/%
100	82.81	93.20
80	78.53	93.61
60	75.41	93.15
40	72.42	93.98

4.4 不同方法对比

将 AFDNet 与其他检测方法进行对比。对比结果如表 13 所示。

表 13 不同检测方法对比

Table 13 Comparison of the different detection methods

方法	准确率/%	参数量	检测时间/ms
时频域特征提取+			
随机森林 ^[1]	57.21		9.13
改进 Mobilenet ^[24]	84.64	59 842	9.78
AFDNet	93.73	125 250	10.82

文献[1]使用了传统的特征提取方法,手动的提取了信号的多种时域和频域特征,包括平均值、标准差、傅里叶变换的最大值等,然后结合随机森林分类器进行电动汽车串联电弧故障诊断。此方法操作简单,检测时长较短,但检测的准确率不足。PTC 加热器支路故障后,其故障特征微弱,简单的时频特征提取方法不能将电压信号故障前后的差异表现出来。另外,如果有针对性地设计更为复杂的特征提取方法,这对研究人员的经验要求较高且会花费大量时间。所以通过传统的人工手动的提取信号特征的方法进行电动汽车电弧故障检测具有一定的困难。

相较之下,通过搭建神经网络自动的进行微弱特征的提取具有较强的优势。文献[24]是本团队针对电动汽车串联型电弧故障检测问题的前期研究成果,对轻量型的卷积神经网络 Mobilenet 进行了一维修改和更轻量的调整,大幅度提升了模型的检测效率。但改进 Mobilenet 的参数数量虽为 AFDNet 的 47.78%,但在嵌入式设备中运行时的检测时长也仅低于 AFDNet 的 9.61%。并且改进 Mobilenet 的主要工作在于缩小模型规模、提高检测效率,在检测准确率方面的关注度不足,其检测的准确率要低于 AFDNet。AFDNet 在构建时考虑的实际应用问题,并使用了搜索算法极大程度的提升了模型对于电动汽车数据的适应程度,该模型在综合检测性能方面具有较大优势。

5 结 论

论文搭建了电动汽车故障电弧实验平台,以电源端电压为检测对象,建立了的电动汽车串联型电弧故障检测模型 AFDNet。

1) 论文考虑了轻量化卷积操作 MBConv 在实际应用时的局限性,将常规卷积与 MBConv 进行结合,并根据本文的故障检测特点,对 MBConv 的内部结构进行了调整。通过验证,将常规卷积与 MBConv 结合使用具有更高的运行效率。

2) 使用基于精英保留策略的遗传算法对 AFDNet 的外部结构和内部参数进行寻优,逐步建立针对检测任务的高适应度的检测模型。

3) 通过与不同网络和检测方法的对比,证明 AFDNet 在电动汽车串联型电弧故障检测中有较好的准确性及实时性。为电动汽车串联型电弧故障检测提供了一种可行性方案。

参考文献

- [1] 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). IEEE, 2017, 1-4.
- [2] LIU S H, ZHANG J, LI X K, et al. Research on fault identification method of series arc in electric vehicle charging system based on machine learning [C]. 2023 8th Asia Conference on Power and Electrical Engineering (ACPEE), 2023: 1628-1632.
- [3] 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.
- [4] ABDULLAH Y, SHAFFER J, HU B. Hurst-exponent-based detection of high-impedance DC arc events for 48 V systems in vehicles [J]. IEEE Transactions on Power Electronics, 2021, 36(4): 3803-3813.
- [5] 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 D, 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.
- [6] 李智华,钟杰人,吴春华,等.光伏电站中故障电弧信号的传输行为研究[J].太阳能学报,2021,42(7):152-160.

- LI ZH H, ZHONG J R, WU CH H, et al. Research on transmission behavior of fault arc signal in photovoltaic power station [J]. Acta Energiæ Solaris Sinica, 2021, 42(7): 152-160.
- [7] MIAO W CH, XU Q, LAN K. H, et al. DC arc-fault detection based on empirical mode decomposition of arc signatures and support vector machine [J]. IEEE Sensors Journal, 2021, 21(5): 7024-7033.
- [8] GAO W, WAI R J. Series arc fault detection of grid-connected PV system via SVD denoising and IEWT-TWSVM [J]. IEEE Journal of Photovoltaics, 2021, 11(6): 1493-1510.
- [9] 杨洋,黄罗杰,李平,等.基于多维度特征提取的电弧故障检测方法[J].电子测量与仪器学报,2021,35(10):107-115.
- YANG Y, HUANG L J, LI P, et al. Arc fault detection based on multi-dimension feature extraction [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(10): 107-115.
- [10] 孟羽,陈思磊,吴子豪,等.基于随机共振方法增强光伏直流故障电弧检测特征的研究[J].中国电机工程学报,2022,42(6):2396-2407.
- MENG Y, CHEN S L, WU Z H, et al. Research on feature enhancement of DC arc fault detection in photovoltaic systems based on stochastic resonance [J]. Proceedings of the CSEE, 2022, 42(6): 2396-2407.
- [11] CAI X R, WAI R J. Intelligent DC arc-fault detection of solar PV power generation system via optimized VMD-based signal processing and PSO-SVM classifier [J]. IEEE Journal of Photovoltaics, 2022, 12(4): 1058-1077.
- [12] 邱婷婷,曹文平,刘孝宇,等.多时间尺度小波变换和LSTM自编码器电弧故障检测方法[J/OL].电机与控制学报:1-10.
- QIU T T, CAO W P, LIU X Y, et al. Multi time scale wavelet transform and LSTM autoencoder arc fault detection method [J/OL]. Electric Machines and Control:1-10.
- [13] 陈思磊,王源丰,孟羽,等.包络微分算子增强直流故障电弧特征及其半监督式辨识方法[J].高压电器,2023,59(7):145-155.
- CHEN S L, WANG Y F, MENG Y, et al. Envelope-differential-operator-based DC arc fault feature enhancement and its semi-supervised identification method [J]. High Voltage Apparatus, 2023, 59(7): 145-155.
- [14] 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.
- [15] WANG Y, HOU L M, PAUL K CH, 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.
- [16] PAUL K C, ZHAO T F, CHEN C, 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.
- [17] LU SH B, RUI M, THARMAKULASINGAM S, et al. Lightweight transfer nets and adversarial data augmentation for photovoltaic series arc fault detection with limited fault data [J]. International Journal of Electrical Power & Energy Systems, 2021, 130.
- [18] SUNG Y, YOON G, BAE J H. TL-LEDarcNet: Transfer learning method for low-energy series DC arc-fault detection in photovoltaic systems [J] IEEE Access, 2022, 10: 100725-100735.
- [19] AMIRI A, SAMET H, GHANBARI T. Recurrence plots based method for detecting series arc faults in photovoltaic systems [J]. IEEE Transactions on Industrial Electronics, 2022, 69(6): 6308-6315.
- [20] 贾科, 张昉, 温志文, 等. 基于电流-温度动态映射的新能源直流汇集送出系统串联电弧故障检测[J]. 电网技术, 2022, 46(8): 3123-3132.
- JIA K, ZHANG Y, WEN ZH W, et al. Series-arc fault detection of new energy DC collection and delivery system based on current-temperature dynamic mapping [J]. Power System Technology, 2022, 46(8): 3123-3132.
- [21] XING L, WEN Y H, XIAO S, et al. A deep learning approach for series DC arc fault diagnosing and real-time circuit behavior predicting [J]. IEEE Transactions on Electromagnetic Compatibility, 2022, 64(2): 569-579.
- [22] 王尧, 马桐桐, 赵宇初, 等. 基于电磁辐射时延估计的串联光伏直流电弧故障定位方法[J]. 电工技术学报, 2023, 38(8): 2233-2243.
- WANG Y, MA T T, ZHAO Y CH, et al. Series DC arc-fault location method based on electromagnetic radiation delay estimation for photovoltaic systems [J]. Transactions of China Electrotechnical Society, 2022, 64(2): 569-579.
- [23] TAN M X, LE Q V. EfficientNetV2: Smaller models and faster training [J]. arXiv preprint arXiv: 2104.00298, 2021.
- [24] 刘艳丽, 王浩, 张帆. 电动汽车串联型电弧故障检测方法[J]. 电子测量与仪器学报, 2023, 37(6): 222-231.
- LIU Y L, WANG H, ZHANG F. Series arc fault detection method in electric vehicle [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(6): 222-231.

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 from Liaoning Technical University in 2004, M. Sc. degree from Liaoning Technical University in 2007 and Ph. D. degree from Liaoning Technical University in 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 in Liaoning Technical University. His main research interests include electrical contact and arc theory.