DOI: 10. 13382/j. jemi. B2306263

电动汽车串联型电弧故障检测方法*

刘艳丽王浩张帆

(辽宁工程技术大学电气与控制工程学院 葫芦岛 125105)

摘 要:电弧故障是引发电气火灾的主要原因之一。在电动汽车电气系统中,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、爆炸等严重事故。为快速、准确地检测电动汽车串联型电弧故障,搭建了电动汽车故障电弧实验平 台,采集不同工况下干路电流时间序列并建立了样本库。通过轻量化卷积神经网络,建立了基于改进 Mobilenet 网络的串联故 障电弧检测模型。通过对比分析学习率、网络层数、样本长度,对模型进行了优化。该优化模型通过干路电流可实现电动汽车 串联型故障电弧的检测和故障选线,检测准确率达到 96.39%,论文为电动汽车电气系统电弧故障检测提供了一种可行性方案。 关键词:电动汽车;轻量化卷积神经网络;改进 Mobilenet;电弧故障检测;电弧故障选线 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

Series arc fault detection method in electric vehicle

Liu Yanli Wang Hao Zhang Fan

(Faculty of Electrical and Control Engineering, Liaoning Technical University, Huludao 125105, China)

Abstract: Are fault is one of the main causes of electrical fire. In the electric system of electric vehicle, the DC series are fault usually occurs at the loose contact point or the line connection damage, which will cause serious accidents such as fire and explosion. In order to quickly and accurately detect the series electric are fault of electric vehicles, an experimental platform for electric car fault are has been constructed to collect time series data on trunk current under various operating situations and create a sample library. Through the lightweight convolutional neural network, a series fault are detection model based on the improved Mobilenet network is established. By comparing and analyzing the learning rate, network layer number and sample length, the model is optimized. The optimization model can realize the detection of series fault are, the selection of fault lines of electric vehicles through the trunk current, and the detection accuracy reaches 96. 39%. This paper provides a feasible scheme for the arc fault detection of arc fault; selectrical system. **Keywords**: electric vehicle; lightweight convolutional neural networks; improved Mobilenet; detection of arc fault; selection of the arc fault line

0 引 言

电动汽车电路结构复杂,外部碰撞、道路颠簸等都可 能导致电气接触点接触不良,进而引发串联型电弧故障。 据国家应急管理部数据显示,2022 年第1季度共发生新 能源汽车火灾事故 640 起,较 2021 年同期增长 32%,这 表明平均每天有超过7辆新能源汽车发生火灾事故。多 起事故分析报告指出,在起火后的电动汽车残骸内有电 弧燃烧的痕迹。电弧具有高温的特性,持续的燃弧可能 会引燃线路,进而导致火灾的发生^[1]。

电动汽车电路中电气接触点较多,电弧故障发生位 置不固定,很难通过弧声、弧光等物理特征对故障电弧进 行检测^[2]。发生故障电弧时,电信号特征早于弧声弧光 等物理特征,基于电信号特征的电弧故障检测方法更有 利于提高检测的实时性。Xia等^[34]使用加窗傅里叶变换 (windowed Fourier transform,WFT)、小波熵算法提取了电 弧故障特征,再与机器学习结合建立了电动汽车电弧故

收稿日期: 2023-02-15 Received Date: 2023-02-15

*基金项目:国家自然科学基金(52104160)、2022年度葫芦岛市科技指导计划重点研发项目(2022JH2/07b)资助

障检测模型,实现了直流电弧故障的有效检测。Shaffer 等^[5]使用了带通滤波器和包络滤波器对含噪的故障电弧 电流信号进行滤波,以滤波后信号的 Hurst 指数为特征 值,实现了电动汽车故障电弧进行检测。Emrani 等^[6]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电弧故障的检测。郭琳等^[7]建立 Cassic 时频域电弧仿真模型,以燃弧前后能量比值为特 征参量,采用阈值法有效识别电动汽车直流电弧故障。 文献[3-7]的研究成果实现了对电动汽车直流主回路故 障电弧的检测,这类基于特征提取的方法具有一定的主 观性,特征提取的角度和方法将直接影响故障电弧识别 准确率。

电动汽车与光伏系统均为直流电源,且存在逆变电 路,两者电路结构有许多相似之处。唐圣学等^[8]分析了 光伏系统微弱直流串联型故障电弧产生机理,以电弧电 流脉冲因子及小波能量熵为特征量,采用极限学习机对 微弱故障电弧进行辨识。Lu 等^[9]提出了基于域自适应 和深度卷积生成对抗网络的光伏系统故障电弧检测方 法,检测方法具有良好的鲁棒性。Park 等^[10]提出了一种 采用差分功率处理结构的直流串联电弧故障检测算法, 降低了光伏系统故障电弧检测的成本。Yang 等^[11]提出 一种基于 BP 神经网络的多判据直流电弧故障检测方 法,选取时域的峰峰值、标准差以及频域的谐波含量为特 征量,通过 BP 神经网络实现了直流故障电弧的识别。 Liu 等^[12]以光伏侧电压的时域电导和回路电流时频域熵 为特征量,建立了直流电弧检测模型,两种不同信号的融 合增强了模型的抗干扰能力。Ahmadi 等^[13]将光伏阵列 输出端和逆变器入口的两个电压信号,以及太阳能阵列 的输出电流作为算法输入,提出了基于主成分分析的盲 源分离算法,来识别串联型电弧故障。此外,该团队还以 电压的低频分量与电弧特征的功率比为特征值,提出能 够消除逆变器开关对直流端电压的影响的电弧故障检测 方法^[14]。Lu 等^[15]通过检测线路电流的下降幅度、平均 值变化率、交流分量标准差以及电源电压交流分量标准 差来检测光伏系统直流串联电弧故障。Cai 等^[16]提出了 一种基于优化变分模态分解和支持向量机的智能检测算 法。该算法可以识别串联和并联型电弧故障,在动态遮 阳、逆变器启动、风吹下均能保持良好的诊断效果。 Amiri 等^[17]提出基于递归图的光伏系统串联电弧故障检 测方法。该算法以电源端电压为分析对象,具有高精度、 高速、低计算量的优点。孟羽等^[18]在故障电弧检测环节 引入随机共振方法,增强了信号中的电弧特征信息。由 于光伏系统与电动汽车回路负载不同,电源电压性质也 不同,文献[8-18]对本文具有一定参考价值,但不能直接 应用于电动汽车故障电弧特征提取与检测工作。

深度学习具有较强的自适应、自学习能力,可全方位

深度挖掘隐藏在样本中的信号特征,相关学者也将其引 入到故障电弧检测领域中。周新城等^[19]以线路电流信 号为样本,基于一维卷积神经网络(1D-CNN)建立了家 用负载串联故障电弧检测模型。余琼芳等^[20-22]先后使用 AlexNet 网络、LSTM 网络、CNN-LSTM 网络实现了家用单 负载故障电弧检测、多负载并联情况下电弧故障二分类、 电弧故障支路选择。Li等^[23]在双电机负载并联情况下, 以某一相干路电流为训练样本,提出了一种基于递归神 经网络的串联型电弧故障诊断及故障线路选择方法。 Wang 等^[24]提出了一种基于卷积神经网络的电弧故障检 测模型 ArcNet,并将该模型在树莓派 3B 中实现。文献 [19-24]直接以干路电流为样本,通过神经网络去挖掘电 流信号中存在的故障电弧信息,此类检测方法对论文工 作地实施具有较好的参考价值。

本文的创新点及学术贡献如下:

1)设计了电动汽车故障电弧实验平台,分别进行了 无振动和振动条件下串联型故障电弧实验,分析了道路 颠簸等引起的振动对电弧故障实验结果的影响。

2)构建了基于改进的轻量级网络 Mobilenet 的串联 电弧故障检测模型。该模型不仅能识别电动汽车电弧故 障,还能判断电弧所在回路。

3)建立的电弧故障检测模型直接以一维的干路电流 为检测对象,提高了检测模型的实时性,同时避免了人为 提取电弧特征对检测模型准确性的影响。

1 串联电弧故障实验

1.1 实验系统设计

论文搭建了电动汽车故障电弧实验平台。其中电源 为直流 72 V 锂离子电池组,负载主要包括无刷直流电机 JY72V200W 及其控制器 JY36、空调和 PTC 加热器,实验 平台如图 1 所示。

为模拟不同位置发生串联型故障电弧情况,将电弧 发生器分别安装在图 1 中干路位置①和负载支路位置 ②、③、④处。电压互感器 LHB500V5VT1、电流互感器 LHB100A5VY2 分别采集电弧电压和干路电流信号时间 序列,采样频率为 50 KHz,实验结果通过数据采集卡传 送至计算机。磁粉制动器 PB-40 通过传送皮带连接无刷 电机,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。直流电机 5GU-5K、直流电机调速 器 DC6-90V15AMAX、直流风机三者组合来模拟车载空 调。PTC 加热器模拟电动汽车加热负载,其发热源是一 种 PTC 热敏电阻元件,实际工作时的功率与热敏电阻的 居里温度及外加电压有关。控制柜用于控制各负载的启 停及投切。

依据 UL1699,故障电弧发生器设计如图 2 所示。其中



图 1 电动汽车故障电弧实验平台 Fig. 1 Experimental platform for the fault arc of electric vehicles

开关电源为音圈电机工作系统提供 24 V 的直流电源。静止电极为直径 5 mm 柱形碳棒,移动电极为直径 5 mm 锥形 铜棒。系统正常工作时,两个电极紧密接触。实验时,通过音圈电机 OWS80 拖动铜棒移动与碳棒分离从而产生电弧,模拟电动汽车在平坦道路行驶时接触点接触不良导致电弧产生的情况。将音圈电机振幅设置为 450 μm、振动频率设置为 15 Hz,音圈电机拖动铜棒往复运动,不断重复碳棒与铜棒分离又接触的过程,模拟电动汽车在颠簸道路行驶时接触点接触不良导致的电弧故障。



图 2 故障电弧发生器 Fig. 2 Failure arc generator

1.2 实验方案

实验通过调整负载的类型、各负载的工作状态、电弧 发生位置等,获取不同工况下干路电流和故障弧电压。 实验方案如表1所示。

实验中,当电机和其他负载并联运行时,首先电机负 载单独运行,当电机回路电流稳定在10A或15A后,再 投切其他负载。PTC加热器共4条,每条额定功率为

表 1 实验方案 Table 1 Experimental protocol

组别	1~6	7~42	43~78
负载类型	电机	电机+空调	电机+PTC 加热器
电机回路电流	10 A/15 A	10 A/15 A	10 A/15 A
空调	无	刻度 10/刻度 20	无
PTC 加热器	无	无	160 W/320 W
电弧发生器			
位置	Û	(1,2,3)	(1,2,4)
	正常/	正常/	正常/
故障类型	无振动拉弧/	无振动拉弧/	无振动拉弧/
	振动拉弧	振动拉弧	振动拉弧

80 W,实验时 PTC 加热器功率分别设置为 160、320 W。 用来模拟空调的直流风机功率为 70~80 W,直流电机额 定功率 120 W。实验时,分别调节电机控制器的调速旋 钮至 10 和 20 刻度处,使直流电机以不同的转速运行。

1.3 实验数据分析

图 3 为电机单独运行,回路电流为 15 A 时的电流波 形。无振动条件下发生电弧故障时,电流周期性尖峰主 要是由无刷直流电机的启动特性、转矩平衡和电弧特性 共同决定。振动条件下发生电弧故障时,无刷直流电机 的负载特性、电弧特性、移动电极周期性往返运动同时影 响了回路电流。图 4 为电机和空调并联运行,直流电机 调速旋钮调至刻度为 20 时,空调支路发生电弧故障时的 干路电流波形。在无振动条件下,电流波形出现无规律 性尖峰,电路中的谐波分量明显增多。振动条件下,由于 音圈电机拖动移动电极周期性往返运动,电流波形出现 周期性尖峰。图 5 为电机与 PTC 加热器并联,PTC 加热 器处于 320 W 工作模式下,PTC 支路发生故障电弧时的 干路电流波形,受 PTC 本身负载性质的影响,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无 明显变化。

总体来看,忽略干路电流波形中的尖峰特征,在无振 动条件下拉弧时,电极间的接触电阻增加,导致干路电流 幅值整体下降。振动条件下,由于不断重复动静电极分 断又接触的过程,接触电阻在一定范围内周期性变化,导 致干路电流也出现了一定的周期性特征。





为分析干路电流反映的故障电弧信号特征,对不同 工况下干路电流信号进行时域和频域分析。为衡量燃弧 前后干路电流信号的中心位置、波动程度以及信号分布 的偏态和峰度,计算了干路电流的平均值、方差和峭度。 从图 3~5 对应实验组别的实验数据中各取 100 个干路 电流样本,样本长度为1 500 个时间序列点。计算 100 个 样本平均值、方差、峭度的平均值,求出燃弧后与燃弧前 3 个时域特征参数的比值,具体如表 2 所示。不同负载 类型、不同故障条件下,燃弧前后干路电流的平均值无明 显变化。相较于其他负载类型,电机和 PTC 加热器并联 运行时燃弧前后其时域特征比值接近 1,故障特征较为 微弱。



	平均值		方差		峭度	
贝轼矢至	无振动	振动	无振动	振动	无振动	振动
电机	0.91	0.98	1304	253	2.21	1.65
电机+空调	0.86	0.95	4.38	4.39	2.43	2.39
电机+PTC 加热器	0. 92	0.99	1.68	1.60	0.97	0.93

通过快速傅里叶变换来观察燃弧前后干路电流在频 域中的差别,结果如图 6、7 所示。

图 6 中,电机单独运行时,在 0~2 000 Hz 范围内,燃 弧后频谱幅值明显增加。以无振动故障为例,图 7 中,空 调或 PTC 加热器支路发生无振动电弧故障后,燃弧前后 的频谱幅值无明显差别。对存在较多特征信息的 0~ 1 000 Hz 区域进行放大处理,发现空调支路故障时,可以



operating in parallel with the air conditioning or PTC heater 捕捉到干路电流频谱在燃弧前后的微弱区别。但 PTC

捕捉到十路电流频谱在燃弧间后的微弱区别。但 PTC 加热器支路故障时,频域上依旧很难发现故障电弧的特征信息。

2 建立检测模型

由 1.3 节实验数据分析发现,很难通过传统时频域 特征分析方法,建立有效的电动汽车串联型电弧故障检 测模型。为检测电弧故障及故障回路,本文建立了基于 改进 Mobilenet 网络的电动汽车电弧故障检测模型。

2.1 深度可分离卷积原理

Mobilenet 是基于深度可分离卷积(depthwise separable convolution, DS)的轻量化卷积神经网络。深度 可分离卷积由深度卷积(depthwise convolution, DW)和逐 点卷积(pointwise convolution, PW)两部分构成^[25],卷积 结构如图 8 所示。DW 进行的是逐通道卷积操作,无法 对输入信息的通道数进行扩展,输出信息的通道数和输 入信息一致,且每个通道内的卷积操作相互独立进行。 PW 操作与标准卷积相同,不过其卷积核大小为1×1,它 将 DW 生成的各通道的特征进行组合,生成新的特征,卷 积核每次只对一个像素区域进行卷积操作,以较少的计 算量来改变数据的维数。

在计算量方面,假设输入信息大小为 $D_F \times D_F \times M$,当



采用标准卷积核进行卷积操作时,卷积核大小 $D_{k} \times D_{k} \times M \times N$,卷积步长为1且进行 padding,则输出信息大小为 $D_{F} \times D_{F} \times N$,计算量为 $D_{F} \times D_{F} \times M \times N \times D_{F} \times D_{F}$ 。使用 DS 进行卷积操作,先进行 DW,使用 M 个大小为 $D_{K} \times D_{K}$ 的卷 积核分别对输入信息的各个通道进行卷积,得到输出信息大小为 $D_{K} \times D_{K} \times M$,计算量为 $D_{K} \times D_{K} \times M \times D_{F} \times D_{F}$ 。DW 后进行 PW,卷积核大小为 1×1×N,输入信息大小为 $D_{F} \times D_{F} \times N$,计算量为 $M \times N \times D_{F} \times D_{F}$,故 DS 操作总计算量为 $D_{K} \times D_{K} \times M \times D_{F} \times D_{F} \times D_{F}$ 。两种卷积操作的计算量之比如下:

$$\frac{D_{K} \times D_{K} \times M \times D_{F} \times D_{F} + M \times N \times D_{F} \times D_{F}}{D_{K} \times D_{K} \times M \times N \times D_{F} \times D_{F}} = \frac{1}{N} + \frac{1}{D_{K}^{2}}$$
(1)

相较于标准卷积, DS 在保证检测准确率的基础上, 计算量和参数量大大减少,运算速度得到大幅度提升,达 到网络轻量化的效果。

2.2 改进 Mobilenet 网络结构

本文从网络的基本结构、卷积核大小、卷积步长等各 方面对 Mobilenet 网络进行了改进,使其更适用于本文 数据。

电流数据为 1D 信号时间序列,并不能直接输入到 Mobilenet 网络中。因此,对网络部分结构进行 1D 改进。 图 9 中,改进前的卷积核进行卷积操作时,会同时进行横 向和纵向的卷积,而改进后的卷积核进行的是单向卷积, 适用于 1D 数据。





Fig. 9 Modification of the convolution kernel size

标准 Mobilenet 网络结构见文献[26]。改进后的 Mobilenet 网络结构如图 10 所示。该网络有 1 个标准卷 积层、6 个 DS 层、5 个最大池化层、1 个平均池化层和 2 个全连接层。网络首端的标准卷积层卷积核大小为 15×1,卷积步长为 5,在获得较大感受野的同时降低输入 信息的分辨率。随后后端的 6 个深度可分离卷积层对信 息特征进行更为深度的提取。最后信息进入全连接层并 通过 Softmax 函数完成信号类别的判断。网络的参数说 明如表 3 所示。



Fig. 10 Network structure diagram of the improved Mobilenet

表 3 网络参数说明

Table 3 Description of network parameters

Structure of layers	Filter Size/Pool Size	Number of Params
Conv1D+stride of 5	15×1×32	480
DC 1	3×1×32(DW)	96
DSI	1×1×32×64(PW)	2 048
Max pooling1	2×1	
D62	3×1×64(DW)	192
052	1×1×64×96(PW)	6 144
Max pooling2	2×1	
DC2	3×1×96(DW)	288
055	1×1×96×128(PW)	12 288
Max pooling3	2×1	
DC 4	3×1×128(DW)	384
D54	1×1×128×128(PW)	16 384
Max pooling4	2×1	
D6 5	3×1×128(DW)	384
055	1×1×128×96(PW)	12 288
Max pooling5	2×1	
DCC	3×1×96(DW)	288
050	1×1×96×64(PW)	6 144
Avg pooling	9×1	
FC(64,5)	64×5	325

将文献[26]中的 Mobilenet 网络改变为 1D 网络 (Mobilenet1D)后,使用本文样本库进行训练, Mobilenet1D 和改进 Mobilenet 的对比分析如表 4 所示。 结果表明,与 Mobilenet1D 相比,改进 Mobilenet 网络的检 测准确率小幅度提升,网络结构也更加简单,其参数量和 检测时间仅为 Mobilenet1D 的 1.89%和 7.82%。

表 4 Mobilenet 网络改进前后对比分析 Table 4 Comparative analysis of Mobilenet

network	before	and	after	improvement
	~~~~			

网络	Mobilenet1D	改进 Mobilenet
卷积层数量	14 个	7个
网络参数量	3.18M	60. 04k
检测正确率/%	96.15	96.39
检测时间/ms	4.99	0.39

## 3 模型测试与分析

模型运行环境如下:操作系统为 Windows11, CPU 为 Intel(R)Core(TM)i7-11800H,运行内存 16.0 GB,模型的 搭建和训练等工作在 PyCharm Community Edition 2022. 2.1 中完成。

## 3.1 数据预处理

本文使用了滑窗重叠采样的方式来采集所需的样 本,滑窗重叠采样方法的示意图如图 11 所示。



图 11 滑窗重叠采样示意图 Fig. 11 Schematic diagram of the sliding window overlapping sampling

电弧故障检测需要在极短的时间内完成信号采集、 处理、判断和控制等操作。在信号采集方面,相较于窗口 没有重叠的滑窗采样方式,采集同等长度的数据,使用滑 窗重叠采样需要的时间更短。例如,当重叠率为1/5,单 个检测样本的长度为1500个时间序列点时,使用滑窗 重叠采样只需采集1200个时间序列点,剩余的300个由 上一个检测样本提供。如此,在实时的电弧检测中,使用 滑窗重叠采样能够提高检测频率,这对故障检测的实时 性有所帮助。但值得注意的是,如果滑窗重叠采样的重 叠度过高,单个待检测数据需要的采集时间较短,有可能 网络还没有判断出当前数据类别,下一个需要检测的数 据已经采集完成,如此,便会造成数据堆积,影响检测的 实时性。

为了消除信息间单位和尺度差异的影响,提高模型的收敛速度和诊断准确率,对数据进行归一化预处理,将数据大小映射到0~1之间,其转换公式如下:

$$y_{i} = \frac{x_{i} - \min\{x_{j}\}}{\max\{x_{j}\} - \min\{x_{j}\}}$$
(2)

其中, $x_i$  为待归一化的样本数据, $\min\{x_j\}$ 和 max $\{x_j\}$ 分别是样本数据中的最小和最大值, $y_i$  为归一化后的 结果。

#### 3.2 模型的训练与测试

基于表1的实验方案,获得不同实验条件下干路电 流信号时间序列,通过滑窗重叠采样的方式获得样本并 建立样本库,每个样本由1500个连续的时间序列点组 成。将样本分为5类,将每类样本以75:15:10的比例 划分训练、验证和测试集。每类样本的数量和标签如表 5所示。

#### 表 5 样本的标签和数量

#### Table 5 Labels and numbers of the samples

系统运行状态	标签	样本数量
正常运行(电机,电机+PTC,电机+空调)	0	16 008
干路故障(电机+PTC,电机+空调)	1	10 692
电机回路故障(电机,电机+PTC,电机+空调)	2	16 050
PTC 加热器回路故障(电机+PTC)	3	5 340
空调回路故障(电机+空调)	4	5 364

模型训练使用收敛速度较快且稳定的 Adam 优化器,损失函数为交叉熵损失函数 CrossEntropy Loss,激活函数使用 ReLU,训练批次为 100。首先以 0.01、0.001、0.000 1 这 3 个学习率各进行 100 轮训练。如图 12 所示,当学习率设置值过大时,验证集准确率曲线波动较大,模型无法收敛。当学习率设置值过小时,模型收敛速度较慢且易陷入局部最优解。学习率为 0.001,模型的收敛速度和训练准确率都比较理想,模型训练至 80 轮左右时,验证准确率趋于稳定,但依旧存在小幅度波动。



因此,设置模型的初始学习率为0.001,且加入学习 率调整机制,当模型训练至80轮时,将学习率从0.001 调整至0.0001,使模型的检测准确率最大程度的接近或 达到最优值。模型的训练和验证准确率趋势如图13所 示,模型训练过程中没有出现过拟合。训练后期降低学





模型检测结果的混淆矩阵如图 14 所示。



图 14 混淆矩阵 Fig. 14 Confusion matrix

#### 3.3 网络模型优化分析

1) 网络结构分析

在深度学习中,网络的深度是网络性能的主要影响 因素之一,网络越深,表达能力越强。但过深的网络会增 加计算的复杂度,降低检测效率,可能还会产生深度网络 的退化问题,而过浅的网络又不能对信号深层次特征进 行充分提取。本文对不同网络结构下电弧故障检测准确 率进行比较分析,以期获得模型的最优网络结构。在本 文6层 DS 层的基础上分别削减和增加 DS 层,得到不同 的网络结构模型,削减的卷积层为网络的最后两个 DS 层,增加的卷积层结构与削减的卷积层对应,各网络的参 数数量和检测准确率如表6所示。

由表 6 可知, 在本文网络结构基础上增加 DS 层, 模型检测的准确率不会再有明显的增长, 并且检测时间增加。减少 DS 层, 虽然检测时间有所减少, 但准确率下降

明显。由此,确定本文网络模型中 DS 层为6层。

表 6 不同网络结构的模型性能对比分析 Table 6 Comparative analysis of the model performance of the different network structures

5714/z	DS 层	· · · · · · · · · · · · · · · · · · ·	参数	检测准
网络 数量	增加/ 削减的苍松层结构	数量	确率/%	
	4	3×1×128(DW),1×1×128×96(PW)	40 401	05 15
a 4	3×1×96(DW),1×1×96×64(PW)	40. 49K	95.15	
$\mathbf{b}$	5	3×1×96(DW), 1×1×96×64(PW)	53. 45k	95.91
с	6	本文 DS 层结构	60. 04k	96.39
$\mathbf{d}$	7	3×1×64(DW),1×1×64×96(PW)	64. 58k	96.15
е	ō	3×1×64(DW),1×1×64×96(PW)	60 16h	06 27
	0	3×1×96(DW),1×1×96×128(PW)	09. IOK	96.37

#### 2)样本长度分析

当样本长度较短时,虽然可以提高检测效率,但样本 长度过短会丢失信号特征,导致准确率降低。样本过长 虽能够保证准确率,但相应的会增加检测时间。本文分 别建立了样本长度为1000、1250、1500、1750、2000个 采样点的数据库,分析输入信息的长度对模型检测准确 率的影响,结果如表7所示。由此可知,样本长度超过 1500个采样点后准确率未明显提升,反而增加了检测时 长。样本长度低于1500个采样点,准确率下降幅度较 明显。因此将样本长度设置为1500个时间序列点。

表 7 样本长度对比分析 Table 7 Comparative analysis of the sample length

样本长度(采样点个数)	准确率/%	检测时间/ms
1 000	95.15	0.30
1 250	95.59	0.34
1 500	96.39	0.39
1 750	96.41	0.46
2 000	96.33	0.52

## 4 模型检测效果对比分析

为分析样本长度对模型性能的影响,对文献[21]、 [22]、[24]以及本文的检测模型在不同样本长度时的检 测准确率及检测时间进行对比分析。文献[21]、[22] 以10000个电流信号时间序列点作为网络输入,文献 [24]的输入信息长度为800个电流信号时间序列点。 本文通过表7的分析,选择1500个时间序列点作为模 型输入。文献[21]、[22]、[24]中的检测模型使用本 文数据分别以原文中样本长度和1500个时间序列点 对模型进行训练,4个模型的检测准确率及检测时间如 表8所示。 表 8 不同的样本长度下模型性能对比分析 Table 8 Comparative analysis of Model Performance under different sample lengths

检测模型	样本长度 (采样点个数)	检测准确率/%	检测时间/ms
LCTM [21]	10 000	83.15	0.46
LSIM	1 500	83.23	0.20
CNN L CTM [22]	10 000	81.96	77.89
CININ_LSTIM ¹	1 500	81.64	10.40
Arcnet ^[24]	800	93.25	0.89
	1 500	96.59	1.64
本文模型	1 500	96.39	0.39

文献[21]、[22]的检测模型在减少样本长度时缩短 了检测时间,但模型准确率无明显变化。当样本长度均 为1500时,文献[24]检测方法的检测准确率略高于本 文方法,但检测时间是本文方法的4.2倍。综合比较模 型检测准确率及样本检测时间,本文提出的改进 Mobilenet检测模型对本文实验结果检测效果最佳。

与文献[21]、[22]相比,本文检测模型准确率较高, 主要原因是本文数据中的特征信息相对隐蔽,结构过于 简单的网络结构不能对数据特征进行充分提取。LSTM 网络由两个单记忆门控单元组成,CNN_LSTM 也仅有一 个卷积层和一个 LSTM 层,且卷积层只有 4 个输出通道, 难以捕捉到较为复杂和抽象的特征。

在不改变基本网络结构(卷积层、LSTM 层数量)的 基础上,将文献[21]检测模型中第1个记忆门控单元的 神经元个数增加为原来的3倍,将文献[22]检测模型中 卷积层参数调整为与本文网络模型首端卷积层参数一 致,力图提高文献[21]、[22]检测模型对本文数据的检 测能力。在3个模型样本长度均为1500个时间序列点 的情况下,对文献[21]、[22]检测模型改进后与本文模 型进行对比分析,结果如表9所示。

## 表 9 改进后的网络模型性能对比分析

## Table 9 Comparative analysis of the

## improved model performance

网络模型	改进 LSTM ^[21]	改进 CNN_LSTM ^[22]	本文方法
检测准确率/%	84.45	96.02	96.39
检测时间/ms	0.65	4. 79	0.39

由表9可知,对文献[21]检测方法改进后,模型对样本检测时间增加,检测准确率却没有明显变化,这主要是由于LSTM使用的是单记忆门控单元,其检测能力有限。对文献[22]检测方法改进后,在增强网络特征提取能力的同时LSTM层的输入信息减小,明显提高了CNN_LSTM对本文数据的检测能力和检测效率。但由于其LSTM层具有多个的记忆门控单元,在信息处理时依旧要花费较长的时间。所以综合而言,本文所建模型的检测性能要优于对文献[21]、[22]检测方法改进后的网络模型。

综上,本文建立的改进 Mobilenet 网络模型在电动汽 车电弧故障检测的准确率和实时性方面效果较好。

## 5 结 论

论文搭建了电动汽车故障电弧实验平台。开展了无 振动和振动条件下故障电弧实验,对平坦路面和道路颠 簸情况下串联型故障电弧进行模拟,分析了不同工况下 干路电流中串联型故障电弧信号特征。

构建了基于改进 Mobilenet 网络的电动汽车串联型 故障电弧检测模型。通过分析不同的学习率、网络层数、 样本长度对网络检测性能的影响,进一步对模型进行了 优化。该检测模型可直接以干路电流为样本,检测电动 汽车主电路串联型电弧故障,并判断电弧的发生回路,检 测准确率和实时性效果较好。

通过和其他方法的对比分析,验证了本文方法在电 动汽车主电路串联型电弧故障检测中的适用性,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]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.
[2]杨帆,宿磊,杨志淳,等.基于改进 CEEMDAN 分解与

时空特征的低压供电线路串联故障电弧检测[J].电 力系统保护与控制,2022,50(12):72-81. YANG F, SU L, YANG ZH CH, et al. Series fault arc detection CEEMDAN decomposition; rough selection of frequency band; spatial-temporal features SVM[J]. Power System Protection and Control,2022,50(12):72-81.

- [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] XIA K, LIU B ZH, FU X L, et al. Wavelet entropy analysis and machine learning classification model of DC serial arc fault in electric vehicle power system [J]. IET Power Electron, 2019, 12(15): 3998-4004.
- [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 Exposition (ECCE). IEEE, 2020: 6372-6378.
- [6] 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.

- [7] 郭琳,柯希彪,汤引生,等.新能源汽车电弧故障检测方法及测试系统设计[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.
- [8] 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.

- [9] LU SH B, 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, 7: 45831-45840.
- [10] PARK H P, KIM M, JUNG J H, et al. Series DC arc fault detection method for PV systems employing differential power processing structure [J]. IEEE Transactions on Power Electronics, 2021, 36 (9): 9787-9795.
- [11] YANG J, WANG Y K. Identification and detection of DC arc fault in photovoltaic power generation system [C].
  2020 International Conference on Intelligent Transportation, Big Data & Smart City (ICITBS).
  IEEE, 2020: 440-444.
- [12] LIU SH Y, DONG L, LIAO X ZH, et al. Application of the variational mode decomposition-based time and timefrequency domain analysis on series DC arc fault detection of photovoltaic arrays[J]. IEEE Access, 2019, 7: 126177-126190.
- [13] AHMADI M, SAMET H, GHANBARI T. A new method for detecting series arc fault in photovoltaic systems based on the blind-source separation [J]. IEEE Transactions on Industrial Electronics, 2020, 67(6): 5041-5049.
- [14] AHMADI M, SAMET H, GHANBARI T. Series arc fault detection in photovoltaic systems based on signal-to-noise ratio characteristics using cross-correlation function [J].
   IEEE Transactions on Industrial Informatics, 2020, 16(5): 3198-3209.
- [15] LU Q W, YE Z Y, SU M M, et al. A DC series arc fault detection method using line current and supply voltage[J]. IEEE Access, 2020,8:10134-10146.

- [16] CAI X R, WAI R J. Intelligent DC arc-fault detection of solar pv power generation system via optimized VMDbased signal processing and PSO-SVM classifier [J].
   IEEE Journal of Photovoltaics, 2022, 12 (4): 1058-1077.
- [17] 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.
- [18] 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.
- [19] 周新城,吴自然,吴桂初. 基于 1D-CNN 的串联故障电弧检测[J]. 消防科学与技术,2020,39(2):278-281.
  ZHOU X CH, WU Z R, WU G CH. Series fault arc detection based on 1D-CNN [J]. Fire Science and Technology, 2020,39(2):278-281.
- [20] 余琼芳,黄高路,杨艺,等. 基于 AlexNet 深度学习网络的串联故障电弧检测方法[J]. 电子测量与仪器学报,2019,33(3):145-152.
  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.
- [21] 余琼芳,路文浩,杨艺.基于深度长短时记忆网络的多 支路串联故障电弧检测方法[J].计算机应用,2021, 41(S1):321-326.

YU Q F, LU W H, YANG Y. Multi-branch series fault arc detection method based on deep long short-term memory network [J]. Journal of Computer Applications, 2021,41(S1):321-326.

[22] 余琼芳,徐静,杨艺. 基于 CNN_LSTM 模型的复杂支路 故障电弧检测[J].中国安全生产科学技术,2022, 18(4):204-210.
YU Q F, XU J, YANG Y. Fault arc detection of complex branch based on CNN_LSTM model[J]. Journal of Safety Science and Technology, 2022,18(4):204-210.

- [23] LI W CH, LIU Y L, LI Y, et al. Series arc fault diagnosis and line selection method based on recurrent neural network [J]. IEEE Access, 2020, 8: 177815-177822.
- [24] 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.

- [25] 谷峥岩,魏利胜. 基于深度学习网络的轴承工件自动 检测[J]. 电子测量与仪器学报,2021,35(9):80-88.
  GU ZH Y, WEI L SH. Automatic detection for bearing roller based on deep learning network [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(9):80-88.
- [26] HOWARD A G, ZHU M, CHEN B, et al. Mobilenets: Efficient convolutional neural networks for mobile vision applications [J]. arXiv preprint arXiv: 1704. 04861, 2017.

### 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 at Liaoning Technical University. His main research interests include electrical contact and arc theory.