

DOI:10.19651/j.cnki.emt.2107264

基于 T-MobileNet-L 模型的 GIS 局部 放电模式识别研究*

程江洲 温静怡 鲍刚 何艳 陈奕睿
(三峡大学 电气与新能源学院 宜昌 443002)

摘要: 针对当前 GIS 局部放电模式智能识别过程中存在计算资源消耗大以及缺少真实标签数据的问题,利用激活函数为 Leaky ReLU 的 MobileNet-V2 模型,在减少模型参数数量的同时提取大量的图像特征信息。并融合迁移学习对模型参数进行预训练,在减少网络对输入数据量需求的同时提高模型的识别准确性。结果表明,该模型的参数量可降至 2.24×10^6 ,并且对于干扰以及 GIS 局部放电模式识别的平均准确率分别达到 95.8% 和 92.1%,与传统深度学习模型相比,该模型在显著降低计算复杂度的同时提升模式识别的准确率,对实际 GIS 设备进行有效、智能、轻量化运维检修具有一定的价值与意义。

关键词: 气体绝缘组合电器; MobileNet-V2; 迁移学习; 故障诊断; 智能运维

中图分类号: TP391; TM855 **文献标识码:** A **国家标准学科分类代码:** 510.4030

Research on pattern recognition of GIS partial discharge based on T-MobileNet-L model

Cheng Jiangzhou Wen Jingyi Bao Gang He Yan Chen Yirui

(School of Electrical Engineering and New Energy, China Three Gorges University, Yichang 443002, China)

Abstract: Aiming at the problems of large computing resource consumption and lack of real label data in the process of partial discharge mode intelligent identification in GIS. This paper uses the MobileNet-V2 model whose activation function is Leaky ReLU to extract a large amount of image feature information while reducing the amount of model parameters. It also integrates migration learning to pre-train the model parameters, which reduces the network's need for input data and improves the recognition accuracy of the model. The results show that the parameter quantity of the model can be reduced to 2.24×10^6 , and the average accuracy of interference and partial discharge pattern recognition in GIS reaches 95.8% and 92.1%, respectively. Compared with the traditional deep learning model, this model can significantly reduce the computational complexity and improve the accuracy of pattern recognition, which has certain value and significance for effective, intelligent and lightweight operation and maintenance of actual GIS equipment.

Keywords: GIS; MobileNet-V2; transfer learning; fault diagnosis; intelligence operations

0 引言

气体绝缘组合电器(gas insulated switchgear, GIS)作为一种电网关键设备,保证其安全稳定运行,对维持电网健康具有重要的意义。近年来随着电网的建设发展, GIS 设备被广泛应用于电力系统之中,因此对进一步提高 GIS 绝缘风险判别的准确性和运维决策的效率,以实现运维检修的智能化、轻量化,保障电网的安全稳定提出了更高的要求^[1]。

据统计,绝缘故障为 GIS 设备的主要故障,而局部放电

(partial discharge, PD)作为 GIS 设备绝缘故障的主要表现形式,对其进行检测识别成为判断设备绝缘状态的主要依据^[2]。目前,绝缘故障主要是通过通过对 PD 引发的物理现象和分解的化学产物进行检测的。检测方法中由于超高频(ultra high frequency, UHF)法具有较强的抗干扰能力和检测灵敏度较高而被广泛使用。目前国内外学者针对 GIS 局部放电检测数据的缺陷分类识别提出了基于局部放电相位分布模式(phase resolved partial discharge, PRPD)、脉冲序列分布(phase resolved pulse sequence, PRPS)等模

收稿日期:2021-07-14

* 基金项目:国家自然科学基金(61876097)项目资助

式下特征参数的提取和分类方法^[3]。

近年来随着深度学习的发展,以卷积神经网络(convolutional neural networks, CNN)为代表的多种深度学习模型在故障识别方面得到了大量应用^[4]。文献[5]通过 CNN 提取利用短时傅里叶变换得到滚动轴承振动时间序列的二维时频谱中不同故障特征,实现轴承故障诊断。文献[6]将 CNN 与深度置信网络(deep belief networks, DBN)进行融合,用于 GIS 设备局部放电故障类别的识别当中。文献[7]将传统的 CNN 网络进行深层和浅层的特征融合,并用于局部放电模式识别分类当中。虽然在以往的研究中,深度学习模型在智能分类方面解决了传统浅层学习中存在对大量的信号处理技术与专家经验的依赖的问题,提高了识别效率与准确性。但是这些模型往往是通过不断加深结构来达到提高识别准确率的目的,这使得提高识别准确率的同时极大地增加了计算资源的消耗。并且由于难以获取足量的现场数据用于深度学习模型的训练,现在大多的研究都是基于实验室数据,研究成果的可行性存疑,且往往忽略检测现场复杂环境中存在的各种电磁干扰。

因此,针对上述问题,为在减少计算资源消耗与训练模型对输入数据量的要求的同时进一步提高模型的识别准确性,以实现 GIS 识别运维的智能化、轻量化。本文提出一种结合迁移学习与典型的轻量化神经网络 MobileNet-V2 的 GIS 局部放电模式的自动识别方法。首先采用 ImageNet 数据集对激活函数替换为带泄露线性整流(leaky rectified linear unit, Leaky ReLU)函数的 MobileNet-V2 模型进行预训练,然后通过迁移学习使用现场采集的 GIS 各类局部放电以及干扰的 PRPD 谱图对模型进行微调,最后用于 GIS 局部放电模式的自动识别。并将识别结果与其他常用算法进行对比验证。

1 深度学习理论研究

1.1 MobileNet-V2 模型

近年来, CNN 神经网络已在图像识别领域取得了巨大的成功。但 CNN 网络识别准确率的提升往往伴随着参数数量的增长,使得运行过程中计算量和资源开销大幅度的增长。因此需要使用较高配置的设备进行识别处理,不满足电网运维检修智能化、轻量化的发展趋势和要求。而谷歌在 2017 年提出的深度学习网络 MobileNet,如今已成为主流的轻量化深度学习网络而被广泛的应用与计算机视觉当中^[8]。其基本思想是使用深度可分离卷积(depthwise separable convolution)代替常规卷积,在保证识别精度的情况下,达到大幅度的减少模型的参数的目的。

深度可分离卷积,从原理上看是用深度卷积(depthwise convolution, DW)以及逐点卷积(pointwise convolution, PW)两步卷积操作来替换传统卷积中的标准卷积。与常规卷积同时对每个通道进行卷积不同,深度可分离卷积先使用卷积核按通道对输入特征分别进行卷积,即使用深度卷

积获取特征的空间信息,然后使用 1×1 的卷积核对深度卷积的输出进行逐点卷积,使得深度卷积与逐点卷积可以分别作为滤波器和线性组合,从而深度可分离卷积可以在保证精确度的情况下,大幅度的降低网络的参数和计算量^[9],其具体分解过程如图 1 所示。

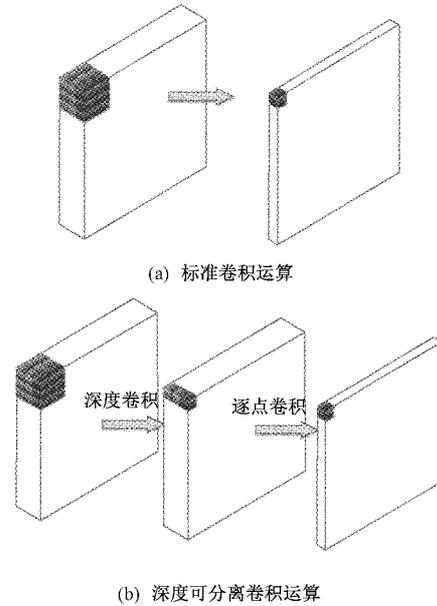


图 1 标准卷积与深度可分离卷积对比

当采用大小为 $D_K \times D_K = 3 \times 3$ 的卷积核时,深度可分离卷积的复杂度只有标准卷积的 $1/8$ 到 $1/9$,大幅度提高了网络模型计算速度。

与使用类似 VGG 简单堆栈结构的 MobileNet-V1 相比, MobileNet-V2 使用类似 ResNet 的残差结构,在 MobileNet-V1 结构的基础上,增加了线性瓶颈(Line Bottleneck)和反向残差(Inverted residuals)两种基本结构,可以加快收敛速度,防止退化^[10-11]。针对 MobileNet-V1 中梯度消失的潜在风险,本文采用 MobileNet-V2 对 GIS 局部放电模式进行检测和分类。具体结构如图 2 所示。

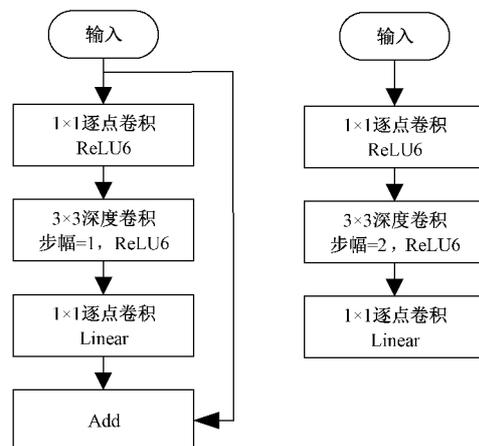


图 2 MobileNet-V2 模型的反向残差结构

MobileNet-V2 对 MobileNet-V1 中存在的问题进行改善,进一步提高了 MobileNet 模型的对图片的识别速度与精度,在本质上仍属于轻量化卷积神经网络,采用深度卷积和逐点卷积实现特征提取。

1.2 Leaky ReLU 激活函数

由于激活函数线性整流(rectified linear unit, ReLU)函数可以有效地解决梯度弥散现象的问题,而作为一种经典的激活函数被广泛用于深度学习模型的非线性学习当中。但是 ReLU 激活函数存在负半轴输出值恒为 0,使得对应的权重得不到更行的问题。而 Leaky ReLU 激活函数的负半轴是一个较小斜率的函数,因此相较于 ReLU 函数,其不仅解决了 ReLU 函数存在的负半轴神经元死亡现象引发的对应权重无法更新的问题,还对特征图内的负值特征进行提取,从而获取更多的特征信息^[12-13]。

因此本文将采用 Leaky ReLU 函数替代 MobileNet-V2 模型中的 ReLU 函数,进行进一步的探索研究。相应的激活函数曲线如图 3 所示。

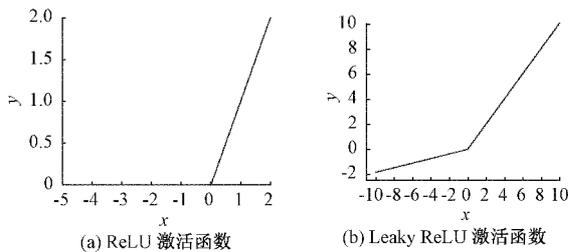


图 3 Leaky ReLU 函数曲线

Leaky ReLU 激活函数的表达式如下:

$$y_i = \begin{cases} x_i, & x_i \geq 0 \\ \frac{x_i}{a_i}, & x_i < 0 \end{cases} \quad (1)$$

采用 Leaky ReLU 激活函数进行的卷积操作公式为:

$$x_j^l = f(\sum_{i \in M_j} x_i^{l-1} \cdot k_{ij}^l + b_j^l) \quad (2)$$

其中, l 表示当前层; x_j^l 表示当前层第 j 个特征图; x_i^{l-1} 表示前一层第 i 个特征图; k_{ij}^l 表示该层第 i 个特征图和前一层第 j 个特征图所作用的卷积核; b_j^l 表示偏置值; M_j 表示产生该层第 j 个特征图相关的前一层特征图累计值; $f(\cdot)$ 表示 Leaky ReLU 激活函数。

1.3 迁移学习

1) 迁移学习介绍

在先前对神经网络的研究学习当中得出两个结论:首先,利用从相关数据集或任务中学习的转移特征初始化深层神经网络可以提高泛化性能,从而提高网络的效率;其次,神经网络浅层的低层特征对于不同但相关的是通用的和相似的任务,而最后一层的高级特性通常是特定于特定任务的^[14-16]。

而迁移学习即是一种应用上述结论,可在其他领域学到的知识应用于所需的研究领域的机器学习方法。由于

GIS 设备绝缘故障不长发生,因此累计采取到的现场谱图不足以支撑神经网络网络进行训练达到较好的识别效果,因此本文采用迁移学习的方法对模型进行预训练,从而解决由于数据不足和训练时间过多而引起的问题。

2) 基于迁移学习的 MobileNet-L 模型

基于迁移学习的 MobileNet-L 模型的总体结构如表 1 所示。本文首先采用 ImageNet 数据集对模型进行预训练,然后对训练完成的模型的标准卷积层以及前 13 个 Bottleneck 层进行封装,冻结相应参数。最后使用现场实测的 GIS 局部放电 PRPD 数据集对模型的其余参数进行微调。在加快模型训练速度的同时,提取到目标图像的深层特征。

表 1 使用迁移学习的 MobileNet-V2 模型的总体结构

| 结构 | 输入 | 操作 | t | c | n | s |
|----------|--------------------|----------------------|-----|-------|-----|-----|
| 参数 | $224^2 \times 3$ | Conv2d | — | 32 | 1 | 2 |
| | $112^2 \times 32$ | Bottleneck | 1 | 16 | 1 | 1 |
| | $112^2 \times 16$ | Bottleneck | 6 | 24 | 2 | 2 |
| | $56^2 \times 24$ | Bottleneck | 6 | 32 | 3 | 2 |
| | $28^2 \times 32$ | Bottleneck | 6 | 64 | 4 | 2 |
| 参数 微调 | $14^2 \times 64$ | Bottleneck | 6 | 96 | 3 | 1 |
| | $14^2 \times 96$ | Bottleneck | 6 | 160 | 3 | 2 |
| | $7^2 \times 160$ | Bottleneck | 6 | 320 | 1 | 1 |
| | $7^2 \times 320$ | Conv2d 1×1 | — | 1 280 | 1 | 1 |
| | $7^2 \times 1 280$ | Avgpool 7×7 | — | — | 1 | — |
| | $1^2 \times 1 280$ | Conv2d 1×1 | — | k | — | — |

由表 1 可知,每行描述同一层的 1 个或多个序列。标准的 MobileNet-V2 网络模型由 1 个卷积层(Conv),17 个 Bottleneck 层以及 2 个逐点卷积层(PW conv),共计 54 层构成。虽然相较于其他模型,MobileNet-V2 网络模型的网络层次有所加深,但是由于其采用了线性瓶颈和反向残差的结构,使得其模型参数量以及计算速度没有增多反而有所下降。

MobileNet-V2 核心模块,及 Bottleneck 层构建的实现,如表 2 所示。

表 2 MobileNet-V2 核心模块构建的实现

| 输入 | 操作 | 输出 |
|----------------------------|------------------------------------|----------------------------|
| $h \times w \times k$ | 1×1 Conv2d, ReLU6 | $h \times w \times tk$ |
| $h \times w \times tk$ | 3×3 Dwise $s = s$, ReLU6 | $h/s \times w/s \times tk$ |
| $h/s \times w/s \times tk$ | Linear 1×1 Conv2d | $h/s \times w/s \times k'$ |

2 基于 T-MobileNet-L 模型的局部放电模式识别方法

2.1 数据获取

现场检测时利用局部放电巡检仪和示波器,在变电站

进行特高频局部放电信号的 PRPD 和 PRPS 图谱采集。现场发现的局部放电缺陷经进一步停电试验并解体得到验证,确认缺陷类型。现场检测信号采集测点选取 GIS 上的盆式绝缘子进行测量。

通过对湖北省某电力公司 110~500 kV 多座变电站近 5 年来的运维和检修数据进行搜集,获取实际运行环境下变电站组合电器的局部放电检测图谱,共搜集现场检测图谱 600 张,形成检测信号图谱库,其中包括沿面放电 70 张、自由金属颗粒 120 张、绝缘件内部气隙放电 130 张、悬浮放电 130 张以及雷达噪音、马达噪音、闪光噪音以及移动电话噪音典型干扰的 PRPD 图谱共计 150 张,用于局部放电模式识别的训练与测试。典型缺陷检测图谱如图 4 所示,典型干扰的 PRPD 检测图谱入图 5 所示。

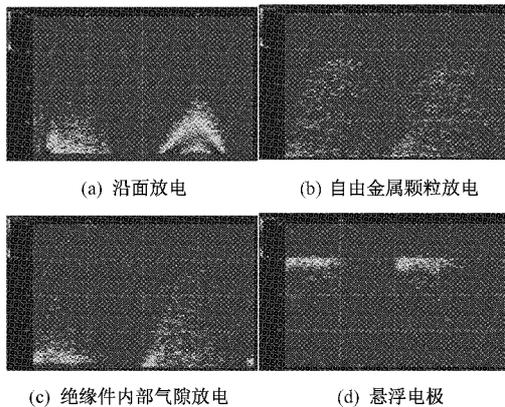


图 4 典型局部放电图谱

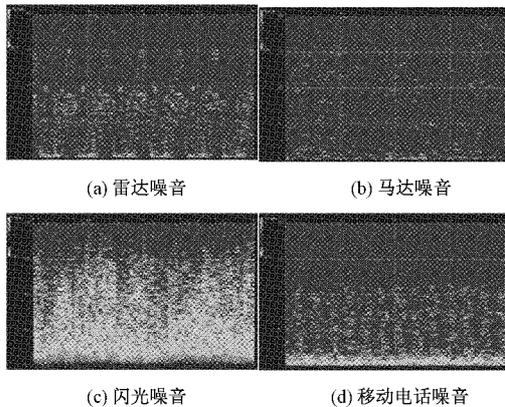


图 5 部分典型干扰信号

2.2 基于 T-MobileNet-L 模型的 GIS 局部放电模式识别方法

本文以采用 Leaky ReLU 激活函数的 MobileNet-V2 模型为基础,利用迁移学习对 ImageNet 数据集进行预训练,然后通过获取的 GIS 局部放电数据集进行微调,最后将 Softmax 作为分类器应用于模型的输出层中,基于 T-MobileNet-L 模型的 GIS 局部放电模式识别结构如图 6 所示。

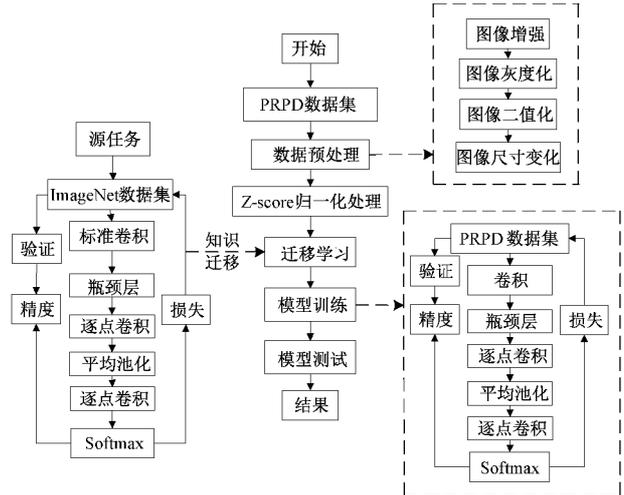


图 6 基于 T-MobileNet-L 模型的 GIS 局部放电模式识别结构

1) 数据预处理,构建训练样本集。随机选取 20% 经过二值化处理后的 PRPD 频谱进行数据增强,即对选取的图片进行旋转、翻转、缩放、裁剪等操作进行图像生成,从而提高模型的泛化能力。最后为满足网络模型的输入维度,采用 Z-score 标准化的方法对输入数据进行归一化。

2) 建立基于 MobileNet-V2 网络和迁移学习的 GIS 局部放电识别模型。

3) 模型训练,采用反向传播算法(BP)和随机梯度下降算法(SGD),通过计算实际与期望网络分类输出样本之间的差异进行微调,使得全连接层的模型参数不断优化,同时为提高训练性能采用了丢弃(dropout)和批量归一化(BN)的方法。

4) 模型测试。输出层根据缺陷类别设置为 5 类。最终得到训练好的局部放电识别模型。可自动根据输入的检测图谱输出相应的诊断结果。

3 结果与分析

本文基于 MobileNet-V2 轻量化神经网络结构,以 Anaconda 为开发工具,采用 Keras 框架并使用 Tensorflow 2.0 编写代码,使用 Windows 10, 64 位操作系统,CPU 使用 Intel Core i7-7700K,GPU 使用 NVIDIA GTX1080Ti 8 G,内存为 32 G 以实现所有实验。

使用 4 种典型缺陷以及 4 种典型干扰的各 500 组,共计 4 000 组数据建立 5 类样本集进行进行 GIS 局部放电模式识别分类方法的研究,随机选取数据中的 70% 作为训练集,10% 作为验证集,剩余的 20% 数据作为测试集。模型训练时,设置学习率为 0.001,丢弃率(dropout)取 0.5,选取批量大小(batch-size)为 64,迭代 50 次。使用 ImageNet 数据集进行预训练。

为了验证本文采用模型的有效性以及将其应用于 GIS 设备的局部放电故障分类识别的效果。本文将本文采用的

模型与传统的 MobileNetV1、MobileNetV2、深度残差网络 (deep residual network, ResNet) 和 VGG16 模型进行对比分析。

3.1 改进模型效果验证

1) 改进模型效果参数量对比分析

由于在输入相同数据的情况下,模型的计算量会随着参数量的减少而降低,从而使得模型的资源开销得以减少。本文将 T-MobileNet-L 模型与其他模型的参数量以及训练所需要的时间进行对比分析,具体数据如图 7 所示。

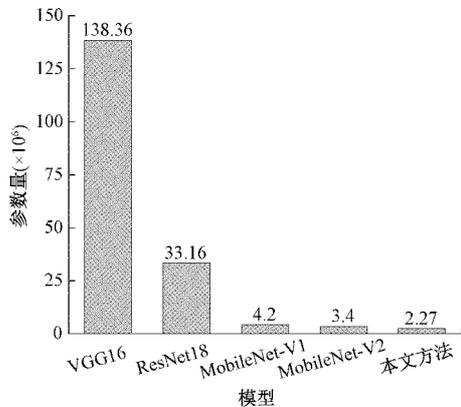


图 7 各种模型的参数量

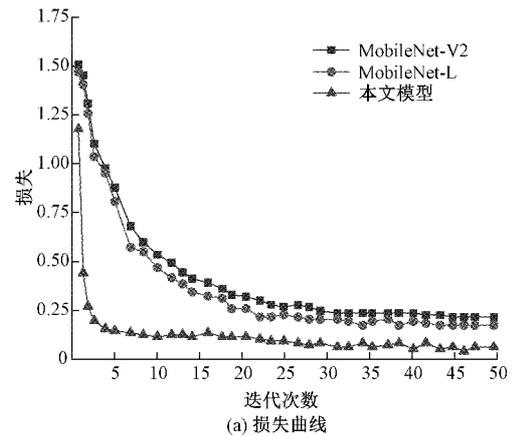
分析图 7 可知, MobileNet 模型的参数量相较于 VGG16 模型和 ResNet18 模型已大幅度减少。而本文模型由于采用了 Leaky ReLU 函数,使得本文模型可以通过原位运算完成从输入到输出的非线性映射,排除输出特征映射的参数量,从而使得参数量由进一步减少,由 3.4×10^6 降低至 2.27×10^6 ,只有 VGG16 模型的 1.64%, ResNet18 模型的 6.85%。从模型参数量变化上看,本文模型具有较小的计算资源开销,降低识别设备的配置需求,可以应用于移动端以及嵌入式设备,实现运检的智能化,轻量化。

2) 改进模型效果验证

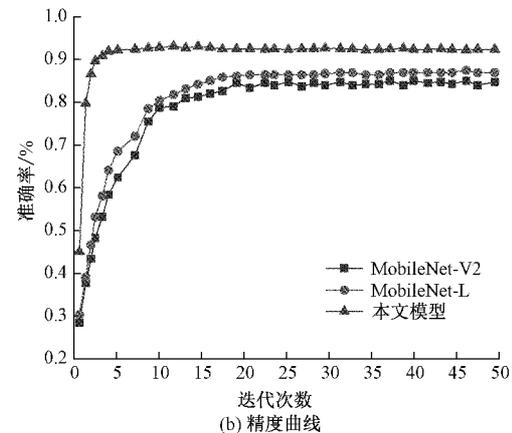
为了验证改进模型的真实效果,本文将原 MobileNet-V2 模型、使用 Leaky ReLU 激活函数的 MobileNet-L 模型以及进一步使用迁移学习进行预训练的 T-MobileNet-L 模型用于 GIS 局部放电模式的识别的,进行收敛速度与准确率变化对比分析。相应的损失曲线以及精度曲线如图 8(a)、(b) 所示。

由图 8 可知,采用 Leaky ReLU 函数代替的 MobileNet-V2 模型相较于原模型,准确率已从 85.3% 提升至 87.9%,收敛速度也有所加快。而进一步应用迁移学习的 T-MobileNet-L 模型,即本文所采用的识别模型,准确率与收敛性提升更加明显。准确率又由 87.9% 上升至 92.1%,达到了较好的识别分类精度。并且相较于原模型在第 30 次迭代时才达到稳定状态,本文模型在第 7 次迭代时已达到稳定状态,收敛速度明显加快。

分析可知,本文采用的模型相较于原模型,应用于 GIS



(a) 损失曲线



(b) 精度曲线

图 8 MobileNet 模型的损失和精度曲线

的局部放电模式识别中时可以在加快收敛速度的同时达到更好的识别分类效果。因此本文对原模型的采取的改善是真实有效地。

3.2 模式识别的准确性分析

模型识别的准确率是判别模型是否有实际应用价值的最大参考因素,因此为验证模型的识别精度,基于前文建立的共计 4 000 组 PRPD 图谱的数据库,与传统的深度学习模型 VGG16、ResNet18 以及相应的 MobileNet 神经网络进行 GIS 局部放电模式识别准确率的对比分析,结果如表 3 所示。

由表 3 可知,标准 MobileNet 模型与 VGG16 和 ResNet18 模型相比,对 GIS 设备局部放电故障的分类准确率相差不大。但对比图 7,相比于传统深度学习模型, MobileNet 模型的参数量大幅度降低,使得增模型的资源开销得以降低。而经过改进的使用 Leaky ReLU 激活函数与采用迁移学习进行预训练的 MobileNet 模型,即本文使用的 T-MobileNet-L 模型对电晕放电、悬浮放电以及干扰的识别准确率都达到了 90% 以上,其中对干扰的识别准确率达到 95.8%,可以有效地排除干扰带来的影响,而对于自由金属微粒以及绝缘子气隙放电缺陷的识别准确率也有大幅度的提升,其中对绝缘子气隙放电的识别准确率最低,但也达到了 87.6%,远高于其余模型。平均准确率提升至

表 3 GIS 局部放电模式识别结果

%

| 放电类型 | 识别准确率 | | | | |
|----------|-------|----------|--------------|--------------|------|
| | VGG16 | ResNet18 | MobileNet-V1 | MobileNet-V2 | 本文方法 |
| 沿面放电 | 84.6 | 86.2 | 81.9 | 83.7 | 94.8 |
| 自由金属微粒放电 | 83.2 | 82.6 | 83.7 | 85.4 | 89.7 |
| 绝缘子气隙放电 | 75.4 | 80.1 | 79.4 | 81.4 | 87.6 |
| 悬浮放电 | 86.4 | 90.4 | 86.3 | 87.1 | 92.6 |
| 干扰 | 86.2 | 87.2 | 85.6 | 87.9 | 95.8 |
| 平均准确率 | 83.2 | 85.3 | 83.4 | 85.1 | 92.1 |

92.1%，比原模型提升了 6.8%，相较于 VGG16、ResNet18 以及 MobileNet-V1 模型，平均准确率分别提升了 8.9%、6.8% 和 8.7%，识别准确率效果提升显著。

4 结 论

本文提出一种采用 Leaky ReLU 激活函数，融合迁移学习的 MobileNet-V2 模型，用于 GIS 设备的局部放电模式识别当中。首先，本文将 MobileNet-V2 模型中的激活函数优化为 Leaky ReLU 函数，使得模型可以在提取更多图像信息的时候进一步减少模型参数量，减少运行时的资源消耗。并应用迁移学习，使得在减少模型训练所需的数据量的同时达到加快模型的训练速度，提高准确性的目的。基于本文建立的由现场检测的局部放电和干扰 PRPD 图谱组成的数据库进行模型的测试。实验结果表明，本文所建立模型对于干扰的识别准确率可以达到 95.8%，平均识别准确率达到 91.1%，对比其余传统模型在实际应用中已达到较高识别精度，具有实际应用的价值与优势。并且进一步的减少了模型的参数量，使得参数量将至 2.24×10^6 ，极大地减少对运行资源的消耗，使得模型在移动端和嵌入式设备中运行成为可能。

因此综合来看，本文所建立的 T-MobileNet-L 模型对实现电气设备的智能化、轻量化运维具有一定的实际价值。但是本文还有许多改进的余地，例如本文仅采用翻转等简单方式来达到增强数据的目的，然而近年来由于生成对抗网络(GAN)以及其衍生模型的出现与，未来可以利用相关网络获取更好的数据增强效果。

参考文献

- [1] 倪辉, 胡文山, 徐进霞, 等. 基于移动应用平台的变电站智能化现场运维系统[J]. 电测与仪表, 2018, 55(6): 35-41.
- [2] 金协杰. 基于特高频法的 GIS 局部放电故障智能诊断与方法研究[D]. 广东: 华南理工大学, 2018.
- [3] 唐志国, 唐铭泽, 李金忠, 等. 电气设备局部放电模式识别研究综述[J]. 高电压技术, 2017, 43(7): 2263-2277.
- [4] 陈星. 基于卷积神经网络算法的飞机发电机故障诊断研究[J]. 国外电子测量技术, 2020, 39(11): 57-60.
- [5] 唐波, 陈慎慎. 基于深度卷积神经网络的轴承故障诊断方法[J]. 电子测量与仪器学报, 2020, 34(3): 88-93.
- [6] 袁文海, 刘彪, 徐浩, 等. 基于复合神经网络的 GIS 局放故障类型识别[J]. 电力科学与技术学报, 2021, 36(4): 157-164.
- [7] 李宏波, 朱永利, 王京保. 基于多层特征融合 CNN 的变压器 PRPD 图谱识别[J]. 电测与仪表, 2020, 57(18): 63-68.
- [8] 邵伟平, 王兴, 曹昭睿, 等. 基于 MobileNet 与 YOLOv3 的轻量化卷积神经网络设计[J]. 计算机应用, 2020, 40(S1): 8-13.
- [9] 杨可军, 杨建旭, 陈思宝, 等. 基于深度可分离卷积及 SVD 输电线路缺陷检测[J]. 智慧电力, 2020, 48(10): 64-77.
- [10] SANDLER M, HOWARD A, ZHU M, et al. Mobilenetv2: Inverted residuals and linear bottlenecks[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 4510-4520.
- [11] 曾娅琴, 张琳琳, 张若楠, 等. 基于 MobileNet 的恶意软件家族分类模型[J]. 计算机工程, 2020, 46(4): 163-168.
- [12] 王建仁, 马鑫, 段刚龙, 等. 边缘智能背景下的手写数字识别[J]. 计算机应用, 2019, 39(12): 3548-3555.
- [13] JEBAVEERASINGH J, IMMANUEL J J, GETZI J L P, et al. Super-resolution of digital images using CNN with Leaky ReLU[J]. International Journal of Recent Technology and Engineering, 2019, 8: 210-212.
- [14] 李传鑫, 刘增力. 时频分析与 VGG 19 迁移学习的轴承故障检测[J]. 电子测量技术, 2021, 44(5): 162-165.
- [15] 赵勇, 雷欢, 马敬奇, 等. 迁移模式下卷积神经网络在虹膜识别中的应用[J]. 电子测量技术, 2020, 43(9): 114-120.
- [16] 曲桂果, 袁琦, 李彦, 等. 基于深度网络迁移学习的致痫区脑电识别[J]. 仪器仪表学报, 2020, 41(5): 164-173.

作者简介

程江洲, 副教授, 硕士生导师, 主要研究方向为电力设备状态在线检测、智能电网等。

E-mail:chengjiangzhou@ctgu.edu.cn

温静怡, 硕士, 主要研究方向为电气设备状态在线检测及故障诊断技术、高电压技术。

E-mail:2878324662@qq.com

鲍刚, 硕士研究生导师, 主要研究方向为电力设备状态在线检测、智能电网。

E-mail:2878324662@qq.com

何艳, 硕士研究生, 主要研究方向为电力负荷聚类算法。

E-mail:1105721258@qq.com

陈奕睿, 硕士研究生, 主要研究方向为虚拟电厂优化调度。

E-mail:704771657@qq.com