

基于改进 MobileNet V3 的非侵入式负荷识别算法研究

郑旭丹, 黄福明

(福州大学至诚学院 信息工程系, 福建 福州 350001)

摘要: 针对目前非侵入式负荷识别算法存在参数量大、计算需求高、负荷识别性能差等问题, 提出一种基于改进 MobileNet V3 的负荷识别算法。首先, 采用格拉姆差场算法将一维时间序列转换成富含谐波特征的二维负荷图像, 经过预处理后作为改进 MobileNet V3 模型的输入数据集; 其次, 采用卷积注意力机制模块替换空间注意力模块, 使模型同时关注输入图像的通道和空间贡献度信息; 最后, 采用 Mish(x) 激活函数以减少深层网络中的梯度消失和爆炸问题。实验结果表明, 改进后的 MobileNet V3 模型在参数量基本不变, 计算量仅增加 2.07% 的情况下, 在 PLAID 与 WHITED 数据集上负荷检测准确率分别达到 96.8% 和 94.5%, 较基准 MobileNet V3 模型的准确率分别提高了 10.1% 和 10.4%, 展示了其在非侵入式负荷识别算法中具有良好的应用前景。

关键词: MobileNet V3; 格拉姆差场算法; 卷积注意力机制; 非侵入式负荷识别; 轻量化

DOI: 10.11907/rjdk.251479

中图分类号: TP391

文献标识码: A

文章编号: 1672-7800(2026)005-0080-08

扫描二维码阅读全文:



Research on Non-Intrusive Load Recognition Algorithm Based on Improved MobileNet V3

ZHENG Xudan, HUANG Fuming

(Department of Information Engineering, Fuzhou University Zhicheng College, Fuzhou 350001, China)

Abstract: To address the challenges in current non-intrusive load identification algorithms such as large parameter sizes, high computational demands, and poor load identification performance, this paper proposes an algorithm based on an improved MobileNet V3 architecture. First, the Gramian Angular Difference Field (GADF) algorithm is first employed to convert the one-dimensional time-series data into two-dimensional load images rich in harmonic features. These images undergo preprocessing and enhancement before being fed as input to the modified MobileNet V3 image classification model. Second, the spatial attention module is replaced with a Convolutional Block Attention Module (CBAM), enabling the model to simultaneously focus on both channel-wise and spatial importance within the input images. Third, the Mish(x) activation function is adopted to mitigate gradient vanishing and explosion issues in deep network layers. The improved MobileNet V3 model achieves load detection accuracies of 96.8% on the PLAID dataset and 94.5% on the WHITED dataset. This represents an improvement of 10.1% and 10.4%, respectively, over the original MobileNet V3 model. Notably, these gains are achieved with nearly identical parameter counts and only a 2.07% increase in computational complexity. The results demonstrate the significant potential of the proposed enhanced MobileNet V3 architecture for practical applications in non-intrusive load identification (NILM) systems.

Key Words: MobileNet V3; Gramian angular difference field algorithm; convolutional block attention mechanism; non-intrusive load recognition; lightweight

0 引言

近年来我国大力推行各项节能减排措施, 积极推进智

慧电力系统建设, 明确提出力争在 2030 年前实现“碳达峰”, 2060 年前实现“碳中和”^[1-2]。智慧电力系统是通过对电力负荷设备的运行数据进行采集和解析, 实现对用电情况的实时监测, 旨在帮助用户获取当前电力负荷设备运行

收稿日期: 2025-07-23

基金项目: 福建省中青年教育科研项目(科技类)(JAT231184); 福建省本科高校教育教学研究项目(FBJY20240105); 教育部产学合作协同育人项目(230706093274451)

作者简介: 郑旭丹(1986-), 女, 福州大学至诚学院信息工程系讲师, 研究方向为人工智能。本文通讯作者: 郑旭丹。

情况,以减少不必要的能源浪费,培养健康的用电习惯,同时为电力公司提供大量的基础用电数据,从而为电网的电力调配提供底层数据支持,提高智能电网负荷模型的精确度、准确度及合理性^[3-6]。

目前的负荷监测系统大致可分为侵入式和非侵入式两大类^[7]。非侵入式负荷监测(Non-Intrusive Load Monitoring, NILM)系统通过在电力入口处安装硬件设备并部署软件系统,对电信号进行监测和分析,推理得到负荷集群中单个负荷的运行情况,能在维持较低监测成本的同时,很好地保护用户隐私数据,符合“十四五”电力发展规划中提出的智能监测设备大规模普及的要求^[8-9]。NILM是1992年由美国麻省理工学院的Hart^[10]教授提出的,通过监测电压、电流等电信号并进行信号处理和分析,得到单个负荷的种类和运行情况等信息;Srinivasan等^[11]对基于稳态电流特征的神经网络进行深入研究,能够改善负荷识别时由于不同负荷功率特征的差异带来的监测误差,提高监测准确率;赵洪山等^[12]对热水器的检测识别结果进行分析,评估热水器需求响应的灵活性,为电网运营商制定合理的电力调控策略提供数据支撑;Piccialli等^[13]将长短期记忆网络(Long Short Term Memory, LSTM)引入NILM系统,以提升序列特征识别和提取能力,提高负荷识别的准确率,降低误差;Feng等^[14]提出一种多通道时空特征融合方法,引入注意力机制,并将卷积神经网络(Convolutional Neural Network, CNN)和循环神经网络(Recurrent Neural Network, RNN)相融合,提升模型的有效性;崔昊杨等^[15]提出一种基于颜色编码的非侵入式负荷细粒度识别方法,利用颜色编码技术对轨迹图像进行处理,并利用CNN对图像特征进行提取。

尽管目前卷积神经网络在负荷识别方面取得了较好效果,但是NILM需要部署在计算能力受限的边缘设备上。上述模型存在计算复杂和参数量大的问题,在边缘设备难以正常运行^[16]。因此,本文设计了一种基于改进 MobileNet V3 的轻量化负荷识别算法,以 MobileNet V3-Large 模型为基准,引入格拉姆差场(Gramian Angular Difference Fields, GADF)算法将一维时序数据转换成更适合卷积神经网络处理的二维图像数据,并引入 Mish(x) 激活函数、卷积注意力机制(Convolutional Block Attention Module, CBAM),在保持 MobileNet V3 模型轻量化的同时,提高模型对数据特征的提取能力和负荷识别的准确度。

1 MobileNet V3 架构

MobileNet V3 是一种应用广泛的轻量化网络结构,具有参数量小、计算成本低等优点,专为计算能力受限的移动设备和边缘设备设计^[17]。MobileNet V3 继承了 MobileNet V1 网络结构中的深度可分离卷积和 MobileNet V2 网络结构中的倒残差连接结构,并引入轻量化通道注意力

机制压缩和激励网络(Squeeze-and-Excitation, SE),同时使用新激活函数 H-Swish(x) 代替 V2 中的部分 ReLU6(x)。

MobileNet V3 结构如图 1 所示。其由多个基本构件组成,每个构件包括一个卷积层、一个非线性激活函数以及一个可选的 SE 模块^[18]。MobileNet V3 结构根据计算量的差别,可分为 Large 和 Small 两个版本。两者并无整体结构框架上的差异,区别体现在基本单元 bneck 的个数以及内部参数数量上。为提升准确率,本文选择将 MobileNet V3-Large 作为基准模型。




Fig. 1 Architecture of MobileNet V3

图1 MobileNet V3 架构

2 改进 MobileNet 模型设计

本文系统基于 MobileNet V3-Large 模型进行改进,将一维时间序列模型转换成二维负荷图像,对图像进行预处理后作为数据集输入到改进 MobileNet V3 模型中进行负荷识别,最终输出负荷识别结果。整体架构如图 2 所示。




Fig. 2 Architecture of non-intrusive load recognition model based on MobileNet V3

图2 基于 MobileNet V3 的非侵入式负荷识别模型架构

2.1 数据增强

2.1.1 一维时间序列转图像

鉴于卷积神经网络在处理一维时间序列数据上存在的不足,以及在处理二维图像数据方面的出色表现,本文系统采用格拉姆差场(GADF)算法对一维电流时序数据进行处理,将其转换成二维负荷图像,以提高模型的学习能力和特征提取能力。

GADF 是格拉姆角场(Gramian Angular Fields, GAFs)的一种,通过坐标转换将一维时序数据从直角坐标系转换

到极坐标系,再对数据作角度差来识别数据间的时间相关性,并将其体现在二维图像中^[19]。GADF转换过程如图3所示。经转换处理后的格拉姆角图包含了原始一维时序数据的关键信息,即电信号谐波信息与时序的对应关系。图像中用红色到紫色的渐变过程映射 $[-1, 1]$ 区间,其中谐波幅值较大的地方呈现红色,谐波幅值较小的地方呈现紫色。对比原始一维时序数据,可以显著增强不同次谐波的差异,提取更多时序特征信息。




Fig. 3 GADF conversion process

图3 GADF转换过程

GADF转换具体步骤如下:

(1)数据标准化处理。为消除不同量纲对结果的影响,对原始一维时间序列数据进行标准化处理,将其归一化到 $[-1, 1]$ 之间。转换公式如式(1)所示,转换结果如图3(a)所示。

$$\tilde{x}_n = \frac{(x_n - \max(X)) + (x_n - \min(X))}{\max(X) - \min(X)} \quad (1)$$

(2)坐标转换。将 $[-1, 1]$ 之间的标准化数据作反余弦处理,从直角坐标系转换到极坐标系,转换公式如式(2)所示。直角坐标系中 $[-1, 1]$ 之间的数据在极坐标系中 $[0, \pi]$ 角度范围内不同的角度点之间扭转,如图3(b)所示。

$$\begin{cases} \phi = \arccos(\tilde{x}_i), & -1 \leq \tilde{x}_i \leq 1, \tilde{x}_i \in \tilde{X} \\ r = \frac{t_i}{N}, & t_i \in N \end{cases} \quad (2)$$

(3)图像生成。考虑数据点与点之间的角度差,本文系统对数据点进行GADF处理,将其转换为二维图像。转换公式如式(3)所示,生成二维图像如图3(c)所示。图像中的每个像素值体现出不同次谐波的差异,从而保留了数据的时序特征。

$$GADF = [\sin(\phi_i - \phi_j)] = \sqrt{I - \tilde{X}^2} \cdot \tilde{X}' - \tilde{X} \cdot \sqrt{I - \tilde{X}^2} \quad (3)$$

2.1.2 预处理层

经过GADF处理后生成的二维负荷图像需要先进行预处理,最终生成 $3 \times 224 \times 224$ 的图像,以提高MobileNet V3模型输入图像的质量,增强特征提取效果。

预处理层的操作主要包括随机裁剪、旋转、调整色彩饱和度等,旨在丰富数据的多样性,提升数据集的有效性和随机性,从而提高后续MobileNet V3模型的泛化能力,防止过拟合。

2.2 引入迁移学习的MobileNet V3模型构建

迁移学习是一种机器学习方法,利用模型在先前任务中已学到的能力来解决新问题,是机器学习的“举一反三”^[20]。MobileNet V3在ImageNet数据集上的Top-1准确率达到了75.2%。ImageNet数据集中庞大的数据基础使MobileNet V3模型具有良好的迁移效果,能弥补实际应用中训练样本数量较少、对图像特征挖掘不足的缺陷,使模型在样本不足时仍能实现较好的训练结果,可达到预期目标要求。

在负荷识别系统中,尽管数据集经过数据增强操作,但负荷图像的样本数量仍与ImageNet数据集中高达千万级的数据样本量相差极大,从0开始进行MobileNet网络参考训练难度大、耗时长,容易过拟合,训练效果欠佳。因此,本文系统采用微调的迁移策略来缩短训练时间,提升训练效果。载入模型在ImageNet数据集上已训练好的权重参数,在训练时冻结特征参数,只训练最后两个全连接层。

2.3 注意力机制改进

MobileNet V3模型的注意力机制为SE模块,通常集成在bneck结构中。其核心思想是以自动学习的方式根据输入信息为特征图的每个通道学习一个权重参数,获取每个特征通道的贡献度信息,再根据学习到的信息强调贡献度高的通道,抑制贡献度低的通道,使模型能更好地学习特征图信息。

虽然SE模块具有性能高和计算开销低等优点,但其只关注特征图内部通道信息,而忽略了空间位置信息的影响。本文系统采用CBAM模块替换SE模块。CBAM模块是一种轻量级卷积注意力模块,由Woo等^[21]于2018年提出。其通过融合通道注意力和空间注意力,为模型提供更全面、有效的特征提取能力,能够帮助模型提取输入图像特征,提高识别能力。同时,CBAM模块结构复杂度低,内部只进行少量池化和卷积操作,避免了大量卷积带来的计算需求,计算效率高,能够保证改进后的MobileNet网络结构维持计算量小的优点。Woo等^[21]通过实验论证了MobileNet+CBAM模型相比MobileNet+SE模型具有更高的准确率,且模型的参数量基本不变,计算量仅增加了1.05%,表明了CBAM在低端设备上的巨大应用潜力。

CBAM模块工作流程如图4所示,经过串行的通道注意力模块和空间注意力模块分别对输入特征进行提取。第一阶段是通道注意力模块,采用最大池化和平均池化分别对输入特征F进行池化操作,将池化结果送入共享多层感知机提取通道特征,获取每个特征通道的贡献度,并对结果进行处理以获得最终的通道注意力权重。最后将通道注意力权重作用到输入特征图F上,得到特征图F'。第二阶段,空间注意力模块将特征图F'在通道维度进行压缩,在空间维度进行最大池化和平均池化操作,然后利用卷积从池化结果中学习空间注意力权重。同时,通过Sigmoid激活函数进行激活,获得最终的空间注意力权重,并将空间注意力权重作用到特征图F'上,得到最终的输出特征图。




Fig. 4 Convolutional block attention module

图4 卷积注意力机制模块

2.4 激活函数改进

MobileNet V3 在网络浅层的卷积层部分使用 ReLU6(x) 激活函数,计算复杂度低,在精度要求不高的计算中能保证高效计算和结果的稳定输出;在网络较深层的卷积层采用 H-Swish(x) 激活函数,利用其非线性优势加强对输入数据深层特征的挖掘。函数具体公式如式(4)所示。

$$H-Swish(x) = x \frac{ReLU6(x+3)}{6} \quad (4)$$

Mish(x) 与 H-Swish(x) 函数值域如图5所示, Mish(x) 与 H-Swish(x) 函数梯度如图6所示。

从图5可以看出, H-Swish(x) 函数在输入值位于 [-3, 3] 区间时平滑度最好, 超过此范围则会对输出的准确率造成一定影响。从图6的函数梯度图像也可以看出, H-




Fig. 5 Ranges of Mish(x) and H-Swish(x) functions

图5 Mish(x)与H-Swish(x)函数值域

Swish(x) 激活函数的梯度僵直,精度和泛化性不够。因此,本文系统采用在分类检测任务中性能更优的 Mish(x) 函数来替代 H-Swish(x) 函数。Mish(x) 函数公式如式(5)所示。

$$Mish(x) = x * \tanh(\ln(1 + e^x)) \quad (5)$$




Fig. 6 Gradients of Mish(x) and H-Swish(x) functions

图6 Mish(x)与H-Swish(x)函数梯度

Mish(x)函数曲线图像在整个输入域都是连续可导的。Mish(x)函数能改善H-Swish(x)函数的梯度僵直问题,其平滑性也有助于在CNN的深层网络中更好地保留梯度信息,减少梯度消失和爆炸问题,使反向传播过程更加稳定。同时有助于算法更快收敛,缩短推理时间,提升模型训练效果。

3 实验与结果分析

3.1 实验环境

本文实验环境为 ubuntu 22.04 系统,软件工具为 Pycharm,处理器为 16 vCPU Intel(R) Xeon(R) Platinum 8352V CPU @ 2.10GHz,显卡为 NVIDIA RTX 4090(24GB),软件编程环境为 Python 3.10,深度学习框架为 Pytorch 2.3.0。

训练参数设置如下:训练周期(epochs)为200,批处理量(batchsize)为16,训练时输入图像大小为 $3 \times 224 \times 224$,模型训练中采用Adam优化器,初始学习率(learning rate)为0.001,损失函数为交叉熵损失(Cross Entropy Loss)。

3.2 数据集

本文在两个公共数据集上进行实验,分别是PLAID和WHITED数据集。PLAID数据集包含从美国60多个家庭中11种不同类型的设备,以30KHz采样率采集的电流和电压数据;WHITED数据集包含来自全球不同地区的54种电器,以44kHz采样率采集的电压和电流数据。这两个数据集均采用高分辨率设备采集,目前被广泛应用于测试负荷识别方法在实际任务中识别的准确性、鲁棒性和实用性。两个数据集的区别在于PLAID数据集具有较大的类内差异,而WHITED数据集具有较大的类间差异,借助这两个公共数据集可全面验证本文方法^[22]。

根据上文阐述的方法,本文将PLAID和WHITED数据集中的电流序列生成GADF图,并进行色彩饱和度调整、随机旋转、裁剪、翻转等数据预处理,最终生成数据集。图7展示了PLAID数据集中9种不同用电负荷的GADF图,依次是白炽灯、笔记本电脑、冰箱、风扇、加热器、荧光灯、空调、微波炉、洗衣机。从图中可以看出,不同负荷对应的GADF图像具有不同的纹理和颜色分布,体现出不同次谐

波的差异。

3.3 模型评估指标

本文主要关注评估模型分类能力的4个重要的通用指标:Top-1准确率、平均精确率、平均召回率和平均F1值,并给出改进后模型的混淆矩阵。混淆矩阵是一个在分类任务中体现输入数据预测值和真实值对应情况的二维矩阵,能将模型的分类测试结果可视化。混淆矩阵的每一列代表数据的预测结果类别标签,每一行代表数据的真实归属类别标签。因此,对角线上的数字代表了模型预测正确的样本个数。

混淆矩阵中包含了4个模型的重要结果参数:①TP(True Positive):实际为真实归属标签且预测为真实归属标签的样本数量,即系统预测正确;②FP(False Positive):实际为错误归属标签但预测为真实归属标签的样本数量,即系统预测错误;③TN(True Negative):实际为错误归属标签且预测为错误归属标签的数量,即系统预测正确;④FN(False Negative):实际为真实归属标签但预测为错误归属标签的数量,即系统预测遗漏。基于这4个预测结果参数,可以计算出Top-1准确率、平均精确率、平均召回率和平均F1值。

准确率(Accuracy)表示模型检测输出预测正确的样本占模型输入总样本数的比例,分类模型更关注准确率。

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad (6)$$

精确率(Precision)表示所有被模型检测输出预测为真实归属标签的样本中所有实际为真实归属标签的样本所占比例,目标识别模型更关注精确率。

$$Precision = \frac{TP}{TP + FP} \quad (7)$$

召回率(Recall)表示实际为真实归属标签的样本,且被模型检测输出预测为真实归属标签的样本所占比例。

$$Recall = \frac{TP}{TP + FN} \quad (8)$$

F1得分综合了精确率和召回率,是两者的加权平均,用于全面评估模型性能。

$$F1 = 2 * \frac{Precision * Recall}{Precision + Recall} \quad (9)$$

本文实验采用PLAID数据集测试结果绘制的混淆矩阵进行直观的视觉表示,结果如图8所示,根据混淆矩阵计算的对应每种负载的准确率、精确率、召回率和F1分数如表1所示。综合图8和表1可以看出,洗衣机和冰箱因存在多种运行状态,容易被误判为其他种类电器。总体而言,本文系统对绝大部分负荷识别的准确率可达97%以上,在全体测试样本上的识别准确率达到96.8%。

3.4 消融实验结果与分析

本文基于PLAID数据集设计消融实验,以验证改进MobileNet V3模型各部分改进的有效性。以基准MobileNet V3-Large为基础模型,分别引入数据增强、Mish(x)函数和CBAM机制等关键模块,观察消融实验中模型的性




Fig. 7 GADF images generated from 9 types of current harmonic sequences in the PLAID dataset

图 7 PLAID 数据集中 9 种电流谐波序列生成的格拉姆差场图




Fig. 8 Confusion matrix plotted from the PLAID dataset test results

图 8 PLAID 数据集测试结果绘制的混淆矩阵

Table 1 Load identification results

表 1 负荷识别结果

编号	类别	样本数	准确率/%	精确率/%	召回率/%	F1 分数/%
1	空调	237	97.47	97.88	97.47	97.67
2	吹风机	256	98.83	96.93	98.83	97.87
3	吸尘器	192	98.44	96.92	98.44	97.67
4	笔记本	213	98.12	96.31	98.12	97.21
5	洗衣机	156	89.74	97.90	89.74	93.65
6	冰箱	176	91.48	96.99	91.48%	94.15
7	加热器	159	96.86	95.65	96.86	96.25
8	荧光灯	211	97.16	96.70	97.16	96.93
9	白炽灯	189	96.83	95.31	96.83	96.06
10	微波炉	243	98.35	97.55	98.35	97.95
11	电风扇	217	98.16	96.38	98.16	97.26

能变化,如表 2 所示。

从表 2 可以看出,基准 MobileNet V3 模型负荷识别的准确率、精确率、召回率、F1 分数分别为 86.7%、87.3%、86.2%、87.75%,数据检测结果说明其在负荷识别任务中存

Table 2 Performance changes of models in ablation experiments**表2 消融实验中模型的性能变化**

模型	数据增强	Mish(x)	CBAM	准确率/%	精确率/%	召回率/%	F1分数/%
MobileNet V3				86.7	87.3	86.2	87.75
MobileNet V3 + A	✓			93.8	92.4	91.3	91.85
MobileNet V3 + A+B	✓	✓		94.7	94.1	91.7	92.88
MobileNet V3+A+B+C(ours)	✓	✓	✓	96.8	95.3	96.4	95.85

在一定的局限性;基准 MobileNet V3+数据增强模型负荷识别的准确率、精确率、召回率、F1 分数分别为 93.8%、92.4%、91.3%、91.85%,数据检测结果表明,相比原始一维电流时序数据,经 GADF 算法生成并经过预处理的二维负荷图像更适合卷积神经网络进行处理,能较大幅度提高负荷识别性能;基准 MobileNet V3+数据增强+Mish(x)激活函数模型负荷识别的准确率、精确率、召回率、F1 分数分别为 94.7%、94.1%、91.7%、92.88%,表明 Mish(x)相比 H-Swish(x)激活函数能更好地优化深层卷积层;基准 MobileNet V3+数据增强+Mish(x)激活函数+CBAM 机制模型负荷识别的准确率、精确率、召回率、F1 分数分别为 96.8%、95.3%、96.4%、95.85%,表明采用 CBAM 机制能更好地识别空间和通道输入特征,提高负荷识别准确率。根据消融实验的结果分析,各改进模块能够有效地协同工作,提高 MobileNet V3 模型的负荷识别性能。

3.5 改进 MobileNet V3 模型实验结果

基准 MobileNet V3 模型和改进 MobileNet V3 模型在 PLAID 与 WHITED 数据集上的训练过程如图 9 所示。改进 MobileNet V3 负荷识别的准确率均高于基准 MobileNet V3 模型,在训练 40 次左右准确率趋于稳定。其中,在 PLAID 数据集上的准确率达到 96.8%,相比基准 MobileNet V3 模型提升了 10.1%,在 WHITED 数据集上的准确率达到 94.5%,相比基准 MobileNet V3 模型提升了 10.4%。从检测结果来看,本文方法在 PLAID 和 WHITED 数据集上的识别效果良好,证明了其有效性。

本文设计实验对改进后的 MobileNet V3 模型与基准 MobileNet V3 模型的准确率、参数量和计算量进行比较,在




Fig. 9 Experimental results of baseline MobileNet V3 and improved MobileNet V3 on public datasets

图9 基准 MobileNet V3 与改进 MobileNet V3 的公共数据集实验结果

实验中采用两个典型的模型权重乘数: {1.0, 0.75}, 计算量采用乘加累积操作数 (Multiply - Accumulate Operations, MACs) 来衡量, 结果如表 3 所示。

Table 3 Performance comparison of various models**表3 各模型性能比较**

模型	数据集	准确率/%	参数量/M	计算量 MACs/M
基准 MobileNet V3-1.0	PLAID/WHITED	86.7/84.1	5.48	221.73
基准 MobileNet V3-0.75	PLAID/WHITED	83.9/81.3	4.06	153.15
改进 MobileNet V3-1.0	PLAID/WHITED	96.8/94.5	5.48	226.32
改进 MobileNet V3-0.75	PLAID/WHITED	94.7/92.6	4.07	156.98

从表 3 可以看出,在 1.0 模型权重参数下,改进的 MobileNet V3 模型参数量基本不变,计算量仅增加了 2.07%,在 PLAID 与 WHITED 数据集上的准确率可分别提升 10.1% 和 10.8%;在 0.75 模型权重参数下,改进的 MobileNet V3 模型参数量基本不变,计算量仅增加了 2.50%,在 PLAID 与 WHITED 数据集上的准确率可分别提升 10.8% 和 11.3%。根据实验结果可以推断,改进的 MobileNet V3 模型能在维持原模型轻量化的基础上,大幅提升负荷识别的准确率。

4 结语

针对目前非侵入式负荷识别算法存在的参数量大、计算需求高、负荷识别性能差等问题,本文提出一种基于改进 MobileNet V3 的负荷识别算法,并在 PLAID 和 WHITED 高频数据集上进行了实验验证。实验结果表明,改进后的 MobileNet V3 算法在参数量基本不变、计算量仅增加 2.07% 的情况下,在 PLAID 与 WHITED 数据集上的准确率可分别达到 96.8% 和 94.5%,展示了其在非侵入式负荷监测 (NILM) 中良好的应用前景。未来的研究工作将对模型作进一步的轻量化改进,通过模型剪枝、知识蒸馏等技术进一步减少模型参数,降低模型对边缘设备计算能力的要求。

参考文献:

- [1] MAHMOUD S, INAS K, NADIA D, et al. Economic growth and renewable and non-renewable energy consumption: evidence from the U. S. states[J]. Renewable Energy, 2021, 178: 50-65.
- [2] HU A G. China's goal of achieving carbon peak by 2030 and its main ways[J]. Journal of Beijing University of Technology (Social Sciences Edition), 2021, 21(3): 1-15.
胡鞍钢. 中国实现 2030 年前碳达峰目标及主要途径[J]. 北京工业大学学报(社会科学版), 2021, 21(3): 1-15.
- [3] RIDI A, GISLER C, HENNEBERT J. A survey on intrusive load monitoring for appliance recognition[C]// 2014 22nd International Conference on Pattern Recognition, 2014: 3702-3707.
- [4] VINE D, BUYS L, LEWIS J, et al. Application of a Bayesian network

- complex system model examining the importance of customer-industry engagement to peak electricity demand reduction[J]. *Open Journal of Energy Efficiency*, 2016, 5(2): 31-47.
- [5] ZHAO W R. Application of computer vision technology in power system automation[J]. *Electronic Technology*, 2025, 54(2): 310-311.
赵威瑞. 计算机视觉技术在电力系统自动化中的应用[J]. *电子技术*, 2025, 54(2): 310-311.
- [6] WU Z, GAN H Q. Review of research on the assessment and regulation of the demand side resources under electricity market circumstances [J]. *Power Demand Side Management*, 2024, 26(1): 1-8.
吴争, 甘海庆. 电力市场环境需求侧资源评估与调控综述[J]. *电力需求侧管理*, 2024, 26(1): 1-8.
- [7] QIAN Y J, BAO Y Q, JIANG D Q, et al. Research advances in non-intrusive load monitoring technology [J]. *Computer & Digital Engineering*, 2023, 51(2): 380-389.
钱玉军, 包永强, 姜丹琪, 等. 非侵入式负荷监测技术研究进展[J]. *计算机与数字工程*, 2023, 51(2): 380-389.
- [8] ZOHA A, GLUHAK A, IMRAN M A, et al. Non-intrusive load monitoring approaches for disaggregated energy sensing: a survey [J]. *Sensors*, 2012, 12(12): 16838-16866.
- [9] BAO H B, YANG S H, CHEN Z M, et al. Review on event-inspection based non-intrusive load monitoring algorithms [J]. *Automation of Electric Power Systems*, 2023, 47(13): 94-109.
鲍海波, 杨舒惠, 陈子民, 等. 事件检测类非侵入式负荷监测算法综述[J]. *电力系统自动化*, 2023, 47(13): 94-109.
- [10] HART G W. Nonintrusive appliance load monitoring [J]. *Proceedings of the IEEE*, 1992, 80(12): 1870-1891.
- [11] SRINIVASAN D, NG W S, LIEW A C. Neural-network-based signature recognition for harmonic source identification [J]. *IEEE Transactions on Power Delivery*, 2006, 21(1): 398-405.
- [12] ZHAO H S, YAN X H, DAI X, et al. Quantifying flexibility of water heater participating in demand response based on non-intrusive load extracting algorithm [J]. *Automation of Electric Power Systems*, 2020, 44(3): 98-104.
赵洪山, 闫西慧, 戴湘, 等. 基于NILE算法量化热水器参与需求响应的灵活性[J]. *电力系统自动化*, 2020, 44(3): 98-104.
- [13] PICCIAILLI V, SUDOSO A M. Improving non-intrusive load disaggregation through an attention-based deep neural network [J]. *Energies*, 2021, 14(4): 847-856.
- [14] FENG J, LI K, ZHANG H, et al. Multichannel spatio-temporal feature fusion method for NILM [J]. *IEEE Transactions on Industrial Informatics*, 2022, 18(12): 8735-8744.
- [15] CUI H Y, CAI J, CHEN L, et al. Non-intrusive load fine-grained identification based on color encoding [J]. *Power System Technology*, 2022, 46(4): 1557-1567.
崔昊杨, 蔡杰, 陈磊, 等. 基于颜色编码的非侵入式负荷细粒度识别方法[J]. *电网技术*, 2022, 46(4): 1557-1567.
- [16] LI S K, ZHAO S, ZAI Z P. Lightweight non-intrusive load recognition method based on improved mobileNetV3 [J]. *Journal of Wenzhou University (Natural Science Edition)*, 2025, 46(4): 55-63.
李淑康, 赵升, 宰州鹏. 基于改进 MobileNetV3 的轻量化非侵入式负荷识别方法研究[J]. *温州大学学报 (自然科学版)*, 2025, 46(4): 55-63.
- [17] HOWARD A, SANDLER M, CHEN B, et al. Searching for MobileNetV3 [C]// 2019 IEEE/CVF International Conference on Computer Vision, 2019: 1314-1324.
- [18] ZHAO L, WANG L. A new lightweight network based on MobileNetV3 [J]. *KSII Transactions on Internet and Information Systems*, 2022, 16(1): 1-15.
- [19] WANG Z, OATES T. Imaging time-series to improve classification and imputation [C]// The 24th International Joint Conference on Artificial Intelligence, 2015: 3939-3945.
- [20] WANG J M, FAN Y Y, LI Z H. Texture image recognition based on deep convolutional neural network and transfer learning [J]. *Journal of Computer-aided Design & Computer Graphics*, 2022, 3(5): 701-710.
王军敏, 樊养余, 李祖贺. 基于深度卷积神经网络和迁移学习的纹理图像识别[J]. *计算机辅助设计与图形学学报*, 2022, 3(5): 701-710.
- [21] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module [C]// Proceedings of the European Conference on Computer Vision, 2018: 3-19.
- [22] CHEN J F, WANG X, ZHANG X T. Non-intrusive load recognition using color encoding in edge computing [J]. *Chinese Journal of Scientific Instrument*, 2020, 41(9): 12-19.
陈军锋, 王雪, 张效天. 非侵入式负荷识别边缘计算颜色编码研究[J]. *仪器仪表学报*, 2020, 41(9): 12-19.

(责任编辑: 黄健)