

基于图像分类网络的非侵入式负荷辨识算法的 运算成本优化

杨舒惠,黎静华,韦善阳

(广西大学 广西电力系统最优化与节能技术重点实验室,广西 南宁 530004)

摘要:目前基于图像分类网络的非侵入式负荷辨识算法可达到较高的辨识准确率,但存在较严重的参数冗余,引发了不必要的运算成本。对此类算法的运算成本进行优化,提出一种基于灰色编码的设备特征组合方法,以减少算法中设备特征的参数冗余;然后使用轻量级图像分类网络ZFNet构建设备辨识模型,并引入Inception模块来减少模型中卷积层输出的参数冗余,同时基于仿真实验结果对模型中全连接层的结构和参数进行适应性调整,以减少模型的参数冗余,最后使用PLAID数据集进行算例分析。结果表明:相比于同类算法,所提算法在设备特征的参数量上减少了66.7%~67.5%,在模型的参数量上减少了90%~97.1%,在整体运算量上的变动为-91.7%~6.1%。

关键词:非侵入式负荷监测;图像分类网络;灰度图;特征组合;设备辨识

中图分类号:TM714

文献标志码:A

DOI:10.16081/j.epae.202303045

0 引言

近年来,数字电网技术在电网低碳转型中的作用日益显现,其中,传感量测是基础和重要的环节之一^[1-2]。非侵入式负荷监测(non-intrusive load monitoring, NILM)是一种微型化的传感量测方法,从原理上概述,NILM包括分解和辨识2个步骤,分解是指从区域总电压、电流数据中分解得到设备的电压、电流数据;辨识是指通过对设备电压、电流数据的特征提取,辨识出设备的名称,这一过程也称非侵入式负荷辨识^[3]。NILM的结果可为用电行为分析、需求响应潜力评估等技术提供数据基础,也能为用电模式的优化提供参考^[4]。

目前,基于图像分类网络的非侵入式负荷辨识算法可达到较高的准确率,是重要的研究方向之一,此类算法的框架可归纳为特征值的标准化处理、组合特征图的构造、基于图像分类网络的设备辨识模型建模3大步骤。例如文献[5]和文献[6]都以设备样本的视在功率为基准,对该样本的有功或无功功率进行标准化;然后分别使用RGB彩色编码算法和HSV彩色编码算法构造组合特征图;最后基于AlexNet图像分类网络实现设备辨识。但上述标准化处理方法改变了特征的种类,实质上,功率特征并未在设备辨识中发挥作用,影响辨识的准确性。为了改进这一不足,文献[7]以瞬时功率在全部设备样本上的最值为基准,对其进行标准化;然后使用RGB

彩色编码算法构造组合特征,最后基于VGG-16图像分类网络实现设备辨识。但这一特征标准化方法中基准参数的计算复杂,需考虑所有设备的所有运行状态,且要求计算结果必须精确,效率较低。

另外,以上文献所提方法都存在着参数冗余的问题:一是由于彩色编码算法的不足,设备组合特征存在参数冗余;二是由于图像分类网络的参数冗余,以上文献虽然都对原始的图像分类网络进行了优化,但仅限于网络的全连接层,且在优化方法上不具备理论支撑,参数冗余的改善效果不佳。算法的参数冗余将引发不必要的运算成本,不利于算法在工程上的规模化应用^[8]。

本文针对基于图像分类网络的非侵入式负荷辨识,提出了一种运算成本优化算法。一方面,设计了一种新的非线性函数来实现特征的标准化,该方法中的基准参数可凭经验估计得到,效率更高、可操作性更强。另一方面,从设备特征和辨识模型2个角度减少算法的参数冗余:①提出了一种基于灰色编码的特征组合方法,以减少特征的参数冗余;②基于图像分类网络ZFNet构建设备辨识模型,并引入Inception模块来减少模型卷积层输出的参数冗余,同时基于仿真实验结果调整模型全连接层的结构,以减少模型的参数冗余。最后,使用PLAID数据集对本文所提算法的运算成本优化效果进行测试。

1 设备特征标准化方法

从数据的角度,设备特征可分为一维特征和二维特征,例如有功、无功功率等属于一维特征,而V-I轨迹属于二维特征,是一张图像。由于维度不同,一维特征和二维特征不能直接组合,一般通过将一维

收稿日期:2022-12-15;修回日期:2023-02-28

在线出版日期:2023-04-03

基金项目:国家自然科学基金资助项目(51977042)

Project supported by the National Natural Science Foundation of China(51977042)

特征赋值给二维特征中某一位置的像素参数,实现特征的组合。当一维特征的取值范围与像素参数的取值范围相同时,可直接进行赋值操作;否则为了能够进行赋值操作,就需要对一维特征的值域进行调整,即特征标准化。

对取值范围有界的特征,标准化只需线性缩放即可;对取值范围无界的特征,本文设计了一种非线性函数来实现特征标准化。以本文中组合的功率特征为例易知,虽然理论上功率的取值范围为无界区间,但实际中,考虑设备的经济性和安全性,存在一个涵盖绝大部分设备功率取值的有界子区间。对于该子区间内的特征,可进行线性映射,以保持特征分布特性;对于区间以外的功率,可基于指数函数设计非线性映射,从而将无界的特征值域映射到像素参数的取值范围 $[0, 1]$ 中。

特征标准化函数的表达式如式(1)、(2)所示。

$$P' = \begin{cases} \frac{n-\alpha}{p_1} P & 0 \leq P \leq p_1 \\ n - \alpha e^{-\alpha(P-p_1)} & P > p_1 \end{cases} \quad (1)$$

$$Q' = \begin{cases} \alpha e^{\alpha(Q-q_1)} & Q < q_1 \\ \frac{(n-\alpha)-\alpha}{q_2-q_1} Q + \frac{(n-\alpha)q_1-\alpha q_2}{q_1-q_2} & q_1 \leq Q \leq q_2 \\ n - \alpha e^{-\alpha(Q-q_2)} & Q > q_2 \end{cases} \quad (2)$$

式中: P 和 Q 分别为有功、无功功率的计算值; P' 和 Q' 分别为有功、无功功率的标准化值; $[0, p_1]$ 表示有功功率的有界子区间; $[q_1, q_2]$ 表示无功功率的有界子区间; $[0, n]$ 表示像素参数的取值范围,本文取为 $[0, 1]$; α 为 $[0, 1]$ 范围内用于非线性映射的子区间长度。

本文中, α 取为0.05, $[0, p_1]$ 和 $[q_1, q_2]$ 分别取为 $[0, 2000]$ W和 $[-300, 150]$ var,有功、无功功率的标准化函数分别如图1、2所示。

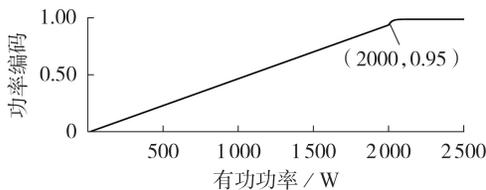


图1 有功功率的标准化函数

Fig.1 Normalized function of active power

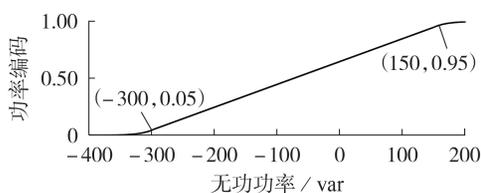


图2 无功功率的标准化函数

Fig.2 Normalized function of reactive power

图1和图2中的参数取值为样本功率分布的统计分析结果,即将功率按大小顺序排列后,取距首、尾5%的数值,再就近取整所得。样本来自NILM公开数据集PLAID,并排除了下文中的设备辨识模型测试样本,以保障测试结果的可靠性。

2 基于灰色编码的设备组合特征构造方法

2.1 基本原理

本文提出一种基于灰色编码的组合特征构造方法,对设备的暂态 $V-I$ 轨迹、稳态 $V-I$ 轨迹、稳态有功和无功功率进行组合。 $V-I$ 轨迹是一种准确率较高的设备特征,但不能反映设备的功率,故使用 $V-I$ 轨迹与功率的组合来构造组合特征^[9]。特征组合方法的示意图如图3所示。图中: P' 、 Q' 分别为有功、无功功率标准化值。

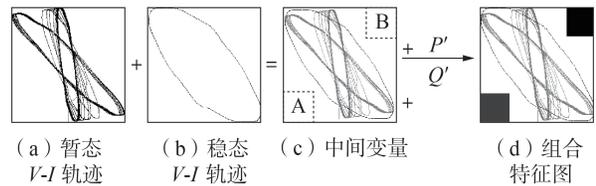


图3 基于灰色编码的特征组合方法

Fig.3 Feature combination method based on gray coding

由图3可见:图像数据本质上为矩阵,暂态 $V-I$ 轨迹图(图3(a))和稳态 $V-I$ 轨迹图(图3(b))可通过矩阵点乘合成一张轨迹图(图3(c)),暂态和稳态 $V-I$ 轨迹上像素点的参数值分别被赋值为0.5和0,以示区别。将有功、无功功率的标准化值分别赋给图3(c)中区域A、B的像素参数,即可得到组合特征图。

注意到图3(c)中轨迹的位置集中在主对角线附近,区域A、B中没有轨迹图像。对 $V-I$ 轨迹图中轨迹位置的物理意义进行分析,如图4所示。

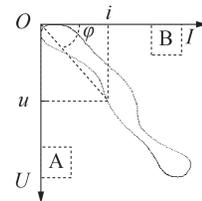


图4 $V-I$ 轨迹分析结果

Fig.4 Analytical results of $V-I$ trajectory

由图4可见, $V-I$ 轨迹是指以设备一定运行时段内的电流、电压值分别为横、纵坐标的点所组成的曲线,图4中的变量满足关系式(3)、(4)。

$$\tan \varphi = u/i = |z| \quad (3)$$

$$\varphi: 0^\circ \rightarrow 90^\circ, z: 0 \rightarrow +\infty(\Omega) \quad (4)$$

式中: u 和 i 分别为电压、电流采样值; z 和 φ 分别为设备阻抗和阻抗角。

易知,图4中区域A、B分别对应设备阻抗接近 ∞ 和接近0的运行状态,实际中,设备处于此类运行状态的概率较小,即区域A、B中出现V-I轨迹曲线的概率较小。这些位置的像素点的参数值不包含V-I轨迹的特征信息,属于冗余参数。因此,使用有功、无功功率的标准化值对其进行赋值替换,以减少设备特征的参数冗余。

2.2 方法步骤

本文所提设备组合特征构造方法的步骤如下。

1) 计算设备的有功功率和无功功率^[10]。

2) 按照第1章的方法,计算功率的标准化值;

3) 构造设备的暂态、稳态V-I轨迹。由于V-I轨迹在构造过程中已进行了类似标准化的处理,本文不再对其进行标准化操作。V-I轨迹构造方法见文献[11],所需数据的采样时段分别为完整的暂态运行时段和一个周期的稳态运行时段。

4) 按照2.1节方法,生成组合特征图。PLAID数据集中设备特征图的示例如图5所示。

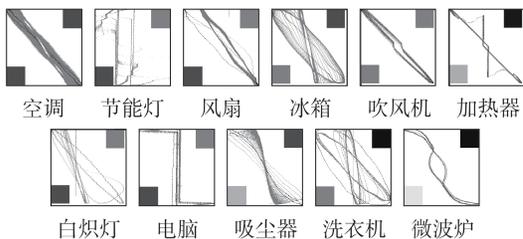


图5 设备组合特征图示例

Fig.5 Examples of combination feature image of devices

本文中,特征图的分辨率为 224×224 ,由于使用了轨迹图像更为复杂的暂态V-I轨迹作为特征之一,高分辨率的特征图虽然参数量更大,但可以反映更多的V-I轨迹的细节信息,特征的准确性更高,有利于设备的辨识。

3 基于ZFNet-Inception的设备辨识模型建模方法

3.1 模型结构和参数

设备特征的数据格式为图像,适合使用图像分类网络对设备特征进行分类,实现设备辨识。相比于图像分类网络最初的应用对象,设备特征图的构成更简单,可以选择轻量级的图像分类网络,例如LeNet^[12]、AlexNet^[13]、ZFNet^[14]等,以减少运算成本和模型训练的过拟合。其中:LeNet的层数过少,其准确率较低;ZFNet相比AlexNet的网络性能更优。

综合考虑设备辨识模型的准确率和运算成本,本文基于ZFNet构建设备辨识模型,模型结构和参数见附录A图A1。模型主要包括卷积层和全连接层2类结构,前者的作用是对输入图像进行特征提

取;后者的作用是构造分界面,最终实现对特征的分辨。

相比于原始的ZFNet模型,本文所提模型在结构和参数上的主要调整如下。

1) 在卷积层中引入Inception模块的 1×1 卷积结构,Inception模块的结构如图6所示。图中:“ 1×1 ”“ 3×3 ”“ 5×5 ”表示卷积核的大小。

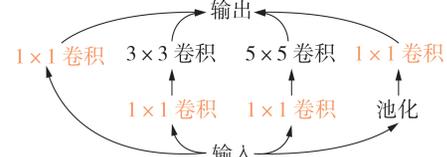


图6 Inception 模块

Fig.6 Inception module

本文将Inception模块中的 1×1 卷积结构引入设备辨识模型中。 1×1 卷积的作用是对前一层的输出进行压缩。每层卷积在进行特征提取后,都会产生多个输出,但并不是每个输出都包含有效的信息,即卷积的输出具有稀疏性^[15]。通过 1×1 卷积对其进行压缩,可以减少后层卷积在对前层输出进行运算时的运算量。

除此之外,Inception模块中还包含由多个大小不同的卷积核组成的并联卷积结构。这一结构可使网络具备更强的分类能力,但其在简单图像的分类任务中的效果并不明显,反而会增加模型的运算成本和过拟合的概率,故在本文所提模型中并未使用。

2) 对全连接层进行精简。

本节通过实验对ZFNet全连接层的结构和参数进行优化。实验一共设置6组对比实验,第1组的模型为ZFNet,第2—6组模型的卷积层与第1组模型相同,而全连接层的参数量递减。使用各模型对设备组合特征图进行辨识,模型的参数量和辨识准确率如表1所示。

表1 ZFNet全连接层优化实验中各模型的参数和性能

Table 1 Parameters and performance of each model in ZFNet fully connected layer optimization experiment

模型	全连接层		模型参数量	准确率 / %	
	层数	神经元数量			
1	3	4096, 4096, 11	4.30×10^7	4.68×10^7	94.2
2	2	4096, 11	2.62×10^7	3.00×10^7	95.6
3	2	2048, 11	1.31×10^7	1.68×10^7	95.1
4	2	1024, 11	6.60×10^6	1.03×10^7	94.2
5	2	512, 11	3.30×10^6	7.00×10^6	95.1
6	1	11	7.00×10^5	3.80×10^6	96.7

由表1可知:随着全连接层参数量的减少,1—5号设备辨识模型在辨识准确率上的波动小于1.4%,6号模型的准确率最高;1—5号模型皆存在参数冗余,6号模型的全连接层结构和参数设计最优。

3)增加 Dropout层和批归一化层。

Dropout层和批归一化层的作用都是减少模型训练的过拟合,批归一化层还能加快网络的收敛速度^[16]。

3.2 模型训练

本文中,设备辨识模型的训练使用交叉熵损失函数,模型参数优化算法为自适应随机梯度下降算法;初始学习率为0.01,每经过4轮训练降低学习率为现有学习率的50%,一共训练10轮。

4 算例分析

4.1 算法仿真流程与数据集划分

算法仿真分析使用的是NILM领域公开数据集PLAID^[17],其中包括空调、洗衣机等11类常见家电的运行电压、电流数据共1823组。在每类设备的样本集中随机抽取20%的数据构成模型测试集,剩余数据为模型训练集。算法仿真流程如图7所示。

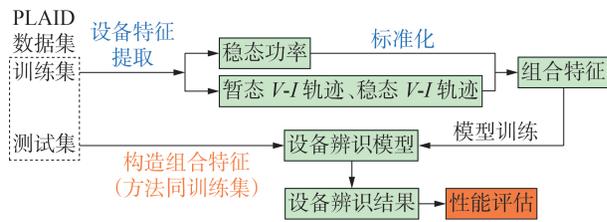


图7 算法仿真流程

Fig.7 Flow of algorithm simulation

4.2 评价指标

1)设备辨识准确率。

设备辨识准确率指被正确辨识的样本数占总测试样本数的比例,计算公式如式(5)所示。

$$k_{\text{acc}} = \frac{1}{M} \sum_{i=1}^T m_i \quad (5)$$

式中: m_i 为第*t*类设备的测试样本中被正确辨识的样本数; T 为设备种类数; M 为总测试样本数。

2)运算成本。

本文使用参数量和运算量来衡量算法的运算成本。其中:参数量分为设备特征的参数量和模型的参数量;运算量为数据从模型输入到输出的单次传递过程中乘法运算的总数。参数量与运算量具有一定的正相关关系,而运算量越大,显然算法的运算成本就越高。

4.3 仿真结果与对比分析

使用混淆矩阵对测试集样本的设备辨识结果进行整理,结果如图8所示。图中:主对角线上的数值表示被正确辨识的样本数;其他位置的数值表示被错误辨识为相应设备的样本数,体现了辨识时2类设备相互混淆的情况。根据混淆矩阵可以方便地计算出各类设备的辨识准确率,如表2所示。

辨识结果	空调	节能灯	风扇	冰箱	吹风机	加热器	白炽灯	微波炉	洗衣机	吸尘器
空调	39.2	0	0.6	1.0	0	0	0	0	0	0
节能灯	0	45.4	0	0	0	0	0	0	0	0
风扇	1.2	0	43.2	1.0	0.4	0	0.6	0	0.2	0
冰箱	0	0	0.2	18.6	0	0	0	0	0.4	0
吹风机	0.2	0	0	0	47.6	1.2	0	0	0	0
加热器	0	0	0	0	1.0	15.8	0	0	0	0
白炽灯	0.4	0	0	0.4	0	0	30.4	0	0	0
微波炉	0	0.6	0	0	0	0	0	42.4	0	0
吸尘器	0	0	0	0	0	0	0	0.2	39.4	0
洗衣机	0	0	0	0	0	0	0	0	0	17.0
	0	0	0	0	0	0	0	0.4	0	0

真实类别
空调 风扇 吹风机 白炽灯 微波炉 洗衣机
节能灯 冰箱 加热器 电脑 吸尘器

图8 设备辨识结果的混淆矩阵的平均值

Fig.8 Mean value of confusion matrix of device identification results

表2 本文所提算法的辨识准确率

Table 2 Identification accuracy of proposed algorithm

设备	准确率 / %	设备	准确率 / %
空调	95.6	白炽灯	98.1
节能灯	98.7	电脑	98.6
风扇	98.2	微波炉	98.5
冰箱	88.6	吸尘器	100
吹风机	97.2	洗衣机	85.3
加热器	92.9		

综合图8和表2可知,本文所提算法对多数设备的辨识准确率可达95%~100%,在全体测试样本上的辨识准确率总体为96.7%,仅冰箱和洗衣机的辨识准确率与平均水平相差较远,分别为88.6%和85.3%。究其原因:一是PLAID数据集中冰箱和洗衣机的样本数相对少,设备辨识模型未能充分学习到这2类设备的特征;二是这2类设备的运行状态更多变,设备特征更多样、复杂,辨识难度更高。

为了测试本文所提算法的性能,分别控制设备特征和辨识模型这两项变量进行仿真对比实验,如表3所示。保持测试数据抽取和模型训练方法相同,各实验组的准确率和运算量如表4所示,详细数据见附录A表A1。

表3 对照实验的方案

Table 3 Scheme of controlled experiment

特征	构成	标准化方法	组合方法
1	稳态V-I轨迹	无需标准化	无
2	稳态V-I轨迹、有功和无功	以最值为基准值进行标准化	彩色编码
3 (本文方法)	稳态V-I轨迹、有功和无功	本文所提方法(式(1)、(2))	灰色编码
模型	AlexNet、ZFNet、GoogLeNet、本文所提模型		

表4中的数据兼具纵向对比和横向对比的功能。

1)纵向对比相同模型下不同特征的辨识效果,特征1—3分别为稳态V-I轨迹、彩色编码和本文所

表 4 对照实验的结果

Table 4 Results of controlled experiment

特征	特征 参数量	准确率 / %				运算量			
		AlexNet	ZFNet	GoogLeNet	本文模型	AlexNet	ZFNet	GoogLeNet	本文模型
1	50 176	90.6	92.3	88.0	92.3	1.6×10^9	2.4×10^9	1.6×10^9	1.3×10^9
2	150 528	91.8	93.7	88.4	94.2	2.8×10^9	2.8×10^9	1.9×10^9	1.6×10^9
3	50 176	92.3	94.5	87.8	94.5	1.6×10^9	2.4×10^9	1.6×10^9	1.3×10^9

提灰色编码特征。由表 4 中数据可知,在 AlexNet、ZFNet、GoogLeNet 和本文所提模型上,灰色编码特征和彩色编码特征的辨识准确率的相差值皆小于 1%。理论上分析,设备辨识准确率主要取决于不同类设备之间特征的差异性(可区分性)和辨识模型的准确性,灰色编码和彩色编码所组合的特征是一致的,只是在组合方法上有所区别,且 2 种组合方法都没有改变特征的差异性(可区分性),故两者对设备辨识准确率的贡献也应是相当的。在特征的参数量上,灰色编码相比彩色编码减少 66.7%;在模型的运算量上,灰色编码相比彩色编码减少了 14.3%~42.8%。可知,灰色编码能有效减少特征占据的存储空间和设备辨识模型处理特征时的运算成本,且对辨识准确率的影响较小。

2) 横向对比相同特征下不同模型的辨识效果,分别使用 AlexNet、ZFNet、GoogLeNet 和本文所提模型对特征 1—3 进行辨识。根据表 4 中数据可知,本文模型的运算量相比 AlexNet 减少了 18.7%~42.8%,相比 ZFNet 减少了 42.8%~45.8%,相比 GoogLeNet 减少了 15.8%~18.7%,可知本文所提模型的运算成本更低。

将本文所提算法与近年的同类非侵入式负荷辨识算法的准确率、参数量和运算量进行对比分析,如表 5 所示,详细数据见附录 A 表 A2。表 5 中数据为在同等的测试数据抽取和模型训练条件下,对各文献所提方法的原理进行复现仿真所得,可能与部分文献的实验条件不一致。

表 5 同类算法的对比分析

Table 5 Comparative analysis of similar algorithms

算法	特征组 合方法	设备辨识 模型	参数量		运算量	准确 率 / %
			特征	模型		
文献 [7]	彩色 编码	VGG-16	150 528	1.71×10^7	1.5349×10^{10}	87.1
文献 [5]	彩色 编码	AlexNet	154 587	4.62×10^7	1.2045×10^9	92.4
文献 [6]	彩色 编码	AlexNet	154 587	5.83×10^7	2.8215×10^9	94.6
本文	灰色 编码	本文模型	50 176	1.70×10^6	1.2785×10^9	96.7

根据表 5 中数据可知,相比于同类算法,本文所提算法在保持较高的设备辨识准确率的同时,在特征的参数量上减少了 66.7%~67.5%,在模型的参数量上减少了 90%~97.1%,在整体运算量上的变动为

-91.7%~6.1%。由此可知,本文所提算法的参数冗余更少,运算成本更低。

5 结论

本文提出一种运算成本优化的非侵入式负荷辨识算法:在设备特征上,建立一种基于灰色编码的组合特征构造方法;在设备辨识模型上,基于图像分类网络 ZFNet 构建设备辨识模型,并通过引入 1×1 卷积结构和实验分析,对原 ZFNet 模型的结构和参数进行了优化设计。经过算例分析可证实:所提方法在保障较高的设备辨识准确率的同时,可有效减少算法的参数冗余,降低算法的运算成本。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] 李鹏, 习伟, 蔡田田, 等. 数字电网的理念、架构与关键技术[J]. 中国电机工程学报, 2022, 42(14): 5002-5017.
LI Peng, XI Wei, CAI Tiantian, et al. Concept, architecture and key technologies of digital power grids[J]. Proceedings of the CSEE, 2022, 42(14): 5002-5017.
- [2] 王云静, 邢奥岚, 曲正伟, 等. 基于 AMI 全量测点分区的配电网动态状态估计方法[J/OL]. 电力自动化设备. [2022-12-14]. <https://doi.org/10.16081/j.epae.202204049>.
- [3] 郭红霞, 陆进威, 杨苹, 等. 非侵入式负荷监测关键技术问题研究综述[J]. 电力自动化设备, 2021, 41(1): 135-146.
GUO Hongxia, LU Jinwei, YANG Ping, et al. Review on key techniques of non-intrusive load monitoring[J]. Electric Power Automation Equipment, 2021, 41(1): 135-146.
- [4] 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.
ZHAO Hongshan, YAN Xihui, DAI Xiang, 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.
- [5] 解洋, 梅飞, 郑建勇, 等. 基于 V-I 轨迹颜色编码的非侵入式负荷识别方法[J]. 电力系统自动化, 2022, 46(4): 93-102.
XIE Yang, MEI Fei, ZHENG Jianyong, et al. Non-intrusive load monitoring method based on V-I trajectory color coding[J]. Automation of Electric Power Systems, 2022, 46(4): 93-102.
- [6] LIU Yanchi, WANG Xue, YOU Wei. Non-Intrusive load monitoring by voltage-current trajectory enabled transfer learning[J]. IEEE Transactions on Smart Grid, 2019, 10(5): 5609-5619.
- [7] 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.
CUI Haoyang, CAI Jie, CHEN Lei, et al. Non-intrusive load fine-grained identification method based on color encoding[J]. Power System Technology, 2022, 46(4): 1557-1567.
- [8] 邓晓平, 张桂青, 魏庆来, 等. 非侵入式负荷监测综述[J]. 自

- 动化学报,2022,48(3):644-663.
- DENG Xiaoping,ZHANG Guiqing,WEI Qinglai, et al. A survey on the non-intrusive load monitoring[J]. Acta Automatica Sinica,2022,48(3):644-663.
- [9] DU Liang, HE Dawei, HARLEY R G, et al. Electric load classification by binary voltage-current trajectory mapping[J]. IEEE Transactions on Smart Grid,2016,7(1):358-365.
- [10] TIAN Chunwei, ZHANG QI, SUN Guanglu, et al. FFT consolidated sparse and collaborative representation for image classification[J]. Arabian Journal for Science and Engineering,2018,43(2):741-758.
- [11] 王守相,郭陆阳,陈海文,等. 基于特征融合与深度学习的非侵入式负荷辨识算法[J]. 电力系统自动化,2020,44(9):103-110.
- WANG Shouxiang, GUO Luyang, CHEN Haiwen, et al. Non-intrusive load identification algorithm based on feature fusion and deep learning[J]. Automation of Electric Power Systems,2020,44(9):103-110.
- [12] 丁昊,杨乐,石鸿凌,等. 利用数据可视化实现智能非侵入式负荷辨识[J]. 华中科技大学学报(自然科学版),2021,49(10):85-90.
- DING Hao, YANG Le, SHI Hongling, et al. Realize intelligent non-intrusive load identification by using data visualization [J]. Journal of Huazhong University of Science and Technology(Natural Science Edition),2021,49(10):85-90.
- [13] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM,2017,60(6):84-90.
- [14] ZEILER M D, FERGUS R. Visualizing and understanding convolutional networks[C]//European Conference on Computer Vision. Zurich, Switzerland:Springer,2014:818-833.
- [15] SZEGEDY C, LIU W, JIA Y Q, et al. Going deeper with convolutions[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition[J]. Boston, MA, USA:IEEE,2015:1-9.
- [16] IOFFE S, SZEGEDY C. Batch normalization:accelerating deep network training by reducing internal covariate shift [C]// International Conference on Machine Learning. Lille, France: PMLR,2015:448-456.
- [17] MEDICO R, LEEN D B, JINGKUN G, et al. A voltage and current measurement dataset for plug load appliance identification in households[J]. Scientific Data,2020,7(1):1-10.

作者简介:

杨舒惠(1998—),女,硕士研究生,主要研究方向为非侵入式负荷监测算法(**E-mail**:897150016@qq.com);

黎静华(1982—),女,教授,博士,主要研究方向为电力系统优化运行与控制、大规模可再生能源并网技术等(**E-mail**:lijinghua@gxu.edu.cn);

韦善阳(1993—),男,博士,主要研究方向为广义负荷特性分析(**E-mail**:shanyangwei@gxu.edu.cn)。

(编辑 任思思)

Computational cost optimization of non-intrusive load identification algorithm based on image classification network

YANG Shuhui, LI Jinghua, WEI Shanyang

(Guangxi Key Laboratory of Power System Optimization and Energy Technology, Guangxi University, Nanning 530004, China)

Abstract: At present, the non-intrusive load identification algorithm based on image classification network can achieve high identification accuracy, but there is serious parameter redundancy, which leads to unnecessary calculation costs. The computational cost of this kind of algorithm is optimized. Firstly, a device feature combination method based on grey coding is proposed to reduce the parameter redundancy in device features. Then, the lightweight image classification network ZFNet is used to construct the device identification model, and inception submodule is introduced to reduce the parameter redundancy in the output of the convolutional layers in the model. At the same time, based on the simulative results, the structure and parameters of the fully connection layers in the model are adjusted adaptively to reduce the parameter redundancy of the model. Finally, PLAID data set is used for example analysis, and the results show that, compared with similar algorithms, the proposed algorithm reduces the parameter number of equipment features by 66.7%~67.5%, the parameter number of the model by 90%~97.1%, and the change of the overall calculation amount is -91.7%~6.1%.

Key words: non-intrusive load monitoring; image classification network; gray scale image; feature combination; device identification

附录 A

名称	参数设置
输入层	输入特征图尺寸: [224,224,1]
卷积层	卷积核: 6×6(96), 步长: 2, relu
最大池化层	卷积核: 3×3, 步长: 2
批归一化层	批归一化层
1×1卷积层	卷积核: 1×1(48), 步长: 1, relu
卷积层	卷积核: 5×5(256), 步长: 2, relu
最大池化层	卷积核: 3×3, 步长: 2
批归一化层	批归一化层
1×1卷积层	卷积核: 1×1(128), 步长: 1, relu
卷积层	卷积核: 3×3(384), 步长: 1, relu
卷积层	卷积核: 3×3(256), 步长: 1, relu
最大池化层	卷积核: 3×3, 步长: 2
Dropout层	Dropout Probability: 0.5
全连接层 (输出层)	神经元数量: 11

图 A1 设备辨识模型

Fig.A1 Device identification model

表 A1 对照实验的结果

Table A1 Results of controlled experiment

设备特征编号		1	2	3	Δ_{23}
特征的参数量		50,176	150,528	50,176	-66.7%
准确率/%	AlexNet	90.6	91.8	92.3	+0.5
	ZFNet	92.3	93.7	94.5	+0.8
	GoogLeNet	88.0	88.4	87.8	-0.6
	本文	92.3	94.2	94.5	+0.3
运算量 ($\times 10^9$)	AlexNet	1.6	2.8	1.6	-42.8%
	ZFNet	2.4	2.8	2.4	-14.3%
	GoogLeNet	1.6	1.9	1.6	-15.8%
	本文	1.3	1.6	1.3	-18.7%
本文模型的 运算量优化效果	对比 AlexNet	-18.7%	-42.8%	-18.7%	
	对比 ZFNet	-45.8%	-42.8%	-45.8%	
	对比 GoogLeNet	-18.7%	-15.8%	-18.7%	

表 A2 同类算法的对比分析

Table A2 Comparative analysis of similar algorithms

算法		文献[7]	文献[5]	文献[6]	本文	
组合特征构造方法		彩色编码	彩色编码	彩色编码	灰色编码	
特征的参数量		150,528	154,587	154,587	50,176	
设备辨识模型		VGG-16	AlexNet	AlexNet	本文模型	
设备辨识准确率/%	空调	79.0	75.8	92.7	95.6	
	节能灯	100	97.0	98.3	98.7	
	风扇	75.5	95.2	93.2	98.2	
	冰箱	47.6	77.8	75.3	88.6	
	吹风机	96.3	93.2	98.8	97.2	
	加热器	71.8	92.3	96.5	92.9	
	白炽灯	96.8	93.2	97.4	98.1	
	电脑	93.5	98.4	96.7	98.6	
	微波炉	99.0	100.0	99.5	98.5	
	吸尘器	100.0	100.0	97.6	100.0	
	洗衣机	60.0	81.8	74.7	85.3	
总计		87.1	92.4	94.6	96.7	
模型参数量($\times 10^6$)		17.1	46.2	58.3	1.7	
运算量($\times 10^6$)		15,349.0	1,204.5	2,821.5	1,278.5	
本文算法的优化效果	准确率	+9.6	+4.3	+2.1		
	参数量	特征	-66.7%	-67.5%		-67.5%
		模型	-90.0%	-96.3%		-97.1%
	运算量	-91.7%	+6.1%	-54.5%		