

# 优化卷积神经网络超参数的非侵入式电力负荷识别算法

赵安军<sup>1</sup>, 赵啸<sup>1</sup>, 荆竞<sup>2\*</sup>, 席江涛<sup>1</sup>, 崔朴方<sup>1</sup>

<sup>1</sup>西安建筑科技大学信息与控制工程学院, 陕西 西安 710055;

<sup>2</sup>中国建筑西北设计研究院, 陕西 西安 710018

**摘要** 针对深度学习模型在电力负荷识别中存在的识别率不高、超参数设置等问题,提出了一种粒子群优化算法(PSO)与卷积神经网络(CNN)相结合的非侵入式电力负荷识别模型(PSO-CNN)。首先,以各电器 VI 轨迹像素化图像作为 CNN 输入;其次,分析 CNN 超参数对模型性能影响,并使用 PSO 算法寻求最优解以提升模型识别效果;最后,基于 PLAID、WHITED 公开数据集对 PSO-CNN 模型进行对比验证。实验结果表明,该模型的识别准确率、F-measures 平均值皆优于其他模型,有效降低了设备之间的混淆,具有良好的识别能力与泛化能力。

**关键词** 图像处理;非侵入式电力负荷识别;深度学习;卷积神经网络;粒子群优化算法

中图分类号 Tm714

文献标志码 A

DOI: 10.3788/LOP212374

## Non-Intrusive Electric Load Identification Algorithm for Optimizing Convolutional Neural Network Hyper-Parameters

Zhao Anjun<sup>1</sup>, Zhao Xiao<sup>1</sup>, Jing Jing<sup>2\*</sup>, Xi Jiangtao<sup>1</sup>, Cui Pufang<sup>1</sup>

<sup>1</sup>College of Information and Control Engineering, Xi'an University of Architecture and Technology, Xi'an 710055, Shaanxi, China;

<sup>2</sup>China Northwest Architecture Design and Research Institute, Xi'an 710018, Shaanxi, China

**Abstract** Aiming at the problems of low recognition rate and hyper-parameter setting of deep learning model in electric load recognition, a non-intrusive electric load recognition model (PSO-CNN) combining particle swarm optimization algorithm (PSO) and convolutional neural network (CNN) was proposed. First, the pixelated image of VI trajectory of each appliance is used as the CNN input feature. Secondly, the influence of CNN hyper-parameter on model performance was analyzed, and PSO algorithm is used to find the optimal solution to improve model recognition effect. Finally, the PLAID and WHITED public datasets were used to compare and verify the PSO-CNN model. The experimental results show that the recognition accuracy and average F-measures of this model are better than other models. The model effectively reduces the confusion between devices and has good recognition and generalization ability.

**Key words** image processing; non-intrusive electric load identification; deep learning; convolutional neural network; particle swarm optimization algorithm

## 1 引言

我国经济的快速发展使得家庭能源消费总量增加<sup>[1]</sup>。在家庭能源消耗中,如果向用户反馈其能耗详细信息,用户很可能会作出相应策略以减少能耗<sup>[2]</sup>。为监测家庭电能消耗,非侵入式负荷监测(NILM)提供了经济且有效的解决方案,通过功率、电压、电流等

丰富负荷特征,NILM 基于机器学习技术对用电总负荷进行分解及识别。

国内外学者在 NILM 领域进行了大量的研究工作。部分研究手动设计特征提取器,并将提取的特征作为模型输入进行辨识。文献[3]使用快速傅里叶变换提取设备稳态电流的谐波幅值与相位角作为负荷特征,但此特征难以识别多状态负荷。文献[4]对 VI 轨

收稿日期: 2021-08-27; 修回日期: 2021-10-22; 录用日期: 2021-11-08; 网络首发日期: 2021-12-10

基金项目: 国家重点研发计划(新型建筑智能化系统平台技术)(2017YFC0704100)

通信作者: \*xby5s@163.com

迹表现出的不对称性等 8 种形状特征进行了详细阐述,使用层次聚类方法分别与基于传统功率指标和特征向量方法进行了对比,实验结果表明,VI 轨迹的形状特征对负荷的特性具有明确含义,并具有良好的辨识能力。文献[5]计算 VI 轨迹轮廓的椭圆傅里叶描述符,并将其作为分类算法输入。文献[6]在文献[4]基础上提出跨度新特征,使用 4 种分类算法分别与电流谐波含量、有功功率、无功功率进行对比,结果均表明,VI 轨迹具有更好的识别能力。传统的手动设计特征提取器的方式虽取得较好效果,但依赖于先验知识<sup>[7]</sup>,并且设计的特征提取器可能对噪声和伪影不具有鲁棒性<sup>[8]</sup>。深度学习的快速发展为 NILM 提供了新思路。文献[9]使用 BP 神经网络、卷积神经网络(CNN)分别对功率、VI 轨迹进行特征提取、融合,并将此复合特征作为用于负荷识别的新特征。文献[10]将电流信号转换为电流图像形式,利用 CNN 进行特征提取及负荷识别。

深度神经网络可充分利用大量负荷数据样本,提取到能更好地表达输入与输出关系的特征。已有研究证明,深度学习模型性能与其超参数设置有着复杂的关系<sup>[11]</sup>,但目前没有通用有效的理论来指导超参数的设置。深度学习模型可能花费数天时间进行训练,依赖传统的实验组合方式是低效的、不彻底的,模型也可能不具有最佳识别能力。

基于 CNN 强大的提取特征能力,本文尝试使用粒子群优化算法(PSO)对其超参数进行最优查找,并建立了一种 PSO-CNN 负荷识别模型。首先通过高频采样数据提取电器 VI 轨迹,并将其转化为像素化图像作为 CNN 输入;在网络训练过程中,使用 PSO 对 CNN 主要超参数进行最优查找,并以此结果构建 PSO-CNN 模型进行负荷辨识;最后基于 PLAID、WHITE 数据集对该模型进行对比验证。

## 2 VI 轨迹像素化图像

相比其他特征,VI 轨迹特征能更好地反映家用电器负荷特性<sup>[4,6,12-13]</sup>,因此本研究选取 VI 轨迹作为模型输入。在用电设备开启后的规定时间段内,绘制其电压与电流关系曲线得到 VI 轨迹。文献[12,14]中,VI 轨迹被映射到单元网格中,网格的每个单元被分配一个二进制值表示其是否被轨迹遍历。基于该像素化的 VI 图像,提取占用单元的连续数量、左水平单元和中央单元的二进制值等特征作为分类模型的输入<sup>[12]</sup>。文献[14]中,像素化图像被重新排列成向量,直接输入分类器进行设备分类。

之前的方法将 VI 轨迹所包含的信息压缩为有限的相关统计信息,为充分利用 VI 轨迹信息,本研究对之前的方法进行了一些改进。与文献[12,14]相比,图像具有连续值而不是二进制值,具体处理步骤如下:

1) 获取设备在一定工作时段内的电压  $V$  和电

流  $I$ ;

2) 将电压、电流归一化,  $V \in [-1, 1], I \in [-1, 1]$ ;

$$v_m = \frac{V_m}{\max|V|}, \quad (1)$$

$$i_m = \frac{I_m}{\max|I|}, \quad (2)$$

式中:  $V_m, I_m$  分别表示数据中第  $m$  个采样点的电压、电流值;  $\max|V|, \max|I|$  分别为数据中电压、电流绝对值的最大值;  $v_m, i_m$  分别为第  $m$  个采样点归一化后的电压、电流值。

3) 使用归一化的数据创建 VI 轨迹;

4) 使用  $n \times n$  网格将其覆盖;

5) 遍历全部采样点,若采样点在网格单元范围内,网格单元值加 1;

6) 归一化单元格的值,使单元格的最大值为 1。

图 1 展示了冰箱与节能灯(CFL)的转换对比。

## 3 PSO-CNN 负荷识别算法

### 3.1 卷积神经网络

由于 CNN 处理图像的强大优势<sup>[15-18]</sup>,本研究建立了基于 CNN 的负荷识别模型,其网络结构如图 2 所示,该模型主要由 2 个卷积层、2 个池化层和 1 个 Dropout 层组成:用电设备像素化图像作为模型输入( $n \times n$  矩阵,  $n=50$ );卷积层用来提取输入信息特征,其与全连接层的主要区别在于卷积层中的每个节点都利用局部连接方式连接输入矩阵的部分区域,这种连接方式保证学习后的卷积核对输入的局部特征具有最强响应。感受野是 CNN 中最重要的概念之一,表示网络内部不同神经元对原图像感受范围的大小,神经元感受野的值越大,其可能蕴含了更为全局、语义层次更高的特征,卷积核大小与步长设置影响特征图内像素点的感受野,从而影响模型特征提取能力<sup>[19]</sup>。此外,其数量决定网络是否能多角度分析输入,数量太多可能会导致网络识别能力下降,并且增加网络运算量。池化层对卷积矩阵进行降维和聚合特征操作时有最大池化和平均池化等方法,但在提取特征过程中,最大池化方法会保留更多的局部细节,有利于模型对易混淆电器的识别<sup>[20]</sup>,合适的池化核大小、步长设置可以在保留数据信息的基础上降低数据计算复杂度,同时影响特征图内像素点的感受野。在网络训练时,Dropout 层通过设置阈值并与某些隐含层节点的权重对比,让特定节点不工作以加快网络运算、防止过拟合,丢失概率的随机设定可能导致模型识别性能不佳。输出层设置  $K$  个节点( $K$  为不同设备类型数量),使用 softmax 函数使节点输出值在 0~1 之间。

为使 CNN 具备识别能力,需要大量的训练数据供其学习。训练样本  $X = (X_1, X_2, \dots, X_N)$  相应标签  $t = (t_1, t_2, \dots, t_N)$ ,其中  $X_i$  是各设备 VI 轨迹像素化图像,  $t_i$




图 1 冰箱与节能灯 VI 轨迹转换示意图。(a) (b) VI 轨迹; (c) (d) 像素化图像

Fig. 1 Schematic diagrams of VI trajectories of refrigerator and compact fluorescent lamp. (a) (b) VI trajectories; (c) (d) pixelated images




图 2 CNN 模型结构图

Fig. 2 Structure diagram of CNN model

是对应标签的 one-of-K 编码。训练网络的目的是确定权重和偏差以使成本函数最小化,成本函数使用交叉熵函数<sup>[13]</sup>:

$$L = - \sum_{i=1}^N \sum_{k=1}^K t_{i,k} \log y_{i,k}, \quad (3)$$

式中:预测输出  $y_i$  取决于 CNN 的所有权重和偏差。 $L$  随着  $N$  个训练样本的预测输出  $y_i$  逼近实际输出  $t_i$  而降低。

### 3.2 CNN 超参数优化

PSO 是 Kennedy 等<sup>[21]</sup>开发的一种进化算法,源于对鸟群捕食的行为研究。粒子群优化的主要思想是随机初始化大小为  $N$  且维数为  $D$  的粒子群,通过粒子间的协作和信息共享来寻求最优解。PSO 中每个粒子代表一种潜在的解决方案,第  $i$  ( $i = 1, 2, \dots, N$ ) 个粒子的位置记为  $x_i = (x_{i,1}, x_{i,2}, \dots, x_{i,D})$ 、速度记为  $v_i =$

$(v_{i,1}, v_{i,2}, \dots, v_{i,D})$ , 粒子通过其个体最优 ( $p_{\text{best}}$ ) 和全局最优 ( $g_{\text{best}}$ ) 来进行更新,当满足停止条件时输出最佳解决方案。粒子的更新过程可描述为

$$x_{i,d}^{k+1} = x_{i,d}^k + v_{i,d}^{k+1}, \quad (4)$$

$$v_{i,d}^{k+1} = \omega v_{i,d}^k + c_1 r_1 (p_{\text{best},i,d}^k - x_{i,d}^k) + c_2 r_2 (g_{\text{best},i,d}^k - x_{i,d}^k), \quad (5)$$

式中: $x_{i,d}^k$  是第  $i$  个粒子在第  $k$  代和第  $d$  维度上的位置; $v_{i,d}^k$  是第  $i$  个粒子在第  $k$  代和第  $d$  维度上的速度; $\omega$  是惯性权重; $c_1$  和  $c_2$  是控制  $p_{\text{best}}$  和  $g_{\text{best}}$  之间权衡的参数; $r_1$  和  $r_2$  是  $0.1 \sim 0.9$  之间的随机数,在每次迭代中随机生成; $p_{\text{best},i,d}^k$  表示第  $i$  个粒子在第  $k$  代和第  $d$  维度上的当前最优位置; $g_{\text{best},i,d}^k$  表示第  $i$  个粒子在第  $k$  代和第  $d$  维度上的全局最优位置。



结合第 3.1 节超参数影响分析,本研究选取卷积核数量、大小、步长、池化核大小、步长及 Dropout 层舍弃概率作为待优化超参数,优化范围如表 1 所示,PSO 中粒子参数定义如表 2 所示。

表 1 待优化超参数及其范围

Layer	Hyper-parameter	Dynamic range
Conv	Number of convolution kernels	30-150
	Convolution kernel size	2-7
	Convolution kernel stride	1-4
Pooling	Pooling kernel size	2-7
	Pooling kernel stride	1-4
Dropout	Dropout probability	0-1

表 2 PSO 中粒子的参数定义

Particle parameter	Parameters to be optimized
a1	The number of convolution kernels of convolution layer 1
a2	The convolution kernels size of the convolution layer 1
a3	The convolution kernel stride of convolution layer 1
a4	The pooling kernel size of pooling layer 1
a5	The pooling kernel stride of pooling layer 1
a6	The number of convolution kernels of convolution layer 2
a7	The convolution kernels size of the convolution layer 2
a8	The convolution kernels stride of convolution layer 2
a9	The pooling kernel size of pooling layer 2
a10	The pooling kernel stride of pooling layer 2
a11	Dropout probability

PSO 优化 CNN 的流程如图 3 所示。具体步骤如下:

- 1) 对数据集进行预处理,提取 VI 轨迹像素化图像;
- 2) 选取训练集作为网络输入;
- 3) 初始化粒子群;
- 4) 计算每个粒子的适应度值,并将初始适应度值作为每个粒子的当前最优值;
- 5) 将粒子中最好的适应度值作为全局最优值;
- 6) 根据式(4)和式(5)更新粒子的位置和速度;
- 7) 将每个微粒的适应度值与其历史最优进行比较,如果较好,则进行替换;
- 8) 将每个微粒的适应度值与历史全局最优进行比较,如果较好,则进行替换;
- 9) 如未达到终止条件(通常达到预定的最大迭代

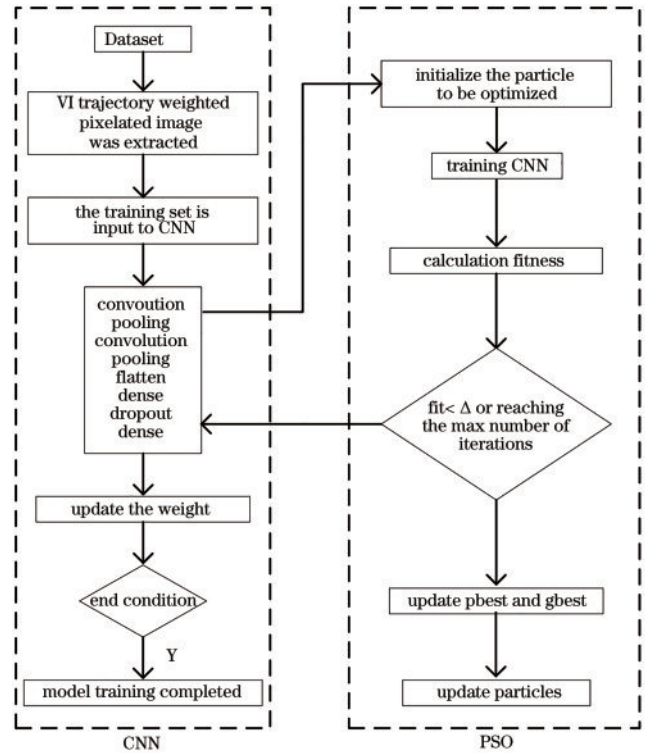


图 3 PSO-CNN 识别模型训练流程图

Fig. 3 PSO-CNN recognition model training flow chart

次数),则返回步骤 6)继续执行;

10) 粒子最优解应用于 CNN 超参数设置,基于该网络进行负荷识别。

设置最大迭代次数为 30、粒子群大小为 10、 $w=0.73$ 、 $c_1=c_2=1.45$ 。

## 4 实验及结果分析

### 4.1 数据集及评价标准

基于 PLAID<sup>[22]</sup>、WHITED<sup>[23]</sup>公开数据集验证模型识别性能。PLAID 数据集以 30 kHz 的采样频率测量了 11 种不同类型电器的电压和电流,对每台设备至少测量 5 次,总共测量 1074 条数据。WHITED 数据集以 44 kHz 的采样频率测量了 46 种不同类型电器的电压和电流,对每台设备至少测量 10 次,总共测量 1100 条数据。

模型的泛化性能通过留一交叉法验证<sup>[14]</sup>。由于 PLAID 数据集按户划分(共 55 户),可以直接使用。WHITED 数据集没有标注电器所在房间,本研究将房间总数设置为 9,对应每种类型设备的最大数量,通过随机分配测量数据,数据集最终包含 20 种设备类型,830 条测量数据。使用准确率(Acc)和文献[19]提出的 F-measure 值作为模型评价标准。

准确率代表分类正确的数量占总样本数量的比例:

$$R_{Acc} = \frac{m}{n}, \quad (6)$$

式中:  $m$  表示模型分类正确的数量;  $n$  为样本总数量。

设备  $i$  的 F-measure 值为

$$P_i = \frac{N_{TP_i}}{N_{TP_i} + N_{FP_i}}, \quad (7)$$

$$R_i = \frac{N_{TP_i}}{N_{TP_i} + N_{FN_i}}, \quad (8)$$

$$F_i = 2 \cdot \frac{P_i \cdot R_i}{P_i + R_i}, \quad (9)$$

式中:  $N_{TP}$  表示真实值是正样本, 模型预测值也是正样本的数量;  $N_{FP}$  表示真实值是负样本, 模型预测值是正样本的数量;  $N_{FN}$  表示真实值是正样本, 模型预测值是负样本的数量。

则每个设备的平均值为

$$F_{i,\text{mean}} = \frac{1}{L} \sum_{g=1}^L F_{g,i}, \quad (10)$$

式中:  $L$  是设备  $i$  存在于测试集中的总次数;  $F_{g,i}$  表示设备  $i$  在第  $g$  次中的 F-measure 值。

最后, 取所有 F-measures 的平均值, 得到宏观平均值  $F_{\text{macro}}$ :

$$F_{\text{macro}} = \frac{1}{A} \sum_{i=1}^A F_{i,\text{mean}}, \quad (11)$$

式中:  $A$  是不同设备类型的总数。

## 4.2 实验结果分析

为验证所提方法有效性, 分别与 CNN、文献[3, 5, 14]的负荷识别算法进行了对比, 各算法识别准确率如表 3 所示, 其中 CNN 与 PSO-CNN 超参数信息如表 4 所示, 卷积层参数个数、感受野、运行时间如表 5 所示。由表 3 可知, PSO-CNN 模型的识别性能优于其他模型: 在 PLAID 数据集中, 其识别准确率为 93.20%, 相较于 CNN、文献[3, 5, 14]的分类算法分别提高了 6.72 个百分点、17.38 个百分点、15.49 个百分点、

表 3 各算法识别准确率对比

Table 3 Comparison of recognition accuracy of algorithms

Model	Recognition accuracy	
	PLAID	WHITED
PSO-CNN	<b>93.20</b>	<b>91.69</b>
CNN	87.33	82.17
Reference[3]	79.40	72.01
Reference[5]	80.70	72.98
Reference[14]	82.40	73.01

unit: %

表 4 CNN 与 PSO-CNN 超参数信息对比

Table 4 Comparison of hyper-parameter information between

CNN and PSO-CNN

Layers	Parameter	PLAID		WHIED	
		CNN	PSO-CNN	CNN	PSO-CNN
Con1	Number	32	50	32	64
	Size	5×5	5×5	5×5	5×5
	Step	1	2	1	2
Pool1	Size	2×2	4×4	2×2	2×2
	Step	1	1	1	2
Con2	Number	64	80	64	120
	Size	5×5	3×3	5×5	3×3
	Step	1	2	1	2
Pool2	Size	2×2	2×2	2×2	4×4
	Step	1	1	1	2
Dropout	Probability	0.3	0.5	0.3	0.4

13.11 个百分点; 在 WHITED 数据集中, 其识别准确率为 91.69%, 相较于 CNN、文献[3, 5, 14]的分类算法分别提高了 11.59 个百分点、27.33 个百分点、25.64 个百分点、25.59 个百分点。

表 5 CNN 与 PSO-CNN 的卷积层参数个数、感受野、运行时间对比

Table 5 Comparison of number of convolutional layer parameters, receptive field, and running time between CNN and PSO-CNN

Dataset	Model	Number of parameters of convolutions			Model receptive field	Running time / h
		Con1	Con2	Sum		
PLAID	CNN	832	1664	2496	11	<b>0.17</b>
	PSO-CNN	1300	800	2100	19	0.25
WHITED	CNN	832	1664	2496	11	<b>0.15</b>
	PSO-CNN	1664	1200	2864	39	0.32

为测试 PSO 算法稳定性, 在 PLAID、WHITED 数据集中分别进行了 11 次、9 次交叉验证, 结果如图 4 所示。从图中可以看出, 在两个公开数据集中, PSO-CNN 模型的波动幅度较大, 但其识别准确率均优于 CNN 模型, 具有良好的鲁棒性。

### 4.2.1 PLAID 数据集结果分析

模型混淆矩阵如图 5 所示, 图中每个单元格中的数量为设备数量, 横坐标表示电器预测值, 纵坐标表示电器真实值。从图中可以看出, 在 PLAID 数据集中,

相较于 CNN 模型, PSO-CNN 模型降低了各电器的 FN、FP 数量, 也降低了各电器被错误分类的设备类型数量。图 6(a)、(b) 分别以节能灯和冰箱为例, 对比展示了 CNN 与 PSO-CNN 各层中一个卷积核提取到的设备特征。结合表 5 可以看出, PSO-CNN 模型的运行时间明显增长, 但减少了网络参数运算量, 并通过扩大感受野使模型提取的特征更具代表性以增强模型识别能力。

模型对各电器的分类性能如图 7 所示。PSO-

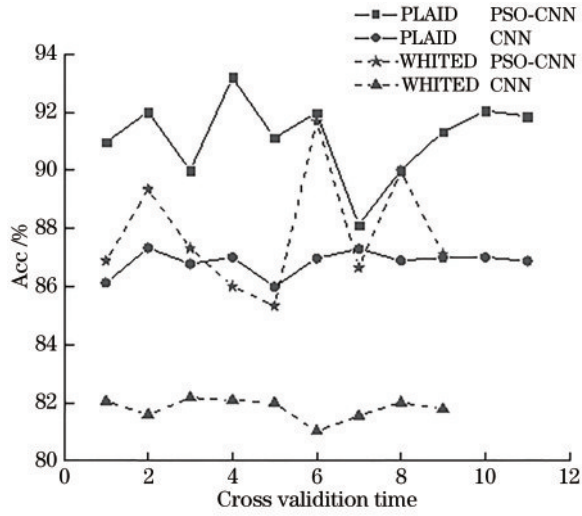


图 4 识别准确率对比

Fig. 4 Comparison of recognition accuracy

CNN 模型对各电器识别效果均优于 CNN 模型。在 PLAID 数据集中, PSO-CNN 模型宏观平均值为 85.22%, 相较于 CNN 模型提高了 9.37 个百分点, 此外, 对冰箱、空调、洗衣机、电风扇的 F-measure 值低于宏观平均值。获得较低 F-measure 值的原因主要有以

下两方面: 1) 数据集中部分设备具有少量测量数据, 如洗衣机共 26 条、冰箱共 38 条, 限制了模型学习能力; 2) 空调、冰箱、电风扇等设备均具有电机组件, 这种外在原因使电器间的相似性更高。

4.2.2 WHITED 数据集结果分析

由图 5 可知, 在 WHITED 数据集中, PSO-CNN 模型中各电器的 TP 数量明显增多且 FP 数量明显降低, 对电烙铁、节能灯的提升效果最为明显, 此外, 该模型降低了各设备间的混淆, 如电灯泡、微波炉等电器没有被错误分类。图 6(c)、(d) 分别以吹风机和电风扇为例, 对比展示了模型各层中一个卷积核提取到的设备特征。结合图 5(d) 和表 5 可以看出, 由于 WHITED 数据集中电器种类的增多, PSO-CNN 模型通过增大网络参数数量、扩大感受野增强网络的特征提取能力, 提升了网络的识别能力, 但其运行时间更长。

由图 7(b) 可知, 电烙铁、电熨斗、节能灯获得较低 F-measure 值。结合图 5(d) 可以看出: 这三台电器的样本数量较少, 各有 20 条。其他电器与这三台电器的原理相似, 例如电烙铁与电灯泡、鞋子烘干器都具有电阻元件, 节能灯与充电器都具有电压限制元件。

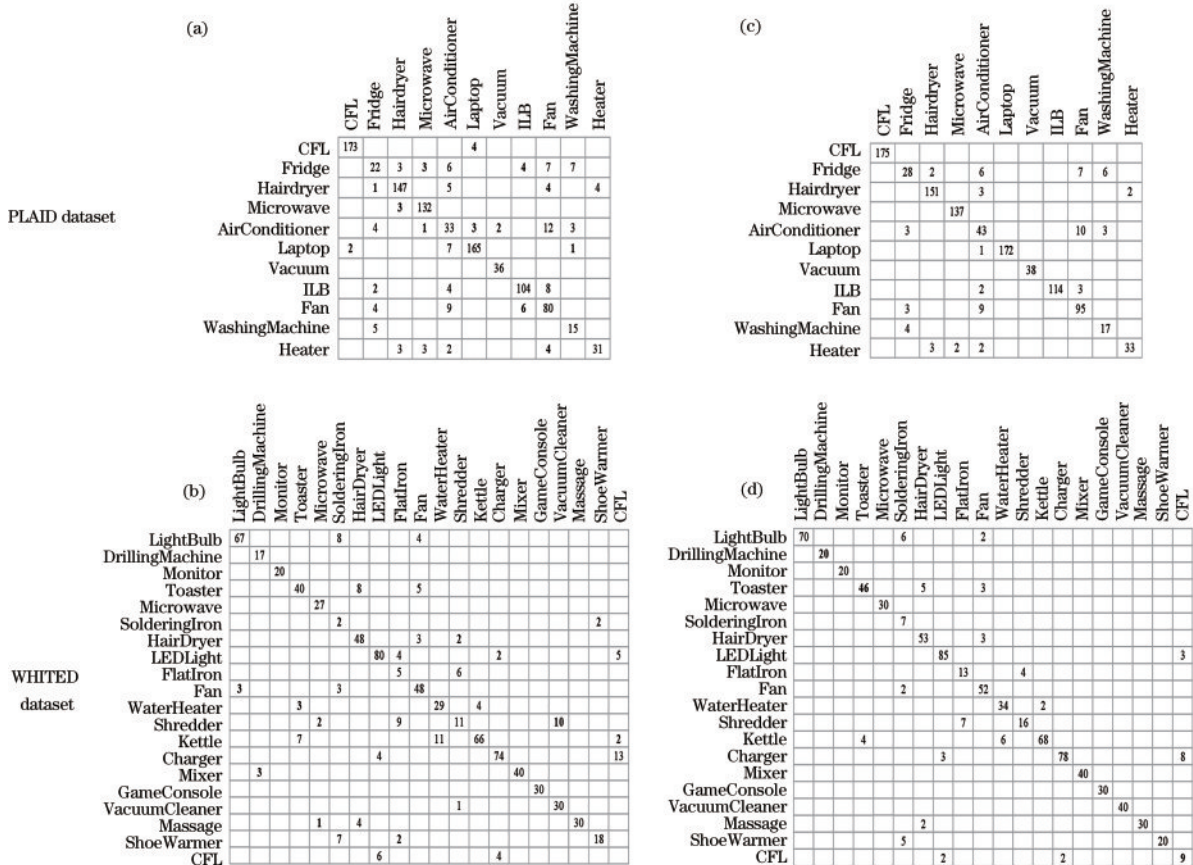


图 5 模型混淆矩阵对比。(a) (b) CNN 模型混淆矩阵; (c) (d) PSO-CNN 模型混淆矩阵

Fig. 5 Confusion matrix comparison of recognition results of each algorithm. (a) (b) CNN confusion matrix; (c) (d) PSO-CNN confusion matrix



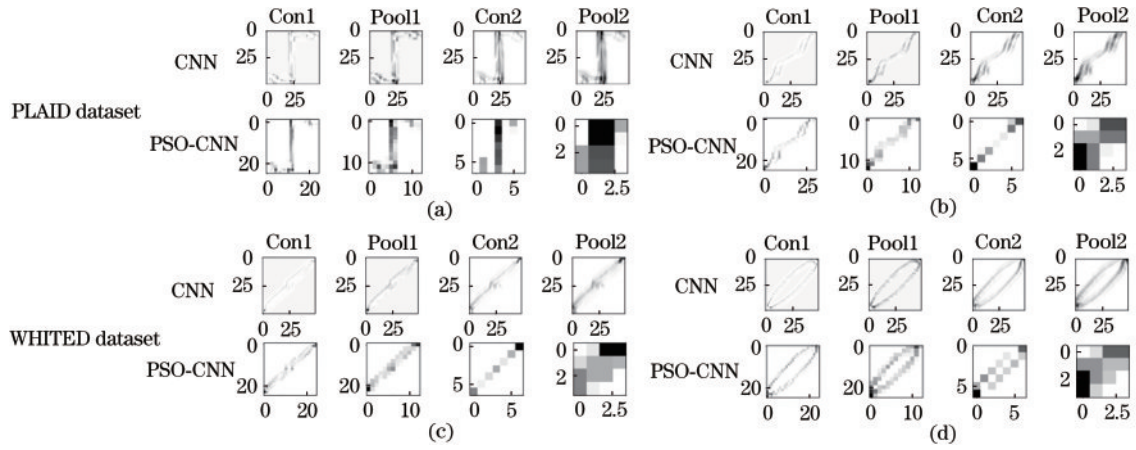


图 6 CNN 与 PSO-CNN 各层的特征提取对比。(a)节能灯;(b)冰箱;(c)吹风机;(d)电风扇

Fig. 6 Comparison of feature extraction of each layer between CNN and PSO-CNN. (a) CFL; (b) refrigerator; (c) hairdryer; (d) fan

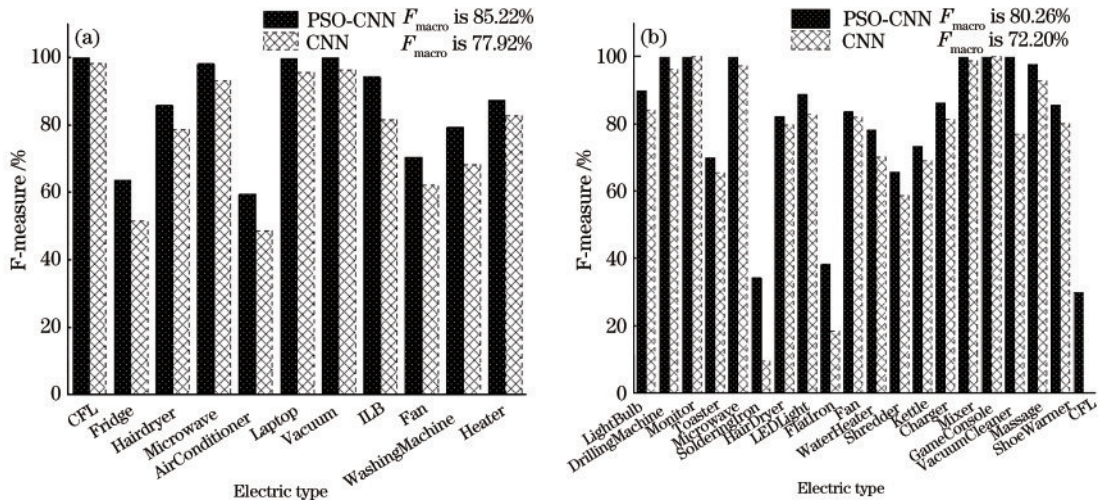


图 7 模型分类性能对比。(a)基于 PLAID 数据集的宏观平均值;(b)基于 WHITED 数据集的宏观平均值

Fig. 7 Model classification performance comparison. (a)  $F_{macro}$  based on PLAID dataset; (b)  $F_{macro}$  based on WHITED dataset

## 5 结 论

本研究提出了一种基于 CNN 的负荷识别方法,分析不同超参数对识别性能的影响,引入 PSO 算法优化超参数的设置以增强特征提取能力。基于 PLAID、WHITED 公开数据集测试结果表明:相较于其他算法,所提 PSO-CNN 有效降低了设备之间的混淆,具有较好的准确性和鲁棒性;该方法对各类电器的识别性能均优于 CNN 模型,但部分电器的样本数据过少,且容易受到其他原理相似电器的影响,导致对其识别效果不理想。因此未来工作中会引入电器的使用时间、功率等特征进行辅助判断。

### 参 考 文 献

[1] Batra N, Singh A, Singh P, et al. Data driven energy efficiency in buildings[EB/OL]. (2014-04-29) [2021-04-05]. <https://arxiv.org/abs/1404.7227>

[2] Ibrahim M, El-Zaar A, Adams C. Smart sustainable cities roadmap: readiness for transformation towards

urban sustainability[J]. Sustainable Cities and Society, 2018, 37: 530-540.

[3] Zheng Z, Chen H N, Luo X W. A supervised event-based non-intrusive load monitoring for non-linear appliances[J]. Sustainability, 2018, 10(4): 1001.

[4] Lam H Y, Fung G S K, Lee W K. A novel method to construct taxonomy electrical appliances based on load signatures[J]. IEEE Transactions on Consumer Electronics, 2007, 53(2): 653-660.

[5] de Baets L, Develder C, Dhaene T, et al. Automated classification of appliances using elliptical Fourier descriptors[C]//2017 IEEE International Conference on Smart Grid Communications (SmartGridComm), October 23-27, 2017, Dresden, Germany. New York: IEEE Press, 2017: 153-158.

[6] Hassan T, Javed F, Arshad N. An empirical investigation of V-I trajectory based load signatures for non-intrusive load monitoring[J]. IEEE Transactions on Smart Grid, 2014, 5(2): 870-878.

[7] 程祥, 李林芝, 吴浩, 等. 非侵入式负荷监测与分解研究综述[J]. 电网技术, 2016, 40(10): 3108-3117.

Cheng X, Li L Z, Wu H, et al. A survey of the research

- on non-intrusive load monitoring and disaggregation[J]. Power System Technology, 2016, 40(10): 3108-3117.
- [8] Kelly J, Knottenbelt W. Neural NILM: deep neural networks applied to energy disaggregation[C]//BuildSys '15: Proceedings of the 2nd ACM International Conference on Embedded Systems for Energy-Efficient Built Environments, November, 2015, Seoul, South Korea. New York: ACM Press, 2015: 55-64.
- [9] 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 S X, Guo L Y, Chen H W, 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.
- [10] 张玉天, 邓春宇, 刘沅昆, 等. 基于卷积神经网络的非侵入负荷辨识算法[J]. 电网技术, 2020, 44(6): 2038-2044.  
Zhang Y T, Deng C Y, Liu Y K, et al. Non-intrusive load identification algorithm based on convolution neural network[J]. Power System Technology, 2020, 44(6): 2038-2044.
- [11] Breuel T M. The effects of hyperparameters on SGD training of neural networks[EB/OL]. (2015-08-12)[2021-04-05]. <https://arxiv.org/abs/1508.02788>.
- [12] Du L, He D W, 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.
- [13] Alpaydin E. Neural networks and deep learning[M]//Machine learning: the new AI. Cambridge: The MIT Press, 2016: 85-109.
- [14] Gao J K, Kara E C, Giri S, et al. A feasibility study of automated plug-load identification from high-frequency measurements[C]//2015 IEEE Global Conference on Signal and Information Processing (GlobalSIP), December 14-16, 2015, Orlando, FL, USA. New York: IEEE Press, 2015: 220-224.
- [15] 张彩珍, 李颖, 康斌龙, 等. 基于深度学习的模糊车牌字符识别算法[J]. 激光与光电子学进展, 2021, 58(16): 1610012.  
Zhang C Z, Li Y, Kang B L, et al. Blurred license plate character recognition algorithm based on deep learning[J]. Laser & Optoelectronics Progress, 2021, 58(16): 1610012.
- [16] 宋晓宇, 金莉婷, 赵阳, 等. 基于有效区域筛选的复杂背景植物图像识别方法[J]. 激光与光电子学进展, 2020, 57(4): 041016.  
Song X Y, Jin L T, Zhao Y, et al. Plant image recognition with complex background based on effective region screening[J]. Laser & Optoelectronics Progress, 2020, 57(4): 041016.
- [17] 刘芾, 李茂军, 胡建文, 等. 基于低像素人脸图像的表情识别[J]. 激光与光电子学进展, 2020, 57(10): 101008.  
Liu F, Li M J, Hu J W, et al. Expression recognition based on low pixel face images[J]. Laser & Optoelectronics Progress, 2020, 57(10): 101008.
- [18] Russakovsky O, Deng J, Su H, et al. ImageNet large scale visual recognition challenge[J]. International Journal of Computer Vision, 2015, 115(3): 211-252.
- [19] Dumoulin V, Visin F. A Guide to convolution arithmetic for deep learning[EB/OL]. (2016-03-23) [2021-04-05]. <https://arxiv.org/abs/1603.07285>
- [20] Li C M, Yang S X, Yang Y, et al. Hyperspectral remote sensing image classification based on maximum overlap pooling convolutional neural network[J]. Sensors, 2018, 18(10): 3587.
- [21] Kennedy J, Eberhart R. Particle swarm optimization[C]//Proceedings of ICNN'95-International Conference on Neural Networks, November 27-December 1, 1995, Perth, WA, Australia. New York: IEEE Press, 2011: 1942-1948.
- [22] Gao J K, Giri S, Kara E C, et al. PLAID: a public dataset of high-resolution electrical appliance measurements for load identification research: demo abstract[C]//BuildSys '14: Proceedings of the 1st ACM Conference on Embedded Systems for Energy-Efficient Buildings, November 3-6, 2014, Memphis, Tennessee, USA. New York: ACM Press, New York: ACM, 2014: 198-199.
- [23] Kahl M, Haq A U, Kriechbaumer T. Whited-a worldwide household and industry transient energy data set[EB/OL]. [2021-07-08]. [http://nilmworkshop.org/2016/proceedings/Poster\\_ID18.pdf](http://nilmworkshop.org/2016/proceedings/Poster_ID18.pdf).