

DOI: 10.19783/j.cnki.pspc.240660

## 基于多 $V-I$ 轨迹融合的非侵入式负荷识别方法

程志友<sup>1</sup>, 胡乐乐<sup>2</sup>, 陈思源<sup>2</sup>, 杨猛<sup>2</sup>

(1. 安徽大学互联网学院, 安徽 合肥 230039; 2. 安徽大学电子信息工程学院, 安徽 合肥 230601)

**摘要:** 在负荷识别领域中, 仅使用单一负荷特征难以有效区分相似轨迹的负荷。为解决这一问题, 提出了一种基于多  $V-I$ (电压-电流)轨迹融合的非侵入式负荷识别方法。该方法首先对高频采样数据进行预处理, 从中提取基波电压( $V_1$ )、基波电流( $I_1$ )以及最大谐波电流( $I_{h\max}$ )。随后使用基波电压分别与基波电流和最大谐波电流相结合, 构建了  $V_1-I_1$  轨迹和  $V_1-I_{h\max}$  轨迹。最后将这两种轨迹特征输入到二维卷积神经网络(2D convolutional neural network, 2D-CNN)中进行负荷分类, 通过 PLAID 和 WHITED 两个公共数据集进行验证, 所提出的负荷识别方法的准确率达 99.66% 和 99.81%。该实验结果表明, 所提方法不仅增加了信息量, 还提高了负荷识别的准确率, 在实际电力监控和负荷管理中具有应用价值。

**关键词:** 非侵入式负荷识别; 相似轨迹;  $V_1-I_1$  轨迹;  $V_1-I_{h\max}$  轨迹; 卷积神经网络

### Non-intrusive load identification method based on multiple $V-I$ trajectory fusion

CHENG Zhiyou<sup>1</sup>, HU Lele<sup>2</sup>, CHEN Siyuan<sup>2</sup>, YANG Meng<sup>2</sup>

(1. Internet School, Anhui University, Hefei 230039, China; 2. School of Electronic and Information Engineering, Anhui University, Hefei 230601, China)

**Abstract:** In the field of load identification, it is difficult to effectively distinguish loads with similar trajectories using a single load feature. To address this issue, a non-intrusive load identification method based on multiple  $V-I$  (voltage-current) trajectory fusion is proposed. This method first preprocesses high-frequency sampling data to extract the fundamental voltage ( $V_1$ ), fundamental current ( $I_1$ ), and maximum harmonic current ( $I_{h\max}$ ). Subsequently, the fundamental voltage is combined with the fundamental current and maximum harmonic current to construct  $V_1-I_1$  trajectories and  $V_1-I_{h\max}$  trajectories. Finally, these two trajectory features are input into a two-dimensional convolutional neural network (2DCNN) for load classification. Validation using the public PLAID and WHITED datasets shows that the proposed load identification method achieves accuracies of 99.66% and 99.81%, respectively. These results indicate that the proposed method not only enriches the information used for classification but also significantly improves load identification accuracy, demonstrating its practical application value in power monitoring and load management.

This work is supported by the National Natural Science Foundation of China (No. 6227020935).

**Key words:** non-intrusive load identification; similar trajectories;  $V_1-I_1$  trajectory;  $V_1-I_{h\max}$  trajectory; convolutional neural network

## 0 引言

近年来, 随着中国经济的发展和人民生活水平的大幅提高<sup>[1]</sup>, 并伴随着新型电力系统建设和智能电网的发展<sup>[2]</sup>, 使得用电量不断上升, 电力行业面临巨大的能耗浪费问题。针对这些问题, 上世纪 80 年

代由 Hart 提出了非侵入式负荷监测(non-intrusiveload monitoring, NILM)<sup>[3]</sup>, 借助 NILM 技术, 新一代家居可以通过对用户的非侵入式监测, 实现居民用电能耗分项计量, 为居民节能智慧调控策略提供数据支撑<sup>[4]</sup>。

在非侵入式负荷识别任务中, 一般使用稳态特征进行分类。常见的稳态特征包括电压电流波形、功率变化<sup>[5]</sup>、 $V-I$  轨迹、谐波电流幅值等。其中,  $V-I$  轨迹作为 NILM 与计算机视觉两者研究的交叉点,

**基金项目:** 国家自然科学基金项目资助(6227020935); 安徽省科技重大专项资助(18030901018)

成为了 NILM 技术和计算机视觉之间的桥梁<sup>[6-7]</sup>。近几年国内外学者针对  $V-I$  轨迹图像展开了深入研究。文献[7]使用公共数据集对比了包括  $V-I$  轨迹特征在内的常用高频特征与常用分类算法的辨识效果, 表明了  $V-I$  轨迹特征比其他高频特征具有更高的辨识准确率, 但是不能区分轨迹相似设备。文献[8]提出将  $V-I$  轨迹映射到具有二进制值的单元网格, 降低了计算成本。文献[9]将  $V-I$  轨迹转换为加权像素图像, 并将其作为二维卷积神经网络的输入进行负荷识别。文献[10]提出一种自适应加权递归图方法, 来更好地表示负荷特征的唯一性。文献[11]通过构造电流、电压和相位 3 个像素矩阵, 叠加形成彩色  $V-I$  图像, 并采用 AlexNet 算法进行分类, 进一步提高了负荷识别的准确度, 但是该方法难以反映电流波形存在的谐波特征。文献[12]表明在 NILM 方法中引入谐波电流信息可以有效提升负荷识别的性能。文献[13]采用前 13 次奇次谐波作为负荷分类特征, 并使用 4 种分类模型进行分类识别, 但是每个谐波幅值不能在一个周期内完整地描述波形特征。文献[14]通过提取设备高频采样数据中的  $V-I$  轨迹图像特征和功率数值特征, 并将二者融合, 进而进行负荷分类。文献[15]使用的负荷特征是灰度  $V-I$  轨迹图片, 并应用二维卷积神经网络(2D convolutional neural network, 2D-CNN)模型进行分类。文献[16]针对传统方法无法准确识别含有高次谐波家用负荷的问题, 提出了基于  $V-I$  轨迹矩阵、功率及高次谐波多特征融合的负荷辨识方法, 弥补了家用电器  $V-I$  轨迹矩阵高度像素化带来的特征损失。文献[17]提出了基于  $V-I$  轨迹特征的颜色编码和负荷高次谐波特征相融合的识别方法, 并使用 AlexNet 模型进行分类, 相对于传统的  $V-I$  轨迹图像识别方法, 效果有明显提升。文献[18]在文献[17]的基础上直接将谐波特征编码进  $V-I$  轨迹图像上, 并使用 2D-CNN 进行负荷辨识。虽然目前基于  $V-I$  轨迹的负荷识别模型及算法日益成熟, 但仍然存在一些挑战。直接将高次谐波信息融合到  $V-I$  轨迹图像中, 会增加其复杂度, 同时添加的高次谐波电流也未能充分反映负荷电流的谐波特征, 所以选择更具有谐波特征的最大谐波电流。

针对以上问题, 本文提出基于多  $V-I$  融合的非侵入式负荷识别方法。首先, 将高频采样信号分解为基波和谐波信息, 得到基波电压和基波电流, 并从谐波信息中筛选出具有显著谐波特征的最大谐波电流; 其次以基波电压为基准分别构建出  $V_1-I_1$  轨迹图像和  $V_1-I_{h \max}$  轨迹图像; 最后, 将构建出的两个轨迹图像输入到 2D-CNN 中进行负荷识别。使用

PLAID 数据集和 WHITED 数据集对提出的方法进行识别效果测试, 并与目前先进算法进行对比, 表明该方法具有更高的识别精度。

## 1 负荷标识的构建

在非侵入式负荷识别领域中, 利用高频采样设备可直接获取家庭总线的电压、电流数据, 电流波形可通过计算开关事件前后稳态电流相同相位点的差值来获取<sup>[19]</sup>, 家庭负载的电压一般是稳定在工频电压附近, 电压波形基本保持不变, 所以负载本身实现的电气特征是与电流有关的。并且本文选择基波电压作为基准, 可以实现对系统状态的有效表征, 并且有助于准确地分析和识别负载特征。具体步骤如下所述。

1) 对原始数据进行过零点处理后, 即将电流或电压波形的起始点与零电平对齐, 可以将数据限制在完整的周期内, 排除了跨越周期的部分, 从而得到稳态数据。

2) 利用快速傅里叶变换(fast Fourier transform, FFT)对一个周期内的稳态电压和稳态电流数据进行处理, 将其转为频域信号得到基波信息和谐波信息, FFT 算法得到的频域信号  $Y(k)$  可以表示为

$$Y(k) = |X(k)| = \left| \sum_{n=0}^{N-1} x(n) e^{-j \frac{2\pi kn}{N}} \right| \quad (1)$$

式中:  $k$  为谐波次数;  $N$  为采样点数;  $x(n)$  为第  $n$  个点的时域信息(时域信息包括电压信息和电流信息);  $Y(k)$  表示第  $k$  次的谐波幅值;  $X(k)$  表示第  $k$  次的谐波分量。根据式(1)得到电压和电流的基波信息以及电流的谐波信息, 比较每个奇次谐波的幅值大小得到幅值最大的谐波电流。

3) 将得到的频域信息通过式(2)转换为时域信息, 得到基波电压  $v_1(n)$  和电流  $i_k(n)$ 。

$$x_k(n) = \frac{1}{N} \sum_{k=0}^{N-1} X(k) e^{j \frac{2\pi kn}{N}} \quad (2)$$

并对得到的时域信息进行归一化处理, 其中对电流和基波电压进行归一化处理, 如式(3)和式(4)所示。

$$I_k(n) = \frac{i_k(n) - i_{k-\min}}{i_{k-\max} - i_{k-\min}} \quad (3)$$

$$V_1(n) = \frac{v_1(n) - v_{1-\min}}{v_{1-\max} - v_{1-\min}} \quad (4)$$

式中: 当  $k=1$  时,  $i_1(n)$  为基波电流,  $i_{1-\min}$  和  $i_{1-\max}$  分别为基波电流的最小值和最大值,  $I_1(n)$  为归一化之后的基波电流; 当  $k=3$  时,  $i_3(n)$  为三次谐波电流,

$i_{3-\min}$  和  $i_{3-\max}$  分别为三次谐波电流的最小值和最大值,  $I_3(n)$  为归一化之后的三次谐波电流; 由于每种电器的幅值最大的谐波电流的谐波次数不同, 有的电器三次谐波电流幅值最大, 而有的则是五次谐波电流幅值最大, 所以将其统称为最大谐波电流;  $V_1(n)$  为归一化之后的基波电压;  $v_1(n)$  为基波电压,  $v_{1-\min}$  和  $v_{1-\max}$  分别为基波电压的最小值和最大值。归一化后电压和电流的波形如图 1 所示, 分别是空调的基波电压、基波电流和最大谐波电流波形, 可以看到其稳态基波电压、电流与谐波电流具有周期性和规律性的特点<sup>[20]</sup>。

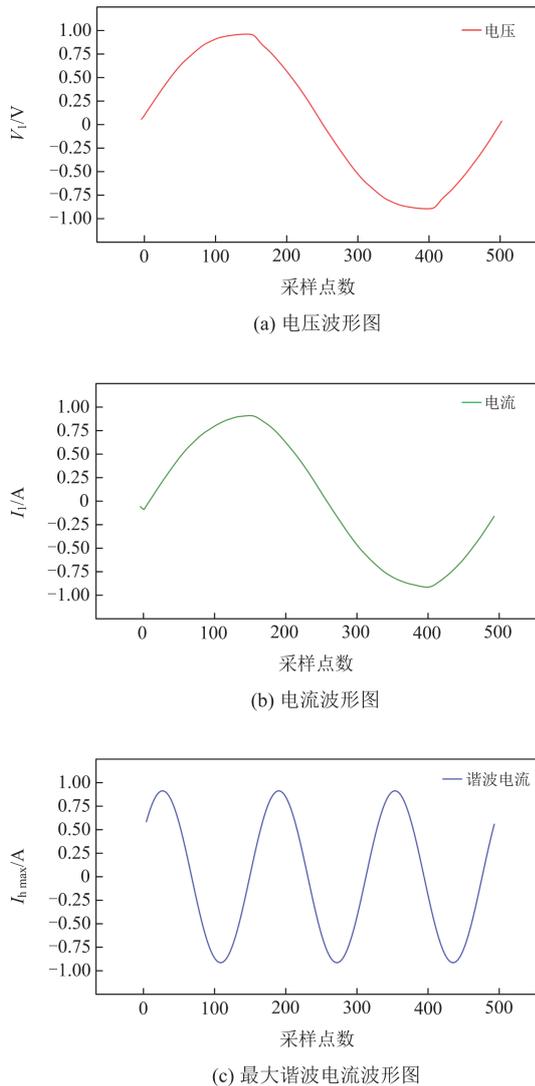


图 1 归一化后电压和电流的波形

Fig. 1 Waveform of voltage and current after normalization

4) 对每个设备的数据采取每隔 30 个周期获取一个周期的基波电压和基波电流绘制  $V_1-I_1$  轨迹图像, 空调的  $V_1-I_1$  轨迹图像如图 2 所示。

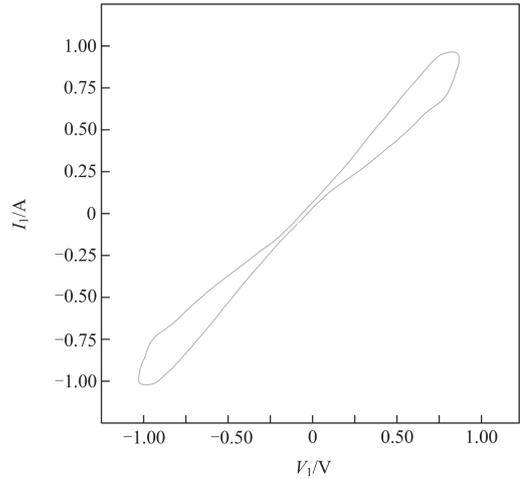


图 2 空调的  $V_1-I_1$  轨迹图像

Fig. 2  $V_1-I_1$  trajectory diagram of air conditioner

5) 再对每个设备的数据每隔 30 个周期获取一个周期的基波电压, 并选取和基波电压一样长度的最大谐波电流绘制  $V_1-I_{h \max}$  轨迹图像。例如, 若基波电压长度为 500, 那么为了绘制图形, 也应截取最大谐波电流的长度为 500。空调的  $V_1-I_{h \max}$  轨迹图像如图 3 所示。

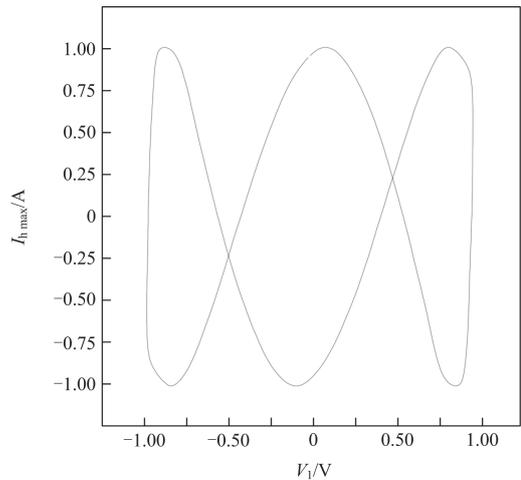


图 3 空调的  $V_1-I_{h \max}$  轨迹图像

Fig. 3  $V_1-I_{h \max}$  trajectory diagram of air conditioner

## 2 神经网络的构建

卷积神经网络是一种经典神经网络, 2D-CNN 是它的一种变体, 也是主要用于图像处理和计算机视觉任务的深度学习模型。本文中主要是对灰度图像进行分类处理, 采用 2D-CNN 神经网络即可。2D-CNN 神经网络也是由卷积层、池化层和全连接层组成的, 其中卷积层和池化层交替重复, 并且上一层的输出均直接作为下一层的输入<sup>[21-22]</sup>。

在本文的卷积操作中，采用了多个大小为 $3 \times 3$ 的卷积核组成的卷积层。这些卷积核以一定步长在输入数据上滑动平移进行卷积运算，从而得到输入数据的特征图谱<sup>[23]</sup>。这种基于滑动卷积核的操作可以有效地捕捉输入数据的底层特征，进而提高负荷特征的分类准确性和效率。

在特征降维的过程中，池化层扮演着至关重要的角色，其主要功能在于通过减小特征图的尺寸，从而降低数据的维度，有效地减少了计算量。同时，池化操作还有助于提取关键特征，从而帮助模型更好地理解并表示输入数据。在本文中，所选取的池化层过滤器大小为 $2 \times 2$ ，这意味着每次池化操作都会将输入单元数缩小4倍输出。

在最终分类过程中，使用的是全连接层，其作用是汇总卷积层和池化层得到图像的底层特征和信息。其中激活函数选用了 Softmax 函数，损失函数则采用了交叉熵损失函数。这些选择旨在有效地实现对样本的分类，并在训练过程中引导模型朝着正确的方向学习。Softmax 激活函数的使用能够将输出转化为类别概率分布，使得模型能够更加自信地做出分类决策。而交叉熵损失函数则是一种常用的分类任务损失函数，其作用是实现样本的分类，输出向量的维度与样本总类别数相同，向量的第  $i$  个元素代表了本次辨识结果为第  $i$  类设备的概率，所有元素的和为 1<sup>[16]</sup>。

本文中神经网络结构主要是将主特征的  $V_1-I_1$  轨迹图像传入通道 1，辅助特征的  $V_1-I_{h_{max}}$  轨迹图像传入通道 2 中进行特征提取，两种轨迹图像分辨率均为  $128 \times 128$ ，输入到相同的特征提取网络中。分

类算法的输入为两个通道形成的特征融合，总维数为 512。通道 1、通道 2 和分类神经网络的输出维度都为 11，代表一共有 11 类电气设备。神经网络的模型结构如图 4 所示，神经网络的具体参数如表 1 所示。具体步骤如下所述。

- 1) 输入层：将两种分辨率为  $128 \times 128$  的轨迹图像传入网络；
- 2) 卷积层 1：经过大小为  $3 \times 3$ 、深度为 6 的过滤器，步长为 1，没有填充，激活函数为 Relu，输出大小为  $(126 \times 126 \times 6)$ ；
- 3) 池化层 1：经过一个  $2 \times 2$  的池矩阵，步长为 2，输出维度为  $(63 \times 63 \times 6)$ ；
- 4) 卷积层 2：经过大小为  $3 \times 3$ 、深度为 12 的过滤器，步长为 1，没有填充，激活函数为 Relu，输出大小为  $(61 \times 61 \times 12)$ ；
- 5) 池化层 2：经过一个  $2 \times 2$  的池矩阵，步长为 2，输出维度为  $(30 \times 30 \times 12)$ ；
- 6) 卷积层 3：经过大小为  $3 \times 3$ 、深度为 18 的过滤器，步长为 1，没有填充，激活函数为 Relu，输出大小为  $(28 \times 28 \times 18)$ ；
- 7) 池化层 3：经过一个  $2 \times 2$  的池矩阵，步长为 2，输出维度为  $(14 \times 14 \times 18)$ ；
- 8) 卷积层 4：经过大小为  $3 \times 3$ 、深度为 24 的过滤器，步长为 1，没有填充，激活函数为 Relu，输出大小为  $(12 \times 12 \times 24)$ ；
- 9) 池化层 4：经过一个  $2 \times 2$  的池矩阵，步长为 2，输出维度为  $(6 \times 6 \times 24)$ ；
- 10) Flatten 层：把多维数据一维化，输出大小为 864；

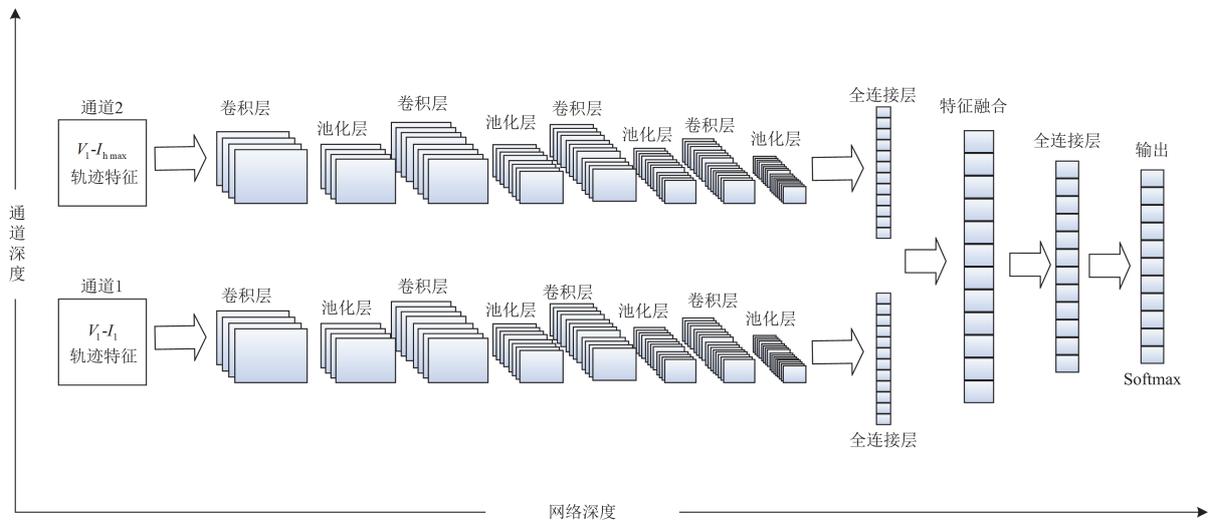


图 4 神经网络的模型结构  
Fig. 4 Model architecture of neural network

表 1 神经网络参数

Table 1 Parameters of neural network

	层类型	核函数	激活函数	输出维度	
特征 提取 网络	输入层	—	—	(128×128×1)	
	卷积层 1	(3×3×6)	Relu	(126×126×6)	
	池化层 1	(2×2)	—	(63×63×6)	
	卷积层 2	(3×3×12)	Relu	(61×61×12)	
	池化层 2	(2×2)	—	(30×30×12)	
	卷积层 3	(3×3×18)	Relu	(28×28×18)	
	池化层 3	(2×2)	—	(14×14×18)	
	卷积层 4	(3×3×24)	Relu	(12×12×24)	
	池化层 4	(2×2)	—	(6×6×24)	
	Flatten 层	—	—	864	
	全连接层 1	—	Relu	256	
	全连接层 2	—	Softmax	11	
	分类 神经 网络	输入层	—	—	512
		全连接层 3	—	Relu	128
输出		—	Softmax	11	

11) 全连接层 1: 经过 256 个神经元, 激活函数为 Relu, 输出大小为 256;

12) 全连接层 2: 经过 11 个神经元, 激活函数为 Softmax, 输出大小为 11, 之后将通道 1 和通道 2 的特征融合得到总维数为 512(256+256);

13) 全连接层 3: 经过 128 个神经元, 激活函数为 Relu, 输出大小为 128;

14) 输出层: 经过 11 个神经元, 激活函数为 Softmax, 输出大小为 11。

### 3 算例分析与讨论

#### 3.1 算例说明

本文中对于负荷识别使用的操作系统是 Win11, GPU 型号为 RTX4070, CPU 型号为 13th Gen Intel(R) Core(TM)i5-13600KF, 32 GB 内存。软件环境是 Python3.9(64 位)、Tensorflow2.13 以及 Keras2.13。

选择在两个常用的公共数据集 PLAID 和 WHITED 上进行实验验证。PLAID 数据集提供了住宅环境中常见电器的高频数据, 以采样频率为 30 kHz 记录了每一个样本单独运行超过 2 s 的电压与电流信号<sup>[24]</sup>, PLAID 数据集覆盖 11 类共 235 台独立设备的电压-电流波形数据, 总样本数有 1074 组<sup>[25]</sup>, 且 PLAID 数据集中同种设备间的特征差异更加明显<sup>[26]</sup>。WHITED 数据集也是提供了住宅环境中常见电器的高频数据, 以采样频率为 44.1 kHz 记录了来自世界各个地区的 54 种电器的 1339 组数据, 而不同于 PLAID 数据集, WHITED 数据集不同设备之间特征差异更加明显。

#### 3.2 评价指标

本文中采用  $F_1$  分数、准确率和混淆矩阵 3 种评价指标对负荷识别结果进行评价。

$F_1$  分数是召回率( $R_{re}$ )和精确率( $P_{re}$ )的调和平均值, 旨在综合考虑模型的准确性和全面性, 其计算如式(5)一式(7)所示。

$$R_{re} = \frac{T_p}{T_p + F_N} \quad (5)$$

$$P_{re} = \frac{T_p}{T_p + F_P} \quad (6)$$

$$F_1 = \frac{2 \times R_{re} \times P_{re}}{R_{re} + P_{re}} \quad (7)$$

准确率( $A_c$ )是所有分类结果中正确分类的比例, 其计算公式如式(8)所示。

$$A_c = \frac{T_p + T_N}{T_p + T_N + F_P + F_N} \quad (8)$$

式中:  $T_p$  为真阳性, 表示状态监测为正, 实际为正的个数;  $F_P$  为假阳性, 表示状态监测为正, 实际为负的个数;  $F_N$  为假阴性, 表示状态监测为负, 实际为正的个数<sup>[25]</sup>;  $T_N$  为真阴性, 表示状态监测为负, 实际为负的个数。

#### 3.3 数据集实验结果和分析

根据本文方法对 PLAID 数据集和 WHITED 数据集的电压和电流进行处理得到基波信息和谐波信息, 再根据谐波电流的幅值选出最大谐波电流, 其中 PLAID 数据集中每个设备的最大谐波电流都是三次谐波电流, WHITED 数据集中每个设备的最大谐波电流除了空调和洗衣机是五次谐波电流其他设备都是三次谐波电流。之后以基波电压为基准分别与基波电流和最大谐波电流绘制出 PLAID 数据集的  $V_1-I_1$  轨迹图像和  $V_1-I_{h_{max}}$  轨迹图像, 总共有 3572 个样本, 分别如图 5 和图 6 所示; WHITED 数据集的  $V_1-I_1$  轨迹图像和  $V_1-I_{h_{max}}$  轨迹图像, 总共有 2110 个样本, 分别如图 7 和图 8 所示。

从图 5 中可以看到, 使用  $V_1-I_1$  轨迹可以对大部分负载进行区分, 但是对于工作原理相似且轨迹形状相似的负载来说使用  $V_1-I_1$  轨迹难以进行有效的区分。比如图 5 中的吹风机和加热器, 就是工作原理相似且轨迹形状相似, 这使得很难对这两个设备进行准确分类。但是根据图 6 可以看出, 吹风机和加热器绘制出来的  $V_1-I_{h_{max}}$  轨迹图像是有区别的, 可以用作辅助特征来区分原轨迹图像类似的设备。对于 WHITED 数据集, 风扇、吹风机、加热器和白炽灯这 4 个非线性负载绘制出来的  $V_1-I_1$  轨迹图像是相似的, 但是根据图 8 结合最大谐波电流绘制出来的

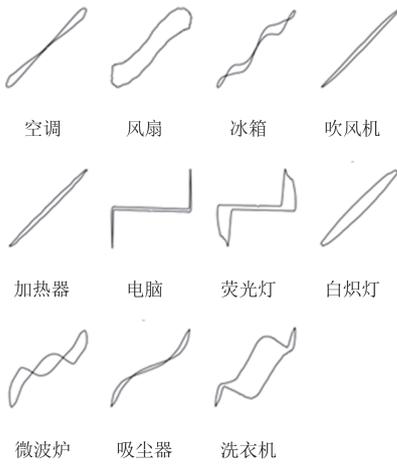


图 5 PLAID 数据集的  $V_1-I_1$  轨迹图像

Fig. 5  $V_1-I_1$  trajectory images for PLAID dataset

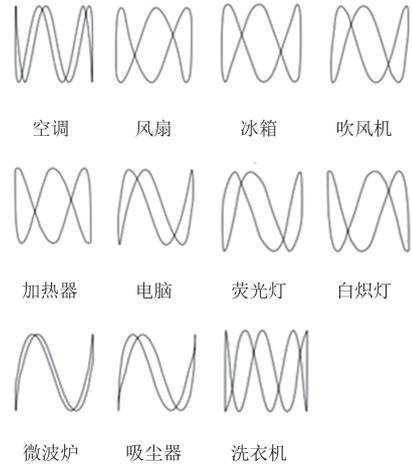


图 8 WHITED 数据集的  $V_1-I_{h \max}$  轨迹图像

Fig. 8  $V_1-I_{h \max}$  trajectory images for WHITED dataset

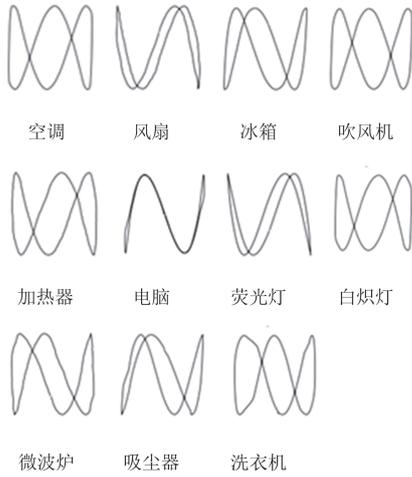


图 6 PLAID 数据集的  $V_1-I_{h \max}$  轨迹图像

Fig. 6  $V_1-I_{h \max}$  trajectory images for PLAID dataset

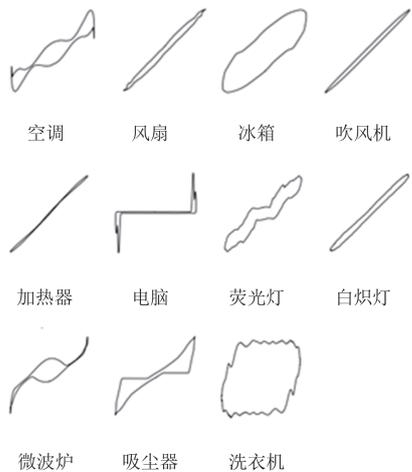


图 7 WHITED 数据集的  $V_1-I_1$  轨迹图像

Fig. 7  $V_1-I_1$  trajectory images for WHITED dataset

$V_1-I_{h \max}$  轨迹是有差别的, 可以将其作为辅助特征来进行负荷识别分类。

根据第 2 节的 2D-CNN 神经网络模型的输入层大小为  $128 \times 128 \times 1$ , 需要将上述构建的轨迹图像大小进行调整以匹配网络的输入维度<sup>[27]</sup>。模型中采用的是 Adam 优化器进行训练, 其中初始学习率为 0.0001, 训练次数为 4 次, 丢弃率为 1/6, 将训练过程中的批次处理数量设置为 100。从 PLAID 数据集里面的 3572 个数据随机选取 75% 为训练集, 剩下 25% 为测试集, 同样 WHITED 数据集里面的 2110 个数据随机选取 75% 为训练集, 剩下 25% 为测试集, 并将两个数据集的训练集投入神经网络模型中进行训练。图 9 和图 10 分别展示了 PLAID 训练集和 WHITED 训练集 的识别准确率和损失值随迭代次数的变化情况。可以清晰地观察到, 随着迭代次数的增加, 训练集的准确率逐步提高, 而损失函数值持续减小。特别是在迭代次数达到 300 次时, 训练准确率和损失函数值的变化趋势都逐渐稳定<sup>[17]</sup>, 变化幅度变小。

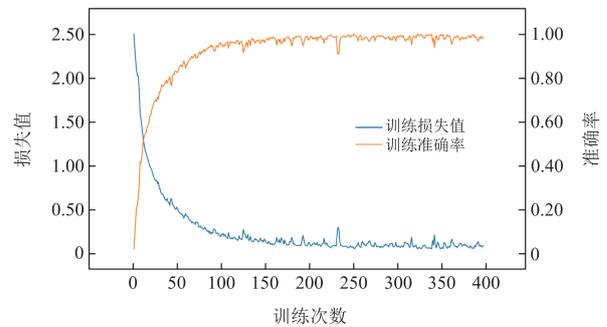


图 9 PLAID 训练集的训练结果

Fig. 9 Training results of PLAID training set

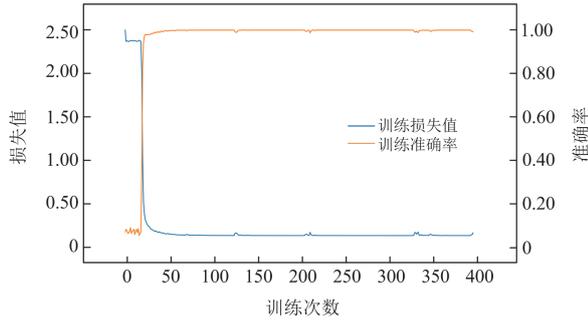


图 10 WHITED 训练集的训练结果

Fig. 10 Training results of WHITED training set

为评估本文所提算法的准确性, 采用 3.2 节所描述的混淆矩阵对测试集进行分类识别并进行评价。在这个算例中, 使用了一个  $11 \times 11$  的混淆矩阵, 它清晰地展示了被错误分类的情况。混淆矩阵中的行代表的是家用电器真实类别, 列代表的是预测类别<sup>[16]</sup>, 对角线上代表的是设备被正确分类的情况, 非对角线上则代表被错误分类的情况。通过观察图 11 和图 12 中的混淆矩阵可以清晰地看出, PLAID 数据集与 WHITED 数据集在原有  $V-I$  轨迹的基础上加了  $V-I_{h \max}$  轨迹的实验结果。PLAID 数据集中吹风机和加热器都被正确分类, 但是空调、风扇和冰箱这 3 个负载预测结果容易与其他设备发生混淆; 在 WHITED 数据集中白炽灯的预测结果容易与吹风机产生混淆, 其他设备都被正确分类。

为了进一步验证该方法的优越性, 引入文献[16-17]对 PLAID 数据集中  $F_1$  指数进行对比, 如表 2 所示。表 2 中对比了文献[16]提出的在  $V-I$  轨迹右侧加上高次谐波电流、文献[17]提出的在彩色  $V-I$  轨迹右侧加上谐波特征方法和本文方法中各个电器的

空调	101	0	0	0	0	0	0	0	0	0	1
荧光灯	0	115	0	0	0	0	0	0	0	0	0
风扇	0	0	109	1	0	0	0	0	0	0	0
冰箱	1	0	0	53	0	0	0	0	0	0	0
吹风机	0	0	0	0	123	0	0	0	0	0	0
加热器	0	0	0	0	0	43	0	0	0	0	0
白炽灯	0	0	0	0	0	0	78	0	0	0	0
电脑	0	0	0	0	0	0	0	89	0	0	0
微波炉	0	0	0	0	0	0	0	0	100	0	0
吸尘器	0	0	0	0	0	0	0	0	0	42	0
洗衣机	0	0	0	0	0	0	0	0	0	0	37

空调 荧光灯 风扇 冰箱 吹风机 加热器 白炽灯 电脑 微波炉 吸尘器 洗衣机

图 11 PLAID 数据集的实验结果

Fig. 11 Experimental results of PLAID dataset

空调	53	0	0	0	0	0	0	0	0	0	0
荧光灯	0	37	0	0	0	0	0	0	0	0	0
风扇	0	0	20	0	0	0	0	0	0	0	0
冰箱	0	0	0	67	0	0	0	0	0	0	0
吹风机	0	0	0	0	60	0	0	0	0	0	0
加热器	0	0	0	0	0	60	0	0	0	0	0
白炽灯	0	0	0	0	1	0	59	0	0	0	0
电脑	0	0	0	0	0	0	0	48	0	0	0
微波炉	0	0	0	0	0	0	0	0	37	0	0
吸尘器	0	0	0	0	0	0	0	0	0	33	0
洗衣机	0	0	0	0	0	0	0	0	0	0	53

空调 荧光灯 风扇 冰箱 吹风机 加热器 白炽灯 电脑 微波炉 吸尘器 洗衣机

图 12 WHITED 数据集的实验结果

Fig. 12 Experimental results of WHITED dataset

$F_1$  指数, 可以明显地看出本文方法相比较另外两种方法平均  $F_1$  指数明显提高, 相比于文献[16]  $F_1$  指数提高了 6.4%, 相比于文献[17]  $F_1$  指数提高了 4.1%。本文方法中低于平均  $F_1$  指数的设备类别有空调、冰箱、风扇和洗衣机, 其中将空调错判为洗衣机是因为空调有多种工作状态, 其中的加热模式与洗衣机里面的高温模式有相似之处, 容易产生混淆; 将冰箱错判为空调是因为在制冷这一方面有相似的地方, 并且冰箱里面有冷却风扇使得设备风扇容易被错认为冰箱; 其余电器设备的  $F_1$  指数都达到了 100%。

表 2 3 种方法各种电器  $F_1$  指数对比Table 2 Comparison of  $F_1$  scores for various appliances

负荷类型	with three methods		
	$V-I$ 谐波电流	混合彩色图像	本文方法
空调	90.5	92.7	99.0
荧光灯	98.1	100	100
冰箱	88.5	81.0	98.1
风扇	94.0	97.4	99.5
吹风机	92.9	97.5	100
加热器	97.0	92.7	100
白炽灯	89.7	97.4	100
电脑	89.7	100	100
微波炉	97.4	97.4	100
吸尘器	97.3	100	100
洗衣机	90.4	94.7	98.7
平均	93.2	95.5	99.6

为了进一步验证本文模型与算法的有效性, 将所提方法与其他文献的先进方法进行对比。其中文献[15]使用的负荷特征是灰度  $V-I$  轨迹图片, 并应用 2D-CNN 网络模型进行分类。文献[16]提出了基于  $V-I$  轨迹矩阵和高次谐波电流特征融合的负荷辨识

方法,使用的也是 2D-CNN 神经网络模型。文献[26]采用 RGB 颜色编码方法处理  $V-I$  轨迹,并使用 AlexNet 模型进行负荷辨识。文献[17]在文献[16]的基础上使用  $V-I$  轨迹特征的颜色编码,运用 AlexNet 网络进行训练和分类。不同于文献[16-17]将谐波特征加在  $V-I$  轨迹的右侧,文献[18]将谐波特征以编码的形式融入  $V-I$  轨迹中,并使用 2D-CNN 模型对图片进行训练和测试。各负荷识别方法与准确率的对比如表 3 所示。在特征选取方面,本文直接选择基波电压与基波电流绘制的  $V_1-I_1$  轨迹图像和从谐波电流中选取最具有代表性的最大谐波电流与基波电压绘制的  $V_1-I_{h\max}$  轨迹图像作为负荷特征。不同于其他文献将谐波特征加在原  $V-I$  轨迹的右侧或者

直接以编码的形式融入  $V-I$  轨迹中,本文的方法不仅降低了图像的复杂度还丰富了负荷特征。在分类模型选择方面,选用文献[15-16,18]使用的 2D-CNN 模型结构,并且相比于文献[17,26]使用的 AlexNet 模型,本文使用的轨迹图像复杂度低,不需要采取复杂的 AlexNet 模型来进行负荷分类。因此结合特征提取和分类模型两方面的改进,本文方法的分类效果要优于其他 5 个方法。在 PLAID 数据集上,本文方法相比于其他 5 种负荷识别算法,识别准确率分别提高了 14.06%、6.46%、4.6%、4.16%和 2.66%;在 WHITED 数据集上,本文方法相比于其他两种负荷识别算法,识别准确率分别提高了 8.81%和 2.05%。

表 3 本文方法与现有方法的比较

Table 3 Comparison between the proposed method and existing methods

参考文献	负荷特征	训练模型	PLAID 数据集的准确率/%	WHITED 数据集的准确率/%
[15]	$V-I$	2D-CNN	85.00	91.00
[16]	$V-I$ + 谐波电流	2D-CNN	93.20	—
[26]	彩色 $V-I$	AlexNet	95.06	97.76
[17]	混合彩色图像	AlexNet	95.50	—
[18]	彩色 $V-I$ + 谐波特征	2D-CNN	97.00	—
本文	$V_1-I_1 + V_1-I_{h\max}$	2D-CNN	99.66	99.81

## 4 结论

针对负荷识别仅仅用基波电压与基波电流形成的  $V_1-I_1$  轨迹图在两个公开数据集上有许多同类设备或异类设备难以分类的问题,本文提出了一种基于多  $V-I$  轨迹融合的非侵入式负荷识别方法。在基波电压与基波电流形成的  $V_1-I_1$  轨迹图像的基础上,添加了基波电压与最大谐波电流  $V_1-I_{h\max}$  轨迹图像,并使用 2D-CNN 网络实现负荷识别,采用 PLAID 和 WHITED 两个高频数据集验证本文方法。相较于传统方法,添加了基波电压与最大谐波电流构建的  $V_1-I_{h\max}$  轨迹图像,能够增大不同类型设备间  $V_1-I_1$  轨迹的形状差异,并且结合了谐波电流的信息,可以更全面地进行负载检测。与目前其他以  $V-I$  轨迹进行识别的方法相比,本文所提方法明显地提高了精度,证明了本文方法的优越性。

## 参考文献

- [1] 严萌,于雅雯,王玲静,等. 基于多特征联合稀疏表达的 SOM-K-means 非侵入负荷辨识[J]. 电力建设, 2023, 44(5): 61-71.  
YAN Meng, YU Yawen, WANG Lingjing, et al. SOM-K-means non-intrusive load identification based on multi feature joint sparse expression[J]. Electric Power Construction, 2023, 44(5): 61-71.
- [2] 高敏,朱明星,张华赢,等. 基于无相位谐波监测数据的

- 谐振源辨识方法[J]. 电力系统保护与控制, 2024, 52(4): 166-175.
- GAO Min, ZHU Mingxing, ZHANG Huaying, et al. Resonance source identification method based on phase-free harmonic monitoring data[J]. Power System Protection and Control, 2024, 52(4): 166-175.
- [3] HART G W. Non-intrusive appliance load monitoring[J]. Proceedings of the IEEE, 1992, 80(12): 1870-1891.
- [4] 徐崇钧,于鹤洋,朱琪,等. 基于多元特征分析的居民非侵入式相似电器辨识算法[J]. 电力系统保护与控制, 2023, 51(13): 111-121.  
XU Chongjun, YU Heyang, ZHU Qi, et al. Non-intrusive identification algorithm of residents' similar electrical appliances based on multivariate feature analysis[J]. Power System Protection and Control, 2023, 51(13): 111-121.
- [5] ZOHA A, GLUHAK A, IMRAN M A, et al. Non-intrusive load monitoring approaches for disaggregated energy sensing: a survey[J]. Sensors, 2012(12): 16838-16866.
- [6] WANG L, CHEN X, WANG G, et al. Non-intrusive load monitoring algorithm based on features of V-I trajectory[J]. Electric Power Systems Research, 2018, 157: 134-144.
- [7] GAO J, 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, USA.
- [8] 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.
- [9] DE BAETS L, RUYSSINCK J, DEVELDER C, et al.

- Appliance classification using VI trajectories and convolutional neural networks[J]. *Energy and Buildings*, 2018, 158: 32-36.
- [10] FAUSTINE A, LUCAS P, CHRISTOPH K. Adaptive weighted recurrence graphs for appliance recognition in non-intrusive load monitoring[J]. *IEEE Transactions on Smart Grid*, 2020, 12(1): 398-406.
- [11] 郇嘉嘉, 汪超群, 洪海峰, 等. 基于图像编码与深度学习的非侵入式负荷识别方法[J]. *科学技术与工程*, 2021, 21(21): 8901-8908.  
HUAN Jiajia, WANG Chaoqun, HONG Haifeng, et al. Non-intrusive load monitoring method based on color encoding and deep learning[J]. *Science Technology and Engineering*, 2021, 21(21): 8901-8908.
- [12] LOUKAS E P, BODURRI K, EVANGELOPOULOS P, et al. A machine learning approach for NILM based on odd harmonic current vectors[C] // 2019 8th International Conference on Modern Power Systems (MPS), May 21-23, 2019, Cluj-Napoca, Cluj, Romania: 1-6.
- [13] 涂京, 周明, 宋旭帆, 等. 基于监督学习的非侵入式负荷监测算法比较[J]. *电力自动化设备*, 2018, 38(12): 128-134.  
TU Jing, ZHOU Ming, SONG Xufan, et al. Comparison of supervised learning-based non-intrusive load monitoring algorithms[J]. *Electric Power Automation Equipment*, 2018, 38(12): 128-134.
- [14] 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.
- [15] 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.
- [16] 裘星, 尹仕红, 张之涵, 等. 基于 V-I 轨迹与高次谐波特征的非侵入式负荷识别方法[J]. *电力工程技术*, 2021, 40(6): 34-42.  
QIU Xing, YIN Shihong, ZHANG Zhihan, et al. Non-intrusive load identification method based on V-I trajectory and high-order harmonic feature[J]. *Electric Power Engineering Technology*, 2021, 40(6): 34-42.
- [17] 宰州鹏, 赵升, 朱翔鸥, 等. 基于颜色编码与谐波特征融合的非侵入式负荷识别方法[J]. *电气技术*, 2022, 23(12): 9-16.  
ZAI Zhoupeng, ZHAO Sheng, ZHU Xiangou, et al. Non-intrusive load monitoring based on color coding and harmonic feature fusion[J]. *Electrical Engineering*, 2022, 23(12): 9-16.
- [18] 班昭. 面向家居负荷的非侵入式负荷辨识方法研究[D]. 石家庄: 河北科技大学, 2023.  
BAN Zhao. Research on non-intrusive load identification method for home load[D]. Shijiazhuang: Hebei University of Science and Technology, 2023.
- [19] 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 based on color encoding[J]. *Power System Technology*, 2022, 46(4): 1557-1567.
- [20] 许仪勋, 李旺, 李东东, 等. 基于改进鸡群算法的非侵入式家电负荷分解[J]. *电力系统保护与控制*, 2016, 44(13): 27-32.  
XU Yixun, LI Wang, LI Dongdong, et al. Disaggregation for non-invasive domestic appliances based on the improved chicken swarm optimization algorithm[J]. *Power System Protection and Control*, 2016, 44(13): 27-32.
- [21] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. *Communications of the ACM*, 2017, 60(6): 84-90.
- [22] HAO W, BIE R, GUO J, et al. Optimized CNN based image recognition through target region selection[J]. *Optik*, 2018, 156: 772-777.
- [23] 姚芳, 汤俊豪, 陈盛华, 等. 基于 ISSA-CNN-GRU 模型的电动汽车充电负荷预测方法[J]. *电力系统保护与控制*, 2023, 51(16): 158-167.  
YAO Fang, TANG Junhao, CHEN Shenghua, et al. Charging load prediction method for electric vehicles based on an ISSA-CNN-GRU model[J]. *Power System Protection and Control*, 2023, 51(16): 158-167.
- [24] GAO J, GIRI S, KARA E C, et al. PLAID: a public dataset of high-resolution electrical appliance measurements for load identification research: demo abstract[C] // Proceedings of the 1st ACM Conference on Embedded Systems for Energy-Efficient Buildings, 2014, New York, NY, USA: 198-199.
- [25] 郇嘉嘉, 汪超群, 洪海峰, 等. 基于双通道多特征融合的电力负荷智能感知方法[J]. *科学技术与工程*, 2021, 21(13): 5360-5368.  
HUAN Jiajia, WANG Chaoqun, HONG Haifeng, et al. Intelligent power load identification method based on dual-channel and multi-feature fusion[J]. *Science Technology and Engineering*, 2021, 21(13): 5360-5368.
- [26] LIU Y, WANG X, YOU W. Non-intrusive load monitoring by voltage-current trajectory enabled transfer learning[J]. *IEEE Transactions on Smart Grid*, 2019, 10(5): 5609-5619.
- [27] 李成华, 邹堰辉, 江小平, 等. 基于多维数据图像化的非侵入式负荷识别[J]. *华中科技大学学报(自然科学版)*, 2023, 51(5): 119-124.  
LI Chenghua, ZOU Yanhui, JIANG Xiaoping, et al. Non-intrusive load recognition based on multi-dimensional data visualization[J]. *Journal of Huazhong University of Science and Technology (Natural Science Edition)*, 2023, 51(5): 119-124.

收稿日期: 2024-05-28; 修回日期: 2024-07-31

作者简介:

程志友(1972—), 男, 博士, 教授, 研究方向为智能系统设计及应用; E-mail: czy@ahu.edu.cn

胡乐乐(2000—), 女, 通信作者, 硕士研究生, 研究方向为非侵入式负荷识别。E-mail: 714678007@qq.com

(编辑 魏小丽)