

## 基于格拉姆角差场图像编码的非侵入式负荷识别方法

符明\*, 段斌

湘潭大学自动化与电子信息学院, 湖南 湘潭 411105

**摘要** 非侵入式负荷监测作为家庭用电精细化管理的重要手段,对推进节能减排、实现“双碳”目标具有积极作用。然而,利用原始电压-电流轨迹图像特征很难实现高精度负荷识别。因此,提出了一种基于格拉姆角差场(GADF)图像编码的非侵入式负荷识别方法。首先,对设备采集到的高频稳态数据进行预处理,获得一个完整基波周期电流和电压信号。然后,利用GADF分别对一维电压和电流信号进行图像编码,生成相对应的二维图像。最后,通过叠加融合输入到卷积块注意力模型中完成负荷识别。为了验证所提方法的有效性,利用公共数据集PLAID和WHITED进行实验分析。结果表明,该方法具有很高的识别精度,PLAID数据集平均识别准确率达到99.45%,WHITED数据集平均识别准确率达到99.24%。

**关键词** 图像处理; 非侵入式负荷识别; 深度学习; 卷积块注意力模型; 格拉姆角差场

中图分类号 TM714

文献标志码 A

DOI: 10.3788/LOP230716

## Non-Intrusive Load Identification Method Based on Gramian Angular Difference Field Image Coding

Fu Ming\*, Duan Bin

*School of Automation and Electronic Information, Xiangtan University, Xiangtan 411105, Hunan, China*

**Abstract** Non-intrusive load monitoring, as an essential means for fine-grained management of household electricity consumption, plays a significant role in promoting energy conservation and emission reduction for achieving the dual-carbon goal. However, it is challenging to achieve high-precision load identification using a single voltage-current trajectory image. Therefore, a non-intrusive load identification method based on the fusion of Gramian angular difference field (GADF) image coding is proposed. First, the high-frequency steady-state data collected by the device are preprocessed to obtain a complete base-wave period current and voltage signal. Then, the one-dimensional voltage and current signals are encoded separately using the GADF to generate the corresponding two-dimensional feature images, and load identification is performed via superimposed fusion input to a neural network based on a convolutional block attention module. The public datasets PLAID and WHITED are used for testing experiments to verify the effectiveness of the proposed method. The results indicate that the method has a high recognition accuracy, with average accuracies of 99.45% and 99.24% for the PLAID and WHITED datasets, respectively.

**Key words** image processing; non-intrusive load identification; deep learning; convolutional block attention module; Gramian angular difference field

## 1 引言

“双碳”目标驱动下,电力行业正面临新一轮改革,需全面向绿色低碳化转型。而转型最重要的途径就是加强需求侧精细化管理,非侵入式负荷监测(NILM)作为智能电网需求侧精细化管理的关键技术之一<sup>[1-2]</sup>,通过智能电表采集的数据实时监测用户各电器的类

型、运行状态和能耗情况等信息,为用户优化自身用电模式提供决策依据,引导用户合理减少家庭用电量,提高家庭用电效率,推进节能减排,助力实现“碳达峰”和“碳中和”<sup>[3]</sup>。

非侵入式负荷识别作为NILM的重要子任务之一,包含两个关键步骤:特征提取和负荷分类<sup>[4-5]</sup>。早期计算机处理能力和存储容量有限,而且电表采样频

收稿日期: 2023-02-27; 修回日期: 2023-03-26; 录用日期: 2023-04-04; 网络首发日期: 2023-04-14

基金项目: 湖南省自然科学基金(2020JJ6034)

通信作者: \*fuming\_xtu@163.com

率很低,通常为 1 Hz 或更低。因此,早期国内外学者主要基于低频采样数据开展研究,通过分析频率、电压和电流等特征识别电器运行状态及类型<sup>[6-7]</sup>。然而,低频采样数据中缺乏足够的细节信息,使得负荷识别性能受到严重影响<sup>[8]</sup>。

随着深度学习技术的不断发展以及高频数据获取难度和成本大幅降低,从高频稳态或暂态数据中提取细粒度特征进行非侵入式负荷识别的研究越来越多。例如,文献[9-11]分别采用电流谐波、稳态视在功率和瞬态功率波形作为负荷特征进行非侵入式负荷识别,并用实际数据集验证了细粒度特征有助于提升识别准确率。此外,一些学者利用电压-电流(V-I)轨迹来描述电器的特性。例如,文献[12]详细解释了可由 V-I 轨迹描述的物理特性,并验证了不同类型的负荷能通过 V-I 轨迹表征其独有的形状特征,获得较好的负荷识别效果。文献[13]提出了一种基于特征融合与深度学习的负荷辨识方法,在 V-I 轨迹中融入功率特征,解决了 V-I 轨迹无法体现电器功率大小的问题,提升了多状态负荷辨识能力。文献[14]先利用 K-means 聚类算法进行初步分类,然后将颜色编码后的 V-I 轨迹特征输入到 AlexNet 神经网络进行负荷精细化分类。上述研究表明 V-I 轨迹及其二维图像能有效地用于非侵入式负荷识别,且能利用深度学习算法提取到更深层次的特征来提升负荷识别的整体性能。

尽管上述方法已成功将 V-I 轨迹图像应用于非侵入式负荷识别,但 V-I 轨迹图像主要由归一化后的电压和电流绘制而成,而部分电器的工作电压和工作电流相近,这使得其 V-I 轨迹图像存在重叠现象,难以识别。为增强负荷印记的唯一性,本文引入格拉姆角差场(GADF)分别对电压和电流信号进行图像编码并叠加融合,输入到基于卷积块注意力模型(CBAM)的神经网络中完成负荷识别。该方法充分利用 CBAM 在图像分类领域的强大优势,有效提升负荷识别准确率。基于公共数据集 PLAID 和 WHITED 进行实验分析,验证了所提方法的有效性。

## 2 基于 GADF 图像编码的负荷印记构建

### 2.1 数据获取与预处理

负荷识别作为基于事件的 NILM 方法的关键步骤,首先要检测电器投切事件并获取每个电器的工作电压和工作电流数据。借鉴文献[15-17]方法,假设同一时刻只有一个电器发生投切事件,并根据有无功率变化检测电器投切事件,从事件前后的稳态聚合数据中获取每个电器的稳态电压、电流数据。

当电器稳定运行时,其电压和电流波形趋于稳定且呈周期性变化。所以单个基波周期的稳态电压、电流信号就能表征电器的负载特性。但电器稳定工作时,其状态仍可能存在微小的变化。为了更准确地描

述电器的负载特性,采用一种求平均的方法,通过提取事件前后连续  $N_t$  个基波周期的稳态电压、电流信号,并求其平均值,得到一个完整基波周期的稳态电压、电流信号。这种方法既能减少测量中的随机误差,又能提高对电器负载特性的描述精度<sup>[18]</sup>。此外,在稳态条件下电流和电压之间的相位差是固定的,所以通过在电压正过零点处对齐稳态电流信号的波形,可以实现对稳态电流信号和电压信号的相位同步,便于分析二者之间的关系<sup>[8,15]</sup>。

首先假设电器稳态电压、电流信号的采样频率为  $f_s$ , 基波频率为  $f$ , 则每个基波周期样本数量为  $N_s = f_s/f$ ,  $N_t$  个基波周期的样本数量为  $N_{ts} = N_t \times N_s$ , 电器  $k$  的  $N_t$  个基波周期稳态电压信号  $\mathbf{v}_k = [v_{1k}, v_{2k}, \dots, v_{N_s k}]$  和稳态电流信号  $\mathbf{i}_k = [i_{1k}, i_{2k}, \dots, i_{N_s k}]$ 。然后,让  $\mathbf{v}_k, \mathbf{i}_k$  在  $\mathbf{v}_k$  每个基波周期正过零点处对齐,得到对齐后的稳态电压信号  $\tilde{\mathbf{V}}_k$  和稳态电流信号  $\tilde{\mathbf{I}}_k$ 。最后,对  $\tilde{\mathbf{V}}_k$  和  $\tilde{\mathbf{I}}_k$  的每列求平均值,得到一个完整基波周期的稳态电压信号  $\bar{\mathbf{v}}_k = [\bar{v}_{1k}, \bar{v}_{2k}, \dots, \bar{v}_{N_s k}]$  和电流信号  $\bar{\mathbf{i}}_k = [\bar{i}_{1k}, \bar{i}_{2k}, \dots, \bar{i}_{N_s k}]$ 。  $\tilde{\mathbf{V}}_k, \tilde{\mathbf{I}}_k$  可表示为

$$\tilde{\mathbf{V}}_k = \begin{bmatrix} \tilde{v}_{1k} & \tilde{v}_{2k} & \dots & \tilde{v}_{N_s k} \\ \tilde{v}_{(N_t+1)k} & \tilde{v}_{(N_t+2)k} & \dots & \tilde{v}_{(2N_t)k} \\ \vdots & \vdots & & \vdots \\ \tilde{v}_{(N_t-N_s+1)k} & \tilde{v}_{(N_t-N_s+2)k} & \dots & \tilde{v}_{N_s k} \end{bmatrix}_{N_t \times N_s}, \quad (1)$$

$$\tilde{\mathbf{I}}_k = \begin{bmatrix} \tilde{i}_{1k} & \tilde{i}_{2k} & \dots & \tilde{i}_{N_s k} \\ \tilde{i}_{(N_t+1)k} & \tilde{i}_{(N_t+2)k} & \dots & \tilde{i}_{(2N_t)k} \\ \vdots & \vdots & & \vdots \\ \tilde{i}_{(N_t-N_s+1)k} & \tilde{i}_{(N_t-N_s+2)k} & \dots & \tilde{i}_{N_s k} \end{bmatrix}_{N_t \times N_s}。 \quad (2)$$

### 2.2 负荷印记构建

格拉姆角场(GAF)是一种将一维时序信号编码为二维图像的编码方法<sup>[18]</sup>,该方法将一维时序信号的每个点分别映射到二维平面上的一个点,并通过计算这些点之间的内积得到格拉姆矩阵。该格拉姆矩阵保留时序信号的完整信息,也保持时序信号对时间的依赖性。将 GAF 理论引入到负荷识别中,利用 GADF 将一维电压、电流信号转换为二维图像,其中每个像素点的值表示两个时间点之间的角度差,这样可以捕捉到电压、电流信号在不同时间点上的变化。最后,将电压和电流的二维图像叠加融合构建独特的负荷印记,用于后续负荷分类。整个负荷印记构建流程如图 1 所示。

由图 1 可知,首先对预处理获得的  $\bar{\mathbf{v}}_k$  和  $\bar{\mathbf{i}}_k$  进行归一化处理,将其归一化至  $[-1, 1]$  范围内,具体可表示为

$$\hat{x}_i = \frac{[x_i - \max(\mathbf{X})] + [x_i - \min(\mathbf{X})]}{\max(\mathbf{X}) - \min(\mathbf{X})}, \quad (3)$$

式中:  $x_i$  为  $\bar{\mathbf{v}}_k$  或  $\bar{\mathbf{i}}_k$  中的第  $i$  个值;  $\hat{x}_i$  为  $x_i$  归一化后的值;

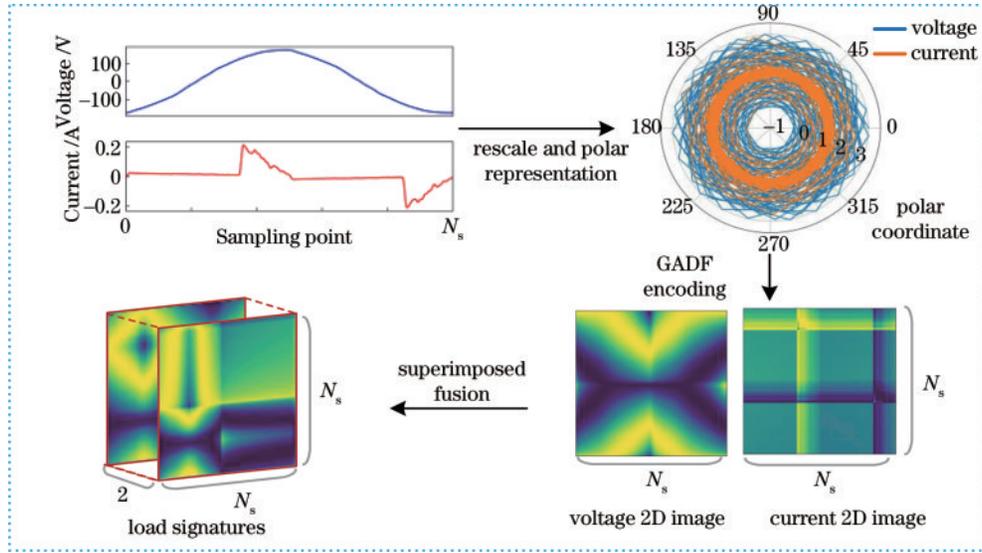


图1 负荷印记构建示意图

Fig. 1 Chart of load signatures construction

max 为求最大值函数; min 为求最小值函数;  $\mathbf{X}$  为电压或电流量。

然后, 将归一化后的  $\hat{x}_i$  从笛卡儿坐标系转换到极坐标系中, 即将其数值转换为极坐标系中的角余弦  $\phi$ , 将时间戳转换为极坐标系中的半径  $r$ , 转换公式可表示为

$$\begin{cases} \phi_i = \arccos \hat{x}_i, & -1 \leq \hat{x}_i \leq 1, \hat{x}_i \in \hat{\mathbf{X}} \\ r_i = \frac{t_i}{N}, & t_i \in N \end{cases}, \quad (4)$$

式中:  $\phi_i$  为极坐标系中第  $i$  个值的角余弦;  $r_i$  为极坐标系中第  $i$  个值的半径;  $t_i$  为第  $i$  个值的时间戳;  $N$  为正则化极坐标系产生的常数因子;  $\hat{\mathbf{X}}$  为包含  $N_s$  个归一化后的时序信号  $\hat{x}_i$  归一化后的电压或电流。

其次, 通过正弦函数对转换到极坐标系上的点作角度差获得 GADF 二维图像, GADF 二维图像的计算可表示为

$$\mathbf{f}_{\text{GADF}} = \begin{bmatrix} \sin(\phi_1 - \phi_1) & \cdots & \sin(\phi_1 - \phi_{N_s}) \\ \sin(\phi_2 - \phi_1) & \cdots & \sin(\phi_2 - \phi_{N_s}) \\ \vdots & & \vdots \\ \sin(\phi_{N_s} - \phi_1) & \cdots & \sin(\phi_{N_s} - \phi_{N_s}) \end{bmatrix} = \hat{\mathbf{X}} \sqrt{\mathbf{I} - (\hat{\mathbf{X}}^T)^2} - \hat{\mathbf{X}}^T \times \sqrt{\mathbf{I} - \hat{\mathbf{X}}^2}, \quad (5)$$

式中:  $\mathbf{f}_{\text{GADF}}$  为 GADF 的结果;  $\mathbf{I}$  为单位行向量;  $\hat{\mathbf{X}}^T$  为  $\hat{\mathbf{X}}$  的转置。

最后, 将电压、电流的 GADF 二维图像叠加融合, 生成一个大小为  $N_s \times N_s \times 2$  的三维特征图。为了减少负荷识别模型的计算量和内存占用, 同时提高模型的计算速度, 对特征图进行灰度化处理, 即将特征图每个像素点数值都乘以 256 并向下取整得到整数, 从而将浮点数值转换为整数。处理后的三维特征图作为负荷印记, 用于负荷分类。

### 3 基于 CBAM 的负荷识别模型

#### 3.1 卷积块注意力模型

卷积神经网络 (CNN) 凭借其强大的特征表达能力广泛应用于图像识别领域<sup>[19-20]</sup>。近年来, 部分学者为了提升 CNN 的性能从深度、宽度、基数和注意力模块等方面改进网络结构。将 CBAM 与 CNN 结合用于非侵入式负荷识别模型, 来提升负荷识别能力。CBAM 由通道注意力子模块和空间注意力子模块组成<sup>[21-22]</sup>, 能从空间和通道两个维度提取重要特征, 抑制不必要特征。

CBAM 属于轻量级注意力模块, 能与 CNN 无缝融合, 改进 CNN 特征提取能力, 引导 CNN 更好地捕捉图像中关键区域, 抑制背景和不必注意区域, 提升图像识别能力<sup>[21]</sup>。假设给定一个特征图  $\mathbf{F} \in \mathbf{R}^{C \times H \times W}$  作为输入, CBAM 可依次推断出一维通道注意力  $\mathbf{M}_c \in \mathbf{R}^{C \times 1 \times 1}$  和二维空间注意力  $\mathbf{M}_s \in \mathbf{R}^{1 \times H \times W}$ , 实现过程如图 2 所示, 整个注意力过程可表示为

$$\mathbf{F}' = \mathbf{M}_c(\mathbf{F}) \otimes \mathbf{F}, \quad (6)$$

$$\mathbf{F}'' = \mathbf{M}_s(\mathbf{F}') \otimes \mathbf{F}', \quad (7)$$

式中:  $\otimes$  为对应元素逐个相乘, 在乘法操作过程中, 通道注意值沿着空间维度广播, 空间注意力值则沿着通道维度广播;  $\mathbf{F}'$  为通道注意力输出;  $\mathbf{F}''$  为 CBAM 最终输出。

在 CBAM 的通道注意力模块中, 首先通过最大池化和平均池化分别对输入的特征图在空间维度进行压缩, 聚合得到两个不同的空间特征描述符 ( $\mathbf{F}_{\text{max}}^c, \mathbf{F}_{\text{avg}}^c$ )。然后将这两个空间特征描述符传递到由多层感知机组成的共享网络中生成通道注意力图  $\mathbf{M}_c \in \mathbf{R}^{C \times 1 \times 1}$ 。为了减少参数开销, 多层感知机的隐藏激活大小设置为  $\mathbf{R}^{C/r \times 1 \times 1}$ ,  $r$  为压缩比。通道注意力  $\mathbf{M}_c$  可表示为

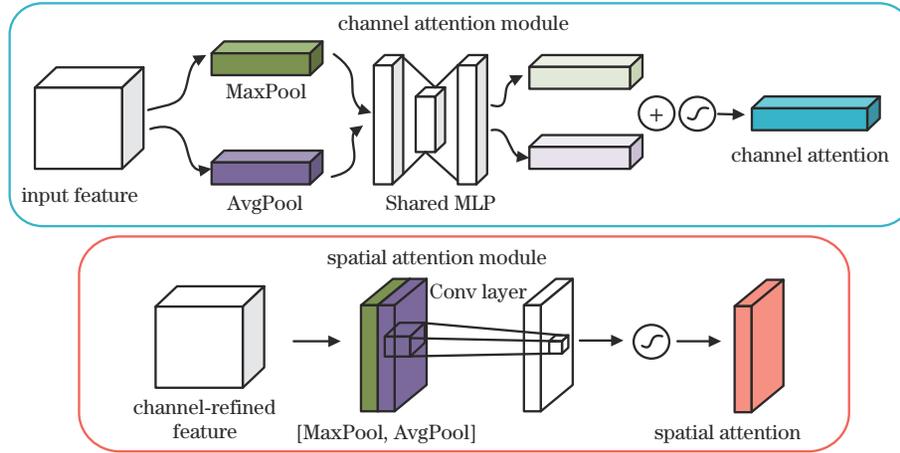


图2 CBAM注意力机制实现过程图

Fig. 2 Chart of CBAM attention mechanism implementation process

$$M_c(\mathbf{F}) = \sigma \left\{ \text{MLP} \left\{ \text{AvgPool}(\mathbf{F}) + \text{MLP} \left[ \text{MaxPool}(\mathbf{F}) \right] \right\} \right\} = \sigma \left\{ \mathbf{W}_1 \left[ \mathbf{W}_0(\mathbf{F}_{\text{avg}}^c) \right] + \mathbf{W}_1 \left[ \mathbf{W}_0(\mathbf{F}_{\text{max}}^c) \right] \right\}, \quad (8)$$

式中： $\sigma$ 为Sigmoid函数；MLP为多层感知机；AvgPool为平均池化；MaxPool为最大池化； $\mathbf{W}_0 \in \mathbf{R}^{(C/r) \times C}$ 、 $\mathbf{W}_1 \in \mathbf{R}^{C \times (C/r)}$ 为多层感知机的权值。

同样，空间注意力模块首先利用最大池化和平均池化在通道维度上对特征图进行压缩，生成两个二维特征图  $\mathbf{F}_{\text{max}}^s \in \mathbf{R}^{1 \times H \times W}$  和  $\mathbf{F}_{\text{avg}}^s \in \mathbf{R}^{1 \times H \times W}$ 。然后，将  $\mathbf{F}_{\text{max}}^s$  和  $\mathbf{F}_{\text{avg}}^s$  两个特征图进行拼接得到一个包含 2 个通道数的三维特征图  $\mathbf{F}_{\text{pool}}^{2 \times H \times W}$ 。紧接着利用卷积核大小为  $7 \times 7$  的卷积层对特征图  $\mathbf{F}_{\text{pool}}^{2 \times H \times W}$  进行卷积操作，得到二维特征图  $\mathbf{F}_{\text{Conv}}^{1 \times H \times W}$ ，最后输入到 Sigmoid 函数中生成二维空间注意力特征图  $\mathbf{M}_s \in \mathbf{R}^{H \times W}$ 。 $\mathbf{M}_s$  可表示为

$$M_s(\mathbf{F}) = \sigma \left\{ f^{7 \times 7} \left\{ \left[ \text{AvgPool}(\mathbf{F}); \text{MaxPool}(\mathbf{F}) \right] \right\} \right\} = \sigma \left\{ f^{7 \times 7} \left[ \mathbf{F}_{\text{avg}}^s; \mathbf{F}_{\text{max}}^s \right] \right\} \quad (9)$$

式中： $f^{7 \times 7}$ 为卷积层的卷积核大小为  $7 \times 7$ 。

### 3.2 负荷识别模型

基于 GADF 图像编码的负荷印记可以提供丰富的负荷特征信息，而 CBAM 能从通道和空间两个维度提取图像的关键信息。因此，设计了基于 CBAM 的神经网络从负荷印记中提取特征以实现负荷识别。其网络结构如图 3 所示，主要包括输入单元、残差单元和输出单元。

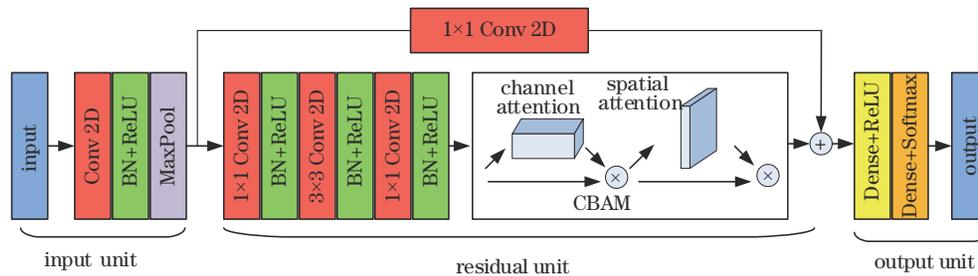


图3 负荷识别网络结构图

Fig. 3 Chart of load identification network structure

在输入单元中，先通过输入层输入大小为  $N_s \times N_s \times 2$  的负荷印记，再利用卷积层对负荷印记进行初步的特征提取，为了减少数据分布带来的影响，让卷积层提取的特征具有零均值和单位方差，在卷积层后添加批量归一化层，最后通过 1 个最大池化层来降低特征维度，进而减少后续单元的计算量，提升模型训练速度。

残差单元主要由恒等映射部分、残差部分和 CBAM 构成，在输入单元基础上进行深层次特征提取，具体可表示为

$$x_{l+1} = h(x_l) + F(x_l, \mathbf{W}_l), \quad (10)$$

式中： $h(x_l) = \mathbf{W}'_l x_l$ ， $\mathbf{W}'_l$  为恒等映射中的  $1 \times 1$  卷积操作，其主要用于调节输入输出的通道数； $F(x_l, \mathbf{W}_l)$  为残差部分的映射函数； $x_{l+1}$  为残差单元处理后得到的特征。

残差单元中的残差部分包括 1 个  $3 \times 3$  卷积层和 2 个  $1 \times 1$  卷积层，且每个卷积层后都会连接 1 个批量归一化层和 1 个 ReLU 激活函数。残差单元首先连接一个  $1 \times 1$  卷积层，通道数设置为 128；然后连接  $3 \times 3$  卷积层，通道数设置为 128，最后连接另一个  $1 \times 1$  卷积层，通道数设置为 512。恒等映射部分和残差部分提取的特征图通过逐像素相加操作进行融合。在残差

部分的最后一层  $1 \times 1$  卷积层接入 CBAM,使整个神经网络在提取负荷特征过程中专注于负荷印记中的重要区域信息,忽略无关区域信息,以增强整个网络特征学习能力,进而提升负荷识别任务性能。

输出单元主要由 2 个全连接层组成,是整个神经网络的最后一个单元,与残差单元相连。其全连接层神经元数量分别为 128 和  $K$ ,激活函数分别为 ReLU 函数和 Softmax 函数,其中  $K$  由电器种类数决定。

## 4 实验及结果分析

选择在公共数据集 PLAID 和 WHITED 上进行实验验证,其中 PLAID 数据集记录了美国宾夕法尼亚州匹兹堡 60 多个家庭的用电数据,最新版本 PLAID 2018 包含 17 种电器的 1876 组电压、电流数据,基波频率为 60 Hz,采样频率为 30 kHz;WHITED 数据集记录了世界各地 56 种电器的 1339 组电压、电流数据,基波频率为 50 Hz,采样频率为 44.1 kHz。PLAID 数据集具有较高的类内差异,而 WHITED 数据集具有较高的类间差异,使用这两个数据集可以更加全面评估所提方法的有效性和可行性。在实验过程中,计算硬件平台为 CPU Intel i7-9700K、GPU NVIDIA RTX 2080Ti、内存为 16 GB 的计算机,软件平台为 Windows 10 操作系统、Python 3.8 编程语言、深度学习框架 Keras 3.4.2 和 Tensorflow 2.4.0。

### 4.1 评价指标

为了更加全面地评估所提方法,采用混淆矩阵、准确率和 F1 分数等 3 种评价指标对负荷识别结果进行评估。混淆矩阵用于评估负荷识别整体效果,可以直观地展示负荷识别模型对各个类别的识别结果,每一行表示负荷的真实类别,每一列表示负荷的预测类别,对角线单元格的值表示负荷正确识别的结果,非对角线单元格的值表示负荷错误识别的结果。准确率用于评估负荷识别总体效果,其值大小为负荷正确识别实例数目与负荷总实例数目之比,准确率  $A_{acc}$  可表示为

$$A_{acc} = \frac{n_{true}}{n_{total}}, \quad (11)$$

式中:  $n_{true}$  为正确识别实例数目;  $n_{total}$  为负荷总实例数目。

F1 分数用于评估每种负荷类别的识别效果,可以平衡精确率  $P$  和召回率  $R$  并综合评估负荷识别方法, F1 分数可表示为

$$F_1 = \frac{2 \cdot P \cdot R}{P + R}, \quad (12)$$

$$P = \frac{T_p}{T_p + F_p}, \quad (13)$$

$$R = \frac{T_p}{T_p + F_N}, \quad (14)$$

式中:  $F_1$  为 F1 分数;  $T_p$  为真正例,即负荷实际上是正类,又被预测为正类的数量;  $F_p$  为假正例,即负荷实际上是负类,但被预测为正类的数量;  $F_N$  为真反例,即负荷实际上是正类,但被预测为负类的数量。

### 4.2 实验结果

选取 PLAID 和 WHITED 两个数据集中共同包含的 11 种电器作为实验分析对象,并通过 2.1 节中描述的方法对数据集进行预处理,分别获得 1824 组和 340 组样本实例。在实验分析过程中,发现这些样本实例存在数据不平衡的情况。由于数据不平衡可能会导致模型在训练过程中对数量较少的类别表现不佳,并容易出现过拟合的情况。因此,采用了一种基于支持向量机的过采样方法(SVMSMOTE)对数据进行过采样增强,以平衡两个数据集中不同类别的样本数量。最终,实验样本实例数量得到平衡,如图 4 所示。SVMSMOTE 能够在少数类样本之间进行插值,从而实现数据集的平衡。这种方法能够有效地提高模型的性能,并降低过拟合的风险<sup>[23]</sup>。

利用 2.2 节所述负荷印记构建方法生成负荷印记,并按 4:1 的比例随机划分训练集和测试集。在训练集中随机抽取 85% 的样本用于模型普通参数寻优,剩余 15% 的样本作为验证集,用于模型超参数调优。

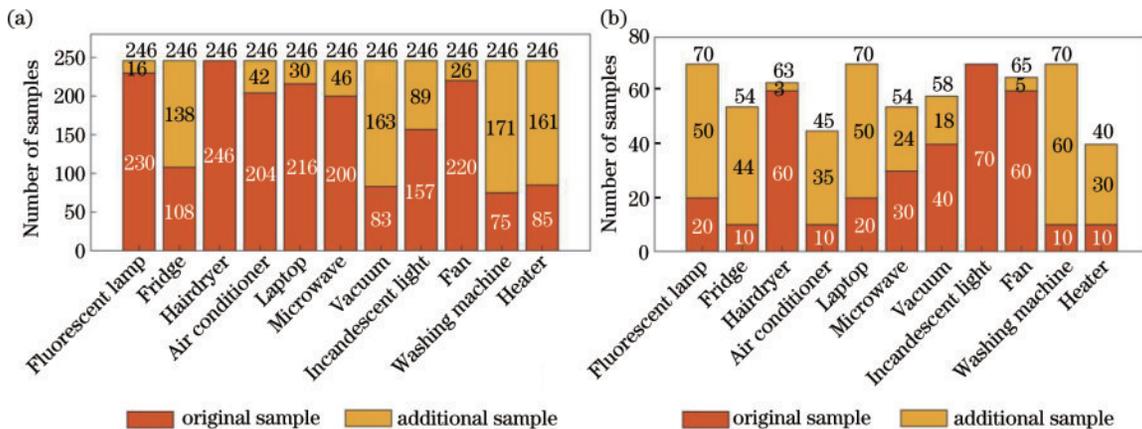


图 4 数据集中每种电器的样本数量。(a) PLAID 数据集; (b) WHITED 数据集

Fig. 4 Number of samples for each appliance in the dataset. (a) PLAID dataset; (b) WHITED dataset

使用 Adam 优化器训练模型, Batchsize 设置为 32, 训练次数为 50, 并引入 Early-Stopping 机制, 进一步降低过拟合的风险, 以获得最优负荷识别模型, 其训练过程如图 5 所示。训练得到最优负荷识别模型后, 使用测试集来评估模型性能, 获得最终测试结果, 混淆矩阵结果如图 6 所示。其中 PLAID 数据集平均准确率为 99.45%, 平均 F1 分数为 99.44%; WHITED 数据集平

均准确率 99.24%, 平均 F1 分数为 99.23%。由图 6 可知, PLAID 数据集除便携式计算机和洗衣机两个电器的识别率略低于平均准确率之外, 其他电器的识别准确率都达到了 100%; WHITED 数据集除洗衣机的识别率略低于平均准确率之外, 其他电器的识别准确率都达到了 100%。实验结果表明所提方法具有较高的识别性能。

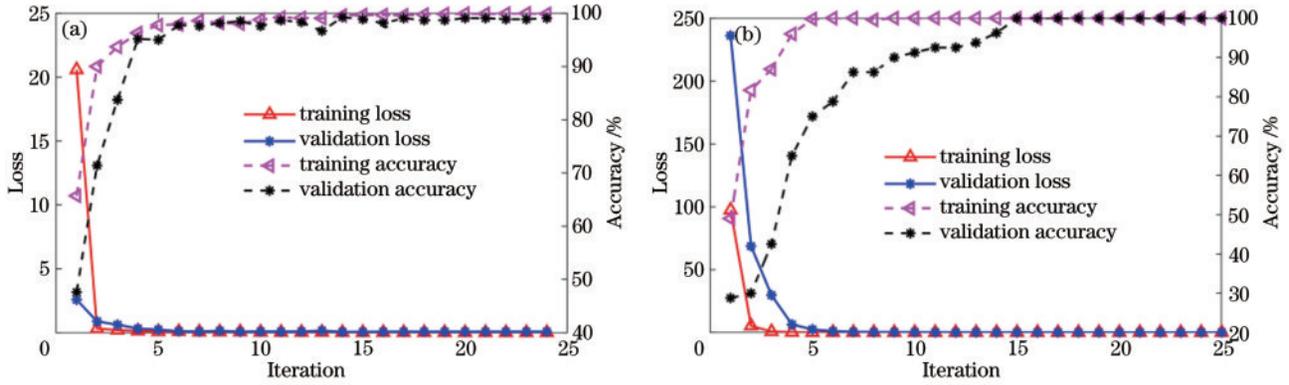


图 5 负荷识别模型训练过程。(a) PLAID 数据集; (b) WHITED 数据集

Fig. 5 Training process of load identification model. (a) PLAID dataset; (b) WHITED dataset

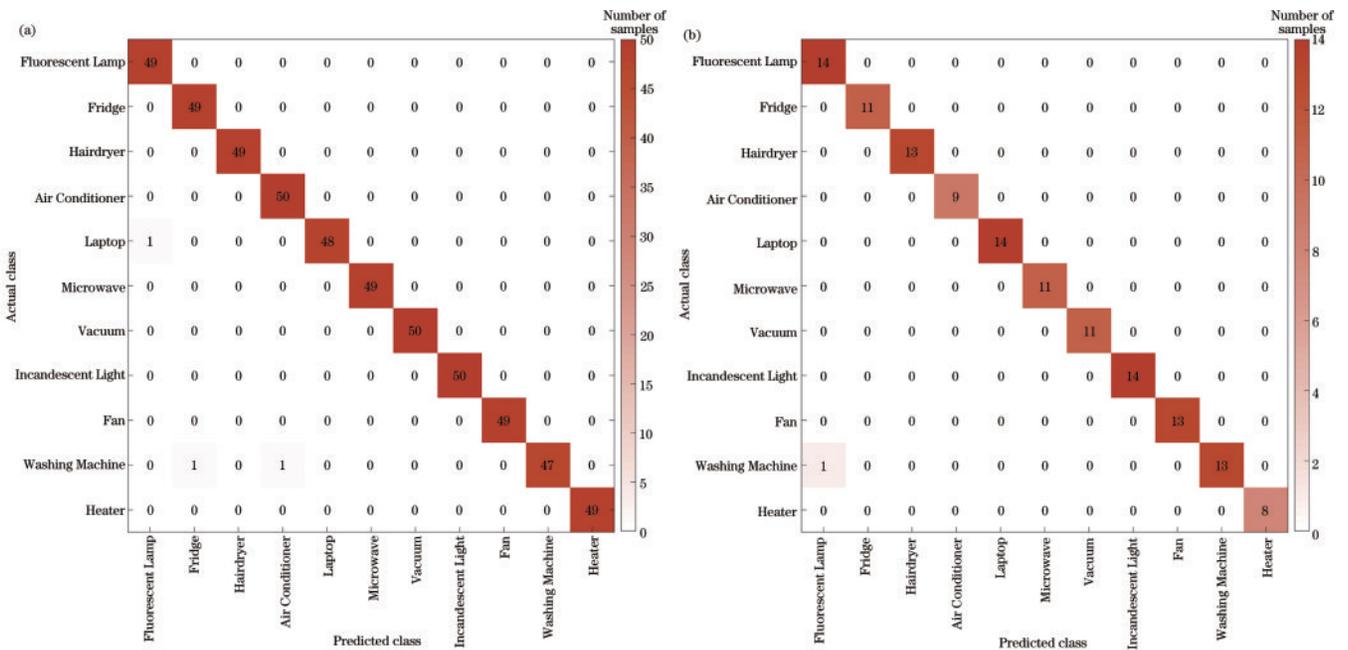


图 6 最终测试结果的混淆矩阵。(a) PLAID 数据集; (b) WHITED 数据集

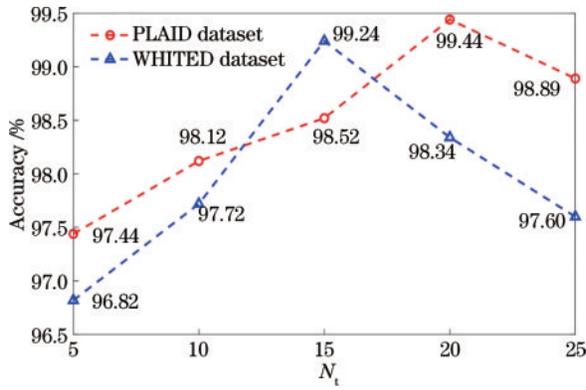
Fig. 6 Confusion matrix for the final test results. (a) PLAID dataset; (b) WHITED dataset

### 4.3 分析与讨论

为了进一步探究影响负荷识别性能的因素, 针对负荷识别模型中的关键要素设计对比实验进行深入分析与讨论。

在负荷识别数据获取和预处理过程中, 先提取  $N_i$  个基波周期的稳态电压、电流信号, 故  $N_i$  值大小的设置会影响到负荷识别最终性能。为此, 设计对比实验讨论  $N_i$  值对负荷识别效果的影响。将  $N_i$  分别设置为 5, 10, 15, 20, 25, 然后按照 2 节所述方法构建相应的负荷印记, 完成对比实验, 实验结果如图 7 所

示。由图 7 可知, 当  $N_i$  值较低时, 负荷印记包含的负荷细节信息不足, 无法充分反映负荷特性, 使得负荷识别准确率相对较低。当  $N_i$  值较高时, 负荷印记包含的负荷细节信息过多, 放大了负荷数据中的噪声, 导致负荷识别效果不佳。在 PLAID 数据集中,  $N_i = 20$  时负荷识别效果最优, 识别准确率达到 99.44%; 在 WHITED 数据集中,  $N_i = 15$  时负荷识别效果最优, 识别准确率达到 99.24%。因此, 最终将 PLAID 数据集的  $N_i$  值设置为 20, WHITED 数据集的  $N_i$  值设置为 15。

图 7 不同  $N_i$  值的负荷识别准确率Fig. 7 Experimental results for different  $N_i$  values

使用 GADF 对电压、电流信号进行编码,并采用叠加融合方式为每个电器构建了特定的负荷印记,在此基础上,利用基于 CBAM 的神经网络完成负荷识别任务。因此,有必要讨论分析所构建的负荷印记的有效性以及不同神经网络的负荷识别能力。在负荷特征方面,引入  $V-I$  轨迹进行对比实验, $V-I$  轨迹图像分辨率为  $128 \times 128$ ;在神经网络方面,引入两种经典的 CNN (ResNet-18<sup>[24]</sup> 和 LeNet-5<sup>[25]</sup>) 以及两种经典视觉注意力机制 (SE<sup>[26]</sup> 和 ECA<sup>[27]</sup>) 进行对比实验,实验结果如表 1 所示。由表 1 可知,基于 GADF 特征融合的负荷印记相较于  $V-I$  轨迹有更好的识别效果,识别准确率和 F1 分数都具有一定优势。

表 1 对比实验结果

Table 1 Comparison of experimental results

Model	Load signature	PLAID dataset		WHITED dataset	
		Accuracy / %	F1 score / %	Accuracy / %	F1 score / %
CBAM	$V-I$ image	95.16	95.11	97.55	97.56
	GADF image	99.45	99.44	99.24	99.23
ResNet-18	$V-I$ image	97.39	97.41	96.92	96.89
	GADF image	97.41	97.42	97.73	97.72
LeNet-5	$V-I$ image	95.53	95.52	96.15	96.12
	GADF image	96.43	96.44	96.24	96.24
SE	$V-I$ image	95.16	95.15	96.15	96.14
	GADF image	98.52	98.53	98.48	98.47
ECA	$V-I$ image	96.27	96.26	96.15	96.21
	GADF image	96.86	96.87	97.18	97.17

为了验证所提方法的优越性,选择与其他文献先进负荷识别方法进行对比。所有文献的实验均在 PLAID 数据集上开展,其中文献[13]将  $V-I$  轨迹图像与功率数值特征融合,并通过 BP 神经网络实现负荷识别。文献[14]使用颜色编码的  $V-I$  轨迹,并利用  $K$ -means 聚类算法和 AlexNet 神经网络进行识别。文献[28]利用 RGB 颜色编码融合特征构建负荷标识,并

通过 VGG16 CNN 实现负荷识别。文献[29]采用  $V-I$  轨迹迁移学习方法,通过对  $V-I$  轨迹的形状和颜色信息来区分不同的负荷。文献[8]利用双流 CNN 提取负荷印记的时空特征实现负荷识别。各负荷识别方法的准确率对比结果如表 2 所示。由表 2 可知,所提方法对各电器的识别准确率整体上要优于另外 5 种先进负荷识别方法。

表 2 与其他负荷识别方法准确率对比

Table 2 Comparison of accuracy with other load recognition method

Appliance	Accuracy / %					
	Ref. [13]	Ref. [14]	Ref. [28]	Ref. [29]	Ref. [8]	Proposed method
Fluorescent lamp	100	98.5	99.43	100	99.4	100
Fridge	70.0	84.0	81.58	90	78.9	100
Hairdryer	100	94.5	96.79	99.4	98.1	100
Air conditioner	75.0	92.2	92.42	86.6	95.5	100
Laptop	100	92.4	96.51	99.4	99.4	97.96
Microwave	100	98.6	97.84	97.9	100	100
Vacuum	100	100	96.79	97.4	100	100
Incandescent light	100	93.2	100	97.4	100	100
Fan	75.0	83.3	100	96.6	100	100
Washing machine	85.0	90.0	96.15	100	88.5	95.92
Heater	95.0	82.8	100	100	100	100
Total	91.0	94.0	97.95	97.7	98.2	99.45

## 5 结 论

提出了一种基于 GADF 图像编码的负荷识别方法,通过对一维电压和电流信号进行 GADF 图像编码,并以叠加融合的方式构建负荷印记,增强了负荷特征的特征能力,有效提高了不同负荷之间的辨识度。此外,设计了基于 CBAM 的神经网络作为负荷识别模型,从负荷印记中获取更多有效信息,进一步提升了负荷识别效果。该方法在 PLAID 数据集和 WHITED 数据集上均进行了实验验证,并在 PLAID 数据集上与其他方法进行了比较。实验结果表明:与其他方法相比,该方法具有更高的识别准确度。但对一些特殊电器(计算机或洗衣机等)而言,识别效果仍有待改进。因此,未来工作将尝试引入更多的特征以辅助负荷识别。

### 参 考 文 献

- [1] 汪颖,杨维,肖先勇,等.基于U-I轨迹曲线精细化识别的非侵入式居民负荷监测方法[J].电网技术,2021,45(10):4104-4113.  
Wang Y, Yang W, Xiao X Y, et al. Non-intrusive residential load monitoring method based on refined identification of U-I trajectory curve[J]. Power System Technology, 2021, 45(10): 4104-4113.
- [2] 赵安军,赵啸,荆竞,等.优化卷积神经网络超参数的非侵入式电力负荷识别算法[J].激光与光电子学进展,2023,60(2):0210001.  
Zhao A J, Zhao X, Jing J, et al. Non-intrusive electric load identification algorithm for optimizing convolutional neural network hyper-parameters[J]. Laser & Optoelectronics Progress, 2023, 60(2): 0210001.
- [3] Han Y H, Li K K, Feng H T, et al. Non-intrusive load monitoring based on semi-supervised smooth teacher graph learning with voltage-current trajectory[J]. Neural Computing and Applications, 2022, 34(21): 19147-19160.
- [4] 魏广芬,赵航,胡春华,等.基于香农熵加权投票算法的集成式非侵入式负荷识别方法[J].中国电机工程学报,2022,42(24):8876-8887.  
Wei G F, Zhao H, Hu C H, et al. An ensemble non-intrusive load identification method based on Shannon entropy weighted voting algorithm[J]. Proceedings of the Chinese Society for Electrical Engineering, 2022, 42(24): 8876-8887.
- [5] 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 X P, Zhang G Q, Wei Q L, et al. A survey on the non-intrusive load monitoring[J]. Acta Automatica Sinica, 2022, 48(3): 644-663.
- [6] Makonin S, Popowich F, Bajic I V, et al. Exploiting HMM sparsity to perform online real-time nonintrusive load monitoring[J]. IEEE Transactions on Smart Grid, 2016, 7(6): 2575-2585.
- [7] Iwayemi A, Zhou C. SARAA: semi-supervised learning for automated residential appliance annotation[J]. IEEE Transactions on Smart Grid, 2017, 8(2): 779-786.
- [8] Chen J F, Wang X, Zhang X T, et al. Temporal and spectral feature learning with two-stream convolutional neural networks for appliance recognition in NILM[J]. IEEE Transactions on Smart Grid, 2022, 13(1): 762-772.
- [9] 刘恒勇,史帅彬,徐旭辉,等.一种关联RNN模型的非侵入式负荷辨识方法[J].电力系统保护与控制,2019,47(13):162-170.  
Liu H Y, Shi S B, Xu X H, et al. A non-intrusive load identification method based on RNN model[J]. Power System Protection and Control, 2019, 47(13): 162-170.
- [10] Mukesh K, Gopinath R, Harikrishna P, et al. Non-intrusive load monitoring system for similar loads identification using feature mapping and deep learning techniques[J]. Measurement Science and Technology, 2021, 32(12): 125902.
- [11] Liu B, Luan W P, Yu Y X. Dynamic time warping based non-intrusive load transient identification[J]. Applied Energy, 2017, 195: 634-645.
- [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] 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.
- [14] 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 Y, Mei F, Zheng J Y, 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.
- [15] Faustine A, Pereira L, Klemenjak C. Adaptive weighted recurrence graphs for appliance recognition in non-intrusive load monitoring[J]. IEEE Transactions on Smart Grid, 2021, 12(1): 398-406.
- [16] Wang A L, Chen B X, Wang C G, et al. Non-intrusive load monitoring algorithm based on features of V-I trajectory[J]. Electric Power Systems Research, 2018, 157: 134-144.
- [17] Faustine A, Pereira L. Improved appliance classification in non-intrusive load monitoring using weighted recurrence graph and convolutional neural networks[J]. Energies, 2020, 13(13): 3374.
- [18] 郑炜,林瑞全,王俊,等.基于GAF与卷积神经网络的电能质量扰动分类[J].电力系统保护与控制,2021,49(11):97-104.  
Zheng W, Lin R Q, Wang J, et al. Power quality disturbance classification based on GAF and a convolutional neural network[J]. Power System Protection and Control, 2021, 49(11): 97-104.
- [19] 鲍瑞,刘庆文,刘远远,等.基于卷积神经网络的双层

- 生物组织光学参数反演研究[J]. 激光与光电子学进展, 2022, 59(6): 0617018.
- Bao R, Liu Q W, Liu Y Y, et al. Inversion algorithm for optical properties of double-layer tissue based on convolutional neural network[J]. Laser & Optoelectronics Progress, 2022, 59(6): 0617018.
- [20] 季颖, 龚凌冉, 傅爽, 等. 基于卷积神经网络的相位体自动识别方法研究[J]. 激光与光电子学进展, 2022, 59(6): 0617026.
- Ji Y, Gong L R, Fu S, et al. Automatic phase recognition method based on convolutional neural network [J]. Laser & Optoelectronics Progress, 2022, 59(6): 0617026.
- [21] Woo S, Park J, Lee J Y, et al. Cbam: convolutional block attention module[M]//Ferrari V, Hebert M, Sminchisescu C, et al. Computer vision-ECCV 2018. Lecture notes in computer science. Cham: Springer, 2018, 11211: 3-19.
- [22] 宋智勇, 潘海鹏. 基于空间注意力多尺度特征融合的织物缺陷分类算法[J]. 激光与光电子学进展, 2022, 59(10): 1010005.
- Song Z Y, Pan H P. Fabric defect classification algorithm based on multi-scale feature fusion of spatial attention[J]. Laser & Optoelectronics Progress, 2022, 59(10): 1010005.
- [23] Nguyen H M, Cooper E W, Kamei K. Borderline over-sampling for imbalanced data classification[J]. International Journal of Knowledge Engineering and Soft Data Paradigms, 2011, 3(1): 4-21.
- [24] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [25] LeCun Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.
- [26] Hu J, Shen L, Sun G. Squeeze-and-excitation networks [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 7132-7141.
- [27] Wang Q L, Wu B G, Zhu P F, et al. ECA-net: efficient channel attention for deep convolutional neural networks [C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 11531-11539.
- [28] 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): 1557-1565.
- 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): 1557-1565.
- [29] Liu Y C, 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.