

DOI: 10.19783/j.cnki.pspc.231443

基于马尔可夫转移场和轻量级网络的非侵入式负荷识别

张帅¹, 程志友^{1,2}, 田甜¹, 徐正林¹, 杨猛³

(1. 安徽大学互联网学院, 安徽 合肥 230039; 2. 教育部电能质量工程研究中心(安徽大学), 安徽 合肥 230601;
3. 安徽大学电子信息工程学院, 安徽 合肥 230601)

摘要: 负荷识别是非侵入式负荷监测(non-intrusive load monitoring, NILM)的关键一步。针对目前识别方法存在网络参数量大、识别率低的局限性, 提出了一种基于马尔可夫转移场(Markov transition field, MTF)和轻量级网络的非侵入式负荷识别方法。首先, 利用归一化后的电压电流计算马尔可夫状态转移矩阵, 在时域上排列每个状态转移概率构建 MTF。其次, 对 MTF 降采样以适应神经网络的学习, 利用伪彩色编码技术得到 RGB 彩色图像。最后, 在轻量级网络 ShuffleNetV2 中加入 SimAM 无参注意力模块作为特征提取网络, 以较少的参数量实现负荷分类识别。使用公共数据集 PLAID 和 WHITED 对所提方法进行实验, 结果表明, SimAM-ShuffleNetV2 在两个数据集的识别准确率分别达到了 98.99%和 99.22%, 参数量分别为 0.37 M 和 0.41 M, 比现有的方法具有更高的识别准确率和更少的参数量, 验证了所提方法的有效性和优越性。

关键词: 非侵入式负荷识别; 数据图像化; 马尔可夫转移场; SimAM 无参注意力; 轻量级网络

Non-intrusive load identification based on the Markov transition field and a lightweight network

ZHANG Shuai¹, CHENG Zhiyou^{1,2}, TIAN Tian¹, XU Zhenglin¹, YANG Meng³

(1. School of Internet, Anhui University, Hefei 230039, China; 2. Power Quality Engineering Research Center (Anhui University), Ministry of Education, Hefei 230601, China; 3. School of Electronics and Information Engineering, Anhui University, Hefei 230601, China)

Abstract: Load identification is a key step in non-intrusive load monitoring (NILM). There are limitations caused by a large number of network parameters and a low identification rate of current identification methods. Thus a non-intrusive load identification method based on a Markov transition field (MTF) and a lightweight network is proposed. First, the Markov state transition matrix is calculated using the normalized voltage and current, and the MTF is constructed by arranging each state transition probability in the time domain. Second, the MTF is downsampled to facilitate the learning of the neural network, and an RGB color image is obtained using a pseudo-color coding technique. Finally, a SimAM parameter-free attention module is added to the lightweight network ShuffleNetV2 as a feature extraction network to achieve load classification identification with fewer parameters. Experiments on the proposed method using the public datasets PLAID and WHITED show that the identification accuracy of SimAM-ShuffleNetV2 achieves 98.99% and 99.22% respectively in the two datasets, with the number of parameters of 0.37 M and 0.41 M, respectively. This shows higher identification accuracy and fewer parameters than existing methods, verifying the validity and superiority of the proposed method.

This work is supported by the National Natural Science Foundation of China (No. 61672032).

Key words: non-intrusive load identification; data visualization; Markov transition field; SimAM parameter-free attention; lightweight network

0 引言

智能电网为电力能源的高效管理和有效利用提

供了强有力的技术支撑。负荷监测方法作为智能电网技术研究的关键环节, 为智能电网提供了完整的数据基础和技术手段^[1-2]。文献[3]提出了非侵入式负荷监测(non-intrusive load monitoring, NILM), 仅需要在总线处安装一个监测装置, 便可以分析居民负荷的种类、运行状态和能耗信息。与侵入式负荷监

基金项目: 国家自然科学基金项目资助(61672032); 安徽省自然科学基金项目资助(2108085QE237)

测相比,非侵入式负荷监测的成本更低,这对负荷识别和功率分析算法提出了新的要求。

特征提取和识别是 NILM 的两个关键技术。NILM 被提出以来,大量研究工作致力于利用信号分析与处理、机器学习和深度学习等各种技术来构建负荷识别算法。早期的负荷识别主要以有功功率和无功功率为负荷特征进行识别^[4-5],然而,当负荷种类增加,负荷特征重叠,仅使用功率特征的识别准确率并不高。为了取得更好的识别效果,研究人员利用更多的负荷电气特征,并利用机器学习算法进行负荷监测^[6-7]。文献[8]通过对负荷的电压和电流进行高频采样,利用快速傅里叶变换提取电流的复谱,使用支持向量机(support vector machine, SVM)完成负荷识别。文献[9]将负荷功率信号转换成二维空间,提取直方图代表每个负荷,然后使用改进的 K 近邻(K-nearest neighbor, KNN)法来减少学习时间,提高识别性能。

随着图像处理技术的发展,利用信号处理技术将一维电流电压数据转换为二维图像,再利用深度学习进行负荷识别是当前热门的研究方法^[10-12]。文献[13]提出了 $U-I$ 轨迹的加权像素化图像作为卷积神经网络(convolutional neural network, CNN)的输入来实现负荷识别,二值图像仅包含负载 $U-I$ 轨迹的形状信息,不足以对负荷进行细粒度识别。文献[14-16]采用 $U-I$ 轨迹颜色编码技术,将功率大小、轨迹变换、功率因数等信息融入 $U-I$ 轨迹,得到彩色 $U-I$ 轨迹图像作为负荷特征,取得了较好的识别效果,但基于 $U-I$ 轨迹的特征图像会有大量空白信息。负荷拥有唯一特征可以提高其可识别性,许多研究人员摒弃特性相似的电压数据,使用电流序列的二维可视化方法进行负荷识别^[17-18]。文献[19-20]提出了电流自适应的递归图(recurrence plot, RP)方法,以表现负荷特征的唯一性,通过 CNN 提升负荷识别效果,然而,当负荷间电流序列相似时,负荷之间容易发生混淆。文献[21]提出了无功电流的格拉姆角场(Gramian angular field, GAF)作为负荷特征,利用 Inception-v3 进行识别,无功电流的类间差距较大,取得了较好的识别效果,但网络参数量较大,不利于大规模使用。

为此,考虑电压与电流数据之间的相关性和网络参数的优化,本文提出了一种基于马尔可夫转移场和轻量级网络的非侵入式负荷识别方法,将归一化后的电流电压划分在相同的分位数单元中,构建马尔可夫状态转移矩阵,对按时序排列的电流电压进行填充得到马尔可夫转移场(Markov transition field, MTF),对 MTF 采用伪彩色编码技术将其可视化为

RGB 图像,在计算量较小的基础上利用了电流与电压之间的关系。在轻量级网络 ShuffleNetV2^[22]中加入 SimAM^[23]注意力模块作为特征提取网络,以较少的参数量实现负荷分类识别。最终在公共数据集 PLAID^[24]和 WHITED^[25]上进行实验验证。

1 马尔可夫转移场

MTF 是一种将一维序列转换为二维图像的方法^[26],目前常见的 MTF 是在单一序列中通过相邻状态转移的概率得到马尔可夫状态转移矩阵,进而构建 MTF,本文在电压电流两个序列之间构建 MTF,MTF 的示意图如图 1 所示。

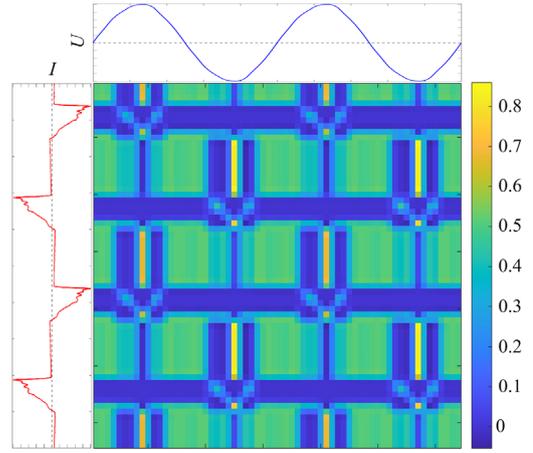


图 1 MTF 示意图

Fig. 1 MTF schematic diagram

1.1 马尔可夫状态转移矩阵

对给定的离散电流信号 $i = \{i_1, i_2, \dots, i_N\}$ 和电压信号 $u = \{u_1, u_2, \dots, u_N\}$, 首先对其进行归一化处理,如式(1)所示。

$$i_d = \frac{i - i_{\min}}{i_{\max} - i_{\min}} \quad (1)$$

$$u_d = \frac{u - u_{\min}}{u_{\max} - u_{\min}} \quad (2)$$

式中: i_d 和 u_d 分别为归一化后的电流和电压信号; i_{\min} 和 i_{\max} 分别为电流的最小值和最大值; u_{\min} 和 u_{\max} 分别为电压的最小值和最大值。

对数据归一化之后,将电压数据 u_d 根据幅值划分为 Q 个分位数单元(bin 值),bin 值用 $q_j (j \in [1, Q])$ 表示,每一个单元有相同的采样点个数,将每一个 u_d 映射到对应的 q_j 上。由于分位数单元是按照幅值进行划分,将 i_d 映射到划分好的分位数单元中,利用马尔可夫链的转移概率表示两序列的关系,如式(3)所示。

$$P_{j,k} = p_{j,k}(i_d \in q_j | u_d \in q_k) \quad (3)$$

式中, $P_{j,k}$ 表示在同一时刻 u_d 和 i_d 从分位数单元 q_k 转移到 q_j 的条件概率。将马尔可夫链的所有转移概率沿转移规律进行排列, 就可以得到 $Q \times Q$ 的马尔可夫状态转移矩阵 T , 如式(4)所示。

$$T = \begin{bmatrix} p_{1,1}(i_d \in q_1 | u_d \in q_1) & \cdots & p_{1,Q}(i_d \in q_1 | u_d \in q_Q) \\ p_{2,1}(i_d \in q_2 | u_d \in q_1) & \cdots & p_{2,Q}(i_d \in q_2 | u_d \in q_Q) \\ \vdots & & \vdots \\ p_{Q,1}(i_d \in q_Q | u_d \in q_1) & \cdots & p_{Q,Q}(i_d \in q_Q | u_d \in q_Q) \end{bmatrix} \quad (4)$$

1.2 马尔可夫转移场

从式(4)中可以看出, 马尔可夫状态转移矩阵丢失了电流电压序列的时间依赖性。为了在时域上保留信息, 可以通过在时域上按顺序排列状态转移概率将其转换为 MTF, 式(5)表示马尔可夫转移场 M 的计算过程。

$$M = \begin{bmatrix} M_{11} & M_{12} & \cdots & M_{1N} \\ M_{21} & M_{22} & \cdots & M_{2N} \\ \vdots & \vdots & & \vdots \\ M_{N1} & M_{N2} & \cdots & M_{NN} \end{bmatrix} = \begin{bmatrix} p_{j,k}(i_1 \in q_j | u_1 \in q_k) & \cdots & p_{j,k}(i_1 \in q_j | u_N \in q_k) \\ p_{j,k}(i_2 \in q_j | u_1 \in q_k) & \cdots & p_{j,k}(i_2 \in q_j | u_N \in q_k) \\ \vdots & & \vdots \\ p_{j,k}(i_N \in q_j | u_1 \in q_k) & \cdots & p_{j,k}(i_N \in q_j | u_N \in q_k) \end{bmatrix} \quad (5)$$

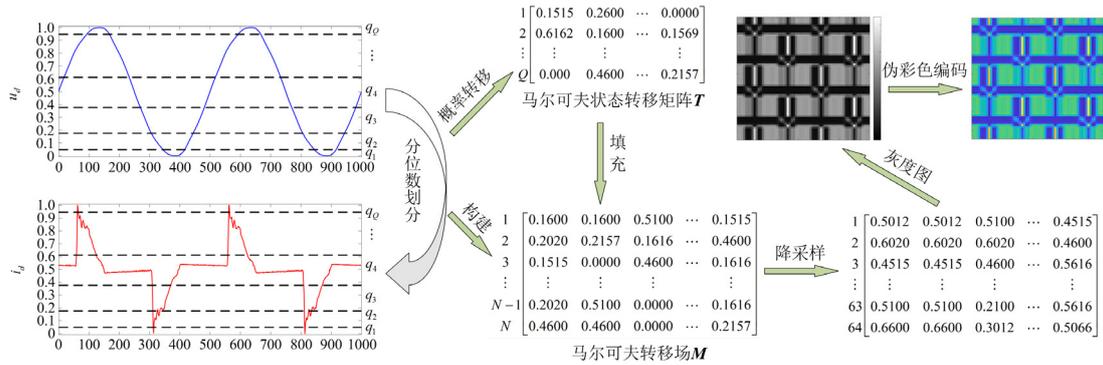


图 2 MTF 变换流程

Fig. 2 MTF transformation process

e_k^* 值越小表示能量越低, 第 k 个神经元与周围神经元的区别越大, 对视觉处理也越重要。因此, 每个神经元的重要性可由 $1/e_k^*$ 得到, 输出特征图 \tilde{X} 的计算如式(7)所示。

$$\tilde{X} = \text{Sigmoid}\left(\frac{1}{E}\right)X \quad (7)$$

式中, M 中元素 M_{jk} 表示 u_d 和 i_d 所在分位数单元 q_j 和 q_k 在状态转移矩阵 T 上的概率。

由此构建的 MTF 可以保留序列的时域信息, 最终得到的马尔可夫转移场大小为 $N \times N$, 当 N 过大时, 生成的 MTF 尺寸较大, 不利于神经网络的计算和数据的存储, 且拥有大量冗余信息, 因此使用模糊内核对 MTF 进行降采样, 得到 $m \times m$ 的二维矩阵, 将该矩阵与计算机内部编码的灰度值对应, 从而绘制出灰度图, 通过将不同灰度值映射到不同的颜色进行伪彩色编码, 得到 RGB 彩色图像。生成的图像既有序列的时域信息, 又包含电流电压的关联性, MTF 变换流程如图 2 所示。

2 基于轻量级网络的负荷识别模型

2.1 SimAM 无参注意力

本文采用 SimAM 作为网络的注意力模块。SimAM 不同于现有的通道注意或空间注意, 它在获取特征映射的三维注意力权重时, 不需要额外的参数。为了成功地实现注意力, 需要估计单个神经元的重要性。通过最小能量函数 e_k^* 来计算神经元的权重, 如式(6)所示。

$$e_k^* = \frac{4(\hat{\sigma}^2 + \lambda)}{(t_k - \hat{u})^2 + 2\hat{\sigma}^2 + 2\lambda} \quad (6)$$

式中: t_k 为输入特征图在单个通道上的第 k 个神经元; \hat{u} 为所有神经元在单个通道上的均值; $\hat{\sigma}^2$ 为所有神经元在单个通道上的方差; λ 为正项。

式中: E 为所有通道和空间维度中能量函数 e_k^* 的汇总; Sigmoid 函数的目的是用来约束 E 中过大的值, 增强神经元之间的相对重要性; X 表示输入特征图。

SimAM 模块如图 3 所示, 其中, C 、 H 、 W 分别为特征图的通道数、高度、宽度。输入特征图经过 $H \times W$ 个 SimAM 注意力模块后, 根据式(7)进行

计算，从而获得最终输出特征图。

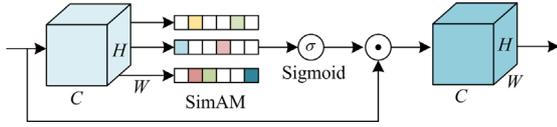


图 3 SimAM 模块

Fig. 3 SimAM module

2.2 改进的 ShuffleNetV2 轻量级网络

ShuffleNetV2 模型利用信道变换和深度可分离卷积对 ResNet 残差结构进行优化，不仅提高了模型的运行效率，而且保证了网络的准确性。其中，深度可分离卷积将标准的卷积操作分解为两步：深度卷积和逐点卷积。深度卷积首先对输入的每个通道

进行独立的卷积操作，然后使用逐点卷积将上一步的结果进行融合。然而，在结构上 ShuffleNetV2 中没有有效的注意力机制来帮助模型学习特征。基于这个出发点，本文将 SimAM 注意力模块添加到模型中，为了避免注意力模块增加模型的复杂性，将 SimAM 放在分类层前，提高了模型对通道信息的感知能力，进一步使模型更好地提取空间特征。同时，在参数数量基本不变的情况下，对深度可分离卷积中的卷积核进行了扩展，将 3×3 卷积替换为 5×5 卷积，获得了更大的感受野。本文的研究选择参数最少的 ShuffleNetV2-0.5 作为负荷识别的轻量级网络，本文的网络模型整体结构如图 4 所示。

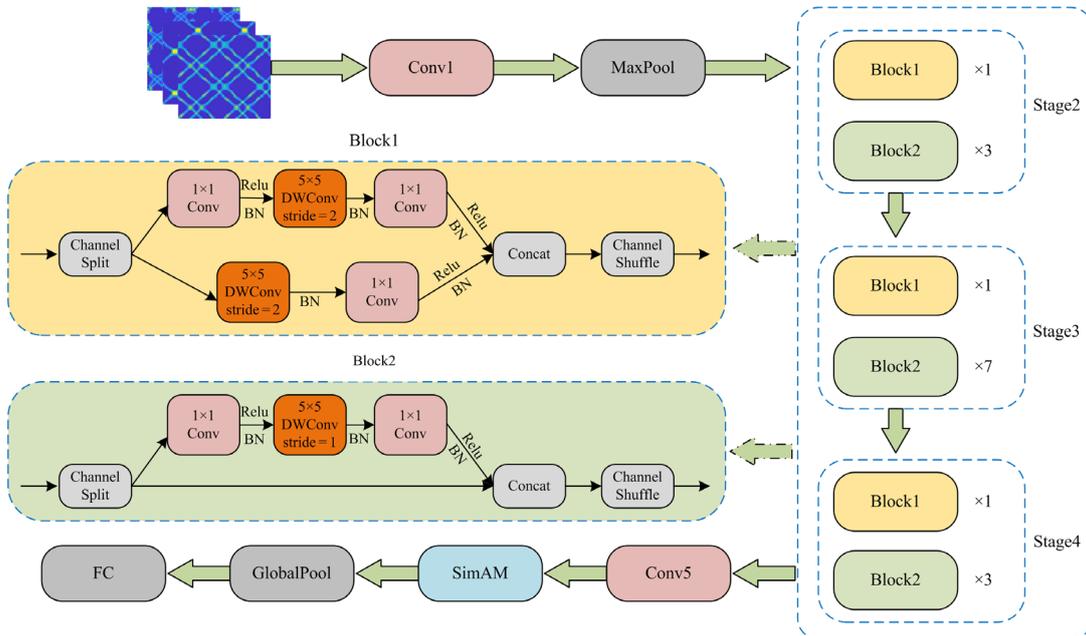


图 4 网络模型整体结构

Fig. 4 Overall structure of network model

3 实验结果与分析

3.1 数据集选取与变换

为了验证所提方法的可行性，本文的实验使用了两个公共数据集 PLAID 和 WHITED。数据集包含了每个电器从启动到稳定运行的详细信息。PLAID 数据集共包含 11 种电器的 1074 个实例，数据的采样频率为 30 kHz。WHITED 数据集来自世界上 9 个地区的 54 种电器，包括 1339 个实例，采样频率为 44.1 kHz。本文使用稳态下的电压电流数据进行实验。

负荷在启动的暂态过程电流不稳定，本文认定负荷在开启 30 个周期后为稳定运行状态。两个数据集的采样频率较大，综合考虑计算量和图像辨识度，

选取电压过零点后 2 个周期的数据进行实验。以 PLAID 数据集为例，电网工频为 60 Hz，2 个周期共 1000 个数据点，取 $Q = 20$ ，转换后的 MTF 大小应为 1000×1000 ，再经过降采样处理得到 64×64 的灰度矩阵，最后利用伪彩色编码得到 $3 \times 64 \times 64$ 的 RGB 彩色图像。PLAID 数据集共生成 7953 个样本，WHITED 数据集共生成 6450 个样本。

本文电流电压的 MTF 变换和识别模型均基于 Matlab，所使用的实验环境参数如表 1 所示。

3.2 实验评价指标

本文采用准确率 $A_{accuracy}$ 、混淆矩阵和 F_1 分数作为负荷识别的评价指标。

表 1 实验环境参数

Table 1 Experimental environment parameters

硬件/软件	版本/型号
操作系统	Windows10(64 位)
CPU	Intel(R)Core(TM) i7-10700@2.90 GHz
GPU	RTX3060
Matlab	2021b
Deep Learning Toolbox	14.0

准确率用于评价数据集整体识别效果, 如式(8)所示。

$$A_{\text{accuracy}} = \frac{a}{A} \quad (8)$$

式中: A 表示总样本个数; a 表示识别正确的样本数。

F_1 分数用于评价每一类负荷的识别效果, 是查准率和召回率的调和平均数。

$$R_c = \frac{T_p}{T_p + F_N} \quad (9)$$

$$P_{re} = \frac{T_p}{T_p + F_p} \quad (10)$$

$$F_{1\text{-score}} = \frac{2 \times P_{re} \times R_c}{P_{re} + R_c} \quad (11)$$

式中: P_{re} 表示查准率; R_c 表示召回率; $F_{1\text{-score}}$ 表示 F_1 分数指标值; T_p 表示实际上是正类, 同时被识别为正类的样本数; F_N 表示实际上是正类, 但是被识别为负类的样本数; F_p 表示实际上是负类, 但是被识别为正类的样本数。

3.3 PLAID 的实验结果

将 PLAID 数据集生成的 7953 个样本按 6:2:2 的比例随机分成训练集、验证集和测试集, 以检验模型的泛化能力。将训练集和验证集输入 SimAM-ShuffleNetV2 轻量级网络, 训练使用 Adam 优化器, 并设置了学习率自适应调整机制, 初始学习率为 0.0001, 若损失函数值在 7 次之内不下降, 则将学习率更新为原学习率的 1/10 以优化模型, 损失函数为交叉熵损失函数, 批次大小设置为 64, 训练包括 100 次迭代。训练集和验证集的准确率与损失函数值如图 5 所示。

由图 5 可以看出, 模型在 80 次左右完全收敛, 收敛后验证集最高准确率达到 99.31%, 验证集损失值收敛至 0.018。将测试集输入训练好的模型, 在 PLAID 的测试集上识别准确率达到 98.99%, 图 6 是根据测试集结果绘制的混淆矩阵, 混淆矩阵的行代表预测类别, 列表示真实类别, 由混淆矩阵可以看出, 冰箱、加热器、笔记本电脑容易混淆为其他负荷, 电风扇、吹风机和荧光灯易被其他负荷误判成该类。

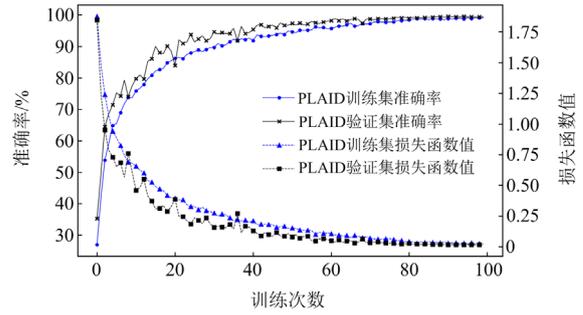


图 5 PLAID 数据集训练过程

Fig. 5 Training process of PLAID dataset

预测类别	空调	白炽灯	电风扇	冰箱	吹风机	加热器	荧光灯	笔记本电脑	微波炉	吸尘器	洗衣机
空调	146	1	0	1	0	0	0	0	0	0	1
白炽灯	0	156	1	2	0	0	0	0	0	0	0
电风扇	0	0	182	3	0	0	0	0	0	0	0
冰箱	1	0	0	98	0	0	0	0	0	0	0
吹风机	0	0	1	0	185	2	0	0	0	0	0
加热器	0	0	0	0	0	100	0	0	0	0	0
荧光灯	0	0	0	0	0	0	181	2	0	0	1
笔记本电脑	0	0	0	0	0	0	0	253	0	0	0
微波炉	0	0	0	0	0	0	0	0	128	0	0
吸尘器	0	0	0	0	0	0	0	0	0	41	0
洗衣机	0	0	0	0	0	0	0	0	0	0	100

真实类别

图 6 PLAID 测试集实验结果的混淆矩阵

Fig. 6 Confusion matrix of experimental results of PLAID test set

根据测试集结果计算 F_1 分数, 各负荷的 F_1 分数如表 2 所示。冰箱的 F_1 分数低于其他负荷, 这是由于在 PLAID 数据集中, 冰箱有较多未知状态, 容易误判为其他负荷。荧光灯和笔记本电脑有相似的电流轨迹, 以致二者的马尔可夫转移矩阵差异较小, 易发生混淆。加热器和吹风机同属于加热设备, 有相似的工作模式, 导致难以区分。识别的平均 F_1 分数 F_{macro} 达到了 98.96%, 可以看出本文方法有较好的识别效果。

表 2 PLAID 中 11 种负荷的 F_1 分数

Table 2 F_1 score of 11 loads in PLAID

负荷	F_1 分数/%	负荷	F_1 分数/%
冰箱	96.54	吹风机	99.19
空调	98.65	荧光灯	99.19
电风扇	98.65	笔记本电脑	99.60
白炽灯	98.75	微波炉	100.0
加热器	98.99	吸尘器	100.0
洗衣机	98.99	F_{macro}	98.96

3.4 WHITED 的实验结果

使用与 PLAID 数据集相似的实验步骤和训练参数对 WHITED 数据集进行实验,训练过程的准确率和损失函数值如图 7 所示,WHITED 数据集中类间差异较大,因此收敛速度高于 PLAID 数据集,在 70 次左右实现完全收敛,验证集准确率最高为 99.53%,损失函数值低至 0.016,可以看出,本文方法对 WHITED 数据集依然有较好的识别效果。

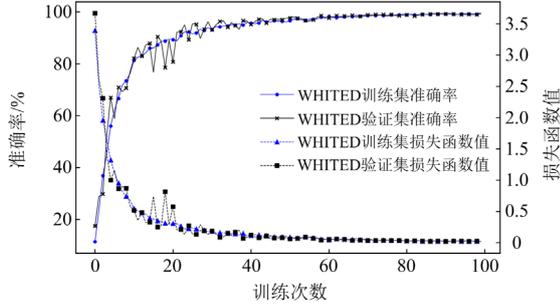


图 7 WHITED 数据集训练过程

Fig. 7 Training process of WHITED dataset

将测试集输入训练好的模型,整体准确率达到 99.22%,平均 F_1 分数 F_{macro} 为 99.21%,混淆矩阵和各负荷 F_1 分数如附录 A 图 A1 和图 A2 所示。WHITED 数据集中有较多的加热类型负荷如水壶、熨斗、电饭煲、三明治机等,这些负荷电流信号几乎是正弦信号,相位角也接近于 0,极易发生混淆。因此后续将对加热型负荷的精确识别做进一步研究。游戏机、跑步机、电视机和荧光灯电流波形和相位差相似,归一化后生成的 MTF 图像差异较小,这些负荷之间发生了误判,跑步机样本数较少,导致 F_1 分数较低。

3.5 分析与讨论

3.5.1 MTF 不同参数与策略对比

不同的 bin 值对图像生成产生了较大的影响,当 bin 值变大时,马尔可夫转移矩阵概率更加多样,MTF 图像更加复杂。图 8 表示 PLAID 数据集中,微波炉分别在 bin 值为 5、10、20 和 40 时的 MTF 图像。可以看出随着 bin 值的增大,图像的分割增加,纹理更加复杂。

利用电流电压两个序列生成的 MTF 作为特征图像进行负荷识别,相比于传统的单一电流序列生成的 MTF 图像,本文方法更具区分度,附录 A 图 A3 是在 bin 值为 20 时吹风机、白炽灯、电风扇和加热器 4 种电器用以上两种策略生成的 MTF 图像,可以看出当负荷电流信号接近正弦信号的时候,用单一信号生成的图像区分度较小易混淆,而本文的方法可以利用相位差产生不同的马尔可夫转移矩

阵,增加了图像差异性。

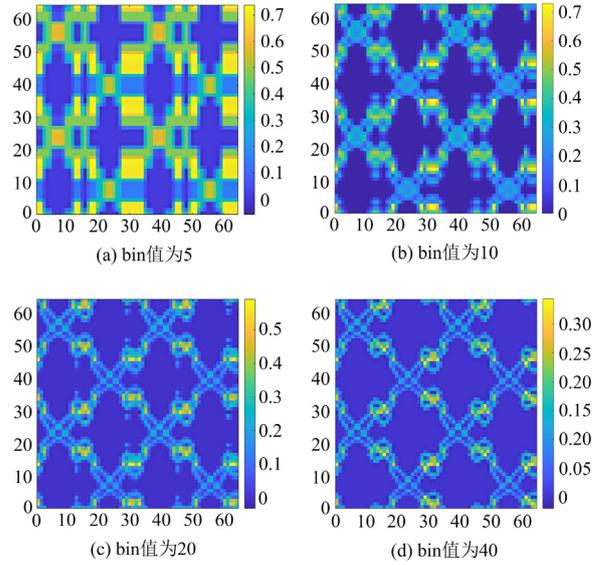


图 8 微波炉在不同 bin 值下的 MTF 图像

Fig. 8 Microwave MTF images with different bin values

在不同 bin 值下测试集在两种策略下的准确率对比如图 9 所示,由图 9 可以看出,两个数据集在不同 bin 值下本文方法准确率均显著高于单一电流序列 MTF 方法。在本文方法下,PLAID 数据集在 bin 值为 20 时达到最高准确率 98.99%,WHITED 数据集在 bin 值为 40 时达到最高准确率 99.30%,由于两个数据集在 bin 值为 20 和 40 时准确率差别不大,从计算量角度考虑,本文选取 20 作为最终的 bin 值进行实验。

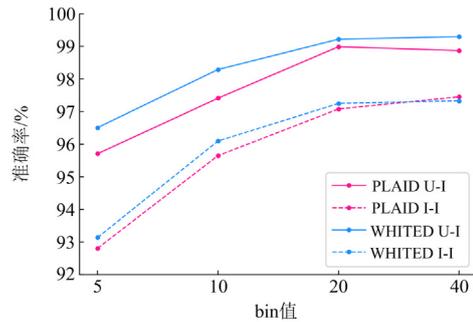


图 9 不同参数 MTF 方法的准确率对比

Fig. 9 Comparison of accuracy of MTF methods with different parameters

在实验中,每张 MTF 图像是基于 2 个周期获得,不同周期得到的图像会对识别结果产生影响。表 3 列出了不同周期数生成的图像在两个数据集下的识别准确率。由结果可以看出,两个数据集均在周期为 2 时得到最高准确率。基于 1 个周期生成图像时,无法保证特征的连续性,图像准确率处于较

低水平。当周期数超过 2 时, 准确率略有下降, 是由于增加周期会导致参数过拟合, 对测试集的认识效果较差。因此本文选取 2 个周期的数据进行实验。

表 3 不同周期数图像的准确率

Table 3 Accuracy of images with different number of periods

周期数	识别准确率/%	
	PLAID 数据集	WHITED 数据集
1	97.48	98.45
2	98.99	99.22
3	98.87	99.15
4	98.87	98.91
5	98.73	98.91

3.5.2 不同网络模型对比

当前深度学习模型已广泛应用于负荷识别领域, 为了进一步证明本文模型在轻量化和有效性方面的优势, 分别选取轻量级网络模型 ShuffleNetV2、MobileNetV3、GhostNetV2 和经典网络模型 ResNet34、DenseNet 进行对比实验, 图 10 为两个数据集在各模型上验证集的准确率变化曲线。

由图 10 可知, 本文模型比 ShuffleNetV2 验证集准确率更高, 证明在引入 5×5 的卷积和 SimAM 注意力模块可以有效提取更多深层特征, 提升模型的特征提取能力; 相比于其他 4 种模型, 本文模型在两个数据集有更好的训练效果, 收敛之后验证集准确率最高。表 4 记录了不同网络模型的识别准确率、参数量、计算量和平均每次训练的时间对比。

由表 4 可以看出, 本文模型在参数较小、计算量较小的情况下, 两个数据集均得到较好的识别结果。相比于 MobileNetV3, 本文模型准确率分别高出了 1.36% 和 1.09%; GhostNetV2 在 3 种轻量级网络获得了最高准确率, 但在两个数据集上准确率分

别低于本文模型 0.50% 和 0.85%, 且参数量在两个数据集上分别是本文模型的 13.2 和 12.1 倍; ResNet34 准确率比 GhostNetV2 有小幅提升, 但本文模型参数量在两个数据集上分别仅有 ResNet34 的 1.74% 和 1.92%, 在两个数据集上平均每次训练时间分别减少了 7.1 s 和 6.2 s; DenseNet 的参数量和计算量低于 ResNet34, 但需要频繁访问内存, 导致训练速度较慢。综上, 本文模型有更好的可行性和实用性。

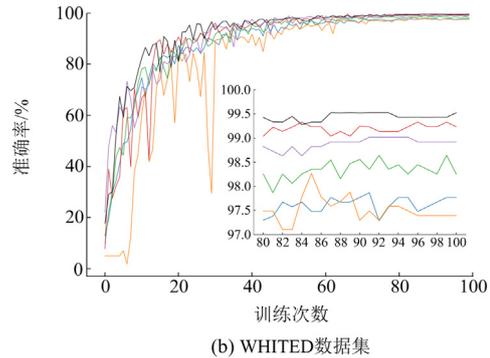
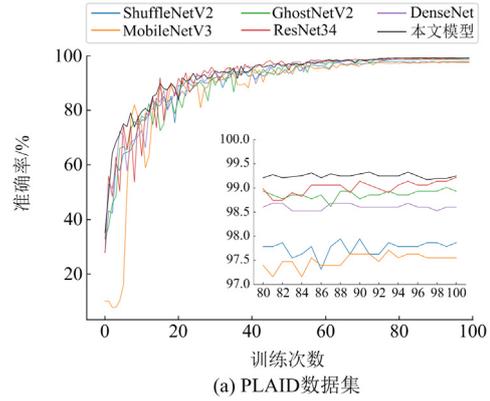


图 10 不同模型的验证集准确率曲线

Fig. 10 Validation set accuracy curves of different models

表 4 不同模型下结果对比

Table 4 Comparison of results under different network models

网络模型	PLAID 数据集				WHITED 数据集			
	准确率/%	参数量/M	计算量/M	训练时间/s	准确率/%	参数量/M	计算量/M	训练时间/s
ShuffleNetV2	97.86	0.35	3.57	15.8	97.90	0.39	3.61	13.9
MobileNetV3	97.63	1.53	5.99	17.5	98.13	1.57	6.04	15.4
GhostNetV2	98.49	4.89	17.77	20.4	98.37	4.95	17.83	18.7
ResNet34	98.86	21.29	300.27	23.2	99.15	21.31	300.29	20.4
DenseNet	98.36	6.97	236.42	48.2	98.76	7.01	236.46	44.6
本文模型	98.99	0.37	3.83	16.1	99.22	0.41	3.87	14.2

3.5.3 不同图像化方法对比

不同的图像生成方法对非侵入式负荷识别会有不同表现, 采用本文 SimAM-ShuffleNetV2 作为识

别模型, 将 MTF 方法与常见的一维转二维方法 $U-I$ 轨迹、电流 S 变化频谱图、电流递归图、电流 GAF 和 MTF 灰度图方法进行对比, 生成图像的维度相

等，不同图像化方法结果对比如图 11 所示。

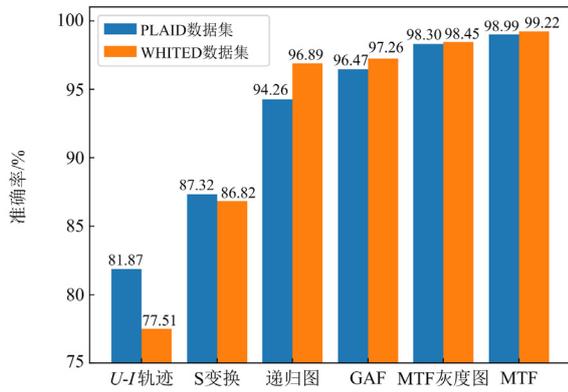


图 11 不同数据图像化方法结果对比

Fig. 11 Comparison of different data visualization method

从图像生成的角度，MTF 的转换方法计算过程简洁，引入分位数单元使图像的抗干扰能力增强，由图 11 可以看出，MTF 的识别效果明显，在两个数据集拥有的识别准确率最高，分别为 98.99%和 99.22%，MTF 变换能够有效利用电压电流之间的关系，比单一电流生成的 S 变换频谱图、递归图和 GAF 特征更加明显，使本文图像化方法具有较高的识别性能。相比于 MTF 灰度图，MTF 彩色图像在两个数据集的识别准确率分别提升了 0.69%和 0.77%，彩色图像能够增强图像的隐含特征信息，有利于神经网络的特征识别。

3.5.4 本文方法与现有方法对比

为了更加全面地验证本文方法的有效性，将文献[10,15,20]所提方法在两个公共数据集上进行复现，与本文方法的参数量、计算量和准确率进行对比，数据的选取和划分与本文相同，结果可能与原文献不一致，分析结果如表 5 所示。4 种方法在 PLAID 数据集上各负荷 F₁ 分数雷达图如图 12 所示，在 WHITED 数据集出现混淆的 20 种负荷 F₁ 分数雷达图如图 13 所示。

由对比结果可以看出，相比于现有算法，本文方法比其他 3 种方法有更高的识别准确率，在 PLAID 上加热器、吹风机、冰箱等负荷识别效果取得较大提升；在 WHITED 上本文方法 F₁ 分数较低

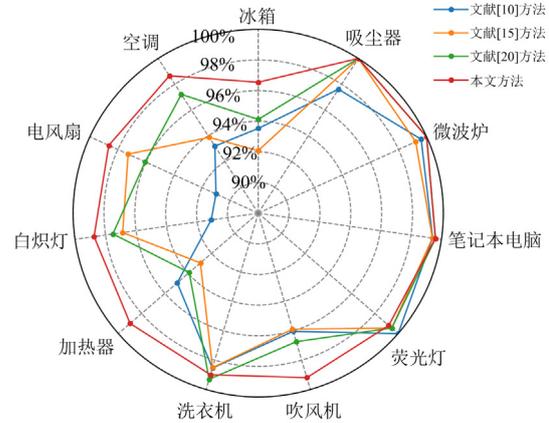


图 12 4 种方法在 PLAID 上的 F₁ 分数雷达图

Fig. 12 The F₁ score radar chart of four methods in PLAID

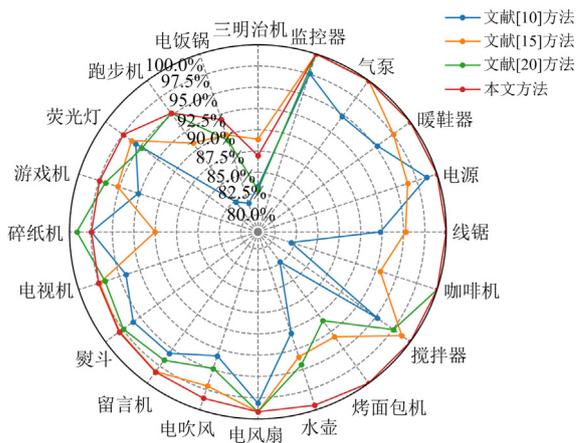


图 13 4 种方法在 WHITED 上的 F₁ 分数雷达图

Fig. 13 The F₁ score radar chart of four methods in WHITED

表 5 本文方法与现有方法的对比

Table 5 Comparison between proposed method and current methods

方法	负荷特征	训练模型	参数		计算量/M	数据集	准确率/%
			特征	模型/M			
文献[10]	特征组合灰度图	ZFNet-Inception	1×224×224	1.70	1.28×10 ³	PLAID	95.96
				1.73	1.32×10 ³	WHITED	95.35
文献[15]	改进彩色 U-I 轨迹	VGG16	3×224×224	134	1.54×10 ⁴	PLAID	97.04
				135	1.55×10 ⁴	WHITED	97.98
文献[20]	无功电流 GAF	Inception-v3	3×224×224	21.8	2.85×10 ³	PLAID	97.73
				22.0	2.86×10 ³	WHITED	98.29
本文	U-I 马尔可夫转移场	SimAM-ShuffleNetV2	3×64×64	0.37	3.83	PLAID	98.99
				0.41	3.87	WHITED	99.22

的负荷在其他 3 种方法中也出现了混淆, 并且在水壶、烤面包机、咖啡机等负荷 F_1 分数较低, 说明本文方法对加热型负荷的识别能力高于其他 3 种方法。特征图像的参数量上减少了 75.5%~91.8%; 网络参数量远低于文献[15]的 VGG16 和文献[20]的 Inception-v3 模型, 比文献[10]的轻量级网络 ZFNet 参数量减少了 78.3%; 在计算量上, 本文方法仅为 3 种方法的 1/1000 左右。由此可知, 本文方法在参数量和计算量更少的情况下, 达到了更高的识别准确率, 体现了本文方法的优越性。

4 结论

针对非侵入式负荷识别方法网络参数量大, 识别率低的局限性, 本文提出了一种基于马尔可夫转移场和轻量级网络的非侵入式负荷识别方法。利用电压电流构建 MTF, 再使用 SimAM-ShuffleNetV2 网络进行负荷识别, 通过 PLAID 和 WHITED 数据集进行实验验证, 得到如下结论:

附录 A

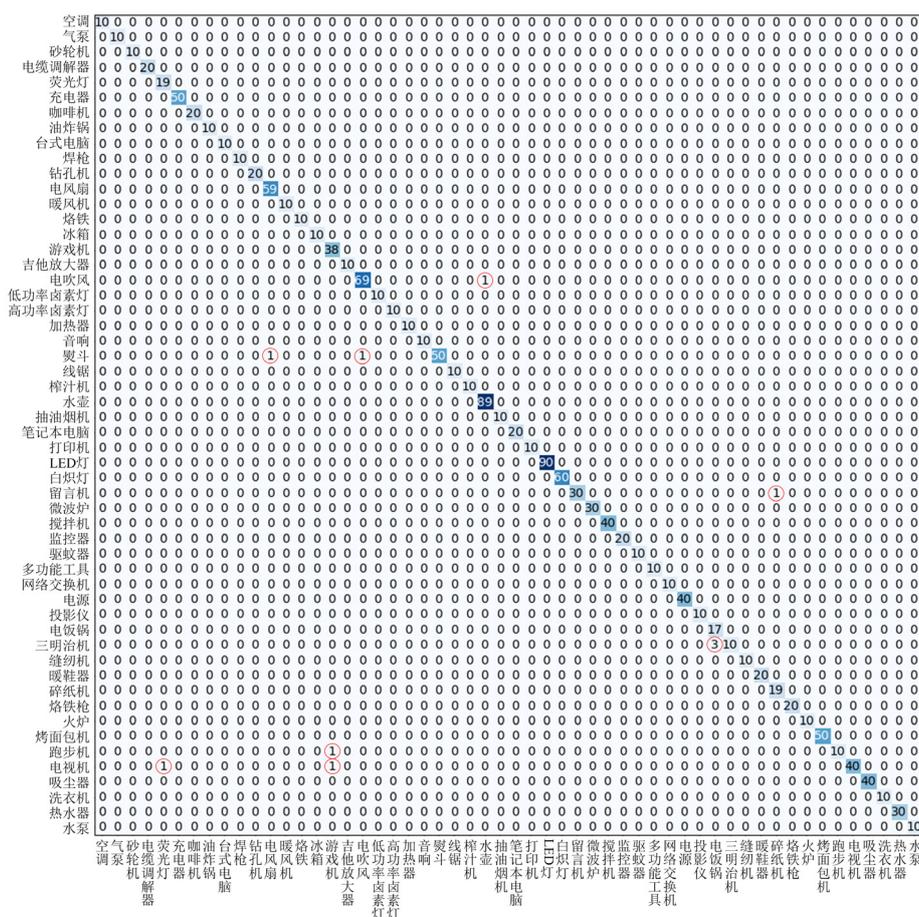


图 A1 WHITED 数据集测试结果绘制的混淆矩阵

Fig. A1 Confusion matrix plotted from the test results for the appliances on the WHITED dataset

1) 通过 $U-I$ 构建的 MTF 图像在负荷识别时有良好的适用性, 比单一电流序列生成的特征图像有更高的区分度。

2) 本文提出的 SimAM-ShuffleNetV2 网络通过引入 5×5 的卷积和 SimAM 注意力模块, 优化了网络结构, 在两个数据集上的识别准确率分别达到了 98.99% 和 99.22%。

3) 本文模型在两个数据集的网络参数量为 0.37 M 和 0.41 M, 比常见的网络模型参数量更低, 与现有的方法相比, 在保障负荷有更高识别准确率的同时, 计算量仅为已有方法的 1/1000 左右, 可以看出本文方法在参数量和计算量较低的情况下, 仍能较好地完成负荷识别任务, 验证了本文方法的有效性。

本文方法在公共数据集上取得较好的识别效果, 在实际应用中环境因素可能会对识别结果存在影响, 如电压波动、不同地区的电能质量差异、新型负荷的加入等, 考虑环境因素对国内负荷进行识别将成为下一步研究的目标。

- [8] TU Lingling, CAI Gaoyan, LIANG Bingji, et al. Non-intrusive load identification based on complex spectrum and support vector machine[C] // Proceedings of the 8th International Conference on Communication and Information Processing, November 3-5, 2022, Beijing, China: 17-21.
- [9] HIMEUR Y, ALSALEMI A, BENSAAFI F, et al. Smart non-intrusive appliance identification using a novel local power histogramming descriptor with an improved k-nearest neighbors classifier[J]. Sustainable Cities and Society, 2021, 67: 102764.
- [10] 杨秀, 李安, 孙改平, 等. 基于改进 GMM-CNN-GRU 混合的非侵入式负荷监测方法研究[J]. 电力系统保护与控制, 2022, 50(14): 65-75.
YANG Xiu, LI An, SUN Gaiping, et al. NON-invasive load monitoring based on an improved GMM-CNN-GRU combination[J]. Power System Protection and Control, 2022, 50(14): 65-75.
- [11] 郭红霞, 陆进威, 杨苹, 等. 非侵入式负荷监测关键技术研究综述[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.
- [12] 邱磊鑫, 余涛, 彭秉刚. 基于异构基 Stacking 机制的居民负荷特征图像识别方法[J]. 电力系统保护与控制, 2022, 50(20): 97-105.
QIU Leixin, YU Tao, PENG Binggang. Image recognition method of resident load characteristics based on heterogeneous basis Stacking mechanism[J]. Power System Protection and Control, 2022, 50(20): 97-105.
- [13] DEBAETS L, RUYSSINCK J, DEVELDER C, et al. Appliance classification using VI trajectories and convolutional neural networks[J]. Energy and Buildings, 2018, 158: 32-36.
- [14] HAN Yinghua, LI Keke, FENG Hantong, 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.
- [15] 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.
- [16] 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.
- [17] YIN Bo, ZHAO Liwei, HUANG Xianqing, et al. Research on non-intrusive unknown load identification technology based on deep learning[J]. International Journal of Electrical Power & Energy Systems, 2021, 131.
- [18] ZHANG Yusen, WU Hao, MA Qing, et al. A learnable image-based load signature construction approach in NILM for appliances identification[J]. IEEE Transactions on Smart Grid, 2023, 14(5): 3841-3849.
- [19] WENNINGER M, BAYERL S P, MAIER A, et al. Recurrence plot spacial pyramid pooling network for appliance identification in non-intrusive load monitoring[C] // 2021 20th IEEE International Conference on Machine Learning and Applications (ICMLA), December 13-16, 2021, Pasadena, USA: 108-115.
- [20] 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.
- [21] 崔昊杨, 吴轶凡, 江友华, 等. 非侵入式负荷识别的电流序列可视化方法[J]. 电力自动化设备, 2022, 42(7): 40-45.
CUI Haoyang, WU Yifan, JIANG Youhua, et al. Current sequence visualization method of non-intrusive load recognition[J]. Electric Power Automation Equipment, 2022, 42(7): 40-45.
- [22] MA Ningning, ZHANG Xiangyu, ZHENG Haotao, et al. Shufflenet v2: practical guidelines for efficient CNN architecture design[C] // Proceedings of the European conference on computer vision (ECCV), September 8-14, 2018, Munich, Germany: 116-131.
- [23] YANG Lingxiao, ZHANG Ruyuan, LI Lida, et al. Simam: a simple, parameter-free attention module for convolutional neural networks[C] // International conference on machine learning, PMLR, July 18-24, 2021: 11863-11874.
- [24] GAO Jingkun, 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, November 3-6, 2014, Memphis, USA: 198-199.
- [25] KAHL M, HAQ A U, KRIECHBAUMER T, et al. Whited-a worldwide household and industry transient energy data set[C] // 3rd international workshop on non-intrusive load monitoring, May 14-15, 2016, Vancouver, Canada: 1-4.
- [26] WANG Zhiguang, OATES T. Encoding time series as images for visual inspection and classification using tiled convolutional neural networks[C] // Workshops at the Twenty-ninth AAAI Conference on Artificial Intelligence, January 25-26, 2015, Austin, USA.

收稿日期: 2023-11-10; 修回日期: 2024-01-02

作者简介:

张 帅(1999—), 男, 通信作者, 硕士研究生, 研究方向为非侵入式负荷监测; E-mail: 1461842844@qq.com

程志友(1973—), 男, 博士, 教授, 主要研究方向为电能质量分析、电力负荷预测。E-mail: 94028@ahu.edu.cn

(编辑 周金梅)