文章编号：1000-3673（2025）11-4854-11　　中图分类号：TM 721　　文献标志码：A　　学科代码：470·40

基于彩色图像特征提取及融合的非侵入式负荷识别

魏广芬[1]，李谊林[1]，KUZENGURIRA T.Tapiwa[1]，赵航[2]，胡春华[2]，张玉猛[2]
（1. 山东工商学院信息与电子工程学院，山东省 烟台市 264005；
2. 烟台东方威思顿电气有限公司，山东省 烟台市 264003）

Non-intrusive Load Recognition Based on Color Image Feature Extraction and Fusion

WEI Guangfen[1], LI Yilin[1], KUZENGURIRA T. Tapiwa[1], ZHAO Hang[2], HU Chunhua[2], ZHANG Yumeng[2]
(1. School of Information and Electronic Engineering, Shandong Technology and Business University, Yantai 264005, Shandong Province, China;
2. Yantai Dongfang Wisdom Electric Co., Ltd., Yantai 264003, Shandong Province, China)

ABSTRACT: Non-Intrusive Load Monitoring (NILM) technology offers effective monitoring and analysis of electrical equipment's energy use and operational status, with wide application potential due to its cost-effectiveness and practicality. To enhance the recognition performance beyond traditional image-based NILM methods, this paper presents a novel approach for extracting and fusing three gray-scale image features. Utilizing a weighted recurrence diagram, Gram angle field, and Markov transfer field, the method captures steady-state current periodicity, similarity, time dependence, correlation, global and local trends. These features are transformed into three gray-scale matrices corresponding to the RGB channels of a color image, creating a rich feature set. We propose a lightweight convolutional neural network (CNN) model for load recognition to counter the complexity in processing color image features. This model maintains high accuracy with fewer parameters and faster iteration speeds, simplifying the analysis of color image features. Comparing with the typical state-of-the-art algorithms in the NILM field, experimental results demonstrate the superior recognition accuracy of the proposed method across multiple high-frequency datasets, showcasing its good robustness and generalization capability.

KEY WORDS: non-intrusive load monitoring; appliance recognition; weighted recurrence graph; Markov transition field; Gramian angular field; image feature

摘要：非侵入式负荷监测(non-intrusive load monitoring，NILM)技术可以有效监测和分析电器负荷设备的能耗及运行状态，其成本低、实用性强，具有广泛的应用前景。为有效提升基于图像特征的非侵入式负荷识别方法的识别效果，该文提出了一种新颖的 3 种 NILM 灰度图像特征提取及融合方法，分别通过加权递归图、格拉姆角场和马尔可夫转移场提取稳态电流周期性和相似性等重复模式特征、时间依赖性和相关性等静态特征及全局趋势和局部趋势等动态特征，得到 3 个 NILM 灰度图像矩阵，将其对应构建为彩色图像的红绿蓝 3 个颜色通道，从而融合为含有丰富负荷特征的彩色特征图像。进一步针对彩色特征图像处理复杂度提升的问题，提出了一种参数量更少、迭代速度更快同时保持高准确率的卷积神经网络负荷识别模型，有效降低了彩色图像分析模型的复杂度。与当前 NILM 领域的典型新型算法对比，该文所提负荷识别方法在多个高频数据集的识别精度均取得最优。

关键词：非侵入式负荷监测；负荷识别；加权递归图；马尔可夫变迁场；格拉姆角场；图像特征

DOI：10.13335/j.1000-3673.pst.2024.0972

0　引言

近年来，全球能源需求不断增加，世界一次能源消费需求年增长率达 1%至 2%，主要为电力能源需求，这给传统电网系统的效率和可靠性带来了严峻挑战[1-2]。调查表明，能耗反馈有望节能约 4.5%[3]，设备级别的能耗监测展现出更高的节能潜力[4]。非侵入式负荷监测(non-intrusive load monitoring, NILM)由 Hart[5]于 20 世纪 80 年代提出，旨在通过单个智能电表测量的多种电器设备的总负荷信息，分解出设备级别的电力能耗信息，一方面为用户提供细粒度的电力能耗详情，帮助用户树立完善的用

基金项目：国家自然科学基金项目(62173213)；山东省自然科学基金(ZR2019MF069)；烟台市科技创新发展项目(2020LJRC119)。

Project Supported by the National Natural Science Foundation of China (62173213); Natural Science Foundation of Shandong Province (ZR2019MF069); Yantai Science and Technology Innovation Development Project (2020LJRC119).

电节能意识；另一方面，详尽的能耗信息可以反映并反馈电力供需情况，电力供应商能更科学、可靠地调整用电策略，推进智能电网的构建[6-10]。

负荷识别指从聚合的能耗信息提取负荷特征来识别运行的电器设备类型及状态，是 NILM 领域目前面临的重要挑战之一，其关键在于负荷特征的提取。理想的负荷特征应该具有对目标设备表征的唯一性和多种设备表征的差异性，也就是应该能够最大程度减小同一类型用电设备实例之间的差异性，同时尽可能地增加不同类型用电设备之间的区分度[11]。

随着计算机视觉领域的发展，负荷识别开始转向图像特征表示。电压(U)-电流(I)轨迹特征最早成为 NILM 技术与计算机视觉领域的媒介，它将两个一维的负荷信号转变为通过视觉表达的二维轨迹图。将 U-I 轨迹映射为二值化图像，可以尽可能地保存了轨迹信息，同时降低了计算复杂度[12]。但 U-I 轨迹二值化会丢失一些负荷特征信息，从而导致设备的识别性能较差，因而分别尝试融入了动量、电流幅值、功率等负荷信息构建了灰度 U-I 轨迹[13]、彩色 U-I 轨迹[14-16]以及充分利用无效像素的彩色 U-I 轨迹，识别效果逐级提升。

二值 U-I 轨迹图像的实质是将电流与电压数据归一化，这意味着 U-I 轨迹损失了部分幅值信息，仅传递了轨迹形状信息，无法反映功率、谐波等电力特性，因而导致构建的 U-I 轨迹图像特征不能充分表征电器设备。随着电器种类繁多，尤其一些工作原理相似的电器 U-I 轨迹类似[17]，导致基于 U-I 轨迹特征的识别能力提升难度增加。

为了提高负荷特征的唯一性和差异性，近年来研究人员探索提出了一些构建图像特征的其他方法，即借助一些非线性算法提取时间序列中的重复模式、时频特性等负荷信息来构建灰度图像特征，广泛应用于非侵入式负荷识别[17-21]。递归图方法(recurrence graph，RG)通过分析时间序列的递归特性，将其转换为特征图像[18-19]。与 U-I 轨迹不同，RG 通过距离相似矩阵与预设阈值的比较来构建图像特征，可以识别 U-I 轨迹无法识别的设备。但 RG 中的预设阈值参数目前还没有标准的设置方案，通常需要根据经验知识获得，这容易造成部分负荷信息的丢失，影响负荷识别性能[20]。其他几种类似 RG 的图像特征方法，同样存在着部分负荷信息丢失的问题，例如格拉姆角场(Gramian angular field，GAF)的归一化过程[21-23]。RG、GAF 等方法提取的负荷特征各具特色，如果能合理融合几类方法，构建的负荷特征能更充分地反映电器设备的独特特性[24-25]。

将电力信息转换为图像特征后，负荷识别问题就转化成了图像识别问题。卷积神经网络(convolutional neural networks，CNN)基于局部连接和权重共享方式，利用卷积层、池化层能够充分挖掘图像数据的局部判别特征，在图像识别方面具有出色的判别能力，在 NILM 问题中，CNN[13,16]及其变种识别模型，例如 AlexNet[14]、TSCNN[21]等模型都已广泛应用于负荷识别问题。

为了能进一步提高负荷特征的唯一性，该文提出了一种新颖的多维度图像特征提取方法，分别是基于加权递归图(weighted recurrence graph，WRG)提取稳态电流周期性和相似性等重复模式的灰度图像特征 R，基于格拉姆角场(Gramian angular field，GAF)提取稳态电流的时间依赖性和时间相关性等静态特性的灰度图像特征 G，基于马尔可夫变迁场(Markov transition field，MTF)方法提取稳态电流的全局趋势和局部趋势等动态特性的灰度图像特征 M。进一步将各维度灰度图像特征融合构建为彩色特征图像，以期提高 NILM 中负荷特征的唯一性。为了更精准地实现彩色特征图像识别，在 RGM 彩色特征图像的基础上，进一步提出参数量更少、网络层级更浅的应用于 NILM 彩色特征图像负荷识别的 RGM-CNN 识别模型，并与其他典型算法进行对比，验证其是否达到迭代速度更快且保持高识别准确率的目的。为有效衡量 NILM 数据集的差异性，该文还提出使用类内散度矩阵和类间散度矩阵以更精准地衡量 PLAID、WHITED 等多类内部特性相异的高频公共数据集的特性，以用于综合评估上述方法。

1 彩色图像特征提取及融合方法分析

NILM 系统通常使用电流传感器、电压传感器、智能电表等监测设备来获取各用电设备的聚合的电压、电流或其他电力信息[26-27]。将某 NILM 设备对 M 种电器负荷监测获得的电力信号记为 $s(t)$，每种负荷用 k 标识，由叠加性可得式(1)所示电力信号模型：

$$s(t)=\sum_{k=1}^{M}a_k x_k(t)+n(t),\ k\in\{1,2,\ldots,M\} \tag{1}$$

式中：$x_k(t)$ 代表第 k 种负荷单独运行的电力信号；$a_k\in\{0,1\}$ 对应第 k 种负荷运行与否，运行时 $a_k=1$，不运行时 $a_k=0$；为噪声。

NILM 负荷识别的核心目标为从混合电力信号

$s(t)$中识别各类目标负荷 k，因而可以视作多分类问题。为深入挖掘电器负荷特征，该文提出基于彩色图像特征提取及融合的负荷识别方法，总体流程如图 1 所示。将由设备获取的数据预处理后，经由 RGM 图像特征提取和特征融合为彩色特征图像，进而由设计的 CNN 负荷识别网络识别，获得结果。

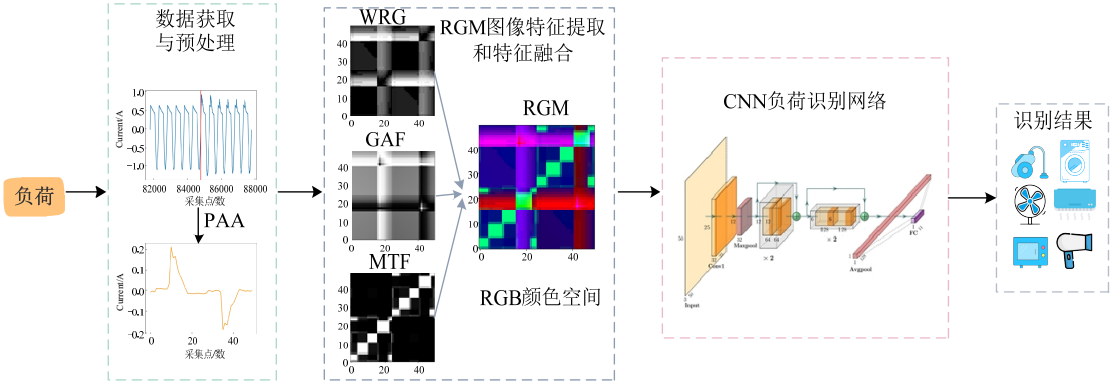


图 1　基于 RGM-CNN 的非侵入式负荷识别整体流程

Fig. 1　Overall process of non-invasive load recognition based on RGM-CNN

1.1　数据获取与预处理

该文使用 NILM 设备监测得到的负荷设备切换前后的稳态电流信号 $i(t)$为电力信号 $s(t)$。如果某电器启动，则该电器的稳态电流为 $i(t)=i_{\text{after}}(t)-i_{\text{before}}(t)$；反之若电器关闭，对应电器稳态电流为 $i(t)=i_{\text{before}}(t)-i_{\text{after}}(t)$，其中 $i_{\text{before}}(t)$ 和 $i_{\text{after}}(t)$ 分别是启动或关闭事件发生前后的电流信号[28]。以紧凑型荧光灯的启动为例，图 2(a)为该电器启动前后的某 NILM 设备测得的电流信号，提取事件切换前后的 N_s 个周期的稳态电流信号，取平均以降低噪声的影响，分别得到紧凑型荧光灯切换前后的一个周期稳态电流信号 $i_{\text{before}}(t)$ 和 $i_{\text{after}}(t)$，见图 2(b)和(c)。由于电流数据为增量型负荷特征，符合特征叠加原理[20]，可利用两个连续快照的差异计算得出紧凑型荧光灯的稳态电流特征，见图 2(d)。该文后续基于稳态电流时间 $i(t)$ 来识别各类电器负荷。

以 PLAID 数据集为例，按照上述流程从各类电器任选一例进行稳态电流提取，得到结果如图 3 所示。由于各类电器的幅值存在很大差异，以 2A 为界限进行划分，可以发现各类电器的电流轨迹差异较为明显，而且大多轨迹都严重偏离了正弦波。

1.2　图像特征提取

为了表述连贯，后文使用连续时间变量 $s(t)$ 暂代稳态电流序列 $i(t)$，根据采样频率将其采样量化后得到时间序列 $S=\{s_1,s_2,\cdots,s_\omega\}$，进一步将其转化为灰度图像特征。

1.2.1　Red 通道

Red 通道选用 WRG 方法生成灰度特征矩阵 $\boldsymbol{R}$，将时间序列转换为图像表示，以提取序列的周期性和重复性等相似模式[16]。

对于给定的时间序列 $\boldsymbol{S}$，首先计算序列的距离相似性矩阵 $\boldsymbol{D}_{\omega\times\omega}$，见式(2)。

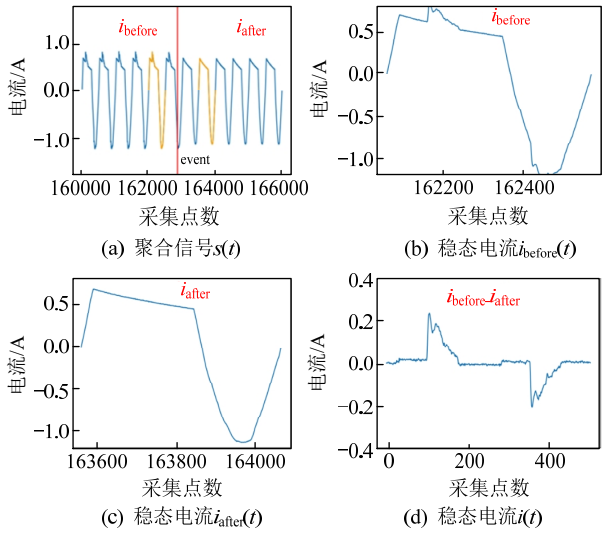


图 2　紧凑型荧光灯启动后稳态电流的提取流程

Fig. 2　Extraction process of steady-state current after compact fluorescent lamps start-up

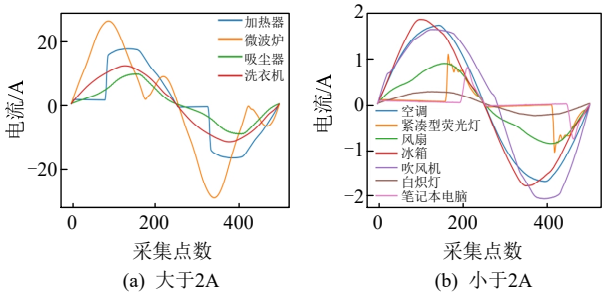


图 3　PLAID 数据集中各类电器电流轨迹 $i(t)$

Fig. 3　Current trajectories $i(t)$ of various electrical appliances in the PLAID dataset

$$\boldsymbol{D}_{\omega\times\omega}=\{\|s_i,s_j\|,s_i,s_j\in S\}=\{d_{i,j}\mid i,j\in[1,\omega]\}\quad(2)$$

式中：s_i 和 s_j 代表时间序列中的元素；$\|\cdot\|$ 代表欧几里得范数；$d_{i,j}$ 为序列中 s_i 和 s_j 的欧氏距离。

引入参数 δ,τ，将距离相似性矩阵 $\boldsymbol{D}_{\omega\times\omega}$的元素

值约束在$[0,\delta]$之间，得到灰度矩阵 $\boldsymbol{R}$，其各元素为

$$R_{i,j}=\begin{cases}\delta, & \tau>\delta\\ \tau, & \tau\le\delta\end{cases} \tag{3}$$

式中：$\delta\ge1$；$\tau=\left\lfloor d_{i,j}/\varepsilon\right\rfloor$；$\varepsilon$ 代表阈值，其通常利用经验知识来进行选取；$\lfloor\cdot\rfloor$代表向下取整。借鉴文献[19]，文中设置 PLAID 数据集参数 δ=20，ε=0.1；WHITED 数据集参数 δ=50，ε=0.001。

图 4 为获得的 PLAID 数据集中 4 类电器的灰度矩阵 $\boldsymbol{R}$，其中吹风机和风扇的电流轨迹类似，$\boldsymbol{R}$ 灰度图整体类似但局部灰度差异明显。对于电流轨迹差异明显的风扇和加热器，$\boldsymbol{R}$ 灰度图展现出截然不同的特征表示。$\boldsymbol{R}$ 灰度图反映了时间序列的畸变性，畸变性越大，灰度图相邻像素点距离越远，会形成具有部分纹理结构的形态；反之则会形成较为光滑的形态。

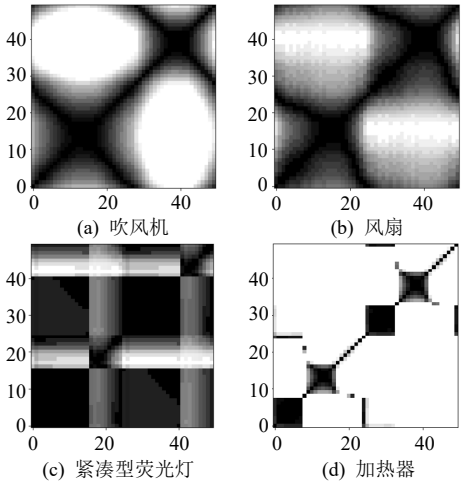


图 4　PLAID 数据集中 4 类电器的 *R* 灰度图

Fig. 4　Grayscale image *R* of four types of electrical appliances in PLAID dataset

1.2.2　Green 通道

Green 通道选用 GAF 方法生成灰度矩阵 $\boldsymbol{G}$，该方法将时间序列数据 S 映射到极坐标系，然后计算相邻时间点的正弦差来构造图像特征矩阵，旨在提取时间序列中的时序模式[29-30]。

首先对数据进行归一化，见式(4)，

$$\overline{s}_i=\frac{(s_i-s_{\max})+(s_i-s_{\min})}{s_{\max}-s_{\min}},\ \overline{s}_i\in[-1,1] \tag{4}$$

式中：$s_{\max}$ 和 $s_{\min}$ 分别代表时间序列中的最大值和最小值。

然后将归一化后的数据映射到极坐标系，以归一化后时间序列的角余弦作为极坐标系的角度值，时间值作为极坐标系的半径，如式(5)所示。

$$\begin{cases}\theta_i=\cos^{-1}(\overline{s}_i),\ \overline{s}_i\in[-1,1]\\ r_i=\dfrac{t_i}{N},\ t_i\in N\end{cases} \tag{5}$$

式中：t_i 和 N 分别是将序列时间跨度等分的时间点和总时长。由于采样信号为时间序列，时间值为线性增量，因而极轴半径坐标值可忽略。

最后计算任意两时间点间的正弦差，得到灰度特征矩阵 $\boldsymbol{G}$，见式(6)。

$$\boldsymbol{G}=\begin{bmatrix}\sin(\theta_1-\theta_1) & \cdots & \sin(\theta_1-\theta_\omega)\\ \sin(\theta_2-\theta_1) & \cdots & \sin(\theta_2-\theta_\omega)\\ \vdots & \ddots & \vdots\\ \sin(\theta_\omega-\theta_1) & \cdots & \sin(\theta_\omega-\theta_\omega)\end{bmatrix} \tag{6}$$

由式(6)可知，灰度特征 $\boldsymbol{G}$ 中的元素值代表序列中时间步长为 $T=t_i-t_j$ 的两时间点间的角度关系，其值能够揭示序列的周期性、相位关系等时间相关性，主对角线元素反映了 $T=0$ 的特殊情形。在 $\boldsymbol{G}$ 矩阵构建过程中，时间沿着对角线方向从左上角到右下角增加，蕴含了序列的时间依赖性。图 5 为吹风机、风扇、紧凑型荧光灯和加热器的灰度特征 $\boldsymbol{G}$，可以看出，电流轨迹的细微区别，在灰度图 $\boldsymbol{G}$ 上表现了差异较大的纹理特征。

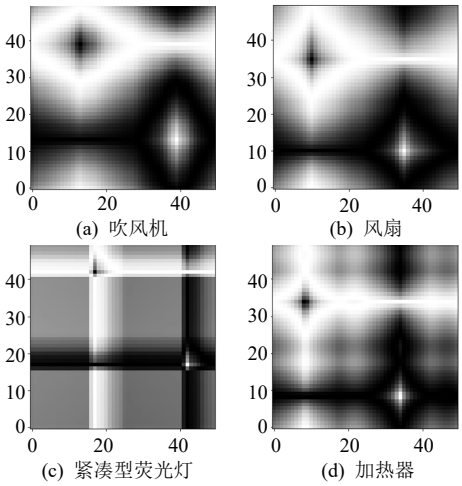


图 5　PLAID 数据集中 4 类电器的 *G* 灰度图

Fig. 5　Grayscale image *G* of four types of electrical appliances in PLAID dataset

1.2.3　Blue 通道

Blue 通道选用 MTF 方法生成灰度矩阵 $\boldsymbol{M}$，该方法于 2015 年提出，可以将时间序列数据转化为二维矩阵，以捕获数据中的动态趋势和状态转换特性[22-23]，已被广泛应用于图像处理和模式识别等领域[31]。该文首次将其引入到 NILM 领域，用来提取稳态电流信号的动态趋势特征。

首先根据时间序列 S 的取值范围将其划分为 Q 个分位数箱 $q_l(l\in[1,Q])$，并将每个 $s_k(k\in\{1,2,\cdots,\omega\})$ 映射到对应的 q_l 中。然后沿时间轴方向以第一阶马尔可夫链的思想计算分位数箱之间的转移概率，构建一个 $Q\times Q$ 的马尔可夫转移矩阵 $\boldsymbol{W}$，见式(7)。

$$\boldsymbol{W}=\begin{bmatrix} w_{11} & \cdots & w_{1Q} \\ \vdots & \ddots & \vdots \\ w_{Q1} & \cdots & w_{QQ} \end{bmatrix} \tag{7}$$

式中：$w_{kl}(k,l\in\{1,2,\cdots,Q\})$表示$q_k$中元素被$q_l$跟随的概率，即$w_{kl}=P(s_m\in q_k\,|\,s_n\in q_l)$，其中$m-n=1$。

$\boldsymbol{W}$矩阵中元素值为相邻两时间点所对应分位数箱间的转移概率，仅考虑时间跨度为1的情形，没有充分利用时间序列整体时间跨度信息，造成部分特征丢失。为了克服这一缺点，依据每个时间跨度顺序排列每个概率来扩展马尔可夫矩阵$\boldsymbol{W}$，从而得到马尔可夫变迁场矩阵$\boldsymbol{M}$。

$$\boldsymbol{M}=\begin{bmatrix} M_{11} & M_{12} & \cdots & M_{1\omega} \\ M_{21} & M_{22} & \cdots & M_{2\omega} \\ \vdots & \vdots & \ddots & \vdots \\ M_{\omega 1} & M_{\omega 2} & \cdots & M_{\omega\omega} \end{bmatrix}=\begin{bmatrix} P(s_1\in q_{s_1}\,|\,s_1\in q_{s_1}) & P(s_1\in q_{s_1}\,|\,s_2\in q_{s_2}) & \cdots & P(s_1\in q_{s_1}\,|\,s_\omega\in q_{s_\omega}) \\ P(s_2\in q_{s_2}\,|\,s_1\in q_{s_1}) & P(s_2\in q_{s_2}\,|\,s_2\in q_{s_2}) & \cdots & P(s_2\in q_{s_2}\,|\,s_\omega\in q_{s_\omega}) \\ \vdots & \vdots & \ddots & \vdots \\ P(s_\omega\in q_{s_\omega}\,|\,s_1\in q_{s_1}) & P(s_\omega\in q_{s_\omega}\,|\,s_2\in q_{s_2}) & \cdots & P(s_\omega\in q_{s_\omega}\,|\,s_\omega\in q_{s_\omega}) \end{bmatrix} \tag{8}$$

式中：q_{s_k}代表采样点s_k对应的分位箱；$M_{i,j}\ (i,j\in[1,\omega])$代表采样点$s_i$对应的分位数箱到$s_j$对应的分位数箱之间的转移概率，例如$M_{13}$表示时间序列信号$s_1$对应分位数箱转移到$s_3$对应分位数箱的概率。$\boldsymbol{M}$矩阵中的每个元素$M_{ij}$表示时间跨度为$|i-j|$之间的转移概率，$M_{ij|i-j|=1}$代表相邻时间点之间的转移概率，$M_{ii}$情形比较特殊，时间跨度为0，提取的是自身的转移概率。

$\boldsymbol{M}$矩阵本质上编码了时间序列中多时间跨度的转移概率，从而提取了电流数据中多时间跨度的转移概率。当时间跨度为1时，像素点代表相邻时间点对应分位数箱的转移概率，多个相邻的像素点组成不同的局部图像，从而反映电流序列的短期趋势、异常点等局部趋势；当时间跨度不为1时，可以反映电流序列整体的转移概率，从而揭示整体上升或下降等全局趋势。图6为PLAID数据集中吹风机、风扇、紧凑型荧光灯和加热器的$\boldsymbol{M}$灰度图，可以看出吹风机和风扇电流轨迹整体上趋势相似，仅存在局部差异，因此对应的$\boldsymbol{M}$图在整体上存在很大的相似性，但在像素点20和像素点40处，两者的图像存在明显的弧度差异和形状差异；而紧凑型荧光灯和加热器与吹风机、风扇电流轨迹差距明显，生成的$\boldsymbol{M}$图也相差甚远。

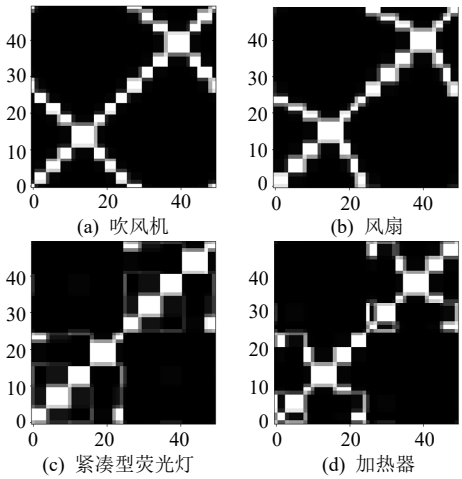


图6 PLAID数据集中4类电器的$\boldsymbol{M}$灰度图

Fig. 6 Grayscale image $\boldsymbol{M}$ of four types of electrical appliances in PLAID dataset

1.3 彩色特征图像融合

通过WRG、GAF和MTF方法分别计算得到灰度特征矩阵$\boldsymbol{R}$、$\boldsymbol{G}$和$\boldsymbol{M}$，与RGB彩色颜色空间的Red通道、Green通道、Blue通道一一对应，获得三维灰度矩阵$[\boldsymbol{R}\ \boldsymbol{G}\ \boldsymbol{M}]^{\mathrm{T}}$，其本质上也可以理解为一张彩色图像，简称为RGM彩色特征图像。为了更清晰地展现RGM特征的独特性，对PLAID2017数据集中的11类电器，分别随机选择一例进行RGM特征图像编码(见附录中的图A1)。

从图A1可以看出，RGM特征图像从相似模式、趋势、时间相关性及依赖性等维度综合提取了电流信号的特征信息，能更加丰富、全面地反映稳态电流的特征。单一灰度特征表达时，由于风扇和吹风机的电流轨迹趋势类似，从而两者单通道图像特征差异不够明显，容易引起误判。但将风扇和吹风机上述特征融合为RGM彩色特征图像后，见附录图A1(c)与(e)，能明显看出两者的差异，这也客观证明了RGM彩色特征图像提取了更全面的负荷特征信息，能更准确地区分多种类型电器设备。

1.4 RGM-CNN识别网络架构

RGM彩色特征图像提取了更全面的特征信息，提高了负荷特征的独特性，但在一定程度上也提高了计算的复杂度。此外，NILM领域监测设备，如智能电表等，搭建的芯片的算力通常有限，这也限制了识别模型的复杂程度。

CNN具有能够自动提取图像特征、利用局部感知野捕捉细节信息、通过多层结构学习图像的层次化特征等优势，在图像识别领域得到广泛应用。

为了有效降低彩色图像识别模型的复杂度，提出一种适用于RGM图像特征识别的CNN识别模型，以实现模型参数量少、网络层级更浅、迭代速

度快，且保持高识别准确率的目标。具体模型结构见附录图 A2，包括依次连接的卷积层、两层池化层、两个残差块以及一个全连接层，图中长方体的变化代表经过 CNN 各网络层后数据维度的改变。核心部分是两个残差模块，第一个残差模块由两个 BasicBlock 层组成，BasicBlock 层包括两个卷积层，一层输入维度为 32，使用 64×3×3 进行卷积，步幅为 1×1，填充为 1×1，使用 ReLU 函数作为激活函数；另一层输入维度为 64，使用 64×3×3 进行卷积，步幅和填充保持相同。第二个残差模块与第一个残差块结构相似，第一个卷积层使用 128×3×3 进行卷积，步幅为 2×2，其余部分使用 128×3×3 进行卷积，步幅为 1×1。输出层为全连接层(fully connected layers，FC)，将之前层级提取的特征映射到最终的输出类别，以 PLAID 数据集为例，其共包含 11 种电器，则 FC 层输出值为 11。

该文设计的 CNN 模型使用多通道卷积提取方法，利用多个卷积核分别对 RGM 图像的 3 个颜色通道进行卷积操作，然后将各颜色通道的卷积结果相加得到最终的输出，这样可以有效地组合和提取各颜色通道的特征，提高负荷识别效果。

3　结果与讨论

3.1　数据集

在 NILM 领域，PLAID 和 WHITED 等高频公共数据集被广泛用于负荷识别性能的评估。根据采集方式的不同，公共数据集可以分为采集子类电器信息和采集所有电器信息的数据集。后者的采集过程包含了电器特性的相互影响，其负荷识别难度通常高于前者。为了更全面评估和验证提出的非侵入式负荷识别方法，该文分别使用不同采集方式多个公共数据集进行综合评估分析。

PLAID 数据集以 30KHz 的采样频率采集家用电器的电压和电流值，截至目前有 3 个版本：PLAID2014、2017、2018。PLAID2018 同时包含两种采集方式，分别简称为 PLAID2018Sub 和 PLAID2018Agg[32-33]。各数据集中电器的测量情况见附录图 A3。WHITED 数据集是一个全球家庭和行业瞬态能量数据集，其采样频率为 44.1KHz[34]。该文选择其中 21 类家用电器进行分析。

不同的数据集具有不同的内部特性，负荷识别的难度也不尽相同。文献[14]通过绘制有功和无功功率分布图，表明 PLAID 数据集具有更高的类内变化(intra-class variety，IACV)，WHITED 数据集具有更高的类间变化(inter-class variety，IECV)。文献[21]更进一步定义将 IACV 和 IECV 定义为同类设备内的平均欧几里得距离和不同类设备间的平均欧几里得距离。类内散度矩阵和类间散度矩阵已被证明可以精准评估这两类数据集的内部特性 IACV 和 IECV[35]。

设有 M 个类别 $\Omega_1,\cdots,\Omega_M$，其中属于 Ω_i 类别的样本集合为 $\{X_1^{(i)},\cdots,X_{N_i}^{(i)}\}$，其类内散度矩阵定义为

$$\boldsymbol{S}_{\mathrm{w}}^{i}=\frac{1}{N_i}\sum_{k=1}^{N_i}(X_k^{(i)}-m^{(i)})(X_k^{(i)}-m^{(i)})^{\mathrm{T}} \tag{9}$$

式中：$m^{(i)}$ 为属于 Ω_i 类的样本均值；N_i 为属于 Ω_i 类的样本总数。

总类内散度矩阵 $\boldsymbol{S}_{\mathrm{w}}$ 和类间散度矩阵 $\boldsymbol{S}_{\mathrm{B}}$ 定义为

$$\begin{cases}\boldsymbol{S}_{\mathrm{w}}=\sum_{i=1}^{M}P(\Omega_i)\boldsymbol{S}_{\mathrm{w}}^{i}\\ \boldsymbol{S}_{\mathrm{B}}=\sum_{i=1}^{M}P(\Omega_i)(m^{(i)}-m)(m^{(i)}-m)^{\mathrm{T}}\end{cases} \tag{10}$$

式中：$P(\Omega_i)$ 代表 Ω_i 类别出现的概率；$\boldsymbol{S}_{\mathrm{w}}^{i}$ 为 Ω_i 类别的类内散度矩阵；m 为所有样本的总体均值。进一步，定义类内散度矩阵和类间散度矩阵的迹为数据集的 IACV 和 IECV，记作

$$\begin{cases}\sigma_{\mathrm{IACV}}=\mathrm{tr}(\boldsymbol{S}_{\mathrm{w}})\\ \sigma_{\mathrm{IECV}}=\mathrm{tr}(\boldsymbol{S}_{\mathrm{B}})\end{cases} \tag{11}$$

各数据集的 IACV 和 IECV 计算结果见附录 A 的表 A1。可以发现，WHITED 比 PLAID 数据集具有更高的 IECV 值，说明其类间变化较大；而两数据集的 IACV 值比较相近，说明其类内变化相近，但由于 PLAID 几个数据集的电器类别远少于 WHITED，因而其 IACV 值的变化较为剧烈。

3.2　实验评估指标

宏平均分数 F_{macro} 和马修斯相关系数(Matthews correlation coefficient，MCC)是负荷识别领域常用的评估指标，它们不受数据类别失衡的影响[36-38]，能更精准地度量分类效果。同时引入混淆矩阵来更直观、更精准地可视化负荷识别的结果。

F_{macro} 定义为 $F_{\mathrm{macro}}=\frac{1}{M}\sum_{i=1}^{M}F_{\mathrm{l}}$，其中 M 代表用电设备的类型数量，F_{l} 代表各类用电设备的宏平均分数，其通过精确率 $P_{\mathrm{Precision}}$ 和召回率 R_{Recall} 来计算。

$$\begin{cases}P_{\mathrm{Precision}}=\dfrac{T_{\mathrm{P}}}{T_{\mathrm{P}}+F_{\mathrm{P}}}\\ R_{\mathrm{Recall}}=\dfrac{T_{\mathrm{P}}}{T_{\mathrm{P}}+F_{\mathrm{N}}}\\ F_{\mathrm{l}}=\dfrac{2P_{\mathrm{Precision}}R_{\mathrm{Recall}}}{P_{\mathrm{Precision}}+R_{\mathrm{Recall}}}\end{cases} \tag{12}$$

式中：T_P 代表正类被预测为正类的数量；F_P 代表负类被预测为正类的数量；F_N 代表负类被预测为负类的数量；F_{macro} 和 F_1 综合了准确率与召回率，能更全面地评估负荷识别效果。

定义 ρ_{MCC} 为分类效果的平衡性能度量指标，其取值位于[–1,1]，越接近 1，说明预测结果越有说服力，其计算见式(13)，

$$\rho_{MCC}=\frac{(T_PT_N-F_PF_N)}{\sqrt{(T_P+F_P)(T_P+F_N)(T_N+F_P)(T_N+F_N)}} \tag{13}$$

式中：T_N 代表正类被预测为负类的数量。

3.3 图像特征大小

PLAID 和 WHITED 数据集都为高频采样，为了降低图像特征计算的繁琐程度，使用分段聚合近似(piecewise aggregate approximation，PAA)降低电流信号的维度，降维后的数据长度记作ω，即特征图像大小为ω。PAA 的基本思想是将时间序列分割成ω段长度相等的子序列，然后对每个子序列取平均值或其他汇总统计量来重构原时间序列。PAA 通常能够降低时间序列数据的维度，减少了数据的存储需求和计算复杂度，同时保留了时间序列的主要特征，但 PAA 是一种有损降维方法，可能会导致某些细节信息的丢失。因此ω是需要预先设定的超参数，ω的选取关乎到整体的负荷识别性能与识别速率。

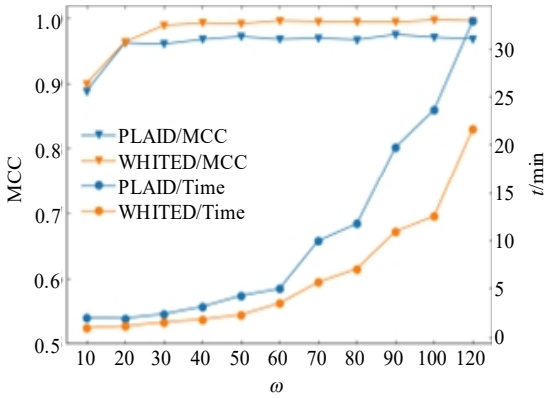


图 7 图像大小ω对 MCC 和训练时间的影响

Fig. 7 Influence of image size ω on MCC and training time

研究首先设置实验讨论图像大小ω 对识别效果的影响，结果见图 7。可以看出，ω 值过小会导致部分特征损失，识别准确率较低；当ω=30 时，识别准确率达到近似峰值，后续ω值继续增大，识别准确率有提高但不显著。该结果与文献[31]对 U-I 图像的分析相同，ω 值到达一定大小后，继续增加ω值并不会提高识别性能。反而ω 值的增加严重影响了学习速度，降低了识别速率，数据集越大受到的影响越明显。通过综合评估 PLAID 和 WHITED 两个数据集的识别准确率和运行时间，本研究选取图像大小ω=50。

3.4 实验设计

为了验证所提方法的有效性，将所提出的 RMG 彩色特征图像与 U-I 轨迹图像、AWRG 特征图像和 PA-GAF 特征图像进行识别效果的对比。其中，AWRG 特征图像为 WRG 特征的改进版，PA-GAF 特征图像提出使用 PA-transformation 机制对 GAF 方法进行改进以最小化 GAF 的信息损失，然后对电流、电压和无功电流进行提取，构建彩色图像特征。U-I 轨迹、AWRG 和 PA-GAF 特征均为当前先进的负荷图像特征。为了公平比较，所有图像特征大小相同，皆设为 50。U-I 轨迹特征图像和 AWRG 特征图像复制到 3 个颜色通道构建对应的彩色特征图像，并对应将参数设置为 RGM-CNN 模型的可学习权重参数。将 RMG 图像特征、U-I 轨迹特征、AWRG 和 PA-GAF 特征分别作为 CNN 模型的输入，使用 PLAID 和 WHITED 数据集进行训练和识别，评估指标选用 F_{macro}、ρ_{MCC} 和混淆矩阵。采用 K 折交叉验证，并设置合理的早停标准，来避免模型训练过程出现过拟合现象以及获得更具有信服力的预测结果。

3.5 在数据集上的结果

表 1 列出了在 5 个公共数据集上的 10 折交叉验证结果。可以看出，U-I 特征的识别效果最差且不稳定，在 PLAID2018Agg 和 WHITED 数据集上评估指标 F_{macro} 和 ρ_{MCC} 都低于 90%，主要原因是 U-I 轨迹负荷特征只提取轨迹的形状信息，蕴含的信息量少，不利于图像识别模型的深度挖掘。AWRG 特征和 PA-GAF 特征识别效果相当，5 个数据集的评估指标 F_{macro} 和 ρ_{MCC} 都超过 95%，其中 AWAG 特征在 PLAID 数据集上保持领先，而在 WHITED 数据集上略差于 PA-GAF 特征。AWRG 特征和 PA-GAF 特征利用非线性的算法提取了更多的负荷特征信息，特征集中且丰富，一定程度上提升了负荷特征的辨识度。该文提出的 RGM 彩色特征图像融合了 WRG、MTF 及 GAF 特征，更全面地提取了电流的能量数据信息，更深刻地捕捉了电器信号特性，有效提高了负荷特征的唯一性，在 5 个数据集上效果均最优，在 PLAID 和 WHITED 平均识别精度分别达到 97.60%和 99.2%。

附录图 A4 展示了使用 PA-GAF 特征、AWRG 特征及 RGM 特征对 PLAID2017 数据集中各类电器识别的 F_{macro} 值。可以发现，对于大多数电器，

表 1 PLAID 和 WHITED 数据集上的实验结果
Table 1 Experimental results on the PLAID and WHITED datasets

数据集	负荷特征	F_{macro}/%	ρ_{MCC}/%
PLAID2014	U-I	93.38±0.03	93.09±0.03
	AWRG	95.72±0.022	95.47±0.021
	PA-GAF	95.83±0.03	95.81±0.03
	RGM	**96.42±0.02**	**96.44±0.02**
PLAID2017	U-I	91.65±0.015	91.14±0.016
	AWRG	96.66±0.01	96.32±0.011
	PA-GAF	95.74±0.008	95.26±0.009
	RGM	**97.47±0.006**	**97.21±0.007**
PLAID2018Sub	U-I	92.55±0.026	92.18±0.026
	AWRG	97.11±0.012	96.82±0.013
	PA-GAF	95.31±0.021	94.80±0.023
	RGM	**98.23±0.012**	**98.05±0.013**
PLAID2018Agg	U-I	88.64±0.022	87.84±0.023
	AWRG	96.88±0.016	96.63±0.017
	PA-GAF	96.16±0.009	96.01±0.010
	RGM	**98.30±0.011**	**98.16±0.012**
WHITED	U-I	89.96±0.030	87.91±0.026
	AWRG	96.64±0.024	96.45±0.026
	PA-GAF	97.53±0.018	97.451±0.018
	RGM	**99.28±0.006**	**99.27±0.006**

PA-GAF 识别效果最差，AWRG 的识别效果次之，RGM 彩色特征图像实现了全方位的超越。而对于洗衣机、空调、风扇和冰箱 4 类电器，3 种负荷特征识别效果都不理想。从附录表 A2 对这 4 类电器的类内和类间属性分析可以发现，空调、洗衣机和冰箱等类别的 IECV 较小从而易混淆，且这 4 类电器均为多状态电器，尤其空调具备加热、通风、制冷等运行模式，该类别的 IACV 较大，从而增大了它们的识别难度。进一步可以看出，相较于其他图像特征，所提 RGM 特征对这 4 类电器的识别效果均有提升，且冰箱识别效果提升较大。

附录图 A5 给出了基于 AWRG 和 RGM 特征识别的混淆矩阵，可以看出该文 RGM 特征更全面提取了能量信息，能更有效地区分多状态类型电器。以冰箱为例，使用 AWRG 特征时，结果显示有 20 个冰箱电器错判，而当使用 RGM 特征时，仅有 13 个冰箱电器被错判。

WHITED 数据集具有较大的 IECV 和较小的 IACV，说明其类间变化大，类内变化小，相较于 PLAID 数据集的识别难度低。附录图 A6 为 WHITED 数据集的各类电器的 F_1 分数，可以看到，RGM 特征识别效果总体优于 PA-GAF 和 AWRG 特征，共有紧凑型荧光灯等 14 类电器的 F_1 分数达到 100%，而 PA-GAF 和 AWRG 特征分别只有 5 类和 6 类达到 100%。附录图 A7 展现了 WHITED 数据集上分别使用 PA-GAF 和 RGM 特征得到的混淆矩阵，可以更明显地看出，RGM 特征有效减少混淆类别及数量，熨斗、吹风机、钻孔机等多类电器都实现全部正确分类。

3.6 讨论

3.6.1 负荷识别方法耗时分析

该文在稳态电流基础上，提出一种基于 WRG、GAF 和 MTF 的彩色特征图像提取方法，该方法可以多维度提取稳态电流特征的电力信息，提高负荷特征的唯一性。但另一方面，一定程度上也增加了负荷特征提取的复杂程度，可能会影响负荷识别的整体效率。因此该文计算了特征提取和负荷识别各部分的耗时情况，具体见附录中的表 A3。

从表 A3 可以看出，所提方法在特征提取和负荷识别两个部分耗时都较低，其中 RGM 特征提取耗时最多，为 0.0039s，其余模块大多为 0.001s 左右，整体流程耗时 0.0078s，这表明该文所提方法可以实现接近实时的负荷识别。

3.6.2 采样频率对识别效果的影响

在 NILM 领域，采样频率是至关重要的一个参数。随着采样频率的提升，能够获取更为详尽的电力信息，从而使得负载特征更具唯一性，进而提高识别的准确度。然而，提高采样频率的同时，也会增加对硬件设备的要求，并且会导致采集到的电力信息增多，加大了特征提取的计算复杂度。

为了更进一步研究采样频率与识别效果的关系，通过下采样的方式模拟各种采样频率并计算识别率。图 8 为 PLAID 数据集在不同采样频率下的 F_{macro} 值，可以发现随着采样频率的下降，识别准

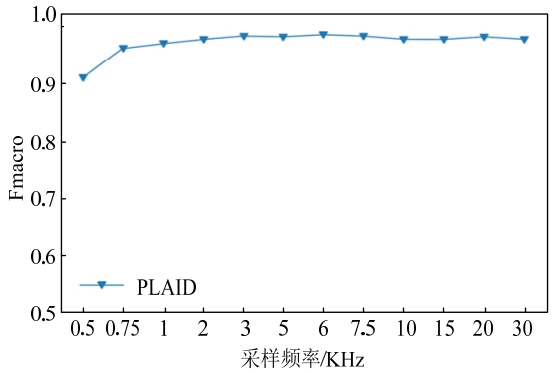


图 8 PLAID2017 数据集中采样频率对识别效果的影响
Fig. 8 Influence of sampling frequency on recognition in the PLAID2017 dataset

确度并没有明显降低，当采样频率小于 2kHz 时，识别准确度略有降低但仍保持在 90%以上。这意味着所提方法允许在一定范围内降低采样频率，从而可以降低对采样设备的硬件要求，减少采样成本。

3.6.3 RGM 特征图像对负荷识别的影响

在 PLAID2017 数据集上设计了 WRG、GAF 和 MTF 3 种灰度特征的对比试验，结果如表 2 所示，表中值代表使用两种特征提取方法提取负荷特征进行负荷识别的 F_{macro} 分数，例如第 2 行第 3 列即使用 WRG 和 GAF 方法进行特征提取，斜对角线代表使用单一负荷特征提取的结果。

表 2 RGM 图像特征各方法的负荷识别的 F_{macro}
Table 2 F_{macro} of load recognition for various methods of RGM image features %

方法	WRG	GAF	MTF
WRG	96.38	96.67	97.11
GAF	96.67	95.72	96.47
MTF	97.11	96.47	96.24

可以看出，3 个特征中，WRG 识别效果最好，GAF 效果最差，本研究首次引入的 MTF 识别效果与 WRG 基本持平，说明了该负荷特征的独特性。将 3 种灰度特征两两融合，与单一负荷特征方法相比，识别准确率都得到了一定程度的提升，其中 WRG+MTF 组合提升最为明显，达 97.11%，验证了首次提出的 MTF 灰度特征的有效性。

该文提出的 RGM 特征在此基础上又融合了 GAF 方法，最终将负荷识别的准确率提升至 97.47%，增加了特征的独特性，提高了负荷识别的效果。通过该组对比实验可以发现，基于多模态图像特征提取的负荷识别方法较为有效地提升了 NILM 领域负荷识别的效果。

3.6.4 与其他神经网络算法对比

表 3 对比了所提 CNN 识别模型与其他经典 CNN 模型的关键衡量参数，例如 Params、GFLOPs(giga floating-point operations per second)、训练时间、准确率等。Params 反映模型的参数量，可以用来衡量模型的空间复杂度；GFLOPs 为模型的运算量，通常用来衡量模型的时间复杂度，但该参数仅是一个估量指标，不能确切的衡量模型的运算时间。Params 和 GFLOPs 的值使用 Python 的第三方库 thop 中的 profile 方法进行计算，该方法接受两个参数，分别为模型 model 和模型所需的输入 tensor 参数 inputs；返回值分别为 FLOPs 和 Params。在 pytorch 中逐个加载所需 MobilenetV2、Resnet18 等网络模型，并构建 inputs tensor，依次使用 profile 方法，计算得到各个模型的 FLOPs 和 Params，最后将 Flops 除以 10^9 换算得到 GFLOPs。

MobilenetV2 引入倒残差和线性层，构建了轻量型卷积网络，其 GFLOPs 值最小；Densenet 提出密集连接结构，克服了梯度消失问题，增强特征传递能力，在 WHITED 数据集达到 99%的准确率，其他方面则表现不佳。该文所提模型更加轻型，虽然计算量略大于 MobilenetV2，但在参数量、训练时间和准确率都远优于其他 CNN 模型。

相较于其他 CNN 模型，该文提出的 RGM-CNN 识别模型，其参数量少、迭代速度快，同时保持高识别准确率。RGM 图像特征在多种 CNN 模型上都取得了较高识别准确率，也客观证明了所提 RGM 特征的优越性。

表 3 与其他 CNN 模型比较(准确率为 F_{macro})
Table 3 Comparison with other CNN models

模型	Params	GFLOPs	训练时间/min	准确率/%
Resnet18	≈11.7M	1.82	36.63	95.68/97.34
MobileNetV2	≈3.5M	0.33	20.39	96.16/97.46
Densenet	≈8.0M	2.91	72.67	95.85/99.03
RGM-CNN	**≈0.7M**	**0.89**	**4.27**	**97.21/99.27**

3.6.5 与其他文献对比

进一步将提出的方法与现有文献方法比较，表 4 中对比了不同方法之间的关键特征，包括负荷特征、分类模型、数据集及准确率。对比文献均采用数据集 PLAID2017 和 WHITED 的文献进行评估。

文献[13]和文献[14]是对 U-I 轨迹图像的改进方案，前者将 U-I 轨迹处理为灰度 U-I 图像特征，CNN 作为训练模型，识别性能较差；后者融合动量信息、功率信息等构造彩色 U-I 轨迹图像特征，并借助迁移学习模型，较大幅度提高了识别精度。

文献[19]引入权重的概念对二值递归图进行改进，在 WHITED 数据集上识别效果较优，PLAID 数据集结果不理想。文献[39]使用 GAF 算法分别对电压、电流及无功电流生成三张灰度图，融合构建彩色图像特征，通过迁移学习进行负荷识别，取得

表 4 与其他文献方法的比较(准确率为 F_{macro})
Table 4 Comparison with other literature

负荷特征	模型	数据集	准确率/%	文献
gray-scale	CNN	PLAID	77.60	[13]
		WHITED	75.46	
WRG	CNN	PLAID	88.53	[19]
		WHITED	97.23	
color-encoded U-I	Pretrained Alexnet	PLAID	95.60	[14]
		WHITED	98.66	
GAF-encoded	Pretrained Alexnet	PLAID	96.86	[39]
		WHITED	97.90	
RGM	**CNN**	**PLAID**	**97.47**	
		WHITED	**99.30**	

较好识别结果。相较于其他方法，该文提出方法在 WHITED 数据集和 PLAID 数据集都达到了最优识别效果。

通过多方位的比较和评估，该文构建的 RGM 负荷识别方法在特征提取部分利用 3 种方法充分提取电流中的时间特性及周期特性，能更充分反映电器的内部特性，增强了负荷特征的唯一性；在负荷识别部分提出更适用于、更轻型且保持高识别准确率的 RGM-CNN 识别模型。综合来说，该文提出的方法优于目前大多数最先进的NILM负荷识别算法。

4 结论

该文提出了一种新颖的 3 种 NILM 灰度图像特征提取及融合方法，分别为通过 WRG 提取稳态电流周期性和相似性等重复模式特征的 R 图，通过 GAF 提取稳态电流的时间依赖性和时间相关性等静态特征的 G 图，在此基础上，进一步提出基于 MTF 方法提取稳态电流的全局趋势和局部趋势等动态特征的 M 图，融合构建成 RGM 彩色特征图像，从而实现了多维度提取电流数据中的能量信息，提高了负荷特征的唯一性。针对所提的 RGM 彩色特征图像设计了适用的 CNN 识别模型，该模型参数量少、网络层级更浅、迭代速度快，同时保持了高识别性能，有效降低了彩色图像分析模型的复杂度，更加适用于 RGM 特征图像识别问题。进一步引入类内散度矩阵和类间散度矩阵来更精准地衡量常用 NILM 公共数据集，将所提方法在不同特性的公共数据集进行实验验证，并与多种其他现有典型方法进行评估对比，结果表明，所提方法的识别准确度显著提高，优于目前 NILM 领域的大多数算法。该文提出的方法虽然有效提高了识别性能，但面对多状态电器及连续状态电器的识别，还存有诸多困难与挑战，在未来的工作中，将探索使用更完善的负荷特征提取方法及构建更高性能的识别模型，提高多状态电器及连续状态电器的识别精度。

附录见本刊网络版(http://www.dwjs.com.cn/CN/1000-3673/current.shtml)。

参考文献

[1] AURANGZEB K，ASLAM S，MOHSIN S M，et al．A fair pricing mechanism in smart grids for low energy consumption users[J]．IEEE Access，2021，9：22035-22044．

[2] PÉREZ-LOMBARD L，ORTIZ J，POUT C．A review on buildings energy consumption information[J]．Energy and Buildings，2008，40(3)：394-398．

[3] KELLY J，KNOTTENBELT W．Does disaggregated electricity feedback reduce domestic electricity consumption? A systematic review of the literature[C]//Proceedings of the 3rd International Workshop on Non-Intrusive Load Monitoring．Vancouver：Association for Computing Machinery，2016．

[4] KAHL M，KRAUSE V，HACKENBERG R，et al．Measurement system and dataset for in-depth analysis of appliance energy consumption in industrial environment[J]．tm-Technisches Messen，2019，86(1)：1-13．

[5] HART G W．Nonintrusive appliance load monitoring[J]．Proceedings of the IEEE，1992，80(12)：1870-1891．

[6] 祁琪，石富岭，陈宋宋，等．居民负荷参与电力系统调控关键技术综述与展望[J]．电网技术，2024，48(2)：809-818．
QI Qi，SHI Fuling，CHEN Songsong，et al．Review and prospect of key technologies for residential loads participating in power system dispatch and control[J]．Power System Technology，2024，48(2)：809-818(in Chinese)．

[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 Xiang，LI Linzhi，WU Hao，et al．A survey of the research on non-intrusive load monitoring and disaggregation[J]．Power System Technology，2016，40(10)：3108-3117(in Chinese)．

[8] COMINOLA A，GIULIANI M，PIGA D，et al．A hybrid signature-based iterative disaggregation algorithm for non-intrusive load monitoring[J]．Applied Energy，2017，185：331-344．

[9] PEREIRA L，NUNES N．Performance evaluation in non-intrusive load monitoring：datasets，metrics，and tools—a review[J]．WIREs：Data Mining and Knowledge Discovery，2018，8(6)：e1265．

[10] 邓晓平，张桂青，魏庆来，等．非侵入式负荷监测综述[J]．自动化学报，2022，48(3)：644-663．
DENG Xiaoping，ZHANG Guiqing，WEI Qinglai，et al．A survey on the non-intrusive load monitoring[J]．Acta Automatica Sinica，2022，48(3)：644-663(in Chinese)．

[11] ABUBAKAR I，KHALID S N，MUSTAFA M W，et al．Recent approaches and applications of non-intrusive load monitoring[J]．ARPN Journal of Engineering and Applied Sciences，2016，11(7)：4609-4618．

[12] DU Liang，HE Dawei，HARLEY R G，et al．Electric load classification by binary voltage–current trajectory mapping[J]．IEEE Transactions on Smart Grid，2016，7(1)：358-365．

[13] 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．

[14] LIU Yanchi，WANG Xue，YOU Wei．Non-intrusive load monitoring by voltage-current trajectory enabled transfer learning[J]．IEEE Transactions on Smart Grid，2019，10(5)：5609-5619．

[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(in

Chinese).

[16] WANG Shouxiang，CHEN Haiwen，GUO Luyang，et al．Non-intrusive load identification based on the improved voltage-current trajectory with discrete color encoding background and deep-forest classifier[J]．Energy and Buildings，2021，244：111043．

[17] 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．

[18] 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(in Chinese)．

[19] POPESCU F，ENACHE F，VIZITIU I C，et al．Recurrence plot analysis for characterization of appliance load signature[C]//2014 10th International Conference on Communications (COMM)．Bucharest：IEEE，2014：1-4．

[20] 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．

[21] CHEN Junfeng，WANG Xue，ZHANG Xiaotian，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．

[22] 余雷，刘宏伟，孟芸．基于多模态图像融合的 DCCNN 识别电能质量扰动[J]．现代电子技术，2024，47(3)：137-142．
YU Lei，LIU Hongwei，MENG Yun．Multimodal image fusion based power quality disturbance recognition by DCCNN[J]．Modern Electronics Technique，2024，47(3)：137-142(in Chinese)．

[23] 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．Austin：AAAI，2015：40-46．

[24] 林顺富，林屹峰，李毅，等．基于负荷高频特征图像化的非侵入式负荷辨识技术研究[J]．电网技术，2025，49(3)：1236-1245．
LIN Shunfu，LIN Yifeng，LI Yi，et al．Non-intrusive load identification technology based on high frequency feature pictorialization of load[J]．Power System Technology，2025，49(3)：1236-1245．

[25] 梁志泓，罗庆全，余涛，等．基于庞加莱映射与多元特征融合构图的轻量化负荷识别方法[J]．电网技术，2024，48(11)：4710-4719．
LIANG Zhihong，LUO Qingquan，YU Tao，et al．A lightweight load identification method based on Poincaré Mapping and multivariate feature fusion composition[J]．Power System Technology，2024，48(11)：4710-4719(in Chinese)．

[26] ABUBAKAR I，KHALID S N，MUSTAFA M W，et al．Application of load monitoring in appliances' energy management-a review[J]．Renewable and Sustainable Energy Reviews，2017，67：235-245．

[27] DE BAETS L，DHAENE T，DESCHRIJVER D，et al．VI-based appliance classification using aggregated power consumption data[C]//2018 IEEE International Conference on Smart Computing (SMARTCOMP)．Taormina：IEEE，2018：179-186．

[28] 王磊，马佳琪，韩肖清，等．考虑多状态特征的非侵入式负荷识别方法[J]．电网技术，2024，48(11)：4720-4728．
WANG Lei，MA Jiaqi，HAN Xiaoqing，et al．Non-intrusive load monitoring method with multi-state characterization of loads[J]．Power System Technology，2024，48(11)：4720-4728(in Chinese)．

[29] 刘志坚，何蔚，刘航，等．基于格拉姆角场变换和深度压缩模型的变压器故障识别方法[J]．电网技术，2023，47(4)：1478-1489．
LIU Zhijian，HE Wei，LIU Hang，et al．Fault identification method for power transformer based on gramian angular field transformation and deep compression model[J]．Power System Technology，2023，47(4)：1478-1489(in Chinese)．

[30] 贺才郡，李开成，杨王旺，等，王伟．基于双通道 GAF 和深度残差网络的电能质量复合扰动识别[J]．电网技术，2023，47(1)：369-376．
HE Caijun，LI Kaicheng，YANG Wangwang，et al．Power quality compound disturbance identification based on dual channel GAF and depth residual network[J]．Power System Technology，2023，47(1)：369-376(in Chinese)．

[31] LIU Lu，WANG Zhiguang．Encoding temporal Markov dynamics in graph for visualizing and mining time series[C]//The Workshops of the Thirty-Second AAAI Conference on Artificial Intelligence．New Orleans：AAAI，2018：178-184．

[32] GAO Jingkun，GIRI S，KARA E C，et al．PLAID：a public dataset of high-resoultion electrical appliance measurements for load identification research：demo abstract[C]//Proceedings of the 1st ACM Conference on Embedded Systems for Energy-efficient Buildings．New York：Association for Computing Machinery，2014：198-199．

[33] DE BAETS L，DEVELDER C，DHAENE T，et al．Handling imbalance in an extended PLAID[C]//2017 Sustainable Internet and ICT for Sustainability (SustainIT)．Funchal：IEEE，2017：1-5．

[34] KAHL M，HAQ A U，KRIECHBAUMER T，et al．WHITED - a worldwide household and industry transient energy data set[C]//Proceedings of the 3rd International Workshop on Non-Intrusive Load Monitoring．Vancouver：Association for Computing Machinery，2016：1-4．

[35] BLEI D M，NG A Y，JORDAN M I．Latent dirichlet allocation[J]．The Journal of Machine Learning Research，2003，3：993-1022．

[36] KIM J H．Estimating classification error rate：repeated cross-validation，repeated hold-out and bootstrap[J]．Computational Statistics & Data Analysis，2009，53(11)：3735-3745．

[37] PEREIRA L，NUNES N．A comparison of performance metrics for event classification in Non-Intrusive Load Monitoring[C]//2017 IEEE International Conference on Smart Grid Communications (SmartGridComm)．Dresden：IEEE，2017：159-164．

[38] 郭红霞，陆进威，杨苹，等．非侵入式负荷监测关键技术问题研究综述[J]．电力自动化设备，2021，41(1)：135-144．
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)：135-144(in Chinese)．

[39] CHEN Junfeng，WANG Xue．Non-intrusive load monitoring using Gramian angular field color encoding in edge computing[J]．Chinese Journal of Electronics，2022，31(4)：595-603．



魏广芬

在线出版日期：2025-02-26。
收稿日期：2024-06-02。

作者简介：
魏广芬(1978)，通信作者，女，教授，硕士生导师，研究方向为智能传感技术、负荷识别技术、机器嗅觉、人工智能等，E-mail：guangfen.wei@sdtbu.edu.cn；
李谊林(1997)，男，硕士研究生，研究方向为非侵入式负荷识别及分解，E-mail：2021420002@sdtbu.edu.cn。

（编辑　李健一）

附录 A

表 A1　PLAID 和 WHITED 数据集的 IACV 和 IECV

Table A1　IACV and IECV of PLAID and WHITED datasets

数据集	IACV	IECV
PLAID2014	22.74	32.07
PLAID2017	19.36	18.10
PLAID2018Sub	31.90	50.50
PLAID2018Agg	24.16	64.88
WHITED	29.22	118.32

表 A2　三种电器的 IACV 和 IECV

Table A2　IACV and IECV of electrical appliances of three types of electrical appliances

电器	IACV	IECV
空调	62.05	1.46
洗衣机	12.80	1.46
冰箱	16.61	0.73

表 A3　特征提取和负荷识别的计算时间

Table A3　Computation time for feature extraction and load recognition

	Steady-State Current	WRG	RGM	Load Recognition
时间(s)	0.0011	0.0012	0.0039	0.0016

注：RGM 模块计算时间包含 WRG、MTF、GAF 三部分计算时间。

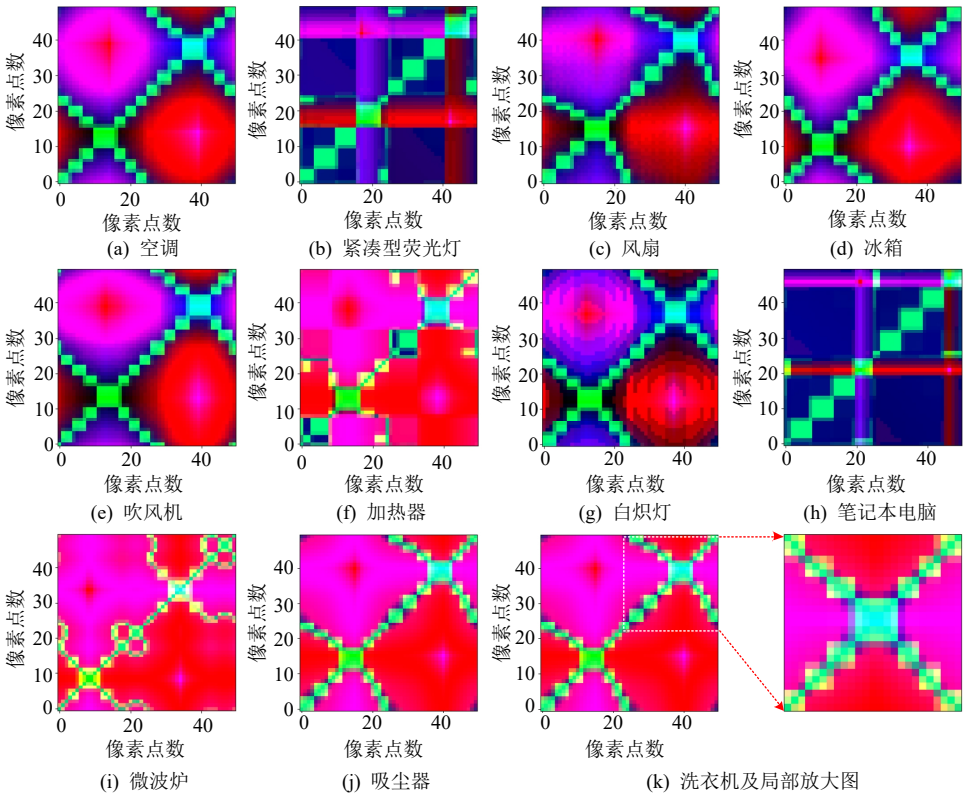


图 A1　PLAID 2017 中 11 类用电设备的 RGM 图像负荷特征

Fig. A1　RGM Image Load Features for 11 Categories of Electrical Appliances in PLAID 2017

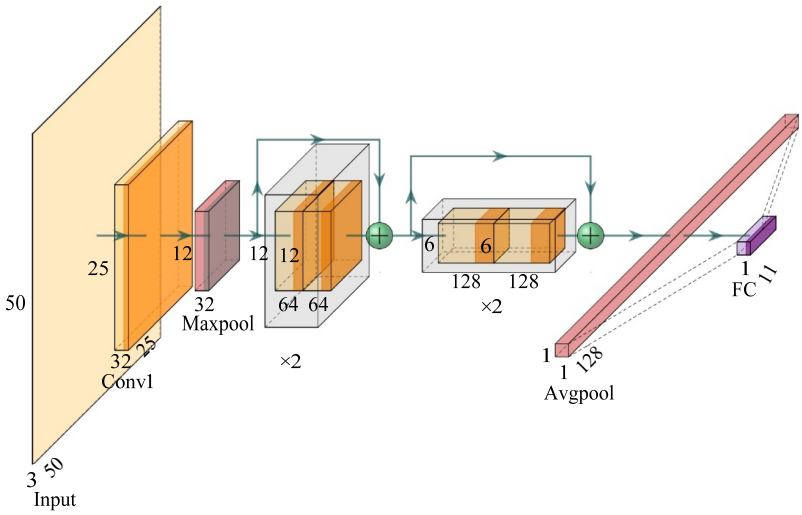


图 A2　用于 RGM 图像负荷识别的 CNN 模型架构

Fig. A2　CNN Model Architecture for RGM Image Load Recognition

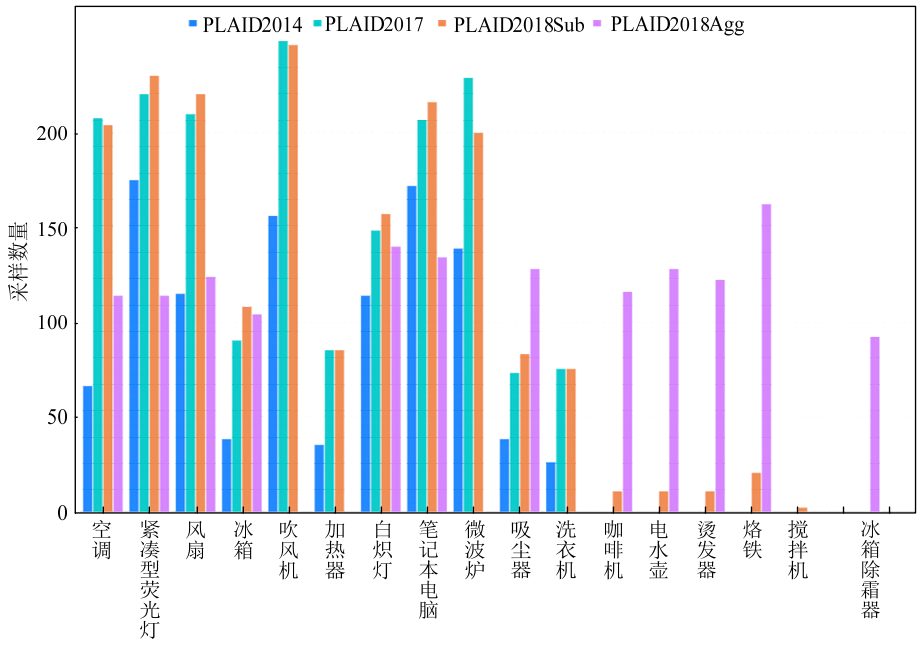


图 A3　PLAID 数据集各版本测量详情

Fig. A3　Measurement details for each version of the PLAID dataset

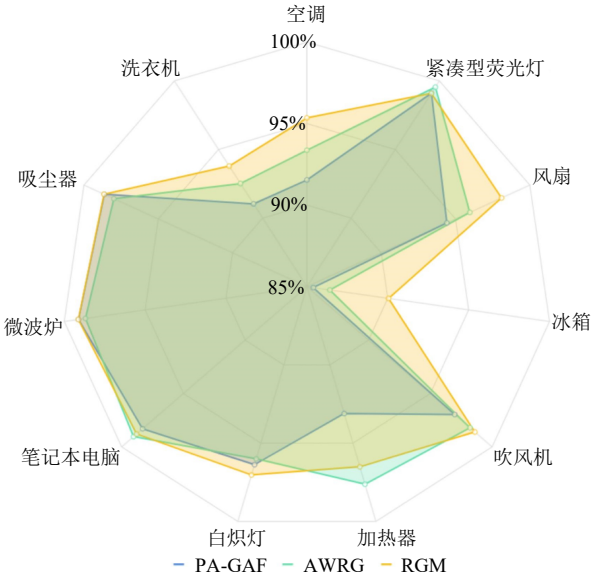
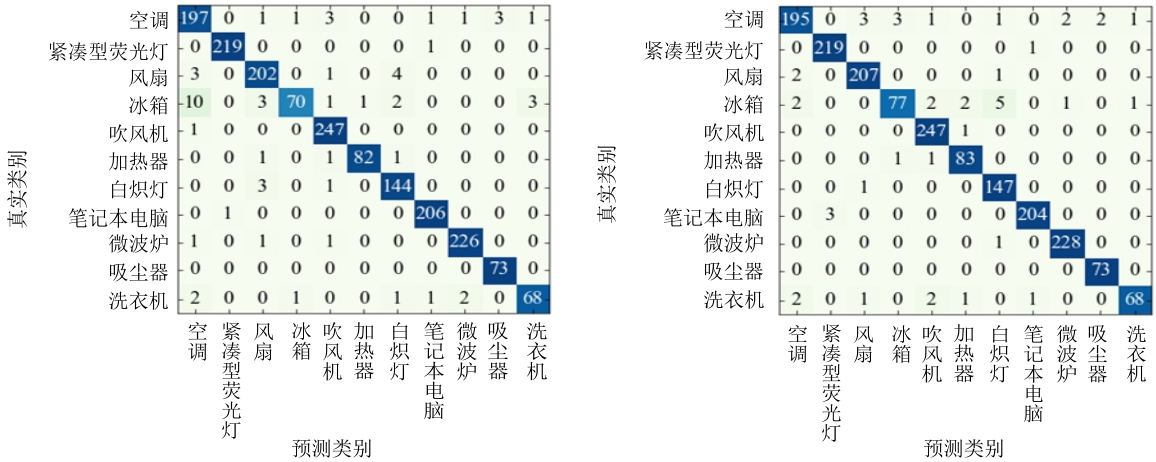


图 A4　基于 PA-GAF、AWRG 和 RGM 特征的 PLAID2017 数据集中设备的 F_1 分数(%)

Fig. A4　F_1 scores of PLAID2017 dataset devices based on PA-GAF and AWRG and RGM features(%)



(a) AWRG图像特征混淆矩阵　　(b) RGM图像特征混淆矩阵

图 A5　基于 AWRG 和 RGM 特征的 PLAID2017 数据集中设备基于 AWRG 和 RGM 特征的混淆矩阵

Fig. A5　The confusion matrix of PLAID2017 dataset devices based on WRG and RGM features

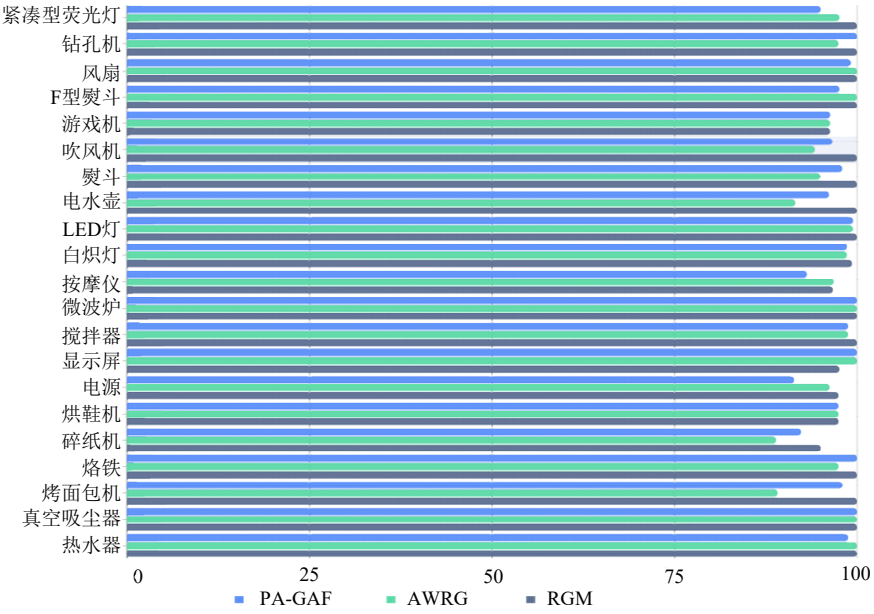
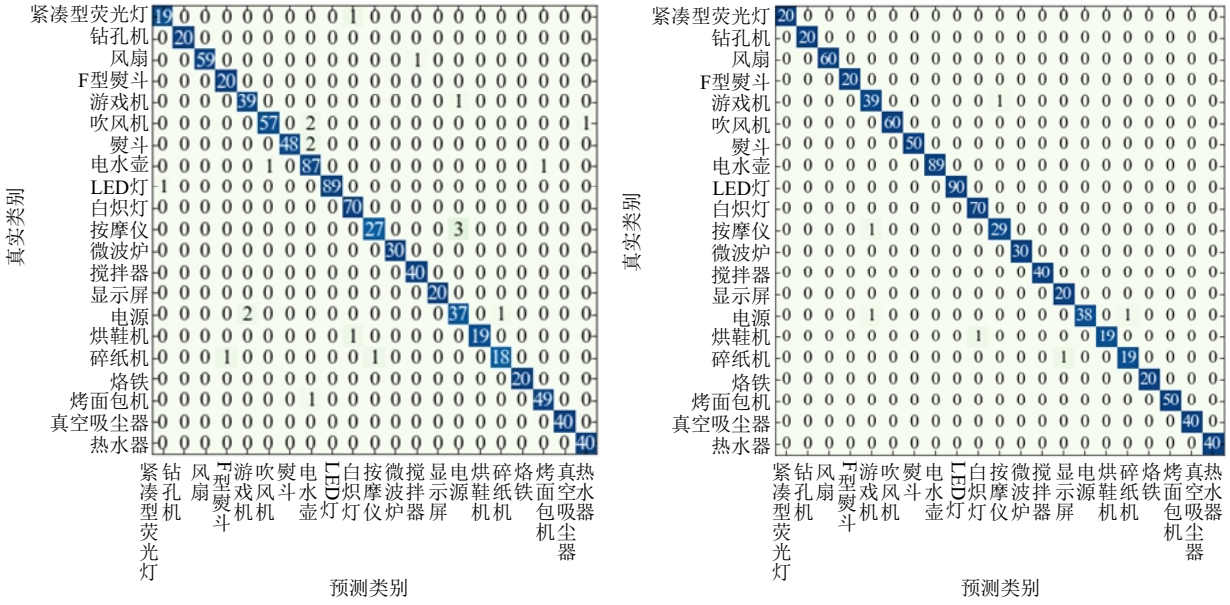


图 A6　基于 PA-GAF、AWRG 和 RGM 特征的 WHITED 数据集中设备的 F_1 分数(%)

Fig. A6　F_1 scores of WHITED dataset devices based on PA-GAF and AWRG and RGM features(%)



(a) PA-GAF图像特征混淆矩阵　　(b) RGM图像特征混淆矩阵

图 A7　基于 PA-GAF 和 RGM 特征的 WHITED 数据集中设备的混淆矩阵

Fig. A7　The confusion matrix of WHITED dataset devices based on PA-GAF and RGM features