

DOI: 10.12158/j.2096-3203.2025.05.012

基于改进 $V-I$ 轨迹的非侵入式负荷辨识方法

李剑文, 梅飞, 张晓光, 封通通, 李欣

(河海大学电气与动力工程学院, 江苏 南京 211100)

摘要: 针对目前非侵入式负荷辨识方法对负荷特征信息挖掘不足和辨识模型规模庞大的问题, 文中提出一种基于改进 $V-I$ 轨迹的非侵入式负荷辨识方法。首先利用格拉姆角场(Gramian angular field, GAF)和颜色编码技术, 将有功电流、瞬时功率、 $V-I_f$ 轨迹进行融合形成新的负荷特征, 然后通过深度可分离卷积(depthwise separable convolution, DSC)模块和混合空洞卷积(hybrid dilated convolution, HDC)模块优化卷积神经网络(convolutional neural network, CNN)模型框架, 构建轻量化负荷辨识模型, 最后利用公开数据集进行实验分析。结果表明, 文中所提方法的 F1 分数为 0.953, 可实现在减少软硬件资源占用的基础上进一步提升对用电负荷的辨识精度。

关键词: 非侵入式负荷监测; 颜色编码; 多特征融合; $V-I_f$ 轨迹; 轻量化模型; 格拉姆角场(GAF)

中图分类号: TM714

文献标志码: A

文章编号: 2096-3203(2025)05-0128-10

0 引言

随着社会的发展, 能源消耗和碳排放问题日益严峻^[1]。负荷监测技术可以有效监测终端用户各负荷的运行情况, 有助于用户更好地了解自身的用电行为, 培养绿色的用能习惯, 提高能源利用率^[2-6], 助力“双碳”目标早日实现。

负荷监测技术分为侵入式负荷监测(intrusive load monitoring, ILM)和非侵入式负荷监测^[7-8](non-intrusive load monitoring, NILM)两种^[9], 相较于 ILM 需要在每个用电设备上安装传感器, NILM 通过用户总用电数据获取各负荷用电信息, 装设简易, 经济成本小, 对用户的干扰度低, 便于终端部署^[10-11]。

NILM 主要过程为挖掘不同负荷具有区分度的特征, 利用特征匹配完成负荷辨识。根据构造特征所用数据位于负荷运行阶段的不同, 可将负荷特征分为稳态特征和暂态特征^[12-14]。虽然暂态特征具有更好的区分度, 但是特征提取困难, 且易受噪声干扰, 所以目前的研究多采用基于稳态特征的方法。文献^[15]使用经过归一化处理的电压、电流数据构造 $V-I$ 轨迹, 并提取相应的形状特征作为负荷特征进行负荷辨识。虽然采用 $V-I$ 轨迹特征相较于其余高频特征具有更佳的辨识效果^[16], 但将 $V-I$ 轨迹进行量化需要较大的计算量。文献^[17]将 $V-I$ 轨迹映射到网格中形成二元化 $V-I$ 轨迹特征以降低运算成本。考虑到模型训练所需的时间成本, 文献

^[18]将二元化的 $V-I$ 轨迹特征作为视觉识别和 NILM 之间的中间域, 并采用迁移学习的方法将视觉识别领域的模型用于负荷辨识。传统的 $V-I$ 轨迹是直接利用电压、电流进行构造, 但由于阻性负载功率因数较大, 有功分量含量占比较高, 直接采用 $V-I$ 轨迹特征难以达到预期的辨识精度。文献^[19]验证了由无功电流和电压构成的 $V-I_f$ 轨迹特征可以在不影响其他种类负荷辨识准确率的基础上增加阻性负荷之间的区分度。但是从构造原理角度分析, $V-I_f$ 轨迹缺乏有功电流信息, 难以体现负荷功率信息, 且存在大量空白无效的信息, 因此文中通过颜色编码的方式将 $V-I_f$ 轨迹、有功电流、功率特征进行融合, 以此增加特征信息, 提高辨识精度。

由于深度学习在计算机视觉等领域取得了优异的效果^[20], 近年来, 国内外学者开始将深度学习方法应用于 NILM 领域^[21-24]。文献^[25]利用格拉姆角场(Gramian angular field, GAF)将电压、电流、无功电流转换为图片特征, 再通过颜色编码技术进行融合, 最后采用轻量级径向基神经网络(radial basis function neural network, RBFNet)、L2-AlexNet 分别在边缘端和云端实现协作负荷辨识。文献^[26]利用迁移学习将经过预训练的 Inception-v3 模型对可视化非有功电流图像特征进行辨识, 能在保持较高辨识准确率的基础上提升模型的学习效率。文献^[27]分别将功率和 $V-I$ 轨迹特征输入到由反向传播神经网络和卷积神经网络(convolutional neural network, CNN)构建的特征提取模型中, 再将提取出的特征进行融合从而完成辨识, 利用该方法可以解决 $V-I$ 轨迹不能反映功率大小的问题, 但是较少的特

收稿日期: 2025-02-09; 修回日期: 2025-04-27

基金项目: 国家重点研发计划资助项目“面向碳中和能源可持续发展的城镇能源互联网大数据分析技术与应用研究”(2022YFE0140600)

征选取并不能达到理想的辨识效果。文献[28]利用 AlexNet 对 $V-I$ 轨迹进行分类, 取得了较高的准确率。虽然在图像辨识领域已经出现了很多性能优异的网络模型, 且这些模型与 NILM 也实现了有效结合, 但是相关方法辨识步骤较为复杂, 模型规模难以控制, 不利于终端部署。

综合上述问题, 文中提出一种基于改进 $V-I$ 轨迹的非侵入式负荷辨识方法。利用电压和无功电流构造 $V-I_f$ 轨迹特征, 减少阻性负载之间的特征相似度。通过 GAF 对有功电流和瞬时功率进行图像编码, 保留不同元素之间的时间相关性。将 $V-I_f$ 轨迹、有功电流和瞬时功率图像分别输入到不同的颜色通道中形成彩色融合特征, 利用不同像素点的颜色差异, 进一步丰富特征信息, 提升不同负荷之间的特征区分度。针对模型计算复杂度高的问题, 在 CNN 架构的基础上, 结合混合空洞卷积 (hybrid dilated convolution, HDC) 模块和深度可分离卷积 (depthwise separable convolution, DSC) 模块构建负荷辨识模型。最后利用插件级器具识别数据集 (the plug-level appliance identification dataset, PLAID) 对文中方法进行有效性验证。

1 融合特征构建

单一的灰度 $V-I_f$ 轨迹可以提升不同种类阻性负荷之间的区分度, 但存在信息挖掘不足和含有大量空白无效信息的问题。因此, 文中通过 GAF 对瞬时功率、有功电流波形进行图像编码, 并采用颜色编码的方式将其与灰度 $V-I_f$ 轨迹进行有效融合, 增加特征信息维度。融合特征的构建流程如图 1 所示。

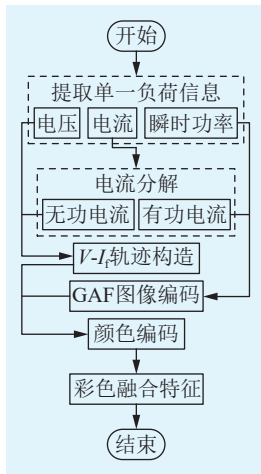


图 1 融合特征构建流程

Fig.1 The process of constructing fusion features

1.1 数据预处理

在负荷辨识任务中, 可以通过高频采样装置直

接获取用户总电压、电流数据。由于用电设备的状态变化通常需要人为操作, 在高采样率的条件下, 不同事件交叠和在极短的周期间隔内连续发生的概率较小, 因此有望实现单个设备的数据分离。由于各用电设备大多采用并联的连接方式, 状态较为独立, 单个用电设备的电压、电流数据可通过总用电数据中的事件点进行分离。

电压在设备状态变化前后均较为稳定, 但是仍会存在一定的波动, 因此对事件前后的电压进行平均处理以减少误差。

$$v_m = \frac{v_q + v_h}{2} \quad (1)$$

式中: v_m 为平均电压; v_q 为设备状态变化前的电压; v_h 为设备状态变化后的电压。

电流的变化较大, 即使是在稳态情况下, 每个周期都会存在一定的波动。为减少这一不稳定因素的影响, 文中利用电流的可加性准则, 将事件发生前后的稳态电流取 3 个周期作差。

$$\begin{cases} \hat{i}_d = \hat{i}_h - \hat{i}_q \\ \hat{i}_h = (i_{h1}, i_{h2}, \dots, i_{hl}) \\ \hat{i}_q = (i_{q1}, i_{q2}, \dots, i_{ql}) \end{cases} \quad (2)$$

式中: \hat{i}_d 为单个负荷的稳态电流序列; \hat{i}_h 为事件发生之后的稳态电流序列; \hat{i}_q 为事件发生之前的稳态电流序列; i_{hl} 为事件发生之后的第 l 个稳态电流值; i_{ql} 为事件发生之前的第 l 个稳态电流值。

1.2 轨迹特征构造

文中采用 Fryze 功率理论对电流序列 $i(t)$ 进行分解^[29], 将其分解成有功电流分量 $i_a(t)$ 和无功电流分量 $i_f(t)$, 具体计算公式如下:

$$P = \frac{1}{T} \int_0^T v(t)i(t)dt \quad (3)$$

$$V = \sqrt{\frac{1}{T} \sum_{t=1}^T v^2(t)} \quad (4)$$

$$i_a(t) = \frac{P}{V^2} v(t) \quad (5)$$

$$i_f(t) = i(t) - i_a(t) \quad (6)$$

式中: P 为稳态周期的有功功率; T 为选定的稳态周期; $v(t)$ 为稳态周期内 t 时刻的电压值; $i(t)$ 为稳态周期内 t 时刻的电流值; V 为稳态周期内电压的有效值。

同一种用电设备的电流波形形状大致相同, 但由于功耗不同, 电流大小会存在差异, 导致同类负荷的 $V-I$ 轨迹特征差异扩大。为降低这一不确定性, 需要对稳态电流和电压序列进行归一化处理, 其计算公式为:

$$U(t) = \frac{v(t) - v_{\min}}{v_{\max} - v_{\min}} \quad (7)$$

$$I(t) = \frac{i(t) - i_{\min}}{i_{\max} - i_{\min}} \quad (8)$$

式中: $U(t)$ 为经过归一化处理后 t 时刻的电压值; $I(t)$ 为经过归一化处理后 t 时刻的电流值; v_{\max} 、 v_{\min} 分别为提取周期内电压的最大值和最小值; i_{\max} 、 i_{\min} 分别为提取周期内电流的最大值和最小值。

将经过归一化处理的无功电流和电压序列分别作为横、纵坐标绘制 $V-I_f$ 轨迹图, 并将其映射到网格中。如果轨迹穿过某个单元格, 该单元格便被占用, 并赋值为 1, 否则赋值为 0。轨迹映射具体步骤如下。

(1) 设 $v_k = (v_1, v_2, \dots, v_k)$ 和 $i_k = (i_1, i_2, \dots, i_k)$ 分别表示长度为 K 的电压和电流序列。

(2) 将电压和电流序列分别进行归一化处理之后得到数值在 0~1 之间的序列 $\bar{v}_k = (\bar{v}_1, \bar{v}_2, \dots, \bar{v}_k)$ 和 $\bar{i}_k = (\bar{i}_1, \bar{i}_2, \dots, \bar{i}_k)$ 。

(3) 定义网格的尺寸为 $N \times N$, 即表示生成的 $V-I_f$ 轨迹图分辨率为 $N \times N$, 并且创建一组 $N \times N$ 的零矩阵。

(4) 将电压和电流根据网格尺寸大小进行转换, 具体转换公式为:

$$v_m = \lfloor \bar{v}_k \times N \rfloor \quad m = 1, 2, \dots, K \quad (9)$$

$$i_m = \lfloor \bar{i}_k \times N \rfloor \quad m = 1, 2, \dots, K \quad (10)$$

式中: $\lfloor \cdot \rfloor$ 为向下取整函数; v_m 、 i_m 的取值小于等于 N 。

(5) 对 v_m 和 i_m 从第一个元素依次进行取样, 将矩阵中第 i_m 行第 v_m 列的元素赋值为 1, 如此重复直至遍历序列中的全部元素。

通过上述方法可将 3 个周期的电压、电流轨迹映射到 $N \times N$ 的网格中, 形成分辨率为 $N \times N$ 的灰度轨迹图像。

1.3 基于 GAF 的特征构建

在构造 $V-I_f$ 轨迹特征时仅使用无功电流, 而未考虑有功电流, 会导致负荷阻性信息丢失。同时, 功率作为负荷的重要特征, 无法在 $V-I_f$ 轨迹中体现, 不能有效区分轨迹相似但是功率差别较大的负荷。

为将有功电流和功率数据进行编码从而构建负荷特征, 文中将 GAF^[30] 引入 NILM 领域, 假设用一组时间序列 $X = (x_1, x_2, \dots, x_n)$ 表示电气数据, 其 GAF 图像编码的实现流程如下。

(1) 对数据进行归一化, 将序列中的元素数值缩放在 $[-1, 1]$ 范围内。

$$\tilde{X}_i = \frac{(x_i - \max(X)) + (x_i - \min(X))}{\max(X) - \min(X)} \quad 1 \leq i \leq n \quad (11)$$

式中: x_i 为 i 时刻的元素数值; \tilde{X}_i 为经过归一化处理后 i 时刻的元素数值。

(2) 极坐标转换。

$$\begin{cases} \varphi_i = \arccos(\tilde{X}_i) \\ r = \frac{t_i}{O} \quad t_i \in \mathbf{Z} \end{cases} \quad (12)$$

式中: φ_i 为将归一化后的时间序列经过反余弦生成的角度; t_i 为采样时间戳; O 为降采样参数; r 为半径; \mathbf{Z} 为整数集。

(3) 利用三角函数差角公式构造 GAF 矩阵, 具体的矩阵形式如下。

$$\mathbf{G} = \begin{bmatrix} \sin(\varphi_1 - \varphi_1) & \sin(\varphi_1 - \varphi_2) & \cdots & \sin(\varphi_1 - \varphi_n) \\ \sin(\varphi_2 - \varphi_1) & \sin(\varphi_2 - \varphi_2) & \cdots & \sin(\varphi_2 - \varphi_n) \\ \vdots & \vdots & \ddots & \vdots \\ \sin(\varphi_n - \varphi_1) & \sin(\varphi_n - \varphi_2) & \cdots & \sin(\varphi_n - \varphi_n) \end{bmatrix} \quad (13)$$

(4) 将生成的 GAF 矩阵 \mathbf{G} 中的元素投射到对应的颜色空间, 得到二维的图像特征。

GAF 将序列从笛卡尔直角坐标系转换到极坐标系。对于序列中的每个元素而言, 在极坐标中只有唯一的映射与之对应; 此外, 各元素在极坐标系下与时间信息关联更加紧密, 从而保留了序列元素之间的时间信息。

1.4 颜色编码处理

在 RGB 颜色空间下, 将编码后的有功电流和功率信息分别输入到 G、B 通道中, 将 $V-I_f$ 轨迹图像输入到 R 通道中构成融合了不同特征信息的彩色图像, 如图 2 所示。

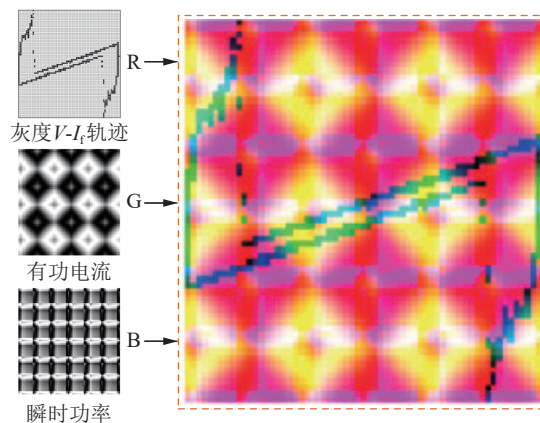


图 2 彩色图像融合过程

Fig.2 Fusion process of color image

文中充分利用轨迹图像中的空白部分, 通过每个像素点的颜色和明暗的区别反映单元格中数值的差异, 将不同的特征信息进行融合, 可以弥补单

一特征信息不足,解决 $V-I_f$ 轨迹信息丢失的问题,提高特征信息的利用率。

2 轻量化负荷辨识模型

传统的负荷辨识模型为了增加对特征的学习能力,不断扩大模型规模,导致模型计算量大、训练耗时长等问题。文中通过融合 HDC 和 DSC 构建轻量化负荷辨识模型 DSHDNet,在不损失辨识准确率的基础上,可以有效减小模型规模。

2.1 HDC

空洞卷积与传统卷积的不同之处在于引入了扩张率这一新的参数,如图 3 所示,彩色部分为卷积核的感受野。




图 3 不同扩张率下卷积核的感受野

Fig.3 Receptive fields of convolution kernel with different expansion rates

空洞卷积是在普通卷积核的中间插入零元素进行填补。加入扩张率之后的卷积核尺寸 K'_{size} 计算公式为:

$$K'_{size} = d_r(K_{size} - 1) + 1 \quad (14)$$

式中: K_{size} 为原始卷积核的尺寸; d_r 为扩张率。

当扩张率取值为 1 时,卷积核的尺寸与原始卷积核相同。对于尺寸为 3×3 的卷积核,当扩张率取值为 2 时,所得效果与 5×5 的卷积核相同,且在卷积核感受野覆盖的 25 个像素点中,仍有 9 个像素点参与运算。在相同运算参数的基础上,增加提取特征的范围,可使模型的特征提取能力提高。

对于同一个输入特征,采用多个具有相同扩张率的空洞卷积进行处理时,会造成视野不连续^[31]。同时,选用过大的扩张率也会导致输入特征的采样稀疏,造成大量细节的丢失。基于上述问题,文中采用扩张率分别为 1、2、3 的卷积层,组成 HDC 模块。

2.2 DSC

DSC 可分为分离卷积和点状卷积,分离卷积将输入图像的所有通道进行分离,并逐一进行卷积运算;点状卷积对经过分离卷积处理后的输出采用 1×1 大小的卷积核,并对所有通道合并进行卷积操

作,如图 4 所示。




图 4 DSC 结构

Fig.4 Structure of DSC

假设数据的长和宽分别为 L 和 W ,输入通道数为 A ,输出通道数为 B ,卷积核的尺寸为 $H \times H$ 。传统卷积和 DSC 的计算量公式为:

$$C_{cb} = H^2 ABLW \quad (15)$$

$$C_{dsch} = H^2 ALW + ABLW \quad (16)$$

式中: C_{cb} 为特征经过传统卷积的计算量; C_{dsch} 为特征经过 DSC 的计算量。

传统卷积和深度可分离卷积的计算量比值为:

$$\frac{C_{dsch}}{C_{cb}} = \frac{1}{B} + \frac{1}{H^2} \quad (17)$$

从式(17)可以看出,当采用的卷积核尺寸为 3×3 、输出通道数为 8 时, DSC 的计算量为传统卷积的 $1/4$ 左右。DSC 操作将传统卷积操作中的卷积核拆分为两个不同尺寸的卷积核进行处理,可降低计算量,提高模型运行效率。

2.3 DSHDNet 模型结构

文中将 $V-I_f$ 轨迹与经过图像编码的有功电流和瞬时功率特征进行融合,形成融合特征。在颜色空间中,文中特征存在 3 个通道。将特征并行输入到模型中,利用卷积层从不同通道对特征进行提取与融合。文中轻量化辨识模型架构如图 5 所示。




图 5 DSHDNet 模型架构

Fig.5 Architecture of DSHDNet

首先,将融合特征输入到第一个分离卷积中,对每一个通道的特征进行特征提取;接着,将提取到的特征输入到点状卷积中进行整合;然后,将提取到的特征信息输入到具有不同扩张率的分离卷积和点状卷积中,利用不同的感受野对特征进行提取及整合;最后,将提取到的特征信息进行展平,并输入到全连接层(fully connected layer, FC)中进行

分类,实现对不同种类负荷的辨识。

3 算例分析

3.1 实验数据与实验配置

PLAID 是 NILM 领域常用的公共数据集,所包含的设备数据中同类差异较大,即同种设备之间的特征具有较大差异,这有利于提升样本多样性,更好地训练模型,增加模型的稳定性。数据集中的数据样本采样频率为 30 kHz。考虑到实际用电环境,文中选择荧光灯、冰箱、吹风机、空调、笔记本电脑、微波炉、吸尘器、白炽灯、风扇、加热器、洗衣机等 11 种不同类型的家庭场景下常见的用电设备,共包含 1 744 组家庭实测的电压、电流数据。

由于网络从训练样本数多的负荷中学习到的信息量要多于样本数少的负荷,模型辨识准确度下降,因此文中将通过基于合成少数类过采样技术^[32](synthetic minority oversampling technique, SMOTE)的 Borderline-SMOTE^[33]方法生成新样本,并贴上对应的标签,添加到原来的样本集中。其中,不同种类负荷的样本数扩充为 246,一共有 2 706 个样本。平衡的样本数量可以使模型均衡地学习不同种类的信息,提高模型辨识的稳定性和准确性。

文中采用的软件配置情况如下:编程语言环境为 Python 3.6.5,深度学习框架为 PyTorch 1.10.2。硬件配置情况如下:CPU 采用 Intel(R) Core(TM) i5-8300H CPU @ 2.30 GHz,随机存取存储器(random access memory, RAM)为 16 GB,图形处理器(graphics processing unit, GPU)采用 NVIDIA GeForce GTX 1050 Ti 的笔记本电脑。

3.2 评价指标

为对文中方法做出全面客观的评价,文中选取分类任务中常用的 3 个指标来评价方法效果,包括精确率 $\varepsilon_{\text{presion}}$ 、召回率 $\varepsilon_{\text{recall}}$ 和 F1 分数 ε_{F1} ,具体公式如下:

$$\varepsilon_{\text{presion}} = \frac{\delta_{\text{TP}}}{\delta_{\text{TP}} + \delta_{\text{FP}}} \quad (18)$$

$$\varepsilon_{\text{recall}} = \frac{\delta_{\text{TP}}}{\delta_{\text{TP}} + \delta_{\text{FN}}} \quad (19)$$

$$\frac{1}{\varepsilon_{\text{F1}}} = \frac{1}{2} \left(\frac{1}{\varepsilon_{\text{presion}}} + \frac{1}{\varepsilon_{\text{recall}}} \right) \quad (20)$$

式中: δ_{TP} 为实际为正、预测为正类的数量; δ_{FN} 为实际为正、预测为负类的数量; δ_{FP} 为实际为负、预测为正类的数量。

对每一种类别分别计算对应的指标数值,最后对所有类别求取未加权平均值^[34]。

3.3 模型和特征的参数设置

文中从原先的真实样本集中为每个类别随机抽取 50 个样本,形成总数为 550 的测试集,其余包含过采样生成的模拟样本作为训练集进行训练。模型主要参数设置如表 1 所示。

表 1 模型超参数
Table 1 Hyperparameters of the model

模块名称	层类型	卷积核尺寸	扩张率	神经元个数	激活函数
HDC-DSC1	分离卷积1	3×3	1		ReLU
	点状卷积1	1×1			
HDC-DSC2	分离卷积2	3×3	2		ReLU
	点状卷积2	1×1			
HDC-DSC3	分离卷积3	3×3	3		ReLU
	点状卷积3	1×1			
输出模块	FC1			200	ReLU
	FC2			100	ReLU
	FC3			11	Softmax

为防止出现过拟合现象,在第一个 FC 后面添加 Dropout 层,参数设置为 0.15,最后通过 Softmax 输出分类结果。文中模型损失函数选用交叉熵损失函数(cross entropy loss, CEL);采用 Adam 优化网络参数,其中学习率为 0.003,设置训练次数为 500。

图片特征的分辨率大小会直接影响最终的辨识精度。若分辨率过小,特征信息则会变模糊,信息量相对减少,导致辨识准确率下降。随着分辨率的提升,图像特征蕴含的信息量提高,特征的细节信息更加清晰,从而提升辨识准确率。然而,分辨率与数据量息息相关,分辨率越高,数据量增长越快,使得网络整体效率降低。不同分辨率的图像特征辨识效果如图 6 所示。由图 6 可知,当分辨率设置为 48×48 时,模型的训练耗时较短,但辨识准确率较低;当分辨率设置为 80×80 时,模型的辨识准确率较高,但训练耗时较长;而当分辨率设置为 64×64 时,模型在训练耗时和准确率方面的综合表现更佳。图 7 显示了不同种类负荷的部分彩色融合特征。

3.4 基于不同特征的辨识效果分析

为进一步验证融合特征的有效性,文中选择有功电流、无功电流、瞬时功率、灰度 $V-I$ 轨迹和灰度 $V-I_f$ 轨迹与文中方法进行对比分析。采用 GAF 方法将一维数据特征转换为图像特征,对于每一种特征均采用文中所构建的轻量化模型进行分类,具体辨识效果如表 2 所示。

相较于其他特征,有功电流、无功电流和瞬时功率特征的精确率和召回率均明显较低,说明基于

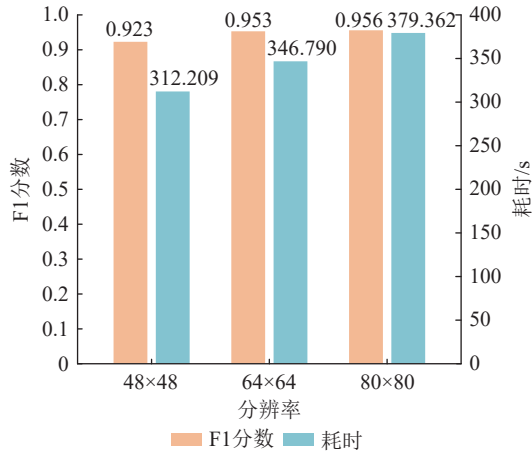


图6 不同分辨率的图像特征的辨识效果

Fig.6 The recognition effect of image features with different resolutions




图7 不同种类负荷的融合特征

Fig.7 Fusion characteristics of different kinds of loads

表2 基于不同特征的辨识效果

Table 2 Identification effect based on different features

特征	精确率	召回率	F1分数
有功电流	0.339	0.340	0.325
无功电流	0.798	0.798	0.797
瞬时功率	0.589	0.571	0.562
灰度 $V-I$ 轨迹	0.879	0.873	0.873
灰度 $V-I_f$ 轨迹	0.919	0.915	0.915
文中融合特征	0.953	0.954	0.953

$V-I$ 轨迹特征的方法通过整合多个电气量, 包含轨迹的闭合面积、形状、曲率、对称性等信息, 可以得到比单一稳态电气特征更好的区分度。

相较于灰度 $V-I$ 轨迹, 灰度 $V-I_f$ 轨迹将无功电流作为轨迹特征, 在不影响其余种类用电设备的基础上增加了阻性负荷的区分度。而文中所采用的

彩色融合特征, 在灰度 $V-I_f$ 轨迹的基础上通过颜色编码技术融合功率和有功电流信息, 实现了特征信息的补充, 让多种特征在不同维度上进行展示, 有效避免了不同信息在同一维度上的相互影响, 强化了特征的区分度。

为更加直观地分析辨识情况, 文中引入混淆矩阵作为辅助的评价指标, 辨识效果如图8所示。图8中, 每个单元格中的数字代表着不同类的数量, 横坐标为经过模型辨识出的预测便签, 纵坐标为不同类的实际标签, 0为荧光灯、1为冰箱、2为吹风机、3为空调、4为笔记本电脑、5为微波炉、6为吸尘器、7为白炽灯、8为风扇、9为加热器、10为洗衣机。对角线为测试集中各个设备被正确辨识的个数, 为提升观察分析的便捷性, 对每一个方块都进行上色处理, 辨识准确的数量越多的, 对应的颜色越深。

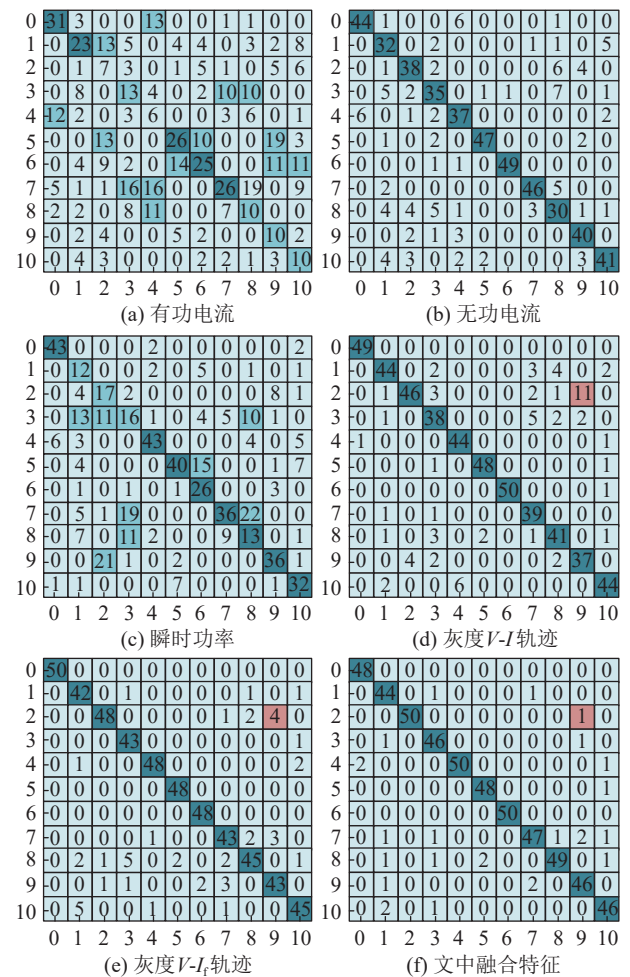


图8 不同特征的混淆矩阵

Fig.8 Confusion matrix of different features

由图8(a)、(c)可知, 当选用单一有功电流和瞬时功率作为特征时, 如吹风机等设备的辨识错误数量甚至要大于正确的数量。当选用无功电流作为

电力设备的辨识特征时,辨识的整体效果要远高于选用有功电流的情况。基于 $V-I$ 轨迹特征的辨识准确率明显高于单一特征,而基于 $V-I_t$ 轨迹特征的辨识效果优于 $V-I$ 轨迹,如图 8(d)、(e)中的红色模块所示,以吹风机和加热器为例,由于吹风机处于吹热风阶段时,与加热器的工作模式较为相似,采用 $V-I$ 轨迹特征不能很好地进行区分,而 $V-I_t$ 轨迹增加了不同阻性负荷之间的区分度,错误辨识的数量明显减少。文中在 $V-I_t$ 轨迹的基础上采用颜色编码的方式融合有功电流和功率特征,进一步提升了最终的辨识精度。

3.5 模型效果分析

3.5.1 模型架构性能对比

采用基于 CNN 的负荷辨识模型,并加入 DSC 模块和 HDC 模块使模型更加轻量化。为进一步验证文中负荷辨识模型的综合效果,选择残差神经网络(residual neural network, ResNet)^[35]、VGG^[29]、GoogleNet^[36]与文中模型进行对比分析。其中 ResNet 提出残差模块,使正、反向梯度一直不为零,从而在增加模型深度的基础上保证模型能够充分训练;VGG 利用多个卷积核尺寸较小的卷积层替代单个大尺寸卷积核的卷积层,从而增加模型的非线性;GoogleNet 将具有不同尺寸卷积核的卷积层进行并联,降低串联结构的信息丢失风险,提升模型的特征提取能力。

文中从辨识效果和运算成本两方面对模型进行综合评价,运算成本采用模型计算量、参数量、模型的训练耗时和辨识耗时进行衡量。不同模型架构的性能表现如表 3 所示。可以看出,4 种辨识模型都取得了不错的辨识效果,文中模型的辨识效果与 ResNet 差别不大,略高于 VGG,其中 GoogleNet 的辨识效果优于文中模型,F1 分数比文中模型高 0.1%。虽然文中模型的辨识效果并不是最优的,但与其他几种模型相差较小,且文中模型的参数量、计算量以及训练耗时最小。虽然 ResNet、VGG、GoogleNet 的图像辨识模型因为具有较深的模型层数而取得了优越的学习能力,但模型规模越大,所需要的运算平台越大,导致硬件成本显著增加。相较于 ResNet、VGG、GoogleNet,文中模型在辨识耗时上分别减少了 65.925%、64.697%、75.670%,在负荷辨识的实时性方面得到很大提升。更短的辨识时间意味着可以更快发现危险负荷的接入和违规的用电行为,有助于用户和电力部门及时采取相关应对措施。

综合上述分析,相较于 ResNet、VGG、GoogleNet,

表 3 不同模型架构的性能表现

Table 3 Performance of different model architectures

性能指标	ResNet	VGG	GoogleNet	文中模型
精确率	0.950	0.890	0.955	0.953
召回率	0.947	0.887	0.957	0.954
F1分数	0.947	0.887	0.954	0.953
参数量/个	21 290 315	126 009 763	5 999 387	42 285
计算量/次	300 269 568	127 590 688	520 698 880	372 100
训练耗时/s	11 966.347	8 100.923	5 079.306	346.790
辨识耗时/s	0.719	0.694	1.007	0.245

文中模型在保证模型规模较小的同时,仍能维持较高的辨识准确率,实现了两者的平衡。

3.5.2 卷积模块消融分析

DSC 利用分离卷积和点状卷积的组合代替传统卷积操作,以此减少模型的计算量,而 HDC 通过具有不同扩张率的卷积核增加模型的感受野。文中在传统 CNN 的基础上引入 DSC 和 HDC,在减少模型计算量的同时,可以保持较高的识别精度。为体现 DSC 和 HDC 的增益效果,采用 CNN、CNN+DSC、CNN+HDC 与文中模型进行对比分析。不同模型架构的辨识效果、参数量和计算量对比结果如图 9 所示。其中,横坐标为不同模型架构的 F1 分数,F1 分数越大,代表辨识准确率越高;纵坐标为模型参数量;圆圈大小为模型的计算量,圆圈越小,代表模型的计算量越少。

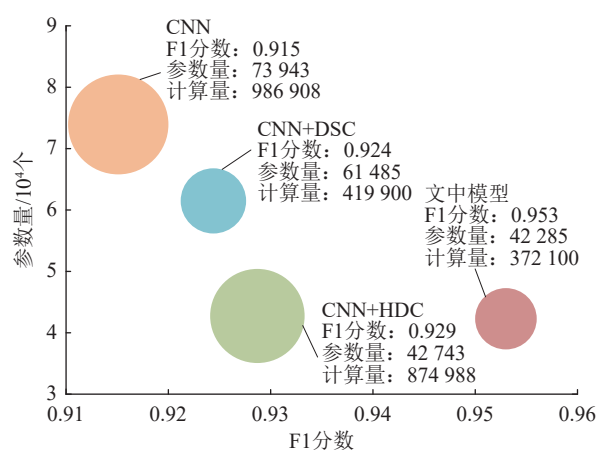


图 9 不同模块与 CNN 融合的效果对比

Fig.9 Comparison of CNN integrated with different modules

从图 9 中可以看出,文中所提模型架构在辨识准确率、模型参数量和计算量方面均优于其他模型架构。随着 HDC 模块的加入与模型感受野的增加,CNN+HDC 的 F1 分数存在一定幅度的提升。相较于传统 CNN 架构,CNN+HDC 和 CNN+DSC 在参数量和计算量的表现上都有一定的改善,其中

CNN+HDC 的参数量要低于 CNN 和 CNN+DSC, 而 CNN+DSC 由于将传统卷积层改为分离卷积和点状卷积的组合, 在计算量上的表现更为突出。

为进一步验证 HDC 模块的有效性, 文中采用 CNN+DSC+DC-2 和 CNN+DSC+DC-3 与文中模型进行对比, 其中 CNN+DSC+DC-2 为将文中模型的扩张率均设置为 2, CNN+DSC+DC-3 为将文中模型的扩张率均设置为 3。当采用 CNN+DSC+DC-2 和 CNN+DSC+DC-3 作为辨识模型时, F1 分数分别为 0.927 和 0.914。空洞卷积模块通过在卷积核中间填补空洞来增加感受野, 但多个相同扩张率空洞卷积堆叠会导致信息丢失。CNN+DSC+DC-2 的扩张率取值较小, 特征信息损失较少, 相较于 CNN, 辨识准确率更高。CNN+DSC+DC-3 的辨识效果劣于 CNN, 其原因在于, 相较感受野增加对模型带来的增益效果, 特征信息丢失导致的负面影响更加严重。而文中模型选取 HDC 以代替多个相同扩张率空洞卷积的堆叠, 增强了视野的连贯性。

在负荷辨识领域, 具有高区分度的负荷特征能够显著提高最终的负荷辨识精度, 而增加辨识模型复杂度在辨识准确率的提升上并不明显, 反而会导致模型需要较长的训练时间, 大幅增加计算量和参数量。文中模型架构综合 DSC 和 HDC 在参数量和计算量上的优点, 在上述模型架构中表现最佳, 可以实现辨识准确率和模型规模的平衡。

4 结论

文中提出一种基于改进 $V-I$ 轨迹的非侵入式负荷辨识方法, 主要特点如下:

(1) 针对负荷特征信息挖掘不足的问题, 将 $V-I$ 轨迹、有功电流和瞬时功率特征分别输入到不同的颜色通道中形成彩色融合特征, 利用不同像素点的颜色差异, 进一步丰富特征信息, 提升不同负荷之间的特征区分度。由算例分析结果可得, 文中方法的 F1 分数达到 0.953, 相较于传统的 $V-I$ 轨迹特征方法, 辨识准确率明显提升。

(2) 针对辨识模型规模过大的问题, 文中通过引入 DSC 模块和 HDC 模块搭建轻量化模型实现负荷辨识工作, 对模型辨识性能和规模进行优化设计。实现模型分类性能和计算复杂度的平衡, 降低模型对运行环境的依赖。同时, 相较于传统模型架构, 文中方法在辨识实时性方面得到了明显提升, 有助于及时发现危险负荷的接入。

参考文献:

[1] LU M Q, LI Z Y. A hybrid event detection approach for non-

intrusive load monitoring[J]. *IEEE Transactions on Smart Grid*, 2020, 11(1): 528-540.

[2] 罗平, 樊星驰, 章坚民, 等. 基于电器运行状态和深度学习的非侵入式负荷分解[J]. *电力系统自动化*, 2021, 45(12): 49-56.

LUO Ping, FAN Xingchi, ZHANG Jianmin, et al. Non-intrusive load decomposition based on operation state of electrical appliances and deep learning[J]. *Automation of Electric Power Systems*, 2021, 45(12): 49-56.

[3] 杨海英, 孙伟, 史梦阳. 基于时间分区和粒子群优化的非侵入式负荷分解研究[J]. *电测与仪表*, 2024, 61(5): 52-59.

YANG Haiying, SUN Wei, SHI Mengyang. Research of non-intrusive load decomposition based on time partition and V-shaped particle swarm optimization[J]. *Electrical Measurement & Instrumentation*, 2024, 61(5): 52-59.

[4] 王谱宇, 耿路路, 刘兴江, 等. 基于在线特征库的非侵入式负荷特征提取方法[J]. *中国电机工程学报*, 2024, 44(9): 3489-3500.

WANG Puyu, GENG Lulu, LIU Xingjiang, et al. Non-intrusive load feature extraction method based on online feature library[J]. *Proceedings of the CSEE*, 2024, 44(9): 3489-3500.

[5] 崔亮节, 孙毅, 刘耀先, 等. 考虑分时段状态行为的非侵入式负荷分解方法[J]. *电力系统自动化*, 2020, 44(5): 215-222.

CUI Liangjie, SUN Yi, LIU Yaoxian, et al. Non-intrusive load disaggregation method considering time-phased state behavior[J]. *Automation of Electric Power Systems*, 2020, 44(5): 215-222.

[6] 李家东, 胡正华, 蒋卫平, 等. 基于时间序列分类任务的智能电能表负荷监测技术研究[J]. *电测与仪表*, 2023, 60(6): 153-159.

LI Jiadong, HU Zhenghua, JIANG Weiping, et al. Load monitoring technology of smart electricity meters based on time series classification task[J]. *Electrical Measurement & Instrumentation*, 2023, 60(6): 153-159.

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

[8] 李俊楠, 何心铭, 周慧娟, 等. 基于非侵入式负荷监测的居民侧灵活性资源评估方法[J]. *电测与仪表*, 2024, 61(6): 148-158.

LI Junnan, HE Xinming, ZHOU Huijuan, et al. Assessment method of residential-side flexibility resources based on non-intrusive load monitoring[J]. *Electrical Measurement & Instrumentation*, 2024, 61(6): 148-158.

[9] 张潼, 于鹤洋, 田江, 等. 基于非侵入式负荷辨识的聚合负荷需求响应能力在线评估[J]. *电力工程技术*, 2020, 39(6): 19-25, 65.

ZHANG Tong, YU Heyang, TIAN Jiang, et al. Online aggregation monitoring of low-voltage power load demand response capability based on non-intrusive load identification[J]. *Electric Power Engineering Technology*, 2020, 39(6): 19-25, 65.

[10] 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.
- [11] 卢德龙, 童充, 吴志坚, 等. 基于电力线载波阻抗特性的电力系统负荷网络主动感知方法[J]. *高电压技术*, 2022, 48(4): 1296-1307.
- LU Delong, TONG Chong, WU Zhijian, et al. Active sensing method of power system load network based on characteristics of power line carrier impedance[J]. *High Voltage Engineering*, 2022, 48(4): 1296-1307.
- [12] 鲍海波, 杨舒惠, 陈子民, 等. 事件检测类非侵入式负荷监测算法综述[J]. *电力系统自动化*, 2023, 47(13): 94-109.
- BAO Haibo, YANG Shuhui, CHEN Zimin, et al. Review on event-inspection based non-intrusive load monitoring algorithms[J]. *Automation of Electric Power Systems*, 2023, 47(13): 94-109.
- [13] 柳青, 刘小平, 陈浩, 等. 复杂设备环境下的多状态负荷运行状态辨识方法[J]. *电测与仪表*, 2024, 61(2): 55-62.
- LIU Qing, LIU Xiaoping, CHEN Hao, et al. Identification approach of multi-state load operating conditions in complex equipment environments[J]. *Electrical Measurement & Instrumentation*, 2024, 61(2): 55-62.
- [14] 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.
- [15] LAM H Y, FUNG G S K, LEE W K. A novel method to construct taxonomy electrical appliances based on load signatures[J]. *IEEE Transactions on Consumer Electronics*, 2007, 53(2): 653-660.
- [16] GAO J K, KARA E C, GIRI S, et al. A feasibility study of automated plug-load identification from high-frequency measurements[C]//2015 IEEE Global Conference on Signal and Information Processing (GlobalSIP). Orlando, FL, USA. IEEE, 2015: 220-224.
- [17] 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.
- [18] 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.
- [19] TESHOME D F, HUANG T D, LIAN K L. Distinctive load feature extraction based on fryze's time-domain power theory[J]. *IEEE Power and Energy Technology Systems Journal*, 2016, 3(2): 60-70.
- [20] 陈俊, 彭勇刚, 凌家源, 等. 基于概率稀疏自注意力模型的非侵入式负荷分解[J]. *电网技术*, 2022, 46(10): 3932-3941.
- CHEN Jun, PENG Yonggang, LING Jiayuan, et al. Non-intrusive load disaggregation based on probabilistic sparse self-attention model[J]. *Power System Technology*, 2022, 46(10): 3932-3941.
- [21] KELLY J, KNOTTENBELT W. Neural NILM: deep neural networks applied to energy disaggregation[C]//Proceedings of the 2nd ACM International Conference on Embedded Systems for Energy-Efficient Built Environments. Seoul South Korea. ACM, 2015: 55-64.
- [22] 李莉, 黄友金, 熊炜, 等. 基于改进卷积神经网络的非侵入负荷辨识方法研究[J]. *电测与仪表*, 2024, 61(1): 125-130,156.
- LI Li, HUANG Youjin, XIONG Wei, et al. Non-intrusive load identification method based on improved convolutional neural network[J]. *Electrical Measurement & Instrumentation*, 2024, 61(1): 125-130,156.
- [23] 邢海青, 郭瑞峰, 杨浙川, 等. 基于数据扩充与无阈值递归图的非侵入式负荷识别方法[J]. *浙江电力*, 2024, 43(6): 88-100.
- XING Haiqing, GUO Ruifeng, YANG Zhechuan, et al. A non-intrusive load identification method based on data augmentation and threshold-free recurrence plot[J]. *Zhejiang Electric Power*, 2024, 43(6): 88-100.
- [24] 何健明, 李梦诗, 张禄亮, 等. 基于 Attention 和残差网络的非侵入式负荷监测[J]. *电测与仪表*, 2024, 61(6): 173-180.
- HE Jianming, LI Mengshi, ZHANG Luliang, et al. Non-intrusive load monitoring algorithm based on attention and residual networks[J]. *Electrical Measurement & Instrumentation*, 2024, 61(6): 173-180.
- [25] 陈军锋, 王雪, 张效天. 非侵入式负荷识别边缘计算颜色编码研究[J]. *仪器仪表学报*, 2020, 41(9): 12-19.
- CHEN Junfeng, WANG Xue, ZHANG Xiaotian. Non-intrusive load recognition using color encoding in edge computing[J]. *Chinese Journal of Scientific Instrument*, 2020, 41(9): 12-19.
- [26] 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.
- [27] 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.
- [28] 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.

- [29] 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.
- [30] WANG Z G, OATES T. Imaging time-series to improve classification and imputation[C]//Proceedings of the 24th International Conference on Artificial Intelligence. Buenos Aires, Argentina, 2015: 3939-3945.
- [31] 李海燕, 尹浩林, 钟杏苑, 等. 基于改进知识一致性注意力的图像修复算法[J]. 华中科技大学学报(自然科学版), 2023, 51(9): 110-117.
LI Haiyan, YIN Haolin, ZHONG Xingyuan, et al. Inpainting algorithm based on hybrid dilated convolution and improved knowledge consistent attention[J]. Journal of Huazhong University of Science and Technology (Natural Science Edition), 2023, 51(9): 110-117.
- [32] CHAWLA N V, BOWYER K W, HALL L O, et al. SMOTE: synthetic minority over-sampling technique[J]. Journal of Artificial Intelligence Research, 2002, 16: 321-357.
- [33] HAN H, WANG W Y, MAO B H. Borderline-SMOTE: a new over-sampling method in imbalanced data sets learning [M]//Advances in Intelligent Computing. Berlin, Heidelberg: Springer Berlin Heidelberg, 2005: 878-887.
- [34] 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.
- [35] 段晶, 李勇, 张振宇, 等. 考虑辨识结果连续性的 Type-III 型工商业负荷辨识方法[J]. 电力系统自动化, 2021, 45(24): 65-72.
DUAN Jing, LI Yong, ZHANG Zhenyu, et al. Identification method for Type-III industrial and commercial load considering identification result continuity[J]. Automation of Electric Power Systems, 2021, 45(24): 65-72.
- [36] SZEGEDY C, LIU W, JIA Y Q, et al. Going deeper with convolutions[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Boston, MA, USA. IEEE, 2015: 1-9.

作者简介:



李剑文

李剑文(1997), 男, 硕士在读, 研究方向为非侵入式负荷监测(E-mail: lijianwen@hhu.edu.cn);

梅飞(1982), 男, 博士, 讲师, 研究方向为电气设备在线监测与故障诊断;

张晓光(1997), 男, 硕士在读, 研究方向为电气设备故障诊断与状态评估。

Non-intrusive load identification method based on improved $V-I$ trajectory

LI Jianwen, MEI Fei, ZHANG Xiaoguang, FENG Tongtong, LI Xin

(School of Electrical and Power Engineering, Hohai University, Nanjing 211100, China)

Abstract: Aiming at the problems of insufficient mining of load characteristic information and large scale of identification model in current non-intrusive load identification methods, a non-intrusive load identification method based on improved $V-I$ trajectory is proposed. Firstly, the active current, instantaneous power, and $V-I_f$ trajectory are fused into new load features by using the Gramian angular field (GAF) and color encoding techniques. Then, the convolutional neural network (CNN) model framework is optimized through the depthwise separable convolution (DSC) module and the hybrid dilated convolution (HDC) module to construct a lightweight load identification model. Finally, experiments are conducted using public datasets for analysis. The results show that the F1 score of the proposed method is 0.953, which can further improve the identification accuracy of electrical loads while reducing the occupation of software and hardware resources.

Keywords: non-intrusive load monitoring; color coding; multi-feature fusion; $V-I_f$ trajectory; lightweight model; Gramian angular field (GAF)

(编辑 陆海霞)