

基于轨迹融合与背景映射的非侵入式负荷监测方法^{*}负 智¹ 伍萍辉¹ 李义博¹ 堪 铮¹ 郭志涛^{1,2}

(1. 河北工业大学电子信息工程学院 天津 300130; 2. 河北工业大学创新研究院(石家庄) 石家庄 050299)

摘 要: 非侵入式负荷监测是一种通过分析电力总线上的电压和电流变化来识别运行中的电器负荷及其能耗的技术。随着电力负荷种类和数量的持续增加,提取独特的负荷特征并建立高效的非侵入式负荷监测分类模型变得尤为重要。提出了一种以多 V-I 轨迹融合与背景特征映射为核心的图像特征增强方法,并结合迁移学习策略将其应用于 ResNet18 网络中,通过多 V-I 轨迹融合和图像背景映射来提高负荷识别的准确性,实现了非侵入式负荷的高效分类。不同于传统方法,本研究首次提出全波与滤波轨迹的差异化融合策略,增强了负荷特征的唯一性,并在图像背景中映射多个稳态特征,进一步提升了图像的代表能力。实验结果表明,所提方法在 PLAID2014、PLAID2017 以及 PLAID2018 数据集上的负荷识别准确率分别提高至 98.67%、97.53% 以及 98.64%,相较于现有模型表现出显著的优势。

关键词: 非侵入式负荷监测; 负荷识别; 背景映射; V-I 轨迹; 迁移学习

中图分类号: TM714; TN99 **文献标识码:** A **国家标准学科分类代码:** 470.40

Non-intrusive load monitoring method based on trajectory
fusion and background mappingYun Zhi¹ Wu Pinghui¹ Li Yibo¹ Kan Zheng¹ Guo Zhitao^{1,2}

(1. College of Electronic Information Engineering, Hebei University of Technology, Tianjin 300130, China;

2. Innovation Research Institute, Hebei University of Technology (Shijiazhuang), Shijiazhuang 050299, China)

Abstract: Non-intrusive load monitoring is a technology that identifies operating electrical appliances and their energy consumption by analyzing voltage and current variations on the main power bus. With the continuous increase in the types and quantities of electrical loads, extracting unique load features and establishing efficient non-intrusive load monitoring classification models have become particularly important. This paper proposes an image feature enhancement method centered on multi-voltage-current trajectory fusion and background feature mapping, and applies it to the ResNet18 network via a transfer learning strategy. By means of multi-V-I trajectory fusion and image background mapping, the accuracy of load identification is improved, thus achieving efficient classification of non-intrusive loads. Different from traditional methods, this paper for the first time proposes a differential fusion strategy of full-wave and filtered trajectories, which enhances the uniqueness of load features. Additionally, by mapping multiple steady-state features in the image background, the representational capability of the images is further improved. Experimental results demonstrate that the load identification accuracies of this method on the PLAID2014, PLAID2017 and PLAID2018 datasets are increased to 98.67%, 97.53% and 98.64% respectively, exhibiting significant advantages over existing models.

Keywords: non-intrusive load monitoring; load identification; background mapping; voltage-current trajectory; transfer learning

0 引 言

中国“双碳”政策强调提高能源利用效率,非侵入式负荷监测(non-intrusive load monitoring, NILM)研究可以在

这一方面发挥重要作用。NILM 技术通过监测电力总线上的电流和电压信号,无需在每个电器负荷上安装独立计量设备,便能识别各个电器负荷的工作状态,帮助更精确地监测和管理能源消费,降低不必要的能源消耗,促进低碳

生活。

在 NILM 研究中,常使用传统机器学习或深度学习方法进行一些基于传统稳态特征的负荷识别,文献[1]利用有功功率和无功功率设计双变量隐马尔可夫模型(bivariate hidden markov model, BHMM)描述负荷特性。文献[2]提出了一种基于希尔伯特变换(Hilbert transform, HT)和长短期记忆网络(long short-term memory, LSTM)的方法来解决负荷识别问题,该方法在电流信号时域特征方面取得了较好的效果。文献[3]基于极限学习机(extreme learning machine, ELM)提出了一种高频电流信号时域和频域特征融合学习策略,提升了识别准确率。

部分学者将研究的方向转向将电气特征映射为图像进行识别,将 NILM 研究引入到计算机视觉领域。文献[4]使用椭圆傅里叶描述符结合随机森林与卷积神经网络(convolutional neural network, CNN)的方法。文献[5]提出加权递归图(weighted recursive graph, WRG),通过保留信号幅值与相似性的量化信息,提升特征区分度。文献[6]设计无阈值递归图(recurrence plot, RP),结合空间金字塔池化(spatial pyramid pooling, SPP)增强模型特征捕捉能力。文献[7]为解决递归图的信息丢失局限,采用可视化格拉姆角场编码,提高了分类精度。文献[8]采用格莱姆矩阵颜色编码方法构建负荷标识,增强标识表征能力,实现较高正确率负荷识别。

电压电流轨迹(V-I 轨迹)作为 NILM 与计算机视觉两者研究的交叉点,被众多学者重视。文献[9]将 V-I 轨迹进行二值映射,把轨迹映射到一个网格上,降低计算成本的同时显著提高了对电器负荷识别精度。文献[10]将 V-I 轨迹转换为加权像素化图像,使得图像具有连续值而不是二进制值,并将图像作为卷积神经网络的输入。

在 NILM 研究中,电器负荷可分为 I 型负荷和 II 型负荷。I 型负荷指运行状态稳定、电气特性为线性的设备,如白炽灯、电热水壶等,其 V-I 轨迹形态稳定、特征明显,易于识别。而 II 型负荷是指如冰箱、空调、洗衣机、笔记本电脑等具有多状态运行行为和显著的非线性特征的负荷,其电流波形畸变严重,谐波丰富, V-I 轨迹复杂多变,识别难度远高于 I 型负荷。II 型负荷的识别难度核心源于其固有的多状态运行特性与非线性电气特征^[11]。这类负荷普遍存在多模式切换行为,如冰箱涉及压缩机启停,洗衣机包含注水、洗涤、脱水等动态过程。因此 II 型负荷的识别难点集中体现在两点。一是其不同运行状态下,电流波形畸变程度、无功功率占比差异显著,这直接导致同一 II 型负荷的 V-I 轨迹波动剧烈,使其多种运行状态难以被归类为同一负荷;二是 II 型负荷的某一种运行状态的 V-I 轨迹会与其他负荷的 V-I 轨迹特征高度重叠,使其某种运行状态容易与其他负荷相互混淆,例如空调这种电器负荷具有多种工作模式^[12],在工作在送风模式下其轨迹与风扇相似,从而在分类任务中这个状态的空调易与风扇混淆。

在文献[13]中,在 HSV 空间中进行了颜色编码,得到了彩色的 V-I 轨迹,使用了迁移学习的策略,使用预训练的 AlexNet 对 V-I 轨迹进行识别和分类,提高了识别的准确率,但其对 II 型负荷的识别效果不稳定。文献[14]通过颜色编码将负荷的功率和电流大小转换为颜色信息并与 V-I 轨迹进行融合。然而,不同负荷之间的功率和电流差异很大,用功率或幅值确定颜色会导致大多数负荷的功率或电流集中在同一颜色区间,这影响了识别精度。文献[12]通过改进通道注意力机优化变分自编码器对 II 型负荷空调进行识别,提高了单一 II 型负荷识别的准确率,但未拓展至多负荷识别领域。

但 II 型负荷的非线性特性会具备丰富的高次谐波特征,能精准反映负荷内部电气元件的差异,通过引入谐波特征,可以显性化不同 II 型负荷的谐波响应差异,使 V-I 轨迹不仅包含电压电流的时域关联信息,还承载了反映负荷线性度的频域特征,从而显著提升识别效果。文献[15]证明了谐波特征可以有效区分小功率负荷,并将 3 谐波与功率进行融合。文献[16]针对住宅负荷的多个奇次谐波分别设计了带阻滤波器,证明了奇次谐波对在不同电器负荷中的差异性以及用于分类的可行性。文献[17]提取了各类电器负荷的电流谐波向量,并指出 7 次及以上的谐波含能量少,对电器负荷分类的贡献小。基于以上研究, V-I 轨迹特征与谐波特征结合的方式被广泛应用与近年的 NILM 研究当中,文献[18]提出基于 V-I 轨迹特征的颜色编码和负荷高次谐波特征相融合的识别方法,相对于传统的 V-I 轨迹图像识别方法,识别效果提升。文献[19]将 V-I 轨迹、奇次谐波的幅值和相角以及基波幅值集成到特征矩阵中,通过颜色构造矩阵热图,采取多维特征融合方式,准确率方面仍有提升空间。文献[20]采用 RGB 颜色编码的对称 V-I 轨迹图像,配合有利于对称轨迹的 Swim Transformer 模型进行识别,进一步提升识别准确率,但在 II 型负荷的识别上仍然存在困难。文献[21]在彩色 V-I 轨迹的基础上添加时间轴,构建了三维空间的 V-I 轨迹,并采用迁移学习与 ResNet34 模型进行识别,提升了识别精度,但是在 II 型负荷的识别上效果欠佳。

受以上研究内容和问题的启发,本文提出了一种以多 V-I 轨迹融合与背景特征映射为核心的图像特征增强方法,并结合迁移学习策略将其应用于 ResNet18 网络中,实现了非侵入式负荷的高效分类。通过在全波上去除特定高次谐波后进行 HSV 颜色编码获得嵌入多个特征的 V-I 轨迹图像,并将全波 V-I 轨迹图像与去除 3、5 次谐波的 V-I 轨迹图像进行融合,并在图像背景中映射多个稳态特征。此外,使用在 ImageNet 数据集得到充分训练的 ResNet18 模型,将其训练好的权重迁移至 PLAID 数据集继续训练,实现迁移学习。文章主要贡献为:

1) 本文提出一种多 V-I 轨迹图像差异化融合的创新方法,利用全波 V-I 轨迹图像与去除特定高次谐波后的 V-I

轨迹图像进行融合,保留非线性特征的同时增强不同谐波成分对轨迹形态的影响差异对比,从而增强图像的特征表示能力,使模型能更好地捕捉图像中的关键特征。

2)在图像背景中映射多稳态特征,本文有效利用了图像的背景,设计 RGB 3 通道背景映射方法,将电流幅值、电流均方根、有功功率等稳态特征分别映射到图像背景的 RGB 3 个通道中,引入更多特征,补充 V-I 轨迹图像的稳态特征维度。




图 1 整体框

Fig. 1 Overall block

1.1 V-I 轨迹数据获取与预处理

为满足信号功率计算以及周期性分析需求,选择电压由负到正的过零点作为数据的起始点,确保采集到完整的周期信号,并对齐电压电流数据。为避免单周期的非典型性,截取 3 个完整的电压和电流周期,PLAID2014 数据集中第一个电器负荷的电压电流波形如图 2 所示。




图 2 PLAID2014 数据集中第一个电器负荷的电压、电流、无功电流波形

Fig. 2 Voltage, current, and reactive current waveforms of the first electrical appliance in the PLAID2014 dataset

在电力系统和电负荷分析中,V-I 轨迹的形状直接反映了负荷的物理特性。有功电流通常比无功电流占据更大的比例,在 V-I 轨迹的显示上,不同负荷类型的电器负荷可能显得非常相似,导致无法有效区分它们。

为了增强区分度,采用 Fryze 功率理论将电流信号中的无功电流分解出来以增强 V-I 轨迹的特异性。

Fryze 功率理论表明,有功电流代表负荷电流在电源电压方向上的投影,反映了电阻的贡献。它与电压成正

1 V-I 轨迹特征映射

本文的轨迹融合和背景映射整体框图如图 1 所示。首先,利用 Fryze 功率理论将电流信号中的无功电流分解出来,利用无功电流和电压在 HSV 空间映射全波 V-I 轨迹,然后通过滤波得到去 3、5 次谐波的 V-I 轨迹,将 3 个轨迹融合得到多 V-I 轨迹融合图像,最后在 RGB 3 通道分别映射电流幅值、电流均方根以及有功功率实现背景特征的映射。

比,因此直接反映了电阻性的负荷特性。有功电流分量的具体公式为:

$$i_a(t) = \frac{P_{active}}{V_{rms}^2} V(t) \quad (1)$$

$$P_{active} = \frac{1}{T} \int_0^T V(t) I(t) dt \quad (2)$$

其中, $V(t)$ 、 $I(t)$ 为电压和电流, $i_a(t)$ 为有功电流分量, P_{active} 为有功功率,表示负荷的实际功率。 V_{rms} 为电压的有效值。

无功电流代表了与电压正交的分量,这部分电流不参与功率传输,主要与负荷的电抗特性有关。无功电流分量计算公式为:

$$i(t) = I(t) - i_a(t) = I(t) - \frac{V(t)}{V_{rms}^2 T} \int_0^T V(t) I(t) dt \quad (3)$$

其中, $i(t)$ 为无功电流分量, $I(t)$ 为总电流信号, $i_a(t)$ 为有功电流分量。

本研究采用无功电流与电压绘制 V-I 轨迹,这样增强负荷区分度,提升系统稳定性。通过将电流分解为有功与无功成分,无功电流反映了电负荷的电抗特性,有助于区分不同负荷类型。

1.2 彩色 V-I 轨迹映射

首先利用二进制轨迹映射将轨迹转移到矩阵 $\mathbf{W}$ 。将原始电压 v 和无功电流 i 的二维平面划分为大小均匀的单元网格,计算单个单元格的长度和宽度:

$$\begin{cases} \Delta i = \frac{i_{max}}{N} \\ \Delta v = \frac{v_{max}}{N} \end{cases} \quad (4)$$

其中, $N \in \mathbf{Z}^+$, 矩阵 $\mathbf{W}$ 的形状为 $2N \times 2N$, 为保证图像质量与分辨率, N 取值为 16。对于每个电流电压数据点 (i_k, v_k) , $k = 1, 2, \dots, K$, 落入对应的单元格坐标为 $(n_{i_k}, n_{v_k}) = (\text{ceil}(i_k/\Delta i) + N, \text{ceil}(v_k/\Delta i) + N)$, K 为数据点总数。若有数据点落入单元格, 令对应单元格的值为 1, 即 $W(n_{i_k}, n_{v_k}) = 1$, 此时矩阵 $\mathbf{W}$ 为描述 V-I 轨迹的二值矩阵。

色相、饱和度、明度 (hue saturation value, HSV) 是一种常见的颜色表示方式, 主要特点在于将颜色信息分解为 3 个独立的分量, 使得操作和处理颜色变得更加直观, 尤其在图像处理和计算机视觉中非常常用。

Hue 代表色相, 以角度来表示, 范围是 $0^\circ \sim 360^\circ$, 本文将轨迹方向映射到 H 通道, 用来表示 V-I 轨迹的运动特征。计算轨迹中两个连续点的相位角, 得到的角度范围为 $0^\circ \sim 360^\circ$ 。然后, 将第 k 点的色相存储在 $2N \times 2N$ 的全波 V-I 轨迹 H 通道矩阵 $\mathbf{H}$ 中。多周期绘制轨迹存在多数据点落入同一格点则取均值, 具体公式为:

$$H_k = \arg\left(\frac{v_{k+1} - v_k}{v_{\max}}, \frac{i_{k+1} - i_k}{i_{\max}}\right), k = 1, 2, \dots, K \quad (5)$$

$$H(n_{i_k}, n_{v_k}) = \frac{\sum_{k \in A} H_k}{|A|} \quad (6)$$

其中, H_k 为第 k 点与第 $k+1$ 点的相位角, $|A|$ 为集合 A 的基数, 集合 A 中的元素为落入 (n_{i_k}, n_{v_k}) 格点中的点。

Saturation 代表饱和度, 表示颜色的纯度或强度, 范围从 0~1, 将功率因数映射到 S 通道, 将第 k 点的饱和度存储在 $2N \times 2N$ 的全波 V-I 轨迹 S 通道矩阵 $\mathbf{S}$ 中, 来补充有功和无功分量之间的关系特征。具体公式为:

$$S(n_{i_k}, n_{v_k}) = \frac{P_{\text{active}}}{P_{\text{apparent}}} = \frac{1}{K} \sum_{k=1}^K \frac{v_k i_k}{v_{\text{rms}} i_{\text{rms}}} \quad (7)$$

其中, N 为采样点总数, P_{apparent} 为视在功率, v_{rms} 、 i_{rms} 分别为负荷电压和电流的有效值。

Value 代表明度, 表示颜色的亮度, 范围从 0~1, 值越高, 颜色越亮, 本文将轨迹的重复性映射到 V 通道矩阵 $\mathbf{V}$, 通过使用各周期二值矩阵 $\mathbf{W}_m$ ($m = 1, 2, \dots, M$) 的值计算, 通过平均像素值得到。即使在电力负荷稳定运行时, V-I 轨迹也不会一直保持不变。因此, 不同周期的 V-I 轨迹容易分别因负荷波动或未滤波噪声而略有不同。这种现象在只使用波形的一个周期的情况下, 不可避免地会导致错误分类。虽然一个周期的波形对于 V-I 轨迹的绘制已经足够了, 但为了适应负荷的动态特性, 提高鲁棒性, 建议采用多周期的波形。具体公式为:

$$V = \frac{1}{M} \sum_{m=1}^M \mathbf{W}_m \quad (8)$$

其中, M 为绘制 V-I 轨迹使用的周期数, 设为 3。

最后利用得到的 H 、 S 和 V 这 3 个通道值, 将 V-I 轨迹转换为人类可感知的 RGB 图像, 绘制出的全波 V-I 轨迹图像如图 3(a) 所示。




图 3 紧凑型荧光灯的 V-I 轨迹图像

Fig. 3 V-I trajectory image of compact fluorescent lamps

1.3 轨迹融合

在原始全波轨迹中, 所有谐波共同决定了 V-I 轨迹的整体形态, 但不同负荷对特定谐波的响应差异明显, 直接使用全波轨迹容易掩盖这类区分性特征。仅保留某一阶谐波虽可突出其特性, 但会导致轨迹过于简化、缺乏代表性, 识别的效果不佳。而保留在全波中占比较高的 3 次、5 次谐波, 则会掩盖其他阶次谐波的关键特征。为兼顾信息丰富性与辨识能力, 本文提出差异化谐波去除策略, 分别去除 3 次与 5 次谐波生成对应轨迹, 并与全波轨迹进行融合, 在保留非线性特征的同时强化谐波变化带来的形态差异, 从而提升负荷特征的可辨识性。

本研究通过带阻滤波器分别去除 3 次和 5 次谐波, 生成两张去除特定谐波的 V-I 轨迹。将这 3 种轨迹进行融合, 实际上是在图像中显性编码各次谐波对轨迹形态的贡献差异。在本方法中, 并不以单一滤波图像作为最终输入, 而是将完整信息与滤波信息做对比融合, 通过采用信息融合的方式, 达到负荷间特征差异对比增强、轨迹间差异对比增强、鲁棒性提升的效果。去除某阶次谐波后, 轨迹形状的微小变化直接凸显该阶次谐波在不同负荷间响应差异。在融合图像中, 全波与滤波后的轨迹在 HSV 空间下的色相与饱和度不同, 对全波与滤波后的轨迹进行了差异对比增强, 使神经网络能够更高效地学习到各阶谐波所引起的图形变化特征; 高次谐波往往易受噪声和测量误差影响, 通过在多视图融合中对它们进行有选择的去除, 可降低模型对噪声谐波的过度拟合, 提升鲁棒性。

使用带阻滤波器在全波中去除某阶次谐波,首先进行傅里叶变换,将电流信号从时域转换到频域。公式为:

$$\hat{i}(f) = \mathcal{F}\{i(t)\} \quad (9)$$

其中, $i(t)$ 是原始无功电流分量, $\hat{i}(f)$ 是频域中的电流信号。

去除目标谐波频率,应用频率掩码清除目标频率及其邻域,去除特定谐波成分。滤波后频域电流信号 $\hat{i}_{filtered}(f)$ 计算公式为:

$$\hat{i}_{filtered}(f) = \hat{i}(f) \times (1 - mask(f)) \quad (10)$$

$$mask(f) = \begin{cases} 1, & |f - n \times f_0| \leq BW \\ 0, & \text{其他} \end{cases} \quad (11)$$

其中, $mask(f)$ 是频率掩码,标记需要去除的目标谐波频率及其邻域, n 是目标谐波的次数, f_0 是基频, BW 是用于限制去除范围的带宽,在针对家用电器负荷谐波处理的研究中,带阻滤波器的带宽通常设置为目标谐波频率的 2%,本文去除 3 次谐波时 BW 取值为 3 Hz,去除 5 次谐波时 BW 取值为 5 Hz,以确保有效去除特定谐波的同时,避免过度影响相邻频率成分。

标记出去要去除的目标谐波频率及其邻域后,逆傅里叶变换和取实部,将处理后的频域信号转换回时域并取实部。滤波后时域电流信号 $i_{filtered}(t)$ 计算公式为:

$$i_{filtered}(t) = Re\{\mathcal{F}^{-1}(\hat{i}_{filtered}(f))\} \quad (12)$$

去除谐波后的电流信号 $i_{filtered}$ 被恢复为时域信号,得到去除某阶次谐波的电流信号,对电压做同样操作,即可得到去除了特定阶次谐波的电压信号 $v_{filtered}$ 。本文选择了去除占比与影响最大的 3 次和 5 次谐波,使用 $i_{filtered}$ 和 $v_{filtered}$ 作为原始数据重复本文 1.2 节步骤可以得到去 3 次谐波 V-I 轨迹的 H 、 S 、 V 通道矩阵 $\mathbf{H}_3$ 、 $\mathbf{S}_3$ 、 $\mathbf{V}_3$, 去 5 次谐波 V-I 轨迹的 H 、 S 、 V 通道矩阵 $\mathbf{H}_5$ 、 $\mathbf{S}_5$ 、 $\mathbf{V}_5$, 这些矩阵的形状均为 $2N \times 2N$, 即 32×32 , 以此数据绘制出的去除了 3 次、5 次谐波的 V-I 轨迹如图 3(b)和(c)所示。

随后,将全波、去 3 次和去 5 次谐波的 3 张 V-I 轨迹图进行融合处理,以构建更具区分性的图像输入。在 H 通道中,首先映射全波轨迹的色相值,若对应像素处为空,则依次填充去除 3 次谐波轨迹与去除 5 次谐波轨迹的色相值,确保轨迹信息的完整性。融合 H 通道矩阵记为 $\mathbf{H}_f$, 具体映射过程依次执行以下步骤:

先在融合 H 通道矩阵 $\mathbf{H}_f$ 中填充全波 V-I 轨迹 H 通道矩阵 $\mathbf{H}$ 的值。计算公式为:

$$\mathbf{H}_f = \mathbf{H}, if \mathbf{H}_f = 0 \quad (13)$$

完成全波 V-I 轨迹的映射后,填充去 3 次谐波 V-I 轨迹 H 通道矩阵 $\mathbf{H}_3$ 的值。计算公式为:

$$\mathbf{H}_f = \mathbf{H}_3, if \mathbf{H}_f = 0 \quad (14)$$

最后填充去 5 次谐波 V-I 轨迹 H 通道矩阵 $\mathbf{H}_5$ 的值。

$$\mathbf{H}_f = \mathbf{H}_5, if \mathbf{H}_f = 0 \quad (15)$$

S 通道对应功率因数的映射,采用与处理 H 通道相同的优先级策略填充 3 张图像的值。处理公式同 H 通道式(13)~(15),得到融合 S 通道矩阵 $\mathbf{S}_f$ 。

V 通道采用融合处理方式,对 3 张轨迹图的 V 通道值进行平均后,进行 Gamma 变换, γ 取值为 0.3,以增强轨迹的重复性特征与重叠区域的亮度表达,同时避免单个轨迹重复性弱导致亮度过低的特征丢失,通过以上操作得到 V 通道矩阵 $\mathbf{V}_f$ 。对应的数学公式为:

$$\mathbf{V}_f = \left(\frac{\mathbf{V} + \mathbf{V}_3 + \mathbf{V}_5}{3} \right)^\gamma \quad (16)$$

3 个轨迹融合后的 V-I 轨迹图像如图 3(d)所示。

1.4 背景特征映射

为了使图像能承载更多的信息,本文在图像背景中也引入一些常用特征,考虑到要避免背景中的信息对 V-I 轨迹中的动态特征产生干扰,选择电流幅值、电流均方根以及有功功率等稳态特征进行背景映射。

电流幅值反映负荷的最大电流强度,是区分如空调、微波炉等高功率设备与如笔记本电脑、荧光灯等低功率设备的核心稳态特征,其数值范围通常具有显著差异性,电流幅值记为 $i_{\max}$, 计算公式为:

$$i_{\max} = \max(i) \quad (17)$$

R 通道在视觉感知中具有最强的显著性,将高区分度的电流幅值映射到图像背景的 R 通道,可使模型在特征学习时优先捕捉这一关键差异,增强不同功率等级负荷的区分度,因电流幅值各样本差异较大,因此对所有样本的电流幅值采用对数归一化进行处理后乘以系数 255,将各样本电流幅值较为均匀地映射到 R 、 G 和 B 通道均采用这一策略。对数归一化计算公式为:

$$\mathcal{N}(x) = \frac{\log(x - x_{\min} + 1)}{\log(x_{\max} - x_{\min} + 1)} \quad (18)$$

其中, $\mathcal{N}(x)$ 为对数归一化函数。

R 通道映射公式为:

$$R = 255 \times \mathcal{N}(i_{\max}) \quad (19)$$

电流均方根反映信号的波动幅度与稳定性,其数值变化体现负荷的动态特性,电流均方根记为 i_{rms} , 计算公式为:

$$i_{rms} = \sqrt{\frac{1}{K} \sum_{k=1}^K i_k^2} \quad (20)$$

G 通道在 RGB 模型中常作为过渡性特征载体,适合传递负荷运行状态的平稳性信息,将电流均方根映射到图像背景的 G 通道。 G 通道映射公式为:

$$G = 255 \times \mathcal{N}(i_{rms}) \quad (21)$$

有功功率直接反映负荷的实际能耗,是衡量能量消耗的核心指标,记为 P_{active} , 计算公式为:

$$P_{active} = \frac{1}{K} \sum_{k=1}^K i(k) \times v(k) \quad (22)$$

其中, $i(k)$ 为电流信号的第 k 个数据点, $v(k)$ 为电压

信号的第 k 个数据点, K 为数据点的个数。

有功功率数值范围相对连续, B 通道在视觉感知中显著性较低, 适合承载这类需要精细区分的特征, 避免与 R 通道的强特征产生视觉干扰, 因此, 将有功率映射到图像背景的 B 通道。 B 通道映射公式为:

$$B = 255 \times \mathcal{N}(P_{active}) \quad (23)$$

2 基于 ResNet18 和迁移学习的识别方法及流程

为保证识别效果与网络实时性以及轻量化需求, 本文使用结合迁移学习策略的 ResNet18 网络。 ResNet18^[22] 是一种深度卷积神经网络, 其网络架构包括 18 层。传统卷积神经网络在训练数据集较小的情况下难以实现良好效果, 因此采用迁移学习策略^[23], 迁移学习可以有效提高网络模型的训练效率^[24], 同时可以有效解决电器负荷识别任务中训练数据不足的问题。使用大规模数据集 ImageNet 自然图像作为源域对 ResNet18 网络进行预训练, 通过在海量图像中学习到的通用视觉特征, 为后续任务提供丰富的特征表示。迁移学习的具体过程为:

首先通过 ImageNet 数据集对 ResNet18 进行预训练,

得到预训练的权重参数; 然后从预训练的 ResNet18 中提取除原全连接层外的所有层, 并将原全连接层替换为一个输出维度与 PLAID 数据集电负荷类别数量一致的新全连接层, 原全连接层输出维度为 ImageNet 的类别数量 1 000, 新全连接层输出维度为电器负荷类别数量, PLAID2014、PLAID2017 为 11, PLAID2018 为 15。模型输入为使用本文第 1 节方法经过轨迹融合与背景映射处理后的彩色 V-I 轨迹图像, 并将其尺寸调整为与 ResNet18 输入神经元相同, 即 $3 \times 224 \times 224$; 冻结除原全连接层外的所有层参数, 即使用预训练模型的权重参数, 训练过程中除新全连接以外的各层权重参数不更新, 仅训练新全连接层。训练轮次设置为 200 个 epoch, 批大小设置为 32, 采用 Adam 优化器更新网络训练参数, 初始学习率设置为 2×10^{-3} , 经过 100 个 epoch 后学习率设置为 1×10^{-4} , 损失函数采用交叉熵损失。训练集数据采用随机裁剪、旋转等方式进行数据增强, 避免过拟合问题, 提高模型泛化能力。通过该方法能充分利用在大规模数据上训练得到的特征, 显著提升模型的训练效率和判别能力。使用迁移学习策略的负荷识别网络结构如图 4 所示。




图 4 使用迁移学习策略的负荷识别网络结构

Fig. 4 Network structure of load identification using transfer learning strategy

3 结果与讨论

3.1 数据来源

PLAID 数据集为高分辨率电器负荷测量的公共数据集, 被广泛应用于 NILM 研究中。PLAID2014 包括来自美国宾夕法尼亚州匹兹堡 56 个家庭的 11 类 200 多个电器的电流和电压数据, 共有 1 074 组数据, 采样频率为 30 kHz, 采集的家庭场景数量多, 在 NILM 研究中有着很强的说服力。PLAID2017^[25] 包含美国宾夕法尼亚州匹兹堡的 9 个家庭 11 类 82 个电器的数据, 共 11 种设备类型, 共有 719 组

数据, 相较于 PLAID2014, PLAID2017 数据集采样更加精细, 集中对较少的家庭场景的具体电器的不同操作模式进行采集, 如风扇的低档和高档, 能够反映出模型对具有多种操作模式的同一种电器类别分类能力。PLAID2018^[26] 是当前最贴近真实住宅场景的数据集, 相较前两个数据集实现了负荷扩容与地域扩展, 包含了 15 种电器负荷类型的 1 800 多组数据, 还包含了东亚地区的电器负荷, 采样频率提升至 50 kHz, 因此谐波信息更加丰富, PLAID2018 的数据更加接近真实住宅场景, 有着更丰富的电器负荷种类和更广泛的地域覆盖, 更能证明模型对不同地区电器负荷

分类的普遍适用性以及在实际场景部署应用的可行性。

3.2 PLAID 数据集结果

根据第 2 节中的图像处理方法,PLAID 数据集的原始电压电流波形被可视化表示,基于 PLAID2014 数据集生成的 11 种不同电器负荷类型的彩色图像如图 5 所示。通过比较可以发现,以紧凑型荧光灯与笔记本电脑为例,两类负荷的全波轨迹相似,去除 3 次谐波后的轨迹以及背景有很大区别,通过融合这些特征能够更好的区分两类电器负荷。因此,本研究提出的图像特征增强方法能够帮助更好的区分这些电器负荷。




图 5 PLAID2014 数据集生成的 V-I 轨迹图像

Fig. 5 V-I trajectory image generated from the PLAID2014 dataset

为了验证迁移学习的可行性和有效性,图 6 描述了使用迁移学习策略训练的模型和从头开始训练的模型的训练过程。可以观察到,使用迁移学习策略训练的模型比从头开始训练的模型的收敛速度快,最终准确率结果更好,证明迁移学习策略可以提高模型的训练效率和准确率。

表 1 为在有无背景映射和轨迹融合的情况下,在 PLAID2014 数据集上进行负荷识别的验证结果。结果表明,通过背景映射和轨迹融合技术,将 PLAID2014 数据集的识别准确率从 97.79% 提高到 98.67%,单独的背景映射与轨迹融合也同样有准确度提升,证明本文提出的特征提取方法有效增强了 V-I 轨迹的表示能力。

为完整体现模型的识别效果,本文采用了 5 次测试结果共同绘制混淆矩阵,图 7~9 分别为 PLAID2014 数据集、PLAID2017 数据集、PLAID2018 数据集分类结果的混淆矩阵。

混淆矩阵的左侧和下方标识为各类别电器负荷名称,




图 6 使用迁移学习策略训练的模型和从头开始训练的模型的训练过程

Fig. 6 Training processes of the model trained using the transfer learning strategy and the model trained from scratch

表 1 在有轨迹融合和背景映射的情况下,在 PLAID2014 数据集上进行负荷识别的验证结果

Table 1 Verification results of load identification on the PLAID2014 dataset with and without trajectory fusion and background mapping

background mapping			%
序号	轨迹融合	背景映射	准确率
1	×	×	97.79
2	×	✓	97.88
3	✓	×	98.23
4	✓	✓	98.67

混淆矩阵的每一行代表模型的预测类别,而每一列代表实际的真实类别。对角线上的单元格显示了每个类别中预测正确的样本数,即真实类别和预测类别一致的数量。对角线外的数值表示模型的分类错误位置,即模型在这些实例上预测错误。矩阵最右侧的一列展示了每个预测类别的准确率,用 Precision 表示,而矩阵最底部的一行展示了每个真实类别的召回率,用 Recall 表示。右下角的单元格表示整体的准确率,计算公式为所有正确预测与总样本数的比例。评估性能公式为:

$$Precision = \frac{TP}{TP + FP} \tag{24}$$

$$Recall = \frac{TP}{TP + FN} \tag{25}$$

$$F1 = \frac{2 \times Precision \times Recall}{Precision + Recall} \tag{26}$$

其中,TP 为真阳性,FP 为假阳性,FN 为假阴性。以图 7 电风扇为例,在混淆矩阵中,TP = 120,FP = 0,FN = 3,则电风扇的准确率为 100%,召回率为 97.56%,F1 分数为 98.77%。

从混淆矩阵分析可以得出,模型在 3 个数据集上均展现出较高的识别准确率,在 PLAID2014 和 PLAID2018 中,




图 7 PLAID2014 数据集分类结果的混淆矩阵
Fig. 7 Confusion matrix of classification results on the PLAID2014 dataset




图 8 PLAID2017 数据集分类结果的混淆矩阵
Fig. 8 Confusion matrix of classification results on the PLAID2017 dataset

整体准确率超过 98%，说明本文提出的融合多轨迹与背景映射的策略具有良好的泛化能力。对于 I 型负荷，模型表现出极高的识别精度，在多个数据集中均达到 100% 或接近 100%，体现了方法在处理线性、稳态负荷方面的强大能力。尽管 II 型负荷识别难度较高，但模型仍在多个数据集中实现了较好的识别效果，显示出一定的适应能力。这类负荷由于具有非线性和多状态特性，轨迹变化复杂，容易与其他




图 9 PLAID2018 数据集分类结果的混淆矩阵
Fig. 9 Confusion matrix of classification results on the PLAID2018 dataset

类别发生混淆，如在 PLAID2014 与 PLAID2017 中，空调与冰箱、风扇与吹风机之间存在一定程度的误判。而在 PLAID2018 中，冰箱被识别为吹风机或笔记本电脑，空调易混淆为吸尘器、洗衣机等。这反映出在电器负荷类别增多、样本规模扩大时，II 型负荷的特征分离度仍需加强。但是除 PLAID2014 数据集中对冰箱的识别准确率较低外，整体的 II 型负荷识别准确率均达到 85% 以上，体现出本文方法在面对较难识别的 II 型负荷具有比较好的效果。

图 10 为 HSV 彩色轨迹方法与本文方法 F1 分数柱状




图 10 HSV 彩色轨迹与本文方法各电器负荷 F1 分数
Fig. 10 F1 scores of various electrical appliances for HSV color trajectories and the method in this paper

图,显示了 PLAID2014 数据集中 11 种电器负荷在单纯使用 HSV 彩色 V-I 轨迹图像作为输入和使用经过本文方法处理后的多轨迹融合与背景映射的彩色 V-I 轨迹图像作为输入的 F1 分数的对比情况,可以体现出使用本文方法处理后相对于不做轨迹融合与背景映射处理各个电器负荷识别结果的直观对比。横轴标识为各类别负荷名称,纵轴标识为 F1 分数,其中,浅色柱表示 HSV 彩色轨迹方法的各负荷识别 F1 分数,深色柱表示本文方法的各负荷识别 F1 分数,水平线为本文方法的平均 F1 分数基准线。从图 10 中可以看出,本文方法相较于 HSV 彩色轨迹方法,绝大多数电器负荷的识别 F1 分数有所提升,尤其是风扇、空调、微波炉、笔记本电脑等 II 型负荷,F1 分数提升较为显著,表明本文方法在提取具有复杂运行情况的 II 型负荷的特征方面具有良好效果。同时,对于原本准确率已较高的

I 型负荷,如白炽灯、电热器等,融合后仍保持稳定甚至进一步提升,说明该方法在提升 II 型负荷表现的同时并未影响 I 型负荷的稳定识别,处于平均线之下的电器负荷有空调与冰箱,这两种都是 II 型负荷,表明在对 II 型负荷的识别方面仍存在挑战。

3.3 实验对比

为进一步验证本文方法的优越性能,选择了现有的在 PLAID 数据集上结果较好的方法进行对比实验,文献[2-3]使用的是传统负荷特征,其他文献使用的是图像特征。表 2 为将本文方法结果与先进方法结果在 PLAID 数据集上的结果比较,本文方法在 PLAID2014、PLAID2017 以及 PLAID2018 数据集上的负荷识别准确率分别提高至 98.67%、97.53%以及 98.64%,不论是相较于传统特征还是图像特征,均表现出了显著的优势。

表 2 本文方法与现有先进方法在 PLAID 数据集上的比较

Table 2 Comparison between the proposed method in this paper and existing advanced methods on the PLAID dataset %				
数据集	文献	负荷特征	训练模型	准确率
PLAID2014	[2]	电流时域振幅、相位、频率	HT+LSTM	92.00
	[3]	电流频域幅值、相位及时域振幅、相位、频率	ELM	95.00
	[5]	WRG 递归图	CNN	97.00
	[13]	HSV 彩色 V-I 轨迹	AlexNet	98.04
	[20]	对称的 RGB 彩色 V-I 轨迹	Swim Transformer	97.59
	[21]	三维空间 HSV 彩色 V-I 轨迹	ResNet34	98.51
	本文方法	HSV 彩色 V-I 轨迹+轨迹融合+RGB 背景映射	ResNet18	98.67
PLAID2017	[6]	RP 递归图	SSP+CNN	84.56
	[20]	对称的 RGB 彩色 V-I 轨迹	Swim Transformer	96.46
	本文方法	HSV 彩色 V-I 轨迹+轨迹融合+RGB 背景映射	ResNet18	97.53
PLAID2018	[4]	椭圆傅里叶描述符	CNN	80.40
	[7]	可视化格拉姆角场编码	TSCNN	98.42
	本文方法	HSV 彩色 V-I 轨迹+轨迹融合+RGB 背景映射	ResNet18	98.64

4 结 论

本研究针对非侵入式负荷监测任务中电器负荷特征提取不足与 II 型负荷识别困难的问题,提出了一种融合多个 V-I 轨迹与背景映射特征的彩色图像构建方法,并结合迁移学习策略在预训练 ResNet18 网络上进行分类识别。该方法通过差异化谐波滤波策略分别构造全波、去 3 次、去 5 次谐波 3 类 V-I 轨迹,并在 HSV 空间中融合其图像特征,实现了特征的增强表达。实验结果表明,所提方法在 PLAID2014、PLAID2017 和 PLAID2018 这 3 个数据集上均取得了较高的分类准确率,其中对 I 型负荷表现出极高的识别精度与稳定性。尽管 II 型负荷具有非线性 and 多状态特性带来较高识别难度,本文方法依然取得了优于传统 V-I 轨迹表示的分类性能,表现出较强的适应性和鲁棒性。总体而言,所提出的轨迹融合与背景映射方法在保证识别

准确性的同时,兼顾了对复杂负荷特征的提取与表达,在负荷类型多样化的场景下展现出良好的泛化能力。

参考文献

[1] BONFIGLI R, PRINCIPI E, FAGIANI M, et al. Non-intrusive load monitoring by using active and reactive power in additive factorial hidden Markov models[J]. Applied Energy, 2017, 208: 1590-1607.

[2] LE T T H, HEO S, KIM H. Toward load identification based on the hilbert transform and sequence to sequence long short-term memory [J]. IEEE Transactions on Smart Grid, 2021, 12 (4): 3252-3264.

[3] 莫浩杰, 彭勇刚, 蔡田田, 等. 一种基于时频特征融合和极限学习机的非侵入式负荷识别方法[J]. 电工电能新技术, 2023, 42(3): 85-96.

- MO H J, PENG Y G, CAI T T, et al. A non-intrusive load monitoring method based on time-frequency feature fusion and extreme learning machine [J]. Advanced Technology of Electrical Engineering and Energy, 2023, 42(3): 85-96.
- [4] 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), 2018: 179-186.
- [5] 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.
- [6] 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), 2021: 108-115.
- [7] 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, 2021, 13(1): 762-772.
- [8] 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 J F, WANG X, ZHANG X T. Non-intrusive load recognition using color encoding in edge computing[J]. Chinese Journal of Scientific Instrument, 2020, 41(9): 12-19.
- [9] 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, 2015, 7(1): 358-365.
- [10] 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.
- [11] KONG W C, DONG Y ZH, WANG B, et al. A practical solution for non-intrusive type II load monitoring based on deep learning and post-processing[J]. IEEE Transactions on Smart Grid, 2020, 11(1): 148-160.
- [12] 王凌云, 唐涛, 鲍刚, 等. 基于改进通道注意力优化变分自编码器的居民空调负荷辨识[J]. 仪器仪表学报, 2025, 46(5): 251-263.
WANG L Y, TANG T, BAO G, et al. Identification of residential air conditioning loads via channel-attention-optimized variational autoencoder [J]. Chinese Journal of Scientific Instrument, 2025, 46(5): 251-263.
- [13] LIU Y CH, WANG X, YOU W. Non-intrusive load monitoring by voltage-current trajectory enabled transfer learning [J]. IEEE Transactions on Smart Grid, 2018, 10(5): 5609-5619.
- [14] XIANG Y ZH, DING Y F, LUO Q, et al. Non-invasive load identification algorithm based on color coding and feature fusion of power and current[J]. Frontiers in Energy Research, 2022, 10: 899669.
- [15] 孙毅, 崔灿, 陆俊, 等. 基于遗传优化的非侵入式家居负荷分解方法[J]. 电网技术, 2016, 40(12): 3912-3917.
SUN Y, CUI C, LU J, et al. A non-intrusive household load monitoring method based on genetic optimization[J]. Power System Technology, 2016, 40(12): 3912-3917.
- [16] GHOSH S, CHATTERJEE A, CHATTERJEE D. Improved non-intrusive identification technique of electrical appliances for a smart residential system[J]. IET Generation, Transmission & Distribution, 2019, 13(5): 695-702.
- [17] DJORDJEVIC S, SIMIC M. Non-intrusive load monitoring using current harmonic vectors and adaptive feature selection [J]. Facta Universitatis, Series: Automatic Control and Robotics, 2024, 22(2): 103-113.
- [18] 宰州鹏, 赵升, 朱翔鸥, 等. 基于颜色编码与谐波特征融合的非侵入式负荷识别方法[J]. 电气技术, 2022, 23(12): 9-16.
ZAI ZH P, ZHAO SH, ZHU X OU, et al. Non-intrusive load monitoring based on color coding and harmonic feature fusion[J]. Electrical Engineering, 2022, 23(12): 9-16.
- [19] CHEN T, QIN H Y, LI X SH, et al. A non-intrusive load monitoring method based on feature fusion and SE-ResNet[J]. Electronics, 2023, 12(8): 1909.
- [20] YU W Q, YANG L F, HE Z X. Hierarchical classification for symmetrized VI trajectory based on lightweight swin transformer[C]. International Conference on Artificial Neural Networks, 2023: 407-420.
- [21] CHEN T, YUAN Y M, GAO J Q, et al. Non-intrusive load monitoring based on time-enhanced multidimensional feature visualization [J]. Scientific Reports, 2025, 15(1): 4800.

[22] 孙曙光, 张婷婷, 王景芹, 等. 基于连续小波变换和 MTL-SEResNet 的断路器故障程度评估[J]. 仪器仪表学报, 2022, 43(6): 162-173.
SUN SH G, ZHANG T T, WANG J Q, et al. Fault degree evaluation of circuit breaker based on continuous wavelet transform and MTL-SEResNet [J]. Chinese Journal of Scientific Instrument, 2022, 43(6): 162-173.

[23] 颜凌岚, 常俊, 赵楠, 等. 基于雷达时频特征提取和 CBAM-MFResNet 的人体行为识别[J]. 电子测量技术, 2025, 48(24):204-212.
YAN L L, CHANG J, ZHAO N, et al. Human action recognition based on radar time-frequency feature extraction and CBAM-MFResNet [J]. Electronic Measurement Technology, 2025, 48(24):204-212.

[24] 王雷, 何坤, 李宗帅, 等. 基于 BiLSTM-Attention 的迁移学习变工况故障识别方法研究[J]. 电子测量与仪器学报, 2023, 37(7): 205-212.
WANG L, HE K, LI Z SH, et al. Transfer learning based on BiLSTM-Attention research on fault identification methods for variable operating conditions[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(7): 205-212.

[25] DE BAETS L, DEVELDER C, DHAENE T, et al.

Handling imbalance in an extended PLAID[C]. 2017 Sustainable Internet and ICT for Sustainability(SustainIT), 2017: 1-5.

[26] MEDICO R, DE BAETS L, GAO J K, et al. A voltage and current measurement dataset for plug load appliance identification in households [J]. Scientific-data, 2020, 7(1): 49-58.

作者简介

负智, 硕士研究生, 主要研究方向为人工智能与机器学习。

E-mail:942775630@qq.com

伍萍辉, 教授, 主要研究方向为智能控制、物联网、电路系统。

E-mail:2005114@hebut.edu.cn

李义博, 硕士研究生, 主要研究方向为深度强化学习。

E-mail:yibo_li2001@163.com

堪铮, 硕士研究生, 主要研究方向为特定辐射源识别、深度学习。

E-mail:1316896156@qq.com

郭志涛(通信作者), 教授, 主要研究方向为物联网、智能传感器、智能优化算法。

E-mail:2002089@hebu.edu.cn