

DOI: 10.12158/j.2096-3203.2025.01.023

融合卷积神经网络和注意力机制的负荷识别方法

赵毅涛¹, 李钊², 刘兴龙¹, 骆钊², 王钢², 沈鑫¹

(1. 云南电网有限责任公司, 云南 昆明 650217;

2. 昆明理工大学电力工程学院, 云南 昆明 650500)

摘要:对居民住宅进行非侵入式负荷监测(non-intrusive load monitoring, NILM)是智能电网用户需求侧的重要研究内容,居民负荷的能耗分析和用电管理是实现节能减排、可持续发展的关键环节。针对传统算法识别性能差、难以适应当下复杂用电环境的问题,文中从增强分类算法特征提取性能的优化思路出发,提出融合卷积神经网络(convolutional neural network, CNN)和自注意力机制的NILM负荷识别方法。首先,采集8种不同家用电器的电力数据,建立 $U-I$ 轨迹曲线数据库;其次,采用挤压-激励网络(squeeze-and-excitation network, SENet)注意力机制提升CNN的特征聚合能力,完成对不同电器 $U-I$ 轨迹曲线的特征提取和负荷识别;最后,对私有数据集和PLAID数据集进行测试,算例结果表明,所提方法在不同运行场景下均具有较高的识别准确率和较好的泛化性能。

关键词:非侵入式负荷监测(NILM);负荷识别;卷积神经网络(CNN);挤压-激励网络(SENNet);注意力机制;特征提取; $U-I$ 轨迹

中图分类号:TM933

文献标志码:A

文章编号:2096-3203(2025)01-0227-09

0 引言

负荷监测是用电管理、用能分析中的关键技术之一,能够为相关企业进行能耗分析和提供合理有效的数据支撑,实现节能减排和可持续发展。针对不同的用电设备、运行环境,负荷监测的目的是获取设备级用电信息^[1],了解电器设备的能耗情况,评估其能源使用效率,发现能耗浪费问题,并采取相应的节能措施。此外,负荷监测还可以帮助实现电力系统的负载均衡,减少供电设备的过载和损坏,提高系统的可靠性和稳定性。

随着深度强化学习等技术日益成熟,以及智能电表在居民住宅中广泛应用,越来越多的研究表明^[2-5],基于非侵入式负荷监测(non-intrusive load monitoring, NILM)^[6]的算法在很大程度上取代了传统的侵入式负荷监测(intrusive load monitoring, ILM),成为居民设备级用电信息负荷监测的主流手段。近年来,结合人工智能算法的NILM负荷识别方法^[7-8]逐渐成为供电企业和能源公司关注的研究热点。目前,基于NILM的电流、电压、功率等电气量特征进行机器学习挖掘并建立的负荷识别模型中,常见的有隐马尔可夫^[9]、支持向量机、贝叶斯网络^[10]、人工神经网络^[11]以及改进超参数后的混合识别模型^[12-13]。

在NILM中引入深度学习算法后,特征提取成为负荷识别的关键环节。文献[14]采用卷积神经网络(convolutional neural network, CNN)学习功率序列的负荷特性,建立序列到点模型提取负荷特征,在一定程度上提高了负荷识别的综合性能。文献[15]对负荷样本数据进行时频信号特征提取,提出多特征融合学习策略,从而获取信号特征与负荷类型的映射关系,实现负荷识别。文献[16]将负荷能量分解与设备运行状态的强关联特性作为识别特征,提出基于多感受野融合的残差网络,改善了负荷识别效果。尽管上述文献从不同角度的功率信号特征建立负荷识别模型,但这些信号特征的提取完全依赖于机器学习的无监督处理,未能实现负荷特征可视化,且在设备小功率运行的判断中容易出现负荷识别错误。文献[17-18]表明,经过归一化处理,一个周期内稳态电压和电流信号形成的 $U-I$ 轨迹具有区分度,作为负荷特征在识别方面优于其他高频特征。文献[19]基于 $U-I$ 轨迹提出非侵入式负荷识别的深度学习方法,并在数据集PLAID和REDD上进行评估,证明了所提方法的有效性。文献[20]将 $V-I$ 轨迹改进为 $V-\Delta I$ 轨迹,并提出混合式位元图构建方法,采用DeiT模型实现在单一复杂场景下对电动自行车负荷的准确识别。上述文献从 $U-I$ 轨迹曲线所表现出的特征出发,量化了不同参考角度的特征,将其细化为谐波特征、斜率特性、封闭区域等。

文中从增强分类算法特征聚合能力的优化思

收稿日期:2024-05-05;修回日期:2024-07-29

基金项目:国家自然科学基金资助项目(52277104, 519070-84);云南省重点研发计划资助项目(202303AC100003)

路出发,提出融合 CNN 和挤压-激励网络 (squeeze-and-excitation network, SENet) 注意力机制的 NILM 负荷识别方法,针对传统算法识别性能差、难以适应当下复杂用电环境的问题,引入 SENet 注意力机制,强化神经网络的空间特征聚合能力,实现对不同居民负荷 $U-I$ 轨迹特征的自动提取;此外,结合目前家用负荷设备种类多、运行场景复杂的情况,构建 8 种家用电器的电压、电流信号数据集,导入 CNN-SENet 识别模型进行训练和测试,并采用 PLAID 数据集对模型进行有效性验证。结果表明,所提方法有效提升了家用负荷识别的精细化水平,增强了识别算法的可靠性和泛化性能,实现了在不同运行场景下家用负荷的准确识别。

1 基于 $U-I$ 轨迹的负荷监测

1.1 负荷监测

负荷监测是对电力系统中各个电器设备或整体能耗进行实时监测、记录和分析的过程,其通过采集和处理设备级电力功耗数据,了解不同电器设备的用电量、能耗模式、用能效率、使用频率等信息。负荷监测的主要目的为实现对电力系统用能需求侧的有效管理和电网供电侧的线路优化布局。通过了解电器设备的能耗情况,可以评估其能源使用效率,发现潜在的能耗浪费问题,并采取相应的节能措施。负荷监测具有重要的应用价值,可以帮助家庭、企业和能源供应商更好地了解和管理能源消耗,实现节能减排和可持续发展。从居民用户的角度出发,负荷监测不仅能为家电设备用能分析提供数据支持,还能发现谐波干扰、功率跳变以及某些家用电器的非正常误动等信息,对居民用户的用电安全隐患作出预警。从供电企业和能源供应商的角度出发,负荷监测能够直接、全面地反映用户用能的普遍情况,包括用电高峰时段以及能源使用效率等。基于上述用能信息,供应商可以结合实际情况优化供电线路、改良供电方案,实现供电、配电的高度一致,使得供配电源荷协同、负载均衡,维持电力系统经济、可靠、稳定运行。此外,负荷监测技术在智能家居、电力市场交易和能源规划等领域的应用也广泛。通过实时监测和分析负荷情况,可以制定更加科学合理的能源管理策略,从而提高能源利用效率,降低能源开支,避免资源浪费,助力节能减排,保障能源安全和可持续发展。

传统的负荷监测方法为每个独立的家用电器入户安装专门的传感器进行实时监测,因此被称为 ILM,如图 1(a)所示。ILM 方式的数据采集形式单

一,其监测结果虽然准确可靠,但实施成本高昂,安装和维护过程复杂,且设备入户对居民隐私造成困扰,用户接受度低。随着智能电网技术的发展,NILM 逐渐成熟,在居民侧用能管理中被广泛应用。在线路入户口接入 NILM 装置采集总电力消耗数据,并利用人工智能算法对单个电器设备进行能耗监测和识别,使 NILM 能够更加便捷和高效地掌握设备级用电信息。NILM 结构示意图如图 1(b)所示。

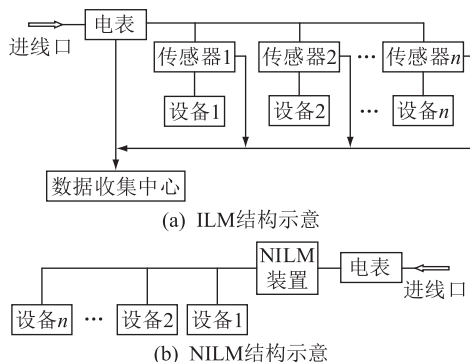


图 1 负荷监测结构示意图

Fig.1 Schematic diagram of load monitoring structure

1.2 基于 $U-I$ 轨迹的负荷识别

1.2.1 负荷稳态特征

负荷的稳态特征是指在正常运行状态下,电器在各个方面(如功率、电流、电压等)表现出来的统计特性和稳定性。

(1) 功率特征。电器的稳态功率特征是指电器在运行过程中的平均功率消耗,反映了电器的能耗水平。不同类型的电器设备具有不同的功率特征。家用电器如电视机、冰箱等通常具有较高的稳态功率消耗,小型电子设备如手机充电器则具有较低的功率特征。

(2) 电流特征。电器的稳态电流特征是指电器在运行过程中的电流大小和波动情况。不同的电器设备会表现出不同的电流特征,这取决于电器内部电路结构和工作原理。某些电器设备在启动或运行时会出现峰值电流、产生谐波等,而其他电器设备则具有相对稳定的电流消耗。

(3) 电压特征。电器的稳态电压特征是指电器在运行过程中所需的电压水平。不同的电器设备对电压的要求也不同。除了额定电压指标,某些家用电器对电压的稳定性要求较高,较大的电压波动可能会导致设备故障或损坏。

(4) 功率因数特征。功率因数是指电器设备在运行过程中所展现的功率与视在功率之比,具有较高功率因数的电器设备能够更有效地提高能源利用效率。

一般而言,描述家用设备的稳态特征除了上述4种,还包括有功功率、无功功率、谐波分量等,但直接对比稳态特征很难有效区分不同家用设备。在以往研究中,部分学者利用负荷的有功功率变化量、无功功率变化量、总谐波失真系数等特征进行负荷识别,在一定程度上提高了不同电器的特征区分度,但仍存在部分家用设备特征重叠的问题^[21]。

1.2.2 $U-I$ 轨迹曲线

通过负荷设备在稳态下一一对应的电压和电流数据点绘制 $U-I$ 轨迹曲线,电压、电流分别作为横、纵坐标,形成包含稳态特征的二维轨迹曲线,从而反映负荷设备工况下电压、电流间的耦合特征。

$U-I$ 轨迹曲线耦合了电压、电流的关联关系,从二维角度表征负荷设备的稳态信息,能够体现不同电压下电器元件或电路中的电流变化情况,展示电器元件或电路的一些重要性能和特征。相比 1.2.1 节中提及的 4 种负荷稳态特征, $U-I$ 轨迹曲线在负荷识别中表现出更好的区分度^[20],避免了因部分家用设备特征重叠而出现的负荷识别错误情况。因此,文中选取 $U-I$ 轨迹二维曲线特征作为负荷识别的特征量度,通过提取 8 种家用电器的 $U-I$ 轨迹特征建立数据库,导入机器模型进行学习和训练,挖掘不同家用电器的稳态信息,并通过对比 $U-I$ 轨迹的匹配程度实现负荷识别。

2 CNN-SENet 识别模型

提取负荷 $U-I$ 轨迹特征属于图像目标的识别与分类,因此,文中引入 CNN 作为不同家用电器设备 $U-I$ 轨迹曲线的图像分类器,并采用 SENet 注意力机制加强 CNN 特征聚合的能力,实现不同家用负荷在不同运行场景下的准确识别。

2.1 CNN

CNN 是一种深度学习模型^[22],主要用于处理具有网格结构的数据,如图像和音频等。模型由多个卷积层、激活函数、池化层和全连接层组成,能够自动学习输入数据的特征。同时,CNN 还具有参数共享和局部连接的特点,使得模型参数较少,且能够适应不同大小的输入图像。

CNN 的核心思想为利用卷积层和池化层提取输入数据的特征,并通过全连接层进行分类或回归。图 2 为 CNN 的主要组成部分,其核心结构如下。

卷积层:卷积层为 CNN 的基本构建单元,其通过一组可学习的滤波器(特征图)对输入数据进行卷积操作,提取局部特征。卷积层可以有效捕捉空




图 2 CNN 主要组成部分

Fig.2 The main components of CNN

间相关性,因此在图像处理中尤其重要。卷积层的计算公式如下:

$$y_i = x_i \lambda_i + \delta_i \quad (1)$$

式中: y_i 为第 i 个卷积核对应的输出矩阵; x_i 为第 i 个卷积核对应的输入矩阵; λ_i 为第 i 个卷积核窗口; δ_i 为第 i 个卷积核对应的偏差。其中,偏差 δ_i 是可学习的参数。

激活函数:经过卷积层后通常会应用一个非线性激活函数,如 ReLU 或 Sigmoid,引入非线性特征,使网络更好地捕捉数据的复杂耦合关系。

池化层:池化层用于降低特征图的空间维度,减少参数数量并提取图像中的重要信息。常见的池化操作包括最大池化和平均池化,通过在每个区域中选择最大值或平均值来汇总特征。文中采取最大池化的方式进行操作,即选用 ReLU 作为输出 y_i 的激活函数,实现特征提取,并映射为 c_i ,进而通过最大池化操作,取 c_i 的最大值作为图像的有效特征。计算公式为:

$$\begin{cases} c_i = \text{ReLU}(y_i) \\ p_i^{\max} = \max(c_i) \end{cases} \quad (2)$$

式中: p_i^{\max} 为第 i 个卷积核对应的最大池化操作输出。

全连接层:全连接层一般在卷积层和输出层之间,其将上一层的特征数据展平,并通过神经网络中的全连接操作学习输入数据与输出标签的关系。

输出层:输出层通常为全连接层的末端,根据不同任务类型,可以采用不同的激活函数(如 Sigmoid、Softmax),生成模型输出的目标预测标签。

2.2 SENet 注意力机制

SENet 是一种注意力机制^[23],用于改进 CNN 在特征聚合方面的性能。如图 3 所示,SENet 的核心思想为引入一种轻量级的注意力模块,其由挤压操作、激励操作 2 个关键部分组成。




图3 SENet 注意力机制

Fig.3 SENet attention mechanism

(1) 挤压操作。通过全局平均池化对每个通道的特征进行压缩,全局平均池化将每个通道中的特征图转换为一个标量值,以表示该通道特征在全局特征中所占的权重。图3中, C 为特征通道数,即包含全局信息的特征图被压缩为 C 个大小为 1×1 的特征图。

(2) 激励操作。通过引入多层感知机结构对每个通道的加权处理进行建模,其由 2 个全连接层组成,分别通过 ReLU 和 Sigmoid 激活函数增强特征的聚合能力。将激励操作的输出与原始特征相乘,得到调整后的权重特征聚合结果。

2.3 CNN-SENet 模型构建

在 CNN 的负荷识别模型中引入 SENet 注意力机制,可以增强原始信号 ($U-I$ 轨迹曲线) 的聚合特征。在数据训练过程中,CNN 能够有选择地对不同类别、不同特征图通道进行不同程度的学习,降低无关变量对后续分类、预测结果的影响,更好地提取 $U-I$ 轨迹曲线的图像特征。

为实现卷积运算的特征聚合,进一步在输出层完成精细化分类输出的任务。文中构建的 $U-I$ 轨迹曲线分类器可分为如下 3 个环节,其网络结构如图 4 所示。

(1) $U-I$ 轨迹曲线图的标准化处理。对 $U-I$ 轨迹曲线图进行预处理,调用 Resize 和 Reshape 函数对窗口大小进行归一化。对于不同家用电器负荷的 $U-I$ 轨迹图,统一调整为 $256 \times 256 \times 3$ 的有损压缩图像文件格式,使用 3 个特征图通道。

(2) CNN-SENet 网络模型构建。模型在整体结构上分为 1 个输入层、5 个卷积层、1 个池化层、1 个全连接层和 1 个输出层。在输出层基于交叉熵构建模型的损失函数,同时选择 Adam 作为梯度优化器对 CNN 的网络参数进行动态更新。

(3) 分类模型训练和测试。在所提方法中,训练集和测试集按照 7:3 的比例进行样本设置。该环节属于半监督式机器学习训练过程,在人工辅助标签数据的情况下完成对分类器的参数寻优,实现对不同家用电器的负荷识别。

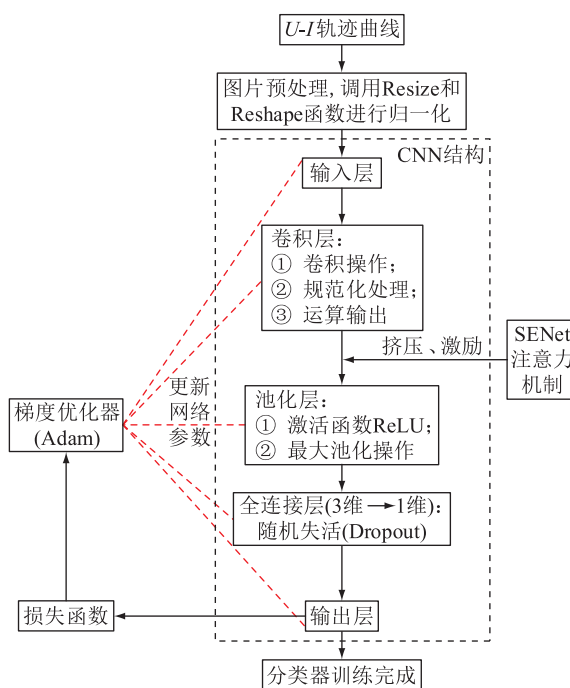


图4 CNN-SENet 网络模型

Fig.4 CNN-SENet network model

2.4 基于 CNN-SENet 的负荷识别流程

文中基于 $U-I$ 轨迹曲线的 NILM 负荷识别方法的具体步骤如下。

(1) 采集家用电器的负荷数据。通过 NILM 装置采集 8 种家用电器的电力数据,并以时间序列的形式进行保存。

(2) 数据预处理。对于采集的原始数据,以电压、电流的二维形式绘制稳态下的 $U-I$ 轨迹曲线图,并进行归一化处理,以便后续的特征提取和模型训练。

(3) 负荷特征提取。通过 CNN-SENet 分类器对 8 种不同家用电器的 $U-I$ 轨迹曲线进行特征挖掘和提取。

(4) 负荷标识与分类。在 CNN-SENet 分类器的输出层对检测出的家用电器类型进行标识,在测试样本中对不同设备进行分类。

(5) 机器训练与测试。导入步骤(2)中经过预处理的电力数据样本,在 CNN-SENet 分类器中重复步骤(3)和步骤(4),当模型达到最佳迭代次数时,终止训练。其中,最佳迭代次数为训练集损失函数持续下降,而测试集的准确率停止上升或开始下降时对应的迭代次数。

(6) 识别结果评估。将 NILM 负荷识别的结果与真实值进行对比,计算识别准确率、算法效率等相关指标,结合评估结果调整和优化 CNN-SENet 模型的性能。

3 算例分析

文中采用云南电网某地方供电局在实验室环境下通过 USB 型 A/D 数据采集卡获得的居民录波数据,包括电压、电流数据,采样频率为 10 kHz,采集对象包括 6 种常见的家用电器:定频空调、变频空调、电烤箱、电磁炉、电水壶、微波炉。文中仿真实验的硬件环境为 12th Gen Intel(R) Core(TM) i7-1260P、16 GB 内存的 64 位计算机,软件运行环境为 Python 3.8,并在 TensorFlow 框架下搭建 CNN 模型。

3.1 $U-I$ 轨迹图预处理及标签标识

数据集共 1 916 组数据,分别由定频空调制冷、定频空调制热、变频空调制冷、变频空调制热、电烤箱、电磁炉、电水壶、微波炉 8 类负荷组成,每组样本包含负荷的采样电压和采样电流。数据集包含了负荷暂态事件和稳态运行信息,为从数据集中提取 $U-I$ 轨迹特征,须对数据集进行预处理。根据所采集的电压和电流,负荷数据的 $U-I$ 轨迹特征提取细节如图 5 所示。当负荷的暂态事件发生时,截取暂态事件发生前一个周期的电流 I_B 和暂态事件发生后一个周期的电流 I_A ,并截取 I_A 同周期内的电压 U ,每组样本电流数据 $I = I_A - I_B$ 。将原始数据集中电压、电流序列进行归一化处理,如式(3)所示,得到序列 \tilde{V}_α 、 \tilde{I}_α ,并输出 8 类负荷的 $U-I$ 轨迹曲线图。

$$\begin{cases} \tilde{V}_\alpha = \frac{V_\alpha - V_{\min}}{V_{\max} - V_{\min}} \\ \tilde{I}_\alpha = \frac{I_\alpha - I_{\min}}{I_{\max} - I_{\min}} \end{cases} \quad (3)$$

式中: \tilde{V}_α 、 \tilde{I}_α 分别为归一化后第 α 点的电压和电流序列; V_α 、 I_α 分别为第 α 点的原始电压和电流值; V_{\max} 、 I_{\max} 分别为数据序列中电压和电流的最大值;

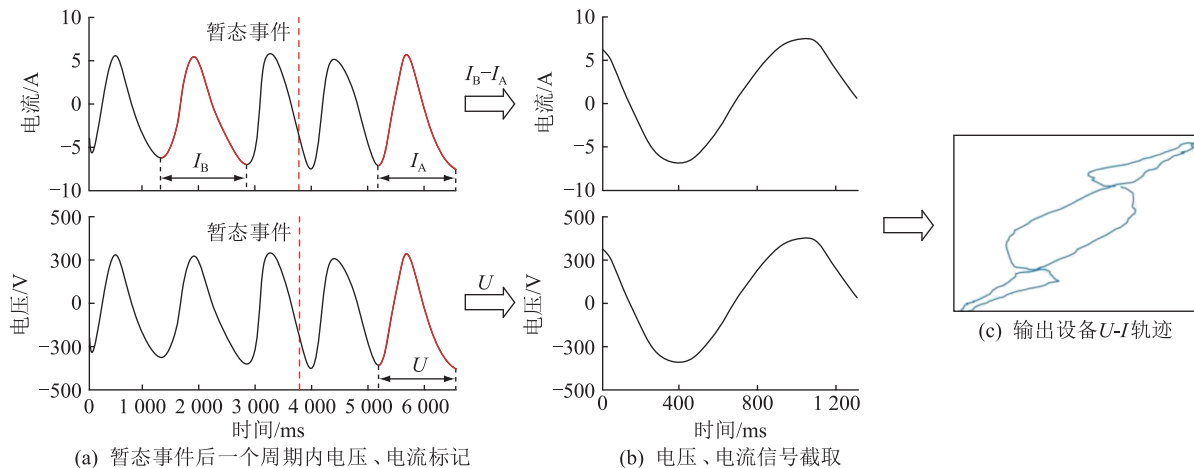


图 5 $U-I$ 轨迹特征提取过程

Fig.5 $U-I$ trajectory feature extraction process

V_{\min} 、 I_{\min} 分别为数据序列中电压和电流的最小值。

值得注意的是,数据集包含 2 种多状态负荷和 4 种单状态负荷。其中,变频空调和定频空调都有制冷和制热 2 种状态,其余 4 种负荷只有一种运行状态。阻抗特性相似的负荷,其 $U-I$ 轨迹曲线也具有相似性,例如空调制冷和制热的负荷特性都由压缩机、冷凝器和蒸发器等关键组件决定,在某些情况下呈阻抗特性或感抗特性,故 $U-I$ 轨迹图随负荷的实际运行情况改变。而电水壶和电烤箱主要由电加热元件组成,通常表现为具有较低电阻的电热元件,属于纯阻性负荷,电流和电压成正比,故 $U-I$ 轨迹图呈一条直线。

居民用电负荷识别为监督学习任务,模型需要从带有标签的训练数据中学习。标签提供了数据样本的类别信息,以便 CNN 模型通过比较预测值和实际标签之间的损失函数调整自身参数,从而改进性能。所以,为帮助 CNN 学习 $U-I$ 轨迹特征和负荷类别之间的关系,在模型训练之前,需要对数据集样本进行标签化处理。文中将 8 类负荷编号为 0—7,并按照 7:3 的比例划分训练集和测试集,构建 CNN-SENet 模型。8 类负荷样本的具体分布见表 1。

3.2 模型评价指标

居民负荷识别问题本质上属于分类问题,即根据 $U-I$ 轨迹特征识别负荷类型。文中采用机器学习中分类器的评价方法衡量 CNN-SENet 模型的负荷识别性能^[24],具体评价指标包括准确率 A_c 、精确率 P_r 、召回率 R_c 。

$$A_c = \frac{T_P + T_N}{T_P + T_N + F_P + F_N} \quad (4)$$

$$P_r = \frac{T_P}{T_P + F_P} \quad (5)$$

表 1 8 类居民负荷样本具体分布

Table 1 Specific distribution of eight types of residential load samples

负荷编号	负荷类型	总样本数	训练样本数	测试样本数
0	变频空调制冷	243	170	73
1	变频空调制热	282	197	85
2	定频空调制冷	272	190	82
3	定频空调制热	226	158	68
4	微波炉	237	166	71
5	电水壶	247	173	74
6	电磁炉	325	228	97
7	电烤箱	84	59	25
总计		1 916	1 341	575

$$R_e = \frac{T_p}{T_p + F_N} \quad (6)$$

式中： T_p 为“真”样本被正确识别为“真”的样本数； F_p 为“假”样本被错误识别为“真”的样本数； T_N 为“假”样本被正确识别为“假”的样本数； F_N 为“真”样本被错误识别为“假”的样本数。

值得注意的是，在负荷识别的实际过程中，不同类别负荷的样本分布不均。文献[25]考虑了精确率和召回率两方面，提出 F_1 分数这个更具综合性的模型评价指标，如式(7)所示，其通过调和两者之间的权重关系，在尽量减少分类失误的同时尽可能多地捕捉正类别样本。 F_1 分数改善了样本分布不均导致的模型性能评估偏差问题，故 F_1 分数也是文中评价模型性能的重要指标之一。 F_1 分数值越大，说明模型识别性能越好。


$$F_1 = \frac{2P_r R_e}{P_r + R_e} \quad (7)$$

3.3 实验结果与分析


为更好地表现 CNN-SENet 基于 $U-I$ 轨迹特征识别居民负荷的有效性和优越性，文中设计 2 个实验。实验一构建 CNN-SENet 模型，通过输出 8 类家用电器负荷识别的训练结果，验证文中方法的有效性；实验二将所提方法与文献[26-29]中的居民负荷识别方法进行对比，采用 3.2 节所提评价指标评估各类方法的负荷识别性能，验证所提方法的优越性。

实验一先对表 1 中 8 类家用电器电压、电流测量值进行数据预处理，提取家用电器 $U-I$ 轨迹，并对其编码。然后，构建 CNN-SENet 负荷识别模型，主要包括输入模块、CNN-SENet 模块以及输出模块。输入模块设置家用电器的 $U-I$ 轨迹特征图像大小为 256×256 ，通道数为 3。CNN-SENet 模块分别设置卷积核为 4×4 、 5×5 的卷积层 conv1、conv2，在每个卷

积层后应用 SENet 中的挤压-激励网络和最大池化操作增强模型特征表征能力和下采样能力。输出模块由全连接层和输出层组成，是整个模型的输出单元，与 CNN-SENet 模块相连。全连接层和输出层分别由 64、8 个神经单元组成，激活函数为 ReLU。设置迭代次数为 10，CNN-SENet 模型训练的损失函数和准确率收敛曲线如图 6 所示。不难看出，文中所提方法对家用电器识别有优秀表现，经过 10 轮训练后，所提负荷识别方法的准确率由 43.7% 上升到 97.1%，损失函数由 1.960 1 下降到 0.009 1。



(a) 模型训练准确率变化



(b) 模型训练损失函数变化

图 6 CNN-SENet 模型训练

Fig.6 CNN-SENet model training

实验二采用 3.1 节中的 1 916 组样本数据，根据 8 类家用电器的 F_1 分数分析 5 种不同方法在 8 类家用电器识别中的表现。方法 1：文献[26]利用改进的 K 最邻近 (K-nearest neighbor, KNN) 算法训练 $U-I$ 轨迹特征样本数据；方法 2：文献[27]采用自动选择设备特征的递归特征消除算法，将随机森林作为分类算法识别居民负荷类别；方法 3：文献[28]融合居民负荷功率特征和 $U-I$ 轨迹特征，利用反向传播 (back propagation, BP) 神经网络进行居民负荷识别；方法 4：文献[29]提出长短期记忆 (long short-term memory, LSTM) 的递归神经网络模型，用于识别居民负荷类别；方法 5：文中所提 CNN-SENet 负荷识别方法。5 种方法的负荷识别结果如表 2 所示。由表 2 可知，所提 CNN-SENet 负荷识别方法对 8 类家用电器识别的 F_1 分数均高于 90%，其中，变频空

调制冷的 F_1 分数最低,为 94.9%;特别地,对于电水壶、电烤箱这类纯阻性负荷,负荷识别 F_1 分数超过 98%。此外,在 8 类家用电器的总体负荷识别性能上,文中所提方法均优于其他 4 种负荷识别方法。

表 2 不同方法对比
Table 2 Comparison of different methods

负荷编号	$F_1/\%$				
	方法 1	方法 2	方法 3	方法 4	方法 5
0	76.2	83.6	89.6	91.7	94.9
1	71.6	79.0	88.2	94.6	98.0
2	74.3	85.9	91.4	96.6	97.7
3	72.3	80.6	90.6	97.1	97.5
4	69.4	81.2	85.0	97.5	97.3
5	82.1	82.1	90.4	98.3	98.4
6	71.8	83.4	92.3	96.5	95.2
7	80.0	80.0	95.8	100	100
平均值	74.7	82.0	90.4	96.5	97.4

最后,为验证所提方法的泛用性,文中选取 PLAID 数据集,以 30 kHz 的采样频率采样 56 个家庭 11 类家用电器的电流和电压测量值,总计 1 096 组样本数据,与 3.1 节相同,以 7:3 的比例划分训练集与测试集。表 3 展示了不同类别家用电器训练集与测试集的样本分布情况。

表 3 PLAID 家用电器样本分布情况
Table 3 PLAID household appliances sample distribution

设备编号	家用电器类别	训练样本数	测试样本数
1	空调	64	28
2	节能灯	121	52
3	冰箱	32	14
4	吹风机	109	47
5	笔记本电脑	114	49
6	微波炉	95	41
7	洗衣机	18	8
8	白炽灯	82	35
9	真空吸尘器	25	11
10	电风扇	80	34
11	热水器	26	11
总计		766	330

经过训练后的 CNN-SENet 网络负荷识别结果见表 4,可以看出,PLAID 数据集中 11 类家用电器负荷识别的 F_1 分数为 90.7%、准确率为 89.6%、精确率为 92.5%、召回率为 89.6%,证明了 CNN-SENet 在家用电器识别性能上表现良好。文中所提方法同样适用于国际公开数据集,对国外样本数据集可以达到较好的识别效果。

表 4 PLAID 数据集实验结果

Table 4 Experimental results on PLAID dataset

设备编号	家用电器类别	$A_c/\%$	$P_r/\%$	$R_c/\%$	$F_1/\%$
1	空调	92.9	96.3	92.9	94.5
2	节能灯	92.3	96.0	92.3	94.1
3	冰箱	85.7	92.3	85.7	88.9
4	吹风机	95.7	90.0	95.7	92.8
5	笔记本电脑	87.8	93.5	87.8	90.5
6	微波炉	97.6	100	97.6	98.8
7	洗衣机	75.0	100	75.0	85.7
8	白炽灯	85.7	90.9	85.7	88.2
9	真空吸尘器	81.8	90.0	81.8	85.7
10	电风扇	100	85.0	100	91.9
11	热水器	90.9	83.3	90.9	87.0
平均值		89.6	92.5	89.6	90.7

4 结论

针对传统算法在执行居民负荷识别任务时,存在难以适应复杂用电环境、运算量大、特征提取能力差的问题,文中提出一种融合 CNN 和 SENet 注意力机制的 NILM 负荷识别方法。通过对 CNN 特定通道进行加权增强网络的特征提取能力,截取负荷暂态事件后一周期的电压和电流构成 $U-I$ 轨迹特征进行负荷识别训练,降低了网络运算成本,增强了特征提取能力。在居民负荷识别实验中,通过神经网络学习 $U-I$ 轨迹特征,实现了对不同居民负荷的准确识别。在实验室环境下采集的 8 类居民负荷的识别任务中,文中方法的 F_1 分数均高于 90%,优于 KNN、随机森林、BP 神经网络及 LSTM 等负荷识别方法。在公开数据集 PLAID 的 11 类负荷识别任务中,文中方法的 F_1 分数同样高于 90%。实验结果表明,所提方法具有较好的负荷识别能力和良好的泛化性能。

文中方法改进了传统神经网络对居民负荷的特征提取能力,提升了算法的负荷识别性能。后续研究将进一步增加训练样本中家用电器设备的种类,增强算法的泛化能力。此外,将构建半实物仿真平台,对更多复杂场景下的负荷监测与识别方法进行研究,不断优化算法以实现更加准确、高效的非侵入式负荷辨识。

参考文献:

- [1] 郭红霞,陆进威,杨莘,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):135-146.
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.
- [2] UL ISLAM N, MEHRAJ SHAH S. A low complexity binary-

- weighted energy disaggregation framework for residential electricity consumption [J]. *Energy and Buildings*, 2023, 298: 113553.
- [3] 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.
- [4] 董哲,陈玉梁,薛同来,等. 基于全局与滑动窗口结合的Attention机制的非侵入式负荷分解算法[J]. *电测与仪表*, 2023, 60(11): 74-80.
- DONG Zhe, CHEN Yuliang, XUE Tonglai, et al. Non-intrusive load monitoring algorithm based on Attention mechanism combined with global and sliding window [J]. *Electrical Measurement & Instrumentation*, 2023, 60(11): 74-80.
- [5] OUZINE J, MARZOUQ M, DOSSE BENNANI S, et al. New hybrid deep learning models for multi-target NILM disaggregation [J]. *Energy Efficiency*, 2023, 16(7): 82.
- [6] HART G W. Nonintrusive appliance load monitoring [J]. *Proceedings of the IEEE*, 1992, 80(12): 1870-1891.
- [7] 魏广芬,赵航,胡春华,等. 基于香农熵加权投票算法的集成式非侵入式负荷识别方法[J]. *中国电机工程学报*, 2022, 42(24): 8876-8888.
- WEI Guangfen, ZHAO Hang, HU Chunhua, et al. An ensemble non-intrusive load identification method based on Shannon entropy weighted voting algorithm [J]. *Proceedings of the CSEE*, 2022, 42(24): 8876-8888.
- [8] GUO X C, WANG C, WU T, et al. Detecting the novel appliance in non-intrusive load monitoring [J]. *Applied Energy*, 2023, 343: 121193.
- [9] 孙毅,李昊洋,刘耀先,等. 基于改进隐马尔科夫模型的非侵入式家居负荷识别[J]. *电力建设*, 2020, 41(4): 73-80.
- SUN Yi, LI Haoyang, LIU Yaoxian, et al. Non-intrusive home-load identification based on improved hidden Markov model [J]. *Electric Power Construction*, 2020, 41(4): 73-80.
- [10] 肖江, François AUGER, 荆朝霞, 等. 基于贝叶斯信息准则的非侵入式负荷事件检测算法 [J]. *电力系统保护与控制*, 2018, 46(22): 8-14.
- XIAO Jiang, François AUGER, JING Zhaoxia, et al. Non-intrusive load event detection algorithm based on Bayesian information criterion [J]. *Power System Protection and Control*, 2018, 46(22): 8-14.
- [11] 张安安, 庄景泰, 郭红鼎, 等. 结合图半监督与广义回归神经网络的非侵入式海洋平台负荷监测 [J]. *电力系统保护与控制*, 2020, 48(7): 85-91.
- ZHANG An'an, ZHUANG Jingtai, GUO Hongding, et al. Non-intrusive offshore platform load monitoring based on graph-based semi-supervised learning and generalized regression neural networks [J]. *Power System Protection and Control*, 2020, 48(7): 85-91.
- [12] 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.
- [13] 王溥宇, 丁一帆, 陈鉴祥, 等. 基于动态谐波导纳参数的非侵入式负荷监测数据模拟生成方法 [J/OL]. *中国电机工程学报*: 1-14 [2023-11-02]. <http://kns.cnki.net/kcms/detail/11.2107.TM.20231026.1452.012.html>.
- WANG Puyu, DING Yifan, CHEN Jianxiang, et al. Non-invasive load monitoring data simulation generation method based on dynamic harmonic admittance parameters [J/OL]. *Proceedings of the CSEE*: 1-14 [2023-11-02]. <http://kns.cnki.net/kcms/detail/11.2107.TM.20231026.1452.012.html>.
- [14] 钱玉军, 包永强, 姜丹琪, 等. 基于 LSTM 和序列到点模型的非侵入式负荷分解技术 [J]. *电子器件*, 2023, 46(3): 841-848.
- QIAN Yujun, BAO Yongqiang, JIANG Danqi, et al. Non-intrusive load decomposition techniques based on LSTM and sequence-to-point models [J]. *Chinese Journal of Electron Devices*, 2023, 46(3): 841-848.
- [15] 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 Haojie, PENG Yonggang, CAI Tiantian, et al. Nonintrusive load identification method based on time-frequency feature fusion and extreme learning machine [J]. *Advanced Technology of Electrical Engineering and Energy*, 2023, 42(3): 85-96.
- [16] 宋玮琼, 王立永, 宋威, 等. 基于设备运行状态检测与能量回归同步评估的居民非介入式负荷辨识算法研究 [J]. *电测与仪表*, 2023, 60(12): 182-188, 195.
- SONG Weiqiong, WANG Liyong, SONG Wei, et al. Research on residential non-intrusive load identification algorithm based on equipment operation state detection and energy regression synchronous evaluation [J]. *Electrical Measurement & Instrumentation*, 2023, 60(12): 182-188, 195.
- [17] WANG A L, CHEN B X, WANG C G, et al. Non-intrusive load monitoring algorithm based on features of V-I trajectory [J]. *Electric Power Systems Research*, 2018, 157: 134-144.
- [18] 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.
- [19] BAPTISTA D, MOSTAFA S S, PEREIRA L, et al. Implementation strategy of convolution neural networks on field programmable gate arrays for appliance classification using the voltage and current (V-I) trajectory [J]. *Energies*, 2018, 11(9): 2460.
- [20] HUANG Q F, FANG K J, DING Z C, et al. A non-intrusive residential electric bicycle load monitoring method based on hybrid feature bitmap and DeiT [J]. *Frontiers in Energy Re-*

- search, 2022, 10: 896398.
- [21] 赵成, 宋彦辛, 周赣, 等. 基于先验统计模型的非侵入负荷辨识算法[J]. 电力工程技术, 2024, 43(1): 165-173, 211.
ZHAO Cheng, SONG Yanxin, ZHOU Gan, et al. Resident non-invasive load identification algorithm based on prior statistical model[J]. Electric Power Engineering Technology, 2024, 43(1): 165-173, 211.
- [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] 陈乾, 洪征, 司健鹏. 融合 SENet 和 Transformer 的应用层协议识别方法[J]. 计算机科学与探索, 2024, 18(3): 805-817.
CHEN Qian, HONG Zheng, SI Jianpeng. Application layer protocol recognition incorporating SENet and Transformer [J]. Journal of Frontiers of Computer Science and Technology, 2024, 18(3): 805-817.
- [24] ANDERSON K D, BERGÉS M E, OCNEANU A, et al. Event detection for non intrusive load monitoring[C]//IECON 2012-38th Annual Conference on IEEE Industrial Electronics Society. Montreal, QC, Canada. IEEE, 2012: 3312-3317.
- [25] ALTRABALS H, LIAO J, STANKOVIC L, et al. A low-complexity energy disaggregation method: performance and robustness[C]//2014 IEEE Symposium on Computational Intelligence Applications in Smart Grid (CIASG). Orlando, FL, USA. IEEE, 2014: 1-8.
- [26] 延菲, 张瑞祥, 孙耀杰, 等. 基于改进 kNN 算法的非侵入式负荷识别方法[J]. 复旦学报(自然科学版), 2021, 60(2): 182-188.
- YAN Fei, ZHANG Ruixiang, SUN Yaojie, et al. Non-intrusive load identification method based on improved kNN algorithm [J]. Journal of Fudan University (Natural Science), 2021, 60(2): 182-188.
- [27] SADEGHIANPOURHAMAMI N, RUYSSINCK J, DESCHRIJVER D, et al. Comprehensive feature selection for appliance classification in NILM[J]. Energy and Buildings, 2017, 151: 98-106.
- [28] 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.
- [29] 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.

作者简介:



赵毅涛

赵毅涛(1988),男,学士,工程师,从事电能计量、网络安全工作(E-mail: zyt717@hotmail.com);

李钊(1997),男,硕士在读,研究方向为人工智能在电力系统中的应用;

刘兴龙(1984),男,学士,高级工程师,从事计量自动化系统、大数据分析与应用工作。

Load recognition method based on convolutional neural network and attention mechanism

ZHAO Yitao¹, LI Zhao², LIU Xinglong¹, LUO Zhao², WANG Gang², SHEN Xin¹

(1. Yunnan Power Grid Co., Ltd., Kunming 650217, China;

2. Faculty of Electric Power Engineering, Kunming University of Science and Technology, Kunming 650500, China)

Abstract: Non-intrusive load monitoring (NILM) of residential houses is an important research content of the user demand side of smart grids, and the energy consumption analysis and power consumption management of residential loads are key steps in achieving energy conservation, emission reduction, and sustainable development. Aiming at the problems of poor recognition performance of traditional algorithms and difficulty in adapting to the current complex electricity environment, a NILM load recognition method integrating convolutional neural network (CNN)-self-attention mechanism is proposed from the optimization idea of enhancing the feature extraction performance of classification algorithms. Firstly, the power data of eight different household appliances are collected to establish a $U-I$ trajectory curve database. Secondly, the feature aggregation ability of CNN is improved by using squeeze-and-excitation network (SENet) attention mechanism to complete the feature extraction and load identification of $U-I$ trajectory curves of different electrical appliances. Finally, the private dataset and PLAID dataset are tested, and the example results show that the proposed method has high recognition accuracy and good generalization performance in different operational scenarios.

Keywords: non-intrusive load monitoring (NILM); load identification; convolutional neural network (CNN); squeeze-and-excitation network (SENet); attention mechanism; feature extraction; $U-I$ trajectory

(编辑 陆海霞)