

基于阈值调整的负荷辨识开集识别算法

李一鸣,邓君华,李志新,程含渺,鲍进,易永仙
(国网江苏省电力有限公司 营销服务中心,南京 210024)

摘要:负荷辨识是电力系统规划、运行和管理的关键技术之一,对于智能电网的高效调度和稳定运行具有重要意义。传统的负荷辨识方法通常依赖于封闭集假设,然而,在实际应用中,未知电器的出现使得基于封闭集假设的算法难以准确识别。针对这一问题,提出了一种基于阈值调整的负荷辨识开集识别算法 OpenAppliance。该算法结合深度学习与概率模型,通过对神经网络输出进行校准,提升对未知类别的检测能力,同时保持已知类别的辨识精度。首先将负荷数据转换为适合深度学习的图像形式,构建了基于卷积神经网络(convolutional neural network, CNN)的负荷辨识模型;其次,结合 OpenAppliance 算法进行后处理,以调整分类阈值并优化识别结果;最后,在 BLUED 负荷数据集上进行验证,并与现有的负荷辨识算法进行对比。研究结果表明,OpenAppliance 算法能增强负荷辨识的泛化能力,有效提升了负荷辨识系统的准确性与鲁棒性。

关键词:负荷辨识;开集识别;深度学习;未知类识别;概率模型

Open-set recognition algorithm for load identification based on threshold adjustment

LI Yiming, DENG Junhua, LI Zhixin, CHENG Hanmiao, BAO Jin, YI Yongxian
(Marketing Service Center, State Grid Jiangsu Eleacric Power Co., Ltd., Nanjing 210024, China)

Abstract: Load identification is one of the key technologies in power system planning, operation, and management, playing a crucial role in the efficient scheduling and stable operation of smart grids. Traditional load identification methods typically rely on the closed-set assumption. However, in practical applications, the presence of unknown appliances makes it difficult for algorithms based on this assumption to achieve accurate recognition. To address this issue, an open-set load identification algorithm, OpenAppliance, based on threshold adjustment is proposed. The proposed algorithm integrates deep learning and probabilistic models, calibrating the neural network outputs to enhance the detection capability for unknown categories while maintaining recognition accuracy for known categories. First, load data is transformed into an image format suitable for deep learning, and a CNN-based load identification model is constructed. Then, the OpenAppliance algorithm is applied for post-processing to adjust classification thresholds and optimize recognition results. Finally, the method is validated on the BLUED load dataset and compared with existing load identification algorithms. Experimental results demonstrate that the OpenAppliance algorithm enhances the generalization ability of load identification and significantly improves the accuracy and robustness of the load identification system.

Key words: load identification; open-set recognition; deep learning; unknown class recognition; probabilistic model

0 引言

负荷辨识是电力系统规划、运行和管理中的重要环节,通过准确的负荷辨识,可以实时了解电网中各类负荷的特性、分布及变化规律,从而为电网调度和运行提供科学依据,确保电力系统的安全稳定运行^[1-2]。负荷辨识能够帮助电网调度人员根据负荷特性调整发电计划和功率分配,优化资源配置,提高电网运行效率^[3]。同时,负荷辨识还为电网规划和改造提供了基础数据,有助于提升电网的适应性和可靠性,满足不断增长的用电需求^[4]。因此,

负荷辨识不仅是电网智能化和精细化管理的关键技术,也是保障电网安全稳定运行的重要支撑。

负荷辨识方法可以分为非侵入式负荷辨识和侵入式负荷辨识。其中,非侵入式负荷辨识以低成本、高效率 and 便捷性等优势,在家庭能源管理、智能电网建设和碳排放监测等领域具有广泛的应用前景^[5-7]。这些算法通常依赖于预先收集和标注的训练数据来进行模型训练。这些训练数据涵盖了已知电器的电力使用特征,模型在训练过程中学习并识别这些特征。通过分析电力使用数据,识别出不同电器的运行状态,从而优化能源消耗,提高电力管理的效率^[8-10]。然而,当前非侵入式负荷监测(non-intrusive load monitoring, NILM)主要目标还在于提升负荷辨识的准确度,针对未知类电器的识别

收稿日期:2026-01-06;修回日期:2026-03-08

基金项目:国家电网公司科技项目(5700-202418277A-1-1-ZN)

缺少有效的方法。在实际应用中,系统可能会遇到未在训练集中出现的新电器。这些未知电器的存在使得传统的负荷辨识算法难以准确识别和分类,导致识别率下降,甚至可能误识别为已知电器,造成误报或漏报。

相比之下,开集识别方法可以检测出未知样本,从而跳出封闭集假设。文献[11]提出 RF-KOSNN 方法,为随机森林分类器引入开放集识别能力,结合高斯过程距离度量与极值理论建模,但依赖于足够高质量的训练数据集;文献[12]提出 OpenGAN 方法,通过结合 GAN 生成的假开放数据与特征空间判别器,从而避免生成图像的训练不稳定性,有效提升开放集识别精度,然而生成的“假开放数据”是否足够真实且能代表实际应用中的未知类别仍然是一个挑战;文献[13]采用深度卷积神经网络(convolutional neural network, CNN)构建多任务学习框架,结合分类任务与解码器重建误差,通过极值理论建模提升对未知类别的检测能力,同样需要大量的标注数据进行训练;文献[14]提出了一种结合 ResNet 和 Vision Transformer 的混合架构,通过自注意力机制捕捉图像特征的相关性,并利用全卷积网络引导网络聚焦于操纵区域,实现对未知操纵类型的有效识别。但在训练集中的未知操纵类型未充分覆盖的情况下,对于未知类别的适应性仍然有限。

现有的开集识别方法大多侧重于传统的分类任务,在一些基准数据集上进行验证。而针对负荷辨识任务,负荷特征往往局限于电器工作过程中某一特定时刻,需要高精度高频采样数据,导致传统开集识别方法并不能在负荷辨识任务证明其优势。

因此本文提出了基于阈值调整的负荷辨识开集识别算法 OpenAppliance,在识别已知类别的同时,能够有效地检测并处理未知类别。通过融合负荷辨识的特征提取方法与开集识别的未知检测技术,可以构建一个兼具精确性与泛化性的智能负荷辨识系统,从而提升智能电网对复杂电力环境的感知和响应能力。本文将负荷辨识与开集识别技术结合,重点探讨如何利用深度学习与概率模型实现未知负荷的检测与分类,并通过实验验证该方法在实际负荷数据中的有效性。

1 负荷辨识开集识别模型

1.1 模型框架

模型先对负荷数据进行预处理,再通过 GAFS 将其转化为图片,每张图片配备了对应的标签,以供深度学习模型进行训练。训练完成后,通过构建

一个基于 OpenAppliance 算法的后处理模块,包括概率矫正、阈值设置部分,从而达到识别出未知类电器的效果,测试样本分类流程如图 1 所示。深度学习模型将在 1.2 节进行介绍,其余流程在第 2 章进行详细阐述。




图1 测试样本分类流程

Fig. 1 Classification process of test samples

1.2 模型介绍

由于非侵入式负荷辨识的芯片在计算能力、存储空间和功耗方面都有严格限制,无法支持大规模深度学习模型的运行,这使得在部署时必须选择轻量级模型。因此本算法使用的深度学习模型结构为 CNN, CNN 通过将输入数据不断地应用多层卷积、池化和全连接层的运算来学习高维特征表示。

本文构建的 CNN 网络结构如图 2 所示,构建一个基于 Keras 的卷积神经网络,为 32×32 单通道图像的分类任务设计,在保证基本性能的同时减少计算和存储开销,有关模型参数设置的消融实验将在第 3.3 节中详细阐述。模型包含 3 个卷积层组,逐层提取低、中、高层次特征,卷积核数量从 16 增加到 64,增强特征表达能力。每组卷积后通过最大池化层降维以减少计算复杂度。随后经过随机失活层、扁平化层和一个 64 神经元的全连接层学习全局特征。最后通过带有 SoftMax 激活的输出层完成 10 类的分类任务,同时根据分类结果输出分类正确样本在全连接层输出的激活向量。模型使用 RELU 激活函数和 Dropout 正则化,兼顾非线性表达能力和防止过拟合。模型使用 Adam 优化器进行训练,初始学习率设为 0.001。




图2 CNN网络结构

Fig. 2 CNN network architecture

2 OpenAppliance算法

2.1 OpenAppliance算法简介

传统负荷辨识方法通常基于封闭集假设,即认为训练数据覆盖了所有可能的电器类型和运行模式。然而,在实际应用中,新的电器设备不断涌现,且用户的用电行为为多样化,导致负荷辨识系统常常遇到未见过的未知负荷类型。传统的SoftMax分类器在这种情况下表现不佳,因为它倾向于将所有输入分配给已知类别。通过重新计算神经网络的输出概率,使其能够更好地区分已知类别和未知类别,OpenAppliance算法流程如图3所示。




图3 OpenAppliance算法流程

Fig. 3 OpenAppliance algorithm flow

2.2 OpenAppliance算法步骤

2.2.1 构建基础分类模型

使用深度学习模型CNN对已知类别进行训练,这里本模型使用的是SoftMax分类器,计算每个类别的预测概率,如下所示

$$P(i|x) = \frac{e^{z_i}}{\sum_{x=1}^c e^{z_x}} \quad (1)$$

式中: $P(i|x)$ 为样本 x 属于类别 i 的概率; z_i 为向量 z 中的第 i 个元素; e^{z_i} 为指数函数的计算结果,确保输出始终为正; $\sum_{x=1}^c e^{z_x}$ 为所有指数结果的和,用于归一化。

2.2.2 校准概率分布

根据所有正确分类样本的激活向量 V_x 计算各类别的均值激活向量 MV_i ,用于计算每个样本与该

样本所属类别的 MV_i 的欧氏距离 d_{xi} 。

$$MV_i = \frac{1}{N_i} \sum_{x=1}^{N_i} V_x \quad (2)$$

式中: MV_i 为类别 i 的均值激活向量; N_i 为类别 i 样本的数量; V_x 为第 x 个样本的激活向量。

$$d_{xi} = |V_x - MV_i| \quad (3)$$

式中: d_{xi} 为样本 x 的激活向量 V_x 与其所属类别 MV_i 的欧氏距离; V_x 为第 x 个样本的激活向量; MV_i 为类别 i 的均值激活向量。

对每个类别的欧氏距离集合进行排序,选择最高的 k 个值,通过对这些最高值进行Weibull分布拟合,得到每个类别的Weibull分布参数。

$$f(x; \lambda; k) = \begin{cases} \frac{k}{\lambda} \left(\frac{x}{\lambda}\right)^{k-1} e^{-(x/\lambda)^k} & x \geq 0 \\ 0 & x < 0 \end{cases} \quad (4)$$

式中: $F(x; \lambda; k)$ 为随机变量的概率密度; k 为Weibull分布的形状参数,决定分布的形状特征; λ 为Weibull分布的尺度参数,控制分布的扩展范围。

通过对Weibull分布的概率密度函数进行积分,得到各类别的累积分布函数。

$$F(\varepsilon; k; \lambda) = 1 - e^{-(\varepsilon/\lambda)^k} \quad (5)$$

式中: $F(\varepsilon; k; \lambda)$ 为Weibull分布的累积分布函数值; ε 为输入的激活向量; k 为Weibull分布的形状参数,决定分布的形状特征; λ 为Weibull分布的尺度参数,控制分布的扩展范围。

2.2.3 阈值设置

OpenAppliance算法通过计算验证样本中类别 i 的每个样本 x 的矫正概率向量元素和 χ ,统计其前 $n\%$ 的阈值 α_i ,也就是说对于第 i 类电器,有 $n\%$ 样本的值大于 α_i ,最终得到一个阈值向量 $\beta_i = (\alpha_1, \alpha_2, \dots, \alpha_i)$ 。

2.2.4 类别识别

对于测试样本 y ,首先经过模型得到激活向量 V_y 和预分类类别 i ,根据测试样本的 V_y 与该样本所属类别的 MV_i 计算测试样本的 d_{yi} 。再计算 d_{yi} 与该样本所属类别的累积分布函数计算测试样本的矫正概率。最后计算该测试样本的矫正概率的元素和 γ ,将其与预分类类别 i 在阈值向量 β_i 中对应类别的阈值 α_i 比较,如果 γ 大于 α_i ,则将该样本分类到类别 i ,否则归于未知类,输出最终的分类结果。

$$C_{\text{lass}}(y) = \begin{cases} i & \gamma \geq \alpha_i \\ U_{\text{known}} & \gamma < \alpha_i \end{cases} \quad (6)$$

式中: $C_{\text{lass}}(y)$ 为样本 y 的最终分类类别; i 为测试样本 y 概率得分最大值所属的类别; U_{known} 为未知类别; γ 为样本 y 在类别 i 的矫正概率元素和; α_i 为类别 i 的阈值。

通过寻找已知类和未知类存在的差异,另一方面能够消减模型训练过程中极端的训练数据(即 χ 值低于 α_i 的部分)带来的影响,再提升未知类识别准确率的同时降低对已知类的影响。

3 算法实验与结果分析

3.1 数据集介绍

为了验证 OpenAppliance 算法的性能,本文选用了3份负荷辨识领域的高频数据集进行实验:

(1) BLUED数据集

BLUED是由美国卡内基梅隆大学发布的一份高频负荷数据集,包含了典型家庭电器,采样频率为12 kHz,记录了家庭总负荷的电压和电流波形,具有完整的人工标注的开关事件,适合研究电器的开关瞬态信号和特征提取。

(2) COOLL^[15]数据集

COOLL(Controlled On/Off Loads Library)是由法国 GREAH 实验室发布的高频采样、单电器控制开关事件数据集,采样频率为100 kHz,包含了42种常用的家庭电器。

(3) 自采数据集

由于国内外电力系统的差异性,在实验室采集了一个新的数据集,采样频率为6.4 kHz,包含了15种家庭电器,同样对开关事件进行了完整的标注。

3.2 数据集预处理

为了将负荷数据转化为图片输入模型,需要进行预处理操作。BLUED数据集和自采数据集记录了事件的时间戳和电器的类别信息,通过事件匹配可截取设备对应的开启时间段。COOLL本身由开关事件组成,根据电流增幅即可锁定开启时刻。

为了扩充数据集,同时提升模型的泛化能力,本文采用添加高斯噪声的策略来进行数据增强,在原始电流信号上添加小幅度随机噪声来模拟实际采集中的传感器误差和电网波动。之后计算时间段中每个周波的有效功率将其转换为功率时间序列,最后结合输入图片的大小对功率时间序列的头部进行进一步截取,通过 GAFS 算法将负荷时间序列转换为灰度图像即将一维数据转到二维层面,可通过该算法成功将难识别的负荷特征转为图像,转化得到的负荷特征灰度图像可视化如图4所示。

最终根据电器普及率及使用频率划分已知电器与未知电器,以 BLUED 数据集为例,如表1所示。其中已知类按照8:1:1的比例划分为训练集、验证集和测试集,未知类则全部划分到测试集。




图4 GAFS 负荷特征图像
Fig. 4 GAFS load feature image

表1 BLUED数据集电器所属类别划分
Table 1 Appliance category classification in BLUED dataset

电器种类	所属类别
洗衣机	已知
电视	已知
冰箱	已知
台式电脑	已知
笔记本电脑	已知
破壁机	已知
打印机	已知
吹风机	已知
熨斗	已知
微波炉	已知
电动车库门	未知
空气压缩机	未知

3.3 消融实验

本小节将进行不同图像尺寸和网络深度的消融实验来验证模型性能,在 BLUED 数据集上进行实验。在开集识别任务中,模型性能通过两个指标进行评估:一是受试者工作特征曲线下面积(AUROC),用于衡量模型区分已知类别与未知类别的能力,数值越高表示模型识别性能越好;二是包含所有 K 个已知类别与1个未知类别的宏平均 F_1 分数,用于评估模型在各类别上的整体分类性能,数值同样越高越佳。

3.3.1 图片尺寸

为验证输入图像尺寸对模型性能的影响,通过对功率时间序列的进行不同长度的截取,保留头部重要的开启信息,适当舍弃尾部的稳态信息,分别转化为16×16、32×32、64×64大小的灰度图像,在相同的网络结构和训练参数下进行对比实验,实验结果如表2所示。

表2 图像尺寸对模型性能的影响

Table 2 Impact of model performance under different image sizes

图像尺寸/像素	A_{UROC}	$F_{1-score}$
16×16	0.873	0.825
32×32	0.961	0.885
64×64	0.926	0.867

由表2的结果可知,32×32大小的图片尺寸下模型的性能优于其他图片尺寸。结合电器开启上升沿特征,由于16×16大小的图片尺寸仅包含开启后16个周波的功率数据,此时大多数电器种类功率并未回归到稳态,导致部分特征丢失,而64×64大小的图片虽然包含了更多的功率信息,但由于负荷特征具有局域性,多余的稳态功率信息对模型训练没有有效的提升效果,所以最终选择32×32作为最终输入图像尺寸。

3.3.2 网络深度

为探究网络深度对模型性能的影响,设计了3种不同深度的卷积神经网络结构,分别包含4层、5层与6层卷积层,在相同训练配置下进行实验,实验结果如表3所示。

表3 不同卷积层数下模型性能对比

Table 3 Comparison of model performance with different numbers of convolutional layers

卷积层数	A_{UROC}	$F_{1-score}$
4层	0.910	0.819
5层	0.961	0.885
6层	0.954	0.874

由表3的结果可知,5层卷积结构的模型性能最优。4层卷积结构对负荷特征提取能力不足, A_{UROC} 和 $F_{1-score}$ 都偏低;6层卷积结构相比5层在两个指标上略有下降,说明模型对训练数据过度学习,所以最终选择5层卷积结构作为主要网络架构。

3.4 OpenAppliance 算法实验

为了进行OpenAppliance算法的实验,需要得到阈值向量。通过对 n 分别取95、96、97、98和99得到5组阈值向量,5次实验结果图5所示,可以分析得出,未知类的准确率为 n 的取值呈递增关系,且上升曲线平稳;而已知类的准确率则与 n 的取值呈递减关系。当 n 大于97时,已知类准确率出现大幅度降低。考虑到已知类是常用电器,应当优先考虑已知类的识别性能,且当 n 取97时,已知类准确率仅比 n 取96时低0.6%,但未知类准确率提高了2.7%。综合比较之下,取 $n=97$ 时的阈值向量。




图5 不同阈值对算法准确度的影响

Fig. 5 Impact of different thresholds on algorithm accuracy

3.5 对比实验

本文进行了3组对比实验,前两组分别与现有的负荷辨识算法、开集识别算法进行对比实验,最后一组对比了不同的距离公式对OpenAppliance算法的性能影响。为评估模型的稳定性和结果的可靠性,进行了5次独立实验,以消除随机性对结果的影响。

3.5.1 负荷辨识算法性能对比

本文选取了一些其他在BLUED数据集上测试过的负荷辨识算法,与本文多提的OpenAppliance算法进行比较,选取准确度、精确度、召回率和 $F_{1-score}$ 作为评估指标。对比结果如表2所示。OpenAppliance算法精确度低于VCE+FWO,但在其他3项指标上均高于DenseNet-12和Fast-shapelets。召回率和 $F_{1-score}$ 与VCE+FWO相当,但准确率略高于VCE+FWO,在已知类上具有良好的分类性能。可以得知虽然OpenAppliance算法在阈值设置阶段对已知类的识别性能略有削减,但对性能影响较小,设置的阈值向量成功排除了测试样本中部分极端数据的影响,同时增加了对未知类的识别能力,这是现有的负荷辨识算法所不具备的。

表4 负荷辨识算法性能对比

Table 4 Comparison of load identification algorithm performance

算法	$A_{accuracy}$	$P_{recision}$	R_{ecall}	$F_{1-score}$
DenseNet-121 ^[16]		0.87	0.81	0.84
VCE+FWO ^[17]	0.96	0.89	0.90	0.89
Fast-shapelets ^[18]		0.70	0.78	0.72
OpenAppliance	0.97	0.88	0.91	0.89

3.5.2 开集识别算法性能对比

本文将3种开集识别算法运用到负荷辨识领域与OpenAppliance算法进行比较,分别在BLUED数据集、COOLL数据集、自采数据集上进行实验。其中,OpenMax^[19]方法通过计算已知类原SoftMax分类

器输出的概率与矫正概率之差,将其分配给未知类别,从而进行重新分类;ARPL^[20]是一种用于开放集识别的新框架,旨在通过引入互补点建模类外空间,并结合对抗性边界约束与数据增强机制,从而有效区分已知与未知类别;CROSR^[21]通过引入深度分层重建网络,联合学习潜在表示和分类结果实现对未知类的稳健检测。实验结果如表5所示。

OpenAppliance算法在BLUED和自采数据集上表现均优于其他开集识别算法,但在COOLL数据集上相比CROSO方法在 $F_{1-score}$ 上略有降低。这是由于COOLL数据集拥有最多的电器类别,对于模型性能带来了一定的挑战。虽然其他3种开集识别算法在图像识别领域有良好的未知类识别效果,但往往依赖于大量已知类别的数据来构建特征空间,由于负荷数据集规模较小,且不同电器特征易于重叠,将现有的开集识别算法直接应用于负荷辨识领域表现不佳。

表5 开集识别算法性能对比
Table 5 Comparison of open set recognition algorithm performance

算法	数据集	A_{UROC}	$F_{1-score}$
OpenMax	BLUED	0.873	0.842
	COOLL	0.846	0.807
	自采数据集	0.851	0.816
CROSO	BLUED	0.957	0.880
	COOLL	0.923	0.854
	自采数据集	0.944	0.873
ARPL	BLUED	0.952	0.874
	COOLL	0.901	0.839
	自采数据集	0.939	0.864
OpenAppliance	BLUED	0.961	0.885
	COOLL	0.912	0.843
	自采数据集	0.950	0.877

3.5.3 距离计算公式

OpenAppliance算法在校准概率分布步骤中需要选取合适的距离公式来衡量每个样本的激活向量与其所属类别的均值激活向量的差异,本实验分别采用欧氏距离和归一化距离来分析距离计算公式对OpenAppliance算法识别性能的影响,其余步骤和参数不变,结果如表6所示。

表6 未知类识别性能对比
Table 6 Comparison of unknown class recognition performance

距离公式	A_{UROC}	$F_{1-score}$
归一化距离	0.937	0.841
欧式距离	0.961	0.885

由表6可知,在OpenAppliance算法中运用欧式

距离时算法性能全面超过归一化距离。原因在于归一化距离通过对数据进行归一化处理,使得不同取值范围的特征尺度相同,不利于衡量样本与已知类别之间的差异,所以选取欧氏距离作为本算法的距离计算公式。

3.5.4 对比实验总结

通过对比实验发现,基于阈值调整的负荷辨识开集识别算法OpenAppliance能够增强了负荷辨识算法对未知电器的识别能力,同时对识别已知类电器负荷的造成的算法性能下降影响较小,从而提高了负荷辨识算法的准确性、鲁棒性和实用性,有利于负荷辨识算法真正的从实验室走向真实场景应用中。

4 结束语

本文为了解决负荷辨识算法在实际应用中处理未知电器负荷时的局限性,提升算法整体鲁棒性,提出了一种基于阈值调整的负荷辨识开集识别算法OpenAppliance。通过融合深度学习优势和概率模型,引入阈值调整策略,实现对未知电器负荷的检测与分类,同时维持对已知电器负荷的识别性能稳定。OpenAppliance算法在智能电网环境中具有广泛的应用潜力,为复杂负荷辨识问题提供了新思路。D

参考文献:

[1] 刘恒勇,刘永礼,邓世聪,等.一种基于LSTM模型的电力负荷辨识方法[J].电测与仪表,2019,56(23):62-69.
LIU Hengyong, LIU Yongli, DENG Shicong, et al. A power load identification method based on the LSTM model [J]. Electrical Measurement & Instrumentation, 2019, 56(23):62-69.
[2] 李利刚,刘浩,陈建强,等.基于最优特征和改进随机森林的非侵入式负荷辨识方法[J].电力需求侧管理,2024,26(3):55-61.
LI Ligang, LIU Hao, CHEN Jianqiang, et al. A non-intrusive load identification method based on optimal features and improved random forest [J]. Power Demand Side Management, 2024, 26(3):55-61.
[3] 申浩.非侵入式负荷辨识技术研究[D].杭州:杭州电子科技大学,2021.
SHEN Hao. Research on non-intrusive load identification technology [D]. Hangzhou: Hangzhou Dianzi University, 2021.

- [4] 刘俊雨,白牧可,张立梅. 基于耦合特征和改进随机森林的非侵入式农业负荷辨识[J]. 供用电, 2025, 42(1): 106-115.
LIU Junyu, BAI Muke, ZHANG Limei. Dispatch-centric forecasting strategy of electric vehicle charging load for economic operation of energy system in service area[J]. Distribution & Utilization, 2025, 42(1): 106-115.
- [5] 魏小曼,余昆,陈星莺,等. 基于 Affinity propagation 和 K-means 算法的电力大用户细分方法分析[J]. 电力需求侧管理, 2018, 20(1): 15-19, 35.
WEI Xiaoman, YU Kun, CHEN Xingying, et al. Analysis of power large user segmentation based on Affinity propagation and K-means algorithm[J]. Power Demand Side Management, 2018, 20(1): 15-19, 35.
- [6] 王一,马子明,谭跃凯,等. 广东日前电力市场方案设计与市场仿真[J]. 电力需求侧管理, 2018, 20(1): 10-14.
WANG Yi, MA Ziming, TAN Yuekai, et al. Day-ahead power market design and market simulation in Guangdong province [J]. Power Demand Side Management, 2018, 20(1): 10-14.
- [7] 王健,易姝慧,刘俊杰,等. 基于随机森林算法和稳态波形的非介入式工业负荷辨识[J]. 中国电力, 2022, 55(2): 82-89.
WANG Jian, YI Shuhui, LIU Junjie, et al. Non-intrusive industrial load identification based on random forest algorithm and steady-state waveform [J]. Electric Power, 2022, 55(2): 82-89.
- [8] 朱亮,支妍力,梅贱生,余萌,胡琛,徐超群. 基于 GMM-FHMM 的工业产线非介入式负荷辨识[J]. 浙江电力, 2024, 43(12): 68-76.
ZHU Liang, ZHI Yanli, MEI Jiansheng, YU Meng, HU Chen, XU Chaoqun. Non-intrusive load monitoring for industrial production line based on GMM-FHMM [J]. Zhejiang Electric Power, 2024, 43(12): 68-76.
- [9] 严永辉,李新家,王淑云,等. 基于云端协同的家用电器负荷辨识能力提升技术研究[J]. 电力需求侧管理, 2021, 23(3): 58-63.
YAN Yonghui, LI Xinjia, WANG Shuyun, et al. Research on technology to enhance household appliance load identification capability based on cloud collaboration[J]. Power Demand Side Management, 2021, 23(3): 58-63.
- [10] 谢应彪,侯慧,唐俊一,等. 台风灾害下含移动氢能存储的电-气综合能源系统负荷恢复策略[J]. 电力系统自动化, 2025, 49(6): 134-143.
XIE Yingbiao, HOU Hui, TANG Junyi, et al. Load restoration strategy for integrated electricity-gas energy system with mobile hydrogen energy storage under typhoon disasters [J]. Automation of Electric Power Systems, 2025, 49(6): 134-143.
- [11] FENG G, DESAI D, PASQUALI S, et al. Open set recognition for random forest [C]//Proceedings of the 5th ACM International Conference on AI in Finance. 2024: 45-53.
- [12] KONG S, RAMANAN D. Opengan: open-set recognition via open data generation [C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. 2021: 813-822.
- [13] OZA P, PATEL V M. Deep CNN-based multi-task learning for open-set recognition [J]. arXiv preprint arXiv: 1903.03161, 2019.
- [14] WANG J, ALAMAYREH O, TONDI B, et al. Open set classification of gan-based image manipulations via a vit-based hybrid architecture [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2023: 953-962.
- [15] PICON T, MEZIANE M N, RAVIER P, et al. COOLL: controlled on/off loads library, a public dataset of high-sampled electrical signals for appliance identification [J]. arXiv preprint arXiv: 1611.05803, 2016.
- [16] WU Q, WANG F. Concatenate convolutional neural networks for non-intrusive load monitoring across complex background [J]. Energies, 2019, 12(8): 1572.
- [17] TAVEIRA P R Z, DE MORAES C H V, LAMBERT-TORRES G. Non-intrusive identification of loads by random forest and fireworks optimization [J]. IEEE Access, 2020(8): 75 060-75 072.
- [18] MADHAN M S, KARTHIKEYAN E. Classification of image using deep neural networks and SoftMax classifier with CIFAR datasets [C]//2022 6th International Conference on Intelligent Computing and Control Systems (ICICCS). IEEE, 2022: 1 132-1 135.
- [19] BENDALE A, BOULT T E. Towards open set deep networks [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2016: 1 563-1 572.
- [20] CHEN G, PENG P, WANG X, et al. Adversarial reciprocal points learning for open set recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2021, 44(11): 8 065-8 081.
- [21] YOSHIHASHI R, SHAO W, KAWAKAMI R, et al. Classification-reconstruction learning for open-set recognition [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 4 016-4 025.

作者简介:

李一鸣(1997),男,江苏南京人,硕士,主要从事营销数字化、人工智能工作;

邓君华(1980),男,江苏南京人,正高级工程师,主要从事营销数字化、营销大数据、人工智能、供电服务工作;

李志新(1986),男,辽宁朝阳人,博士,主要从事电能计量、计量检测工作;

(责任编辑 水 鸪)