

一种基于云边协同的非侵入式负荷辨识框架

顾水福,周磊,李洁,李亚飞,李圆琪,朱超群

(国网江苏省电力有限公司 苏州供电分公司,江苏 苏州 215004)

摘要:为解决海量非侵入式负荷监测(non-intrusive load monitoring, NILM)数据上传云端带来的分析时延性与云端资源大量消耗问题,提出了一种基于云边协同的非侵入式负荷辨识框架。首先,采用马尔可夫转移场(Markov transition field, MTF)编码方式对功率数据进行颜色编码,构建特征明晰的负荷标识;接着,在云服务层和边缘服务层分别部署相同结构的轻量级深度学习模型以完成训练与负荷辨识任务,在降低云边资源压力的同时,通过迁移学习方式实现负荷辨识的云边协同;最后,基于自适应合成采样(adaptive synthetic sampling, ADASYN)对REDD数据集进行扩充以解决数据集不平衡引起的模型学习偏见,并基于该数据集对所提框架辨识性能进行有效性验证,结果表明该框架不仅能够满足负荷辨识的高精度与实时性需求,同时能够显著降低云端和边缘端的存储与计算资源压力。

关键词:非侵入式负荷辨识;云边协同;马尔可夫转移场;轻量级深度学习模型;自适应合成采样

Non-intrusive load identification framework based on cloud-edge collaboration

GU Shuifu, ZHOU Lei, LI Jie, LI Yafei, LI Yuanqi, ZHU Chaoqun

(Suzhou Power Supply Company, State Grid Jiangsu Electric Power Co., Ltd., Suzhou 215004, China)

Abstract: In order to solve the problem of analysis ductility and large consumption of cloud resources caused by massive non-intrusive load monitoring (NILM) data uploaded to the cloud, a non-intrusive load identification framework based on cloud-edge collaboration is proposed. Firstly, the Markov transition field (MTF) coding method is used to color code the power data, and the load identification with clear characteristics is constructed. Then, a lightweight deep learning model with the same structure is deployed in the cloud service layer and the edge service layer respectively to complete the training and load identification tasks. While reducing the pressure of cloud-edge resources, the cloud-edge coordination of load identification is realized through transfer learning. Finally, based on adaptive synthetic sampling (ADASYN), the REDD dataset is extended to solve the model learning bias caused by dataset imbalance, and the identification performance of the framework proposed is validated based on the dataset. The results show that the framework can not only meet the requirements of high precision and real-time load identification, but also significantly reduce the pressure of cloud and edge storage and computing resources.

Key words: non-intrusive load identification; cloud-edge collaboration; Markov transition field; lightweight deep learning model; adaptive synthetic sampling

0 引言

随着中国“碳达峰·碳中和”战略的提出和推进,完善用户侧需求响应机制,发挥需求侧资源削峰填谷、节能降碳成为电力领域研究重点^[1]。根据国际能源组织报告,我国碳排放量占全球总排放量的28%,其中电力行业排放量占总量的比例超过了40%^[2]。随着居民生活水平的提高,居民用电量在国民经济总用电量的占比不断增加,由此引发的碳排放问题引起广泛关注。据统计,我国居民家用电器耗电量约占全国总用电量的12%^[3]。以NILM^[4]为代表的负荷监测技术通过监测各类用电设备的能

耗数据,帮助用户培养绿色生活习惯,减少电能损耗,是实现双碳战略发展要求的重要举措。

负荷识别是NILM领域的关键问题,目前国内外针对非侵入负荷辨识问题已开展了大量研究。文献[5]通过将高频的波形信息转换成结构化的图谱特征,并在其基础上形成多类负荷组合支持向量机模型,实现了非侵入式负荷的准确识别。文献[6—7]利用如V-I轨迹,格拉姆角场(gramian angular field, GAF)等图像编码技术,将一维原始信号进行可视化转换,结合先进图像识别网络挖掘原始数据隐含信息以准确分类负荷类型。文献[8]通过与已建立的负荷稳态波形特征库进行比较,利用动态时间弯曲技术计算与模版库波形的距离,从而识别家用负荷。文献[9]根据不同电器运行状态将

其划分,并针对不同运行状态的电器类型,分别利用双向长短期记忆网络和多层感知器实现了负荷分解。文献[10—11]对负荷功率状态进行聚类,并将分时段状态概率因子引入目标函数,通过多特征遗传优化迭代实现负荷分解。上述基于图像编码和深度学习的负荷识别方法可有效提升识别精度,但存在两个问题:① 负荷图像编码过程繁琐、效率低,导致难以广泛应用;② 海量数据上传云端集中计算的方式对网络带宽要求较高,容易引起通信拥塞,导致时延性问题,且会大量占用云端资源。为此,部分学者引入边缘计算技术来解决上述问题,边缘计算是一种新兴的计算架构,其节点部署尽可能接近数据源和终端用户,实现数据就近处理^[12]。文献[13]设计了一种云边协同计算体系,通过挖掘边缘侧采集的负荷数据行为特征,实现负荷信号的分解。然而,其时序数据特征提取采用的是传统的人工筛选方法,同时结合基于无监督学习的聚类算法,导致整体算法框架的泛化性能偏低。文献[14]提出了一种边缘计算架构来合理分配计算任务,根据边缘端和云端计算资源分别部署 RBFNet 和 L2-AlexNet 两种深度学习模型进行负荷识别,实现云边资源的充分利用。然而,该算法框架存在以下几点问题:① 计算资源受限的边缘端承担辨识模型训练任务,往往会造成模型训练效率低下;② 未考虑数据集不平衡带来的模型学习偏见问题;③ 边缘端模型负荷辨识精度较低,且云端和边缘端模型各自独立执行辨识任务,未从根本上利用云边协同解决边缘侧负荷辨识性能受限问题。

综上,现有基于边缘计算的非侵入式负荷辨识研究较少,且技术方法还尚不完善,部署在边缘端的模型负荷辨识精度与效率偏低导致难以满足工程实际中海量负荷监测数据的识别性能需求。为此,本文开发了一种基于轻量级深度学习网络的非侵入式负荷云边协同辨识框架。为提升负荷编码的转换效率,提出一种基于 MTF 的负荷编码方法,将原始一维数据转换为特征明晰的二维图像;引入轻量级卷积神经网络 SqueezeNet 作为负荷辨识模型,将其部署于云端和边缘端分别执行负荷标识的训练与就地诊断工作;通过云边模型权重参数交

互,实现整体系统框架的云边协同与负荷类型的高精度、实时辨识。最后,算例结果验证了所提框架的有效性与优越性。

1 云边协同负荷辨识框架

本文提出的云边协同负荷辨识框架结构如图 1 所示,主要由边缘服务层和云服务层两大模块组成。其中,边缘服务层主要执行终端数据采集、颜色编码以及负荷辨识任务。

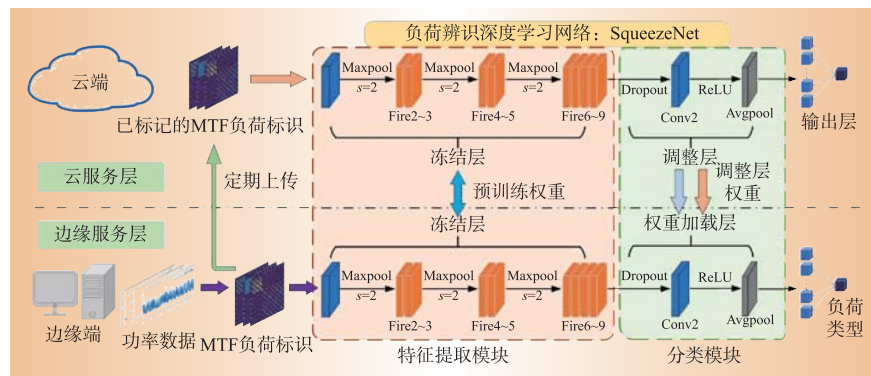


图 1 云边协同负荷辨识框架

Fig. 1 Framework of cloud-edge collaborative load identification

边缘服务层:由于边缘端资源有限,部署大规模深度学习网络会大量占用其计算资源与空间,导致平台计算响应迟缓,甚至造成系统崩溃。因此,本文在边缘服务层部署轻量级网络 SqueezeNet 进行负荷标识特征提取和分类辨识,该模型能够在仅消耗极小存储与计算资源的情况下,获得高精度的辨识效果,在缓解平台资源压力的同时,实现负荷辨识的高精度、实时响应。

云服务层:基于云端强大的计算能力与丰富的存储资源,部署于其上的深度学习网络规模越来越大,虽然在一定程度上提高了负荷辨识的准确率,但随着海量数据的持续堆积,对于模型算力的要求也越来越高,使得云平台的计算资源与存储空间受到了极大的挑战。为此,本文使用与在边缘侧结构一致的轻量级网络 SqueezeNet 部署于云计算平台,以缓解其资源消耗。同时,依据其训练权重的下发与加载,可以很好地实现负荷辨识的云边协同。

2 负荷辨识算法

2.1 基于 MTF 的时序数据颜色编码

马尔可夫转移场^[15]是一种一维时序信号转换成二维矩阵的图像编码方法。该方法在电力系统

工程中已有少量应用,例如电能质量扰动检测^[16],然而现有研究还未有将MTF编码技术应用至电力负荷辨识中。

给定一组时间序列 $X=\{x_1, x_2, \dots, x_n\}$, x_i 为第 i 个采样点,首先定义 Q 个分位数单元 $q_j(j \in [1, Q])$ 对时间序列进行离散化处理,量化其中的每一个值,任意数值点 x_i 可以映射到相应的分位数 q_i 上。然后,通过沿时间轴以一阶马尔可夫链的方式计算各分位数单元之间的转移概率,经归一化处理得到 $Q \times Q$ 的马尔可夫转移矩阵 \mathbf{W} 。然而,马尔可夫转移矩阵对 \mathbf{X} 的空间分布不够敏感,同时忽略了其与时间步长之间的时间相关性,造成了大量的信息损失。为解决这一问题,利用MTF理论对其进行改进,通过考虑时间位置关系,沿时间顺序对每个转移概率进行排列,将包含幅值轴上转移概率的矩阵 \mathbf{W} 扩展至包含时间轴的MTF矩阵 \mathbf{M} ,保留了原始信号的时间相关性,其表达式为

$$\mathbf{M} = \begin{bmatrix} M_{11} & M_{12} & \dots & M_{1Q} \\ M_{21} & M_{22} & \dots & M_{2Q} \\ \vdots & \vdots & \ddots & \vdots \\ M_{Q1} & M_{Q2} & \dots & M_{QQ} \end{bmatrix} = \begin{bmatrix} P(w_{11}|x_1 \in q_1, x_1 \in q_1) \\ P(w_{21}|x_2 \in q_2, x_1 \in q_1) \\ \vdots \\ P(w_{Q1}|x_Q \in q_Q, x_1 \in q_1) \\ P(w_{12}|x_1 \in q_1, x_2 \in q_2) \dots P(w_{1Q}|x_1 \in q_1, x_Q \in q_Q) \\ P(w_{22}|x_2 \in q_2, x_2 \in q_2) \dots P(w_{2Q}|x_2 \in q_2, x_Q \in q_Q) \\ \vdots \\ P(w_{Q2}|x_Q \in q_Q, x_2 \in q_2) \dots P(w_{QQ}|x_Q \in q_Q, x_Q \in q_Q) \end{bmatrix} \quad (1)$$

式中: M_{ij} 为从分位数 q_i 到 q_j 的转移概率,即 $M_{ij} = P(w_{ij}|x_i \in q_i, x_j \in q_j)$ 。

这样经过MTF编码得到的图像具有以下特点与优势:

(1) 图像的像素点位置信息即为功率数据的时序信息,避免了一维功率数据的时序信息丢失。

(2) 像素点幅值信息即为 M_{ij} 的大小,并进行了颜色编码,其颜色深浅体现了转移概率,编码后的二维负荷标识十分利于深度学习网络学习和辨识。

(3) 较距离矩阵和GAF而言,MTF整个转换过程十分简洁,计算量较小。分位数划分的引入使MTF对干扰和噪声的抵抗力变强。

2.2 SqueezeNet轻量级深度学习网络

近年来,基于深度学习的图像识别方法愈加成熟,其对图像颜色有很高的灵敏度,能够很好地进行图像信息挖掘^[17]。因此,本文结合深度学习技术对一维功率数据对应的MTF颜色编码负荷标识进行特征提取与辨识。目前,应用于非侵入式负荷辨

识研究中的深度学习网络由于规模较大,基本部署在资源充足的云平台,这一方面造成了数据传输带来的时延性与云计算资源的大量消耗;另一方面,大规模的网络模型难以部署至资源受限的边缘端。为此,本文引入轻量级网络SqueezeNet^[18]作为主辨识网络,这是因为我们发现SqueezeNet不仅可大量减少模型参数量与计算量,而且将其应用于REDD公共数据集,还取得了超越现有高性能负荷识别模型的辨识效果。为与负荷辨识任务匹配,本文针对SqueezeNet输出层进行神经元数目微调,以适应分类任务。SqueezeNet结构及其核心模块Fire如图2所示。图2(b)中, $H \times W$ 为输入图像尺寸; C 和 S 分别为Squeeze层的输入和输出通道数, E_1 和 E_2 分别为扩展层 1×1 和 3×3 卷积核的输出通道数。

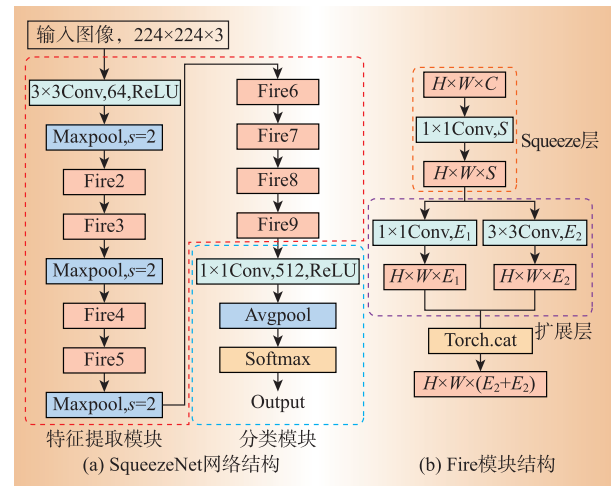


图2 SqueezeNet结构及其核心模块Fire

Fig. 2 Structure of SqueezeNet and its core module Fire

3 基于ADASYN的不平衡数据处理

本文采用公共数据集REDD进行负荷辨识框架性能验证。REDD数据集为美国波士顿6个家庭数月的实测用电数据记录,包括每个家庭的总负荷数据和各个用电设备的负荷数据,根据采样频率不同分为高频数据和低频数据。本文主要针对基于低频采样的数据进行负荷辨识,采样频率为 $1/3$ Hz,且每个记录的功率数据都有对应的时间戳,该部分数据记录的时间信息如表1所示,其中测量开始时间指的是4月18日,测量结束时间指的是5月24日。本文采用洗碗机、照明灯、微波炉、烤箱、洗衣机、冰箱和火炉这7种常用的非侵入式负荷设备用电数据进行后续分析。由于智能电表大多采集功率数据,因此以功率数据为基础的辨识算法更加适用于实际场景。

表1 REDD低频部分数据采集时间

Table 1 Data acquisition time of low-frequency part of REDD

用户	测量开始时间	测量结束时间	持续天数/d
1	04:00—18:00	05:00—24:00	6
2	04:00—17:00	05:00—22:00	5
3	04:00—16:00	05:00—30:00	4
4	04:00—16:00	06:00—03:00	8
5	04:00—17:00	05:00—31:00	4
6	05:00—21:00	06:00—14:00	4

当设备的状态发生改变时,可以通过分析功率的变化来检测设备状态。本文将REDD数据集中6个家庭的所有设备的有功功率数据依次进行读取,并对读取后的数据进行归一化处理,提取设备事件发生前后的128个采样数据点(电器开启或关闭瞬间的时刻)。数据集中各设备的采样数量差异较大,其中照明灯的采样数量最多,达到了1 866组,而烤箱的采样数量只有73组。深度学习网络在提取设备特征时更偏向于采样数量更多的设备数据,因而易造成模型的学习偏见,使得其对采样量多的设备辨识准确率要普遍高于采样量少的设备,从而降低了模型的负荷识别性能。

目前,绝大多数非侵入式负荷辨识研究在应用公共数据集方面采用直接应用的方式,未考虑数据集不平衡带来的负面影响。因此,本文采用ADASYN^[19]算法对不平衡数据集进行处理,以解决数据分布不平衡带来的模型学习偏见问题。ADASYN算法是根据少数类样本的困难程度,自适应的合成相应数量的新样本,相对于合成少数类过采样技术^[20],其更能反应数据集底层分布。

4 实验分析

4.1 实验环境

本文实验环境由边缘服务器和云服务器两大模块组成,将采集到的负荷监测数据输入到云边协同框架中进行负荷辨识。边缘服务器和云服务器环境配置如表2所示。云服务器基于其强大的计算资源,主要负责模型的训练任务,而边缘服务器主要负责负荷监测数据的实时辨识任务。

表2 实验环境参数

Table 2 Experimental environment parameters

边缘服务器		云服务器	
配置参数	类别型号	配置参数	类别型号
CPU	Intel Core i7-7700 @2.80 GHz	CPU	AMD Ryzen3970X @3.70 GHz
GPU	NVIDIA GTX 1050	GPU	NVIDIA RTX 3090
RAM	8 GB	RAM	128 GB

4.2 性能评价指标及模型超参数设置

本文重点考察所提出的云边协同负荷辨识框架在辨识精度与效率方面的综合性能表现。因此,精度评价指标采用平均准确率;效率评价指标包括模型参数量(Params)、占用内存空间以及辨识时间。平均准确率计算如下

$$A_{\text{accuracy}} = \frac{T_p + T_n}{T_p + T_n + F_p + F_n} \quad (2)$$

式中: T_p 和 T_n 分别为阳性样本数量和阴性样本数量; F_p 和 F_n 分别为阳性和阴性样本的错误识别数量。

模型参数量在卷积层与全连接层的计算式为

$$P_{\text{arams}}^c = (K_h K_d C_{\text{in}} + 1) C_{\text{out}} \quad (3)$$

$$P_{\text{arams}}^l = (D_{\text{in}} + 1) D_{\text{out}} \quad (4)$$

式中: K_h 和 K_d 分别为卷积核的高度和宽度; C_{in} 和 C_{out} 分别为卷积层的输入和输出通道数; D_{in} 和 D_{out} 分别为全连接层的输入和输出通道数。

负荷辨识框架采用的深度学习模型各项超参数如表3所示。网络全连接层的隐含层激活函数都统一设置为ReLU,分类网络中的损失函数采用交叉熵损失函数,优化方法采用SGD优化算法,学习率设置为0.001,迭代次数为100次。

表3 深度学习模型超参数设置

Table 3 Hyperparameter settings of deep-learning model

超参数	取值	超参数	取值
深度	18	冻结层数量/层	17
批处理大小	64	调整层数量/层	1
学习率	0.001	Dropout	0.5

4.3 数据处理结果

经ADASYN方法对REDD数据集处理后,各类样本数量如表4所示。烤箱的样本数量从73组扩充至1 866组,火炉的样本数量增至1 890组,每类设备样本数量基本保持均衡,使得深度学习网络对每类样本的关注度基本保持一致,实现模型特征提取合理性与辨识精度的进一步提升。

表4 经ADASYN处理前后的数据集中各设备采样数量

Table 4 Number of samples for each device in the ADASYN processed dataset

设备名称	处理前样本个数	处理后样本个数
洗碗机	608	1 864
照明灯	1 866	1 866
微波炉	1 107	1 824
烤箱	73	1 866
冰箱	1 307	1 859
火炉	152	1 890
洗衣机	1 787	1 863

4.4 数据集不平衡对辨识性能的影响

使用ADASYN技术对数据集进行处理之后,数据集共有13 032组样本数据。为验证数据集不平衡对负荷辨识性能的影响,同时考虑到原始数据集中烤箱功率样本数仅有73个,因此本文从每个负荷类别随机抽取30组样本数据作为测试集,保存至边缘端用于验证边缘模型的负荷辨识性能。其余12 822组样本以9:1划分为训练集和验证集,保存至云端用于训练云端深度学习模型。对于未经过ADASYN处理的原始不平衡数据集,采取同样的方式划分训练集、验证集和测试集,并分别保存至云端和边缘端。模型训练过程如图3所示。

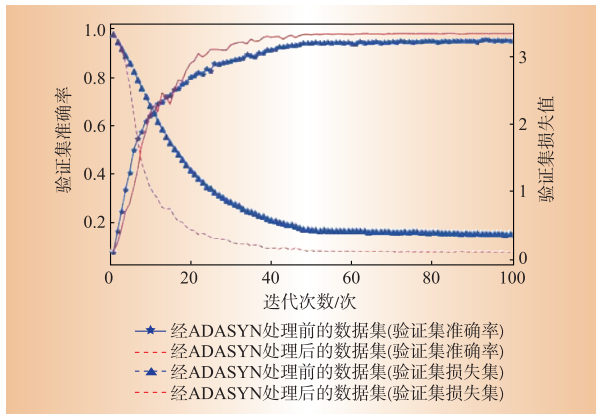


图3 模型在经 ADASYN 处理前后数据集上的训练结果

Fig. 3 Training results of model on REDD dataset before and after ADASYN processing

由图3可知,在数据集经过 ADASYN 技术进行扩充处理后,SqueezeNet 模型在验证集上的识别准确率得到了较大幅度的提升,同时进一步加快了损失值的收敛速度,使得模型的负荷辨识性能得到了明显的提升。另一方面,将训练得到的最优模型权重参数文件下发至边缘端,在边缘辨识模型中进行加载,并针对测试集进行负荷辨识性能测试,通过测试结果可以得到模型的负荷辨识准确率达到96.19%,而未经过处理的数据集的准确率为90.00%,提升了6.19%。由此验证了基于 ADASYN 的不平衡数据处理算法能有效提高模型的负荷识别精度。为了对识别结果进行可视化分析,本文使用混淆矩阵来更加直观的展示识别结果,模型在经过 ADASYN 处理后的数据集上的识别结果混淆矩阵如图4所示。

图4中,每个单元格中的数字代表各个负荷的数量,横坐标为预测的设备类别,纵坐标为真实的设备类别,其中0代表洗碗机,1代表照明灯,2代表微波炉,3代表烤箱,4代表冰箱,5代表火炉,6代表洗衣机。对角线数字代表准确识别的各个相应类别的设备数量。由不平衡处理前后的混淆矩阵可以看出,烤箱和火炉的正确识别数量得到了明显的

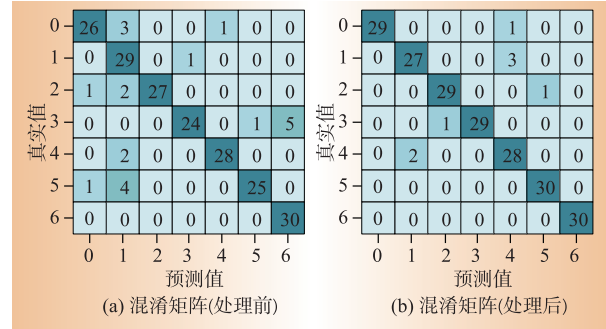


图4 经 ADASYN 处理前后的数据集辨识结果混淆矩阵

Fig. 4 Identification results confusion matrix of dataset before and after ADASYN processing

提升,证明基于 ADASYN 的不平衡数据集处理有助于提高模型的识别精度。

4.5 不同序列图像编码方法下的辨识性能对比

图像编码方法是负荷辨识的关键环节,其转换质量决定了负荷辨识模型提取特征的精度。为验证所提出的 MTF 负荷编码方法的优越性,本文以 SqueezeNet 作为辨识模型,将 MTF 与现有应用较为广泛的距离矩阵和 GAF 编码方法进行负荷辨识性能对比,结果如表5所示。其中,转换一图是指使用相应编码方法对一个序列数据进行转换所用的平均时间。

表5 不同图像编码方法下的准确率与效率对比

Table 5 Comparison of accuracy and efficiency of different image coding methods

编码方法	输入尺寸/ 像素×像素	准确率/%	转换一图/ms
距离矩阵	224×224	68.58	32.39
GAF	224×224	94.61	67.55
MTF	224×224	96.19	49.71

由表5可以看出,在负荷辨识精度方面,距离矩阵的辨识精度较差,这是因为距离矩阵是各点的横纵坐标折射到时域数据的差值,图像对称重复,扰动信息有限且只涵盖在图像中一小块区域,在下采样时易造成特征丢失,泛化能力不强。而 GAF 由于在特征映射过程中容易丢失幅值等关键原始数据,因此其辨识精度仍然受限。在负荷辨识效率方面,距离矩阵由于其仅涉及简单的编码计算流程,因此其转换效率最高,然而其精度性能的缺陷使得其难以应用于实际负荷辨识工程中。GAF 由于涉及将时域信号转移至极坐标系的跨域转换过程,因此其转换效率较 MTF 更低。综上,相对于距离矩阵与 GAF,MTF 在负荷辨识精度与效率方面取得了最佳综合性能表现。

4.6 与现有负荷辨识算法的精度与效率性能对比

为进一步验证所提云边协同辨识框架的有效性与优越性,本文基于相同实验环境和数据集及其

划分方式,将现有取得优异识别性能的负荷辨识算法与本文算法进行对比分析,以平均准确率、辨识时间以及模型参数作为综合评价指标。现有负荷辨识算法方面,以文献[21]采用的LSTM模型以及文献[14]使用的RBFNet与L2-AlexNet模型作为基准算法。3种模型均采用与原文相同的模型结构,而超参数选取与本文保持一致。在经ADASYN处理后的REDD数据集上,各辨识算法采用与本文相同的训练、验证与测试集划分模式,其在边缘端测试集上的综合性能测试结果如图5所示。各辨识算法的精度指标对比如表6所示,效率指标对比如表7所示。其中,颜色编码时长与模型辨识时长分别表示针对一个功率样本与负荷标识样本循环测试100次得到的平均所用时长。




图5 不同负荷辨识算法综合性能对比

Fig. 5 Comparison of comprehensive performance of different load identification algorithms

表6 不同负荷辨识算法平均准确率对比

Table 6 Average accuracy comparison of different load identification algorithms

模型	负荷标识	输入尺寸	准确率/%
LSTM	功率特征	一维信号	86.19
RBFNet	GAF	32×32	89.52
L2-AlexNet	GAF	227×227	95.24
本文算法	MTF	224×224	96.19

表7 不同负荷辨识算法效率对比

Table 7 Efficiency comparison of different load identification algorithms

模型	编码时长/ ms	参数量/ M	占用空间/ MB	辨识时长/ ms
LSTM		1.72	6.58	15.63
RBFNet	67.55	1.96	7.12	7.39
L2-AlexNet	67.55	59.57	446.33	34.85
本文算法	49.71	0.73	2.72	9.67

由图6和表6可以看出,在负荷辨识精度方面,本文算法较LSTM、RBFNet及L2-AlexNet分别提升10%、6.67%和0.95%。这一方面是由于squeezeNet的Fire特殊设计模块能够有效提取负荷标识的深层

特征信息,进而实现负荷类型的高精度辨识。另一方面主要是由于:①时间序列的顺序性质嵌入了许多重要的特征,这些特征超出了典型的时域分析。因此,以一维功率特征作为输入的LSTM时序分析模型很难在时域内完成高精度分类;②REFNet和L2-Alexnet模型整体结构较为简单,且前者输入负荷标识仅为32×32,因此很难针对负荷标识的深层特征信息进行捕捉与提取。

在负荷辨识效率方面,由图6和表7可知,本文应用的SqueezeNet模型在参数量、占用空间方面均明显优于其他3种负荷辨识模型。其中,SqueezeNet的参数量和占用空间仅为0.73 M和2.7 MB,这不论在云端还是边缘端均极大地缓解了平台计算与存储压力,同时其轻量化的结构设计使得模型辨识一负荷标识样本的平均时长仅需9.6 ms,相对LSTM和L2-AlexNet的辨识效率得到了明显提升,虽略低于RBFNet,但该模型的负荷辨识精度性能存在较大的缺陷。此外,MTF颜色编码算法在转换效率方面亦优于文献[18]采用的GAF算法,这是因为GAF算法需要将时域信号转移至极坐标系中再进行矩阵变换,进而形成负荷标识,而MTF算法则省去了跨域转换的过程,因此其转换时间更短。综上,在资源受限的边缘服务层,本文所提出的MTF颜色编码技术结合轻量级网络SqueezeNet的负荷辨识算法不仅在精度方面能够实现高精度负荷识别,在效率方面其整体辨识一功率样本的平均时长仅需59.38 ms,实现了边缘端采集样本负荷类型的实时辨识,同时该框架能够极大地节省边缘端计算量与存储空间。

5 结束语

针对海量NILM数据上传云端带来的分析时延性与云端资源大量消耗问题,本文提出了一种基于深度学习的非侵入式负荷云边协同辨识框架。采用MTF颜色编码进行功率时序数据的负荷标识构建,在实现功率特征具象化的同时提升了可视化转换效率。依托云边协同计算框架合理分配负荷识别计算任务,通过在云端和边缘端部署轻量级网络SqueezeNet,并利用迁移学习减轻了网络传输与云端资源压力。基于ADASYN对不平衡数据集进行扩充处理,以解决数据集不平衡带来的模型学习偏见。实验结果表明,依托所提云边协同框架,较现有负荷辨识算法,本文算法能够取得更佳的非侵入式负荷辨识精度性能,同时在辨识效率与节省资源方面更具优势,可满足工程应用中海量NILM数据的识别精度与效率需求。D

参考文献:

- [1] 王利兵,张赞,郑炜,等.化石能源非能利用需求和碳排放研究[J].全球能源互联网,2023,6(6):577-587. WANG Libing, ZHANG Yun, ZHENG Wei, et al. Research on demand and carbon emissions of non-energy use of fossil energy [J]. Journal of Global Energy Interconnection, 2023, 6(6):577-587 (in Chinese).
- [2] WANG P, LI M. Scenario analysis in the electric power industry under the implementation of the electricity market reform and a carbon policy in China [J]. Energies, 2019, 12(11):2 152.
- [3] DING L, SCOTT D. Non-intrusive load monitoring using multi-label classification methods [J]. Electrical Engineering, 2020:1-13.
- [4] 裘星,尹仕红,张之涵,等.基于DTW的多状态负荷的非侵入式负荷分解[J].电力需求侧管理,2022,24(6):84-90. QIU Xing, YIN Shihong, ZHANG Zhihan, et al. Non-intrusive load decomposition of multi-state load based on DTW [J]. Power Demand Side Management, 2022, 24(6):84-90.
- [5] 武昕,严萌,郭一凡,等.基于结构化特征图谱的组合支持向量机非侵入式负荷辨识[J].电力系统自动化,2022,46(12):210-219. WU Xin, YAN Meng, GUO Yifan, et al. Non-intrusive load identification by combined support vector machine based on structured characteristic spectrum [J]. Automation of Electric Power Systems, 2022, 46(12):210-219.
- [6] 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.
- [7] 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.
- [8] 祁兵,董超,武昕,等.基于DTW算法与稳态电流波形的非侵入式负荷辨识方法[J].电力系统自动化,2018,42(3):70-76. QI Bing, DONG Chao, WU Xin, et al. Non-intrusive load identification method based on DTW algorithm and steady-state current waveform [J]. Automation of Electric Power Systems, 2018, 42(3):70-76.
- [9] 罗平,朱振宇,樊星驰,等.基于时序生成对抗网络的居民用户非侵入式负荷分解[J].电力系统自动化,2024,48(2):71-81. LUO Ping, ZHU Zhenyu, FAN Xingchi, et al. Non-intrusive load decomposition for residential users based on time-series generative adversarial network [J]. Automation of Electric Power Systems, 2024, 48(2):71-81.
- [10] ZHOU Y, LI F, LIU L, et al. Non-intrusive load monitoring method based on the time-segmented state probability [J]. Energy Report, 2022, 8(S4):1 418-1 423.
- [11] 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.
- [12] SHI W S, CAO J, ZHANG Q, et al. Edge computing: vision and challenges [J]. IEEE Internet of Things Journal, 2016, 3(5):637-646.
- [13] 孙睿晨,董坤,赵剑锋,等.基于递进式模型结构和时间信息嵌入的非侵入式负荷分解[J].智慧电力,2024,52(2):55-62,70. SUN Ruichen, DONG Kun, ZHAO Jianfeng, et al. Non-intrusive load decomposition based on progressive model structure and temporal information embedding [J]. Smart Power, 2024, 52(2):55-62,70.
- [14] 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.
- [15] WANG Z, OATES T. Spatially encoding temporal correlations to classify temporal data using convolutional neural networks [J/OL]. Journal of Computer and Systems Sciences, 2015, <https://arxiv.org/pdf/1509.07481>.
- [16] 钱倍奇,陈谦,李宗源,等.基于马尔可夫转换场与多头注意力机制的电能质量扰动分类方法[J].电网技术,2023,48(2):721-733. QIAN Beiqi, CHEN Qian, LI Zongyuan, et al. Power quality disturbances classification based on Markov transition field and multi-head attention [J]. Power System Technology, 2023, 48(2):721-733.
- [17] XIE G, ZHANG X, YANG W, et al. LG-CNN: from local parts to global discrimination for fine-grained recognition [J]. Pattern Recognition, 2017, 71:118-131.
- [18] IANDOLA F N, HAN S, MOSKEWICZ M W, et al. SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5 MB model size [EB/OL]. <http://arXiv.org/abs/1602.07360>.
- [19] HE H, BAI Y, GARCIA E A, et al. ADASYN: adaptive synthetic sampling approach for imbalanced learning [C]// Proceedings of International Joint Conference on Neural Networks. New York: IEEE, 2008: 1 322-1 328.
- [20] CHAWLA N, BOWYER K, HALL L, et al. SMOTE: synthetic minority over-sampling technique [J]. Journal of artificial intelligence research, 2002, 16:321-357.
- [21] LAI CH F, CHIEN W C, YANG L T, et al. LSTM and edge computing for big data feature recognition of industrial electrical equipment [J]. IEEE Transactions on Industrial Informatics, 2019, 15(4):2 469-2 477.

作者简介:

顾水福(1966),男,江苏苏州人,研究员级高级工程师,主要从事电力系统自动化方面工作;

周磊(1989),男,山西临汾人,博士研究生,高级工程师,主要从事电力需求侧响应及其在电力系统中的应用方面工作;

李洁(1972),女,江苏苏州人,高级工程师,主要从事电力负荷管理及需求响应方面工作。

(责任编辑 水 鹤)