

基于标么化三阈值事件检测与LDA分类器的工商业负荷辨识方法

陈霄¹, 马云龙¹, 李新家², 方磊¹, 严永辉², 喻伟²

(1. 国网江苏省电力有限公司, 南京 210000; 2. 江苏方天电力技术有限公司, 南京 210024)

摘要:非侵入式负荷辨识技术能够低成本地获取用户各类设备使用情况,实现电力负荷的在线监测与分析,对支撑负荷预测、需求响应等应用开展有着重要意义。针对一般工商业用户类型多样、负荷种类繁多、设备运行特性复杂的特点,提出了一种基于标么化三阈值事件检测与LDA分类器的工商业负荷辨识方案。首先针对不同能耗级别、不同启停特性的设备设计了参数可调的统一负荷事件检测框架,提升了缓变型、分段型、震荡型负荷事件的检出准确度。随后提出了基于多元特征与LDA线性判别的设备类型判断算法,在兼顾边缘端计算效率的同时取得了与随机森林等非线性分类器相同的辨识性能。

关键词:非侵入式负荷辨识;一般工商业用户;事件检测;改进三阈值算法;LDA线性判别

Industrial and commercial load identification method based on normalized three threshold event detection and LDA classifier

CHEN Xiao¹, MA Yunlong¹, LI Xinja², FANG Lei¹, YAN Yonghui², YU Wei²

(1. State Grid Jiangsu Electric Power Co., Ltd., Nanjin 210024, China; 2. Jiangsu Fangtian Electric Power Technology Co., Ltd., Nanjin 210000, China)

Abstract: Non-intrusive load identification technology can obtain the usage of various equipment at low cost, and can monitor and analyze power load on line, which is of great significance for load forecasting, demand response and other applications. In view of the diversity of general industrial and commercial users, the variety of loads and the complexity of equipment operation characteristics, an industrial and commercial load identification scheme based on normalized three threshold event detection and LDA classifier is proposed. Firstly, a unified load event detection framework with adjustable parameters is designed for devices with different energy levels and different start-stop characteristics, which improves the detection accuracy of slow-moving, segmented and oscillating load events. Then an equipment type identification algorithm based on multivariate features and LDA linear discrimination is proposed, which achieves the same identification performance as nonlinear classifiers such as random forest while ensuring the computational efficiency of the edge.

Key words: non-intrusive load identification; general industrial and commercial users; event detection; improved three threshold algorithm; LDA linear discriminant

0 引言

非侵入式负荷辨识技术能够低成本地获取用户各类设备使用情况^[1],实现电力负荷的在线监测与分析,支撑负荷预测、需求响应等应用的开展。但当前关于非侵入式负荷辨识技术的研究,主要集中在居民用户场景,在用电量调节潜力更大的工商业用户场景亟待进一步加强。

常见的非侵入式负荷辨识技术一般分为基于特征和基于数据挖掘的方法,前者不需要对模型进

行统计学习,只需要对信号层面进行处理就可以达到理想效果^[2],后者依靠一定量的标记数据来学习分类辨识模型,其主要分为传统的机器学习^[3]和深度神经网络^[4]。对于居民用户,由于用电设备类型相对有限,用电习惯相对规律,且数据采集难度低,越来越多的学者开始研究基于数据挖掘的方法。隐马尔科夫模型(hidden markov model, HMM)是传统机器学习算法中较为经典的算法,文献[5]提出了多种隐马尔科夫模型的变体,并加入了设备的非功率特征参数,采用最大期望值算法找到最佳的隐状态序列,从而实现电力负荷的识别和分解,一定程度上解决了居民用户开关事件重叠导致的识别准确度下降问题。文献[6]提出了差分隐半马尔科夫模型,解决了目标电气设备与其他电气设备的信

号重叠问题。而深度学习由于在计算机视觉、语音识别、自然语言处理等诸多领域的显著应用效果也被引入至居民非侵入负荷辨识中,文献[7]提出使用一个循环神经网络(recurrent neural network, RNN),只需将多个长短期记忆(long short-term memory, LSTM)层连接在一起,实现了较高精度的负荷分解。文献[8]采用了卷积神经网络(convolutional neural network, CNN),通过将典型家电的运行电流数据转换成二维图像的形式进行模型训练,实现具有一定泛化能力的高效辨识。

而对于一般工商业用户,由于其涉及的用户类型和负荷种类繁多,用户用电行为复杂,需要大量的采集与标注数据以支撑数据挖掘类算法,难度较大。文献[9]提出了工业负荷辨识存在的挑战,包括复杂设备类型、复杂的使用规律等多种情况。已有文献多聚焦在基于特征的方法上进行工业负荷辨识,文献[10—11]提出了基于随机森林与稳态波形的工业负荷辨识方法。文献[12—13]提出了基于解释空间、特征空间映射关系的工业事件辨识方法。基于特征的方法依赖于正确检测设备的“开关”事件,而当前对于工商业事件检测的研究,主要通过设定合适的有功周期增量差阈值与观测周期数来实现事件检测,研究对象大都聚焦在大功率、运行稳定、投切不频繁的工业负荷中,在复杂场景中难以取得较好效果。基于上述内容本文提出信号标么化联合三阈值的事件检测方法,解决了工业设备中分段型、缓变型、震荡型等多种复杂启停过程辨识困难的问题。随后,本文针对边缘设备计算性能相对较低的特点,设计了基于多元特征与线性判别分析(linear discriminant analysis, LDA)技术的设备类型分类算法,相较于支持向量机的设备分类算法^[14],在不损失分类精度的情况下,大大降低了计算时间。

1 典型工商业设备运行分析

工商业负荷相对居民负荷,无论在设备启停特性还是设备运行特性上都存在着巨大的差异。本节首先对一般工商业负荷中常见的分段式启停、功率爬坡式启停和运行中呈现复杂波动等场景进行展示分析。

设备启动时的功率爬坡、分多次功率抬升多见于电机类负载,由于其启动特性以及其加工产品时的工艺要求,电机类负载的运行功率曲线一般呈现出复杂的变化特性。

以陶瓷工业场景的自动压膜机为例,电机类负载启停时可能出现的情况如图1所示。

- (1) 设备在开启后,出现多次有功容量抬升,启动与抬升的容量变化大小、爬坡速率也不尽相同;
- (2) 设备的关断过程,功率分多次下降,直至关断;
- (3) 设备启停过程每次功率变容间的时长间隔也无固定规律。




图1 陶瓷行业压膜机启停机负荷特征

Fig. 1 Load characteristics of start and stop of film press in ceramic industry

而对于部分由于工艺或生产导致的负载不稳定场景,电机类负载在运行过程会呈现出剧烈的负荷波动,有时甚至无法区分是设备启停还是运行时噪声,常规的阈值增量法很难对此进行区分。图2中展示了建筑工地中的打桩机启动运行特性,其呈现出上述的剧烈波动情况。




图2 建筑工地打桩机启动特性分析

Fig. 2 Analysis on starting characteristics of pile driver in construction site

2 基于标么化三阈值的事件检测算法

综合上述几类负荷的运行特性,可看出:①不同的工商业场景,设备能耗级别差别明显;②工商业负荷分段式启停、缓变启停是一个比较普遍的现象,这类启停方式会弱化设备启停时的功率变化特征;③运行过程常见持续频繁震荡。上述特点都会对事件检测造成较大干扰,因此,本文以增量阈值

检测逻辑为基础^[14],提出了信号标幺化联合三阈值事件检测的方法。通过在三阈值检测部分使用幅值低阈值、幅值高阈值和时间差阈值对缓变或分段过程进行完整识别,克服常规检测方法对这类事件检测不全的问题。

2.1 信号预处理

采用中值降采样滤波,滤波间隔设置偏小,对于波动剧烈的负荷波动噪声滤除效果不佳,这会降低事件检测的准确度;滤波间隔偏大带来的过度降采样则会弱化甚至丢失设备自身特有的负荷特征,如变化率、波动程度等,降低设备类型辨识准确度,本文基于数据分析经验,选取5 s间隔对输入信号滤波。

随后对信号进行标幺化处理,标幺基准值取已滤波信号的幅值最大值,公式如下

$$Y_{bs} = Y_{in} / B_{ase} \quad (1)$$

$$B_{ase} = \max |Y_{in}| \quad (2)$$

式中: Y_{in} 为经过滤波后的输入信号; B_{ase} 为用于标幺化的基准值; Y_{bs} 为经过标幺化处理之后的信号。

经过标幺化之后,输入信号的幅值被限制在0到1之内,这样便可在后续的检测算法中使用相同的增量阈值兼容不同运行功率的设备。

2.2 三阈值事件检测

三阈值检测算法实质是将事件检测分为3个阶段,具体流程如下所述。

(1) 使用低阈值检测可疑负荷突变

计算第 i 个窗与前窗信号均值之差 ΔY_i , 公式如下

$$\Delta Y_i = |u_i - u_{i-1}| \quad (3)$$

式中: u_i 为输入信号 Y_{bs} 在第 i 个事件检测滑窗的均值。

设置低阈值参数 T_{HR_low} , 若 $\Delta Y_i > T_{HR_low}$, 则认为第 i 个滑窗发生了负荷突变。低阈值检测环节可提高事件检测灵敏度, 最大限度避免漏检。

(2) 依据时间差阈值拼接负荷事件

对于缓变型或分段型负荷事件, 其过程会持续较长时间, 仅使用低阈值检测会检出从属完整事件过程的多个事件片段, 需要依据时间差阈值进行拼接, 将多个事件片段合并为一个完整负荷事件。基于上述逻辑即可实现自适应检测完整的事件过程。

假设第 i 个窗口检测到了负荷突变事件, 定义事件在时间维度构成的闭区间集合 D 为

$$D = [t_i - w, t_i + w - 1] \quad (4)$$

式中: t_i 为第 i 个滑窗的起点时刻; w 为滑窗窗长。

假定在第 i 个窗口与第 j 个窗口均检测到了负荷突变 ($j > i$), 定义时间间隔 $\Delta T = t_j - t_i$, 设置时间差阈值 T_{HR_time} , 若 $\Delta T \leq T_{HR_time}$, 则认为 i 、 j 两个滑窗检出的负荷突变属于同一个事件的暂态过程, 将其合并到同一个负荷事件

$$D_{event}(k) = [L(k), R(k)] \quad (5)$$

式中: $D_{event}(k)$ 为第 k 个负荷事件; $L(k) = t_i - w$; $R(k) = t_j + w - 1$ 。

(3) 使用高阈值筛选有效负荷事件

1阶段低阈值检测与2阶段事件拼接可以检出缓变或多段式事件, 但不能克服负荷波动带来的干扰, 需要使用高阈值 T_{HR_high} 对拼接后的事件序列进行筛选。

对于 $D_{event}(k)$ 是否为有效负荷事件, 定义比较信号值进行判别, 具体如下

$$\Delta Y = \frac{1}{w} \sum_{n=R(k)-w+1}^{R(k)} Y_n - \frac{1}{w} \sum_{n=L(k)}^{L(k)+w-1} Y_n \quad (6)$$

式中: Y_n 为标幺化之后的信号; 若 $\Delta Y > T_{HR_high}$, 则认为 $D_{event}(k)$ 是一个真实发生的负荷投入事件, 而不是由波动干扰产生的无效事件。

能量阈值的设置影响检测算法的性能, 一阶段检测阈值设置偏低会增加噪声误检测为负荷事件的概率, 也易导致事件的过度拼接, 偏高会引起真实负荷事件过程检测不全或完全漏检; 3阶段检测阈值用于筛选有效负荷事件, 设置偏低会增加无效事件误判率, 偏高则会降低真实事件检出率。本文中基于多种工业场景的实际工况进行了能量阈值的选取, T_{HR_low} 取0.03, T_{HR_high} 取0.15。

2.3 检测效果分析

分别以上文中提到的工地场景打桩机、陶瓷工业场景自动压膜机为例进行检测效果分析。实验中检测滑窗窗长 w 设置为20个滤波后时刻点, 即时间尺度100 s, 窗口滑动步长取 w , T_{HR_time} 在建筑工地场景取 $2w$, 在陶瓷工业场景中取 $4w$ 以适应较长时间的设备分阶段启动。

事件检测结果如图3所示, 红色曲线为输入幅值信号, 蓝色点覆盖曲线段为算法检测到的整个设备启停过程。

事件检测时间与真实发生时间的偏差如表1所示, 定义检测时间偏差值矩阵 $[O_{ffset1}, O_{ffset2}]$, O_{ffset1} 为检测与真实开始时间的差值, O_{ffset2} 为检测与真实结束时间的差值, 符号“-”代表提前, “+”代表滞后。




图3 事件检测结果

Fig. 3 Event detection results

表1 事件检测时间偏差

Table 1 Event detection time deviation

事件类型	事件持续时长	检测时间偏差区间
震荡启动	140	$[-50, +10]$
震荡关停	60	$[-35, +105]$
变容启动	675	$[-65, +10]$
变容关停	810	$[-35, +25]$

由上述检测结果可知,采用标么化联合三阈值方法对分段型、震荡型事件进行检测,均可以检测到完整的事件过程,整体上算法检测到的开始时间会较真实时间提前,检测到的结束时间会较真实时间滞后,时间偏差小于2 min,绝大部分集中在80 s以内。本文所提算法在进行事件合并时存在一定的局限性,可能将两种相邻启动的不同设备进行合并,但在工商业场景中,设备投切并不频繁,设备重叠度不高,当前检测方法中的时间差阈值能够满足辨识要求,此处的时间差阈值同时也可以理解为算法的辨识间隔时间灵敏度。

3 基于LDA分类器的设备类型辨识

LDA线性判别器是一种监督学习框架下的分类模型^[15],其具有实现复杂度低、训练与预测运行时间快的特点,相较于随机森林、支持向量机等复杂算法更适合在计算资源有限的边缘端运行。本文选择LDA线性判别器作为负荷类型判断的辨识工具。

3.1 特征空间

特征的选择是分类器性能优劣的重要因素,需要尽可能多的构造具有物理意义与区分度的特征。

本文构造了31维负荷印记特征,详细特征介绍如表2所示。

表2 负荷印记特征

Table 2 Load imprint characteristics

特征类型	特征描述	数量
事件持续时长	事件过程时长	1
事件稳态特征	有功、无功、二次谐波、五次谐波变化量	4
事件暂态特征变化率	有功、无功、五次谐波变化率的最大值、均值、最小值	9
事件过程特征相似度	有功序列与无功、二次谐波、五次谐波序列的相似度 无功序列与二次谐波、五次谐波序列的相似度	5
事件结束后状态特征	有功、无功、二次谐波、五次谐波的标准差、平均波动程度、平均值与最小值之差	12

特征提取时数据计算区间为事件发生前1个滑窗至事件结束后的3个滑窗。事件过程时长取事件暂态过程持续总时长。事件稳态特征计算方法为取事件发生后1个滑窗与事件发生前1个滑窗的信号幅值均值之差,事件暂态变化率特征的计算区间为事件暂态过程所覆盖滑窗,变化率计算如下

$$R_{i-1} = |X_i - X_{i-1}| / X_{\text{base}} \quad (7)$$

式中: X 为数据序列; X_{base} 为 X 的基准值,基准值取事件发生前后特征量的变化量绝对值; R_{i-1} 为 X 由时刻 $i-1$ 至时刻 i 间的变化率。事件过程相似度特征的计算区间为事件暂态过程所覆盖滑窗,相似度计算如下

$$\rho = \frac{N \sum_{i=1}^N X_i Y_i - \sum_{i=1}^N X_i \sum_{i=1}^N Y_i}{\sqrt{N \sum_{i=1}^N X_i^2 - \left(\sum_{i=1}^N X_i \right)^2} \sqrt{N \sum_{i=1}^N Y_i^2 - \left(\sum_{i=1}^N Y_i \right)^2}} \quad (8)$$

式中: N 为数据序列 X 与 Y 的长度; ρ 为 X 与 Y 的相似度。事件结束后的状态特征计算区间为事件完成之后的3个滑窗,其中标准差特征计算如下

$$S = \left(\frac{1}{N-1} \sum_{i=1}^N (X_i - \bar{X})^2 \right)^{1/2} \quad (9)$$

式中: N 为数据序列 X 的长度; $\bar{X}$ 为 X 的均值; S 为 X 的标准差;平均波动程度计算如下

$$M_{\text{cl}} = \frac{1}{N} \sum_{i=2}^N |X_i - X_{i-1}| \quad (10)$$

式中: N 为数据序列 X 的长度; M_{cl} 为 X 的平均波动程度;平均值与最小值之差计算方法为取信号平

均值与信号最小值的差值。

3.2 基于LDA的分类模型构建

LDA能够充分利用训练样本已知的类别信息,寻找最有助于判别分类的投影子空间,但其主要适用于二分类问题,对于工商业非侵入负荷辨识包含多个不同类型待分类设备的场景,本文在基础LDA二分类器的基础上采用一对一拆分策略(one vs. one, OvO)进行负荷类型的类别多分类。

基础二分类LDA将多维空间样本投影到一条直线上,形成一维空间,最重要的是选取这条直线的方向,使得在这个方向的直线上,相同类别样本聚集最紧密,不同样本可分离程度最大,从而更有利于分类。

假设二类数据集 $C = \{(x_i, l_i)\}_{i=1}^N$, x_i 为第 i 个样本, $l_i \in \{0, 1\}$ 为样本类别, N 为样本数量。第 l 类样本均值为

$$u_l = \frac{1}{N_l} \sum_{x_i \in l} x_i \quad (11)$$

式中: N_l 为第 l 类样本的数量;第 l 类样本的类内离散度矩阵为 $\Sigma_l = \sum_{x_i \in l} (x_i - u_l)(x_i - u_l)^T$, 总类内离散度为 $s_w = \Sigma_0 + \Sigma_1$, 类间离散度矩阵为 $s_b = (u_0 - u_1)(u_0 - u_1)^T$ 。

将两类数据全部样本投影到方向向量为 W 的直线上,则样本 x_i 在该直线上的投影可以表示为

$$y_i = W^T x_i \quad (12)$$

第 l 类样本投影到直线 W 的均值为

$$\bar{u}_l = \frac{1}{N_l} \sum_{y_i \in l} y_i = W^T u_l \quad (13)$$

方差为

$$s_l^2 = \sum_{y_i \in l} (y_i - \bar{u}_l)^2 \quad (14)$$

根据 Fisher 判别准则^[26], 当样本类间距离与类内距离的比值最大时, 可得投影直线的最佳方向向量 W , 即目标函数为

$$\arg \max J(W) = (\bar{u}_0 - \bar{u}_1)^2 / (s_0^2 + s_1^2) \quad (15)$$

式中: 分子可以转化为 $W^T(u_0 - u_1)(u_0 - u_1)^T W$, 即 $W^T s_b W$, 分母可以转化为

$$\sum_{x_i \in l_0} W^T(x_i - u_0)(x_i - u_0)^T W + \sum_{x_i \in l_1} W^T(x_i - u_1)(x_i - u_1)^T W \quad (16)$$

式(16)进一步可以转化为: $W^T(\Sigma_0 + \Sigma_1)W$, 即 $W^T s_w W$, 则目标函数可以表示为

$$\arg \max J(W) = \frac{W^T s_b W}{W^T s_w W} \quad (17)$$

式(17)是 s_b 与 s_w 的广义瑞利商, 求此式的极值, 可得极值解为

$$W_* = s_w^{-1}(u_0 - u_1) \quad (18)$$

此极值解就是 Fisher 准则下的最优投影方向,

根据此投影方向即可获得一维空间的一对一分类器

$$\begin{cases} Y = W_*^T X + W_0 > 0 \Rightarrow X \in l_0 \\ Y = W_*^T X + W_0 < 0 \Rightarrow X \in l_1 \end{cases} \quad (19)$$

式中: $W_0 = -(\bar{u}_0 + \bar{u}_1)/2$; 当 $Y > 0$ 时判定 X 类别为 l_0 , 当 $Y < 0$ 时判定 X 类别为 l_1 。

在基础LDA二分类器基础, OvO策略独立地训练多个二分类模型, 并基于多个二分类器结果进一步决策。OvO策略为每两个类别训练一个分类器, 对于给定的包含 K 类标签的数据样本将产生 $K(K-1)/2$ 个二分类任务。在测试阶段, 新样本将同时提交给所有分类器, 于是会得到 $K(K-1)/2$ 个分类结果, 最终结果通过投票产生: 即统计 $K(K-1)/2$ 个分类结果中每种类别被预测的次数, 某类别被预测到一次即视为此类别获得一票, 把被预测得最多的类别作为最终的分类结果。

分类器如表3所示, 以包含 C_1 、 C_2 、 C_3 、 C_4 4类设备的辨识场景为例, 训练时构造 M_1 到 M_6 共6个二分类器, 分类辨识阶段将每个测试样本提交给6个分类器, 取被预测数量最多的类别为最终设备类型。

表3 分类器

Table 3 Classifiers

正样本	负样本	分类器
C_1	C_2	M_1
C_1	C_3	M_2
C_1	C_4	M_3
C_2	C_3	M_4
C_2	C_4	M_5
C_3	C_4	M_6

3.3 类型辨识效果分析

考虑到一般工商业场景的多样性与差异性, 每个场景单独进行设备类型辨识。在陶瓷工业场景中对自动压膜机、自动拉胚机、电烤花炉、上釉机4类设备作类型辨识, 在建筑工地场景中对打桩机、静压机、干挖机、双轴搅拌机4类设备作类型辨识, 实验中对每类场景分别选择10个用户, 在每个用户内对各类型设备采集50条标注样本作为训练测试样本, 并将前7户的数据作为训练用样本, 后3户数据作为测试用样本。

本次实验分类模型的准确度选择 f_1 值进行描述, 计算公式如下

$$p_{\text{recision}, k} = \frac{T_p}{T_p + F_p} \quad (20)$$

$$r_{\text{ecall}, k} = \frac{T_p}{T_p + F_n} \quad (21)$$

$$f1_k = \frac{2p_{\text{recision}, k} r_{\text{ecall}, k}}{p_{\text{recision}, k} + r_{\text{ecall}, k}} \quad (22)$$

式中： T_p 为设备 k 样本中预测正确的数量； F_p 为设备 k 样本中预测错误的数量； F_N 为非设备 k 被辨识为设备 k 的数量； $p_{\text{recision},k}$ 为设备 k 样本被正确辨识的概率； $r_{\text{ecall},k}$ 为所有被辨识为设备 k 的样本中正确的比率； f_1 为一个介于 0 到 1 的值， f_1 值越大，证明模型的分类效果越好，若精确率与召回率有一方太小，都将影响到 f_1 值。

统计算法对测试样本的设备类型辨识准确度，结果如表 4 所示。

表 4 设备辨识结果

Table 4 Equipment identification results

设备名称	f_1
自动压膜机	0.961
自动拉胚机	0.96
电烤花炉	0.976
上釉机	0.963
静压机	0.957
打桩机	0.954
干挖机	0.969
双轴搅拌机	0.973

由表 4 可看出，电烤花炉、双轴搅拌机、干挖机辨识准确率在第 1 档，上釉机、自动压膜机辨识准确率在第 2 档，静压机、打桩机辨识准确率在最后 1 档。第 1 档所属设备启动时呈简单的震荡状，运行波形相对平稳，算法对其启动事件暂态过程检测效果较优，启动侧负荷印记特征计算更准确；第 2 档所属设备因其变容启动特点和弱规律性的变容间隔，致使启动完整周期的检测存在偏差，从而影响特征提取与后续分类效果；第 3 档所属设备由于其启动及运行过程呈现的剧烈波动特性，较大的影响了启动暂态过程检测及负荷特征计算，更容易产生档内类间设备的混淆辨识。但从整体上看，本文所提辨识方法的 f_1 指标平均超过了 0.95，具有实际应用价值。

同样以 31 维多元特征向量作为输入，对比使用 LDA 算法、多层感知器、SVM 支持向量机、随机森林的辨识情况，辨识准确度 f_1 值与辨识耗时取表 4 所列出的 8 类目标设备的均值，辨识能力对比结果如表 5 所示。

表 5 不同模型辨识效果对比

Table 5 Comparison of identification effects of different models

算法模型	f_1	耗时/ms
LDA	0.964	59
多层感知器	0.972	328
SVM 支持向量机	0.978	217
随机森林	0.983	256

LDA 与其他 3 类算法相比， f_1 值相对较小，但计算时间得到了明显的提升。多层感知器和支持向量机由于激活函数和核函数的引入增加了算法的非线性感知能力，而随机森林在决策树集成的过程中也实现了部分非线性感知功能，因此 3 者辨识精度比纯线性分类器 LDA 略高，但额外的增加了更多的计算开销。由表 5 对比结果可看出，LDA 算法的相对准确性和高计算效率更适合边缘侧的算法部署。

4 结束语

工商业场景繁多，设备能耗级别、功率曲线变化趋势差别大，已往算法对不同场景的兼容性较低；工商业设备启停事件复杂度高，常见分段启停、缓变启停、震荡启停类事件，运行常伴随持续波动；本文使用信号标么化联合三阈值方法进行事件检测，既实现了以一套参数可调的统一事件检测框架来兼容不同能耗级别、不同启停特性的设备，又可以提高对分段型、缓变型、震荡型事件的检出准确度；设备类型辨识使用基于 LDA 算法的辨识方法，分类准确度 f_1 值为 0.964，相较于多层感知器、SVM 支持向量机、随机森林稍低一些，但运行速度却具备明显的优势，更适合在边缘侧执行辨识。

参考文献：

[1] 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.

[2] 李想,刘宇航,张琪,等.小波检测和特征图谱决策的非侵入电动自行车充电实时监测系统[J]. 电力系统自动化,2023,47(19):177-186.

LI Xiang, LIU Yuhang, ZHANG Qi, et al. Non-intrusive real-time monitoring system for electric bicycle charging based on wavelet detection and feature graph decision[J]. Automation of Electric Power Systems, 2023, 47(19): 177-186.

[3] KONG W, DONG Z Y, HILL D J, et al. A hierarchical hidden markov model framework for home appliance

- modeling[J]. IEEE Transactions on Smart Grid, 2016, 9(4):3 079-3 090.
- [4] LIU Y, WANG X, YOU W. Non-intrusive load monitoring by voltage-current trajectory enabled transfer learning[J]. IEEE Transactions on Smart Grid, 2019, 10(5):5 609-5 619.
- [5] KIM H, MARWAH M, ARLITT M F, et al. Unsupervised disaggregation of low frequency power measurements[C]// Society for Industrial and Applied Mathematics. Proceedings of the SIAM International Conference on Data Mining, 2011.
- [6] KOLTER J Z, JAAKKOLA T S. Approximate inference in additive factorial HMMs with application to energy disaggregation[C]// International Conference on Artificial Intelligence and Statistics, 2012.
- [7] 刘恒勇,史帅彬,徐旭辉,等. 一种关联RNN模型的非侵入式负荷辨识方法[J]. 电力系统保护与控制, 2019,47(13):162-170.
- LIU Hengyong, SHI Shuaibin, XU Xuhui, et al. A non-invasive load identification method based on correlated RNN model [J]. Power System Protection and Control, 2019, 47(13):162-170.
- [8] 张玉天,邓春宇,刘沅昆,等. 基于卷积神经网络的非侵入负荷辨识算法[J]. 电网技术, 2020, 44(6): 2 038-2 044.
- ZHANG Yutian, DENG Chunyu, LIU Yuankun, et al. Non intrusive load identification algorithm based on convolutional neural network [J]. Power Grid Technology, 2020, 44(6):2 038-2 044.
- [9] ADABI A, MANTEY P, HOLMEGAARD E, et al. Status and challenges of residential and industrial non-intrusive load monitoring[C]// Technologies for Sustainability. IEEE, 2015.
- [10] 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 stochastic forest algorithm and steady-state waveform[J]. Electric Power, 2022, 55(2):82-89.
- [11] 易姝慧,郭俊岑,刁新平,等. 基于LSQR与系统距离聚类算法的专变用户非介入式负荷辨识[J]. 电测与仪表, 2022, 59(6):60-68.
- YI Shuhui, GUO Juncen, DIAO Xinping, et al. Non intrusive load identification of special transformer users based on LSQR and system distance clustering algorithm [J]. Electric Measurement and Instrument, 2022, 59(6):60-68.
- [12] 武昕,于金莹,彭林,等. 基于用户边缘侧事件解析的工业电力负荷非侵入式感知辨识[J]. 电力系统自动化, 2021, 45(4):29-37.
- WU Xin, YU Jinying, PENG Lin, et al. Non intrusive perceptual identification of industrial power load based on user edge side event analysis[J]. Automation of Electric Power Systems, 2021, 45(4):29-37.
- [13] 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.
- [14] 张志飞,苗夺谦,高灿. 基于LDA主题模型的短文本分类方法[J]. 计算机应用, 2013, 33(6):1 587-1 590.
- ZHANG Zhifei, MIAO Duoqian, GAO Can. A short text classification method based on LDA topic model [J]. Computer Applications, 2013, 33(6):1 587-1 590.
- [15] 徐小雨,赵龙章,程晓月,等. 基于改进Fisher判别准则的卷积神经网络设计[J]. 计算机工程, 2020, 46(11):255-260, 266.
- XU Xiaoyu, ZHAO Longzhang, CHENG Xiaoyue, et al. Design of convolutional neural network based on improved Fisher discriminant criterion[J]. Computer Engineering, 2020, 46(11):255-260, 266.

作者简介:

陈霄(1985),男,江苏连云港人,博士,高级工程师,主要从事电能计量、大数据、新能源消纳等研究工作。

(责任编辑 王 蕊)