

DOI: 10.12158/j.2096-3203.2024.01.018

# 基于先验统计模型的非侵入负荷辨识算法

赵成<sup>1</sup>, 宋彦辛<sup>1</sup>, 周赣<sup>2</sup>, 冯燕钧<sup>2</sup>, 郭帅<sup>1</sup>, 李季巍<sup>1</sup>

(1. 国网北京市电力公司电力科学研究院, 北京 100080;

2. 东南大学电气工程学院, 江苏 南京 211189)

**摘要:**针对传统非侵入负荷辨识技术中电热细分能力不足的问题,文中提出了一种基于先验知识与统计学习模型的非侵入式负荷辨识算法。文中对洗衣机辅热、电水壶、电饭锅、电热水器等设备进行了电热细分研究,通过设备运行关联算法实现了辅热设备的细分,并在用户有限反馈信息和专家标注的基础上,实现了非辅热设备分类的模型训练。实验结果表明,文中所提技术框架在事件检测负荷辨识算法的基础上实现了电热设备的细分,且在运行状态分解的 F1 分数指标中取得了 0.9 以上的优异效果。

**关键词:**非侵入负荷监测(NILM);事件检测;电热细分;统计分析;高斯混合聚类(GMM);支持向量机(SVM)

中图分类号:TM714

文献标志码:A

文章编号:2096-3203(2024)01-0165-09

## 0 引言

非侵入式负荷监测技术通过对用户总负荷数据的监测与分解,可以获得细粒度用电负荷类别和行为数据,是智能用电服务的基础数据支撑。一方面用户掌握家用电器设备的详细耗电信息后,通过适当的节能建议能够有效地降低 5%~20% 的用电量<sup>[1]</sup>,另一方面,细粒度用电数据隐藏着用户的用电规律与生活习惯信息,能够支撑政府、社会进行相关工作的管理,例如用户电动自行车户内充电监测与报警<sup>[2]</sup>、独居老人生活安全防护等内容<sup>[3]</sup>。

Hart 于 20 世纪 80 年代提出了基于事件检测与负荷特征匹配的经典辨识算法<sup>[4]</sup>,通过不同设备状态切换时的独特负荷印记用以区分其类型,并关联启停过程。基于特征的方法依赖于正确检测设备的“开关”事件,部分学者针对高精度事件检测进行了大量研究<sup>[5-7]</sup>,文献[8]提出了一种多频率尺度的事件辨识方法,通过高低频数据结合的方式准确判断各类负荷事件。事件检测算法中对设备类型的分类基于设备启停时独特的电气特征<sup>[4]</sup>,文献[9]将跟随负荷事件发生的电气特征变化定义为增量负荷印记,并列举了多种暂稳态特征集合。事件检测算法也存在一定的局限性,当多个负荷事件在同一时间发生时可能出现事件的重叠湮灭问题,也有学者针对此进行了深入研究,提出了组合优化等事件匹配策略<sup>[10-11]</sup>,一定程度上改善了辨识效果。然而,在面对无明显电气特征的电热类设备时,事件检测算法无法仅凭电气特征进行分类,这是传统算法始终无法回避的问题。

随着机器学习技术的发展,隐式马尔可夫算法与深度学习算法被引入到负荷辨识技术中,其通过训练学习的方法以提升设备整体运行周期感知的能力,包括事件检测方法无法解决的具体电热设备细分。隐式马尔可夫模型(hidden Markov model, HMM)是一个由隐藏序列和可观测序列构成的生成概率模型,在非侵入负荷辨识应用中,前者为多个电器的开启关断状态,后者为用户的总进线处的功率序列,模型基于用户分设备历史用电规律,基于概率最大化原则从总功率曲线中分解出分项负荷<sup>[12-14]</sup>。深度神经网络算法同样聚焦在端到端的解决方案,通过对不同叠加运行工况下的分项设备运行区间进行网络特征自适应提取,直接分离分项设备运行曲线<sup>[15-17]</sup>。深度学习算法与 HMM 算法虽然可以克服事件检测类算法中的一些局限,但须要使用大量真实用电场景实测的分设备电气信号进行学习,消耗较大的数据采集成本。尽管部分学者已经研究了迁移学习模型在负荷辨识中的应用<sup>[18-20]</sup>,以降低实际应用中采集标注数据数量的要求,但模型算法在数据选择、应用范围上仍有一定的局限性。

综合考虑算法辨识性能与算法学习对数据的要求,基于事件检测与特征匹配识别的方法仍然是非介入负荷辨识应用在规模化推广应用时的最优手段。文献[21]初步探索了电热设备无法细分这一事件检测算法框架下的难点,提出了基于功率特征与设备使用规律的细分思路,但仍有部分实际问题须要解决,包括同一功率档下存在多个电热设备场景下的负荷分离问题。鉴于上述情况,文中研究进一步优化了电热细分的算法方案,提出了基于先验统计模型的非侵入式负荷辨识算法,首先新

增了辅热设备的细分类别辨识方法与同功率下多个电热设备信号分离的方案,随后在无须精细化分项设备标注标签,仅需部分前期用户调研与粗粒度专家标注的数据基础上研究了基于特征分类的统计学习模型用以区分电热详细类别。同时,文中所提方法可以进行端云双层部署,充分利用边缘侧的计算能力与云侧的数据存储能力,实现云边协同的高效低成本负荷辨识。

### 1 基于事件检测的云边协同辨识框架

事件检测算法一般部署于边缘侧,通过安装于用户总进线处的采集分析终端或智能电表对高频电流电压信号进行采集并即时分析。有功功率能够准确地反映电器的启停状况、额定功率以及消耗电能等信息,基于事件检测的算法多以有功功率为基准,以基础的差分算法为例,其以有功功率序列的一阶差分值满足某个阈值作为事件发生的判断条件,其定义如(1)所示。

$$\Delta P_a = P_{a+b} - P_a \quad (1)$$

式中: $P_a$ 为功率序列中的第  $a$  个元素; $P_{a+b}$ 为功率序列中第  $a+b$  个元素; $\Delta P_a$ 为第  $a$  个差值。差分检测算法根据实际情况对  $b$  进行取值, $b$  过大会抓取不到极短时间内的投切事件,过小则不能抓取到功率变化的完整过程,因此引申出了具备自适应且精度更高的滑动窗累计和算法与概率比较算法<sup>[5-6]</sup>,此处不再赘述。

根据事件检测结果可以进一步提取事件过程中的暂态稳态特征量,常见的特征量包括无功增量、各次电流谐波增量、各类特征峰值、电流电压曲线等<sup>[9]</sup>。基于上述事件及特征即可进行设备类型的判断以及启停事件的匹配<sup>[22]</sup>,最终得到{设备类型,启动时间,停止时间}的三元结果,如图 1 所示,基于事件检测、匹配与类型辨识后可知,5 s—220 s 为微波炉设备正在运行。

但对于电热类设备而言,由于其基于电阻丝发热的工作原理,电器启停过程是从一个稳定状态迅速过渡到另一个稳定状态,没有功率的缓变和波动,也不存在冲击,运行过程中几乎不产生无功功率和电流谐波,在进行诸如电水壶、电热水器等类别细分时存在瓶颈。尽管可以将电热设备有功功率值区间作为区分不同电热负荷的主要特征量,但对于存在功率范围重叠的电热负荷,仍然难以准确辨识。文献[23]提出了考虑电热类设备的运行时长与是否间歇运行特性用以对部分电热设备进行分类,如存在温度控制系统的电饭锅,在保温状态




图 1 事件检测与特征匹配示意

Fig.1 Event detection and feature matching

时为了将温度控制在预期值,通过不停地通断使其处于恒定温度,如图 2 所示,但该方法仅能区分单个运行周期内的负荷状态差别,仍然无法完全解决对热水壶、电热水器等设备的细分。




图 2 温控类电热设备运行示意

Fig.2 Operation diagram of temperature control electric heating equipment

针对以上情况,须要进一步从非电气特征的维度对电热类设备进行详细类别的分解。以事件检测为基础的云边协同辨识框架在用户负荷边缘侧根据有功功率与其他负荷特征信号对非电热类设备实现具体类别判断,对没有明显物理特征的电热设备直接赋电热大类,得到{设备类型,启动时间,关闭时间}三元结果后,将数据上送至主站执行云端电热二次细分。根据主站辨识数据能够长时间存储的特点,对未进行类别细分的电热大类进行长时间尺度的分析,通过运行时长、是否间歇运行、常见使用时段等统计规律信息进行二次细分辨识。

文中进行电热细分的主体框架如图 3 所示,图

中绿色部分为边缘侧辨识流程,边缘侧输出中间辨识结果后传至蓝色部分进行云端电热细分,在进行云端电热细分时要根据典型设备的常见使用规律,即先验统计模型库进行概率判别,而先验统计模型库可通过训练基于用户问卷与专家标注的负荷数据而获得。

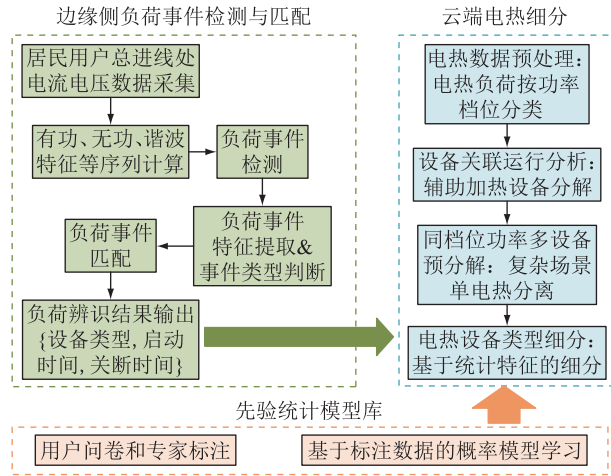


图3 基于事件检测与云端细分的负荷辨识算法

Fig.3 Load identification algorithm based on event detection and cloud subdivision

关于云端电热细分详细流程与先验统计模型库的生成将在第2章进行详细阐述,其主要分为如下三个步骤:

- (1) 预处理电热数据,获得电热负荷的功率分档;
- (2) 预分解同档位功率多设备,将功率相同的多类设备辨识结果进行拆分,以供后续运行规律特征提取;
- (3) 细分电热设备类型,构建基于统计特征的分类模型。

其中,在进行同功率档位设备预分解之前,可以先执行辅热设备的分离。由于辅热设备的判断不需要先验知识,仅分析设备运行关联性即可,因此可以优先完成辅热设备的细分进而减少可能出现的同功率档设备拆分工作的复杂度。

## 2 基于概率统计模型的云端电热细分

第2章通过对长时间尺度内的辨识结果进行二次统计分析,用以克服事件检测算法对电热类设备分类的局限性,实现设备类型细分。而对电热设备的统计分析要将同功率设备进行聚类划分,由于电热设备与电压呈平方关系,在聚类分析时需要对功率进行归一化,如式(2)所示。

$$\Delta P_{\text{std}} = \frac{\Delta P U_{\text{std}}^2}{U^2} \quad (2)$$

式中: $\Delta P$ 为负荷事件功率; $U$ 为事件发生时的电压; $U_{\text{std}}$ 为归一化时使用的标准电压,取220V。

文献[6]基于有功无功聚类的方法直接将设备进行了区分,但是实际情况中,尽管电热在经过标幺化后,由于环境温度、设备采样精度等各方面因素,单个设备的运行功率统计数据无法形成一条直线,如图4所示。这种情况下即可能发生功率相近的多个设备被聚合成一类,在进行电热细分时须要判断同一档位中是否存在多个设备,如果存在则要将同一档位中设备进行分类后再进行细分。




图4 电热设备功率分档示意

Fig.4 Power grading diagram of electric heating equipment

### 2.1 辅热负荷辨识

在电热类负荷中有一类相对特殊的电器,其本身不是独立的设备,而是其他设备的附属功能,即辅热负荷,如洗衣机、洗碗机中对水加热的装置,空调制热模式中的辅助制热装置。对于此类设备的辨识,基于用户数据进行概率统计模型分析即可,即直接分析辨识出的电热设备与洗衣机、洗碗机和空调等设备的关联关系,不需要额外的先验知识。图5展示了用户1800W功率档电热与洗衣机的运行关系关联性,每个子图表示一天24h中1800W档电热与洗衣机的运行状态,其中非0表示正在运行,0表示处于停止状态。虚线框将两者同时出现的位置进行了标注,从图中可以看出两者具有一定的关联关系,当关联关系大到一定程度时即可认为电热设备为洗衣机的附属辅热。

对辅热进行分析,以洗衣机为例,理论上洗衣机的开始时间小于电热的开始时间,电热的关闭时间大于洗衣机的关闭时间,同时考虑到洗衣机为运行功率相对较小的波动型负荷,因此在对负荷辨识中洗衣机的启停时间可能存在一定误差,洗衣机关联电热的筛选条件可以定义为式(3)。

$$\begin{cases} T_{\text{startWash}} - T_{\text{startHeat}} \leq 5 \\ T_{\text{endHeat}} - T_{\text{endWash}} \leq 2 \end{cases} \quad (3)$$

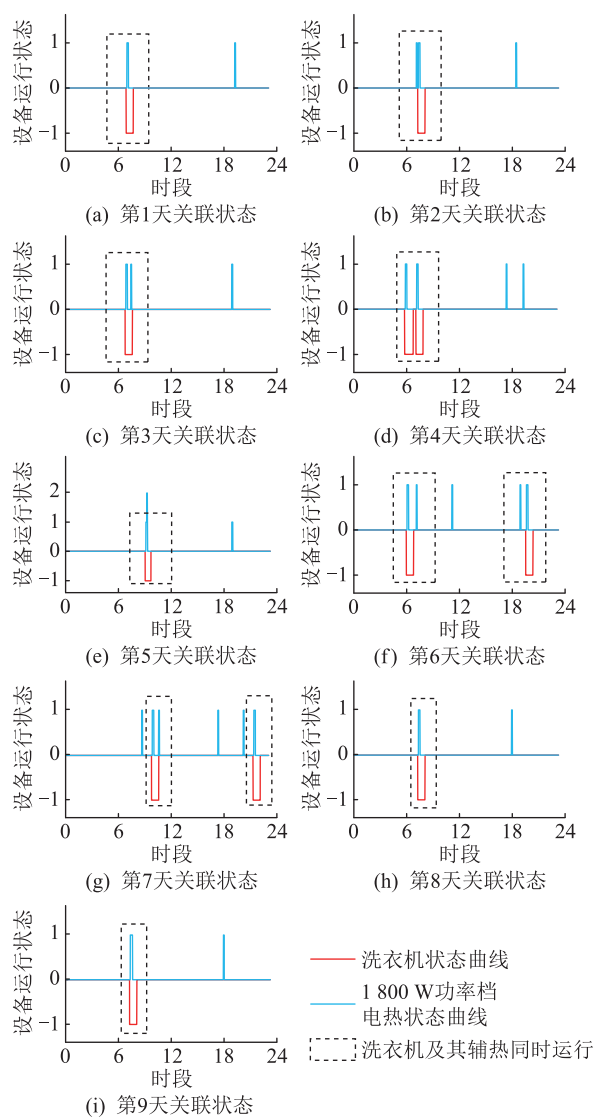


图5 设备运行关联分析

Fig.5 Equipment operation association analysis

式中： $T_{startWash}$ 、 $T_{endWash}$  分别为洗衣机的启动、关停时间； $T_{startHeat}$ 、 $T_{endHeat}$  分别为电热的启动、关停时间。

在进行辅热关联运行分析时，对前文中进行分档的电热运行集合进行逐次筛选，计算该功率档电热在洗衣机运行中出现的占比，如式(4)所示。

$$\beta = \frac{c_{heatInwash}}{c_{wash}} \quad (4)$$

式中： $c_{wash}$  为洗衣机运行总次数； $c_{heatInwash}$  为特定功率档电热满足式(3)条件的运行次数。

当 $\beta$ 大于一定的阈值时即可判断该功率档内存在洗衣机辅热，按照实际测试经验该值一般取0.3~0.4，实验中设置为0.3。特别考虑到大部分辅热设备为电器程序预设置运行，因此可以进一步分析主设备与辅热设备启动延时关系，以进一步确认辅热关系。

在完成辅热设备细分的同时，实际上也完成了

同档位多类型设备细分的部分工作，如图5中未画虚线框位置的电热数据所示，其即为分离后的另外一种或多种设备。

## 2.2 同档位多电热设备判断

对于同一个功率档的电热辨识结果中可能同时存在多个设备的情况要进一步进行分析。基于用户设备使用的规律一般即为何时使用，使用多久的基本原理，2.2节提出基于电热设备启动时间点、运行时长的二维特征分布的聚类分析方法，用以区分不同使用规律的电器设备。如图6所示，图中为某用户3个月内所有1800W功率档电水壶的使用统计分布图，横坐标为设备启动时刻，纵坐标为设备运行时长，每一个点表示一次设备运行。




图6 电水壶运行统计

Fig.6 Operation statistics of electric kettle

由图6可知，用户的水壶使用集中出现在上午、中午和晚上时间段，平均运行时长为6min左右。整体上，每个时间段内无论启动时间还是运行时间都呈现随机分布规律，其分布特征可以使用二维正态分布进行描述，如式(5)所示。

$$\begin{cases} f(x,y) = \frac{e^z}{2\pi\sigma_1\sigma_2} \\ z = -\frac{1}{2} \left[ \left( \frac{x-\mu_1}{\sigma_1} \right)^2 + \left( \frac{y-\mu_2}{\sigma_2} \right)^2 \right] \end{cases} \quad (5)$$

式中： $x$  为启动时间； $y$  为运行时长； $\mu_1$ 、 $\sigma_1$  分别为设备启动时间的均值与方差； $\mu_2$ 、 $\sigma_2$  分别为设备运行时长的均值与方差。

与对单个设备的使用规律进行描述相似，当存在多个同功率档设备时，同样可以使用上述逻辑进行区分，即为高斯混合模型(Gaussian mixture model, GMM)。高斯混合分布的基本思想为用多个高斯分布函数去近似任意形状的概率分布，所以GMM就是由多个单高斯密度分布组成的，每个分布为一组成分，这些成分线性加和即为GMM的概率密度函数。同功率档设备分类的过程即为将统计数据点看成是分布的采样点，通过采样点利用类似极大似然估计的方法估计高斯分布的参数，求出参数及得出了数据点对分类的隶属函数。

GMM的概率密度函数如式(6)所示。

$$p(x, y) = \sum_{k=1}^K \alpha_k p(x, y | \mu_{1,k}, \sigma_{1,k}, \mu_{2,k}, \sigma_{2,k}) \quad (6)$$

式中:  $K$  为模型的个数, 即聚类数量;  $\alpha_k$  为数据点属于第  $k$  个高斯的先验概率, 初始值仅须满足所有  $\alpha_k$  之和为 1;  $p(x, y | \mu_{1,k}, \sigma_{1,k}, \mu_{2,k}, \sigma_{2,k})$  为第  $k$  个高斯分布的概率密度;  $\mu_{1,k}, \sigma_{1,k}$  分别为第  $k$  类设备启动时间的均值与方差;  $\mu_{2,k}, \sigma_{2,k}$  分别为第  $k$  类设备运行时长的均值与方差。

聚类分析时,  $K$  为给定值, 其他参数通过期望最大化 (expectation-maximum, EM) 算法进行估计, 由于实际辨识结果统计数据未给出聚类数量  $K$ , 此处使用聚类评估算法<sup>[24]</sup>, 将簇间误差平方和看成是类簇数量  $K$  的函数, 在曲线“拐点”处定位到最优  $K$  数值。

图 7 展示了一种同功率档位中存在电水壶与电热水器的混合场景, 使用 GMM 自适应聚类后, 数据被切割为 4 个部分, 考虑到一个用户内的不同设备的典型运行时长不会发生太大变化, 因此通过聚类后的运行时间均值和方差参数作为不同类型设备 (或同一设备不同运行模式) 区分的条件, 如式 (7) 和式 (8) 所示。




图 7 基于 GMM 分类器的电水壶+电热水器运行聚类分析

Fig.7 Cluster analysis of electric kettle + water heater operation based on GMM classifier

$$L = (\mu_{2,i} - \mu_{2,j})^2 + (\sigma_{2,i} - \sigma_{2,j})^2 \quad (7)$$

$$F_{ij} = \begin{cases} 1 & L < l_{\text{THR}} \\ 0 & L \geq l_{\text{THR}} \end{cases} \quad (8)$$

式中:  $\mu_{2,i}, \sigma_{2,i}$  分别为第  $i$  类设备运行时长的均值与方差;  $\mu_{2,j}, \sigma_{2,j}$  分别为第  $j$  类设备运行时长的均值与方差;  $L$  为两类设备运行时长特征上的距离;  $l_{\text{THR}}$  为是否为相似设备的判断阈值, 文中取值为 50。基于此方案类 1、类 2 及类 3、类 4 被识别为两种不同类型的设备。

### 2.3 电热细分特征建模

在完成所有的同功率档统计与多设备分离的

预处理后, 即可对非辅助加热类设备进行设备类型细分。在该环节, 文中使用调研与专家标注的方式直接对负荷辨识结果细分类别进行标注, 随后通过特征构造与有监督的分类学习方法对电热设备进行细分, 具体流程如图 8 所示。

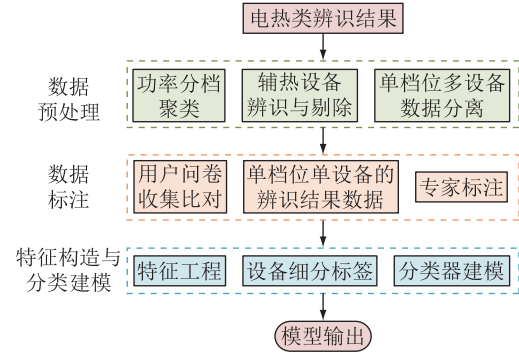


图 8 基于传统机器学习分类方法的电热设备细分建模

Fig.8 Subdivision modeling of electric heating equipment based on traditional machine learning classification method

在标注环节, 一方面结合用户参与的问卷调查内容, 另一方面结合专家的经验判断, 无需入户进行分项用电数据的采集分析, 将收集使用情况信息与辨识结果信息进行对比, 标注出某功率档设备的具体类别即可, 问卷具体内容见表 1。

表 1 电热设备使用问卷主要内容

Table 1 Main contents of questionnaire on the use of electric heating equipment

序号	内容	填写方式
1	是否使用电水壶及功率	单选、填空
2	使用电水壶时间	多选 (区间)
3	是否使用电热水器及功率	单选、填空
4	常见洗澡时间	多选 (区间)
5	是否使用小厨房及功率	单选、填空
6	是否使用电采暖及功率	单选、填空

文中细分建模选择了如表 2 中所示的特征, 同时选择了支持向量机 (support vector machine, SVM) 作为分类器进行模型训练。SVM 是一种二分类模型, 其原理是在特征空间中找到一个最大的超平面, 使得所有样本到该平面的距离最大, 在线性不可分时, 支持加入松弛变量并通过非线性映射将低维输入空间的样本映射到高维空间使其变为线性可分, 并寻找到该特征空间中寻找最优分类超平面。其在小样本情况下的分类效率, 适用于本次项目小区用户数量级别的标注样本, 以及其使用核函数方法时克服维数灾难和非线性可分的特性, 适合电热细分时构造大量特征, 因此选择 SVM 作为文中的基础分类器, 且本次 SVM 分类器选择高斯核函数

作为基础非线性映射函数。

表 2 电热设备特征列表

Table 2 Characteristics list of electric heating equipment

特征 ID	特征描述
pl	最小功率
ph	最大功率
meanP	平均功率
avgDayTimes	日均次数
minTimes	日运行次数最小值
maxTimes	日运行次数最大值
avgRuntime	次均时长
avgDayRuntime	日均时长
maxRuntimeNomerger	无合并的最大运行时长
maxRuntime	最大运行时长
mergeRate	有合并的次数占比
lower2rate	2 min 以下的次数占比
over4rate	4 min—8 min 的次数占比
over8rate	8 min 以上的次数占比
over20rate	20 min 以上的次数占比
shortTimes	短时运行次数
shortAvgRuntime	短时次均时长
shortAvgMergetimes	短时次均合并次数
shortAvgRuntimeWithmerge	有合并的短时次均时长
shortAvgRuntimeNomerger	无合并的短时次均时长
longTimes	长时运行次数
longAvgRuntime	长时次均时长
longAvgMergetimes	长时次均合并次数
longAvgRuntimeWithmerge	有合并的长时次均时长
longAvgRuntimeNomerger	无合并的长时次均时长
longAvgMergeTimesMerge	有合并的长时次均合并次数
longTimesNoMergeRate	无合并的长时次数占比
midRate	0 点—5 点使用比例
am1Rate	5 点—10 点使用比例
am2Rate	10 点—14 点使用比例
ev1Rate	16 点—20 点使用比例
ev2Rate	20 点—24 点使用比例

表 2 中提及的合并次数为一种数据预处理后的计算结果,实际定义为将相同功率关断与开启时间间隔不超过 5 min 的设备进行合并,即视此过程为一次完整运行周期的子过程,合并次数即为该过程中的合并数量。

在进行多分类问题时,要对 SVM 分类器进行一定的设计,文中选用二叉树方案进行模型构建,如图 9 以文中主要进行的电水壶、电热水器、电饭锅非辅助电热细分设备为例说明,该方案的第一步实际是一对多的方案,先将电饭锅单独作为一个类别,其余统一归为另一个类别,在这两个类别(两个树枝)之间构造 SVM1 分类器来区分。此后,以电水

壶、电热水器、其他这一类树枝节点为根节点,构造 SVM2 分类器,分出电水壶与电热水器、其他这两类次级树枝。最后,再以电热水器、其他这一类次级树枝节点为根节点,构造 SVM3 分类器,分出电热水器与其他这两类再次级树枝节点,分类过程即完成。




图 9 SVM 多分类器

Fig.9 SVM multiple classifiers

### 3 实验与分析

实验选取某负荷辨识试点应用区内的用户负荷辨识结果作为训练样本,并通过用户问卷与专家标注的形式进行标签构建,在电热细分分类模型生成后选择公开数据集 UK-DALE 作为设备细分准确性判断的测试样本,同时选择现场另一个未进行数据标注的小区进行整体的电热细分效果展示。

UK-DALE 数据集<sup>[25]</sup>为采集自英国的负荷辨识数据集,其中记录了 5 个用户总进线量测点与各个电器分项计量点的功率曲线数据,其覆盖电器包含电水壶、微波炉、冰箱、洗碗机,洗衣机等主要家用电器,但由于用户选择原因,未见电热水器设备。

实验分为三个部分,第一部分验证辅助加热型负荷的细分效果;第二部分基于已训练其他电热分类模型对电热进行分类,主要分析电水壶分类的准确性;第三部分展示基于训练模型的小区级负荷曲线分布情况,展示电热细分的能力。其中在进行前两部分的分析时,一方面定性判断文中所提方法与训练模型是否具备细分能力,另一方面定量地分析辨识的设备运行状态准确率。

电器的运行状态可被粗略地分为开启与关闭两类,对于二分类问题,F1 分数值是最常用的评估指标。由于数据集中,设备运行的时间占小部分,不运行的时间占大部分,两者存在较大的比例失衡,在此种情况下单纯计算正确率容易误判分类效果,而 F1 能有效且全面地衡量分类的准确性。

在负荷辨识问题中,标签中设备处于运行状态为正,设备处于停止状态为负。根据对真实结果与测试结果的对比,将各个样本点分为真阳性(true positive, TP),假阳性(false positive, FP),真阴性(true negative, TN),假阴性(false negative, FN),对应的样本数量分别记为  $M_{TP}$ 、 $M_{FP}$ 、 $M_{TN}$ 、 $M_{FN}$ ,则 F1 值可由式(9)一式(11)得到。

$$f_{\text{precision}} = \frac{M_{TP}}{M_{TP} + M_{FP}} \quad (9)$$

$$f_{\text{recall}} = \frac{M_{TP}}{M_{TP} + M_{FN}} \quad (10)$$

$$f_{F1} = \frac{2f_{\text{precision}}f_{\text{recall}}}{f_{\text{precision}} + f_{\text{recall}}} \quad (11)$$

式中: $f_{\text{precision}}$ 为准确率,用于衡量被辨识为运行状态样本点的实际正确率; $f_{\text{recall}}$ 为召回率,用于衡量实际为运行状态样本中判断正确的比率; $f_{F1}$ 为 F1 值,在 0 到 1 之间, $f_{F1}$ 越大,证明模型的分类效果越好。

### 3.1 辅热辨识效果分析

选取 UK-DALE 中 3 个用户进行验证,验证时使用数据集总进线数据进行基于事件检测的负荷辨识,随后基于辅热负荷辨识逻辑进行洗衣机辅热辨识。应注意的是,由于 UK-DALE 数据集仅采集了有功功率序列,因此对所有辨识结果设备进行功率聚类分析,实际洗衣机辅热的标签功率数据则同样通过基于分通道数据的事件检测算法获得。

表 3 展示了洗衣机辅热的辨识结果情况,文中所提算法识别出了电热大类中存在洗衣机辅热,且准确地分析到电热设备所在档位。其中用户 5 存在 2 个档位的洗衣机辅热,分别为 1 900 W 档和 1 400 W 档,根据数据集中关于用户 5 的描述可知,该用户洗衣机型号为洗烘一体,包含水温加热和烘干加热的两个环节的加热过程,实际运行情况如图 10 所示。

表 3 洗衣机辅热辨识情况

Table 3 Identification of auxiliary heat of washing machine

用户 ID	辨识平均功率/W	真实平均功率/W
2	2 137	2 149
4	2 050	2 043
5	1 900 W 档	1 908
	1 400 W 档	1 438

表 4 分析了洗衣机辅热运行状态辨识的 F1 情况,可以看出,所有用户的 F1 值都相对较大,辨识准确率高。从细节上看每个用户的召回值高于准确值,这意味着被错误辨识为洗衣机辅热的场景少

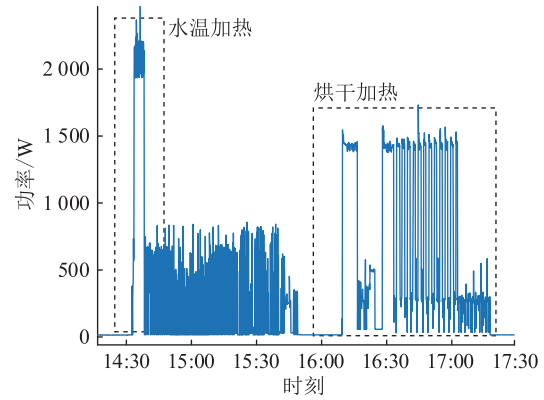


图 10 UK-DALE 用户 5 洗衣机使用模式

Fig.10 Washing machine use mode of UK-DALE user 5

于漏辨识洗衣机辅热的场景,其主要原因来自于部分初始辨识辅热受洗衣机波动负荷叠加的原因偏离了聚类区间,无法进入二次判断的集合内,进而直接引起洗衣机辅热的辨识率下降。

表 4 基于关联分析模型的洗衣机辅热辨识 F1 结果

Table 4 F1 results on identification of washing machine auxiliary heat based on association analysis model

用户 ID	$f_{\text{precision}}$	$f_{\text{recall}}$	$f_{F1}$	
2	0.91	0.93	0.92	
4	0.92	0.96	0.94	
5	1 900 W 档	0.89	0.94	0.914
	1 400 W 档	0.86	0.95	0.903

### 3.2 电水壶细分效果分析

同样选取 UK-DALE 数据集中的 3 个用户进行电水壶细分实验,实验时使用总通道的辨识数据进行电水壶细分效果分析。在进行设备细分时,同样按照模型训练过程的数据预处理方法对数据进行测试,以测试当存在部分辨识误差时,文中所提模型分类效果。表 5 展示了电水壶的电热细分效果情况,从表中结论可知,在电水壶辨识并非完全正确的场景中,分类器正确识别出了电水壶所在档位。这说明文中训练的模型存在少量错误辨识数据时,对电热细分影响不大,其主要原因为模型训练时使用的标签数据中也存在部分错误辨识结果,以及此类错误结果在特征构造与提取过程中被削减了影响度。

表 5 电水壶分类情况分析

Table 5 Analysis on classification of electric kettle

用户 ID	电水壶实际平均功率/W	该档位设备与实际电水壶比较的 F1 值	该档位是否辨识为电水壶
2	2 949	0.89	是
4	2 893	0.93	是
5	2 892	0.85	是

图 11 展示了 UK-DALE 用户 2 家中 2 900 W 功率档设备在 4 个月里的各时段累计使用频次分布图,从图 11 中可以看出,其使用规律与前文所述一致,因此在模型分类中被辨识为电水壶小类。




图 11 UK-DALE 用户 2 电水壶 96 时段累计使用频次  
Fig.11 Kettle accumulated usage frequency of UK-DALE user 2 in 96 periods

### 3.3 小区级电热负荷细分展示

选择非侵入式负荷辨识项目中的另一个试点小区作为分析样本,进行电热细分以及数据展示。该试点小区共 703 户居民,使用 2022 年 6 月份的电热辨识结果数据进行特征计算与设备类型细分,随后将所有用户各日的电热用电曲线按 24 h 分布进行累加得到如图 12 所示曲线分布。




图 12 电热细分后小区电量 24 小时分布  
Fig.12 24 hours electricity distribution in the community after electric heating subdivision

由图 12 可知,该小区的电饭锅负荷集中出现在 07:00、12:00 以及 18:00,且晚上做饭的用户频率更高;而该小区的电热水器用户使用较少,主要使用区间集中在 20:00 后,与之相反的是,该小区用户更习惯于在早上烧电水壶,且总体用电量较多。另一方面,由图 12 可知,仍有一部分电热被辨识为其他电热,这是由于此次建模中只针对电水壶、电饭锅、电热水器等进行了分析,在训练样本小区内的标注数据就有一部分其他电热设备,上述内容也是未来研究要进一步优化改进的方向,通过收集更多样本与标注,提升整体的电热细分能力。

## 4 结论

针对居民非侵入负荷辨识推广应用中国传统算法辨识能力有限、机器学习算法需要逐个定制化的现状,文中提出了一种基于事件检测与先验统计模型的非侵入式负荷辨识算法,算法无须精细化采集分析单个用户的分项设备使用数据进行训练,仅通过基于事件检测算法的用电辨识数据及用户有限的反馈信息即可实现电热类设备的细分训练,具有一定的迁移能力。在辅热分类的实验中,通过关联规律分类法实现了洗衣机辅热的细分,并取得了 F1 指标 0.9 以上的准确率;在电水壶的分类实验中,通过设备运行特征分类模型同样实现了 F1 指标平均 0.9 以上的准确分类。文中基于试点应用中收集及人工标注的用电信息,实现了小区级整体的电热设备分类,为用户电热类设备的可调潜力分析提供了理论依据。

文中在传统辨识算法的基础上尝试了云端协同改进,后续研究中将进一步增加测试样本集的数量与细分设备的种类,并形成与用户在线互动的机制,实现在线标注在线学习的功能,进一步推动居民负荷辨识的实用化应用。同时,针对群租房等多个用户使用多个相同种类电热设备的场景,仍须进一步改进优化算法以实现准确高效的辨识。

### 致谢

本文得到国网北京市电力公司科技项目“低压台区用户非介入式负荷辨识技术研究及负荷辨识关键装置研发应用”(SGBJDK00JLJS2250128)资助,谨此致谢!

### 参考文献:

- [1] ECONOMIDOU M, TODESCHI V, BERTOLDI P, et al. Review of 50 years of EU energy efficiency policies for buildings[J]. Energy and Buildings, 2020, 225: 110322.
- [2] 施雨松, 徐青山, 郑建. 基于特征选择与增量学习的非侵入式电动自行车充电辨识方法[J]. 电力系统自动化, 2021, 45(7): 87-94.  
SHI Yusong, XU Qingshan, ZHENG Jian. Non-intrusive charging identification method for electric bicycles based on feature selection and incremental learning[J]. Automation of Electric Power Systems, 2021, 45(7): 87-94.
- [3] RUANO A, HERNANDEZ A, UREÑA J, et al. NILM techniques for intelligent home energy management and ambient assisted living: a review[J]. Energies, 2019, 12(11): 2203.
- [4] HART G W. Nonintrusive appliance load monitoring[J]. Proceedings of the IEEE, 1992, 80(12): 1870-1891.
- [5] 牛卢璐, 贾宏杰. 一种适用于非侵入式负荷监测的暂态事件检测算法[J]. 电力系统自动化, 2011, 35(9): 30-35.



- NIU Lulu, JIA Hongjie. Transient event detection algorithm for non-intrusive load monitoring[J]. Automation of Electric Power Systems, 2011, 35(9): 30-35.
- [6] LIU B, ZHENG J H, LUAN W P, et al. Enhanced NILM load pattern extraction via variable-length motif discovery[J]. International Journal of Electrical Power & Energy Systems, 2023, 152: 109207.
- [7] LU M Q, LI Z Y. A hybrid event detection approach for non-intrusive load monitoring[J]. IEEE Transactions on Smart Grid, 2020, 11(1): 528-540.
- [8] ZHANG F, QU L T, DONG W, et al. A novel NILM event detection algorithm based on different frequency scales[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1-11.
- [9] 程祥, 李林芝, 吴浩, 等. 非侵入式负荷监测与分解研究综述[J]. 电网技术, 2016, 40(10): 3108-3117.  
CHENG Xiang, LI Linzhi, WU Hao, et al. A survey of the research on non-intrusive load monitoring and disaggregation[J]. Power System Technology, 2016, 40(10): 3108-3117.
- [10] 魏恩伟, 李伟华, 张之涵, 等. 基于改进匈牙利算法的非侵入式负荷匹配方法[J]. 电测与仪表, 2019, 56(22): 58-64.  
WEI Enwei, LI Weihua, ZHANG Zhihan, et al. Non-intrusive load matching method based on improved Hungarian algorithm[J]. Electrical Measurement & Instrumentation, 2019, 56(22): 58-64.
- [11] BERRETTONI G, BOURELLY C, CAPRIGLIONE D, et al. Preliminary sensitivity analysis of combinatorial optimization (CO) for NILM applications; effect of the meter accuracy [C]//2021 IEEE 6th International Forum on Research and Technology for Society and Industry (RTSI). Naples, Italy. IEEE, 2021: 486-490.
- [12] WU Z, WANG C, PENG W X, et al. Non-intrusive load monitoring using factorial hidden Markov model based on adaptive density peak clustering[J]. Energy and Buildings, 2021, 244: 111025.
- [13] MAKONIN S, POPOWICH F, BAJICI V, et al. Exploiting HMM sparsity to perform online real-time nonintrusive load monitoring[J]. IEEE Transactions on Smart Grid, 2016, 7(6): 2575-2585.
- [14] GUO Z Y, WANG Z J, KASHANI A. Home appliance load modeling from aggregated smart meter data[J]. IEEE Transactions on Power Systems, 2015, 30(1): 254-262.
- [15] 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. New York: ACM, 2015: 55-64.
- [16] 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 LSTM model[J]. Electrical Measurement & Instrumentation, 2019, 56(23): 62-69.
- [17] ZHOU G, LI Z, FU M, et al. Sequence-to-sequence load disaggregation using multiscale residual neural network[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-10.
- [18] 欧阳福莲, 王俊, 周杭霞. 基于改进迁移学习和多尺度 CNN-BiLSTM-Attention 的短期电力负荷预测方法[J]. 电力系统保护与控制, 2023, 51(2): 132-140.  
OUYANG Fulian, WANG Jun, ZHOU Hangxia. Short-term power load forecasting method based on improved hierarchical transfer learning and multi-scale CNN-BiLSTM-Attention[J]. Power System Protection and Control, 2023, 51(2): 132-140.
- [19] ZHOU Z J, XIANG Y M, XU H, et al. A novel transfer learning-based intelligent nonintrusive load-monitoring with limited measurements[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-8.
- [20] D'INCECCO M, SQUARTINI S, ZHONG M J. Transfer learning for non-intrusive load monitoring[J]. IEEE Transactions on Smart Grid, 2020, 11(2): 1419-1429.
- [21] 刘西昂, 周赣, 徐欣, 等. 基于三维特征向量的非侵入式电热负荷细分算法[J]. 电力工程技术, 2021, 40(6): 150-156, 192.  
LIU Xi'ang, ZHOU Gan, XU Xin, et al. Non-intrusive load detailed disaggregation algorithm for electrothermal load based on three dimensional characteristics vector[J]. Electric Power Engineering Technology, 2021, 40(6): 150-156, 192.
- [22] QURESHI M, GHIAUS C, AHMAD N. A blind event-based learning algorithm for non-intrusive load disaggregation[J]. International Journal of Electrical Power & Energy Systems, 2021, 129: 106834.
- [23] 李琦. 非侵入式三相负荷建模及辨识算法研究[D]. 南京: 东南大学, 2018.  
LI Qi. Research on non-invasive three-phase load modeling and identification algorithm[D]. Nanjing: Southeast University, 2018.
- [24] SHI Y, YU T, LIU Q J, et al. An approach of electrical load profile analysis based on time series data mining[J]. IEEE Access, 2020, 8: 209915-209925.
- [25] KELLY J, KNOTTENBELT W. The UK-DALE dataset, domestic appliance-level electricity demand and whole-house demand from five UK homes[J]. Scientific Data, 2015, 2: 150007.

#### 作者简介:



赵成

赵成(1982),男,硕士,高级工程师,从事电能计量相关工作(E-mail:sjzlzxbj@163.com);  
宋彦辛(1994),男,硕士,助理工程师,从事电能计量相关工作;  
周赣(1978),男,博士,副教授,研究方向为电工技术与新理论。

(下转第 211 页)

## Closing action characteristics of the electromagnetic mechanism of the parallel double coil type DC contactor

YAN Chengyang, WANG Lijun, ZHANG Wenzhe, HUANG Yifan, WANG Kai

(Xi'an Jiaotong University (State Key Laboratory of Electrical Insulation and Power Equipment), Xi'an 710049, China)

**Abstract:** DC contactor is one of the most widely configured switching appliances in new energy systems and electric vehicles. The dynamic characteristic of DC contactor is one of the important indexes to measure the performance of DC contactor. A dynamic model of the electromagnetic mechanism of DC contactor with parallel double coil type is established in this paper. Dynamical model of the electromagnetic mechanism of DC contactor is simulated. The closing process simulation analyzed of the electromagnetic mechanism of DC contactor by using the co-simulation research method based on Adams and Maxwell. The research results show that the simulation closing time of the closing action the mechanism is consistent with the test closing time. The correctness of the simulation method is verified. At the same time, the influence of spring parameters, coil parameters and other factors on the closing motion characteristics of the mechanism is studied. The change of spring pre-pressure has little influence on the closing time within a certain range. The increase of coil ampere turns will lead to the decrease of closing time, the increase of coil internal resistance will lead to the increase of closing time and the more severe bouncing of moving contact. The simulation method and results can provide some reference for the improvement design and optimization of DC contactor electromagnetic mechanism.

**Keywords:** DC contactor; parallel double coil type; electromagnetic mechanism; closing action; dynamic simulation; electromagnetic coupling

(编辑 吴昊)

(上接第 173 页)

## Resident non-invasive load identification algorithm based on prior statistical model

ZHAO Cheng<sup>1</sup>, SONG Yanxin<sup>1</sup>, ZHOU Gan<sup>2</sup>, FENG Yanjun<sup>2</sup>, GUO Shuai<sup>1</sup>, LI Jiwei<sup>1</sup>

(1. State Grid Beijing Electric Power Company Electric Power Research Institute, Beijing 100080, China;

2. School of Electrical Engineering, Southeast University, Nanjing 211189, China)

**Abstract:** In this paper, a non-intrusive load identification algorithm for residents based on prior knowledge and statistical learning model is proposed to solve the problem of insufficient electric heating subdivision capability in traditional identification technology. In this paper, the electric heating subdivision research is carried out for the auxiliary heating equipment of washing machine, electric kettle, electric rice cooker, electric water heater. The subdivision of auxiliary heating equipment is realized through the equipment operation association algorithm, and the model training of non-auxiliary heating equipment classification is realized based on the limited feedback information of users and expert annotation. The experimental results show that the technical framework proposed in this paper realizes the subdivision of electric heating equipment on the basis of the event detection load identification algorithm and F1 score above 0.9 is achieved in the decomposition of operation state.

**Keywords:** non-intrusive load monitoring (NILM); event detection; subdivision of electric heating equipment; statistical analysis; Gaussian mixture model (GMM); support vector machine (SVM)

(编辑 李栋)