

# 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

李 想<sup>1</sup>, 刘宇航<sup>1</sup>, 张 琪<sup>2</sup>, 武 昕<sup>1</sup>

(1. 华北电力大学电气与电子工程学院, 北京市 102206; 2. 国家节能中心, 北京市 100045)

**摘要:** 电动自行车违规入户充电行为具有时间随机性以及空间隐蔽性, 存在较大安全隐患且难以有效管理。利用非侵入式监测系统具有实时自主执行和便捷易推广的特性, 文中提出了基于小波检测和特征图谱决策的非侵入式电动自行车充电实时监测系统。考虑电动自行车负荷的物理结构和充电特性, 从暂态和稳态两方面分析电动自行车负荷的典型共性特征; 预先构建具有强可分性和通用性的电动自行车专有特征图谱实现电动自行车稳态共性特征的一致性结构化表征; 实际监测过程中, 为了降低系统的算力需求和数据传输压力, 基于小波变换精确定位具有高频分量的电动自行车专有暂态现象完成类电动自行车充电事件检测。最后, 提取事件波形并通过图谱训练高效分类器进行负荷认定并实时上传。通过对实际用户进行监测, 验证了监测系统的有效性, 可以有效解决电动自行车进楼入户充电的问题。

**关键词:** 非侵入式负荷监测; 特征图谱; 电动自行车; 充电行为; 小波变换; 支持向量机

## 0 引言

随着城市居民的出行需求与交通堵塞、环境污染等现象之间的矛盾逐渐凸显, 电动自行车(electric bicycle, EB)因其灵活易驾乘、低碳低成本且不需要投入巨资建设支持性设施等特点快速发展, 并成为城市交通道路中不可或缺的交通工具。在社会保有量达到近3亿辆<sup>[1]</sup>的同时, EB的充电管理问题面临巨大挑战。虽然城中村及住宅小区逐渐普及安装了集中式充电站, 但因其存在数量不足、分布不合理、维护不及时以及用户认可度低等问题, 居民更倾向在家中或街道上私拉电线进行充电<sup>[2]</sup>, 由此引发的火灾事故逐年攀升。据统计, EB引起的火灾已占社会总体火灾的10%<sup>[3]</sup>。其中90%的火灾是充电不当引起的<sup>[4]</sup>。

传统的解决室内充电问题的方法是人工监管、案例宣传等, 存在成本高、效率低、成效差等问题。通过人工智能(AI)摄像头识别EB影像虽然对EB入户行为有较好的监控效果, 但是无法避免私拉电线以及电池入户等行为, 且设备安装和维护成本高, 不易大规模推广。非侵入式负荷监测(non-intrusive load monitoring, NILM)技术在用户电力入

口处采集总电流电压进行分析以得到用电信息。考虑到违规充电的随机性、隐蔽性, 非侵入式负荷监测在不干扰用户的前提下从源头实时监测各种形式的充电行为, 避免用户意愿对设备普及的影响。可以大幅降低硬件和维护成本, 并且向监管部门发出报警信息, 及时提醒用户的违规操作, 为隐患排查提供参考依据, 对城市火灾事故预防具有重要意义。

目前, 国内外针对负荷监测中事件检测、特征提取、负荷辨识等关键技术已有较多研究。文献[5]提出了基于二分递归奇异值分解(single value decomposition, SVD)的居民电器开关事件检测方法。文献[6]利用负荷事件发生时特征空间内产生状态域转移的特性, 提出状态特征聚类事件检测方法。文献[7]基于小波变换的多分辨率分析从时频域进行事件检测, 但目前, 事件检测大多无法实现在混合电流中对单类负荷进行针对性的事件检测。特征提取是将原始数据转化为有意义的信息的过程。目前, 文献大多考虑功率<sup>[8]</sup>、暂态特征<sup>[9-10]</sup>、电压-电流( $U-I$ )轨迹<sup>[11-12]</sup>、谐波<sup>[13]</sup>等典型特征以及多特征融合<sup>[14]</sup>来实现负荷辨识。特征融合可以实现负荷信息的最优整合, 具有较大的应用前景。目前, 人工智能技术已应用于负荷辨识, 如隐马尔可夫模型<sup>[15]</sup>、支持向量机(support vector machine, SVM)<sup>[10, 16]</sup>、深度学习<sup>[17-18]</sup>、贝叶斯分类模型<sup>[19]</sup>等。SVM因具有较高的准确率以及鲁棒性成为有前途的非侵入式负荷监测分类器。

收稿日期: 2023-04-25; 修回日期: 2023-06-13。

上网日期: 2023-09-12。

国家电网公司科技项目(5100-202113564A-0-5-SF); 中央高校基本科研业务费专项资金资助项目(2020MS002)。

以上研究是对常见家用负荷的无差别化辨识,为解决实际问题,一些学者对单类负荷的非侵入式监测也进行了研究。文献[8]构造了空调负荷特征向量的模型,文献[20]分析空调机组以及电动汽车充电行为。文献[21]基于特征选择与增量学习实现EB负荷辨识,但此方法仅考虑了线路空载时单负荷接入场景,没有在实际应用场景中验证算法的效果,不适用于多负荷混杂的实际场景中。

本文提出一种非侵入式EB充电实时监测系统。该系统对EB充电功率信号进行小波变换,通过分析暂态特性实现类EB的事件检测,在进行针对性检测的同时降低计算量;基于知识图谱实现对EB稳态特性的一致化表征,通过EB专有负荷特征图谱训练EB的SVM分类器,实现EB负荷的最终认定与上传。最后,通过对实际用户进行设备安装及监测,验证了监测系统算力需求低、通用性强、实时性及准确率高的优势。

## 1 非侵入式EB充电监测原理

### 1.1 非侵入式负荷监测原理及系统结构

非侵入式负荷监测在电力入口处主动采集用电信息并实时处理分析用电行为,可以监测如电池入户、私拉电线等各种形式的EB入户充电行为。其不接触用户自动实施的优点则保障了监测过程的执行度以及实时性。

特征提取是负荷监测的关键步骤之一。为了满足对不同品牌、型号、运行环境下的EB负荷的通用性以及对其他负荷的可分性,在特征提取过程中,考虑EB负荷代表性稳态特征;在前期训练过程中,构建结构化的EB专有负荷特征图谱对特性进行专有知识表达,以训练专有分类器,并将图谱和分类器作为负荷辨识的数据支撑存入非侵入监测终端,从而满足了对大量用户监测时执行过程的主动性、通用性、自动性以及无干扰性。

在实时监测过程中,采用高频采集方式以获取未知事件全方位的细节特征信息。由于家用电器种类繁多,负荷开断情况复杂,为了降低监测系统计算量,研究了基于小波变换的类EB的事件检测方法。考虑到EB负荷开启时典型暂态变化,利用小波变换对未知负荷进行类EB负荷事件检测。将提取的事件波形通过EB专有特征图谱以及SVM分类器实现最终认定。非侵入式采集终端立即报警并上传至云平台,便于电力用户通过该系统实时获取EB入户的安全用电信息。监测系统结构如图1所示。

各类用电负荷都有其独特的运行特性,为了建立针对EB的非侵入式负荷监测系统,需对EB充电

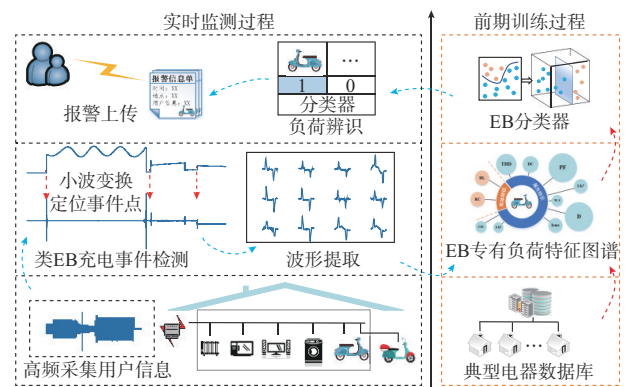


图1 非侵入式负荷监测系统结构  
Fig. 1 Structure of non-intrusive load monitoring system

特性进行一致化表征。从暂态特性、稳态特性两方面对EB充电行为进行描述,并以此完成基于暂态特性的小波变换检测以及基于稳态特性的知识图谱辨识。

### 1.2 EB充电原理

EB一般采用开关电源式充电器,其内部由整流滤波、高压开关、电压变换、恒流恒压充电控制等部分组成;采用智能三段式充电,包括恒流阶段、恒压阶段和涓流阶段。

由附录A图A1可知,采集装置接入位置是市电与充电器之间,不会对市电电压造成很大的影响,采集电压为恒压。开始整流滤波时电容器电压不能跃变,而整流器上的滤波电容几乎为零,产生很高的浪涌电流。其大小取决于输入电压的幅值以及回路总电阻。由于蓄电池在初期可能已处于深度放电状态,为了避免热失控,先进行稳定的小电流充电,然后转入恒流充电阶段,采集到的EB充电电流电压如附录A图A2所示。

为了保证入户监测的实用性,提出的EB入户充电监测系统优势在于能够利用EB接入后几十秒内的暂稳态特性完成事件监测并报警。在研究过程中,仅需要考虑接入后很短时间的电压电流特性。

### 1.3 基于暂态特性的小波变换检测原理

负荷的操作会体现在其运行波形的统计特性上,通过检测波形统计特性发生变化的时间点,从而能够得到负荷运行状态信息。各类家用负荷在投切时均表现出独特的暂态特性如图2(a)所示。通过分析负荷的暂态特性能够在混合波形中有效定位特定负荷投切事件。

如图2(b)所示,EB在接入电路时有明显的暂态变化,其瞬时功率峰值较高,开启有短时的脉冲与延迟时间,然后进入平稳运行状态。为在混合波形中准确定位EB充电事件,对EB充电过程中的暂态

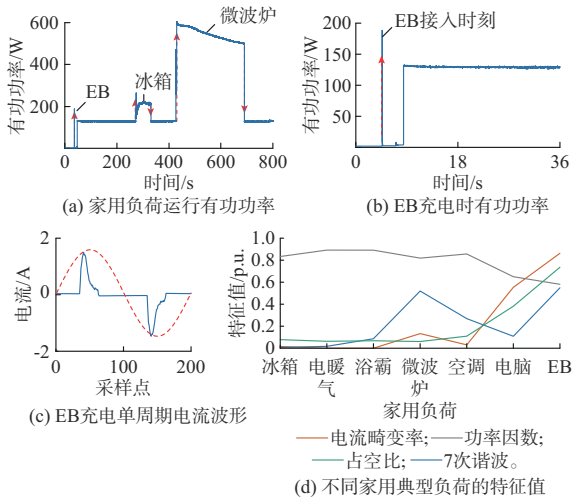


图2 家用负荷运行数据  
Fig. 2 Operation data of household loads

特性进行一致化表征。对于给定的EB充电功率信号观测值序列 $P(t)$ ,假定状态序列 $H_0, H_1, H_2$ 分别服从模型 $M_0, M_1$ 和 $M_2$ ,针对上述EB充电的暂态特性,将 $P(t)$ 归纳为如下模型。

$$\begin{cases} H_0: P(0), P(1), \dots, P(t_1 - 1) \sim M_0 \\ H_1: P(t_1), P(t_1 + 1), \dots, P(t_2 - 1) \sim M_1 \\ H_2: P(t_2), P(t_2 + 1), \dots, P(T_1) \sim M_2 \end{cases} \quad (1)$$

式中: $t_1, t_2$ 分别为EB接入电路时 $P(t)$ 的两个突变时刻;时间间隔 $\Delta t = t_2 - t_1$ ;  $T_1$ 为采样周期数。

由于EB接入时,时域和频域均会产生短暂的突变信号,为得到EB充电数据信息,本文引入小波变换定位功率信号中的类EB接入事件。小波变换是一种时频分析方法,可以检测信号的频域信息,且能够在时间域对不同频率的信号精准定位。由于实际采样信号往往是离散的,对于给定的 $P(t)$ ,可通过多尺度离散小波变换对其进行多层分解,得到低频和高频分量,其中,第 $m$ 层低频信号 $P_m(t)$ 小波分解为:

$$P_m(t) = \sum a_{m,t} \phi_m(t) + \sum d_{m,t} \varphi_m(t) \quad (2)$$

式中: $\sum a_{m,t} \phi_m(t)$ 为低频分量; $\sum d_{m,t} \varphi_m(t)$ 为高频分量; $\phi_m(t), a_{m,t}$ 分别为尺度函数和其对应的系数,即低频系数; $\varphi_m(t), d_{m,t}$ 分别为小波函数和其对应的系数,即高频系数。

信号突变点处的高频分量较丰富。因此,该点处高频系数也会产生突变。以对 $P(t)$ 做三层小波变换为例,如附录A图A3所示,EB接入产生的两个突变点 $t_1, t_2$ 对应多尺度小波分解高频系数的局部极大值点,高频系数的模值反映信号的突变,与信号幅值没有必然联系。因此,在不同负荷开断会存在时

间差<sup>[22]</sup>的前提下,即使是混杂在大功率信号中某时刻产生的EB充电信号变化,仍能通过小波变换检出。因此,可以通过式(3)准确定位负荷投切的时间点。

$$\Delta d_{m,t} = d_{m,t+1} - d_{m,t} \geq \sigma \quad (3)$$

式中: $\Delta d_{m,t}$ 为第 $m$ 层小波分解高频系数的一阶差分; $\sigma$ 为 $\Delta d_{m,t}$ 的阈值。

将多尺度小波变换用于检测功率信号中的类EB充电事件,可用分解后的高频系数重构功率信号,分析其瞬时变化,能够精确检测和定位信号中具有高频分量的瞬态现象。

#### 1.4 基于稳态特性的知识图谱辨识原理

虽然EB数目庞杂且其电流电压波形随品牌、型号、使用环境和习惯的变化而变化,但是无序杂乱的电流中仍然包含着EB负荷固有的稳态特性信息。采集不同品牌、不同损耗程度和电池型号的EB数据,如附录A图A4所示,并分析其稳态特性。图2(c)和图2(d)分别展示了EB充电进入稳态后的典型电流单周期波形图以及不同家用典型负荷的特征值比较。

考虑到EB的电流波形失真程度较大,重点分析能体现电流波形形状的电参数特征,从图2(d)中可以看出,EB负荷具有功率因数低,电流畸变率、7次谐波和占空比高等强可分性特征,与不同家用负荷有明显区别,可以作为共性特征为EB负荷的辨识提供重要依据。

为了对EB负荷稳态单周期过程中的共性特征进行抽取归纳和一致化表征,采用自下而上的方式对底层数据依次进行信息抽取、特征融合、知识加工3个核心步骤,形成结构化特征体系,构建EB专有负荷特征图谱。将EB和其他负荷作为图谱的个体,从非结构化或半结构化的数据中进行特征抽选形成图谱的个体-属性特征集合 $L$ 为:

$$L = \{d_j | j = 1, 2, \dots, J_0\} \quad (4)$$

式中: $J_0$ 和 $d_j$ 分别为初选特征数量以及特征值。

为了形成高区分度、低冗余度的特征集合,解决属性特征之间存在信息重叠、关系扁平化等问题,对属性特征集合进行优化融合。从大量备选属性 $d_j$ 中进行特征抽选形成新的特征集合 $L^{\sim}$ 为:

$$L^{\sim} = \{d_j | j = 1, 2, \dots, J_1\} \quad j = 1, 2, \dots, J_1 \quad (5)$$

式中: $J_1$ 为经过抽选后的特征数。此时,对于EB负荷具有高区分度的特征被抽选出。

不同的属性特征对分类的重要程度不同,为了充分发挥各特征的优势,对每个属性特征赋权,衡量其在分类中的重要程度。构建特征对于EB负荷的

关系及各特征的重要程度的量化模型,以高区分度为目的,对筛选特征进行知识加工得到权重系数向量  $K$ 。

$$K = [k_1, k_2, \dots, k_j, \dots, k_{j_1}] \quad (6)$$

式中:  $k_j$  为反映抽选特征表征重要度的系数。

若此特征在众 EB 波形中表现一致,且与其他家用电器有较高的区分度,则  $k_j$  值较高。

在构建 EB 专有知识图谱后,EB 的稳态特性从原始空间映射到高维特征空间进行一致化表征。

$$SC_{EB} = f(d_1 k_1, d_2 k_2, \dots, d_j k_j, \dots, d_{j_1} k_{j_1}) \quad (7)$$

式中:  $SC_{EB}$  为基于稳态特性的知识图谱判定依据;  $f(\cdot)$  为知识图谱的表征函数。

由于 EB 专有知识图谱形成的特征空间维数较高,可将高维空间的最优分类问题转化为寻找最优超平面问题。SVM 在解决小样本、非线性及高维模式识别中具有显著优势。SVM 找到的为全局最优解,对实际监测过程中的未知样本有较好的泛化能力。由此训练的 SVM 辨识分类器对 EB 负荷的共性特征利用率更高,从而完成 EB 负荷最终的认定。

## 2 非侵入式 EB 监测实现方法

基于上述 EB 监测整体实施结构,本章主要介绍实际监测过程中的实现方法,分为类 EB 充电行为实时检测与提取以及 EB 负荷的最终认定与上传两部分。

### 2.1 类 EB 充电行为实时检测与提取

为获取详细的 EB 充电数据信息,需要从总采集数据中分离出类 EB 充电事件波形。因此,本节首先基于暂态特性分析,利用小波变换定位类 EB 负荷投入事件的突变点;其次,提取类 EB 充电事件的稳态电压、电流波形,用于 EB 充电事件认定。

#### 2.1.1 基于小波变换的类 EB 充电行为检测

EB 接入电路时,有功功率信号会产生两个时间间隔在一定范围内的突变点。本文采用 db4 小波函数对有功功率信号进行多尺度小波变换,通过分解后的高频分量获取与 EB 充电事件相关的暂态特征分量。

经过多尺度小波分解后,对各层细节系数求一阶差分,通过设定细节系数差分值的阈值对突变点进行筛选。基于 EB 接入电路时的暂态特征,当检测信号中存在满足式(8)的两个突变时刻  $t_1$  和  $t_2$ ,初步判定其为类 EB 充电事件。

$$\begin{cases} |d(t_1)| > \sigma_1 \\ d(t_2) > \sigma_2 \end{cases} \quad t_2 - t_1 \in [\delta_1, \delta_2] \quad (8)$$

式中:  $d(t_1)$  和  $d(t_2)$  分别为有功功率信号在  $t_1$  和  $t_2$  时

刻小波变换细节系数的一阶差分;  $\sigma_1$ 、 $\sigma_2$  分别为  $d(t_1)$  和  $d(t_2)$  的阈值。

由于小波变换对瞬时特性的敏感性,所检出事件中包含大量非 EB 充电事件,为减少后续负荷事件认定的计算耗时,本文从 EB 接入电路后进入稳定状态的有功功率增量和负荷运行状态两方面对定位事件进行事件筛选。

1) 以有功功率增量为阈值判断突变点是否为类 EB 负荷投入点,取突变点前后  $m_1$  个周期的有功功率值,计算突变点前向有功功率  $P_{\text{mean}}^-$  和后向有功功率  $P_{\text{mean}}^+$ ,有功功率增量  $\Delta P$  由式(9)求得。

$$\begin{cases} \Delta P = P_{\text{mean}}^+ - P_{\text{mean}}^- \\ P_{\text{mean}}^\mp = \frac{\sum_{i=1}^{m_1} P_{t_2 \mp i}}{m_1} \end{cases} \quad (9)$$

式中:  $P_{t_2 \mp i}$  为突变点  $t_2$  前或后第  $i$  个周期的有功功率。若  $\Delta P$  满足式(10),则判定其为负荷投入点。

$$\sigma_3 \leq \Delta P \leq \sigma_4 \quad (10)$$

式中:  $\sigma_3$ 、 $\sigma_4$  分别为  $\Delta P$  的上、下限阈值。

2) 由于间断运行负荷具有周期性变化的特点,在较短时间内会检测到多个具有相似特征的突变点。若满足式(11)则判定为间断运行负荷,不对与 EB 连续运行状态不符的间断运行负荷投入点进行后续的负荷辨识。

$$\begin{cases} \Delta P(t_3) - \Delta P(t_4) \leq \sigma_5 \\ V(T_s) \geq V_1 \end{cases} \quad (11)$$

式中:  $\Delta P(t_3)$ 、 $\Delta P(t_4)$  分别为某两个突变点处功率增量;  $\sigma_5$  为判断突变点是否相似的阈值;  $V(T_s)$  为  $T_s$  间隔内检测到相似突变点的个数;  $V_1$  为大于 2 的整数阈值。

#### 2.1.2 类 EB 充电事件提取

为提取事件独立运行的电流、电压单周期波形用于后续负荷辨识,需要截取事件点前后稳态的单周期电压、电流波形并作运算。截取时满足电流叠加性,即在前后稳态电压初始相位相同的时刻截取一个完整周期。利用过零点检测的方法,设置电压的初始相位为零,寻找呈上升趋势的电压过零点,如式(12)所示。

$$\begin{cases} u(x) > 0 \\ u(x-1) < 0 \end{cases} \quad (12)$$

式中:  $u(x)$  为第  $x$  个采样点的电压值。以此采样点为初始点提取电压、电流的单周期波形。

由于 EB 接入时有短时的脉冲和延迟时间,需要利用上述方法提取事件发生突变时刻  $t_2$  前后的稳态单周期电流波形分别为  $I_{\text{front}}(t_2)$  和  $I_{\text{back}}(t_2)$ 。根据

电流叠加原理,可通过式(13)得到负荷的稳态单周期电流波形 $I(t_2)$ ,其稳态电压波形 $U(t_2)$ 则可根据事件发生后的电流波形对应时刻的电压波形 $U_{\text{back}}(t_2)$ 提取得到,有

$$\begin{cases} I(t_2) = I_{\text{back}}(t_2) - I_{\text{front}}(t_2) \\ U(t_2) = U_{\text{back}}(t_2) \end{cases} \quad (13)$$

## 2.2 EB 负荷的最终认定与上传

为实现EB负荷的一致化表征,基于稳态特性分析构建EB专有负荷特征图谱,训练专有SVM分类器,准确辨识EB负荷。

### 2.2.1 EB 稳态特性的一致化表征

#### 1) 底层信息抽取

知识图谱由多个交叠的三元组组成,包含本体,属性以及两者之间的关系。将EB负荷作为本体,能够刻画EB负荷的通用特征作为属性信息。分别从波形数据以及负荷运行规律中统计电气特征与实体特征组成属性信息。由于EB负荷电流波形失真程度较大,除基本电气参数外,考虑能体现电流形状的参数,如电流畸变率、占空比和高次谐波分量等共同组成电参特征。初步选取电气参数特征集合记作 $L_p$ ,如附录A表A1所示。

实体特征描述EB本身的功能特性以及用户的操作习惯。EB充电波形均具有较大的畸变,决定了EB属于非线性负荷。EB充电满足三段式规则,电流连续且并不会出现周期性变化。因此,考虑非线性负荷(non-linear, NL)和连续负荷(consistent load, CL)两个特征构成实体特征集合 $L_e$ 。所有抽选特征集合 $L$ 如下:

$$L = L_p \cup L_e \quad (14)$$

#### 2) 特征优化融合

由于电气参数特征是由波形数据逻辑运算得出,存在数据之间信息重叠、关系扁平化等问题。为了选出具有良好可分性的电气参数特征集合,通过类内、类间散布矩阵抽选 $J_1$ 种特征形成最优电气参数特征集。设共有 $N$ 类负荷,待分类负荷样本特征向量集 $\mathbf{A}$ 为:

$$\mathbf{A} = \{Y_{n,1}, Y_{n,2}, \dots, Y_{n,\alpha}, \dots, Y_{n,A_n}\} \quad (15)$$

式中: $\{Y_{n,\alpha} | \alpha = 1, 2, \dots, A_n; n = 1, 2, \dots, N\}$ 为总样本集中的样本特征向量,其中, $\alpha$ 为每个样本在该类负荷中的序号, $A_n$ 为该类负荷样本总数, $n$ 为负荷样本的类别序号。

设 $P_n$ 为相应负荷类别的先验概率, $\mathbf{M}$ 为所有负荷样本集的总平均向量,即

$$\mathbf{M} = \sum_{n=1}^N P_n \mathbf{M}_n \quad (16)$$

式中: $\mathbf{M}_n = 1/A_n \sum_{\alpha=1}^{A_n} Y_{n,\alpha}$ 为第 $n$ 类负荷样本均值向量。

则第 $n$ 类负荷的类内散布矩阵 $\mathbf{S}_n$ 、总体的类内散布矩阵 $\mathbf{S}_w$ 以及类间散布矩阵 $\mathbf{S}_B$ 分别为:

$$\begin{cases} \mathbf{S}_n = \sum_{\alpha=1}^{A_n} [(Y_{n,\alpha} - \mathbf{M}_n)(Y_{n,\alpha} - \mathbf{M}_n)^T] \\ \mathbf{S}_w = \sum_{n=1}^N P_n \mathbf{S}_n \\ \mathbf{S}_B = \sum_{n=1}^N [P_n (\mathbf{M}_n - \mathbf{M})(\mathbf{M}_n - \mathbf{M})^T] \end{cases} \quad (17)$$

设类内类间距离判据 $J$ 为:

$$J = \frac{\text{trace}(\mathbf{S}_B)}{\text{trace}(\mathbf{S}_w)} \quad (18)$$

式中: $\text{trace}(\mathbf{X})$ 表示求矩阵 $\mathbf{X}$ 对角线上元素之和。

通过改变特征种类可以寻找 $J$ 值的局部最优,通过遍历可选特征总数可以寻找 $J$ 值的全局最优。 $J$ 值越大代表所选特征的分类能力越好。此时,对应的属性特征集合即为特征优化融合的结果。

#### 3) 特征知识加工

从图2(d)可以看出,不同特征对EB负荷的区分度不同。利用熵权法量化不同特征对EB负荷的表征程度并重新分配各特征占比,进而强化EB专有特征图谱对EB负荷的一致化表征。其中,实体特征作为功能性特征可以确定负荷类型从而缩小负荷类别所选范围,具有唯一性,无须进行特征融合以及权重量化。信息熵越小,说明该特征对应的样本值集中,对于EB负荷具有更强的共性,赋予其较大权重。

对EB负荷的 $J_1$ 种特征进行赋权,设此EB负荷共有 $A_{\text{EB}}$ 个样本,其中,第 $j$ 个特征的熵值 $h_j$ 可以用下式表示。

$$\begin{cases} h_j = -\frac{1}{\ln A_{\text{EB}}} \sum_{\alpha=1}^{A_{\text{EB}}} f_{j\alpha} \ln f_{j\alpha} \\ f_{j\alpha} = \frac{v_{j\alpha}}{\sum_{\alpha=1}^{A_{\text{EB}}} v_{j\alpha}} \end{cases} \quad (19)$$

式中: $j = 1, 2, \dots, J_1; v_{j\alpha}$ 为该电参特征的真实值; $f_{j\alpha}$ 为第 $\alpha$ 个样本的第 $j$ 个特征对应的信息熵因子。

因此,该特征的权重可以用对应的信息熵表示为:

$$k_j = \frac{\sum_{j=1}^{J_1} (1 - h_j)}{(1 - h_j) \sum_{j=1}^{J_1} \frac{1 - h_j}{1 - h_j}} \quad (20)$$

在重新分配特征权重完成知识加工后即可得到最终的EB专有特征图谱。

### 2.2.2 SVM分类器训练

用知识图谱信息抽取后的带标签样本训练SVM分类器,通过非线性函数 $\Phi(x)$ 对输入数据 $x$ 进行映射,在变换后的空间寻找能将负荷特征数据分割的最优分类超平面,其具有以下形式: $\lambda\Phi(x)+B=0$ 。有监督的训练超平面核参数可以转化为参数优化问题:

$$\begin{cases} \min \frac{\|\lambda\|^2}{2} \\ \text{s.t. } y_p(\lambda\Phi(x_p)+B) \geq 1 & y_p = 1 \\ y_p(\lambda\Phi(x_p)+B) \leq -1 & y_p = 0 \end{cases} \quad (21)$$

式中: $p=1,2,\dots,N_s,N_s$ 为训练样本个数; $\lambda$ 和 $B$ 为超平面的参数; $y_p=\{0,1\}$ 为样本 $x_p$ 的类别,0代表“非”该负荷,1代表“是”该负荷。优化问题的对偶拉格朗日函数 $L_D$ 及约束如式(22)所示。

$$\begin{cases} \max L_D = \sum_{p=1}^{N_s} \alpha_p - \frac{1}{2} \sum_{p,q} \alpha_p \alpha_q y_p y_q \Phi(x_p) \Phi(x_q) \\ \text{s.t. } \sum_{p=1}^{N_s} \alpha_p y_p = 0 & \alpha_p \geq 0 \end{cases} \quad (22)$$

式中: $\alpha_p$ 为拉格朗日乘子。通过二次规划技术得到 $\alpha_p$ 后,利用式(23)、式(24)确定超平面的参数 $\lambda$ 和 $B$ 。

$$\lambda = \sum_p \alpha_p y_p \Phi(x_p) \quad (23)$$

$$B = y_p - \sum_p \alpha_p y_p \Phi(x_p) \Phi(x_q) \quad (24)$$

利用高斯核函数避免高维运算,令 $K(x_p, x_q) = \Phi(x_p) \Phi(x_q) = \exp(-|x_p - x_q|^2 / \sigma_6^2)$ ,其中, $\sigma_6$ 为模型控制参数,式(22)中优化函数转变为:

$$\max L_D = \sum_{p=1}^{N_s} \alpha_p - \frac{1}{2} \sum_{p,q} \alpha_p \alpha_q y_p y_q K(x_p, x_q) \quad (25)$$

由于未知负荷的各特征量具有较大差异,在特征赋权之前对特征值进行归一化处理。为了提高分类器对EB负荷的适应度,将归一化所用的最值进行固定设置,其值由EB负荷数据训练得出。

非侵入式高频采样数据量大,因此,事件检测和辨识由终端上布设的数据采集与处理设备实现,仅上传辨识结果至云平台,不占用通信资源。系统按照运算需求和通信成本进行任务分配,实现对EB入户精准管控的同时优化了端到云之间传输信息的成本。

非侵入式EB负荷监测系统的整体流程如图3所示。

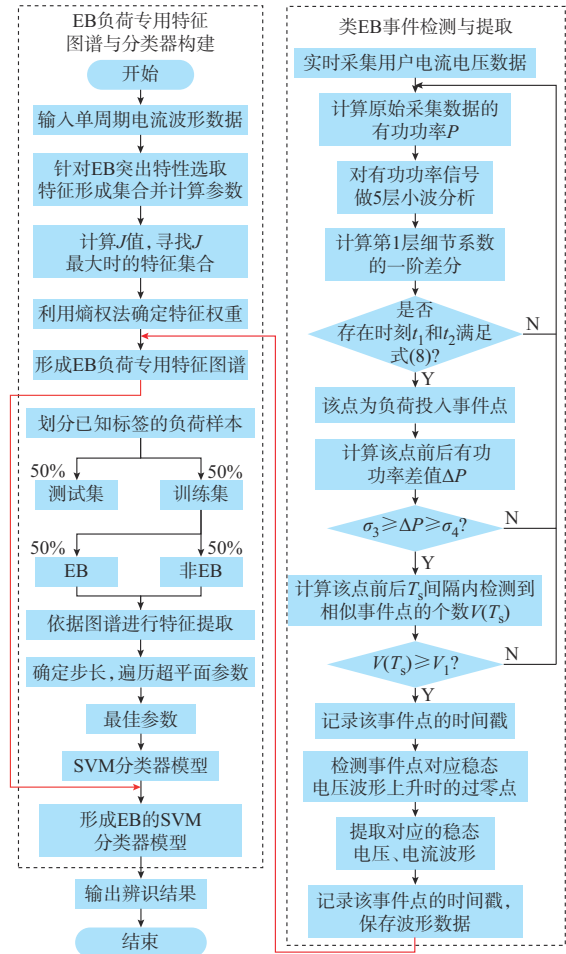


图3 非侵入式负荷监测系统整体流程图  
Fig. 3 Overall flow chart of non-intrusive load monitoring system

## 3 实验分析

为了验证EB入户充电监测系统的有效性,本文从负荷辨识效果和实际监测效果两个方面进行测试实验。

### 3.1 EB专有知识图谱效果验证与算法对比

用户实际运行环境中电器种类复杂,训练样本尽可能涵盖大多数典型家用负荷,避免由于数据不全面而产生误报警现象。样本实际采集环境包含:北京市某小区、高校、二手市场、多户家庭。为了提高分类器的泛化能力,其中,EB负荷包含多种典型EB品牌;非EB负荷包含空调、电脑、冰箱、电视、微波炉、电暖气、浴霸、洗衣机8种典型家用电器。非侵入式采集终端EM9636B具备多种方式的网络接口和存储模式,可以支持不同环境下的数据采集,实验场景如附录A图A5所示。

对采集到的负荷波形数据进行特征融合,附录A表A2展示了不同特征对应的 $J$ 值,当特征数为9

时 $J$ 值达到最优。由此形成了图谱锥形。附录A图A6展示了特征赋权前后的数值大小占总和的百分比。特征占比变化验证了知识加工的必要性。最后,通过EB负荷的一致化表征形成的EB专有负荷特征图谱如图4所示。图中:橙色代表实体特征,蓝色代表电气参数特征,线上数字代表权重系数。

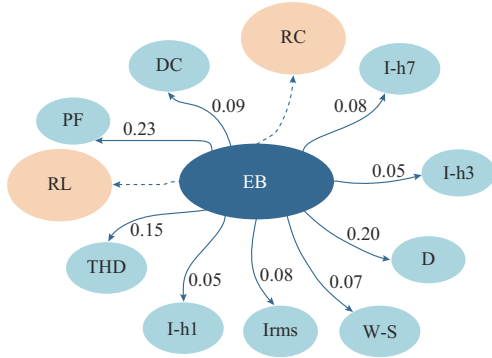


图4 EB专有负荷特征图谱  
Fig. 4 EB proprietary load feature graph

EB专有负荷特征图谱将样本数据转化为高维特征向量以训练SVM分类器。为了验证EB专有负荷特征图谱的准确性以及评价SVM分类器的性能,训练集和测试集各包含100个EB负荷和100个非EB负荷的运行数据,以 $[0, 200]$ 为范围遍历 $\lambda$ ,以 $[0, 50]$ 为范围遍历 $B$ ,如附录A图A7所示。选取准确率最高的一组参数即 $\lambda$ 和 $B$ 分别为11和35,作为SVM核函数的最佳参数。

测试集的测试结果表明,所有EB负荷均可以被辨识出,其中,仅有1个非EB负荷被误认为EB。负荷辨识的准确率以及F1分数均达到了0.995,此分类器对于EB具有接近完全准确的辨识能力。

附录A图A8展示了不同算法辨识准确率的比较。文献[21]通过半监督Fisher计分与最大信息系数数量度特征辨别度与冗余度,采用贪心搜索算法选择特征子集。文献[23]基于SVM弱分类器的AdaBoost多分类学习算法实现非侵入式EB负荷辨识。本文辨识准确率在此基础上增加了0.3%,且文献[21, 23]仅考虑了线路空载时单负荷接入场景。本文构建图谱时考虑到不同实际运行环境、品牌、类型的负荷,形成的EB专有负荷特征图谱可在实际复杂场景中实现高精度辨识。

### 3.2 实际监测效果验证

为了评估提出的非侵入式EB入户监测系统的效果,考虑到实际监测环境的复杂性,选取了北京市昌平区某小区的多个居民用户,在用户电力入口处安装监测设备,分两批进行实际监测,本文抽取其中10个用户分析实际监测效果。第1批在2021年1月

29日至2021年2月27日进行监测,抽取其中3个用户。第2批在2023年3月12日至2023年3月22日进行实际监测,抽取其中7个用户。其中,各用户家中EB的品牌型号如表1所示,除用户4家中有2辆EB,其余测试用户均只有1辆EB。部分实际监测数据已共享。监测系统各阈值具体值如附录A表A3所示,表2展示了监测结果。

表1 实际用户的EB负荷信息  
Table 1 EB load information of actual users

用户	EB品牌	电池材质	电池规格
1	爱玛	石墨烯电池	48V 13Ah
2	雅迪	铅酸蓄电池	48V 12Ah
3	亿通	锂离子电池	36V 8Ah
4	爱玛	铅酸蓄电池	48V 24Ah
	爱玛	铅酸蓄电池	48V 12Ah
5	雅迪	铅酸蓄电池	48V 12Ah
6	绿源	铅酸蓄电池	48V 16Ah
7	新日	锂离子电池	48V 16Ah
8	爱玛	石墨烯电池	72V 22Ah
9	雅迪	锂离子电池	48V 20Ah
10	雅迪	铅酸蓄电池	48V 12Ah

由于实际监测数据量过大,本文仅对用户2中包含EB负荷充电事件的某段有功信号的事件检测结果进行展示。从图5中可以看出,由 $t_1$ 和 $t_2$ 时刻、 $t_3$ 和 $t_4$ 时刻有功信号小波变换细节系数的一阶差分可以定位到2个类EB充电事件,实际用电环境中 $t_1$ 时刻为真实的EB负荷投入点,说明本文算法能够精确定位实际监测环境中的EB充电事件。据实际检测结果统计,定位误差小于0.02 s。




图5 针对EB负荷的事件检测  
Fig. 5 Event detection for EB load

$P$ 、 $R$ 、 $A_{cc}$ 、和 $F_1$ 分别为精确率、召回率、准确率和F1分数,由式(26)得出。

$$\left\{ \begin{aligned} P &= \frac{T_P}{T_P + F_P} \\ R &= \frac{T_P}{T_P + F_N} \\ A_{cc} &= \frac{T_P + T_N}{T_P + T_N + F_P + F_N} \\ F_1 &= \frac{2PR}{P + R} \end{aligned} \right. \quad (26)$$

式中： $T_P$ 、 $F_P$ 、 $F_N$ 和  $T_N$  分别为真阳性、假阳性、假阴性和真阴性。

**表2 本文与文献[24]监测效果对比**  
**Table 2 Comparison of monitoring effect between this paper and reference [24]**

用户	$T_P$	$F_P$	$F_N$	$T_N$	$P$	$R$	$A_{cc}$	$F_1$
用户1	12	0	0	24	1.00	1.00	1.00	1.00
用户2	9	0	0	15	1.00	1.00	1.00	1.00
用户3	10	1	0	18	0.91	1.00	0.97	0.95
用户4	8	1	0	20	0.89	1.00	0.97	0.94
用户5	3	0	0	5	1.00	1.00	1.00	1.00
用户6	4	0	0	7	1.00	1.00	1.00	1.00
用户7	3	0	0	6	1.00	1.00	1.00	1.00
用户8	2	0	0	5	1.00	1.00	1.00	1.00
用户9	4	1	0	8	0.80	1.00	0.92	0.89
用户10	3	0	0	5	1.00	1.00	1.00	1.00
用户11 <sup>[24]</sup>	21	9	0		0.70	1.00		0.82
用户12 <sup>[24]</sup>	26	32	0		0.45	1.00		0.62
用户13 <sup>[24]</sup>	24	1	0		0.96	1.00		0.98
用户14 <sup>[24]</sup>	24	2	1		0.92	0.96		0.94

由于家庭实际用电环境复杂多变,每天会存在多种负荷操作,实验考虑了8种家用负荷。每种负荷每天开启充电1~3次不等,按照每日每户总负荷开启充电12次计算,实验期间总负荷开启数量接近两千次,其中EB事件共58次。由表2可以看出,漏检的EB充电次数为0,若考虑所有负荷开断事件,算法对EB充电事件的漏检率低于0.1%,若仅考虑EB事件,漏检率低于1.7%。

在实际监测过程中,各用户EB负荷的充电频率如表3所示。大部分在2.5~3.3次/d之间,用户4由于有2个EB负荷。因此,充电频率较高。同时,将所检出事件中EB负荷充电事件占比提升到28%~38%,可以避免大量冗余事件检出,降低运算资源消耗。

同时,表2展示了监测的最终结果,文献[24]对不同用户的F1分数不稳定,并且精确率也易受环境的影响。本文在不同用户的通用性上做出较大效果提升,有9个用户的F1分数均不小于0.94, $P$ 和 $R$ 也

**表3 EB负荷检测效果**  
**Table 3 Detection effect of EB load**

用户编号	频次/(次·d <sup>-1</sup> )	EB占比
1	2.50	0.33
2	3.30	0.38
3	3.00	0.34
4	1.25	0.28
5	3.30	0.38
6	2.50	0.33
7	3.30	0.33
8	5.00	0.29
9	2.50	0.31
10	3.30	0.38

稳定提升,其中,7个用户达到了1,平均辨识准确率达到了97.8%。不同种类、容量的EB负荷以及运行环境均不会影响辨识效果,验证了监测算法的通用性以及较高的适应度,监测效果稳定。不仅可以监测到绝大多数用户充电行为,还降低了误报警率,为相关部门提供精准的EB违规充电信息,减少社会资源的浪费。本文非侵入式EB负荷监测算法在实际应用中全方位优化辨识效果。

#### 4 结语

本文通过分析不同品牌与型号EB负荷的通用特性,提出了基于小波检测和图谱决策的非侵入电动自行车充电实时监测系统。首先,利用多尺度小波变换对信号突变的敏感性,基于EB负荷接入电路时的暂态特性检测类电动自行车负荷充电事件,显著降低终端辨识设备的计算量。然后,基于EB负荷运行时的稳态共性,构建EB专有负荷特征图谱对稳态共性特征进行一致化表征,以训练具有强可分性的SVM分类器。最后,综合考虑实际用户的监测结果,本文监测算法满足对不同用户的通用性,验证了监测系统的准确性。

监测系统实际应用效果较稳定,接下来将针对监测系统的算力分配展开研究,进一步降低终端设备的计算压力从而降低成本,以便实现最终的大规模推广。

本文部分实际监测数据和算法代码已共享,可在本刊网站支撑数据处下载(<http://www.aeps-info.com/aeps/article/abstract/20230425001>)。

附录见本刊网络版(<http://www.aeps-info.com/aeps/ch/index.aspx>),扫英文摘要后二维码可以阅读网络全文。



## 参 考 文 献

- [1] 我国电动自行车社会保有量接近3亿辆[EB/OL].(2020-11-20)[2023-04-01]. [https://www.gov.cn/xinwen/2020-11/20/content\\_5562997.htm](https://www.gov.cn/xinwen/2020-11/20/content_5562997.htm).  
There are nearly 300 million electric bicycles in China[EB/OL].(2020-11-20)[2023-04-01]. [https://www.gov.cn/xinwen/2020-11/20/content\\_5562997.htm](https://www.gov.cn/xinwen/2020-11/20/content_5562997.htm).
- [3] 谢耀华. 电动自行车安全风险分析[J]. 电动工具, 2020(4): 23-26.  
XIE Yaohua. Safety risk analysis of electric bicycle[J]. Electric Tool, 2020(4): 23-26.
- [4] 来艳利. 典型电动自行车火灾特征与防范对策[D]. 西安: 西安科技大学, 2019.  
LAI Yanli. Characteristics of typical electric bicycle fire and its preventive countermeasures [D]. Xi'an: Xi'an University of Science and Technology, 2019.
- [5] 林顺富, 于俊苏, 李东东, 等. 基于二分递推SVD分解的居民电器开关事件检测方法[J]. 电网技术, 2020, 44(4): 1534-1543.  
LIN Shunfu, YU Junsu, LI Dongdong, et al. Method of switching events detection of residential appliances based on binary recursive SVD decomposition [J]. Power System Technology, 2020, 44(4): 1534-1543.
- [6] 周东国, 张恒, 周洪, 等. 基于状态特征聚类的非侵入式负荷事件检测方法[J]. 电工技术学报, 2020, 35(21): 4565-4575.  
ZHOU Dongguo, ZHANG Heng, ZHOU Hong, et al. Non-intrusive load event detection method based on state feature clustering [J]. Transactions of China Electrotechnical Society, 2020, 35(21): 4565-4575.
- [7] VAZ R, MORAES G R, ARRUDA E H Z, et al. Event detection and classification through wavelet-based method in low voltage wide-area monitoring systems [J]. International Journal of Electrical Power & Energy Systems, 2021, 130: 106919.
- [8] JIA D N, LI Y X, DU Z H, et al. Non-intrusive load identification using reconstructed voltage-current images [J]. IEEE Access, 2021, 9: 77349-77358.
- [9] ZHANG L, SHI S W. A non-intrusive load monitoring method based on multi-scale wavelet packet optimization and transient feature matching [C]// 2021 IEEE 12th International Conference on Software Engineering and Service Science (ICSESS), August 20-22, 2021, Beijing, China: 113-117.
- [10] REHMAN A U, LIE T T, VALLES B, et al. Comparative evaluation of machine learning models and input feature space for non-intrusive load monitoring [J]. Journal of Modern Power Systems and Clean Energy, 2021, 9(5): 1161-1171.
- [11] 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.
- [12] 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-invasive load identification method based on V-I trajectory color coding [J]. Automation of Electric Power Systems, 2022, 46(4): 93-102.
- [13] YUAN J, WANG H L, WU P, et al. A novel current signal feature and its application in noninvasive load monitoring [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-10.
- [14] 臧海祥, 许瑞琦, 刘璟璇, 等. 基于多维融合特征和卷积神经网络的多任务用户短期负荷预测[J]. 电力系统自动化, 2023, 47(13): 69-77.  
ZANG Haixiang, XU Ruiqi, LIU Jingxuan, et al. Short-term load forecasting of multi-task users based on multidimensional fusion features and convolutional neural network [J]. Automation of Electric Power Systems, 2023, 47(13): 69-77.
- [15] 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.
- [16] 牟魁强, 杨洪耕. 基于PLA-GDTW支持向量机的非侵入式负荷监测方法[J]. 电网技术, 2019, 43(11): 4185-4193.  
MOU Kuiyi, YANG Honggeng. Non-intrusive load identification method based on PLA-GDTW support vector machine [J]. Power System Technology, 2019, 43(11): 4185-4193.
- [17] 廖荣文, 刘刚, 肖刚. 基于时间模糊化长短时记忆的非侵入式负荷分解方法[J]. 电力系统自动化, 2021, 45(24): 73-80.  
LIAO Rongwen, LIU Gang, XIAO Gang. Non-intrusive load decomposition method based on time-fuzzified long short-term memory [J]. Automation of Electric Power Systems, 2021, 45(24): 73-80.
- [18] 罗平, 樊星驰, 章坚民, 等. 基于电器运行状态和深度学习的非侵入式负荷分解[J]. 电力系统自动化, 2021, 45(12): 49-56.  
LUO Ping, FAN Xingchi, ZHANG Jianmin, et al. Non-intrusive load decomposition based on operation state of electrical appliances and deep learning [J]. Automation of Electric Power Systems, 2021, 45(12): 49-56.
- [19] 武昕, 焦点, 高宇辰. 基于非侵入式用电数据分解的自适应特征库构建与负荷辨识[J]. 电力系统自动化, 2020, 44(4): 101-109.  
WU Xin, JIAO Dian, GAO Yuchen. Construction of adaptive feature library and load identification based on decomposition of non-intrusive power consumption data [J]. Automation of Electric Power Systems, 2020, 44(4): 101-109.
- [20] REHMAN A U, TJING LIE T, VALLÈS B, et al. Low complexity non-intrusive load disaggregation of air conditioning unit and electric vehicle charging [C]// 2019 IEEE Innovative Smart Grid Technologies-Asia (ISGT Asia), May 21-24, 2019, Chengdu, China: 2607-2612.
- [21] 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.
- [22] 韩笑, 邓春宇, 张玉天, 等. 基于高频数据  $V-I$  特性的延时反馈负荷在线快速辨识算法 [J]. 电力系统自动化, 2019, 43(9): 108-116.  
HAN Xiao, DENG Chunyu, ZHANG Yutian, et al. Fast online identification algorithm for delayed feedback load based on  $V-I$  characteristics of high frequency data [J]. Automation of Electric Power Systems, 2019, 43(9): 108-116.
- [23] 王岩俊. 基于智能电表的电动自行车充电识别系统研究 [D]. 广州: 广东工业大学, 2022.  
WANG Yanjun. Research on charging identification system of electric bicycle based on smart meter [D]. Guangzhou: Guangdong University of Technology, 2022.
- [24] 栾文鹏, 马纯伟, 赵博超, 等. 非侵入式电动自行车充电负荷在线识别 [J]. 电力系统及其自动化学报, 2022, 34(10): 1-7.  
LUAN Wenpeng, MA Chunwei, ZHAO Bochao, et al. Online identification of charging load of non-invasive electric bicycle [J]. Proceedings of the CSU-EPSA, 2022, 34(10): 1-7.
- 
- 李 想(1999—), 女, 博士研究生, 主要研究方向: 非侵入式负荷智能量测与感知。E-mail: lx2429109351@163.com  
刘宇航(1999—), 男, 硕士研究生, 主要研究方向: 电力系统及其自动化。E-mail: shaonianlyh@163.com  
张 琪(1991—), 女, 博士, 主要研究方向: 非侵入式负荷智能量测与感知。E-mail: zhangqi@chinanecc.cn  
武 昕(1986—), 女, 通信作者, 博士, 副教授, 博士生导师, 主要研究方向: 智能用电及信息处理、电力系统通信与信号处理技术。E-mail: wuxin07@ncepu.edu.cn
- (编辑 代长振)

## Non-intrusive Real-time Monitoring System for Electric Bicycle Charging Based on Wavelet Detection and Feature Graph Decision

LI Xiang<sup>1</sup>, LIU Yuhang<sup>1</sup>, ZHANG Qi<sup>2</sup>, WU Xin<sup>1</sup>

(1. School of Electrical and Electronic Engineering, North China Electric Power University, Beijing 102206, China;

2. National Energy Conservation Center, Beijing 100045, China)

**Abstract:** The illegal charging behavior of electric bicycles (EBs) in households has temporal randomness and spatial concealment, which poses significant safety hazards and is difficult to effectively manage. A non-intrusive real-time monitoring system for EB charging based on wavelet detection and feature graph decision is proposed, utilizing the characteristics of real-time autonomous execution and promotion-friendly non-intrusive monitoring systems. Considering the physical structure and charging characteristics of EB loads, the typical common characteristics of EB loads are analyzed from both transient and steady-state perspectives. The EB proprietary feature map with strong distinguishability and universality is constructed in advance to realize consistent and structured expression of EB steady-state common features. In the actual monitoring process, in order to reduce the computational power demand and data transmission pressure of the system, EB specific transient phenomena with high-frequency components are accurately located based on wavelet transform to complete EB like charging event detection. Finally, the monitoring system extracts event waveforms and trains efficient classifiers through graphs for load identification and real-time upload. By monitoring actual users, the effectiveness of the monitoring system has been verified, which can effectively solve the problem of charging EBs in buildings and households.

This work is supported by State Grid Corporation of China (No. 5100-202113564A-0-5-SF) and Fundamental Research Funds for the Central Universities (No. 2020MS002).

**Key words:** non-intrusive load monitoring; feature graph; electric bicycle; charging; wavelet transform; support vector machine

