

# 轨迹数据驱动的电动汽车充电需求及V2G可调控容量估计

周椿奇, 向月, 童话, 饶萍, 青倚帆, 刘友波  
(四川大学电气工程学院, 四川省成都市 610065)

**摘要:** 电动汽车(EV)充电需求估计是研究电动汽车与电网互动(V2G)的重要前提。为此,提出一种行驶轨迹数据驱动的EV充电需求预测模型,并进一步考虑用户多维效益,构建用户选择参与V2G响应的用户决策模型,分析区域V2G响应能力的调控潜力。首先,对行车轨迹大数据集进行清洗与挖掘,基于动态能耗理论构建了EV充电需求时空分布预估模型。其次,基于社会行为学理论并综合考虑用电需求效用、经济效用、环保效用以及社会效用,构建了EV用户选择参与V2G响应的概率选择模型。该模型不仅考虑了EV用户的异质性,而且体现了用户决策的交互影响。最后,建立V2G可响应容量调度模型,分析V2G响应资源对区域负荷的调节效果。结果表明,所提模型不仅能有效估计某城市区域的EV充电需求时空分布特性,而且能挖掘该区域选择参与V2G响应的EV潜在用户数量,为研究V2G响应资源对区域负荷的调控潜力提供了支撑。

**关键词:** 电动汽车; 轨迹大数据; 数据挖掘; 充电需求时空分布; 用户决策行为; 电动汽车与电网互动(V2G); 响应容量; 区域调控潜力

## 0 引言

电动汽车(electric vehicle, EV)的规模化推广与应用,给“绿色”社会建设提供了可行方案,但其大规模接入电网所造成的电力系统安全问题逐步凸显。为缓解高渗透率下EV充电行为对电力系统稳定运行的冲击,电动汽车与电网互动(vehicle-to-grid, V2G)技术因其“化被动变主动”的特性正逐步得到社会各界的关注<sup>[1-2]</sup>。对V2G的可用容量进行合理调控能够有效缓解电网峰谷波动、提升电网投资效益,以及为电网侧提供紧急辅助服务。但实现V2G需首先满足EV用户的出行需求电量,因此,有必要对EV用户主体的充电需求进行精准预估。

关于EV的充电负荷特性,已有较多研究从多个维度进行了深入探讨。例如,文献[3]基于多代理技术推演了EV规模演化,分析了EV充电负荷随时间尺度的宏观变化路径;文献[4]基于出行链与马尔可夫过程,通过对空间区域进行划分,研究了EV空间移动特性下的充电负荷需求;文献[5]通过元胞机模型,模拟了EV作为智能体参与动态演化过程中负荷需求的时空分布特性;文献[6]提出了一种基

于车辆集合的整体荷电状态概率分布特性的EV充电负荷概率分布数值计算方法;文献[7]基于EV行驶/停放特性,提出一种考虑EV时空分布的充电负荷预测方法;文献[8]基于起讫点(origin-destination, OD)矩阵及Floyd算法模拟EV最短距离出行轨迹,并考虑车速-流量关系建立了EV充电负荷预测模型;文献[9]考虑“车-路-网”耦合下的动态交通流模型,基于起讫点分析法研究了交通系统与充电负荷的动态交互关系。但上述文献对EV充电负荷的研究主要是基于理想场景对EV充电行为进行模拟,而不是以真实数据作为支撑,并且无法准确获得充电需求的空间地理位置。因此,亟须以真实大数据作为支撑对充电负荷的时空需求进行更具精细化的预估,为后续研究V2G可响应容量提供实际依据。

以真实数据作为依据的EV充电需求估计研究中,文献[10]根据美国交通部门所公布的车辆出行行为调查结果(national household travel survey, NHTS),通过拟合用户出行时间、日均里程等车辆行为概率,对充电负荷需求进行预估;文献[11]进一步分析中国不同阶段的EV规模,将乘用车功能细化为不同EV类型,并采用随机抽样方法分析EV的负荷时空维度分布特性。上述文献通过数据拟合形式进行充电需求估计,但前者数据无法体现国内行车数据的真实情况,后者数据年代较为久远,无法为

收稿日期: 2021-12-27; 修回日期: 2022-05-09。

上网日期: 2022-05-26。

国家自然科学基金资助项目(52111530067);四川省科技计划资助项目(2020YFSY0037)。

现阶段开展V2G响应研究提供有意义的参考。为此,本文基于开源数据平台提供的用户订单出行轨迹数据,根据动态能耗理论,预判车辆行驶过程中的实时能耗情况。该方式不仅可精准定位到有充电需求EV用户的兴趣点(point of interest, POI)坐标,而且可为后文研究相关EV用户选择参与V2G响应的决策行为提供支撑。

在EV参与V2G响应的研究方面,现有文献多侧重于对EV可响应资源进行量测的研究<sup>[12-16]</sup>,而忽略了以何种方式激励EV用户参与V2G响应,以及EV用户自身参与V2G响应的主观意愿和客观条件。因此,文献[17]基于替代弹性价格模型,给出了微网短期新能源出力与负荷需求关系的动态分时电价机制;文献[18]提出一种基于模糊贝叶斯学习的EV放电电价谈判模型,构建电网与EV代理商在博弈模式下的放电电价的定价机制。文献[17-18]分别给出了EV放电电价的定价机制,激励EV用户积极参与V2G响应,但与国内EV参与放电响应的具体实施规则差异较大,无法提供参考。为此,本文考虑将文中的放电补偿效益与目前国内相关区域正实施的放电补偿政策规定相适应,构建更具现实参考价值的V2G响应容量及经济效益的研究。最后,将V2G响应容量应用于区域实际负荷削峰的研究中,分析了目前EV参与V2G响应在该区域的潜在调节能力。

## 1 单个EV用户出行需求建模

### 1.1 原始数据来源及处理

本文通过“滴滴开放数据平台”申请得到该平台发布的中国某城市局部区域一周内的出行订单及订单GPS定位数据。该数据包括5个以天为单位的数据包,数据链时间间隔为2s,共包含约27万条出行订单的GPS轨迹数据集。其数据格式如附录A表A1所示,表中给出了每份订单的脱敏司机信息、脱敏订单信息、脱敏行程时间戳以及实时轨迹GPS定位数据。

#### 1.1.1 电动私家车数据清洗

为构建更加符合实际情景下私家车通勤时间的用户出行链(考虑通勤过程中交通堵塞等因素),将5日内的订单数据中时间在07:30—09:30划分为上班时,时间在16:40—19:30划分为下班时,并将该时间划分作为工作日用户出行链构建的选取规则。同时,剔除行驶时间小于300s,且同一订单GPS数据相邻间隔距离过大以及平均速度大于120km/h等的订单数据,以此作为后文构建符合EV用户出行习惯行程链的依据。

#### 1.1.2 电动运营车出行数据清洗

本文通过筛选“滴滴”出行计划获得的行车轨迹数据集,得到典型(单日运营时间长)司机用户,进而得到滴滴司机个体的行车轨迹数据集。因此,可直接在该清洗后的数据库中进行随机抽取,作为电动运营车的出行数据集。

### 1.2 电动私家车用户行程出行链构造

通过1.1.1节中对轨迹数据清洗后得到的通勤时段订单信息,本节在该过滤数据的基础上构建了符合一般私家车用户出行规律的轨迹行程链。电动私家车通勤日出行点相对较为固定,利用前文清洗得到的用户轨迹数据集,对数据集早晚通勤中的起讫点坐标寻找最优的匹配结果,作为EV用户通勤出行链。具体步骤如下:

1)通过订单大数据,构建早通勤出行链 $O_m(i)$ 与晚通勤出行链 $O_d(j)$ 的匹配关系:

$$O_m(i) = \{(x_{0,m}, y_{0,m}, t_{0,m}), (x_{1,m}, y_{1,m}, t_{1,m}), \dots, (x_{n,m}, y_{n,m}, t_{n,m})\} \quad (1)$$

$$O_d(j) = \{(x_{0,d}, y_{0,d}, t_{0,d}), (x_{1,d}, y_{1,d}, t_{1,d}), \dots, (x_{\nu,d}, y_{\nu,d}, t_{\nu,d})\} \quad (2)$$

式中: $x_{i,m}, y_{i,m}, t_{i,m}$ 分别为第 $m$ 号早通勤行程链轨迹数据中第 $i$ 条信息对应的实时经、纬度坐标和对应时间戳,其中 $i=0, 1, \dots, n, n$ 为该行程链总长度; $x_{j,d}, y_{j,d}, t_{j,d}$ 分别为第 $d$ 号晚通勤行程链轨迹数据中第 $j$ 条信息对应的实时经、纬度坐标和对应时间戳,其中 $j=0, 1, \dots, \nu, \nu$ 为该行程链总长度。

2)对挖掘得到的早、晚通勤数据进行空间位置上的匹配:

$$\Omega(x) = \{[O_m(i), O_d(j)]\} \\ x_{0,m} - x_{\nu,d} < \alpha^{la} \cap |x_{0,d} - x_{n,m}| < \alpha^{la} \quad (3)$$

$$\Omega(y) = \{[O_m(i), O_d(j)]\} \\ y_{0,m} - y_{\nu,d} < \alpha^{lon} \cap |y_{0,d} - y_{n,m}| < \alpha^{lon} \quad (4)$$

$$C(z) = \Omega(x) \cap \Omega(y) \quad (5)$$

式中: $\Omega(x)$ 和 $\Omega(y)$ 分别为对经、纬度坐标始末位置进行匹配的出行链轨迹集合; $\alpha^{la}$ 和 $\alpha^{lon}$ 为不同匹配过程中允许的匹配距离误差最小值; $C(z)$ 为成功匹配得到的出行链轨迹数据集合集,其中 $z$ 为行程链数据匹配成功数, $z=1, 2, \dots, n$ 。

图1展示了由式(1)一式(5)匹配得到的5组EV用户早晚通勤出行链的模拟结果(仅为部分结果,依据以上公式共成功匹配约4000条行程链)。由图1可以看出,用户在出行过程中为避免交通堵塞带来的时间成本,会自动选择最优行驶路径。相较于传统的固定出行链,通过该数据挖掘方法得到的出行链结果能更现实地反映城市交通堵塞及行车

状态信息对充电需求的影响(往返行程时间及往返路程不同)。




图1 数据挖掘下的EV用户出行链结果  
Fig.1 Trip chain results of EV users based on data mining

### 1.3 EV行驶特性建模

1) 出行时刻电池荷电状态。实际情况中,现阶段EV的满电量续航里程已基本满足了私家车用户的日均里程需求。根据文献[19]提到的私家车日均能耗需求可知, EV用户每周约充电1.3次。因此,本文设置首次出行时刻的荷电状态服从正态分布 $N(0.8, 0.1)^{[20]}$ , 如式(6)所示, 且通过式(7)得到各EV初始电池容量。

$$f(S, u, \sigma) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(S-u)^2}{2\sigma^2}} \quad (6)$$

$$V_{0,k} = V_{all,k} S_k \quad (7)$$

式中: $u, \sigma$ 为正态分布的相关参数; $S$ 为EV电池荷电状态的初始值; $V_{0,k}$ 为第 $k$ 类EV对应的出行时刻初始电池容量; $V_{all,k}$ 为第 $k$ 类EV的电池总容量; $S_k$ 为第 $k$ 类EV电池的荷电状态; $k=1, 2, \dots, 10$ ,由附录A表A2给出。

2) EV能耗模型。基于文献[21]所提的微观动态能耗量化模型,并结合EV能耗规律给出了EV行驶过程的动态能耗模型。该方法相较于传统的百公里固定耗电模型,能更实际地反映行驶过程的交通流堵塞所造成的EV能耗估计偏差问题。根据滴滴数据平台提供的车辆秒级GPS定位,建立了EV不同运行状态(加速、减速、匀速、怠速)下的单位里程动态耗电模型如下:

$$\begin{cases} \omega_A = \sum_{e=0}^j (\lambda_A v_e a_e) & a_e > 0 \\ \omega_D = \sum_{e=0}^j (\lambda_D v_e a_e) & v_e < 0 \\ \omega_U = \sum_{e=0}^j (\lambda_U v_e) & a_e = 0, v_e \neq 0 \\ \omega_I = E_c & a_e = 0, v_e = 0 \end{cases} \quad (8)$$

$$v_e = \frac{\sqrt{(G_{e+1}(x) - G_e(x))^2 + (G_{e+1}(y) - G_e(y))^2}}{g} \quad (9)$$

$$a_e = \frac{v_e - v_{e-1}}{g} \quad (10)$$

式中: $\omega_A, \omega_D, \omega_U, \omega_I$ 分别为加速、减速、匀速、怠速4种运行状态下的EV耗电量; $\lambda_A, \lambda_D, \lambda_U$ 为通过实验得到的各运行状态对应的回归系数<sup>[21]</sup>;  $E_c$ 为怠速工况下的固定电能消耗量; $v_e$ 为 $e$ 时刻对应的瞬时速度,由 $e$ 时刻GPS数据( $G_e$ )定位的经纬度坐标值确定,由于数据集中采集样本之间的间隔为2~3s,故 $g$ 表示GPS数据采集过程中的时间间隔; $a_e$ 为 $e$ 时刻对应的瞬时加速度。附录B图B1模拟了EV动态行驶过程的情景。

3) 充电需求判断。式(11)给出了行程时间段的剩余电量 $V_{t,k}$ 的计算方式。

$$V_{t,k} = V_{0,k} - \sum_{h \in \{A, D, U, I\}} \omega_h t \quad (11)$$

式中: $h$ 表示EV行驶过程中的不同运行状态。

根据EV剩余电量可判断不同类型EV的充电需求。对于电动私家车用户,当EV抵达目的地后,若无法满足下次出行的需求电量将触发充电需求(由式(12)给出),同时该类型的车辆主要以慢充形式为主;对于电动运营车用户,考虑到其商业运营需求,通常充电模式选择以快充为主且设定阈值电量触发其充电需求(由式(13)给出)。

$$V_{t,k} \leq \sum_{h \in \{A, D, U, I\}} \omega_h t \quad (12)$$

$$V_{t,k} \leq \gamma V_{all,k} \quad (13)$$

式中: $\gamma$ 为电动运营车用户的心理阈值系数,服从区间为0.15~0.30的均匀分布<sup>[22]</sup>,即充电需求一旦触发即选择最近的充电站进行快充。

对于电动私家车用户,当用户抵达目的地后,若无法满足下次出行的电量则触发式(12)所示的充电需求,同时,私家车用户会选择上段行程终点处就近的充电站进行充电。本文以几何距离最近(式(14))作为充电站的选择依据,该充电站通过 $k$ 均值聚类算法可确定该充电站所属的对应充电节点,以此作为充电节点的充电需求;对于电动运营车用户,通过式(13)设置的充电阈值,同样以式(14)确定对应充电节点的充电需求。

$$d(u) = \min_{u=1, 2, \dots, 56} [(x_{u,c} - x_z)^2 + (y_{u,c} - y_w)^2] \quad (14)$$

式中: $u$ 表示距行程终点最近的充电站,研究区域的充电站个数及充电站对应的POI坐标已由数据爬虫技术获取(见附录C表C1); $x_{u,c}$ 和 $y_{u,c}$ 分别为第 $u$ 个

充电站的经、纬度坐标;  $x_z$  和  $y_w$  分别表示当电动私家车触发式(12)或电动运营车触发式(13)时,两类EV分别对应的地理坐标位置的经、纬度坐标。由此,分别确定了电动私家车与电动运营车的充电位置及充电需求结果。

4) 充电时长:

$$T_{ic} = \frac{f_{soc} V_{all,k} - V_{t,k}}{\eta_c P_x} \quad (15)$$

式中:  $f_{soc}$  为充电结束时的荷电状态值,服从  $N(0.85, 0.3)$  的正态分布<sup>[23]</sup>;  $\eta_c$  为充电效率,取值为0.9;  $P_x$  为充电桩功率,根据对现有市面上充电桩的调研,本文设置目的地慢充功率为7 kW,快充功率为30 kW。

5) 充电需求负荷。每个充电节点的需求负荷  $P_{c,t}$  为:

$$P_{c,t} = \sum_{k=1}^Z N_{t,k} P_x \beta_{s,b,t} \quad (16)$$

式中:  $P_{c,t}$  为  $t$  时刻充电节点  $c$  的充电电量;  $Z$  为充电节点  $c$  包含的充电桩数量;  $N_{t,k}$  为  $t$  时刻在充电站  $k$  的EV数量;  $\beta_{s,b,t}$  为  $t$  时刻在区域  $s$  (由4.1节所求得的充电节点及区域划分) 第  $b$  辆车的充电状态,充电时为1,否则为0。

## 2 V2G 需求响应决策模型

目前,国内的EV发展正处于加速上升期,“十四五”提出的能源电气化转型进一步推动了V2G技术的发展。本文认为,实现EV参与需求响应的发展初期的主要参与对象应为电动私家车用户,其主要原因如下:

1) 电动私家车规模占EV规模的绝大部分;

2) 电动私家车日均在线及与电网可互动日均时间占比达到80%以上,能够更有效地接受电网侧需求响应的调控。

### 2.1 用户参与V2G需求响应的影响因素分析

影响用户参与V2G需求响应的因素较为复杂,本节分别从个体用户属性、政策属性、电池产品属性及社会影响等方面进行分类梳理:

1) 个体用户属性:指关于用户选择参与V2G需求响应的本质属性,如里程焦虑、用户EV购买价格以及V2G响应所获收益等。个体用户属性是影响EV用户选择参与V2G需求响应决策的关键评估因素。

2) 政策属性:指关于V2G作为需求响应的相关规则。本文参照《广州市虚拟电厂实施细则》(后文简称《细则》)<sup>[24]</sup>中,关于实时响应电价补偿标准以及需求响应参与时间及容量的规则作为EV用户通

过V2G技术参与需求响应的环境政策属性。

3) 电池产品属性:指EV电池容量裕度、电池成本及其可循环充放电次数等因素。受限于EV产品属性的直接影响,本文基于互联网信息挖掘出研究区域现有的EV产品特征属性,具体结果详见附录A表A2。

4) 社会影响:指影响EV用户参与决策的社会因素,包括区域EV规模、电网需求量及EV低碳运行带来的环保效益等因素。由于V2G的推广范围较小,需要通过社会对其环保减碳效益以及经济效益进行宣传,以提高用户对V2G需求响应的参与度。

## 2.2 用户参与V2G需求响应的行为模型

### 2.2.1 V2G渗透率阈值模型

在新兴事物的发展初期,EV用户的接受程度倾向于采取观望的态度,直到该事物的渗透情况达到个体心理阈值<sup>[25]</sup>,即行为学中的“市场惯性”。由于EV用户具有不同的社会属性,对新兴事物的倾向程度呈现显著差异。根据文献[3]中提出的创新扩散理论,将用户的社会属性分为创新者、早期使用者、早期/晚期大众以及产品滞后者,各类型用户所占的比例取其典型值。本文主要讨论V2G参与需求响应发展初期用户的参与度问题。各类型用户的心理阈值如表1所示。

表1 EV用户行为分类信息  
Table 1 Behavior classification information of EV users

类型	比例/%	心理阈值
创新者	2.50	0
早期使用者	13.50	0.05
早期/晚期跟进者	68.00	0.15
滞后者	16.00	0.35

### 2.2.2 EV用户效用评估模型

用户在参与V2G需求响应前,会评估当日的参与必要性。为评估EV参与V2G需求响应的效用情况,本文建立考虑用户的行程需求、经济性、社会性及环保性的综合效用模型。综合效用值  $U$  的计算方式如式(17)所示。

$$U = \alpha_1 U_{eco} + \alpha_2 U_{so} + \alpha_3 U_{eir} \quad (17)$$

式中:  $U_{eco}$ 、 $U_{so}$ 、 $U_{eir}$  分别为用户经济效用、社会效用以及环境效用;  $\alpha_1$ 、 $\alpha_2$ 、 $\alpha_3$  分别为用户经济效用、社会效用及环境效用的权重系数,且  $\alpha_1 + \alpha_2 + \alpha_3 = 1$ 。

1) 用户经济效用。经济效益是激励EV用户利用V2G参与需求响应的重要因素,本文通过用户放电收益  $B_{V2G}$  与电量成本  $T_{V2G}$  的差值来衡量。

电量成本由固定成本与可变成本组成,如式(18)所示<sup>[26]</sup>。

$$T_{V2G} = \left( \frac{\mu P_{EV,k}}{\tau} + \frac{P_{ch}}{\eta_c \eta_d} \right) E_{dis} + \nu E_{dis}^2 \quad (18)$$

式中: $\mu$ 为电池成本占整车单价的比例,取值为45%<sup>[27]</sup>;  $P_{EV,k}$ 为第 $k$ 类EV的单价,由附录A表A2给出; $\tau$ 为EV电池充放电可循环次数; $P_{ch}$ 为用于放电的电能充电电价; $\eta_d$ 为放电效率; $E_{dis}$ 为参与需求响应的电量; $\nu$ 为EV用户的机会成本系数, $\nu E_{dis}^2$ 表示参与需求响应而失去的出行便利可变成本。

EV用户参与需求响应的放电收益可依据《细则》中需求响应电价补偿标准计算,如式(19)所示。

$$B_{V2G} = E_{dis} C_{pri} \epsilon \quad (19)$$

式中: $C_{pri}$ 为补偿标准单价; $\epsilon$ 为响应系数。

本文将用户的经济效益定义为:

$$U_{eco} = 1 - \frac{G_{OD} P_{ch}}{B_{V2G} - T_{V2G}} \quad (20)$$

式中: $G_{OD}$ 为EV用户日出行所需的总电量,通过2.2节基于轨迹数据的充电需求估计得到。

2) 社会效用。根据社会学原理,用户的决策行为不仅受自身经济情况的影响,还受到与之具有相同经济水平的社会成员的行为影响,即用户的“同群效应”。本文根据车型售价差异区分出不同EV用户的经济水平,此外,参考文献[3]随机生成小世界网络用以描述相同经济水平用户之间的连接关系。将社会效用定义如下:

$$U_{so} = \beta_1 \frac{\sum_{q=1}^N A_{pq} x_q}{K_p} + \beta_2 \frac{B_{V2G} - T_{V2G}}{P_{ad}} \quad (21)$$

式中: $K_p$ 为社会网络中与EV用户 $p$ 具有相似经济水平的用户总量; $A_{pq}$ 为EV用户之间的连接矩阵元素,若 $p$ 与 $q$ 相连,则 $A_{pq}$ 为1,否则为0; $x_q$ 为EV用户 $q$ 参与需求响应的标志,若参与则为1,否则为0; $P_{ad}$ 为EV的日均使用成本,其值取决于相应用户的EV购买单价; $\beta_1$ 、 $\beta_2$ 分别为表示社会集群影响在主观及客观中社会影响的权重系数; $N$ 为具备相同综合特性EV用户已参与V2G响应的总数。

3) 环保效用。EV作为需求响应资源,能够为实现“碳达峰、碳中和”的目标作出贡献。由于EV作为实时响应资源能够满足需求响应的及时性,其环保特性能够缓解传统放电需求响应依靠大量火电机组造成的大规模排碳问题。本文基于V2G响应可减少的碳排放量来定义EV用户的环保效用:

$$U_{eri} = \frac{(1 - R_{per}) \omega_c E_{dis}}{\eta_d \omega_c E_{dis}} = \frac{1 - R_{per}}{\eta_d} \quad (22)$$

式中: $R_{per}$ 为区域内清洁能源发电占比; $\omega_c$ 为燃煤排碳因子。

### 2.2.3 EV用户参与需求响应选择概率模型

电量满足度效用 $r$ 是用户是否参与V2G响应的决定性因素。本文假设若用户当日在停靠时间段内进行了充电行为,则该时间段不参与放电需求响应。因此,该指标取决于参与需求响应的放电电量、EV剩余电量以及返程所需耗电量等因素。

$$r = \begin{cases} 0 & V_{t,k} - E_{dis} \leq e_{do} \\ 1 - \frac{E_{dis}}{V_{t,k} - e_{do}} & V_{t,k} - E_{dis} > e_{do} \end{cases} \quad (23)$$

式中: $e_{do}$ 为EV用户返程途中所需能耗。

最后,通过改进离散选择Logit模型,综合考虑EV用户各方面效用值,得到EV用户选择参与V2G需求响应的概率行为模型为:

$$P_{V2G} = \frac{re^U}{re^U + e} \quad (24)$$

EV用户参与需求响应选择模型的仿真流程图及流程说明如附录D所示。

## 3 V2G需求响应削峰调度模型

第2章确定了EV用户参与需求响应的意愿,本章将针对EV的可响应容量资源进行优化调度。由于参与需求响应的EV用户可参与调度时间远小于其日常停靠时间,本文假设响应容量受EV代理商(electric vehicle aggregation, EVA)统一调控管理。作为中间机构,EVA将有意愿参与需求响应的EV资源纳入削减容量的范围,以便最大限度地发挥EV集群的最优化削峰调节效果。全文结构框架如附录E图E1所示。

### 3.1 单个EV用户的响应容量及响应时间

依据《细则》中的规则确定EV用户参与需求响应的容量及时间。规则中提到,单个电力用户实时需求响应原则上每月不超过4次,且每次不超过2h。因此,将用户日均参与需求响应的时间以期望的形式表示,即 $E = 0.4$ h(仅考虑工作日时间)。此外,根据电动汽车传导式充电接口的充电设施标准,本文所涉及的放电需求响应均在慢充桩上进行,以保证放电过程的安全问题。用户日均放电量为:

$$E_{dis} = \eta_d EP_x \quad (25)$$

### 3.2 调度目标函数及约束条件

EV用户参与削峰需求响应的V2G控制策略主要以削减系统负荷峰值、平抑负荷波动为目标。为此,本文引入日负荷曲线均方差表征系统负荷的波动性。优化调度的目标为最小化负荷曲线均方差,优化变量为调度时段 $\Delta t$ 内EV的调度功率 $D_{g,T0}$

$$\min F_e = \sum_{T=1}^{96} \left( P_{L,T} + \sum_{a=1}^c P_{a,T} - D_{g,T} - P_{avr} \right)^2 = \sum_{T=1}^{96} \left( P_{L,T} + \sum_{a=1}^c P_{a,T} - D_{g,T} - \frac{\sum_{T=1}^{96} P_{L,T} + \sum_{a=1}^c P_{a,T}}{96} \right)^2 \quad (26)$$

式中: $F_e$ 为系统负荷均方差,用于表征电网系统负荷的波动情况,均方差越大则负荷波动越明显; $P_{L,T}$ 为除EV负荷外电网的功率; $P_{a,T}$ 为 $T$ 时段EV的充电功率; $D_{g,T}$ 为 $T$ 时段EVA的放电功率; $P_{avr}$ 为区域的日平均负荷;文中设置的调度周期为一天,分为96个调度时段。

根据《细则》中单体EV用户当日仅允许参加1次响应的规定,可通过式(26)一式(28)控制EVA的放电功率。

$$0 < D_{g,T} < N_{w,T} E_{dis} \quad (27)$$

$$N_{w,T+1} = N_{w,T} - \frac{D_{g,T}}{E_{dis}} \quad (28)$$

式中: $N_{w,T}$ 为 $T$ 时段未参与需求响应的EV数量。

## 4 算例分析

### 4.1 充电站节点的区域划分

为了更好地模拟不同地理位置的充电需求电量,利用高德开放平台(<https://jiaotong.amap.com>)提供的应用程序接口(application programming interface, API)爬取所研究城市的充电桩地理POI数据,数据集包含充电站经纬度坐标、充电站街道详细地址以及所属城市区域。同时,将POI数据进行清洗,筛选出研究区域范围内的充电站POI信息,得到研究区域现存的56个POI地理数据(见附录C表C1),其充电站POI信息可视化数据如图C1所示。为便于后续关于充电需求区域的时空划分,需将离散充电桩POI数据信息归为不同类别。

进一步,采用 $k$ 均值聚类算法对所研究区域充

电站经纬度坐标进行聚类分析,并利用Python的scikit-learn机器学习算法包中的网格搜索法,基于轮廓系数模型(具体公式见附录C式(C1)),确定出聚类效果最优的聚类数 $k=8$ ,区域划分结果如附录C图C2所示,以此作为确定充电需求在不同地理空间充电量的划分依据。

附录C图C2中不同颜色的空心点表示研究区域的POI数据结果;聚类算法得到的充电节点由图中不同颜色的实心点给出。通过聚类算法分别得到8个不同区域的充电节点,其中充电节点所包含的最大充电站数量为11个,即图C2中充电节点5的区域;最小充电站数量为3个,即图C2中充电节点1的区域。

### 4.2 动态轨迹能耗与固定里程能耗比较

传统能耗估计方法主要由行驶里程与单位里程固定能耗所求得,与本文所提的能耗方法具有一定偏差。因此,本文抽取由动态能耗模型得到的电动私家车用户用能结果,并通过GPS数据计算得到EV用户行驶里程,对比动态能耗模型与固定能耗模型的能耗结果,如附录F图F1所示。由附录F图F1可知,相较于固定能耗模型的单位里程耗电量均值,动态能耗模型所求得的单位里程耗电量均值高出35%,其原因主要如下:

1)EV行驶过程因受交通流影响频繁切换行驶状态,导致EV能耗变化波动大;

2)动态能耗模型的怠速状态在城市EV行驶过程中经常出现,增加了固定能耗模型所忽略的停车状态耗电量;

3)本文数据采集的时间及区域范围环境温度约为 $18^\circ\text{C}$ ,属于初冬季节,EV能耗进一步扩大。

### 4.3 区域充电负荷需求估计

以0.5h为时间间隔,基于所提的轨迹数据驱动方法,可分别得到电动私家车用户与电动运营车用户的充电负荷需求,如图2所示。




图2 不同车辆类型的充电需求负荷

Fig. 2 Charging demand load of different vehicle types

由图 2(a)可知,由于电动私家车用户的日均充电次数小于等于 1,其充电时段主要集中在 19:00—次日 03:00,且充电需求高峰出现在 23:00,此时私家车的充电总需求将达到 3 789 kW。此外,通过对比不同区域的充电负荷可知,研究区域中的充电节点 4 的功率普遍大于其他充电节点,此现象的主要原因是充电节点 4 所处区域具有较高的人口密度,从而引发了较高的充电需求。

对于一般运营车的充电需求估计,由于大多数运营车具有日均充电次数大于等于 1 的充电特性,其日均充电需求相较于私家车用户具有更大的随机性及需求量,如图 2(b)所示。由图可知,除去充电区域 1、2 属于城市外环的边缘区域,其余各个节点的充电需求在 11:00—次日 03:00 均保持着较高的充电需求量。同时,各个节点的充电需求相对变化不大,也进一步验证了运营车充电时间及空间随机性较大的特点。通过计算运营车不同时间断面的充电需求可知,充电需求峰值出现在 17:00,其充电负荷约为 4 968 kW。

通过对不同类型 EV 用户的充电功率进行叠加,可得到如图 2(c)所示的 EV 总充电需求负荷。通过比较图 2(c)中不同时间断面及不同区域的充电需求可知,研究区域的总充电需求负荷在 23:00 达到最大值;此外,研究区域中充电节点 4 的充电需求总功率相较其他充电节点功率更大。

#### 4.4 充电需求空间位置定位

通过 GPS 定位数据及微观能耗模型,不仅能够求得不同时间序列的 EV 充电需求负荷,而且能够进一步精准定位 EV 充电需求在所研究区域的 POI 数据,如附录 G 图 G1 所示。

由附录 G 图 G1 可知,不同时间序列充电需求点空间位置具有明显差异。10:00—12:00 的充电需求点主要集中在研究区域中的三环附近地区(见图 G1(a))。此时,充电需求车辆主要为日常通勤出行的电动私家车用户,由于该类 EV 用户车辆停靠时间较长,往往会选取低功率充电桩进行充电,故可在该区域增加低功率充电桩的覆盖比例。此外,图 G1(b)给出了 14:00—16:00 的充电需求点 POI 结果。此时段的 EV 充电用户主要为电动运营车,由于运营需求的不确定性导致其充电需求 POI 坐标具有较大的随机性。但从图中也可以发现,研究区域中内环范围(充电节点 4、5、7)的充电需求点密度高于其他区域,此现象主要是由该范围商业区及住宅区密度大而引起的。此外,由于该类型 EV 的运营特性,EV 车主往往会选择高功率快充桩进行充电,可在该区域增加快充桩的覆盖比例。

#### 4.5 电动私家车用户参与 V2G 决策及经济性分析

前文已探讨电动私家车的充电需求时空分布特性,本节进一步探究工作时段闲置且未充电的电动私家车用户参与 V2G 需求响应的容量。通过本文第 1 章的轨迹数据驱动方法得到单体私家车的剩余荷电状态电量,并将此结果代入第 2 章所阐述的参与 V2G 需求响应决策模型中,得到不同类型私家车的参与数量分布情况,如图 3 所示。

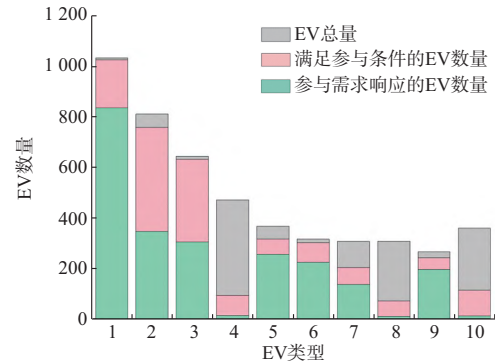


图 3 不同类型 EV 用户参与 V2G 需求响应的数量比较  
Fig. 3 Comparison of number of different types of EV users participating in V2G demand response

从图中可以看出,不同类型 EV 参与 V2G 需求响应的情况具有明显差异。其中,V2G 需求响应参与度最大的类型为 EV 数量占比最大的类型 1 群体。通过分析该类型 EV 群体的不同效用值结果可知,该类型 EV 群体因其相对较大的 EV 容量及偏低的 EV 价格(价格位于低档),导致该类型 EV 用户对需求响应的参与度比例达到约 81%。同时,对于具有相似容量及价格属性的 EV 类型 5 及类型 9,分别具有 80% 及 79% 的高参与度比例。此外,图 3 中 V2G 参与度比例相对较低的类型为 EV 类型 4、8 和 10,其 V2G 参与度比例分别为 13.9%、14.3% 和 9.6%。通过分析该 3 类 EV 用户可知,其参与度比例较低的主要原因是这 3 类 EV 的电池容量均小于等于 20 kW·h(其中 EV 类型 4 及类型 8 均为混合动力 EV),参与 V2G 放电将导致明显的里程焦虑问题。由此可知,EV 电池容量将制约不同类型 EV 参与 V2G 需求响应的积极性。此外,进一步比较该 3 类 EV 的参与度比例发现,尽管类型 10 属于在 3 类 EV 中相对大容量的纯电动 EV,但参与度也小于 EV 类型 4 及类型 8 的混合动力 EV。通过分析可知,造成此现象的原因是混合动力 EV 参与 V2G 的成本相对于纯电动 EV 参与 V2G 的成本偏高。本文分别比较了各类型 EV 参与 V2G 的经济效益,如图 4 所示。

图 4 中的左侧纵坐标表示不同类型 EV 参与 V2G 需求响应的性价比,其数值取决于响应补偿单

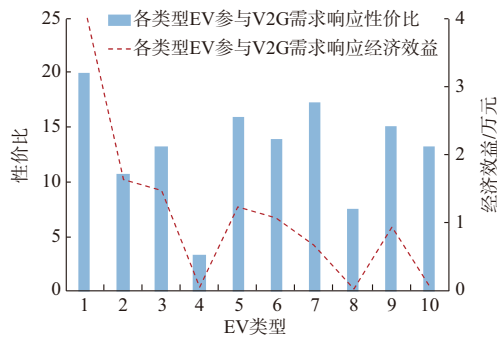


图4 不同类型EV用户参与V2G需求响应的性价比和经济效益

Fig. 4 Cost-performance ratio and economic benefits of different types of EV users participating in V2G demand responses

价与各EV类型参与响应的单位次数电池成本之比,右侧纵坐标表示不同类型EV参与响应后所获得的经济效益补偿值。从图中可知,除了受EV容量限制的类型4、8、10以外,其余各类型EV均可获得明显的经济补偿效益。

#### 4.6 电动私家车用户参与V2G需求响应评估

通过本文第3章中所提的优化调度模型,得到了研究区域中EV参与该区域需求响应的调节效果,调节步长取15 min,结果如图5所示。

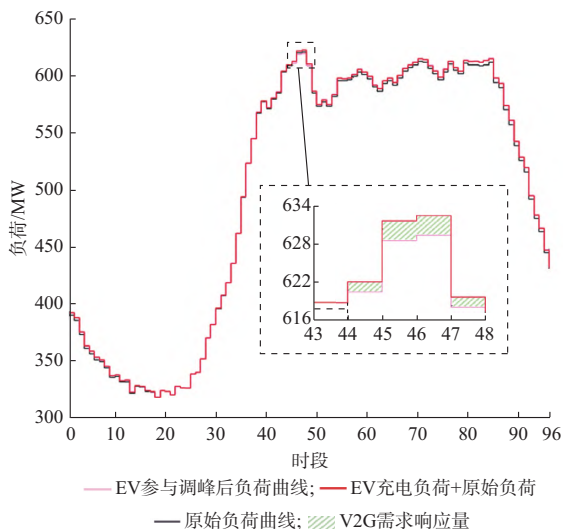


图5 区域EV用户参与V2G需求响应的调节效果  
Fig. 5 Regulation effect of regional EV users participating in V2G demand response

从图5中可知,目前该区域开展EV用户参与V2G需求响应的实际效果并不明显。通过计算求得EV用户参与调峰响应的时段为11:00—12:00,且该时段响应总量仅为8.14 MW·h。同时经分析可知,调节效果欠优主要受限于如下因素:

1) 本文引用的响应补偿规则限制了EV用户参

与需求响应的时间及每日次数,导致EV用户参与V2G的总响应量偏低;

2) 考虑到充电安全及慢充桩白天闲置数量较多等因素,本文假设EV用户参与V2G放电过程中均采用慢充桩,导致EV用户参与响应过程中放电功率偏低;

3) 研究区域较低的EV规模渗透率,导致EV充电需求量占该城市负荷需求的比例偏低,进而导致可参与需求响应的EV数量偏少。

## 5 结语

首先,本文提出一种基于行车轨迹大数据驱动的EV充电需求的时空估计方法;其次,基于社会行为学理论,构建了电动私家车用户参与需求响应的概率选择模型;进而,得到可参与需求响应的V2G可调度容量;最后,分析了该区域现有V2G可调度资源对区域电网的调峰效果。得到主要结论如下:

1) 轨迹动态信息数据求得的EV充电需求相较于传统充电需求估计方法<sup>[28]</sup>,不仅提高了不同时段充电需求估计的准确度,而且可获得EV充电需求空间分布点,为城市充电基础设施规划提供了参考。

2) EV用户利用V2G技术参与需求响应的积极程度受到EV电池容量及EV购买价格的影响。此外,本文得到了研究区域EV用户愿意参与V2G响应的用户比例约为43%(该数据考虑了未满足放电约束用户),一定程度上反映了社会初期开展V2G试点的社会反响情况。

3) 当前,本文研究区域的V2G资源调节能力对该区域负荷调峰效率略低。此外,EV参与需求响应的调节潜力受到需求响应规则、放电功率大小及EV规模渗透率等多方面的影响,可为该区域的相关部门提供政策导向。

本文在利用数据挖掘方式构建出行链过程中,受限于开源数据维度及规模的局限性,海量的开源数据信息仍有待探寻。此外,由于V2G需求响应的开展仍处于试验阶段,本文决策结果难以借鉴历史数据进行拟合及修正。未来,可考虑在相关实际数据支撑下利用机器学习分类算法或强化学习方法构建更为精准的EV用户决策模型。

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] 国务院办公厅. 新能源汽车产业发展规划(2021—2035年)[EB/



- OL]. (2020-11-02) [2021-07-30]. <https://chuneng.bjx.com.cn/news/20201102/1113435.shtml>.
- The General Office of the State Council. New energy automobile industry development plan (2021—2035) [EB/OL]. (2020-11-02) [2021-07-30]. <https://chuneng.bjx.com.cn/news/20201102/1113435.shtml>.
- [2] 蔚来与国网电动汽车签约:2021年共建100座充换电站,推广V2G实现电网削峰填谷[EB/OL].(2020-12-14)[2021-07-30]. <https://chuneng.bjx.com.cn/news/20201215/1122355.shtml>.
- NIO signs contract with State Grid Electric Vehicle Company: a total of 100 charging and swapping stations will be built to promote V2G to achieve grid peak shaving and valley filling in 2021 [EB/OL]. (2020-12-14) [2021-07-30]. <https://chuneng.bjx.com.cn/news/20201215/1122355.shtml>.
- [3] YANG W, XIANG Y, LIU J Y, et al. Agent-based modeling for scale evolution of plug-in electric vehicles and charging demand[J]. IEEE Transactions on Power Systems, 2018, 33(2): 1915-1925.
- [4] 陈丽丹, 聂涌泉, 钟庆. 基于出行链的电动汽车充电负荷预测模型[J]. 电工技术学报, 2015, 30(4): 216-225.
- CHEN Lidan, NIE Yongquan, ZHONG Qing. A model for electric vehicle charging load forecasting based on trip chains[J]. Transactions of China Electrotechnical Society, 2015, 30(4): 216-225.
- [5] XIANG Y, LIU Z P, LIU J C, et al. Integrated traffic-power simulation framework for electric vehicle charging stations based on cellular automation[J]. Journal of Modern Power Systems and Clean Energy, 2018, 6(4): 816-820.
- [6] 张宇轩, 郭力, 刘一欣, 等. 电动汽车充电负荷概率分布的数值建模方法[J]. 电力系统自动化, 2021, 45(18): 61-70.
- ZHANG Yuxuan, GUO Li, LIU Yixin, et al. Numerical modeling method for probability distribution of electric vehicle charging load[J]. Automation of Electric Power Systems, 2021, 45(18): 61-70.
- [7] 张洪财, 胡泽春, 宋永华, 等. 考虑时空分布的电动汽车充电负荷预测方法[J]. 电力系统自动化, 2014, 38(1): 13-20.
- ZHANG Hongcai, HU Zechun, SONG Yonghua, et al. A prediction method for electric vehicle charging load considering spatial and temporal distribution [J]. Automation of Electric Power Systems, 2014, 38(1): 13-20.
- [8] 张琳娟, 许长清, 王利利, 等. 基于OD矩阵的电动汽车充电负荷时空分布预测[J]. 电力系统保护与控制, 2021, 49(20): 82-91.
- ZHANG Linjuan, XU Changqing, WANG Lili, et al. OD matrix based spatiotemporal distribution of EV charging load prediction [J]. Power System Protection and Control, 2021, 49(20): 82-91.
- [9] 邵尹池, 穆云飞, 余晓丹, 等. “车-路-网”模式下电动汽车充电负荷时空预测及其对配电网潮流的影响[J]. 中国电机工程学报, 2017, 37(18): 5207-5219.
- SHAO Yinchi, MU Yunfei, YU Xiaodan, et al. A spatial-temporal charging load forecast and impact analysis method for distribution network using EVs-traffic-distribution model [J]. Proceedings of the CSEE, 2017, 37(18): 5207-5219.
- [10] RAUTAINEN A, REPO S, JARVENTAUSTA P, et al. Statistical charging load modeling of PHEVs in electricity distribution networks using national travel survey data [J]. IEEE Transactions on Smart Grid, 2012, 3(4): 1650-1659.
- [11] 田立亭, 史双龙, 贾卓. 电动汽车充电功率需求的统计学建模方法[J]. 电网技术, 2010, 34(11): 126-130.
- TIAN Liting, SHI Shuanglong, JIA Zhuo. A statistical model for charging power demand of electric vehicles [J]. Power System Technology, 2010, 34(11): 126-130.
- [12] DENG R Q, XIANG Y, DA H, et al. Exploring flexibility of electric vehicle aggregators as energy reserve [J]. Electric Power Systems Research, 2020, 184: 106305.
- [13] 张亚朋, 穆云飞, 贾宏杰, 等. 电动汽车虚拟电厂的多时间尺度响应能力评估模型[J]. 电力系统自动化, 2019, 43(12): 94-103.
- ZHANG Yapeng, MU Yunfei, JIA Hongjie, et al. Response capability evaluation model with multiple time scales for electric vehicle virtual power plant [J]. Automation of Electric Power Systems, 2019, 43(12): 94-103.
- [14] WANG M S, MU Y F, LI F X, et al. State space model of aggregated electric vehicles for frequency regulation [J]. IEEE Transactions on Smart Grid, 2020, 11(2): 981-994.
- [15] 张谦, 邓小松, 岳焕展, 等. 计及电池寿命损耗的电动汽车参与能量-调频市场协同优化策略[J]. 电工技术学报, 2022, 37(1): 72-81.
- ZHANG Qian, DENG Xiaosong, YUE Huanzhan, et al. Coordinated optimization strategy of electric vehicle cluster participating in energy and frequency regulation markets considering battery lifetime degradation [J]. Transactions of China Electrotechnical Society, 2022, 37(1): 72-81.
- [16] 邓艺璇, 黄玉萍, 黄周春. 基于随机森林算法的电动汽车充放电容量预测[J]. 电力系统自动化, 2021, 45(21): 181-188.
- DENG Yixuan, HUANG Yuping, HUANG Zhouchun. Charging and discharging capacity forecasting of electric vehicles based on random forest algorithm [J]. Automation of Electric Power Systems, 2021, 45(21): 181-188.
- [17] 张有兵, 任帅杰, 杨晓东, 等. 考虑价格型需求响应的独立型微电网优化配置[J]. 电力自动化设备, 2017, 37(7): 55-62.
- ZHANG Youbing, REN Shuaijie, YANG Xiaodong, et al. Optimal configuration considering price-based demand response for stand-alone microgrid [J]. Electric Power Automation Equipment, 2017, 37(7): 55-62.
- [18] 张谦, 蔡家佳, 李春燕, 等. 基于模糊贝叶斯学习的电动汽车放电电价谈判策略[J]. 中国电机工程学报, 2018, 38(1): 61-71.
- ZHANG Qian, CAI Jiajia, LI Chunyan, et al. The negotiation strategy of discharging price of electric vehicle based on fuzzy Bayesian learning [J]. Proceedings of the CSEE, 2018, 38(1): 61-71.
- [19] MU Y F, WU J Z, JENKINS N, et al. A spatial-temporal model for grid impact analysis of plug-in electric vehicles [J]. Applied Energy, 2014, 114: 456-465.
- [20] 温剑锋, 陶顺, 肖湘宁, 等. 基于出行链随机模拟的电动汽车充电需求分析[J]. 电网技术, 2015, 39(6): 1477-1484.
- WEN Jianfeng, TAO Shun, XIAO Xiangning, et al. Analysis on charging demand of EV based on stochastic simulation of trip chain [J]. Power System Technology, 2015, 39(6): 1477-1484.
- [21] 宋媛媛. 基于行驶工况的纯电动汽车能耗建模及续航里程估

- 算研究[D].北京:北京交通大学,2014.
- SONG Yuanyuan. Energy consumption modeling and cruising range estimation based on driving cycle for electric vehicles[D]. Beijing: Beijing Jiaotong University, 2014.
- [22] 张晨曦,丁明,张晶晶.基于交通出行矩阵的私家车充电负荷时空分布预测[J].电工技术学报,2017,32(1):78-87.
- ZHANG Chenyu, DING Ming, ZHANG Jingjing. A temporal and spatial distribution forecasting of private car charging load based on origin-destination matrix [J]. Transactions of China Electrotechnical Society, 2017, 32(1): 78-87.
- [23] ARIAS M B, KIM M, BAE S. Prediction of electric vehicle charging-power demand in realistic urban traffic networks [J]. Applied Energy, 2017, 195: 738-753.
- [24] 广州市工业和信息化局.广州市虚拟电厂实施细则[EB/OL]. (2021-02-10) [2021-07-30]. <https://baijiahao.baidu.com/s?id=1692180907705004232&wfr=spider&for=pc>.
- Guangzhou Municipal Industry and Information Technology Bureau. Implementation rules of virtual power plant in Guangzhou [EB/OL]. (2021-02-10) [2021-07-30]. <https://baijiahao.baidu.com/s?id=1692180907705004232&wfr=spider&for=pc>.
- [25] MEADE N, ISLAM T. Modelling and forecasting the diffusion of innovation—a 25-year review [J]. International Journal of Forecasting, 2006, 22(3): 519-545.
- [26] 谭维玉.计及用户需求侧响应的电动汽车充放电电价制定策略研究[D].重庆:重庆大学,2019.
- TAN Weiyu. Study on the formulation strategy of charging and discharging price for electric vehicles considering demand side response[D]. Chongqing: Chongqing University, 2019.
- [27] 陈琦.普华永道:整车厂“三电”产业链布局策略[J].汽车与配件,2019(15):32-33.
- CHEN Qi. Pricewaterhouse Coopers: industrial chain layout strategy of “battery, motor and electronic control” [J]. Automobile & Parts, 2019(15): 32-33.
- [28] 蒋卓臻,向月,刘俊勇,等.集成电动汽车全轨迹空间的充电负荷建模及对配电网可靠性的影响[J].电网技术,2019,43(10):3789-3800.
- JIANG Zhuozhen, XIANG Yue, LIU Junyong, et al. Charging load modeling integrated with electric vehicle whole trajectory space and its impact on distribution network reliability [J]. Power System Technology, 2019, 43(10): 3789-3800.

周椿奇(1995—),男,硕士研究生,主要研究方向:智能电网与电动汽车交互。E-mail:1249787972@qq.com

向月(1987—),男,通信作者,副教授,博士生导师,主要研究方向:智能电网与电动汽车交互。E-mail:xiang@scu.edu.cn

童话(1997—),男,硕士研究生,主要研究方向:电动汽车并网运营。E-mail:529165561@qq.com

(编辑 章黎)

## Trajectory-data-driven Estimation of Electric Vehicle Charging Demand and Vehicle-to-Grid Regulable Capacity

ZHOU Chunqi, XIANG Yue, TONG Hua, RAO Ping, QING Yifan, LIU Youbo  
(College of Electrical Engineering, Sichuan University, Chengdu 610065, China)

**Abstract:** Electric vehicle (EV) charging demand estimation is an important precondition for studying the vehicle-to-grid (V2G) interaction. Therefore, this paper proposes a charging demand prediction model of EVs driven by driving trajectory data, constructs a decision-making model of users to choose to participate in V2G response by further considering the multi-dimensional benefits of users, and analyzes the regulation potential of regional V2G response capabilities. Firstly, the big data set of driving trajectory is cleaned and mined, and a prediction model for the spatio-temporal distribution of EV charging demand is constructed based on the dynamic energy consumption theory. Secondly, based on the social behavior theory and considering the electricity demand utility, economic utility, environmental protection utility and social utility, the probabilistic selection model of EV users participating in V2G response is constructed. The model not only considers the heterogeneity of EV users, but also reflects the interactive influence of user decisions. Finally, a V2G responsive capacity regulation model is established to analyze the adjustment effect of V2G responsive resources on the regional load. The results show that the proposed model can not only effectively estimate the spatio-temporal distribution characteristics of EV charging demand in a certain urban area, but also obtain the number of potential EV users who choose to participate in V2G response in this area, which provides support for studying the regulation potential of V2G responsive resources on the regional load.

This work is supported by National Natural Science Foundation of China (No. 52111530067) and Science and Technology Program of Sichuan Province (No. 2020YFSY0037).

**Key words:** electric vehicle; trajectory big data; data mining; spatio-temporal distribution of charging demand; user decision behavior; vehicle-to-grid (V2G); responsive capacity; regional regulation potential

