

文章编号: 2095-2163(2022)11-0054-10

中图分类号: TM 721

文献标志码: A

基于用户出行习惯的电动汽车充电负荷预测

杜 纤, 龙本锦, 郭永强, 黄世超, 江 奔, 何成龙

(贵州大学 电气工程学院, 贵阳 550025)

摘要: 电动汽车的普及和日益增长的充电需求给配电网调度带来了经济、技术上的挑战。由于用户充电行为的随机性, 预测电动汽车的充电负荷必须准确描述用户的出行习惯。本文基于行程链的概念结合条件概率分布描述用户出行习惯, 通过蒙特卡罗模拟方法, 仿真大量电动汽车在不同区域类型内的驾驶、停放和充电行为, 从而得到电动汽车在不同区域内的充电负荷。应用美国家庭出行调查(National Household Travel Survey, NHTS)数据进行仿真验证, 结果表明基于用户行程链的电动汽车充电负荷预测模型可以准确地预测电动汽车在不同区域类型内的充电负荷, 同一区域类型下不同的充电情景的负荷分布形式不一样, 不同区域类型的充电负荷具有明显差异。

关键词: 电动汽车; 充电需求; 行程链; 充电负荷预测; 蒙特卡罗模拟

Prediction of electric vehicles charging load based on user travel habits

DU Xian, LONG Benjin, GUO Yongqiang, HUANG Shichao, JIANG Ben, HE Chenglong

(College of Electrical Engineering, Guizhou University, Guiyang 550025, China)

[Abstract] The popularity of electric vehicles and the growing demand for charging have brought economic and technical challenges to distribution network scheduling. Due to the randomness of users' charging behavior, predicting the charging load of electric vehicles must accurately describe users' travel habits. Based on the concept of trip chain and conditional probability distribution, this paper describes the user's travel habits, and uses the Monte Carlo simulation method to simulate the driving, parking and charging behavior of a large number of electric vehicles in different types of areas, so as to obtain the charging load of electric vehicles in different areas. Using the data of the National Household Travel Survey (NHTS) in the United States for simulation verification, the results show that the electric vehicle charging load prediction model based on the user journey chain can accurately predict the charging load of electric vehicles in different types of regions. The load distribution forms of different charging scenarios are different, and the charging loads of different types of regions are significantly different.

[Key words] electric vehicles; charging requirements; travel chain; charging load prediction; Monte Carlo simulation

0 引言

近年来由于“碳达峰、碳中和”的“双减”环境要求, 电动汽车(Electric vehicle, EV)作为一种低碳、环保的汽车将替代燃油汽车成为主要的交通工具。2017年, 全球电动汽车总数已达到300多万辆, 并持续呈现出稳步上升的良好态势^[1]。大规模的电动汽车增加了总电力需求, 电力系统的负荷水平将会急剧上升, 从而对配电网的稳定性和安全产生负面影响^[2-3]。电动汽车的充电负荷因其时间和空间的分布具有较大的随机性受多种因素影响, 预测充电负荷难度较大^[4-5]。

文献[6]提出了一种预测电动汽车停车场充电需求的回归综合移动平均方法, 考虑了行驶里程、到

达停车场的的时间以及离开停车场的的时间。文献[7]探讨了电动汽车车主的驱动意图和电价对充电需求在时空上的分布影响, 建立了电动汽车时空分布特征的充电负荷模型, 但是电动汽车的位置和电动汽车充电周期固定, 未能反映电动汽车的具体行驶过程。在假设电动汽车到达充电站的时间遵循泊松分布的前提下, 文献[8]提出了计算充电站负荷的排队模型。但是该方法适用于单个商场停车场或者公路服务区等集中场所充电负荷的计算。文献[9-10]还调查研究了基于不同的充电场景的公共充电, 如工业区域、商业区及其组合。文献[11]用单一对数正态分布描述电动汽车用户的出行规律, 该方法可以在一定程度上反映用户的出行规律。文献[12]分析了电动汽车的充电需求, 并且基于行程链

作者简介: 杜 纤(1996-), 女, 硕士研究生, 主要研究方向: 电动汽车充放电; 龙本锦(1994-), 男, 硕士研究生, 主要研究方向: 储能技术在电力系统中的应用; 郭永强(1992-), 男, 硕士研究生, 主要研究方向: 微电网广义储能配置; 黄世超(1995-), 男, 硕士研究生, 主要研究方向: 综合能源系统负荷预测; 江 奔(2000-), 男, 本科生, 主要研究方向: 电动汽车宏观经济管理; 何成龙(2000-), 男, 本科生, 主要研究方向: 电动汽车宏观经济管理。

收稿日期: 2022-03-09

哈尔滨工业大学主办 ◆ 学术研究与应用

建立了电动汽车出行的规律。

以上研究大多对用户的行程链模拟的空间分配是预先确定的,而不是用概率模型来模拟完全随机移动的电动汽车负荷的时空变化,不仅没有考虑电动汽车用户在日内的空间移动状态,而且也未能根据用户实际充电需求来讨论一日多充的情况。电动汽车的充电需求对系统调度和电力市场有相当大的影响。系统操作员应分析、并掌握电动汽车充电需求及其随机性,以便为系统提供充足的能源和储备^[13]。更准确的电动汽车需求预测模型可以使市场受益,并通过减少日前调度和实时运行之间的不匹配来降低成本。为了充分分析电动汽车充电随机性,本文利用行程链的概念来描述用户的出行规律,其中包含时间和空间特征量的概率分布,包括第一次行程的开始时间、驾驶时长、停车时长、不同类型的出发地和目的地、以及行驶的里程,并采用符合实际特征的分布函数拟合不一样特征量的概率分布。在研究电动汽车充电负荷的模型过程中考虑电动汽车充电的快充和慢充模式,这里是假设电动汽车用户可选择快充和慢充两种模式。最后应用蒙特卡罗模拟方法,生成电动汽车的每日行程链,从而得到电动汽车在不同区域内的充电需求。

1 行程链概念

用户的充电行为直接决定了充电负荷的时空特

性,因此有必要对其进行研究,电动汽车用户的充电行为与用户出行的习惯紧密相关,准确地描述用户每天的出行习惯是分析充电需求的基础。本文采用行程链的概念来拟合用户的出行习惯,行程链描述了用户从起点出发,按照一定的时间顺序和日常习惯经过多个目的地,最终到达终点,完成预定出行的过程^[14]。根据 NHTS 最新的出行目的的分析^[15],私家车的主要出行目的见表 1。在本文行程链的目的地类型中,主要分为 3 类待测区域:居民区充电站(D_1)、工作区充电站(D_2)、商业娱乐区充电站(D_3)。

表 1 私家车主要出行目的地类型占比

Tab. 1 Proportion of main travel destination types of private cars

出行类型	回家	工作	商业娱乐	其他
比例	45.27	13.64	32.82	3.34

本文假设电动汽车用户一天的起点和终点都在居民区,包含时间和空间两类特征量。行程链的简化示意图见图 1。在时间链中,2 个实心点表示电动汽车用户在一天的行程链中行程开始的时刻以及结束行程的时刻,中间的空心点表示在一日行程链中第 i 次出行到达时刻和离开的时刻。虚线表示的是电动汽车在道路上行驶的过程,而实线表示的是电动汽车在某一区域内停车的过程。

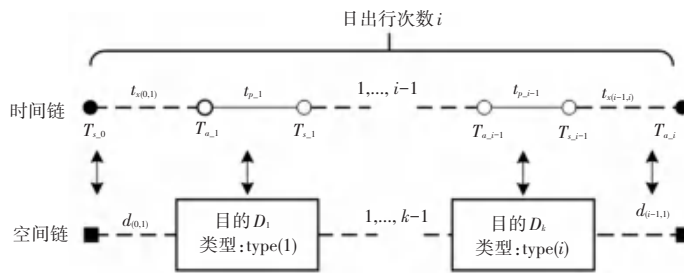


图 1 行程链示意图

Fig. 1 Schematic diagram of travel chain

根据行程链的示意图可得,行程链的特征量包括空间和时间两类。对此拟做分析论述如下。

(1) 时间特征量,从时间的角度描述用户的行程。包括第 i 次出行到达目的地的时刻 $T_{a,i}$ 和离开当前目的地去下一个目的地的时刻 $T_{s,i}$, $t_{x(i-1,i)}$ 表示第 i 次出行从上一个目的地到达本次目的地需要行驶的行驶时长, $t_{p,i}$ 表示用户第 i 次出行在目的地停车的时长。这里, $T_{s,0}$ 表示首次出行的时刻。

(2) 空间特征量,从空间的角度来描述用户的行程。用户在一天中每一次出行的目的地类型分类

集合用 $\{D_1, D_2, \dots, D_U\}$ 表示,这里 $U=3$ 表示每次用户出行目的地类型总数。 $Type(i) = D_k$, D_k 表示的是用户在一日的行程链中第 i 次出行的目的地类型。 $d_{(i-1,i)}$ 表示的是第 i 次出行从上一个目的地到达本次目的地的行驶里程。

2 特征量的拟合模型

2.1 时间特征量

在时间链中,时间是具有连续性的,所以每个时间特征量之间具有相关性。在一个完整的

行程链中,第 i 次出行到达目的地的时刻和离开目的地的时刻可由公式(1) 计算得到:

$$\begin{cases} T_{a,i} = T_{s,i-1} + t_x(i-1, i) \\ T_{s,i} = T_{a,i} + t_{p,i} \end{cases} \quad (1)$$

根据式(1)可以得知,只要得知用户上个目的地离开的时刻、第 i 次出行在目的地的停车时长、从一个目的地到第 i 次出行目的地电动汽车的驾驶时长,就可以计算出到达目的地的时刻和离开时刻。

由第1节可知需要拟合的时间特征量有3类,停车时长的条件概率按照出行的目的地类型进行拟合,行驶时长根据本次出行的目的地的始末端进行拟合。现有的对电动汽车的特征量模拟拟合的条件概率在大多数研究中用的是已知的概率分布,如指数分布、正态分布,此方法局限性太大,并且不符合实际分布。考虑到可根据不同特征量的分布特征来采用合理的分布进行拟合,本文主要采用高斯混合分布(Gaussian mixture model, GMM)拟合^[16]。

混合高斯模型的本质就是融合几个单一的高斯模型,来使得模型更加复杂,从而产生更复杂的样本。理论上,如果某个混合高斯模型融合的高斯模型个数足够多,并对其权重设定得足够合理,该混合模型就可以拟合任意分布的样本。此处需用到的数学公式可写为:

$$p(x_i | \Theta) = \sum_j^M \alpha_j N_j(x_i, \mu_j, \sigma_j^2) \quad (2)$$

这里,进一步推得的公式为:

$$\begin{aligned} N_j(x_j, \mu_j, \sigma_j^2) &= \frac{1}{\sigma_j \sqrt{2\pi}} \exp\left(-\frac{1}{2\sigma_j^2}(x - \mu_j)^2\right) \\ 0 < \alpha_j &\leq 1 \\ \sum_{j=1}^M \alpha_j &= 1 \end{aligned} \quad (3)$$

其中, $\Theta = (\theta_1, \dots, \theta_M)$ 表示参数合集; $\theta_j = (\alpha_j, \mu_j, \sigma_j^2)$ 为第 j 个高斯分布的分布参数; α_j 为混合高斯参数中的第 j 个高斯分布所占的权重; μ_j, σ_j^2 分别为第 j 个高斯分布的均值和方差。

本文主要采用 GMM 拟合时间特征量的概率分布, GMM 分布能更好地拟合无明显特征的分布,相对常见的正态分布能更好地体现数据的实际分布特征,对于时间特征量的拟合分布概率函数, GMM 子函数的数量越多,概率分布的拟合精度越高,本文对于时间特征量的 GMM 拟合采用3个高斯子函数即可确保拟合精度、即 $M = 3$,其余的高斯混合模型中的参数估计使用最大期望值算法(Expectation

maximization, EM)。

蒙特卡罗根据所得的时间特征量的概率密度函数的输入,分别抽取随机数,而且根据式(1)计算剩余的时间特征量,构成一个完整的用户出行时间链。

2.2 空间特征量

在空间链中,空间特征量也受到时间特征量的影响。本次出行的目的地类型与上一次出行的目的地类型和离开上个目的地的时刻有关。行驶里程 $d_{(i-1,i)}$ 由行驶的时长决定,所以行驶里程的条件概率分布可以表示为行驶时长的条件概率。这里可展开研究分述如下。

(1) 出行目的转移概率。目的地的类型取决于前一个目的地的离开时刻和类型。本文将选择行程目的地的概率表示为转移概率矩阵。基于 NHTS 数据集,根据目的地类型收集到不同目的地的转移频率,并将其应用于近似的转移概率。本文将一日内的 T_s 离散为24个时间段,可以将转移到目的地的条件概率转换为 $24 \times 3 \times 3$ 尺度的矩阵形式。文中的数学公式具体如下:

$$P_{T_k} = \begin{pmatrix} \hat{p}_{t_k, D_1, D_1} & \hat{p}_{t_k, D_1, D_2} & \hat{p}_{t_k, D_1, D_3} \\ \hat{p}_{t_k, D_2, D_1} & \hat{p}_{t_k, D_2, D_2} & \hat{p}_{t_k, D_2, D_3} \\ \hat{p}_{t_k, D_3, D_1} & \hat{p}_{t_k, D_3, D_2} & \hat{p}_{t_k, D_3, D_3} \end{pmatrix} \quad (4)$$

其中, p_{t_k, D_i, D_j} 表示在 $t_{i-1} \sim t_k$ 时间段内,用户结束上一次目的地行程后出发前往下个目的地的概率; U 为目的地的总类型,本文中 $U = 3$ 。且 $\sum_{j=1}^U p_{t_k, D_i, D_j} = 1$, 即电动汽车用户结束上一次行程选择下个目的地的总概率和为1。

(2) 行驶里程的条件概率。2个目的地之间的行驶持续时间由行驶里程 d 和速度决定。因此,行驶时长和 d 自然是相互关联的,关系如式(5)所示:

$$d = vt_x \quad (5)$$

这2个变量之间的关系已知时,将行驶里程 d 的分布描述为行驶时长的条件概率分布。其概率密度分布可以描述为式(6):

$$p_d(d | t_x) = \frac{1}{\sqrt{2\pi} \sigma_d(t_x)} e^{-\frac{1}{2\sigma_d^2(t_x)}[d - \mu_d(t_x)]^2} \quad (6)$$

在模拟用户行程链的过程中,根据行程类别提取行驶时间,并利用式(6)得到行驶里程。在本节中,基于上述拟合结果,生成每个随机数服从对应的概率分布。基于蒙特卡罗模拟仿真生成多个电动汽车用户的行程链流程如图2所示。

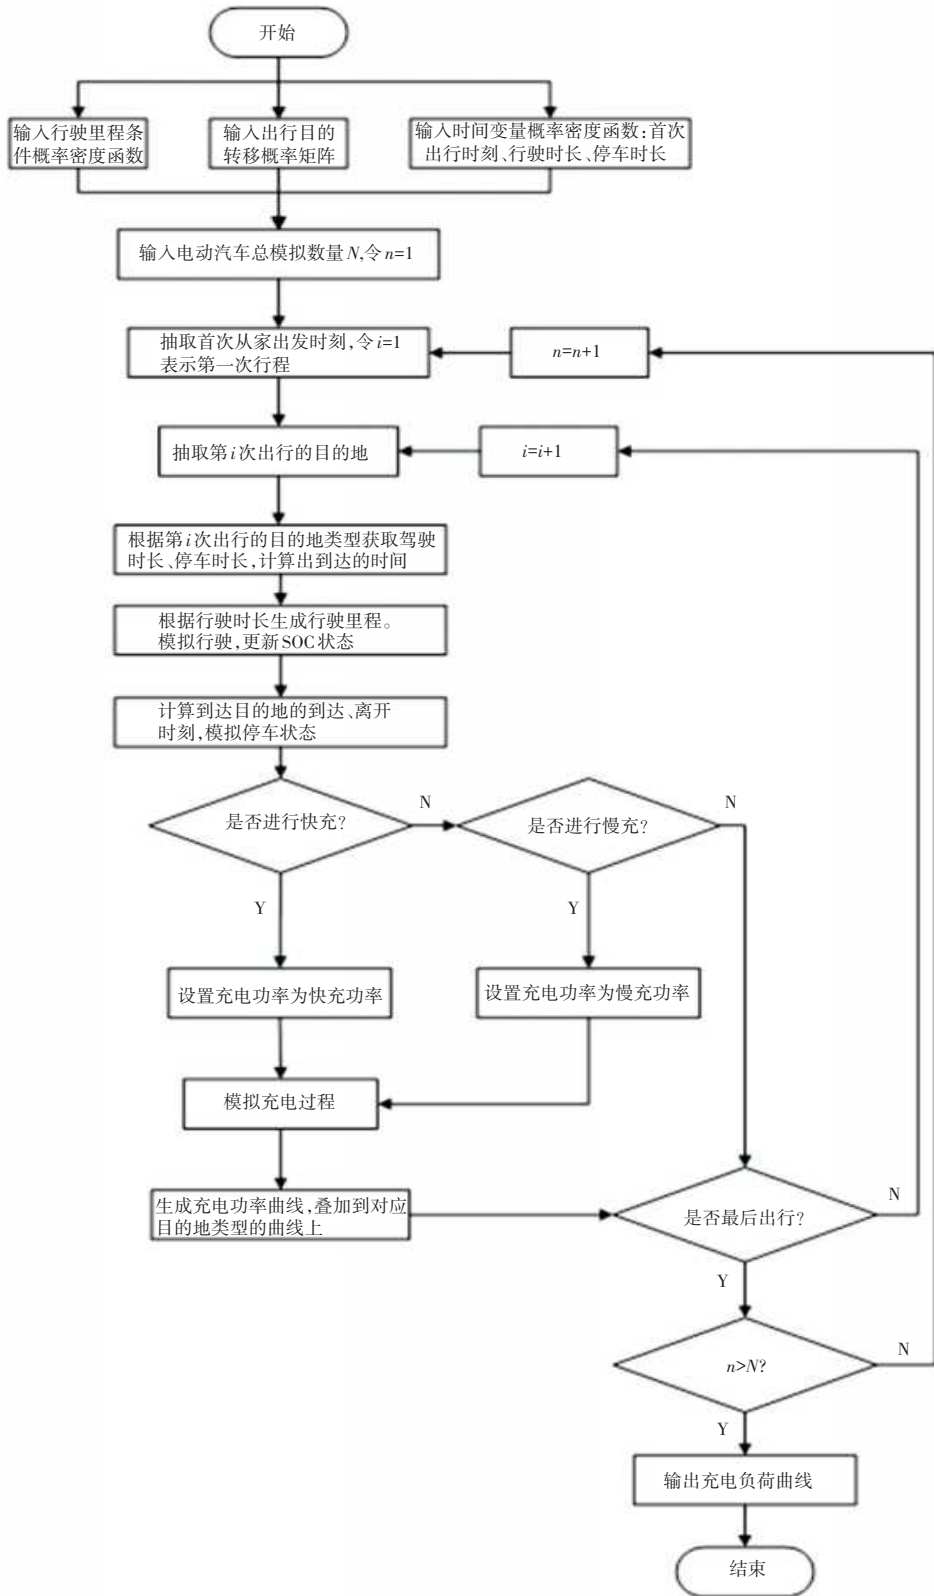


图 2 基于蒙特卡罗模拟的电动汽车充电需求预测流程图

Fig. 2 Flow chart of electric vehicle charging demand prediction based on Monte Carlo simulation

3 用户充电行为分析

本文研究了2种充电方式:交流电源慢速充电模式和直流电源快速充电模式。考虑到电动汽车快充模式下会严重影响电池寿命问题,常规充电模式多会选择慢充。

EV用户的充电行为直接决定了充电负荷的时空特性,因此有必要对其进行研究。用户的充电行为主要取决于个人偏好,例如,有些用户每天出行后往往在家里给电动汽车充电,而有些用户更喜欢外出时充电。如果电动汽车的日里程不远,用户可能对荷电状态(State of charge, SOC)有更高的心理容忍度,会每隔几天充电一次,这意味着只要SOC能满足行程需求,用户就不会担心充电。

本文对于电动汽车用户的充电行为做如下假设:

(1)电动汽车用户到达某一个目的地后,电动汽车的SOC剩余量如果不能保证电动汽车行驶到下一个目的地,电动汽车车主将选择在当前充电站充电。车主只有在停车的时长内才充电,电动汽车车主充电有2种充电模式可供选择。考虑到电动汽车用户在目的地可能停留的时长,慢充将不足以使用户剩余的电量能够行驶到下一个目的地,而且再辅以对驾驶过程安全性的考虑,电动汽车的剩余电池容量应不小于15%^[17]。由此可知,只有在目的地充电后并且足够下段行程的耗电量的容量不大于S的15%时才选择快充模式,相应的数学公式见如下:

$$S_{a_i} - \lambda d_{(i,i+1)} + \frac{P_{st_{p_i}}}{60} \leq 0.15S \quad (7)$$

其中, S_{a_i} 表示电动汽车到达目的地后的剩余电量,单位为 kWh; λ 表示 EV 每公里的耗电量,单位为 (kWh/km); P_s 表示 EV 用户选择慢充的功率,单位为 kW; S 表示 EV 的电池总容量,单位为 kWh。

(2)若电动汽车到达目的地后的剩余电量足够

下次行程的里程消耗,车主可以不考虑充电或者慢充。当电动汽车到达时刻的容量小于80%时候,用户可选择慢充。

4 基于 NHTS 数据的仿真分析

4.1 特征量的拟合结果分析

本研究为了建立每个特征量的概率分布,利用 NHTS 数据集从大量的出行统计数据中提取这些特征,从而生成概率分布。数据集提供了关于行程链的全面数据,包括行程开始和结束时间、行驶距离和每次行程的目的地类型。

4.1.1 时间特征量概率分布

本文主要采用 GMM 拟合时间特征量的概率分布,GMM 分布能更好地拟合无明显特征的分布,相对常见的正态分布能更好地体现数据的实际分布特征。对此可进行重点论述如下。

(1)首次行程的开始时刻。本文设定的首次出行是从目的地开始的一天的行程链,根据 GMM 拟合的结果和结果参数分别如图3所示。




图3 首次出行时刻概率分布

Fig. 3 Probability distribution of first travel time in a day

首次出行时刻的 GMM 分布由3个高斯分布混合组成,拟合的参数见表2。从拟合可得知电动汽车用户首次出行的时刻主要集中在上午7:00~8:00之间,小部分用户的出行时刻在下午15:00~18:00之间。

表2 首次出行时刻的拟合参数

Tab. 2 Fitting parameters of the first travel time in a day

分量	N_1			N_2			N_3		
	α_1	μ_2	σ_3	α_1	μ_2	σ_3	α_1	μ_2	σ_3
参数	0.41	7.54	1.46	0.29	11.77	1.90	0.30	16.93	2.01

(2)行驶时长。根据电动汽车的行驶时长和离开上一个目的地的时刻可以得到到达本次目的地的时刻,本文根据出发和到达目的地的类型不同分别拟合不同的行驶时长概率分布,分布的参数矩阵见

表3~表11所示。研究中总共有3个类型的区域,根据出发地和目的地不同类型,所以一共有9个行驶时长的概率分布。

表 3 居民区到居民区的行驶时长 GMM 分布

Tab. 3 GMM distribution of driving hours from residential area to residential area

分量	N_1			N_2			N_3		
	α_1	μ_2	σ_3	α_1	μ_2	σ_3	α_1	μ_2	σ_3
参数	0.82	0.92	0.75	0.16	3.27	1.51	0.01	10.67	6.76

表 4 居民区到工作区的行驶时长 GMM 分布

Tab. 4 GMM distribution of driving hours from residential area to work area

分量	N_1			N_2			N_3		
	α_1	μ_2	σ_3	α_1	μ_2	σ_3	α_1	μ_2	σ_3
参数	0.84	0.36	0.49	0.01	9.12	10.36	0.14	1.97	0.91

表 5 居民区到商业娱乐区的行驶时长 GMM 分布

Tab. 5 GMM distribution of driving hours from residential area to commercial entertainment area

分量	N_1			N_2			N_3		
	α_1	μ_2	σ_3	α_1	μ_2	σ_3	α_1	μ_2	σ_3
参数	0.81	0.23	0.42	0.02	10.49	8.32	0.17	2.04	1.23

表 6 工作区到居民区的行驶时长 GMM 分布

Tab. 6 GMM distribution of driving hours from work area to residential area

分量	N_1			N_2			N_3		
	α_1	μ_2	σ_3	α_1	μ_2	σ_3	α_1	μ_2	σ_3
参数	0.42	1.22	0.42	0.49	3.36	2.60	0.09	0	0

表 7 工作区到工作区的行驶时长 GMM 分布

Tab. 7 GMM distribution of driving hours from work area to work area

分量	N_1			N_2			N_3		
	α_1	μ_2	σ_3	α_1	μ_2	σ_3	α_1	μ_2	σ_3
参数	0.72	0.51	0.54	0.02	9.47	7.91	0.26	1.95	0.88

表 8 工作区到商业娱乐区的行驶时长 GMM 分布

Tab. 8 GMM distribution of driving hours from work area to commercial entertainment area

分量	N_1			N_2			N_3		
	α_1	μ_2	σ_3	α_1	μ_2	σ_3	α_1	μ_2	σ_3
参数	0.81	0.23	0.42	0.16	1.89	1.00	0.02	7.97	5.93

表 9 商业娱乐区到居民区的行驶时长 GMM 分布

Tab. 9 GMM distribution of driving hours from commercial entertainment area to residential area

分量	N_1			N_2			N_3		
	α_1	μ_2	σ_3	α_1	μ_2	σ_3	α_1	μ_2	σ_3
参数	0.08	0.00	0.00	0.60	4.41	3.73	0.32	1.22	0.41

表 10 商业娱乐区到工作区的行驶时长 GMM 分布

Tab. 10 GMM distribution of driving hours from commercial entertainment area to work area

分量	N_1			N_2			N_3		
	α_1	μ_2	σ_3	α_1	μ_2	σ_3	α_1	μ_2	σ_3
参数	0.06	0.00	0.00	0.69	5.11	5.35	0.25	1.19	0.39


表 11 商业娱乐区到商业娱乐区的行驶时长 GMM 分布

Tab. 11 GMM distribution of driving hours from commercial entertainment area to commercial entertainment area


分量	N_1			N_2			N_3		
	α_1	μ_2	σ_3	α_1	μ_2	σ_3	α_1	μ_2	σ_3
参数	0.77	0.24	0.43	0.19	2.19	1.34	0.04	11.27	7.97

(3) 不同区域内的停车时长。不同目的类型的停车时长概率分布差别较大,3个区域内的停车时长的概率分布如图4所示。各区域内停车时长的分布特征差别较大,本文根据电动汽车在不同的区域内抽取相对区域停车时长概率。在本文中,拟合电动汽车在居民区域内停车的时长仅考虑中途回家停留。


的地两两组合,因为数据量足够大,可以对每一时段内基于不同起点的车辆转移频率进行统计,采用离散时间矩阵来表示目的类型转移的概率矩阵,时间离散为24个时刻,求得的拟合转移概率矩阵可写为:



(a) 居民区



(b) 工作区



(c) 商业娱乐区

图 4 不同目的地停车时长概率分布

Fig. 4 Probability distribution of parking time at different destinations

4.1.2 空间特征量概率分布

(1) 出行目的转移概率。本文将3种类型的目

$$\begin{aligned}
 P_1 &= \begin{pmatrix} 0.057 & 0.326 & 0.616 \\ 0.821 & 0.107 & 0.071 \\ 0.240 & 0.073 & 0.686 \end{pmatrix} \\
 P_2 &= \begin{pmatrix} 0.050 & 0.283 & 0.666 \\ 0.636 & 0.090 & 0.272 \\ 0.178 & 0.050 & 0.771 \end{pmatrix} \\
 P_3 &= \begin{pmatrix} 0.026 & 0.360 & 0.613 \\ 0.542 & 0.042 & 0.414 \\ 0.292 & 0.067 & 0.640 \end{pmatrix} \\
 P_4 &= \begin{pmatrix} 0.038 & 0.453 & 0.508 \\ 0.770 & 0.011 & 0.218 \\ 0.409 & 0.136 & 0.454 \end{pmatrix} \\
 P_5 &= \begin{pmatrix} 0.762 & 0.011 & 0.226 \\ 0.859 & 0.004 & 0.135 \\ 0.532 & 0.097 & 0.369 \end{pmatrix} \\
 P_6 &= \begin{pmatrix} 0.862 & 0.016 & 0.121 \\ 0.972 & 0.008 & 0.019 \\ 0.833 & 0.059 & 0.107 \end{pmatrix} \\
 P_7 &= \begin{pmatrix} 0.810 & 0.022 & 0.166 \\ 0.971 & 0.007 & 0.021 \\ 0.869 & 0.047 & 0.082 \end{pmatrix} \\
 P_8 &= \begin{pmatrix} 0.831 & 0.017 & 0.151 \\ 0.963 & 0.009 & 0.026 \\ 0.902 & 0.031 & 0.066 \end{pmatrix} \\
 P_9 &= \begin{pmatrix} 0.699 & 0.027 & 0.272 \\ 0.912 & 0.036 & 0.050 \\ 0.859 & 0.028 & 0.112 \end{pmatrix} \\
 P_{10} &= \begin{pmatrix} 0.542 & 0.029 & 0.428 \\ 0.754 & 0.128 & 0.116 \\ 0.797 & 0.027 & 0.175 \end{pmatrix} \\
 P_{11} &= \begin{pmatrix} 0.419 & 0.029 & 0.550 \\ 0.561 & 0.245 & 0.193 \\ 0.720 & 0.027 & 0.252 \end{pmatrix}
 \end{aligned}$$

$P_{12} =$	0.294 1	0.066 1	0.639 6
	0.381 4	0.421 8	0.196 6
	0.569 1	0.080 1	0.350 7
$P_{13} =$	0.212 3	0.106 5	0.681 0
	0.321 4	0.366 4	0.312 1
	0.504 4	0.098 1	0.397 3
$P_{14} =$	0.272 1	0.084 0	0.643 8
	0.396 9	0.216 6	0.386 3
	0.565 6	0.053 4	0.380 8
$P_{15} =$	0.284 7	0.110 5	0.640 6
	0.493 7	0.213 1	0.293 0
	0.534 5	0.057 4	0.407 9
$P_{16} =$	0.200 5	0.199 2	0.600 2
	0.492 4	0.227 9	0.279 6
	0.520 6	0.082 5	0.391 3
$P_{17} =$	0.212 1	0.311 6	0.476 1
	0.544 4	0.189 2	0.266 3
	0.604 9	0.092 2	0.302 8
$P_{18} =$	0.193 7	0.366 4	0.439 8
	0.596 1	0.162 2	0.241 5
	0.666 4	0.085 8	0.247 6
$P_{19} =$	0.240 3	0.200 2	0.559 4
	0.626 1	0.098 7	0.275 0
	0.719 6	0.037 5	0.242 7
$P_{20} =$	0.212 2	0.106 5	0.681 1
	0.565 2	0.150 5	0.284 2
	0.616 1	0.024 5	0.359 3
$P_{21} =$	0.142 5	0.071 8	0.785 6
	0.549 2	0.091 5	0.359 1
	0.465 7	0.023 9	0.510 3
$P_{22} =$	0.112 9	0.088 4	0.798 5
	0.615 0	0.055 0	0.330 0
	0.368 5	0.031 1	0.600 2
$P_{23} =$	0.113 7	0.164 0	0.722 2
	0.655 5	0.023 1	0.321 3
	0.306 8	0.042 2	0.650 9
$P_{24} =$	0.621 4	0.280 3	0.098 2
	0.783 2	0.072 4	0.014 4
	0.830 9	0.059 8	0.109 3

由转移概率矩阵可以根据抽取的首次出行时刻,选取相对应时段内的转移概率矩阵,即可得到下个目的地的出行类型。

(2) 行驶里程条件概率。本文将行驶里程 d 的分布描述为 t_x 的条件概率分布,根据式(6)拟合得到

行驶里程的概率分布。行驶里程的均值和标准差均为行驶时长 t_x 的函数 $\sigma_d(t_x)$ 、 $\mu_d(t_x)$ 。由各个时间段里平均行驶里程和行驶里程的标准差,将行驶时长与各个时段里的平均行驶里程以及标准差进行拟合。行驶里程的平均值和标准差与行驶时长 t_x 的拟合图如图 5 所示。表 12 是根据图 5 拟合的行驶时长和行驶里程平均值关系、行驶时长和行驶里程标准差关系的拟合数据,这里的行驶里程服从行驶时长的条件正态分布 $N[5.608 9 t_x^{0.631 2}, 3.714 0 t_x^{0.565 1}]$ 。

表 12 $\sigma_d(t_x)$ 、 $\mu_d(t_x)$ 的拟合结果

Tab. 12 Fitting results of $\sigma_d(t_x)$ 、 $\mu_d(t_x)$

函数	参数 $[a, b]$	
	平均值 μ	标准差 σ
$y = ax^b$	$[5.608 9 \quad 0.631 2]$	$[3.714 0 \quad 0.565 1]$

根据式(6)可得行驶里程的条件概率密度分布具体如下:

$$P_d(d | t_x) = \frac{1}{3.714 0 \sqrt{2\pi} t_x^{0.565 1}} e^{-\frac{1}{2(3.714 0 t_x^{0.565 1})^2} [d - 5.608 9 t_x^{0.631 2}]^2} \quad (8)$$

在蒙特卡罗仿真过程中,根据行驶时长的概率分布抽取得到行驶时长后,再利用式(8)的行驶里程分布抽取可得到对应的行驶里程。行驶里程与行驶时长之间的函数关系如图 5 所示。






图 5 行驶里程与行驶时间之间的函数关系

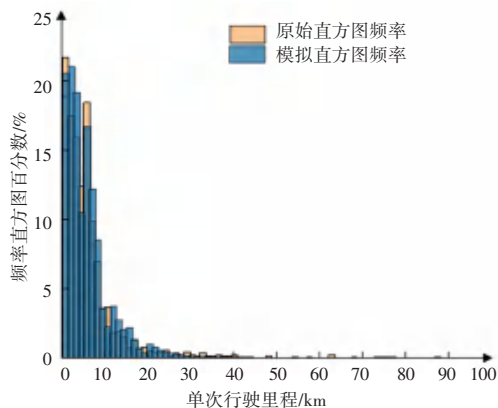
Fig. 5 Functional relationship between mileage and driving time

4.2 负荷预测结果与分析

本文根据 NHTS 的数据模拟各个时间和空间特征量的概率分布模型,并且通过与蒙特卡罗仿真生成的分布对比验证,主要是采用日出行结束时刻和单次行驶里程两个特征量进行验证。2 个特征量的仿真对比验证如图 6 所示。由图 6 可知,根据原始直方图频率和模拟的直方图频率对比可知,基于蒙特卡罗模拟方法所得的出行规律符合实际。



(a) 日出行结束时刻验证



(b) 单次行驶里程验证

图 6 仿真结果验证


Fig. 6 Verification of simulation results

在接下来的研究中,根据图 2 的基于蒙特卡罗模拟的电动汽车充电需求预测流程图,设置了 2 种充电场景来预测充电负荷,分析不同的充电行为对充电负荷的影响。文中将给出详述如下。


(1) 情景 1: 用户偏向于在家充电,考虑在家充电的便利性,在结束一天的行程后,用户一定充电,所以首次出行时刻电动汽车的电量是满的。

(2) 情景 2: 用户充电在每个区域内充电的习惯比较相同,并且首次出行时刻的起始 SOC 均服从正态分布 $N(0.5, 0.1^2)$ 。

根据本文设置的不同充电情景得到的电动汽车充电负荷如图 7 所示,参数设置见表 13。



(a) 情景 1 各区域充电负荷



(b) 情景 2 各区域充电负荷

图 7 基于用户充电行为的电动汽车充电负荷

Fig. 7 Electric vehicles charging load based on user charging behavior

表 13 参数设置

Tab. 13 Parameters setting

参数	值
电动汽车数量 N	100 000 辆
慢充功率	3.5 kW
快充功率	28 kW
百公里耗电量	20 kW · h/100 km
电池容量	30 kWh

对比同一个情境下的充电功率曲线可得知,由于电动汽车在 3 个区域的驾驶行为不同,不同功能区域下的充电负荷曲线差异较大,峰值负荷和谷负荷也不同。

对比不同场景下的充电功率需求,情景 1 由于用户的充电偏向在居民区,所以对比情景 2 可得知,在居民区的充电需求较其他 2 个区域更高,而且情景 1 其他 2 个区域的充电量明显小于情景 2 的其他 2 个区域的充电电量,这是因为情景 2 中 3 个区域的充电无明显偏向。

对比不同场景下峰值时刻可得知,情景 1 的充

电峰值晚于情景 2, 因为情景 2 的电动起始 SOC 并不是充满电出发的, 所以导致电动汽车的充电需求早于情景 1。但是 2 个场景下的总需求没有太大的变化, 并且在家的充电量都是大于其他 2 个区域的充电量, 所以不一样的充电行为对充电总量影响不大, 但是对于电动汽车在各区域的充电电量影响较大。所以根据电动汽车的充电行为分析, 用户可以根据不同的充电行为来合理分配在各区域内的充电量。

5 结束语

本文提出基于用户行程链的电动汽车充电负荷预测方法, 基于行程链概念, 选取 3 个主要的用户活动区域, 利用 NHTS 的数据对行程链的各个特征量进行分析拟合得到概率分布, 最后, 利用蒙特卡罗模拟方法得到了不同区域的充电负荷分布曲线。本文得到的结果如下:

(1) 基于行程链和蒙特卡罗仿真, 可以准确模拟不同类型区域的电动汽车的充电负荷需求。

(2) 用户在不同区域内的充电行为的不同, 导致了不同类型区域内充电负荷的分布特征差异。

(3) 电动汽车用户的充电行为直接决定了充电负荷的特点, 当用户在最后一次出行后回家充电时, 其负荷需求最大。提高工作区和商业娱乐区的充电比例, 可以减少夜间居民区的峰值负荷对居民区配电网的负担。

本文基于用户的充电行为, 利用行程链的各特征概率分布模拟用户在不同空间和时间内的充电负荷。在后续的研究中将进一步完善用户充电行为的模型, 考虑电动汽车与电网交互的充电电价以及参与电网调度, 与此同时还要深入探讨分析充电行为对电网的影响以及电动汽车在各个区域之间的需求分配关系。

参考文献

[1] IEA. Global EV outlook 2018[Z]. Paris, France: IEA, 2018.
 [2] QIAN Kejun, ZHOU Chengke, MALCOLM A, et al. Modeling of load demand due to EV battery charging in distribution systems

[J]. IEEE Transactions on Power Systems, 2011, 26(2): 802-810.
 [3] 胡泽春, 占恺娇, 徐智威, 等. 电动汽车与电网互动的关键问题分析与展望[J]. 电力建设, 2015, 36(07): 6-13.
 [4] 杨晓东, 任帅杰, 张有兵, 等. 电动汽车可调度能力模型与日内优先调度策略[J]. 电力系统自动化, 2017, 41(02): 84-93.
 [5] 陈丽丹, 张尧, FIGUEIREDO A. 电动汽车充放电负荷预测研究综述[J]. 电力系统自动化, 2019, 43(10): 177-191.
 [6] AMINI M H, KARGARIAN A, KARABASOGLU O. ARIMA-based decoupled time series forecasting of electric vehicle charging demand for stochastic power system operation[J]. Electric Power Systems Research, 2016, 140: 378-390.
 [7] UL-HAQ A, AZHAR M, MAHMOUD Y, et al. AI-Amman. probabilistic modeling of electric vehicle charging pattern associated with residential load for voltage unbalance assessment[J]. Energies, 2017, 10(9): 1-18.
 [8] OMAR H, KANKAR B. Integrating EV charging stations as smart loads for demand response provisions in distribution systems[J]. IEEE Transactions on Smart Grid, 2018, 9(2): 1096-1106.
 [9] WU Di, ALIPRANTIS D C, GKRTITZA K. Electric energy and power consumption by light-duty plug-in electric vehicles[J]. IEEE Transactions on Power Systems; A Publication of the Power Engineering Society, 2011, 26(2): 738-746.
 [10] SOARES F J, LOPES J A P, ALMEIDA P M R. A Monte Carlo method to evaluate electric vehicles impacts in distribution networks [C]// 2010 IEEE Conference on Innovative Technologies for an Efficient and Reliable Electricity Supply. Waltham, MA, USA: IEEE, 2010: 365-372.
 [11] MA H Y, WANG J H, ZHENG T, et al. A model for electric vehicle charging load forecasting based on simulated driving path [C]// Proceedings of 2019 4th Asia Conference on Power and Electrical Engineering (ACPEE 2019). Hangzhou: Auckland University of Technology, University of Madaba and Hong Kong Society of Mechanical Engineers, 2019: 969-974.
 [12] 龚丽, 曹伟, 赵建. 基于行程链的电动汽车充电站负载建模方法[C]// 2017 IEEE 能源互联网与能源系统集成会议 (EI₂). Beijing, China: IEEE, 2017: 1-5.
 [13] U.S. Department of transportation, federal highway administration. 2009 national household travel survey [DB/OL]. [2022-02]. <http://nhts.ornl.gov>.
 [14] 周涛, 韩筱璞, 闫小勇, 等. 人类行为时空特性的统计力学[J]. 电子科技大学学报, 2013, 42(04): 481-540.
 [15] 于海洋, 张路, 任毅龙. 基于出行链的电动汽车充电行为影响因素分析[J]. 北京航空航天大学学报, 2019, 45(09): 1732-1740.
 [16] 管涛, 李玲玲. 高斯混合模型、求解算法及视觉应用综述[J]. 中国图象图形学报, 2012, 17(12): 1461-1471.
 [17] LIANG Haifei, LEE Ziyang, LI Gen. A calculation model of charge and discharge capacity of electric vehicle cluster based on trip chain[J]. IEEE Access, 2020, 8: 142026-142042.
 Piscataway, NJ: IEEE Press, 2019: 201-205.
 [18] 李永勇, 张永进, 张燕军. 基于 Petri 网的机动车故障诊断专家系统设计[J]. 机械工程与自动化, 2020(01): 4-7.

(上接第 53 页)

[17] LU Na, XU Bing, FANG Shuang, et al. Research on fault diagnosis simulation of hydraulic system of CNC machine tool based on fuzzy Petri net [C]// Proc of the 4th International Conference on Power and Renewable Energy (ICPRE).