

## 基于数据与模型联合驱动的电动汽车充电负荷时空分布预测

顾玮, 段敬, 张栋, 郝晓伟, 薛泓林, 安毅, 段婕

引用本文

顾玮, 段敬, 张栋, 郝晓伟, 薛泓林, 安毅, 段婕. [基于数据与模型联合驱动的电动汽车充电负荷时空分布预测](#)[J]. 计算机科学, 2024, 51(11A): 231100110-6.

GU Wei, DUAN Jing, ZHANG Dong, HAO Xiaowei, XUE Honglin, AN Yi, DUAN Jie. [Prediction of Spatial and Temporal Distribution of Electric Vehicle Charging Loads Based on Joint Data and Modeling Drive](#) [J]. Computer Science, 2024, 51(11A): 231100110-6.

---

## 相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于强化学习考虑电池损耗的电动汽车充放电控制算法](#)

Reinforcement Learning Algorithm for Charging/Discharging Control of Electric Vehicles Considering Battery Loss

计算机科学, 2024, 51(11A): 231200147-7. <https://doi.org/10.11896/jsjcx.231200147>

[基于加权特征融合的物联网设备识别方法](#)

IoT Devices Identification Method Based on Weighted Feature Fusion

计算机科学, 2024, 51(11A): 240100137-9. <https://doi.org/10.11896/jsjcx.240100137>

[基于改进近端策略优化算法的智能渗透路径研究](#)

Intelligent Penetration Path Based on Improved PPO Algorithm

计算机科学, 2024, 51(11A): 231200165-6. <https://doi.org/10.11896/jsjcx.231200165>

[基于遗传算法的低碳导向的物流中心配送优化](#)

Optimization of Low-carbon Oriented Logistics Center Distribution Based on Genetic Algorithm

计算机科学, 2024, 51(11A): 231200035-6. <https://doi.org/10.11896/jsjcx.231200035>

[基于策略融合及Spiking DRL的移动机器人路径规划方法](#)

Mobile Robots' Path Planning Method Based on Policy Fusion and Spiking Deep Reinforcement Learning

计算机科学, 2024, 51(11A): 240100211-11. <https://doi.org/10.11896/jsjcx.240100211>

# 基于数据与模型联合驱动的电动汽车充电负荷时空分布预测

顾玮<sup>1</sup> 段敬<sup>1</sup> 张栋<sup>1</sup> 郝晓伟<sup>1</sup> 薛泓林<sup>1</sup> 安毅<sup>2</sup> 段婕<sup>1</sup>

<sup>1</sup> 国网山西省电力公司信息通信分公司 太原 030000

<sup>2</sup> 国网山西省电力公司 太原 030000

**摘要** 针对目前充电汽车(Electric Vehicle, EV)负荷预测的研究实时预测充电汽车起讫点(Origin-Destination, OD)准确率不高并考虑道路信息对用户充电行为选择造成影响的问题,在数据驱动方面,针对充电汽车出行 OD 矩阵的时空特性,使用长短期记忆(LSTM)网络和图卷积网络(GCN)的组合预测方法分析已有的充电负荷数据,实现对充电汽车起讫点的预测;模型驱动方面,在综合考虑交通网构成、环境温度、实时车流量等方法的基础上,建立一种包括动态交通信息、城市各路段电动汽车里程能耗及用户路径规划在内的电动汽车用户驾驶行为模型,采用改进 A\* 算法为电动汽车起讫点规划符合用户选择的行驶路径,模拟电动汽车用户的驾驶行为。最终在不同应用场景下完成不同类型电动汽车的路径规划实验和充电需求预测实验。结果表明,所得充电需求时空分布特征与客观需求相符合。

**关键词:** 电动汽车;时空充电负荷预测;LSTM;GCN;OD 矩阵;动态交通信息;路径规划

中图分类号 TP391

## Prediction of Spatial and Temporal Distribution of Electric Vehicle Charging Loads Based on Joint Data and Modeling Drive

GU Wei<sup>1</sup>, DUAN Jing<sup>1</sup>, ZHANG Dong<sup>1</sup>, HAO Xiaowei<sup>1</sup>, XUE Honglin<sup>1</sup>, AN Yi<sup>2</sup> and DUAN Jie<sup>1</sup>

<sup>1</sup> State Grid Shanxi Electric Power Company Information and Communication Branch, Taiyuan 030000, China

<sup>2</sup> State Grid Shanxi Electric Power Company, Taiyuan 030000, China

**Abstract** In response to the current research on charging vehicle(EV) load prediction, the accuracy of real-time prediction of charging vehicle origin-destination(OD) is not high and considers the influence of road information on users' charging behavior choices. On the data-driven side, a combination of long short-term memory(LSTM) networks and graph convolutional networks(GCN) is used to analyze the existing charging load data and realize the prediction of charging vehicle origin-destination(OD), with respect to the spatial and temporal characteristics of the OD matrix of charging vehicle trips. On the model-driven side, a comprehensive consideration of traffic network composition, ambient temperature, real-time traffic flow and other methods, a driving behavior model of electric vehicle users is established, including dynamic traffic information, mileage energy consumption of electric vehicles in various road segments in the city and user path planning, and the improved A\* algorithm is used to plan driving paths for the starting and ending points of electric vehicles in accordance with the users' choices, so as to simulate the driving behavior of electric vehicle users. The improved A\* algorithm is used to plan driving paths for the starting and ending points of EVs that meet the user's choice, and simulate the driving behavior of EV users. Finally, the path planning test and charging demand prediction test for different types of EVs are completed under different application scenarios. The results show that the spatial and temporal distribution characteristics of charging demand are consistent with the objective demand.

**Keywords** Electric vehicles, Spatio-Temporal charging load forecasting, LSTM, GCN, OD matrix, Dynamic traffic information, Path planning

## 1 引言

近年来,能源结构不断调整,电力系统也在不断向前发展,电动汽车作为一种清洁、低碳的交通方式正逐渐走进人们的生活。然而,随着电动汽车数量的增加,其充电负荷对电力系统的影响日益显著。充电负荷的不确定性和波动性使得电力系统在负荷平衡、能源调配以及供电稳定性方面面临新的

挑战。因此,准确预测电动汽车的充电负荷成为了智能能源管理和智能交通系统的迫切需求。

充电负荷预测旨在通过分析电动汽车用户的充电行为、充电桩分布、天气影响等多种因素,提前预测未来一段时间内的充电需求<sup>[1]</sup>。这不仅有助于避免电力系统负荷过载,还有助于优化能源利用、减少能源浪费,并为电力系统调度提供更精确的依据<sup>[2]</sup>。然而,充电负荷预测面临着数据不完整性、因

基金项目:国网山西省电力公司科技项目(52051C230005)

This work was supported by the Science and Technology Project of State Grid Shanxi Electric Power Company(52051C230005).

通信作者:顾玮(zwb\_alphapiggy@163.com)

素复杂性以及时空变化的复杂问题,因此需要引入先进的预测方法和技术来解决<sup>[3]</sup>。

当前对于电动汽车负荷预测方面的研究主要有模型驱动和数据驱动两方面。首先,模型驱动也可以叫知识驱动,基于知识驱动研究对象各要素之间的运行规则和原理进行严格的分析,并根据实际场景中的业务和功能需求建立对应的数学模型和物理模型,来描述对象各变量之间的因果关系<sup>[4]</sup>。文献[5]提出一种考虑道路拓扑特性的电动汽车充电需求预测模型,但未考虑环境温度和速度因素对电动汽车电量消耗的影响。文献[6]提出了一种考虑环境温度和车速的电动汽车充电需求预测模型,采用起止点矩阵法分别获得私家车和出租车出行的起讫点,但影响起讫点(OD)分布的因素很多,非路段交通量因素所能包容,离实用阶段尚有很大距离。其次,基于数据驱动以大量历史数据为基础,进行关联性分析,经过训练得出经验模型,进而用于实验指导。文献[7]提出一种基于反向传播神经网络的电动汽车负荷预测方法,文献[8]提出一种基于极端梯度提升与轻量级梯度提升融合的电动汽车充电负荷预测模型。

模型驱动的电动汽车充电负荷预测方法需要假定大量模型参数以表达复杂的充电行为,数据驱动的预测方法需要大量多源异构数据支撑训练学习,二者均具有各自的局限性<sup>[9]</sup>。为解决上述问题,本文提出融合模型驱动与数据驱动各自优势的充电需求预测模型,充分考虑道路交通的拓扑特性和环境温度等因素的同时,对电动汽车出行 OD 矩阵的预测采用长短期记忆(LSTM)和 GCN 建立深度学习模型,对用户出行时间和空间相对规律进行挖掘分析,精准构建电动汽车充放电负荷预测模型。

## 2 电动汽车起讫点预测模型

本章主要介绍电动汽车充电需求预测模型,并且将对起讫点预测的相关事项引入其中。

首先,电动汽车行驶轨迹数据是离散的、不连续的和广泛分布的。因此,进行起讫点预测前,将交通规划理论的地理网络构造拓扑结构是必须的<sup>[10]</sup>,这样可以有效集中和处理这些轨迹数据。结合住宅区、商业区、工业区的分布,本文使用图论来描述复杂的交通道路网络。

$$\begin{cases} C_u(m) = \{C_u(1), C_u(2), C_u(3), \dots, C_u(n)\} \\ V = \{V_i | i = 1, 2, 3, \dots, n\} \\ E = \{V_{ij} | V_i \in V, V_j \in V, i \neq j\} \\ K = \{k | k = 1, 2, 3, \dots, m\} \\ W = \{w_{ij}^k | v_{ij} \in E, k \in K\} \\ G = (V, E, K, W) \end{cases} \quad (1)$$

其中,  $C_u$  为所选交通网格编号的集合;  $V$  为各交通路口的集合;  $E$  为各条道路的集合;  $K$  为划分的各个时间段  $k$  集合;  $W$  为各条道路通行代价,描述为道路路阻;  $G$  为交通路网。

### 2.1 模型结构

LSTM 网络是由循环神经网络(RNN)改进而来的,一定程度上解决了 RNN 在反向传播时可能发生的梯度消失和梯度爆炸问题。LSTM 通过隐藏状态  $h_t$  保存短期的记忆信息,通过长期记忆单元  $C_t$  保存较长期的信息,使网络能够捕捉较远时间点间的相关性。每个 LSTM 单元有 3 个门:遗忘门、输入门和输出门。遗忘门实现当前  $C_t$  内容的删减,去掉冗余

信息;输入门实现对候选记忆单元的筛选,控制候选记忆单元输入进  $C_t$  的内容;输出门控制  $C_t$  在当前时刻的输出信息。每个 LSTM 单元共享参数,在不断的循环中实现对对应参数的学习。

LSTM 单元的内部结构如图 1 所示,对应的数学表达式如下:

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (2)$$

$$i_t = \sigma(i_f[h_{t-1}, x_t] + b_i) \quad (3)$$

$$g_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (4)$$

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (5)$$

$$C_t = f_t \otimes C_{t-1} + i_t \otimes g_t \quad (6)$$

其中,  $f_t, x_t, i_t, o_t, g_t, h_t$  分别代表遗忘门、输入数据、输入门、输出门、记忆单元和隐藏状态;  $\sigma$  为 sigmoid 激活函数,将  $h_{t-1}$  和  $x_t$  输入  $\sigma$  中,输出介于  $0 \sim 1$  之间,0 表示完全丢弃该内容,1 表示保留;  $W$  为权重参数;  $b$  为在训练中学习的偏置。

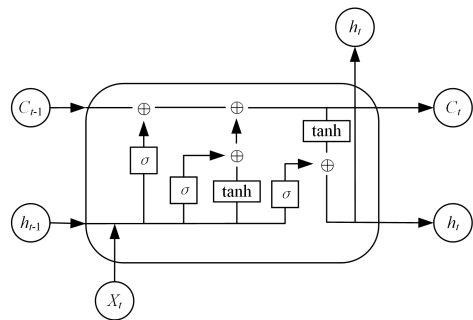


图 1 LSTM 网络结构

Fig. 1 LSTM network structure

图卷积网络有能力提取图结构数据的特征,其中包括基于谱域的方法。这里采用了基于谱域的 GCN 方法。给定一个无向关系图  $G=(V, E, A)$ ,  $V$  表示顶点的合集,  $E$  为边的合集;  $A \in R(N \times N)$  是图  $G$  的邻接矩阵,即由边组成的  $N \times N$  矩阵,矩阵中若  $v_i$  和  $v_j$  两点存在一条边,则  $A_{ij} = 1$ , 否则  $A_{ij} = 0$ 。从图结构可以得到邻接矩阵,同理,也可以通过邻接矩阵得到图结构。

在 GCN 网格中,每一个节点下一层的信息都由前一层本身的信息与相邻节点的信息加权求和,再对其进行线性变换和非线性变换得到。令  $D$  代表邻接矩阵  $A$  中结点的度矩阵,对  $A$  进行归一化,其中  $H^{(l+1)} = \sigma(D^{-\frac{1}{2}} \hat{A} D^{-\frac{1}{2}} H^{(l)} W^{(l)})$  为邻接矩阵与单位矩阵  $I$  的和,层与层之间传递的方式如下:

$$H^{(l+1)} = \sigma(D^{-\frac{1}{2}} \hat{A} D^{-\frac{1}{2}} H^{(l)} W^{(l)}) \quad (7)$$

GCN 在图的拉普拉斯算子基础上对卷积神经网络对图的卷积运算进行进一步推广,在谱图卷积过程中,采用了经过对称归一化处理的拉普拉斯矩阵:

$$L = I - D^{-\frac{1}{2}} A D^{-\frac{1}{2}} \quad (8)$$

图的性质可以由图的拉普拉斯矩阵求得,对图的特征提取可以等价于对图的拉普拉斯矩阵的特征提取。文中采用  $k$  阶切比雪夫多项式作为卷积核,减少参数,从全局卷积变为局部卷积,以降低计算的复杂度。

### 2.2 基于 LSTM-GCN 组合的电动汽车起讫矩阵预测

电动汽车一般分为 3 种类型:通勤私家车、出租车、公交车。因为公交车的行车轨迹较固定,且充电位置与充电时间基

本不变,所以本研究主要考虑通勤私家车、出租车两种类型。

为了获得电动汽车的出行轨迹模型,负荷预测平台需要提前预测从一个地区到另一个地区的汽车数量,将此问题表述为 OD 起讫矩阵预测问题。现有对于电动汽车起讫点的预测研究采用神经网络模型,仍在起步阶段,在路段交通量基础上考虑人为和天气因素,但是并不是很有效。OD 起讫矩阵存在时序特征和空间相关特征<sup>[11]</sup>。电动汽车日常出行可以看作矩阵时间序列,矩阵的每个元素都表现了电动汽车所到实际地理节点与其他节点间的空间相关性<sup>[12]</sup>,所有矩阵又表现了所有节点与自身相关的时间特征。为此,采用长短期记

忆递归神经网络(LSTM)和图卷积神经网络(GCN)建立深度学习模型,利用 LSTM 网络来获取电动汽车出行的时间相关性,利用 GCN 来获取电动汽车的空间相关性,可以更好地评估不同影响因素,准确预测电动汽车的出行时间和空间相对规律。相较于单独的 LSTM 神经网络,组合模型在预测误差方面有更好的表现,更适用于充电汽车出行 OD 矩阵的预测。

组合模型通过提取时间、空间位置关系对历史出行 OD 进行处理,来预测实时的电动汽车出行 OD。组合模型的结构如图 2 所示,包含 3 个关键模块,分别为时间特征提取模块、空间特征提取模块和全连接模块。

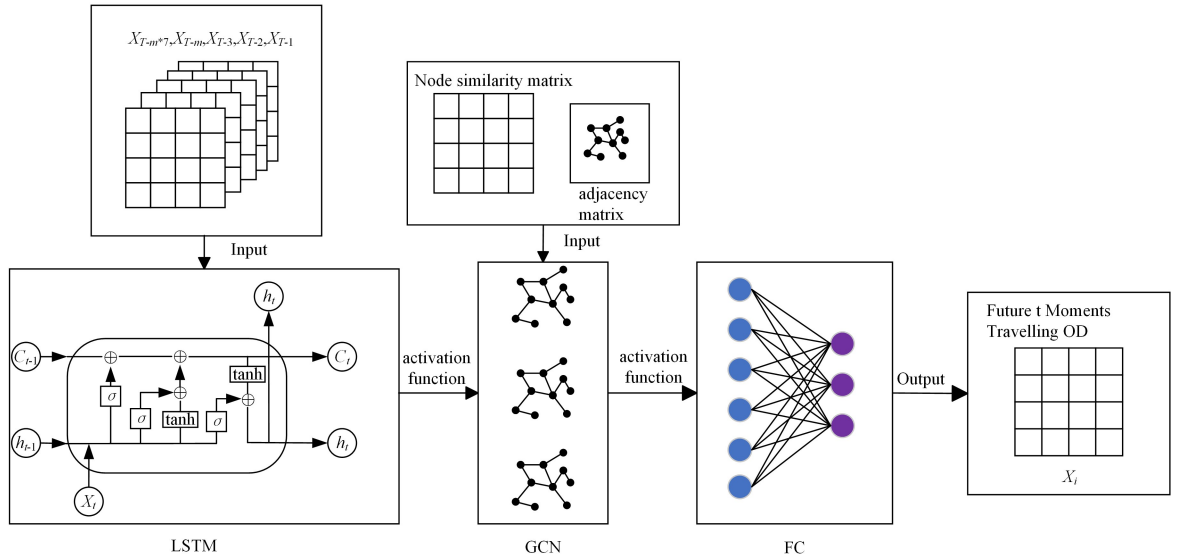


图 2 LSTM-GCN 组合模型结构

Fig.2 LSTM-GCN composite model structure

在时间模块中,本文采用单层的 LSTM 结构,将历史出行 OD 矩阵转化为序列作为输入;在空间特征提取模块,将 LSTM 的输出经过激活函数处理,并引入节点相似度矩阵和邻接矩阵进一步获取空间相关特征。本文采用 3 层 GCN 结构,如式(9)所示:

$$f(X, A) = \sigma(\hat{A}\sigma(\hat{A}\sigma(\hat{A}X\theta_0)\theta_1)\theta_2) \quad (9)$$

其中,  $\theta_0, \theta_1, \theta_2$  为 3 层卷积的权重矩阵;  $\sigma$  代表层与层之间的激活函数。

在进行时间特征提取部分,本文将建立的 OD 矩阵作为输入数据,将每个 OD 对相关联的历史值作为一个单独的时间序列。为预测第  $k$  天的第  $t$  个时间段的出行 OD,使用第  $k$  天的第  $t-3, t-2, t-1$  这 3 个时间段的出行 OD,以及第  $k-1$  天的第  $t$  个时间段和第  $k-7$  天的第  $t$  个时间段的出行 OD 输入 LSTM 模型中,即最近前 3 个时间间隔数据、一天前的同一时间数据、一周前的同一时间数据。使用 LSTM 模块来获取的时间特征,最终将作为 GCN 第 0 层的隐藏向量。在空间特征提取部分历史出行 OD 数据由路网结构得到的表明真实地理信息的邻接图以及每一个时间间隔中节点与节点间的相似性矩阵来进行计算,通过 GCN 来获取 OD 矩阵的空间相关性。根据每一个地理节点的分布,结合 OD 矩阵来形成一个张量。模型中的邻接图由真实地理位置信息得到,即节点与节点之间的邻接关系生成的邻接图,是一个固定的静态图;节点相似度矩阵反映了节点与节点之间的动态相关性,由不同时刻的节点与节点之间的出行 OD 矩阵决定并根据历史 OD

矩阵采用余弦相似度进行计算,数值越大,相似度越高。

这 5 个时间段的历史 OD 矩阵使用 LSTM 获取时间相关性,并作为 GCN 第 0 层的输入信息,再使用 GCN 分别对由节点的邻接矩阵构成的静态图和由出行 OD 构成的动态图进行空间特征的提取,使用平均策略对上述 2 个结果进行融合来获得更好的结果。

### 2.3 电动汽车充电特性

电动汽车类型不同,具备的充电特性也不同。私家车通常表现出以下特点:起讫点具有相似性,在一个地方停留时间较长,充电方式及地点较固定。对于私家车来说,充电场景主要包括车主工作地点、居住地或大型商场的地下充电站等,其中,更侧重于居住地。而出租车则具有以下特点:出行时间和起讫点具有随机性,短时充电使用较多,行驶路线不固定。电动汽车每日的初始电量(SOC)取决于前一天行驶结束时的电量和车主设定的充电阈值。如果电量降至预设的低电量警报水平,车辆会优先选择就近充电。只要电量足以支持当天的行程,车辆便会继续行驶至行程结束。行程结束后,车辆会根据充电阈值判断是否需要充电。若需要充电,车辆将充满电;否则,保持当前电量,并将其作为第二天的初始电量。

目前,快充和慢充是电动汽车通常采用的两种不同充电模式。快充模式可以在较短的时间内为电动汽车提供充足的电能,但可能对电动汽车电池的寿命产生一定影响,并且对电网造成一定程度的负荷冲击。相反,慢充模式采用小电流和低电压,虽然充电时间更长,但对电网和电动汽车的影响相对较轻。

EV的充电时长主要取决于电池总容量、初始SOC、目标SOC和充电功率<sup>[13]</sup>。目前电动汽车多用锂电池,充电分为恒流和恒压两阶段。充电初期和末期所需时间较短,而恒压阶段占大部分充电时间,电能输出相对稳定,因此这一阶段可视为恒定功率充电。充电时长计算公式如式(10)所示:

$$T_c = \frac{(E_{\text{soc}} - I_{\text{soc}})E}{\eta P_c} \quad (10)$$

其中, $T_c$ 为充电所需的时间; $E_{\text{soc}}$ 为目标SOC; $I_{\text{soc}}$ 为初始SOC; $E$ 为电池的容量,单位为千瓦时(kWh); $P_c$ 为充电功率,一般设为恒定功率,单位是千瓦(kW); $\eta$ 表示充电效率,通常取为0.9。

### 3 电动汽车用户驾驶行为模型

本章详细介绍如何根据给定的实时起讫点结合交通路段信息来判断各充电站的实时充电负荷以及构建道路交通模型的各个部分。

#### 3.1 道路交通模型

##### 3.1.1 速度-流量模型

在城市中,EV的行驶速度会受到路段的时速限制、路面的交通容量以及车流量大小的影响。速度的波动直接关系到每单位里程的电耗<sup>[14]</sup>,进而对驾驶者的充电需求产生影响。为此,引入速度-流量模型以更准确地对车辆的行驶速度进行模拟,如式(11)所示:

$$\begin{cases} v_{ij}(t) = \frac{v_{ij-m}}{1 + \left(\frac{q_{ij}(t)}{C_{ij}}\right)^\beta} \\ \beta = a + b \left(\frac{q_{ij}(t)}{C_{ij}}\right)^n \end{cases} \quad (11)$$

其中, $v_{ij}(t)$ 为EV在特定时刻 $t$ 路段 $i$ 到 $j$ 上的行驶速度; $v_{ij-m}$ 为路段 $(i,j)$ 的零流速度,通常为该路段的最高限速,取60km/h; $C_{ij}$ 为路段 $(i,j)$ 的通行能力,本文将道路分为快速路、主干路、次干路和支路4种; $q_{ij}(t)$ 为时刻 $t$ 在节点 $i$ 和 $j$ 之间道路的车流量; $a,b,n$ 为根据道路的实测值确定的参数。

##### 3.1.2 电动汽车单位里程能耗模型

EV的每公里里程能耗受多种因素影响,包括行驶速度和周围环境温度等。环境温度的变化可能会增加车内空调系统的额外电力消耗<sup>[15]</sup>。同时,电动汽车的实时耗电量也受到车速变动的影 响,因此构建了电动汽车单位里程能耗模型。电动汽车里程能耗、道路等级和 $v$ 之间的关系可表示为:

$$\begin{cases} E_{\text{las}}^{\text{roa}} = -0.004v + 0.247 + 1.520/v \\ E_{\text{tru}}^{\text{roa}} = -0.004v - 0.179 + 5.492/v \\ E_{\text{sbra}}^{\text{roa}} = -0.001v + 0.210 + 1.531/v \\ E_{\text{bra}}^{\text{roa}} = -0.002v + 0.208 + 1.553/v \end{cases} \quad (12)$$

其中, $E_{\text{las}}^{\text{roa}}, E_{\text{tru}}^{\text{roa}}, E_{\text{sbra}}^{\text{roa}}, E_{\text{bra}}^{\text{roa}}$ 分别为快速路、主干路、次干路和支路的单位里程能耗。

电动汽车能耗会随温度变化而产生非线性的变化,温度单位里程能耗 $E_c^{\text{tem}}$ 模拟与温度的关系为:

$$E_c^{\text{tem}} = \sum_{y=1}^6 p_y c^{y-1} \quad (13)$$

其中, $p_y$ 为拟合参数, $y$ 为自然数, $c$ 为当前环境温度。

根据式(13),拟合曲线EV在20℃时的单位里程能耗最小。结合式(12)、式(13),以20℃为标准温度,获得EV在温度 $c$ 下行驶在 $r$ 等级道路下的单位里程能耗 $E_{r,c}^{\text{EV}}$ 为:

$$E_{r,c}^{\text{EV}} = E_r^{\text{roa}} E_c^{\text{tem}} / E_{20}^{\text{tem}} \quad (14)$$

其中, $E_r^{\text{roa}}$ 为EV在 $r$ 等级道路下的单位里程能耗。

#### 3.2 路径规划问题

城市交通系统中的路径规划是准确预测充电站充电负荷的重要前提<sup>[16]</sup>。如果能够有效预测电动汽车的行驶路径,不仅能有效估计电动汽车的电池剩余,而且可以准确判断电动汽车会前往的充电站。私家车和出租车路径选择会受到路段长度、行驶速度、通行时间、耗油量等权值的影响,而行驶速度和通行时间取决于当前时刻路段情况。本文基于驾驶成本,使用改进A\*算法对电动汽车的驾驶路径进行规划。

Dijkstra算法在路径规划上使用较多,相比该算法,A\*算法最大的优势在于其引入启发函数可以避免很多无效计算,搜索效率更高<sup>[17]</sup>。A\*算法在搜索过程中会搜索与当前位置相邻的位置,并使用估价函数选择最佳的扩展位置作为下一次搜索的起点,考虑到搜索初期启发函数的比重远大于实际代价,因此本节引入调整函数。

根据电动汽车能耗模型来计算,设汽车从当前位置 $n$ 到起点的对角距离为 $S_1$ ,则实际代价 $G(n)$ 可表示为:

$$G(n) = E_{r,c}^{\text{EV}} S_1 \quad (15)$$

相应地,设从当前位置 $n$ 到终点的对角距离为 $S_2$ ,则启发函数 $H(n)$ 可表示为:

$$H(n) = E_{r,c}^{\text{EV}} S_2 f(t) \quad (16)$$

$$f(t) = \log_2 \left( 1 + \frac{t_{\text{estimate}}}{t_{\text{sum}}} \right) \quad (17)$$

其中, $t_{\text{estimate}}$ 为从当前位置到终点的预测通行时间; $t_{\text{sum}}$ 为汽车出发时从起点到终点的预测通行时间,是一个定值。

本文中改进A\*算法的估价函数计算形式如下:

$$F(n) = G(n) + H(n) + E_{r,c}^{\text{EV}} \quad (18)$$

其中, $n$ 为当前位置, $G(n)$ 为搜索过程中的实际代价; $H(n)$ 为启发函数,即从当前位置到终点的估计代价; $F(n)$ 为估价函数,即 $G(n)$ 与 $H(n)$ 的和; $E_{r,c}^{\text{EV}}$ 也就是上文的EV在温度 $c$ 下行驶在 $r$ 等级道路下的单位里程能耗。

利用基于驾驶成本的A\*算法得出EV行驶路径流程图如图3所示。

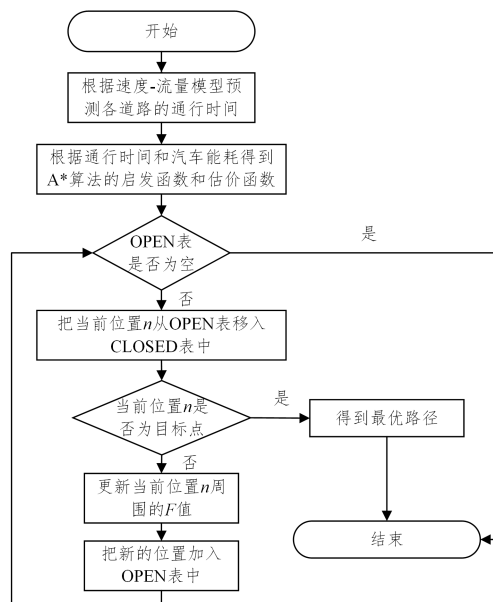


图3 基于驾驶成本的A\*算法流程图

Fig. 3 Flow chart of A\* algorithm based on driving cost

## 4 充电负荷预测与分析

为了测试上述电动汽车充电负荷时空预测算法的有效性,选取了一个城市辖区,该区已进行城市功能区划分,其路网结构如图4所示。在此基础上,进行了不同功能区域内电动汽车充电负荷的预测。该城市被分为4个区域:工业区、居民区1、居民区2和商业区。整个区域包括28个节点,每个节点代表一个区域内的充电站位置。居民区1由节点1,3,5,6,8,12,14,18组成;居民区2由节点21,23,25,26,27,28组成;工业区包括节点2,4,9,11,13;商业区则由节点7,10,15,16,17,19,20,22,24构成。整个区域中有48条主要道路。

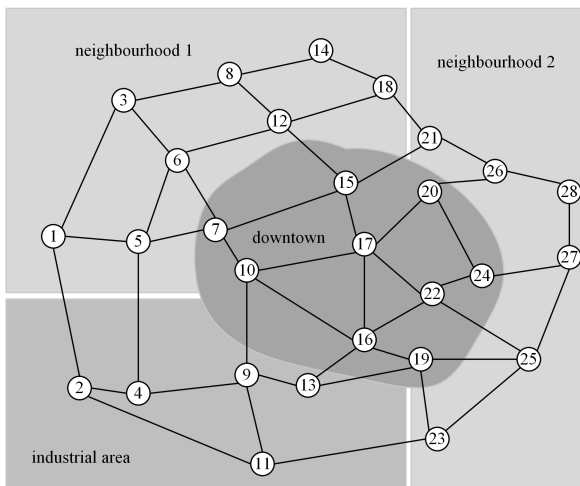


图4 辖区路网拓扑示意图

Fig. 4 Diagram of district road network topology

始发地为 $C_1$ 、目的地为 $C_{20}$ 的24h电动汽车预测效果与LSTM预测结果比较如图5所示。




图5  $C_1$ 到 $C_{20}$ 的神经网络预测结果

Fig. 5 Neural network prediction results from  $C_1$  to  $C_{20}$

不同子区域的总体充电需求如图6所示。工业区、商业区和居民区由于具有独特的区域特性,展现出不同的电力负荷需求。




图6 各个区域的日总充电量

Fig. 6 Total daily charge in each area

在商业区,由于日间娱乐活动的客流量较高,电动汽车通常进行较短时间的快速充电。相比之下,居民区的电动汽车用户多在晚上下班后回家进行充电,因此夜间充电数量较多,且充电时间较长。尽管如此,这3个区域的负荷需求相近,分别为10.97MWh,9.54MWh和8.01MWh。居民区1因区域面积更大、节点更多,其充电负荷达到18.57MWh,是居民区2需求的两倍多。

由于通勤私家车与出租车在出行特点上存在差异,通勤私家车经常来往于家和上班地点之间,而出租车出行更具随机性。因此,实验将不同车辆类型即通勤私家车与出租车的符合需求分布区分对比,可以更直观地分析各功能区域的充电负荷规律。图7、图8为通勤私家车的负荷需求分布。




图7 通勤私家车-交通节点充电需求

Fig. 7 Commuter private cars-traffic node charging requirements




图8 通勤私家车-24h该区域充电需求

Fig. 8 Commuter private car-24h charging demand in the area

由图7可知,通勤私家车充电负荷高峰时段跨度较广,主要集中在15:00—19:30时段,最高峰充电需求为18:00—19:00。

图9、图10为出租车的负荷需求分布。可以看出,出租车的充电时间分布呈现与通勤私家车不同的“双高峰”形式,出租车充电时间集中在早上9:00至13:00和傍晚18:00至21:30,充电负荷时空分布符合居民出行规律。由图10可知,出租车的充电最高峰大致分布在早上9:00至10:00。

分析私家车和出租车的充电需求可知,用户的主要充电时间集中在早上9:00至13:00和傍晚18:00至19:30,形成了一个双高峰的充电模式。特别是在7,10,12,19,21等节点,充电需求相对较高。居民区的充电需求超过了商业区和工业区,显示出充电需求的空间分布是不均匀的。充电需求较高的配电网节点主要集中在居民区和商业区周边。通过分析实验结果可以看出,充电需求的时空分布预测与实际情况高度吻合,从而证明了所提出的负荷预测方法的有效性。

针对该充电需求时空分布特征预测模型,通过对比分析不同配电网节点的充电需求,可为各配电网节点制定电网功率调度策略提供重要信息,并进一步分析充电负荷对电网的影

响,对电力系统负荷调度或充电站预设等研究具有重要意义。




图9 出租车-交通节点充电需求

Fig. 9 Taxi-traffic node charging requirements




图10 出租车-24h 该区域充电需求

Fig. 10 Taxi-24 h area charging requirements

**结束语** 本文基于融合神经网络和用户驾驶行为模型,充分考虑城市交通拓扑结构模拟用户实际驾驶行为,通过对出行 OD 矩阵数据挖掘分析电动车充放电的出行时间和空间相对规律,提出一种融合数据驱动和模型驱动的电动汽车充电负荷时空预测方法,通过算例仿真,得到如下结论:

1)通过采用 LSTM 和 GCN 对用户出行时间和空间相对规律挖掘分析,使用 A\* 算法以最小驾驶成本为目标对电动汽车的驾驶路径进行规划。实验结果表明,充电需求时空分布预测与实际情况相一致。

2)在路径规划上选取 A\* 算法,结合电动汽车在不同道路行驶的能耗模型,更符合用户出行心理,本文也考虑了电动汽车起始 SOC 的更新迭代,以确保电池的荷电状态可以连续地变化。这个方法结合了城市电动汽车的行驶规律和相关影响因素,可提高充电负荷预测的准确性。

## 参考文献

- [1] CAI L, GE S D, DAI N N, et al. A review on the research progress of electric vehicle load forecasting and its interaction with power grid[J]. *Smart Power*, 2022, 50(7): 96-103.
- [2] OBAID M, TOROK A, ORTEGA J. A comprehensive emissions model combining autonomous vehicles with park and ride and electric vehicle transportation policies[J]. *Sustainability*, 2021, 13(4): 4053.
- [3] HU H C, TAN Z F, QIU G, et al. An overview of the development of electric vehicles [J]. *Electrical Application*, 2018, 37(20): 79-85.
- [4] LI P, HUANG W Q, WANG X, et al. A review of joint data-and knowledge-driven artificial intelligence methods in power scheduling[J/OL]. <http://kns.cnki.net/kcms/detail/32.1180.TP.20230608.1043.002.html>.
- [5] SUO J, LI L, HE H Q, et al. Electric vehicle charging load prediction considering traffic conditions[J]. *Grid and Clean Energy*, 2022, 38(10): 141-147.
- [6] ZHANG M X, SUN Q J, YANG X. Electric vehicle charging load prediction considering real-time interaction of multi-source information and user regret psychology[J]. *Grid Technology*, 2022, 46(2): 632-645.
- [7] HAO N, KILMER M E, BRAMAN K, et al. Facial recognition using tensor-tensor decompositions[J]. *SIAM Journal on Imaging Sciences*, 2013, 6(1): 437-463.
- [8] WU D, LEI S, LI Z J, et al. Electric vehicle charging load prediction model based on the integration of XGBoost and LightGBM [J]. *Electronic Technology Application*, 2022, 48(9): 44-49.
- [9] HAN F J, WANG X H, QIAO J, et al. A review of research on new power system load forecasting based on artificial intelligence technology [J/OL]. <https://doi.org/10.13334/j.0258-8013.pcsee.221560>.
- [10] XING Q, CHEN Z, ZHANG Z Q, et al. Modelling driving and charging behaviors of electric vehicles using a data-driven approach combined with behavioral economics theory[J]. *Journal of Cleaner Production*, 2021, 324: 129243.
- [11] LIN Y F, YIN K, DANG Y, et al. OD passenger demand forecasting based on spatio-temporal LSTM[J]. *Journal of Beijing Jiaotong University*, 2019, 43(1): 114-121.
- [12] ZHANG J X, BIN K, JIANG Y Y. Cross-sectional passenger flow prediction considering spatio-temporal distribution of rail travel[J]. *Journal of Chongqing University of Technology(Natural Science)*, 2022, 36(6): 164-171.
- [13] ZHANG L J, XU C Q, WANG L L, et al. Spatial and temporal distribution prediction of electric vehicle charging load based on OD matrix [J]. *Power System Protection and Control*, 2021, 49(20): 82-91.
- [14] CHEN Y, JIANG Y D, XU G, et al. Scale-up electric vehicle charging load forecasting[J]. *Electricity Demand Side Management*, 2022, 24(5): 71-77.
- [15] CHENG S, ZHAO Z K, CHEN N, et al. Spatial and temporal distribution prediction of electric vehicle charging load taking into account coupling factors[J]. *Power Engineering Technology*, 2022, 41(3): 194-201, 208.
- [16] YUAN X F. Spatio-temporal prediction of electric vehicle charging load under "vehicle-station-road-network" information interaction [D]. North University of Technology, 2023.
- [17] LIU T B. Research on vehicle path planning method based on traffic flow prediction and driving cost [D]. Jilin: Jilin University, 2023.



**GU Wei**, born in 1993, master. Her main research interests include computer technology and artificial intelligence.