

# 基于需求预测的单向共享电动汽车车辆调度方法

高俊杰, 崔晓敏, 赵 鹏, 姚宝珍\*

(大连理工大学汽车工程学院, 辽宁 大连 116024)

**摘要:** 用户出行需求的不均衡性和潮汐性造成站点之间的车辆库存不平衡, 阻碍了单向共享电动汽车行业的发展. 在充分考虑用户实际需求的随机性和时效性的基础上, 提出一种单向共享电动汽车车辆调度方法. 其采用长短期记忆神经网络对站点车辆需求进行预测, 进而建立以调度成本、库存成本和潜在损失收益均最小的多目标调度模型, 并采用遗传模拟退火混合算法求最优解. 实证研究表明了该方法的合理性和优越性.

**关键词:** 共享电动汽车; 需求预测; 长短期记忆神经网络; 车辆调度规划

**中图分类号:** TP18

**文献标识码:** A

**doi:** 10.7511/dllgxb201906014

## 0 引言

作为解决交通拥堵、停车难和空气污染问题的有效方法之一, 共享电动汽车 (electric car-sharing, EC) 已成为全球的创新移动概念<sup>[1]</sup>, 用户数量急剧增长. 当前, EC 的运营主要有往返型、单向型和自由浮动型 3 种模式. 其中, 单向共享电动汽车 (one-way electric car-sharing, OW-EC) 以其便利性强和维护成本低的优点成为市场上发展前景最好的模式<sup>[2]</sup>. 然而, OW-EC 发展面临的最大问题是: 用户出行需求的不均衡性和潮汐性造成了共享站点间的车辆库存不平衡<sup>[3-4]</sup>——部分站点车辆积压, 导致用户无空车位还车; 部分站点车辆短缺, 导致用户无车辆可借. 如何合理地调度车辆、平衡供需、增加车辆的利用率, 是 OW-EC 持续发展的关键.

针对此问题, 国内外学者进行了大量研究工作, 主要可归为以下 3 种: (1) 设计最佳的共享系统. 通过部署最佳车队规模、最佳车站数量、位置及容量, 减少系统中车辆库存不平衡的程度<sup>[2, 5-6]</sup>. 这属于系统中长期的设计与规划, 不能有效解决当前运营期间现有站点车辆库存不平衡问题. (2) 针对用户的车辆调度策略. 通过为用户提供折

扣、补贴等方式, 鼓励其改变出行路径, 以改善站点车辆库存不平衡的状况. 这种方式的影响范围较小, 不能从根本上解决问题<sup>[7]</sup>. (3) 基于运营者的车辆调度策略. 将运营者视为调度车辆的负责人, 提出车辆调度模型, 优化调度方法和路线, 以实现调度的车辆数和人员数最小化、利润最大化等多种目标<sup>[8-11]</sup>. 此类研究实用性强, 但对模型和算法都有较高要求. 分析发现: 现有相关研究大都假设提前获取了用户的预约信息且仅根据预约信息确定各个站点的车辆需求, 既较难实现又忽视了用户需求的随机性和时效性. 针对此问题, 本文提出一种基于需求预测的单向共享电动汽车车辆调度方法.

## 1 需求预测

### 1.1 影响因素的选择

影响因素选择的合理性直接影响 OW-EC 需求预测的准确性. 由于影响各个站点 EC 需求的因素众多, 本文以抓主要矛盾为原则. 参考相关文献并结合调研结果<sup>[12-15]</sup>, 分析发现: 首先, 站点覆盖区域内人口特性的不同会造成 EC 需求的差异; 其次, 站点覆盖区域内的交通通达性, 即与公交、地铁等其他出行方式的组合能力, 对 EC 需求

收稿日期: 2019-03-08; 修回日期: 2019-08-02.

基金项目: 辽宁省博士科研启动基金资助项目(20170520365); 国家自然科学基金资助项目(51578112); 中央高校基本科研业务费专项资金资助项目(DUT18JC03).

作者简介: 高俊杰(1978-), 男, 博士, 副教授, E-mail: gaojunjie@dlut.edu.cn; 姚宝珍\* (1976-), 女, 博士, 教授, E-mail: yaobaozhen@dlut.edu.cn.

影响明显;再次,站点覆盖区域内土地使用属性的不同必将造成顾客出行目的和 EC 需求的差异;最后,时间因素(是否工作日、不同时段等)对 EC 需求影响显著.综上,本文提出采用 4 类影响因素相结合的方案.4 类影响因素分别为区域人口特性  $E_1$ 、区域交通通达特性  $E_2$ 、区域土地使用属性  $E_3$ 、时间属性  $E_4$ ,具体内容如表 1 所示.

表 1 影响因素

Tab.1 The influencing factors

| 类别    | 具体内容                                                                        |
|-------|-----------------------------------------------------------------------------|
| $E_1$ | 人口密度 $e_1$ 、受教育水平 $e_2$ 、经济收入水平 $e_3$                                       |
| $E_2$ | 公交站数量 $e_4$ 、地铁站数量 $e_5$ 、火车站数量 $e_6$ 、飞机场数量 $e_7$ 、汽车站数量 $e_8$             |
| $E_3$ | 教育 $e_9$ 、商业 $e_{10}$ 、政府工作 $e_{11}$ 、医院 $e_{12}$ 、住宅 $e_{13}$ 、娱乐 $e_{14}$ |
| $E_4$ | 时间段 $e_{15}$ 、星期属性 $e_{16}$ 、日期属性 $e_{17}$                                  |

1.2 OW-EC 需求预测模型

OW-EC 需求预测除了受到影响因素  $E_1$ 、 $E_2$ 、 $E_3$  和  $E_4$  影响外,用户在预约当前时刻车辆时会根据 APP 获取上一时刻的可用车辆信息做出判断,所以相同站点当前时刻的 OW-EC 需求还受到上一时刻 OW-EC 需求的影响;此外,用户在预约车辆时,会倾向于选择相邻站点中可用车辆较多的站点,所以相邻站点在相同时间的 OW-EC 需求相互影响.传统的神经网络不能很好地确定预测值之间的联系,而长短期记忆(long short term memory,LSTM)神经网络中的记忆单元不仅建立了不同时间段输出的预测值之间的联系,而且解决了循环神经网络中梯度消失问题或梯度爆炸问题<sup>[16]</sup>.所以本文提出了基于 LSTM 的 OW-EC 需求预测模型.

基于 LSTM 的 OW-EC 需求预测模型由数据预处理、数据输入层、隐含层、权重优化层、数据输出层组成.其构建过程如下:

(1)数据预处理

①读取数据.将数据按同一站点的时间段顺序依次排列,读取数据库文件,提取历史需求数据和影响因素数据.

②数据归一化.为避免数据幅值不在同一范围引起的差异干扰,需按式(1)、(2)分别对历史需求数据和影响因素数据进行归一化处理.

$$r_{i,norm} = \frac{r_i - r_{min}}{r_{max} - r_{min}} \quad (1)$$

$$e_{(j,i)norm} = \frac{e_{(j,i)} - e_{(j,i)min}}{e_{(j,i)max} - e_{(j,i)min}} \quad (2)$$

式中: $r_{i,norm}$ 为站点  $i$  归一化 OW-EC 需求, $r_i$ 为站点  $i$  的 OW-EC 需求, $r_{min}$ 为 OW-EC 需求最小值, $r_{max}$ 为 OW-EC 需求最大值. $e_{(j,i)norm}$ 为站点  $i$  归一化的第  $j$  个影响因素, $e_{(j,i)}$ 为站点  $i$  的第  $j$  个影响因素, $e_{(j,i)min}$ 为第  $j$  个影响因素最小值, $e_{(j,i)max}$ 为第  $j$  个影响因素最大值.

(2)数据输入层

输入历史需求数据  $R=(r_1 \ r_2 \ \cdots \ r_i \ \cdots \ r_n)$ 和影响因素数据  $E=(E_1 \ E_2 \ \cdots \ E_i \ \cdots \ E_m)$ ( $E_i=(e_{(1,i)} \ e_{(2,i)} \ \cdots \ e_{(j,i)} \ \cdots \ e_{(v,i)})$ ),其中  $r_1, r_2, \dots, r_i, \dots, r_n$  分别代表站点  $1, 2, \dots, i, \dots, n$  的历史需求, $E_1, E_2, \dots, E_i, \dots, E_m$  分别代表第  $1, 2, \dots, i, \dots, m$  个属性类别, $e_{(1,i)}, e_{(2,i)}, \dots, e_{(j,i)}, \dots, e_{(v,i)}$  分别代表站点  $i$  的第  $1, 2, \dots, j, \dots, v$  个影响因素.

(3)隐含层计算

每个隐含层由多个 LSTM 单元组成,每个 LSTM 单元由遗忘门、输入门、细胞更新和输出门组成,LSTM 单元结构如图 1 所示.




图 1 LSTM 单元结构图

Fig.1 LSTM cell structure diagram

LSTM 单元的计算如下:

①遗忘门  $f_t$  控制  $t-1$  时刻 OW-EC 预测信息  $C_{t-1}$  到  $t$  时刻 OW-EC 预测信息  $C_t$  的遗忘量:

$$f_t = \sigma(W_f[h_{t-1}, \boldsymbol{x}_t] + b_f) \quad (3)$$

②输入门  $i_t$  控制从候选 OW-EC 预测信息  $\tilde{C}_t$  中获取的 OW-EC 预测信息  $C_t$  ( $\tilde{C}_t$  由 tanh 层产生):

$$i_t = \sigma(W_i[h_{t-1}, \boldsymbol{x}_t] + b_i) \quad (4)$$

$$\tilde{C}_t = \tanh(W_c[h_{t-1}, \boldsymbol{x}_t] + b_c) \quad (5)$$

③细胞更新  $C_t$  更新  $t-1$  时刻到  $t$  时刻的细

胞预测信息:

$$C_t = f_i C_{t-1} + i_t \tilde{C}_t \quad (6)$$

④输出门  $o_t$  通过 sigmoid 过滤细胞预测信息,并基于细胞更新  $C_t$  输出隐含层 OW-EC 预测值  $h_t$ :

$$o_t = \sigma(W_o[h_{t-1}, \chi_t] + b_o) \quad (7)$$

$$h_t = o_t \tanh(C_t) \quad (8)$$

式中:  $f_t$  为  $t$  时刻遗忘门的遗忘信息控制量,  $i_t$  为  $t$  时刻输入门的输入预测信息控制量,  $C_t$  为  $t$  时刻更新后的细胞预测信息,  $o_t$  为输出门的预测值;  $W_f$ 、 $W_i$ 、 $W_c$ 、 $W_o$  分别表示遗忘门、输入门、细胞更新和输出门的权重;  $b_f$ 、 $b_i$ 、 $b_c$ 、 $b_o$  分别表示遗忘门、输入门、细胞更新和输出门的偏置;  $h_{t-1}$  为  $t-1$  时刻的输出,  $h_t$  为  $t$  时刻的输出;  $\chi_t$  为  $t$  时刻的输入影响因素矩阵, 且  $\chi_t = (R_t \quad E_t)$ ,  $R_t$  为  $t$  时刻历史需求矩阵,  $E_t$  为  $t$  时刻影响因素矩阵;  $C_{t-1}$  为  $t-1$  时刻的细胞预测信息,  $\tilde{C}_t$  为  $t$  时刻的 OW-EC 预测候选值,  $\sigma$  为 sigmoid 激励函数。

#### (4) 权值优化

将 OW-EC 需求预测值  $h_t$  与  $R_t$  作比较, 计算交叉熵损失函数, 并使用 Adam 方法对权重  $W_f$ 、 $W_i$ 、 $W_c$ 、 $W_o$  进行优化。

#### (5) 数据输出层

①数据反归一化。为得到与 OW-EC 需求真实值的幅值相同范围, 需按式(1)对预测值进行反归一化处理:

$$n_i^t = h_i^t (r_{\max} - r_{\min}) + r_{\min} \quad (9)$$

式中:  $n_i^t$  为  $t$  时刻站点  $i$  的 OW-EC 需求预测值,  $h_i^t$  为  $t$  时刻站点  $i$  的 OW-EC 需求归一化预测值,  $r_{\min}$  为 OW-EC 需求最小值,  $r_{\max}$  为 OW-EC 需求最大值。

②数据可视化。输出预测精度, 同时用折线显示 LSTM 测试集的 OW-EC 预测值与实际历史需求数据。

## 2 车辆调度问题

### 2.1 车辆调度模型建立

共享车辆调度问题是产销分配问题的一种<sup>[17]</sup>, 车辆积压站点视为产出地, 车辆短缺站点视为销售地, 经营者决策车辆调度数量和调度路线, 由此, 车辆调度问题可表示为调度成本最小化的单目标优化问题。但在以往的调度模型中, 未在

对实际站点车辆需求预测的基础上对车辆进行调度, 而且没有考虑车辆积压的库存成本和车辆短缺的潜在损失收益。因此, 本文在使用 LSTM 预测 OW-EC 需求的基础上, 建立以调度成本、库存成本和潜在损失收益最小为目标的多目标调度模型, 数学表达式如下:

$$\min f = \sum_{t=1}^T \left[ \sum_{i=1}^m \sum_{j=1}^n x_{ij}^t d_{ij} c \right] \quad (10)$$

$$\min z = \sum_{t=1}^T \left[ \sum_{i=1}^m C_1 \left( s_i^t - \sum_{j=1}^n x_{ij}^t \right) \right] \quad (11)$$

$$\min y = \sum_{t=1}^T \left[ \sum_{i=1}^m C_2 \left( r_i^t - \sum_{j=1}^n x_{ij}^t \right) \right] \quad (12)$$

$$\text{s. t. } \sum_{i=1}^m x_{ij}^t \leq s_i^t; j = 1, 2, \dots, n, t = 1, 2, \dots, T \quad (13)$$

$$\sum_{j=1}^n x_{ij}^t \leq \max(p_i, r_i^t); \\ i = 1, 2, \dots, m, t = 1, 2, \dots, T \quad (14)$$

$$l_k^{\text{mle}} - d_{ij} \geq 0; k = 1, 2, \dots, K, i = 1, 2, \dots, m, j = 1, 2, \dots, n \quad (15)$$

$$L^{\text{mle}} - d_{ij} > 0; i = 1, 2, \dots, m, j = 1, 2, \dots, n \quad (16)$$

$$x_{ij}^t \geq 0 \text{ 且为整数}; i = 1, 2, \dots, m, j = 1, 2, \dots, n, \\ t = 1, 2, \dots, T \quad (17)$$

$$n_i^t - p_i = \begin{cases} s_i^t; & n_i^t - p_i > 0 \\ r_i^t; & n_i^t - p_i < 0 \end{cases} \quad (18)$$

其中, 式(10)为调度成本最小目标函数, 式(11)为站点车辆积压的库存成本最小目标函数, 式(12)为站点车辆短缺的潜在损失收益最小目标函数, 式(13)为车辆积压站点的调出车辆约束, 式(14)为车辆短缺站点的调入车辆约束, 式(15)为调度车辆最小续航里程约束, 式(16)为站点间调度车辆的最大距离约束, 式(17)为车辆调度数量约束, 式(18)为站点  $i$  的 OW-EC 需求。

式中:  $m$  为车辆积压站点数量;  $n$  为车辆短缺站点数量;  $T$  为共享系统运营时间上限;  $s_i^t$  为  $t$  时刻站点  $i$  的车辆积压数;  $r_i^t$  为  $t$  时刻站点  $i$  的车辆短缺数;  $d_{ij}$  为从站点  $i$  到站点  $j$  的距离;  $c$  为单位距离的运输费用;  $x_{ij}^t$  为决策变量, 表示  $t$  时刻从站点  $i$  到站点  $j$  的调运量;  $C_i$  为站点  $i$  车辆积压的单位库存成本;  $l_k^{\text{mle}}$  为车辆  $k$  的续航里程;  $L^{\text{mle}}$  为车辆的最大续航里程;  $p_i$  为站点  $i$  的车辆停车位数量。

### 2.2 车辆调度模型求解

遗传算法(GA)求解车辆调度问题时, 无法避

免算法后期进化效率低带来的时间延迟。而模拟退火算法(SA)的搜索结果对初始参数设置依赖性大。为此,本文利用遗传模拟退火优化算法(GA-SA)求解模型,既能克服 SA 的早熟现象,又能提高算法的总体搜索能力。

GA-SA 是优化问题的可行解  $\mathbf{X}_\xi$  和目标函数  $F(\mathbf{X}_\xi)$  在温度变量  $\alpha$  变化下,依次执行 Metropolis 算法过程,即依次执行产生新解—评判—保留或舍弃的迭代过程。算法求解流程如图 2 所示。GA-SA 具体步骤如下:




图 2 GA-SA 流程图  
Fig. 2 Flow chart of GA-SA

- (1)设置初始温度、冷却系数和终止温度。
- (2)设置种群规模、最大迭代次数并随机产生初始解:  
$$\mathbf{X}_\xi=(x_{(\xi,1)} \quad x_{(\xi,2)} \quad \cdots \quad x_{(\xi,i)} \quad \cdots \quad x_{(\xi,n)})$$

(19)
- (3)计算适应度函数。
- 将 3 个目标函数进行归一化处理,车辆调度的多目标规划问题可采用加权系数法化为单目标

问题,用加权系数法得到适应度函数:

$$F(\mathbf{X}_\xi)=\omega_1\frac{f(\mathbf{X}_\xi)-\min f(\mathbf{X})}{\min f(\mathbf{X})}+\omega_2\frac{z(\mathbf{X}_\xi)-\min z(\mathbf{X})}{\min z(\mathbf{X})}+\omega_3\frac{y(\mathbf{X}_\xi)-\min y(\mathbf{X}_\xi)}{\min y(\mathbf{X})} \tag{20}$$

其中  $\min f(\mathbf{X})$  为  $f$  的最小值,  $\min z(\mathbf{X})$  为  $z$  的最小值,  $\min y(\mathbf{X})$  为  $y$  的最小值;  $\sum_{i=1}^3 \omega_i=1$ ,  $\omega_i$  为加权系数,采用判断矩阵法确定加权系数<sup>[18]</sup>。

(4)解决约束条件,给不可行解分配罚函数<sup>[19]</sup>,使该个体适应度下降,减小该个体遗传到下一代的概率。罚函数表示为

$$F'(\mathbf{X}_\xi)=\begin{cases} F(\mathbf{X}_\xi); & \mathbf{X}_\xi \text{ 满足约束} \\ 0.8F(\mathbf{X}_\xi); & \mathbf{X}_\xi \text{ 不满足约束} \end{cases} \tag{21}$$

(5)将初始种群个体进行选择、交叉和变异操作,得到两个子代  $\mathbf{X}_\xi$  和  $\mathbf{X}_{\xi+1}$ 。

(6)采用 Metropolis 算法<sup>[20]</sup>评判并保留  $\mathbf{X}_\xi$  和  $\mathbf{X}_{\xi+1}$  中较优子代。

(7)判断迭代次数是否达到最大,若是进行(8),否则迭代次数  $\lambda=\lambda+1$ ,并转到(5)。

(8)判断温度变量  $\alpha$  是否达到终止温度,若是输出最优解,否则将温度变量采用等比下降法降温:  $\alpha=\tau\times\alpha$  ( $\tau$  为冷却系数),同时将  $\lambda$  置零后转到(2)。

3 实证研究

3.1 实例概况

本文采用 EVCARD 位于上海市共享站点车辆调度进行案例分析,以实际历史需求数据和影响因素数据作为输入,采用 LSTM 预测 OW-EC 需求,并在此基础上进行车辆调度优化,验证本文调度方法的有效性。

本文采用 Python 爬虫技术获取上海市 EVCARD 共享站点的历史需求数据,数据来源于 EVCARD 手机 APP。在运营周期内,每 3 h 统计 1 次,收集 2017-09~2018-03 共享站点历史需求数据,如表 2 所示。站点车辆需求为总停车位与可用停车位之差。

为了简化工作量,本文将 5 km×5 km 区域内的站点合并为一个大站点,将网格所有站点的中心位置设置为大站点的位置,该大站点同时包



表 2 上海市 EVCARD 共享站点历史需求数据  
Tab.2 EVCARD car-sharing stations historical data in Shanghai

| 序号  | 地址                | 经度/(°)      | 纬度/(°)     | 日期         | 时间        | 总停车位 | 可用停车位 |
|-----|-------------------|-------------|------------|------------|-----------|------|-------|
| 1   | 上海市宝山区潘泾路 3055 号  | 121.366 231 | 31.443 922 | 2017-11-18 | 7:00~9:00 | 6    | 0     |
| 2   | 上海市宝山区电台路 546 号   | 121.398 504 | 31.360 978 | 2017-11-18 | 7:00~9:00 | 5    | 2     |
| 3   | 上海市宝山区淞兴西路 258 号  | 121.494 872 | 31.373 013 | 2017-11-18 | 7:00~9:00 | 8    | 4     |
| 4   | 上海市宝山区牡丹江路 1843 号 | 121.485 885 | 31.417 373 | 2017-11-18 | 7:00~9:00 | 5    | 2     |
| 5   | 上海市宝山区锦东路 500 号   | 121.420 511 | 31.417 212 | 2017-11-18 | 7:00~9:00 | 6    | 3     |
| 6   | 上海市宝山区江杨北路 1801 号 | 121.446 217 | 31.414 218 | 2017-11-18 | 7:00~9:00 | 10   | 1     |
| 7   | 上海市宝山区团结路 28 号    | 121.490 934 | 31.412 416 | 2017-11-18 | 7:00~9:00 | 6    | 1     |
| 8   | 上海市宝山区盘古路 780 号   | 121.473 685 | 31.408 511 | 2017-11-18 | 7:00~9:00 | 6    | 7     |
| ... | ...               | ...         | ...        | ...        | ...       | ...  | ...   |

含网格内所有站点的借车、还车数量以及调度车辆数量,合并后的 46 个站点分布状况如图 3 所示.




图 3 上海市 EVCARD 站点散点分布  
Fig.3 Spatial distribution of EVCARD stations in Shanghai

OW-EC 需求预测过程中,所需影响因素数据  $e_1 \sim e_{14}$  由上海市统计年鉴和百度地图获取; $e_{15}$  划分为每 3 h 为一时间段, $e_{16}$  划分为一周 7 d, $e_{17}$  划分为工作日和节假日, $e_{15} \sim e_{17}$  从表 2 获取.对于  $e_2$ ,本文将教育水平划分为小学及以下、初中、高中、大专、大学本科、研究生及以上 6 个级别,由式(22)计算得到站点  $i$  区域的教育水平得分为

$$S_i = \frac{\sum_q M_{iq} \times \omega_{iq}}{\sum_i \sum_q M_{iq} \times \omega_{iq}} \quad (22)$$

其中  $M_{iq}$  为区域  $i$  内教育水平级别为  $q$  的人数, $\omega_{iq}$  为区域  $i$  内教育水平级别为  $q$  的权重, $I$  为上海市区域集合, $Q$  为教育水平级别集合.

3.2 OW-EC 需求预测

实验运行环境:CPU 为 1.8 GHz,内存为 8 GB,Windows x64 操作系统,Tensorflow 框架,采用 Python 语言编写代码.输入 OW-EC 历史需求数据和影响因素数据到 LSTM 模型中,采用 Tensorflow 框架内的 Adam 优化方法优化网络结构中各层之间的权值,设置隐含层单元数为 25,学习率为 0.000 6,时间步长为 20 s,数据训练 1 000 次得到工作日 7:00~9:00 的 46 个共享站点车辆需求预测值如图 4 所示.




图 4 OW-EC 需求预测结果  
Fig.4 The result of OW-EC demand forecast

图 4 中横坐标为共享站点  $i$ ,纵坐标为 OW-EC 车辆需求  $\epsilon$ ,图中数据为正表示站点车辆短

缺,为负表示站点车辆积压.模型的预测精度为0.854 1,耗时为121.34 s.

此外,本文将 LSTM 预测方法与 Logit 逻辑回归(LR)、支持向量机(SVM)、径向基神经网络(RBF)和深度神经网络(DNN)等预测方法作比较,所有方法均采用历史需求数据和 $e_1 \sim e_{17}$ 影响因素数据作为输入,LSTM 与其他方法的实验结果对比如表3所示.

表3 OW-EC 需求预测方法对比  
Tab.3 Comparison of OW-EC demand forecasting methods

| 方法   | 精度    | 耗时/s   |
|------|-------|--------|
| LR   | 0.708 | 60.30  |
| SVM  | 0.774 | 85.11  |
| RBF  | 0.768 | 95.14  |
| LSTM | 0.854 | 121.34 |
| DNN  | 0.846 | 208.22 |

表3显示,DNN 的精度仅次于 LSTM,但耗时久,不能更好地满足 OW-EC 需求预测的实时性.LSTM 的精度高于 DNN,且耗时明显少于 DNN,所以 LSTM 在本研究的共享站点预测中表现效果最佳.DNN 和 LSTM 的精度值均高于 LR、SVM 和 RBF,验证了深度学习预测模型比浅层回归预测模型更适合解决 OW-EC 需求预测问

题.

3.3 车辆调度模型求解

将路网中的站点真实距离、站点规模和 OW-EC 需求预测值等数据输入到车辆调度模型中,采用 SA 和 GA-SA 在 Matlab 2018a 软件求解 46 个站点的 OW-EC 车辆调度模型.其中,GA-SA 参数设置如下:种群大小为 100,最大迭代次数为 100,交叉概率为 0.7,变异概率为 0.01,初始温度为 10 ℃,降温系数为 0.8,终止温度为 90 ℃.SA 的种群大小、最大迭代次数、初始温度、降温系数和终止温度与 GA-SA 一致.算法的收敛过程如图5所示,求解全天运营结束后的车辆调度模型结果如表4所示.




图5 SA 和 GA-SA 的收敛曲线  
Fig.5 Convergence curves of SA and GA-SA

表4 车辆最优调度方案  
Tab.4 Optimal vehicle scheduling scheme

| 出发站点 | 到达站点 | 调度车辆数 | 距离/km | 成本/元   | 出发站点 | 到达站点 | 调度车辆数 | 距离/km | 成本/元   |
|------|------|-------|-------|--------|------|------|-------|-------|--------|
| 3    | 4    | 4     | 32.31 | 258.48 | 30   | 29   | 4     | 13.20 | 105.60 |
| 6    | 5    | 2     | 16.67 | 133.36 | 32   | 35   | 7     | 11.30 | 90.40  |
| 8    | 11   | 7     | 16.08 | 128.64 | 34   | 25   | 8     | 53.10 | 424.80 |
| 10   | 12   | 2     | 16.92 | 135.36 | 36   | 33   | 3     | 12.80 | 102.40 |
| 10   | 13   | 4     | 17.71 | 141.68 | 37   | 26   | 5     | 12.49 | 99.92  |
| 14   | 41   | 3     | 11.10 | 88.80  | 39   | 20   | 5     | 11.60 | 92.80  |
| 17   | 15   | 6     | 12.57 | 100.56 | 40   | 42   | 4     | 19.10 | 152.80 |
| 21   | 38   | 4     | 8.44  | 67.52  | 42   | 40   | 9     | 17.30 | 138.40 |
| 21   | 19   | 7     | 13.60 | 108.80 | 43   | 13   | 6     | 10.80 | 86.40  |
| 24   | 23   | 3     | 16.31 | 130.48 | 43   | 44   | 5     | 11.93 | 95.44  |
| 27   | 28   | 2     | 17.10 | 136.80 | 46   | 12   | 3     | 12.80 | 47.12  |

由图5可以看出,SA 和 GA-SA 皆能全局收敛,但 GA-SA 全局收敛性能更好.迭代次数为 135 次时,GA-SA 收敛到最低调度成本 2 866.56 元,而 SA 在迭代次数为 113 次时收敛到较低调度成

本 2 924.62 元,在迭代次数为 155 次时才收敛到最低调度成本 2 866.56 元.说明虽然 SA 收敛速度快,但若初始参数设置不合理,算法易陷入局部最优解,故总体搜索能力强、收敛速度快的 GA-

SA 更适合求解车辆调度模型.

由表 4 可以看出, 站点 9、16、18、22、31、45 的归还车辆与此时的需求车辆保持平衡状态, 所以无须进行车辆调度. 站点 3、4、5、6 和 7 在岛上, 调度到陆地上成本较高且车辆需求较小, 因此共享车辆只从内部区域进行调度. 共享车辆只能从内部区域进行调度, 站点 1、2 车辆供需平衡, 无须进行调度. 其余 39 个站点按最优调度方法进行共享车辆调度, 调度的车辆总数为 103 辆, 此时的调度成本最小为 2 866.56 元, 平均每辆车分担的调度成本为 27.83 元. 参照《共享汽车行业报告》, 一辆共享电动汽车每次分担的调度成本为 30~40 元<sup>[21]</sup>, 本文提出的调度方法使原来调度成本降低了 2.17~12.17 元.

## 4 结 论

(1) 本文设计的 LSTM 模型预测精度高于 LR、SVM 和 RBF, 且耗时比 DNN 少, 满足 OW-EC 需求预测要求.

(2) 基于需求预测的车辆调度模型实现车辆的最优分配, 将每辆车分担的调度成本控制到 27.83 元, 将原来调度成本降低了 2.17~12.17 元.

(3) GA-SA 与 SA 算法相比, 总体搜索能力更强、收敛速度更快, 更适合求解车辆调度模型.

## 参考文献:

- [1] SHAHEEN S A, MALLERY M A, KINGSLEY K J. Personal vehicle sharing services in North America [J]. **Research in Transportation Business & Management**, 2012, **3**: 71-81.
- [2] CORREIA G H D A, JORGE D R, ANTUNES D M. The added value of accounting for users' flexibility and information on the potential of a station-based one-way car-sharing system: An application in Lisbon, Portugal [J]. **Journal of Intelligent Transportation Systems: Technology, Planning, and Operations**, 2014, **18**(3): 299-308.
- [3] FIRNKORN J, MUELLER M. What will be the environmental effects of new free-floating car-sharing systems? The case of car2go in Ulm [J]. **Ecological Economics**, 2011, **70**(8): 1519-1528.
- [4] 王 宁, 张文剑, 刘 向, 等. 电动汽车共享站点间车辆人工调度策略 [J]. 同济大学学报(自然科学版), 2018, **46**(8): 1064-1071.
- [5] WANG Ning, ZHANG Wenjian, LIU Xiang, *et al.* Inter-site-vehicle artificial scheduling strategy design for electric vehicle sharing [J]. **Journal of Tongji University(Natural Science)**, 2018, **46**(8): 1064-1071. (in Chinese)
- [6] BOYACI B, ZOGRAFOS K G, GEROLIMINIS N. An optimization framework for the development of efficient one-way car-sharing systems [J]. **European Journal of Operational Research**, 2015, **240**(3): 718-733.
- [7] ION L, CUCU T, BOUSSIER J M, *et al.* Site selection for electric cars of a car-sharing service [J]. **World Electric Vehicle Journal**, 2009, **3**(3): 531-540.
- [8] DI FEBBRARO A, SACCO N, SAEEDNIA M. One-way carsharing: solving the relocation problem [J]. **Transportation Research Record**, 2012, **2319**(1): 113-120.
- [9] BRUGLIERI M, COLORNI A, LUÈ A. The relocation problem for the one-way electric vehicle sharing [J]. **Networks**, 2014, **64**(4): 292-305.
- [10] CHEMLA D, MEUNIER F, CALVO R W. Bike sharing systems: Solving the static rebalancing problem [J]. **Discrete Optimization**, 2013, **10**(2): 120-146.
- [11] KEK A G H, CHEU R L, MENG Qiang, *et al.* A decision support system for vehicle relocation operations in carsharing systems [J]. **Transportation Research Part E-Logistics and Transportation Review**, 2009, **45**(1): 149-158.
- [12] NOURINEJAD M, ROORDA M J. A dynamic carsharing decision support system [J]. **Transportation Research Part E-Logistics and Transportation Review**, 2014, **66**(3): 36-50.
- [13] SCHMÖLLER S, BOGENBERGER K. Analyzing external factors on the spatial and temporal demand of car sharing systems [J]. **Procedia-Social and Behavioral Sciences**, 2014, **111**: 8-17.
- [14] CERVERO R, GOLUB A, NEE B. City CarShare: longer-term travel demand and car ownership impacts [J]. **Transportation Research Record**, 2007(1992): 70-80.
- [15] LI Wenxiang, LI Ye, FAN Jing, *et al.* Siting of carsharing stations based on spatial multi-criteria evaluation: a case study of Shanghai EVCARD [J]. **Sustainability**, 2017, **9**(1): 152-167.

[15] 高俊杰, 谢亚南, 顾 丰, 等. 基于结构关系识别的中国汽车销量预测 [J]. 大连理工大学学报, 2018, **58**(1): 92-98.  
GAO Junjie, XIE Yanan, GU Feng, *et al.* Chinese automobile sales forecasting based on structural relationship identification [J]. **Journal of Dalian University of Technology**, 2018, **58**(1): 92-98. (in Chinese)

[16] 陈 佳, 刘冬雪, 武大硕. 基于特征选取与 LSTM 模型的股指预测方法研究 [J]. 计算机工程与应用, 2019, **55**(6): 108-112.  
CHEN Jia, LIU Dongxue, WU Dashuo. Stock index forecasting method based on feature selection and LSTM model [J]. **Computer Engineering and Applications**, 2019, **55**(6): 108-112. (in Chinese)

[17] 宋维堂, 张淑梅. 车辆调度优化模型仿真研究 [J]. 计算机仿真, 2011, **28**(9): 346-349.  
SONG Weitang, ZHANG Shumei. Research on transit routes network design based on improved genetic algorithm [J]. **Computer Simulation**, 2011, **28**(9): 346-349. (in Chinese)

[18] KANNAN D, KHODAVERDI R, OLFAT L, *et al.* Integrated fuzzy multi criteria decision making method and multi-objective programming approach for supplier selection and order allocation in a green supply chain [J]. **Journal of Cleaner Production**, 2013, **47**: 355-367.

[19] 张力丹, 李 超, 陈枫松, 等. 多级多受灾点连续消耗应急物资调度优化策略 [J]. 大连理工大学学报, 2017, **57**(5): 501-510.  
ZHANG Lidan, LI Chao, CHEN Biaosong, *et al.* Optimization strategy of emergency resources scheduling of hierarchical multiple disaster sites during continuous consumption [J]. **Journal of Dalian University of Technology**, 2017, **57**(5): 501-510. (in Chinese)

[20] 陈华根, 吴健生, 王家林, 等. 模拟退火算法机理研究 [J]. 同济大学学报(自然科学版), 2004, **32**(6): 802-805.  
CHEN Huagen, WU Jiansheng, WANG Jialin, *et al.* Mechanism study of simulated annealing algorithm [J]. **Journal of Tongji University (Natural Science)**, 2004, **32**(6): 802-805. (in Chinese)

[21] 前瞻产业研究院. 共享汽车行业发展现状分析 可持续盈利模式待解 [EB/OL]. [2018-08-28]. <https://bg.qianzhan.com/report/detail/458/180828-54d5c5d0.html>.  
Prospective Industry Research Institute. Analysis of development status of carsharing industry-sustainable profit model to be understood [EB/OL]. [2018-08-28]. <https://bg.qianzhan.com/report/detail/458/180828-54d5c5d0.html>. (in Chinese)

Scheduling method for one-way electric car-sharing  
based on demand forecasting

GAO Junjie, CUI Xiaomin, ZHAO Peng, YAO Baozhen\*

( School of Automotive Engineering, Dalian University of Technology, Dalian 116024, China )

**Abstract:** The tides and imbalances of the travel demand lead to the imbalance of vehicle inventory among electric vehicle stations, which hinders the development of one-way electric car-sharing industry. Fully considering the randomness and timeliness of actual travel demand, a scheduling method for one-way electric car-sharing is proposed. The long short term memory neural network is applied to forecast the vehicle demands of the stations, and a multi-objective scheduling model with minimum scheduling cost, minimum inventory cost and minimum potential loss profit is built, then the hybrid genetic and simulated annealing algorithm is applied to find the optimal solution. The rationality and superiority of the method are verified by the empirical study.

**Key words:** electric car-sharing; demand forecasting; long short term memory neural network; vehicle scheduling planning