

# 高速公路充电网络充电设施运行状态时空预测建模

陈立兴<sup>1</sup>, 韩晓新<sup>1</sup>, 季振亚<sup>2</sup>, 王琪<sup>1</sup>

(1. 江苏理工学院 电气信息工程学院, 江苏 常州 213001; 2. 南京师范大学 电气与自动化工程学院, 江苏 南京 210023)

**摘要:** 准确的充电网络充电设施运行状态时空预测建模是高速公路预约充电优化的基础。考虑电动汽车行驶速度与传统汽车相接近, 基于传统汽车的实际行驶速度数据, 提出了一种高速公路充电网络充电设施运行状态时空预测建模方法。一方面, 采用灰色关联分析法、协整-自回归移动平均法和小波神经网络方法对电动汽车的行驶速度进行滚动预测; 另一方面, 基于预测值和观察值, 利用蒙特卡洛方法、弗洛伊德方法和排队算法对高速公路充电网络充电设施运行状态进行时空预测。算例研究结果表明, 采用所提方法得到的高速公路充电网络充电设施运行状态时空预测结果比较准确, 可满足电动汽车预约充电优化需求。

**关键词:** 高速公路充电网络; 电动汽车; 充电设施运行状态; 时空预测; 排队算法; 建模

**中图分类号:** U 469.72

**文献标志码:** A

**DOI:** 10.16081/j.epae.202104026

## 0 引言

随着电动汽车规模化发展, 大量电动汽车无序充电将给充电网络的安全经济运行带来一系列的挑战<sup>[1]</sup>。这些挑战源于电动汽车充电负荷时空分布的不确定性。一方面, 电动汽车充电负荷的时空分布依赖于电动汽车的接入时间、接入地点和接入规模, 这些要素均具有随机性<sup>[2]</sup>; 另一方面, 电动汽车充电负荷的时空分布还依赖于道路结构和路况, 其中路况同样具有随机性<sup>[3]</sup>。由此会造成充电网络中电动汽车分布不均衡, 部分充电站拥堵、用户等待时间过长, 而其他充电站无车充电、充电资源浪费等问题<sup>[4]</sup>。充电网络运行所面临的上述问题将成为制约电动汽车发展的“瓶颈”, 亟待解决。

对于电动汽车充电负荷而言, 虽然其分布具有不确定性, 但同时也呈现出柔性负荷的特性, 存在调控潜力。国内外有关电动汽车充电负荷分布调控的研究重点围绕电动汽车充电行为建模<sup>[5]</sup>、充电负荷建模<sup>[6]</sup>、充电对电网的影响<sup>[1]</sup>、预约充电优化<sup>[4,7]</sup>、充电设施规划<sup>[8]</sup>这五大方面内容展开, 有关充电设施运行状态时空预测的研究相对较少, 而这正是预约充电优化的基础。通常城市区域内的充电站建设比较密集, 当用户预约充电后到达目标充电站的时间

较短, 期间可认为站内充电设施的运行状态变化不大。与城市区域相比, 高速公路充电站的站间距离大<sup>[4]</sup>, 当用户预约充电后到达目标充电站的时间较长, 期间站内充电设施的运行状态可能变化较大, 无法满足预约充电对充电设施运行状态精度的要求。目前, 有关高速公路预约充电的研究在估计充电设施运行状态时不考虑电动汽车实际行驶速度剧烈变化的情况, 往往将其简单设定为已知固定值<sup>[4]</sup>, 以此估计所得设施运行状态很可能与实际情况存在较大的偏差, 进而影响预约充电的实施效果。因此, 研究电动汽车行驶速度预测和充电设施运行状态预测具有重要的意义。

目前, 行驶速度预测是时序分析的主要内容之一。时域法是时序分析的主流方法, 其基本思想是时序值间存在一定的相关关系, 进而可建模预测未来的结果。从参数角度来看, 时域法主要分为参数法和非参数法。参数法主要包括自回归法、移动平均法、自回归移动平均法 ARMA (AutoRegressive Moving Average method)、自回归积分移动平均法, 这些方法要求时序为单变量和同方差情形。针对同方差情形难以满足的情况, 自回归条件异方差法、广义自回归条件异方差法及其推广形式<sup>[9-10]</sup>被提出。虽然参数法发展良好, 但其本身有严格假设, 面临参数选择不当的风险。为此非参数法被提出, 主要包括支持向量机方法、神经网络方法及其改进方法<sup>[11]</sup>。非参数法尤其是改进神经网络方法(如小波神经网络方法)无需假设条件, 能有效克服参数模型选择不当所导致的偏差, 但网络训练对历史数据的质量要求较高, 且网络滚动预测精度受实时数据质量的影响。大部分研究<sup>[9-11]</sup>在测试模型时往往忽略了实时数据会因检测器发生故障而大量缺失的情形, 此时若采用改进神经网络方法, 则难以保证预测精度。因此, 本文以此为切入点, 利用空间临近序列间存在

收稿日期: 2020-10-16; 修回日期: 2021-02-27

基金项目: 江苏省自然科学基金资助项目(211320B51903); 江苏省高等学校自然科学基金项目(111320B11902); 常州市科技计划项目(CJ20190073, CJ20200044); 江苏理工学院人才引进项目(KYY17018)

Project supported by the Natural Science Foundation of Jiangsu Province(211320B51903), the Natural Science Research Project of Jiangsu Higher Education Institutions(111320B11902), Changzhou Science and Technology Program(CJ20190073, CJ20200044) and the Talent Introduction Project of Jiangsu University of Technology(KYY17018)

均衡关系选取实时数据以获取正常的序列,从中确定最佳序列进行实时滚动预测,然后采用协整模型预测实时数据大量缺失的序列,以此为基础对高速公路充电网络充电设施的运行状态进行时空预测建模。

### 1 电动汽车行驶速度滚动预测建模

在实际情况中,某些序列间存在非常密切的长期均衡关系。协整理论指出,存在这种关系的序列自身不要求平稳,其残差序列平稳即可。相比于序列自身平稳,残差序列平稳更易实现。

#### 1.1 二元速度序列协整建模

构建回归模型<sup>[10]</sup>为:

$$y_t = \beta_0 + \beta_1 x_t + \varepsilon_t \quad (1)$$

其中,  $\beta_0$ 、 $\beta_1$  为待估计参数;  $\{x_t\}$  为自变量序列;  $\{y_t\}$  为响应变量序列;  $\{\varepsilon_t\}$  为残差序列。

若残差序列  $\{\varepsilon_t\}$  平稳,则称  $\{x_t\}$  与  $\{y_t\}$  之间具有协整关系,可用恩格尔-格兰杰协整检验,检验步骤如下:①根据式(1)建立  $\{x_t\}$  与  $\{y_t\}$  的回归模型;②采用最小二乘法对  $\beta_0$ 、 $\beta_1$  进行估计;③采用菲利普斯-配荣检验法对  $\{\varepsilon_t\}$  进行平稳性检验。若  $\{\varepsilon_t\}$  通过检验,则说明  $\{y_t\}$  与  $\{x_t\}$  之间具有协整关系,则  $\{\varepsilon_t\}$  可表示为:

$$\varepsilon_t = y_t - (\beta_0 + \beta_1 x_t) \quad (2)$$

$\{\varepsilon_t\}$  可能蕴涵了历史信息的相关性,可考察其自相关和偏相关信息,构建自回归移动平均模型,如式(3)所示。

$$\varepsilon_t = \frac{\Theta(B)}{\Phi(B)} a_t \quad (3)$$

其中,  $\Theta(B)$  为  $q$  阶移动平均系数多项式,  $B$  为延迟算子;  $\Phi(B)$  为残差序列  $p$  阶自回归系数多项式;  $\{a_t\}$  为白噪声序列,满足  $a_t \sim N(0, \sigma^2)$ ,  $\sigma$  为标准差。

由此可得,二元时间序列协整拟合模型为:

$$y_t = \beta_0 + \beta_1 x_t + \frac{\Theta(B)}{\Phi(B)} a_t \quad (4)$$

其中,  $\{y_t\}$  依据实际需要指定;而对于序列  $\{x_t\}$ , 仅凭协整这一条件则难以获得相应的最佳序列。

为了评价序列之间的差异性,定义  $\{y_t\}$  与多元变量序列  $\{x_{1,t}\}$ 、 $\{x_{2,t}\}$ 、 $\dots$ 、 $\{x_{i,t}\}$ 、 $\dots$ 、 $\{x_{n,t}\}$  之间的灰色关联系数<sup>[12]</sup>为:

$$s_{i,t} = \frac{\min_i \min_t |y_t - x_{i,t}| + \rho \max_i \max_t |y_t - x_{i,t}|}{|y_t - x_{i,t}| + \rho \max_i \max_t |y_t - x_{i,t}|} \quad (5)$$

$t = 1, 2, \dots, m_0; i = 1, 2, \dots, n$

其中,  $\rho$  为 0~1 范围内的可调节参数,通常取为 0.5 较合适。此时  $\{y_t\}$  与  $\{x_{i,t}\}$  的灰色关联度为:

$$r_i = \frac{1}{m_0} \sum_{t=1}^{m_0} s_{i,t} \quad i = 1, 2, \dots, n \quad (6)$$

因此,定义最佳自变量序列  $\{x_t\}_{op}$  为多元变量序列中与  $\{y_t\}$  的灰色关联度最大值所对应的序列。图 1 给出了一组  $\{x_t\}_{op}$  与  $\{y_t\}$  的观察值,图中  $\{x_t\}_{op} = \{x_1, x_2, \dots, x_n, x_{n+m_1}\}$ ,  $\{y_t\} = \{y_1, y_2, \dots, y_n\}$ ,  $\{y_t\}$  缺失了后  $m_1$  个值。根据观察值,采用二元协整模型可以对  $\{y_t\}$  的缺失值进行修复。




图 1  $\{x_t\}_{op}$  与  $\{y_t\}$  的观察值  
Fig.1 Observed values of  $\{x_t\}_{op}$  and  $\{y_t\}$

#### 1.2 基于小波神经网络方法的速度滚动预测模型

小波神经网络是基于反向传播神经网络拓扑结构,以小波函数为隐含层节点传递函数,时间序列前向传播的同时误差反向传播的神经网络。相比于其他改进神经网络方法,小波神经网络方法的优势在于可以利用小波函数提取时间序列的局部特征<sup>[11]</sup>。因此,本文选取小波神经网络预测方法进行建模,小波神经网络的拓扑结构见附录 A 图 A1。其中,隐含层的输出为:

$$h_j = w_j \left( \left( \sum_{i=1}^{N_{in}} \omega_{i,j} x_i - b_j \right) / a_j \right) \quad j = 1, 2, \dots, l \quad (7)$$

其中,  $h_j$  为隐含层节点  $j$  的输出值;  $x_i$  为输入层节点  $i$  的观察值;  $\omega_{i,j}$  为输入层节点  $i$  到隐含层节点  $j$  的权重值;  $b_j$  为隐含层节点  $j$  小波基函数的平移因子;  $a_j$  为隐含层节点  $j$  小波基函数的伸缩因子;  $N_{in}$  为输入层的节点数量;  $w_j(\cdot)$  为隐含层节点  $j$  的小波基函数,本文选用莫雷小波函数,即  $w_j(x) = \cos(1.75x)e^{-x^2/2}$ ;  $l$  为隐含层的节点数量。

小波神经网络输出层的输出为:

$$y_k = \sum_{j=1}^l \omega_{j,k} h_j \quad k = 1, 2, \dots, m \quad (8)$$

其中,  $y_k$  为输出层节点  $k$  的输出值;  $\omega_{j,k}$  为隐含层节点  $j$  到输出层节点  $k$  的权重值;  $m$  为输出层的节点数量。

小波神经网络的权重值参数修正类似于反向传播神经网络,其预测误差  $E$  为:

$$E = \sum_{k=1}^m (y'_k - y_k) \quad (9)$$

其中,  $y'_k$  为输出层节点  $k$  的期望输出值或观察值。

根据预测误差, 采用梯度修正法可修正小波神经网络的权重值和小波基函数参数, 使得预测输出值逼近期望输出值, 但这会导致进化缓慢并且易陷入最小值, 因此需增加动量项以提高网络学习效率, 即:

$$\omega_{j+1,k} = \omega_{j,k} + \Delta\omega_{j+1,k} + k_1(\omega_{j,k} - \omega_{j-1,k}) \quad (10)$$

$$a_{j+1,k} = a_{j,k} + \Delta a_{j+1,k} + k_1(a_{j,k} - a_{j-1,k}) \quad (11)$$

$$b_{j+1,k} = b_{j,k} + \Delta b_{j+1,k} + k_1(b_{j,k} - b_{j-1,k}) \quad (12)$$

其中,  $k_1$  为动量项的学习速率;  $a_{j,k}$ 、 $b_{j,k}$  分别为对应输出层节点  $k$  的隐含层节点  $j$  小波基函数的平移因子、伸缩因子;  $\Delta$  表示相应变量的修正值。

基于小波神经网络预测模型, 则给定步长  $s$  下的预测输出为:

$$\begin{cases} y_{t+1} = F(x_t, x_{t-1}, \dots, x_1) \\ y_{t+2} = F(y_{t+1}, x_t, x_{t-1}, \dots, x_1) \\ \vdots \\ y_{t+s} = F(y_{t+s-1}, y_{t+s-2}, \dots, y_{t+1}, x_t, x_{t-1}, \dots, x_1) \end{cases} \quad (13)$$

其中,  $\{y_{t+1}, y_{t+2}, \dots, y_{t+s}\}$  为多步预测值;  $F(\cdot)$  为小波神经网络预测模型。

## 2 充电网络充电设施运行状态时空预测建模

单座充电站与站内电动汽车组成小型排队系统, 若干小型排队系统组成大型充电网络排队系统<sup>[4,7]</sup>。

### 2.1 电动汽车行驶位置及其荷电状态模型

电动汽车的行驶位置和荷电状态随时间不断变化, 当前  $\tau$  时刻路径  $r$  中电动汽车  $k$  的行驶位置  $L_\tau^k$ 、荷电状态  $S_{\text{SOC},\tau}^k$  分别为:

$$L_\tau^k = \begin{cases} L_{\tau-\Delta\tau}^k + \Delta L_{\Delta\tau}^k & \tau > T_0^k, L_\tau^k < L_D^k \\ L_0^k & \tau = T_0^k \end{cases} \quad (14)$$

$$S_{\text{SOC},\tau}^k = \begin{cases} S_{\text{SOC},\tau-\Delta\tau}^k - \Delta S_{\text{SOC},\Delta\tau}^k & \tau > T_0^k, L_\tau^k < L_D^k \\ S_{\text{SOC},0}^k & \tau = T_0^k \end{cases} \quad (15)$$

$$\begin{cases} \Delta L_{\Delta\tau}^k = V_{\tau-\Delta\tau}^k \Delta\tau \\ \Delta S_{\text{SOC},\Delta\tau}^k = \Delta L_{\Delta\tau}^k / L_{\text{max}}^k \end{cases} \quad (16)$$

其中,  $L_0^k$ 、 $L_D^k$  分别为路径  $r$  中电动汽车  $k$  的出发位置、目的地位置, 单位为 km;  $\Delta\tau$  为时间间隔, 单位为 min;  $T_0^k$  为路径  $r$  中电动汽车  $k$  到达出发地的时间, 单位为 min;  $\Delta L_{\Delta\tau}^k$  为路径  $r$  中电动汽车  $k$  在时间间隔  $\Delta\tau$  内的行驶路程, 单位为 km;  $L_{\tau-\Delta\tau}^k$  为  $\tau - \Delta\tau$  时刻路径  $r$  中电动汽车  $k$  的行驶位置, 单位为 km;  $\Delta S_{\text{SOC},\Delta\tau}^k$  为时间间隔  $\Delta\tau$  内路径  $r$  中电动汽车  $k$  的荷电状态变化量;  $S_{\text{SOC},\tau-\Delta\tau}^k$  为  $\tau - \Delta\tau$  时刻路径  $r$  中电动汽车  $k$  的荷电状态;  $S_{\text{SOC},0}^k$  为路径  $r$  中电动汽车  $k$  到达出发地时的

荷电状态;  $V_{\tau-\Delta\tau}^k$  为  $\tau - \Delta\tau$  时刻路径  $r$  中电动汽车  $k$  的行驶速度, 单位为 km/h, 可取为行驶速度的预测值;  $L_{\text{max}}^k$  为电动汽车  $k$  的最大续航里程, 单位为 km。

若当前  $\tau$  时刻路径  $r$  中电动汽车  $k$  在充电站  $i$  逗留, 则电动汽车  $k$  的位置可视为不变, 而其荷电状态为:

$$S_{\text{SOC},\tau}^k = \begin{cases} S_{\text{SOC},\text{arr},i}^k & \tau \in [T_1, T_2) \\ S_{\text{SOC},\text{arr},i}^k + \frac{S_{\text{SOC},\text{exp},i}^k - S_{\text{SOC},\text{arr},i}^k}{\lfloor T_{\text{chrg},i}^k / \Delta\tau \rfloor / T_{\text{pro},i}^k} & \tau \in [T_2, T_3] \end{cases} \quad (17)$$

$$\begin{cases} T_{\text{pro},i}^k \in \{1, 2, \dots, \lfloor T_{\text{chrg},i}^k / \Delta\tau \rfloor\} \\ T_1 = T_{\text{arr},i}^k, T_2 = T_{\text{arr},i}^k + T_{\text{wait},i}^k \\ T_3 = T_{\text{arr},i}^k + T_{\text{wait},i}^k + T_{\text{chrg},i}^k \end{cases} \quad (18)$$

其中,  $S_{\text{SOC},\text{arr},i}^k$ 、 $S_{\text{SOC},\text{exp},i}^k$  分别为路径  $r$  中电动汽车  $k$  到达充电站  $i$  的起始荷电状态、在充电站  $i$  内的期望荷电状态;  $T_{\text{pro},i}^k$  为路径  $r$  中电动汽车  $k$  在充电站  $i$  内的充电进度, 单位为 min;  $T_{\text{arr},i}^k$  为路径  $r$  中电动汽车  $k$  到达充电站  $i$  的时间, 单位为 min;  $T_{\text{wait},i}^k$  为路径  $r$  中电动汽车  $k$  在充电站  $i$  内的等待时间, 单位为 min;  $T_{\text{chrg},i}^k$  为路径  $r$  中电动汽车  $k$  在充电站  $i$  内的充电时间, 单位为 min;  $\lfloor \cdot \rfloor$  表示向下取整。

### 2.2 电动汽车充电概率及其到站时间模型

电动汽车  $k$  到达充电站  $i$  的充电行为可用充电概率  $p_{\text{CP}}$  表示:  $p_{\text{CP}} = 1$  表示充电;  $p_{\text{CP}} = 0$  表示不充电。若当前  $\tau$  时刻路径  $r$  中电动汽车  $k$  执行充电行为, 则到达行驶路线上充电站  $i$  的充电概率  $p_{\text{CP},i}^k$  为:

$$p_{\text{CP},i}^k = \begin{cases} 1 & \delta_{\text{min}} < S_{\text{SOC},\tau}^k \leq S_{\text{SOC},\text{wv}}^k, L_\tau^k = L_{\text{CS},i}^k \\ 0 & \text{其他} \end{cases} \quad (19)$$

$$S_{\text{SOC},\text{wv}}^k = \Delta L_{L_{i+1}}^k / L_{\text{max}}^k + \delta_{\text{min}} \quad (20)$$

其中,  $\delta_{\text{min}}$  为电动汽车的最小荷电状态, 本文取为 0.05;  $L_{\text{CS},i}^k$  为路径  $r$  中电动汽车  $k$  到达充电站  $i$  的位置, 单位为 km;  $S_{\text{SOC},\text{wv}}^k$  为电动汽车  $k$  的荷电状态警戒值;  $\Delta L_{L_{i+1}}^k$  为到达目的地前路径  $r$  中电动汽车  $k$  从充电站  $i$  到达下一充电站的路程, 单位为 km, 若电动汽车已到达目的地, 则取值为 50 km。

若当前  $\tau$  时刻电动汽车  $k$  到达充电站  $i$  的充电概率  $p_{\text{CP},i}^k = 1$ , 则其到达充电站  $i$  的时间为:

$$T_{\text{arr},i}^k = \tau \quad p_{\text{CP},i}^k = 1 \quad (21)$$

因式(16)中的行驶速度为多步预测值, 故式(21)中电动汽车到达充电站的时间也为多步预测值, 且两者的预测步长和预测精度均相同。

### 2.3 充电站充电设施运行状态模型

定义充电站队长为当前站内所有电动汽车的数量,由此将站内充电设施运行状态划分为不忙、较忙、忙、非常忙这4个等级,分别用1、2、3、4表示,即充电站 $i$ 充电设施运行状态 $d_{i_t}^k$ 为:

$$d_{i_t}^k = \begin{cases} 1 & 0 \leq L_{i_t}^\tau \leq 0.5N_{i_t} \\ 2 & 0.5N_{i_t} < L_{i_t}^\tau \leq N_{i_t} \\ 3 & N_{i_t} < L_{i_t}^\tau \leq 2N_{i_t} \\ 4 & L_{i_t}^\tau > 2N_{i_t} \end{cases} \quad (22)$$

其中, $L_{i_t}^\tau$ 为当前 $\tau$ 时刻充电站 $i$ 的队长,单位为辆,由排队算法求得; $N_{i_t}$ 为充电站 $i$ 内充电设施数量。

### 3 算法流程

本文算法流程包括电动汽车行驶速度滚动预测流程(见附录A图A2)和充电网络充电设施运行状态时空预测流程(见附录A图A3),其中电动汽车行驶速度滚动预测流程具体如下。

1)数据预处理。读取各站点序列,分别利用小波变换和最大最小法进行降噪和归一化处理。

2)确定响应变量序列和最佳自变量序列。确定响应变量序列,根据式(5)和式(6)计算多元变量序列与响应变量序列的灰色关联度,从而确定灰色关联度最大值对应的序列为最佳自变量序列。

3)协整检验。对响应变量序列和最佳自变量序列序列进行恩格尔-格兰杰协整检验,判断检验值是否为1,若是则执行步骤4),否则执行步骤6)。

4)基于菲利普斯-配荣检验与自回归移动平均法建模。根据式(2)计算残差序列并进行菲利普斯-配荣检验,判断检验值是否为1,若是则根据式(3)对残差序列进行自回归移动平均建模,否则执行步骤6)。

5)小波神经网络参数设置。选取最佳自变量序列的一部分数据作为训练值,剩余数据作为测试值,构建训练值的输入矩阵与输出向量和测试值的输入矩阵与输出向量,设置输入层节点数量、输出层节点数量、隐含层节点数量、输入层到隐含层的学习概率、隐含层到输出层的学习概率以及最大迭代次数。

6)小波神经网络训练。初始化小波神经网络的权重值、权重值增量和节点值,利用最大最小法对训练值的输入矩阵与输出向量进行归一化处理。然后对小波神经网络进行训练,具体包括根据式(9)计算预测误差、根据式(7)和式(8)分别计算隐含层的输出值和输出层的输出值、根据式(10)~(12)修正权重值。

7)滚动预测与评估。读取测试值的输入矩阵与输出向量,利用最大最小法进行归一化处理;设置预

测区间和步长,基于训练好的小波神经网络模型,根据式(13)进行多步滚动预测,将预测区间结果反归一化,再利用残差序列自回归移动平均模型进行预测,根据式(4)反算得到响应变量序列的滚动预测值;计算预测误差并评估预测结果;输出测试值和合适步长下的滚动预测值。

8)结束流程。

获取响应变量序列的预测值和测试值,可将其设置为电动汽车行驶速度,基于相关数据和模型参数,采用蒙特卡洛方法、弗洛伊德方法和排队算法<sup>[4]</sup>可得充电网络充电设施运行状态的预测值和观察值,计算预测误差以评估预测结果。充电网络充电设施运行状态时空预测流程具体如下。

1)设置仿真时段、时间步长、时间进度 $\tau$ ;设置高速公路路网参数,包括路段长度和编号、节点编号;设置电动汽车参数,包括车辆规模、电池容量、单位里程耗电量和充电功率;设置充电站群参数,包括充电站数量、位置编号以及充电站的最大充电桩数量;设置其他变量值。

2)采用蒙特卡洛方法生成设定数量电动汽车的出发地到达时刻、荷电状态、行驶速度、出发地和目的地的位置,基于路网参数和充电站群参数生成的邻接矩阵和电动汽车的出发地和目的地位置,采用弗洛伊德方法生成电动汽车的行驶路径和所经充电站编号;按照到达出发地的时刻,对电动汽车进行递增排序并设置其状态为路上状态。

3)读取 $\tau - \Delta\tau$ 时刻路上行驶的各电动汽车的状态信息,包括行驶速度、荷电状态、行驶位置和目的地位置;根据式(14)~(16)更新其位置和荷电状态并判断是否到达目的地,若到达,则设置其状态为到达状态。

4)由当前 $\tau$ 时刻各电动汽车的位置和充电站位置,判断电动汽车是否到达行驶路线上的充电站。若到达,则根据式(19)和式(20)判断其是否需要充电。若需要充电,则设置其状态为进站状态,根据式(21)记录到达充电站的时刻,设置充电进度并计算充电时间。

5)读取 $\tau - \Delta\tau$ 时刻每座充电站在充电动汽车的进站时刻、充电进度和充电时间,正在等待电动汽车的进站时刻和充电时间,离站电动汽车的状态信息,并将其与 $\tau$ 时刻每座充电站的电动汽车到达时刻、充电时间一同作为输入。利用排队算法<sup>[4]</sup>计算当前 $\tau$ 时刻每座充电站队长和电动汽车的等待时间,根据式(22)计算相应的充电设施运行状态,然后根据式(17)和式(18)更新在充电动汽车的荷电状态,设置离站电动汽车状态为路上状态并更新行驶速度。

6)时间进度加1,判断仿真时段是否结束,若结束则转至步骤7),否则转至步骤3)。

7)结束流程,输出充电网络充电设施运行状态的预测值和观察值,并计算预测误差,评估预测结果。

#### 4 算例分析

考虑到电动汽车的行驶速度与传统汽车较接近,可利用传统汽车的行驶工况数据作用电动汽车的行驶工况数据。故本文从美国明尼苏达州双子城交通管理中心交通数据中提取了2018年12月10日至2019年1月7日共9个站点的751 680条数据,每条数据均包含交通流量和车道占有率(时间粒度为0.5 min)信息,数据均来自于各站点的目标检测器。基于上述信息可通过专用行驶时间计算平台获取相应的行驶速度数据(时间粒度为5 min),将其作为电动汽车的行驶速度数据<sup>[13]</sup>。在实际应用中为了保证数据采集的高可靠性,各站点安装的检测器不止1台,且各检测器采集的数据相同。本文选取的站点检测器和目标检测器如表1所示。表中,站点S280安装了2台检测器,其他站点均安装了3台检测器,故站点S280的数据采集可靠性较低,若假设其2台检测器均在2019年1月7日发生故障,即当天无法获取站点S280的实时数据,故选取站点S280序列为响应变量序列,并对其滚动预测。

表1 站点检测器和目标检测器  
Table 1 Site detectors and target detectors

序号	站点	检测器	目标检测器	序号	站点	检测器	目标检测器
1	S280	1712, 1713	1713	6	S285	777, 778, 779	779
2	S281	1719, 1720, 1721	1721	7	S286	783, 784, 785	785
3	S282	1730, 1731, 1732	1732	8	S287	767, 768, 769	769
4	S283	788, 789, 790	790	9	S288	770, 771, 772	772
5	S284	793, 794, 795	795				

##### 4.1 最佳自变量序列分析

对各站点前28天的自变量序列进行灰色关联分析,可得各自变量序列与响应变量序列的灰色关联度,结果如图2所示。各站点的空间位置分布如图3所示(图中394EB和394WB为2条道路的编号)。

由图2可知,站点S281自变量序列与响应变量序列的灰色关联度最大,为0.9662,这与站点S281与S280的空间位置最为邻近有关,故站点S281自变量序列为最佳自变量序列。同时二者均为单整序列,用MATLAB自带egcitest函数进行恩格尔-格兰杰协整检验,检验结果如下:检验布尔判定值为1且假设概率为0.001,表明二者存在协整关系。




图2 各站点自变量序列与响应变量序列的灰色关联度  
Fig.2 Grey correlation degrees of each site's independent variable sequence and response variable sequence




图3 站点的空间位置分布  
Fig.3 Spatial location distribution of sites

##### 4.2 行驶速度预测结果分析

设置小波神经网络的输入层、输出层、隐含层的节点数量分别为4、1、6,输入层到隐含层的学习概率为0.01,隐含层到输出层的学习概率为0.001,最大迭代次数为100,预测步长 $s$ 分别为5、10、15、20、25、30、35、40、45、50、55、60 min。利用最佳自变量序列前28天的数据训练小波神经网络,并分别利用训练好的网络、协整模型对最佳自变量序列、响应变量序列第29天的数据进行滚动预测。

由电动汽车行驶速度滚动预测流程可得不同的预测步长下的多步预测结果,见附录A图A4。图中,不同颜色表示行驶速度快慢,黄色表示行驶速度快,蓝色表示行驶速度慢;预测步长为0时的结果为观察值。由图A4可知,06:00—18:00时段内观察值主要对应橙色区,随着预测步长不断增加,预测值对应绿色区不断扩大,这表明电动汽车的行驶速度预测误差不断增大。

为了进一步准确评估预测结果,本文选取平均相对误差 $E_{MAPE}$ 、均方根误差 $E_{RMSE}$ 和可靠度 $R$ 为指标,计算式分别见式(23)~(25)。

$$E_{MAPE} = \frac{1}{M} \sum_{j=1}^M \left| \frac{v'_j - v_j}{v'_j} \right| \times 100\% \quad (23)$$

$$E_{RMSE} = \sqrt{\frac{1}{M} \sum_{j=1}^M (v'_j - v_j)^2} \quad (24)$$

$$R = M'/M \times 100\% \quad (25)$$

其中, $M$ 为预测点的数量; $M'$ 为预测值相对误差不超过10%的预测点数量; $v'_j$ 、 $v_j$ 分别为预测点 $j$ 行驶速度的观察值、预测值,单位为 $\text{km/h}$ 。将图A4中的观察值和预测值代入式(23)~(25),可得不同预测

步长下电动汽车行驶速度的预测误差指标值,结果如表 2 所示。由表可知,随着预测步长  $s$  不断增加,平均相对误差  $E_{MAPE}$ 、均方根误差  $E_{RMSE}$  均不断增加,可靠度  $R$  不断降低。总体而言,当预测步长  $s=5$  min 时,预测误差最小;当预测步长  $s=60$  min 时,预测误差最大。

表 2 不同预测步长下电动汽车行驶速度的预测误差指标值

Table 2 Prediction error index values of electric vehicle traveling speed under different predicted step sizes

$s /$ min	$E_{MAPE} /$ %	$E_{RMSE} /$ ( $\text{km} \cdot \text{h}^{-1}$ )	$R /$ %	$s /$ min	$E_{MAPE} /$ %	$E_{RMSE} /$ ( $\text{km} \cdot \text{h}^{-1}$ )	$R /$ %
5	2.92	4.81	93.75	35	6.57	8.14	78.82
10	3.58	5.38	91.67	40	6.62	8.24	81.60
15	4.00	5.57	90.63	45	6.80	8.61	80.56
20	4.52	5.93	87.50	50	6.97	8.19	78.47
25	4.45	5.87	88.19	55	7.21	8.48	78.13
30	5.08	6.43	83.33	60	7.13	8.81	77.78

#### 4.3 充电设施运行状态时空预测分析

根据文献[4]数据设置高速公路路网结构,充电站的容量和位置,单枪充电桩的数量和容量,电动汽车的起讫点(OD)分布、充电行为比例、数量、续航里程、电池容量、到达出发地的荷电状态分布及到达时间概率密度曲线。本文暂不考虑电动汽车行驶速度空间特性的影响,设置路网中所有路段均用同一站点预测所得行驶速度(即图 A4 中预测步长为 30 min 时的预测值和观察值)。由充电网络充电设施运行状态时空预测流程可得各充电站充电设施运行状态时空预测值与观察值,结果见附录 A 图 A5。图 A5 (a)和(b)分别对应 2 个离散值矩阵,且图中黄色表示运行状态等级高。

为了进一步评估预测精度,现定义指标  $S_{FV}$  如式(26)所示。

$$S_{FV} = z'/z \times 100\% \quad (26)$$

其中, $z$ 为单个矩阵的元素数量; $z'$ 为两离散值矩阵中对应元素相等的元素数量。根据式(26)计算可得  $S_{FV} = 92.1\%$ ,即充电网络充电设施运行状态时空预测精度比较高,能满足电动汽车预约充电优化需求。

## 5 结论

本文考虑电动汽车行驶速度与传统汽车的行驶速度较接近,基于传统汽车的实际行驶速度数据,提出了一种高速公路充电网络充电设施运行状态时空预测建模方法,并通过算例分析验证了所提方法的有效性,所得主要结论如下:

1)采用灰色关联分析法选取与响应变量序列空间位置最为邻近的序列得到最佳自变量序列,通过恩格尔-格兰杰协整检验发现,响应变量序列与最佳

自变量序列之间存在协整关系;

2)根据最佳自变量序列的滚动预测值,采用协整模型预测响应变量序列时,随着预测步长的增加,预测误差也随之增加;

3)采用本文所提方法得到的高速公路充电网络充电设施运行状态时空预测精度较高,达到 92.1%,可满足电动汽车预约充电优化需求。

此外,本文暂不考虑行驶速度数据空间特性的影响,将路网中所有路段的电动汽车行驶速度均用同一站点数据进行预测,而收集速度数据时涉及场景匹配问题,直接移植应用难免存在偏差。限于篇幅,本文只分析了充电设施为单枪桩的情形,并未考虑多枪桩。后续可以深入研究单枪桩、多枪桩混合情形下的公共充电网络充电设施运行状态时空预测建模。

附录见本刊网络版(<http://www.epae.cn>)。

#### 参考文献:

- [1] 王毅,陈进,麻秀,等. 采用分群优化的电动汽车与电网互动调度策略[J]. 电力自动化设备,2020,40(5):77-85.  
WANG Yi, CHEN Jin, MA Xiu, et al. Interactive scheduling strategy between electric vehicles and power grid based on group optimization[J]. Electric Power Automation Equipment, 2020,40(5):77-85.
- [2] 陈丽丹,张尧, Antonio Figueiredo. 融合多源信息的电动汽车充电负荷预测及其对配电网的影响[J]. 电力自动化设备, 2018,38(12):1-10.  
CHEN Lidan, ZHANG Yao, ANTONIO F. Charging load forecasting of electric vehicles based on multi-source information fusion and its influence on distribution network[J]. Electric Power Automation Equipment, 2018,38(12):1-10.
- [3] WEI Wei, WU Lei, WANG Jianhui, et al. Network equilibrium of coupled transportation and power distribution systems[J]. IEEE Transactions on Smart Grid, 2018,9(6):6764-6779.
- [4] CHEN Lixing, CHEN Zhong, HUANG Xueliang, et al. A study on price-based charging strategy for electric vehicles on expressways[J]. Energies, 2016,9(5):385.
- [5] CHEN Lixing, HUANG Xueliang, ZHANG Hong. Modeling the charging behaviors for electric vehicles based on ternary symmetric kernel density estimation[J]. Energies, 2020,13(7): 1551.
- [6] 邢强,陈中,黄学良,等. 基于数据驱动方式的电动汽车充电需求预测模型[J]. 中国电机工程学报, 2020,40(12):3796-3813.  
XING Qiang, CHEN Zhong, HUANG Xueliang, et al. Electric vehicle charging demand forecasting model based on data-driven approach[J]. Proceedings of the CSEE, 2020,40(12): 3796-3813.
- [7] 陈立兴,黄学良. 高速公路充电站电动汽车有序充电策略[J]. 电力自动化设备, 2019,39(1):112-117, 126.  
CHEN Lixing, HUANG Xueliang. Ordered charging strategy of electric vehicles at charging station on highway[J]. Electric Power Automation Equipment, 2019,39(1):112-117, 126.
- [8] CHEN Lixing, HUANG Xueliang, ZHANG Hong, et al. A study on coordinated optimization of electric vehicle charging and charging pile selection[J]. Energies, 2018,11(6):1350.
- [9] GU Yuanli, LU Wenqi, XU Xinyue, et al. An improved Bayesian combination model for short-term traffic prediction with deep learning[J]. IEEE Transactions on Intelligent Transport-

tation Systems, 2020, 21(3): 1332-1342.

- [10] 易丹辉, 王燕. 应用时间序列分析[M]. 5版. 北京: 中国人民大学出版社, 2019: 262-263.
- [11] 王小川, 史峰, 郁磊, 等. MATLAB神经网络43个案例分析[M]. 北京: 北京航空航天大学出版社, 2013: 279-287.
- [12] 邓聚龙. 灰理论基础[M]. 武汉: 华中科技大学出版社, 2002: 137-138.
- [13] KWON T M. RTMC traffic data(archived loop data)[EB/OL]. [2020-07-10]. <https://www.d.umn.edu/~tkwon/TMCdata/TMCarchive.html>.

#### 作者简介:

陈立兴(1984—), 男, 河北阳原人, 讲师, 博士, 主要研究方向为电动汽车充电行为建模、充电设施规划、电动汽车有序充电等(**E-mail**: chenlixing@jsut.edu.cn);



陈立兴

韩晓新(1964—), 男, 江苏武进人, 教授, 主要研究方向为智能控制理论方法与应用、先进测控技术与应用等(**E-mail**: dxhxx@jsut.edu.cn);

季振亚(1988—), 女, 江苏南通人, 讲师, 博士, 主要研究方向为电动汽车与电网互动、气电互联综合能源系统优化调度以及能源互联市场等(**E-mail**: jizhenya@outlook.com);

王琪(1987—), 男, 江苏泰州人, 副教授, 博士, 通信作者, 主要研究方向为新能源汽车复合电源能量管理控制、动力电池荷电状态预测控制(**E-mail**: wangqi@jsut.edu.cn)。

(编辑 陆丹)

## Spatio-temporal forecasting modeling for running status of charging facilities in highway charging network

CHEN Lixing<sup>1</sup>, HAN Xiaoxin<sup>1</sup>, JI Zhenya<sup>2</sup>, WANG Qi<sup>1</sup>

(1. School of Electrical & Information Engineering, Jiangsu University of Technology, Changzhou 213001, China;

2. School of Electrical and Automation Engineering, Nanjing Normal University, Nanjing 210023, China)

**Abstract:** Accurate spatio-temporal forecasting modeling for RSCF(Running Status of Charging Facilities) in highway charging network is the basis of reservation charging optimization. Considering that the driving speed of EV(Electric Vehicle) is close to that of traditional vehicle, based on the actual driving speed data of traditional vehicle, a spatio-temporal forecasting modeling method for RSCF in highway charging network is proposed. On the one hand, the rolling forecasting for EV driving speed is carried out by using the grey relational analysis method, cointegration-autoregressive moving average method and wavelet neural network method. On the other hand, based on the forecasting and observed values, the spatio-temporal forecasting for RSCF in highway charging network is realized by using Monte Carlo method, Freudian method and queuing algorithm. The results of case study show that the spatio-temporal forecasting results for RSCF in highway charging network obtained by the proposed method are more accurate, which can meet the optimization requirements of reservation charging of EV.

**Key words:** highway charging network; electric vehicles; running status of charging facilities; spatio-temporal forecasting; queuing algorithm; modeling

# 附录 A

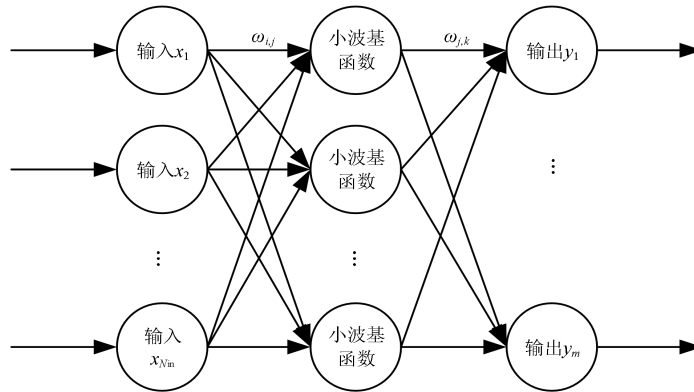


图 A1 小波神经网络的拓扑结构  
Fig.A1 Topological structure of wavelet neural network

图中， $\{x_1, x_2, \dots, x_{N_{in}}\}$  为输入参数； $\{y_1, y_2, \dots, y_m\}$  为预测输出参数； $\omega_{l,j}$ 、 $\omega_{j,k}$  为网络权重值。

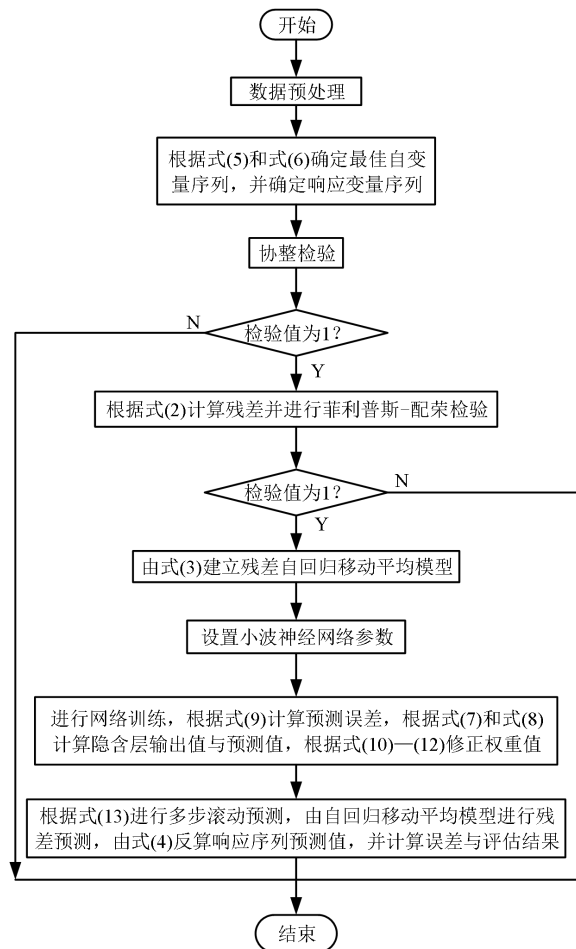


图 A2 电动汽车行驶速度滚动预测流程  
Fig.A2 Flowchart of rolling forecasting electric vehicle travelling speed



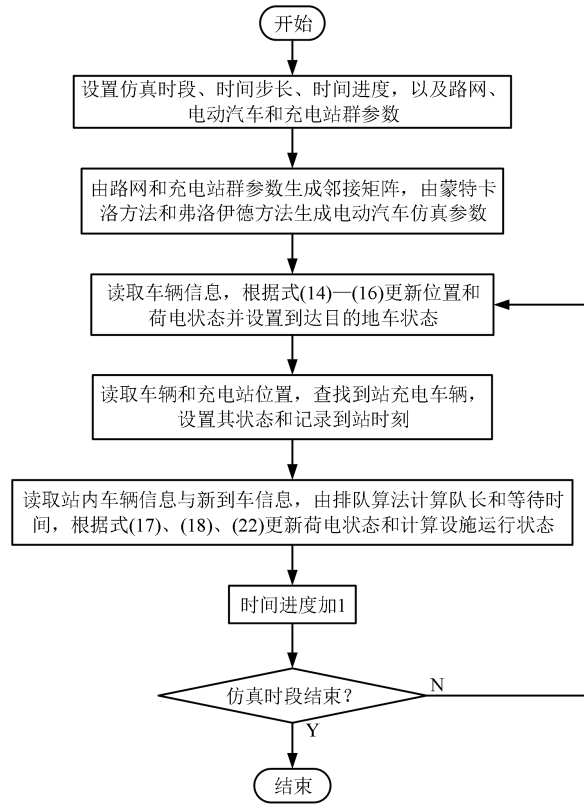


图 A3 充电网络充电设施运行状态时空预测流程

Fig.A3 Spatio-temporal forecasting flowchart of charging facility running status for charging network




图 A4 不同预测步长下电动汽车行驶速度的预测值与观察值

Fig.A4 Predicted values of electric vehicle travelling speed under different time steps and observed values




图 A5 充电站充电设施运行状态时空预测值与观察值

Fig.A5 Spatio-temporal predicted values and observed values of charging facility operation state in charging stations