

基于网格划分的电动汽车充电负荷预测方法

袁小溪¹, 潘鸣宇¹, 段大鹏¹, 李香龙¹, 陈海洋²

(1. 国网北京市电力公司电力科学研究院, 北京 100075; 2. 国网北京市电力公司, 北京 100031)

摘要:准确的电动汽车充电负荷时空分布预测模型是解决电动汽车并网造成的影响和研究充电设施规划的重要基础。为解决现有充电设施数量有限、布局不合理等因素造成的历史充电数据不能正确体现电动汽车实际充电需求的问题,提出一种基于网格划分的电动汽车充电负荷预测方法。首先对预测区域进行网格划分,再结合电力系统负荷预测方法,以网格为空间预测单元,利用含充电设施网格的预测指标和充电负荷的历史数据,通过贝叶斯正则化 BP 神经网络算法建立电动汽车充电负荷和影响因素之间的关系,以最终预测不含充电设施网格的充电需求。最后以北京市海淀区为例对提出的预测方法进行验证分析。仿真结果表明,该预测方法能够较准确地对电动汽车充电负荷进行时空分布预测。

关键词:负荷预测; 网格划分; 神经网络; 电动汽车

DOI:10.19781/j.issn.1673-9140.2021.03.003 中图分类号:TM715 文章编号:1673-9140(2021)03-0019-08

Prediction method of electric vehicle charging load based on grid division

YUAN Xiaoxi¹, PAN Mingyu¹, DUAN Dapeng¹, LI Xianglong¹, CHEN Haiyang²

(1. State Grid Beijing Electric Power Research Institute, Beijing 100075, China;

2. State Grid Beijing Electric Power Company, Beijing 100031, China)

Abstract: Accurate spatial and temporal distribution prediction model for electric vehicle charging load is an important basis for dealing with the impact of electric vehicle connected to the grid and researching charging facility planning. Due to the limited number and the unreasonable layout of existing charging facilities, the historical electric charging load data can not reflect the actual charging demand of electric vehicles explicitly. Under the background, a load forecasting method of power system is proposed based on the grid division. Firstly, the prediction region is divided into block that is taken as the spatial prediction unit. Then, the charging load of block with charging facilities and the history data of prediction indicators are utilized to assign historical charging data in blocks with charging facilities to each block. Secondly, a relationship between charging load and influencing factors is established by employing Bayesian regularization BP neural network algorithm. Finally, Haidian District of Beijing is considered for simulation to verify the proposed prediction method. It is shown that this method can accurately predict the spatial and temporal distribution of the electric vehicle charging load.

Key words: load prediction; grid division; neural network; electric vehicle

收稿日期:2021-03-01;修回日期:2021-04-01

基金项目:国网北京市电力公司科技项目(520223200062);国家重点研发计划(2016YFB0900505)

通信作者:袁小溪(1993-),女,硕士,工程师,主要从事电动汽车充换电设施规划研究;E-mail:bjdky2017@126.com

电动汽车在节能减排、减少对化石燃料的依赖等方面具有巨大的优势,世界多国都有推动电动汽车发展的激励政策^[1-4]。《巴黎协定》提出到2030年全球电动汽车保有量达到1亿辆的目标。大量电动汽车的接入,必将带来用电负荷增长^[5]、电能质量下降^[6]、配网规划难度增加^[7]等影响。然而,“充电难”也制约着电动汽车的发展。合理的充电网络布局优化是推动电动汽车发展的重要基础,也是提供智慧出行服务的前提。

准确的电动汽车充电负荷时空分布预测模型是解决电动汽车并网造成的负面影响和研究充电设施规划的重要基础,但是,电动汽车用户充电的时间、地点、电量具有不确定性,很难准确预测充电负荷。电动汽车充电负荷预测问题已经得到国内外学者的广泛关注,目前电动汽车充电负荷预测方法主要有基于电动汽车用户出行特征的模拟法和基于充电设施历史充电数据的电力系统负荷预测法。

基于用户出行特征的模拟法主要是根据电动汽车的出行规律拟合各段行程的起止时间和行驶距离,建立时空转移模型,对出行路径进行模拟,考虑百公里耗电量,最终得到充电负荷的时空分布。文献[8]对影响电动汽车并网的因素进行了分析,构建了基于蒙特卡罗方法的电动汽车负荷模型;文献[9]提出了一种基于Dijkstra算法的最优路径规划模型,并采用蒙特卡罗方法制定了交通网络区域的动态空间充电需求分布;文献[10]将一天内电动汽车的荷电状态通过马尔科夫链进行描述,采用蒙特卡罗方法对不同条件下的充电需求时空分布进行计算;文献[11]通过马尔科夫决策过程随机模拟电动汽车出行路径,并考虑了交通状况和温度对电动汽车能耗的影响,提出了充电负荷预测方法。但是,上述基于用户出行特征的模拟法对拟合准确度依赖较大,如果拟合估计不准确,则会造成充电负荷的累积误差。

基于充电设施历史充电数据的电力系统负荷预测法,主要是基于充电设施的历史充电数据,参考电力系统负荷预测方法,如人工神经网络法、相似日法、支持向量机法等,对电动汽车的充电负荷进行预测。文献[12]将灰色模型预测算法GM(1,1)应用到电动汽车充电需求预测;文献[13]首先分析了影

响电动公交车站日负荷的因素,然后基于灰色关联理论,选择相似日的样本建立支持向量回归(support vector regression, SVR)预测模型;文献[14]分别采用时间序列分析的自回归模型算法和机器学习的反向传输(back propagation, BP)神经网络算法进行负荷预测,仿真结果表明,在短期预测中,自回归模型算法预测精度低于BP神经网络算法;文献[15]提出了一种基于遗传算法(genetic algorithm, GA)和粒子群算法(particle swarm optimization, PSO)的SVR方法用于对电动汽车充电站的负荷预测,模糊C均值聚类用于建立相似日样本,GA用于全局参数搜索,PSO用于更准确的本地搜索,然后使用SVR对负载预测进行回归。基于历史充电数据的电力系统负荷预测法对历史充电数据的依赖性较大,而且只能对现有充电站/充电桩的负荷进行预测。然而,现有充电设施数量有限且缺乏科学合理的规划,不能正确体现实际充电需求的空间分布。

针对目前电动汽车充电负荷预测方法的不足,该文提出了基于贝叶斯正则化BP神经网络的电动汽车充电负荷预测模型。对预测区域进行网格划分后,提取包括区域功能、交通流量等在内的网格特征作为贝叶斯正则化BP神经网络的输入,以区域的历史充电负荷作为输出,并利用粒子群算法和反向传播算法训练神经网络,训练好的模型即可用于预测未知网格内的充电负荷水平。该文最后采用北京市海淀区为例进行了算例验证,算例结果表明,该文所提充电负荷预测方法不依赖于对用户出行特征的模拟,且能解决现有充电设施充电数据不能正确体现实际充电需求空间分布的问题。

1 粒子群优化的贝叶斯正则化BP神经网络算法

BP神经网络算法由于其优秀的复杂非线性处理能力,被广泛应用到电力系统负荷预测中。然而,BP神经网络算法泛化能力一般,易出现“过拟合”现象,影响预测的准确度。另外,BP神经网络算法在训练时容易陷入局部最优解。针对过拟合和局部极小化问题,该文采用贝叶斯正则化算法和PSO算法

对 BP 神经网络算法进行改进。

1.1 贝叶斯正则化 BP 神经网络算法

贝叶斯正则化算法通过对 BP 神经网络的性能函数进行修正来提高它的泛化能力,在性能函数均方误差 m_{se} (mean squared error) 中加入网络权值平方和的均值 m_{sw} (mean squared weight) 以减少有效权值的个数,改进后的性能函数为

$$m_{sereg} = \alpha m_{sw} + \beta m_{se} \quad (1)$$

$$m_{se} = \frac{1}{N} \sum_{i=1}^N (t_i - a_i)^2 \quad (2)$$

$$m_{sw} = \frac{1}{M} \sum_{i=1}^M \omega_i^2 \quad (3)$$

式(1)~(3)中 α 、 β 为超参数; N 为样本总数; t_i 、 a_i 分别为期望输出和网络实际输出; M 为网络权值总数; ω_i 为网络权值。

超参数 α 和 β 的预测公式为

$$\begin{cases} \alpha = \frac{\gamma}{2m_{sw}} \\ \beta = \frac{n - \gamma}{2m_{se}} \end{cases} \quad (4)$$

$$\gamma = m - 2\alpha tr(\mathbf{H})^{-1} \quad (5)$$

式(4)、(5)中 γ 为有效参数个数,也就是能降低性能函数的参数个数,计算方法见文献[16]; \mathbf{H} 为 m_{sereg} 的 Hessian 矩阵。为提高 \mathbf{H} 矩阵的计算速度,利用高斯-牛顿逼近法对 Hessian 矩阵作进一步简化,即

$$\mathbf{H} \approx 2\alpha \mathbf{I}_m + 2\beta \mathbf{J}^T \mathbf{J} \quad (6)$$

式中 \mathbf{J} 为 m_{se} 的雅可比矩阵。

1.2 粒子群优化的贝叶斯正则化 BP 神经网络算法

PSO 算法是一种全局搜索算法,可以将神经网络的初始权值和阈值作为粒子,利用 PSO 算法进行优化,从而避免神经网络算法陷入局部最优,加快收敛速度。

粒子群优化的贝叶斯正则化 BP 神经网络算法的流程如图 1 所示。

1) 确定神经网络的结构,包括网络层数和节点数的确定。

2) 初始化权值、阈值以及超参数 α 和 β ,一般设 $\alpha=0, \beta=1$ 。

3) 将神经网络的权值和阈值作为粒子,并对粒子群进行初始化,包括粒子的速度和位置。

4) 输入训练数据,计算粒子的适应度,选取神经

网络的性能函数作为粒子群适应度函数,由式(1)计算得到。

5) 通过比较当前和历史最好位置的适应度值,更新粒子个体和群体极值;

6) 更新粒子的速度和位置,更新公式参见文献[17]。

7) 如果不满足迭代终止条件,则返回步骤(4),如果满足迭代终止条件,则输出神经网络最优初始权值和阈值。

8) 用 BP 算法训练神经网络,使误差 m_{sereg} 最小。

9) 如果不满足迭代终止条件,则求有效参数个数 γ ,按照公式(4)更新超参数 α 和 β ,然后返回步骤(8),如果满足迭代终止条件,则输出网络模型。

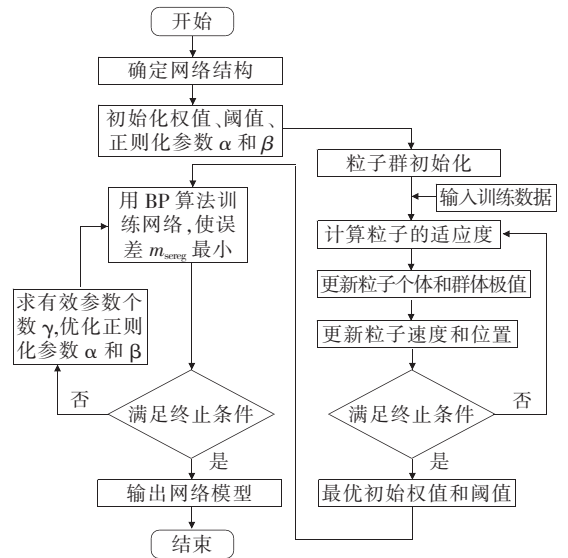


图 1 粒子群优化的贝叶斯正则化 BP 神经网络算法流程

Figure 1 Flow chart of Bayesian regularization BP neural network algorithm optimized by PSO

2 电动汽车充电负荷预测模型

2.1 预测区域网格划分

由于现有充电设施规划主观性强,缺乏协调、科学、统筹、优化手段,充电设施布局并不合理,导致历史充电数据不能正确体现电动汽车充电负荷空间分布。针对该问题,在对预测区域划分网格的基础上,以网格为空间预测单元,通过粒子群优化的贝叶斯正则化 BP 神经网络将包含充电设施网格的历史充电数据合理地分配到每个网格。

首先,将预测区域按一定精度(如 500 m×500 m、

1 000 m×1 000 m)划分为相同大小的网格,为后面充电负荷的空间预测提供基础,其中网格划分精度可以参照停车场规划的网格划分精度。文献[18]指出停车小区的面积要适中,通常停车小区的边长不超过 2 000 m,也不要小于 200 m。下文的模型均以网格为基本单元,分别对每个网格的充电负荷进行预测。

2.2 数据处理

2.2.1 数据统计

在网格划分的基础上,按照每个网格统计充电负荷、区域功能、交通流量数据。

1) 充电负荷。

搭建充电负荷数据仓库,将所研究区域内充电桩资产信息和一段时间的充电记录导入保存,根据充电桩运行编号连接充电桩资产信息和充电记录以确定充电交易记录发生的空间位置,在数据预处理中将脏数据进行过滤。最后,将充电数据从时间维度上按照 24 h 进行统计,从空间维度上按照经纬网格进行统计,生成各个已建有充电设施网格内每天 24 h 充电功率曲线,选取多天充电功率数据求平均值,从而得到典型日各个网格内的 24 h 充电功率统计曲线。

2) 区域功能。

搭建区域功能数据仓库,将所研究区域内的兴趣点(points of interest, POI)导入保存,可以获知该区域内的功能构成。首先,在数据预处理中将脏数据进行过滤;然后,在数据分析统计环节,从空间维度上按照 2.1 节所述的网格划分方式将 POI 数据进行网格化分类。最后,计算各个网格中不同 POI 标签数量占该网格 POI 标签总数的占比,从而得到各网格中不同功能区域的占比。表 1 中展示了某一个 1 000 m×1 000 m 网格内的 POI 标签占比。

3) 交通流量。

首先搭建交通流量数据仓库,将所研究区域内一段时间的交通流量数据导入保存,在数据预处理中将脏数据进行过滤;然后在数据分析统计环节,将数据从时间维度上按照典型工作日、周末、节假日进行统计,从空间维度上按照经纬网格进行统计;最后按照工作日、周末、节假日在一年中的比例计算加权平均值,从而得到各网格中典型日交通流量数据。

表 1 某网格内 POI 标签占比

Table 1 List of POI tags in a grid

| 网格编号 | POI 标签名称 | POI 标签数量 | 占比/% |
|-------|----------|----------|-------|
| G0153 | 民用住宅 | 17 | 30.91 |
| | 生活服务 | 8 | 14.55 |
| | 绿地 | 6 | 10.91 |
| | 公路 | 5 | 9.09 |
| | 医疗保健服务 | 3 | 5.45 |
| | 公共设施 | 3 | 5.45 |
| | 道路附属设施 | 2 | 36.36 |
| | 其他 | 11 | 20 |

2.2.2 数据归一化

为了避免数值问题、加快收敛速度,需要对样本数据进行归一化处理。为了将数据值变换到 $[-1, 1]$ 之间,文中采用数据归一化,即

$$P_n = \frac{2(P - P_{\min})}{P_{\max} - P_{\min}} - 1 \quad (7)$$

式中 P_n 为归一化处理后的数据; P 为原始数据; P_{\min} 、 P_{\max} 分别为原始数据集中的最小值和最大值。

2.3 预测指标的选取

文献[19]中指出用地类型会影响电动汽车规模和充电需求的时空分布特性,如居民用地对应着较大的充电密度,商业和办公区对应的充电需求主要集中在白天;文献[20]同样指出电动汽车充电负荷与区域功能有关;文献[21]中指出交通密度对电动汽车充电需求有较大影响,区域内交通密度越大,则表明电动汽车运行量越大,充电需求也就越大。

在现有研究的基础上,列举可能对电动汽车充电需求产生影响的因素,如区域功能(商场、居民区、工作区等)、交通流量等。利用单因素方差分析法,从运营模式、交通流量、人口分布、区域功能 4 个变量中筛选出对充电电量有显著影响的影响因素。运用 SPSS11.0 数据统计分析软件进行求解,将 3 个变量作为控制变量,充电电量作为观测变量,通过单因素方差分析,考察 F 检验统计值,如果 F 的相伴概率 P 值小于或等于给定的显著性水平($\alpha = 0.05$),则表示具有显著性。

2.4 神经网络结构的确定

BP 神经网络结构的确定主要包括网络层数的确定和网络节点数的确定。

网络层数的确定也就是隐含层个数的确定。由于神经网络的万有逼近性质^[22],即一个含有单独隐

含层的神经网络结构,给定充分的神经元,那么这个神经网络可以拟合任意函数,文中选择包含一个输入层、一个隐含层和一个输出层的 3 层 BP 神经网络结构。

网络节点数的确定包括输入层节点数、隐含层节点数和输出层节点数的确定。其中,输入层和输出层的节点数与网络实际的输入、输出变量个数一致。目前,隐含层节点数的确定尚未建立完善的理论依据,节点数过多会增加训练时间,降低网络的泛化能力,但是节点数过少,又会导致建模不充分。针对隐含层节点数量的选择,有经验公式为

$$G = \sqrt{I + O} + a \quad (8)$$

式中 G 为隐含层节点数; I 和 O 分别为输入层和输出层节点数; a 为 $[1, 10]$ 之间的数。该文依据上述公式,采用试凑法确定隐含层的节点数,即构建多个除隐含层节点数不同,其它条件都相同的 BP 神经网络,并采用相同的样本进行训练。通过比较各网络的训练时间和预测精度,确定最佳隐含层节点数。

2.5 电动汽车充电负荷预测

根据上文中确定的神经网络结构,利用 Matlab 生成、训练粒子群优化的贝叶斯正则化 BP 神经网络,将所规划区域内含有充电设施网格的各项预测指标作为神经网络训练的输入数据,将历史平均一天内 24 h 充电负荷作为神经网络的输出数据,训练生成预测指标与充电负荷之间的神经网络。该网络能够建立预测指标与充电负荷之间的联系,对充电负荷预测问题的非线性特性具有良好的自适应性。不含充电设施区域与训练用区域环境特征相近的前提下,所训练得到的网络可以用于不含充电设施区域的充电负荷预测。

最后,基于训练得到的神经网络对不含充电设施区域的电动汽车充电负荷进行预测。将不含充电设施网格的各项预测指标输入训练好的神经网络,即可输出不含充电设施网格的 24 h 充电负荷预测值。

由于在原历史充电负荷的基础上加入了不含充电设施网格的充电负荷,因此,应该将历史充电负荷按比例分配给所有网格,以保证充电负荷总量不变,即

$$C_{i,t}^p = \frac{C_{i,t}}{\sum_{i=1}^{m+k} C_{i,t}} C_t^{\text{total}}, \quad (9)$$

$$i = 1, 2, \dots, m + k, t = 1, 2, \dots, 24$$

$$C_t^{\text{total}} = \sum_{i=1}^m C_{i,t}^h \quad (10)$$

式(9)、(10)中 m 、 k 分别为规划区域内含充电设施网格的数量和不含充电设施网格的数量; $C_{i,t}$ 为神经网络预测得到的网格 i 在 t 小时的充电负荷预测值; C_t^{total} 为区域内所有网格在 t 小时的历史总充电负荷,即含有充电设施网格的历史总充电负荷; $C_{i,t}^h$ 为网格 i 在 t 小时的历史充电负荷; $C_{i,t}^p$ 为网格 i 在 t 小时的充电负荷,即所有网格内基于历史数据重新分配得到的充电负荷。

各网格一天内电动汽车总的电量需求为

$$E_i = \sum_{t=1}^{24} C_{i,t}^p \Delta t = \sum_{t=1}^{24} C_{i,t}^p \quad (11)$$

式中 E_i 为网格 i 一天总的充电量预测值; Δt 为电动汽车充电负荷预测的时间精度, $\Delta t = 1 \text{ h}$ 。

3 算例分析

选取北京市海淀区为预测区域进行算例分析,将海淀区按经纬坐标划分为 $1\ 000 \text{ m} \times 1\ 000 \text{ m}$ 的方格,其中,含有充电设施的网格有 52 个,不含充电设施的网格有 403 个。在网格划分的基础上,按照每个网格导入充电负荷、区域功能、交通流量数据。

电动汽车充电需求影响因素的相关性分析结果如表 2 所示,通过采用 SPSS11.0 数据统计软件中的单因素方差分析计算得到各控制变量与观测变量的相伴概率 P 值。其中控制变量包括各网格内的运营模式、区域功能、人口数量和交通流量历史数据,观测变量为各网格内的充电负荷历史数据。通过考察计算所得 P 值,如果小于等于 0.05,则判断该变量为充电电量显著影响因素。根据分析结果将对电动汽车充电需求有显著影响的区域功能、交通流量 2 个因素作为充电负荷预测模型的预测指标。

表 2 方差分析结果

| 因素名称 | 显著值 P | 显著程度 |
|------|---------|------|
| 区域功能 | 0.003 | 显著 |
| 交通流量 | 0.001 | 显著 |
| 运营模式 | 0.196 | 不显著 |
| 人口分布 | 0.549 | 不显著 |

根据以上分析,该模型最终抽取了 2 个预测指标,其中区域功能包括住宅区、商业区、办公区等 19 种用地类型,所以输入层节点数为 20。该模型的输出量是电动汽车 24 h 充电负荷,所以输出层节点数为 24。隐含层节点数通过试凑法确定为 12。网络结构如图 2 所示。




图 2 BP 神经网络

Figure 2 BP neural network diagram

利用 Matlab 搭建、训练粒子群优化的贝叶斯正则化 BP 神经网络,并用训练好的神经网络模型预测不含充电设施网格的电动汽车的 24 h 充电负荷。

由神经网络模型得到的充电负荷预测值与历史真实值的对比如图 3 所示。




图 3 神经网络模型预测值与真实值对比

Figure 3 The comparison of the predicted value of neural network mode and the historical real value

对网格 a、b、c 充电负荷真实值与预测值进行误差分析,如表 3 中所示,平均绝对百分比误差为 3.2%,充电负荷的预测值与真实值间误差较小,证明该电动汽车充电负荷预测模型能够较准确地预测电动汽车充电负荷的 24 h 分布。绝对偏差及绝对百分比误差计算方法为

$$A_d = \sum_{i=1}^{24} |A_i - F_i| \quad (12)$$

$$A_{pe} = 100 \sum_{i=1}^{24} \left| \frac{A_i - F_i}{A_i} \right| \quad (13)$$

式(12)、(13)中 A_i 为网格内充电负荷真实值; F_i 为网格内充电负荷预测值。

表 3 充电负荷 24 h 真实值与预测值误差分析

Table 3 Error analysis of 24-hour real value and predicted value of charging load

| 网格编号 | 绝对偏差 | 绝对百分比误差/% |
|-----------|-------|-----------|
| a | 2.12 | 2.96 |
| b | 7.61 | 2.10 |
| c | 34.19 | 4.39 |
| 平均绝对百分比误差 | — | 3.15 |

每个网格中电动汽车充电负荷 24 h 分布可以通过神经网络预测模型得到。在充电负荷 24 h 分布的基础上,可以得到每个网格一天内的充电负荷峰值和总充电电量。由预测模型得到的 3 个不含充电设施网格的 24 h 充电负荷分布如图 4 所示。各网格一天内的充电负荷峰值如图 5 所示,一天内的总充电电量如图 6 所示。




图 4 不含充电设施网格 24 h 充电负荷预测值

Figure 4 The predicted 24-hour charging load for blocks without charging facilities

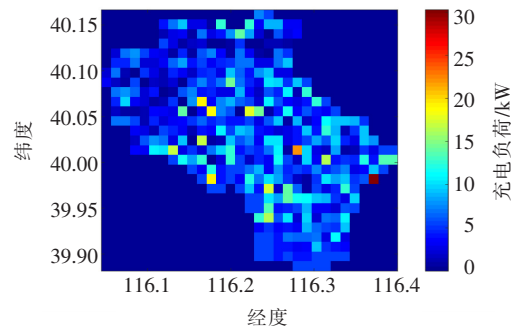


图 5 各网格一天内的充电负荷峰值

Figure 5 The peak charging load in one day for all blocks




图6 各网格一天内的总充电电量

Figure 6 The predicted total charging electricity in one day for all blocks

根据原有充电设施的历史充电数据得到的各网格一天内电动汽车总充电量热力图如图7所示。




图7 现有充电设施一天内总充电量

Figure 7 The total charging electricity of existing charging facilities in one day

由图7可见,由于现有充电设施数量有限,由充电交易记录得到的充电需求只存在少数网格中。从图6中可以看出,预测区域每个网格中都有充电需求,这是由于文中提出的电动汽车充电负荷预测方法能够将现有充电设施的充电负荷分配到所有网格中去,避免了由于充电设施数量有限且布局不合理而造成的历史充电数据无法正确体现电动汽车充电需求空间分布的问题,解决了传统基于充电设施历史充电数据的电力系统负荷预测法只能对现有充电设施的负荷进行预测的问题,实现了对所有区域的负荷预测。对比图6、7可知,图6中充电电量预测值量级明显小于图7中充电电量历史真实值,这是由于图7中的历史充电电量被分配给了所有网格,以保证总充电电量不变。

4 结语

考虑到现有充电设施数量有限且布局不够合理的问题,在将预测区域网格化的基础上,以网格为基

本单元建立电动汽车充电负荷预测模型,将包含充电设施网格的历史充电数据分配到每个网格,可展现实际充电负荷的空间分布。选取了北京市海淀区为例对预测方法进行验证分析,仿真结果表明,该预测方法能够较准确地对电动汽车充电负荷进行时空分布预测,在实际工程应用中可将所得到的不含充电设施网格内的充电负荷预测值与现有停车场地理坐标进行匹配,指导新建充电设施位置选址与定容。

参考文献:

- [1] 程杉,陈梓铭,徐康仪,等. 基于合作博弈与动态分时电价的电动汽车有序充放电方法[J]. 电力系统保护与控制,2020,48(21):15-21.
CHENG Shan, CHEN Ziming, XU Kangyi, et al. An orderly charging and discharging method for electric vehicles based on a cooperative game and dynamic time-of-use price [J]. Power System Protection and Control, 2020, 48(21): 15-21.
- [2] 张钰,张玥,韩新阳,等. 碳排放最小化条件下电动汽车有序充电策略研究[J]. 中国电力,2020,53(4):147-154.
ZHANG Jue, ZHANG Yue, HAN Xinyang, et al. Research on electric vehicle smart charging strategy on carbon emission minimization [J]. Electric Power, 2020, 53(4): 147-154.
- [3] 常小强,宋政湘,王建华. 基于蒙特卡罗算法的电动汽车充电负荷预测及系统开发[J]. 高压电器,2020,56(8):1-5.
CHANG Xiaoqiang, SONG Zhengxiang, WANG Jianhua. Electric vehicle charging load prediction and system development based on monte carlo algorithm [J]. High Voltage Apparatus, 2020, 56(8): 1-5.
- [4] 倪凯旋. 基于分布式博弈的电动汽车充电站最优调度方法[J]. 供用电,2020,37(2):79-84.
NI Kaixuan. Optimal scheduling of electric vehicle charging station based on distributed game [J]. Distribution & Utilization, 2020, 37(2): 79-84.
- [5] 余军伟,孙云莲,张笑迪. 考虑发展不均衡的电动汽车充电负荷预测[J]. 电测与仪表,2019,56(5):43-50.
YU Junwei, SUN Yunlian, ZHANG Xiaodi. Charging load forecasting considering the unbalanced development of EV [J]. Electrical Measurement & Instrumentation, 2019, 56(5): 43-50.
- [6] 范晋衡,刘琦颖,曲大鹏,等. 考虑电动汽车充电负荷的配电网运行风险控制与优化[J]. 电网与清洁能源,2020,36(9):105-112+121.
FAN Jinheng, LIU Qiyang, QU Dapeng, et al. Control and

- optimization of operation risk of distribution network considering electric vehicle charging load[J]. Power System and Clean Energy, 2020, 36(9): 105-112+121.
- [7] 钱科军, 刘乙, 张新松, 等. 考虑电动汽车充电负荷的配电系统场景概率潮流分析[J]. 电力系统保护与控制, 2020, 48(24): 62-70.
QIAN Kejun, LIU Yi, ZHANG Xinsong, et al. Scenario-based probabilistic power flow calculation of distribution systems with electric vehicle charging loads[J]. Power System Protection and Control, 2020, 48(24): 62-70.
- [8] Shan J, Lei W, Ning J, et al. Research on factors that influence the charging load of electric vehicles and modeling of the load[C]//2016 IEEE Advanced Information Management, Communicates, Electronic and Automation Control Conference (IMCEC), Xi'an, China; IEEE, 2016: 1412-1415.
- [9] Su S, Zhao H, Zhang H Z, et al. Forecast of electric vehicle charging demand based on traffic flow model and optimal path planning [C]//2017 19th International Conference on Intelligent System Application to Power Systems (ISAP), TX, USA; IEEE, 2017: 1-6.
- [10] 许威, 吕林, 许立雄, 等. 基于马尔可夫链的电动汽车充电需求计算[J]. 电力系统及其自动化学报, 2017, 29(3): 12-19.
XU Wei, LV Lin, XU Lixiong, et al. Calculation of charging demand from electric vehicles based on Markov chain[J]. Proceedings of the CSU-EPSA, 2017, 29(3): 12-19.
- [11] 张谦, 王众, 谭维玉, 等. 基于 MDP 随机路径模拟的电动汽车充电负荷时空分布预测[J]. 电力系统自动化, 2018, 42(20): 59-66.
ZHANG Qian, WANG Zhong, TAN Weiyu, et al. Spatial-temporal distribution prediction of charging load for electric vehicles based on MDP random path simulation[J]. Automation of Electric Power Systems, 2018, 42(20): 59-66.
- [12] 周国鹏, 傅军, 李雪梅, 等. 基于灰色模型的电动汽车充电需求预测研究[J]. 电气应用, 2017, 36(10): 83-87.
ZHOU Guopeng, FU Jun, LI Xuemei, et al. Research on electric vehicle charging demand prediction based on grey model[J]. Electrotechnical Application, 2017, 36(10): 83-87.
- [13] Xu X B, Liu W X, Zhou X, et al. Short-term load forecasting for the electric bus station based on GRA-DE-SVR[C]//2014 IEEE Innovative Smart Grid Technologies-Asia (ISGT ASIA), Kuala Lumpur, Malaysia; IEEE, 2014: 388-393.
- [14] Wang S J, Xue G B, Chang P, et al. The application of forecasting algorithms on electric vehicle power load [C]//2018 IEEE International Conference on Mechatronics and Automation (ICMA), Changchun, China; IEEE, 2018: 1371-1375.
- [15] 杨海深, 傅红卓. 基于贝叶斯正则化 BP 神经网络的股票指数预测[J]. 科学技术与工程, 2009, 9(12): 3306-3310.
YANG Haishen, FU Hongzhuo. Stock index forecast based on Bayesian regularization BP neural network [J]. Science Technology and Engineering, 2009, 9(12): 3306-3310.
- [16] 李元诚, 白恺, 曲洪达, 等. 基于粒子群-稀疏贝叶斯混合算法的光伏功率预测方法[J]. 太阳能学报, 2016, 37(5): 1153-1159.
LI Yuancheng, BAI Kai, QU Hongda, et al. A photovoltaic power forecasting model using sparse Bayesian regression optimized by particle swarm algorithm [J]. Acta Energeticae Solaris Sinica, 2016, 37(5): 1153-1159.
- [17] 单莹. 通化市停车需求预测研究[D]. 长春: 吉林大学, 2017.
- [18] 赵堃, 李晓婷, 李远卓, 等. 考虑电动汽车充电需求的城市配电网负荷预测[J]. 华北电力技术, 2017(11): 1-5.
ZHAO Kun, LI Xiaoting, LI Zhuoyuan, et al. Urban distribution network load forecasting considering electric vehicle charging demand[J]. North China Electric Power, 2017(11): 1-5.
- [19] 苏小林, 张艳娟, 武中, 等. 规模化电动汽车充电负荷的预测及其对电网的影响[J]. 现代电力, 2018, 35(1): 45-54.
SU Xiaolin, ZHANG Yanjuan, WU Zhong, et al. Forecasting the charging load of large-scale electric vehicle and its impact on the power grid[J]. Modern Electric Power, 2018, 35(1): 45-54.
- [20] 王衡. 探讨电动汽车充电设施规划方式[J]. 军民两用技术与产品, 2017(10): 36-37.
WANG Heng. Discussion on electric vehicle charging facility planning[J]. Dual Use Technology & Products, 2017(10): 36-37.
- [21] Funahashi K. On the approximate realization of continuous mappings by neural networks[J]. Neural Networks, 1989, 2(3): 183-192.
- [22] 黄宇鹏, 李立新, 王磊, 等. 基于神经网络的电网运行趋势估计算法及应用[J]. 智慧电力, 2019, 47(6): 113-120.
HUANG Yupeng, LI Lixin, WANG Lei, et al. Power network operation trend estimation algorithm based on neural network and its application[J]. Smart Power, 2019, 47(6): 113-120.