

引用格式: 庞松岭, 赵雨楠, 唐金锐, 等. 基于充电桩利用率的充电负荷超短期预测方法研究[J]. 电力科学与技术学报, 2024, 39(1): 115-123.

Citation: PANG Songling, ZHAO Yunan, TANG Jinrui, et al. A novel ultra short-term charging load forecasting method based on usage degree of charging piles[J]. Journal of Electric Power Science and Technology, 2024, 39(1): 115-123.

基于充电桩利用率的充电负荷 超短期预测方法研究

庞松岭^{1,2}, 赵雨楠^{1,2}, 唐金锐³, 彭勇⁴, 田金银³, 葛千衡³

(1. 智能电网与海岛微网联合实验室, 海南海口 570226; 2. 海南电网有限责任公司电力科学研究院, 海南海口 570226; 3. 武汉理工大学自动化学院, 湖北武汉 430070; 4. 中国电力工程顾问集团中南电力设计院有限公司, 湖北武汉 430071)

摘要: 为消除空间分布不确定性对电动汽车充电负荷超短期预测准确性的影响, 提出一种基于充电桩利用率的电动汽车充电负荷超短期预测方法。首先, 从海量充电交易数据中提取形成区域内各充电桩充电负荷功率, 编码后得到充电桩利用率的量化值; 然后, 将充电桩利用率以及充电负荷功率数据融合, 得到长短期记忆神经网络的训练样本和测试集, 形成电动汽车充电负荷超短期预测的深度学习模型, 时间分辨率可达 0.5 h; 最后, 在不同规模充电负荷的场景下验证了所提方法的有效性和准确性。结果表明, 相比无优化的长短期记忆神经网络负荷预测方法, 所提方法得到的预测值平均绝对百分比误差提高了约 5%, 可为未来车网互动下的配电网调度优化运行提供重要支撑。

关键词: 电动汽车; 充电桩; 充电负荷; 长短期记忆神经网络; 负荷预测

DOI: 10.19781/j.issn.1673-9140.2024.01.011 中图分类号: TM863 文章编号: 1673-9140(2024)01-0115-09

A novel ultra short-term charging load forecasting method based on usage degree of charging piles

PANG Songling^{1,2}, ZHAO Yunan^{1,2}, TANG Jinrui³, PENG Yong⁴, TIAN Jinyin³, GE Ganheng³

(1. Smart Grid and Island Microgrid Joint Laboratory, Haikou 570226, China; 2. Electric Power Research Institute of Hainan Power Grid Co., Ltd., Haikou 570226, China; 3. School of Automation, Wuhan University of Technology, Wuhan 430070, China; 4. Central Southern China Electric Power Design Institute Co., Ltd., China Power Engineering Consulting Group, Wuhan 430071, China)

Abstract: To eliminate the impact of spatial distribution uncertainty on the accuracy of ultra-short-term forecasting of electric vehicle charging load, a method based on the utilization rate of charging piles for electric vehicle charging load ultra-short-term forecasting is proposed. Firstly, the charging load power of each charging pile within the region is extracted from massive charging transaction data, and then quantified values of the utilization rate of charging piles are obtained through encoding. Then, the utilization rate of charging piles and charging load power data are merged to obtain training samples and test sets for long short-term memory (LSTM) neural networks, forming a deep learning model for ultra-short-term forecasting of electric vehicle charging load, with a time resolution of up to 0.5 h. Finally, the effectiveness and accuracy of the proposed method are validated in scenarios with different scales of charging load. The results indicate that compared to the unoptimized LSTM neural network load forecasting method, the proposed method achieves an increase in the average absolute percentage error of approximately 5%. This can provide significant support for the optimization operation of distribution grids under future vehicle-grid interaction.

Key words: electric vehicle; charging pile; charging load; LSTM; load forecasting

收稿日期: 2023-04-22; 修回日期: 2023-06-07

基金项目: 中国南方电网有限责任公司科技项目(073000KK52220001)

通信作者: 唐金锐(1986—), 男, 博士, 副教授, 主要从事配电网规划、分析与保护技术等研究; E-mail: tangjinrui@whut.edu.cn

作为新能源汽车的主要形式之一,电动汽车(electric vehicle, EV)是绿色交通发展战略的关键一环,有助于提高城市运行智能化水平。海量电动汽车无序充电产生的负荷具有高度的时空不确定性,会显著增大配电网供电负荷的波动率,引起配电网局部地区设备过载、电压越限等问题^[1-8]。

为了降低充电负荷对配电网的冲击,提高配电网的安全稳定运行水平,需进行电动汽车需求响应调度,并通过采用电动汽车与电网互动(vehicle to grid, V2G)技术进一步提升配电网柔性调节能力^[9-13]。因此,开展电动汽车充电负荷超短期预测,实现未来数小时内的充电负荷功率预测,为车网互动调度运行策略提供重要支撑,正逐步得到学者的重视^[14-15]。电动汽车充电负荷超短期预测仍属于电力负荷预测研究范畴,大量学者已提出了多类电力负荷预测方法,这些方法可分为基于模型驱动^[16]和基于数据驱动^[17]两大类。

基于模型驱动的负荷预测方法试图建立电力负荷与外界影响因素的确定性线性或非线性的机理表达式,并根据该表达式计算得出负荷预测值,如典型的多元线性回归法和多元非线性回归法^[18-19]。此类方法多用于中长期电力负荷预测,效果较好。由于短期负荷的影响因素众多,实时性强,基于模型驱动的方法在处理短期和超短期电力负荷预测时面临模型构建复杂、自变量获取难等问题。

基于数据驱动的方法主要借助历史负荷数据序列来实现短期或超短期的负荷预测^[20],主要包括传统方法中的回归分析法、时间序列法、相似日法、指数平滑法、灰色预测法以及基于人工智能算法的负荷预测方法^[21],主要利用专家系统、支持向量机以及深度学习(人工神经网络、卷积神经网络和循环神经网络)等实现。在这些方法中,传统方法在省市系统级电力负荷的短期与超短期预测中,预测精度高,可满足工程需要,目前已得到广泛应用,但在波动性和随机性较强的工业园区电力负荷预测、居民用电负荷预测方面,因其无法挖掘历史用电负荷数据中的深层非线性关系,预测精度始终无法进一步提高。

基于人工智能方法的电力负荷短期预测具备可抽取复杂抽象特征的优越能力,可克服强随机性和高波动性负荷预测困难,已逐渐成为负荷预测的主要研究方法,是目前的研究热点。不同于支持向量机、极限学习机等人工智能方法^[22-23],深度学习技

术近年来快速发展,特别是长短期记忆神经网络(long short-term memory, LSTM)、门控循环单元网络(gated recurrent unit, GRU)等循环神经网络技术的发展,有效地解决了负荷序列长时间依赖、模型训练梯度消失和梯度爆炸问题,已成为当前处理强随机和高波动负荷预测的有力工具^[24-26]。

目前,已有学者将LSTM等深度学习技术引入到电动汽车充电负荷预测当中^[27-29],有效提高其预测精度。但与传统电力负荷仅存在时间上的强随机性和高波动性不同,电动汽车充电负荷还具有空间上的不确定性,其直接受出行规律、道路容量、车流量等因素的影响。因此,为解决此问题,文献[30]根据蒙特卡洛方法建立了各用途电动汽车的时空转移模型,根据电动汽车出行路径模拟来形成各充电站的充电负荷典型日曲线。为了考虑交通拥堵因素对充电负荷的影响,文献[31]由道路等级和各时段交通信息建立电动汽车的行驶速度期望值,并与电动汽车的电池荷电状态进行关联,据此形成了融合多源信息的考虑用户出行行为和充电需求的电动汽车充电负荷预测模型。因上述文献中出行规律模型的参数设置较为主观,文献[32]利用概率统计学和蒙特卡洛模拟方法,提出了基于时刻充电概率的电动汽车充电负荷预测方法。除了交通因素,文献[33-35]还将用户心理状态计入充电桩选择因素,开展了用户一路网一电网复杂交互机理下的电动汽车充电负荷预测。上述研究从机理分析出发,研究了电动汽车空间不确定性对充电负荷预测的影响,完善了电动汽车充电负荷预测理论体系,但由于交通起止点(origin-destination, OD)矩阵、出行规律等统计数据的获取目前较困难,暂时无法用于实际现场的电动汽车充电负荷超短期预测。

为此,在目前已形成的基于数据驱动的电动汽车超短期预测方法基础上,本文利用充电桩充电功率历史数据量化形成充电桩利用率指标,反映这些充电桩对电动汽车的空间吸引力;然后再将充电桩利用率与充电负荷历史数据相结合,形成基于LSTM的电动汽车充电负荷预测模型,最终完成电动汽车充电负荷的超短期预测。

1 充电桩利用率的概念与求取

电动汽车选择充电站的影响因素众多,包括充电站充电电价、充电站位置、充电站周边拥堵情况、

用户心理状态等。为量化这些因素对电动汽车充电负荷的影响,本文引入充电桩利用率概念,具体为区域内充电桩总实时充电负荷功率与其日最大充电负荷功率的比值。

实际现场中,区域内充电桩点多面广,与此同时,不同日最大充电负荷功率变化也会影响到充电桩利用率的计算,因此,本文提出如下具体步骤,实现充电桩利用率的求取。

1) 提取待分析区域内所有 e 个充电桩的充电负荷交易开始时间、结束时间、充电电量等数据,进行功率折算并计算得到历史 N 日的所有 e 个充电桩的充电负荷时间序列,将距离待预测日第 i 天的第 m 个充电桩在 t 时刻的充电负荷表示为 $P_{m,i,t}$ 。则待分析整个区域中距离待预测日第 i 天在 t 时刻的总充电负荷 $P_{i,t}$ 为

$$P_{i,t} = \sum_{m=1}^e P_{m,i,t} \quad (1)$$

式中, e 为待分析区域内所有充电桩的数量。

2) 利用具有噪声的密度聚类算法(density-based spatial clustering of applications with noise, DBSCAN),对待分析区域历史 N 日的充电负荷进行聚类分析,剔除属于离群子的历史日充电负荷曲线,则剩余的 N_a 日充电负荷代表了该区域充电负荷的规律模式,记为集合 R 。

3) 计算剔除规律异常日后的历史 N_a 日下各充电桩充电负荷的典型日负荷曲线,具体如下:

$$\bar{P}_{m,t} = \frac{1}{N_a} \sum_{k=1}^{N_a} P_{m,k,t}, k \in R \quad (2)$$

式中, $\bar{P}_{m,t}$ 为第 m 个充电桩历史 N_a 日在 t 时刻的充电负荷平均值; R 为剔除规律异常日后的历史日组合; $P_{m,k,t}$ 为距离待预测日第 k 天的第 m 个充电桩在 t 时刻的充电负荷。

4) 形成待分析区域内所有 e 个充电桩的典型日充电负荷矩阵 \bar{P} 为

$$\bar{P} = \begin{bmatrix} \bar{P}_{1,1} & \bar{P}_{1,2} & \cdots & \bar{P}_{1,w} \\ \bar{P}_{2,1} & \bar{P}_{2,2} & \cdots & \bar{P}_{2,w} \\ \vdots & \vdots & \ddots & \vdots \\ \bar{P}_{e,1} & \bar{P}_{e,2} & \cdots & \bar{P}_{e,w} \end{bmatrix} \quad (3)$$

式中, w 为日充电负荷全天 24 h 等间隔离散化后的总采样点数量,一般取 48,即采样间隔为 0.5 h; $\bar{P}_{x,1}$ 、 $\bar{P}_{x,2}$ 、 $\bar{P}_{x,w}$ 分别为第 x 个充电桩历史 N_a 日在第 1、2 个采样点和第 w 个采样点对应时刻上的充电负荷平均值, $x=1,2,\dots,e$ 。

5) 受充电负荷时空分布不确定性的影响,每个

充电桩的典型日负荷曲线波动范围大,易导致深度学习模型中特征权值更新优化方向的不均衡。因此,需对上述的典型日充电负荷矩阵 \bar{P} 进行归一化编码。

典型日充电负荷矩阵中的最大值 $\max(\bar{P}) = P_{\max}$,典型日充电负荷矩阵中的最小值 $\min(\bar{P}) = P_{\min}$ 。与此同时,分析表明充电负荷位于不同充电功率区间的充电桩数量差异较大,若在最大值和最小值之间进行线性化编码,将无法同时有效区分各充电桩在功率区间内的波动特性。因此,本文将日充电负荷功率划分为不同区间,然后针对每个划分区间进行单独线性编码。典型日充电负荷矩阵中的第 x 行第 k 列元素 $\bar{P}_{x,k}$ 可按以下方式进行编码:

$$m(\bar{P}_{x,k}) = \text{round}\left(\frac{\bar{P}_{x,k} - P_{\min}}{P_{\max} - P_{\min}} \cdot N_1\right) \quad (4)$$

$$C(\bar{P}_{x,k}) = \left[P_{\min} + \left(m(\bar{P}_{x,k}) + 0.5 \times \frac{P_{\max} - P_{\min}}{N_1} \right) \right] \cdot k + b \quad (5)$$

式(4)、(5)中, N_1 为日充电负荷功率最小值到最大值之间分割的区间数,应结合经验及功率分布情况进行划分; $\text{round}(x)$ 函数为对 x 进行向下取整; $m(\bar{P}_{x,k})$ 为充电功率 $\bar{P}_{x,k}$ 对应的所在区间; $C(\bar{P}_{x,k})$ 为 $\bar{P}_{x,k}$ 的编码值; k 、 b 分别为编码过程中对各区间线性化编码的系数;编码后,应保证全部区间每个充电负荷功率被编码为 1~100 的数值。

经过编码后,所有 e 个充电桩充电负荷的典型日平均负荷矩阵 \bar{P} 转换为编码矩阵 C_{en} 为

$$C_{\text{en}} = \begin{bmatrix} C(\bar{P}_{1,1}) & C(\bar{P}_{1,2}) & \cdots & C(\bar{P}_{1,w}) \\ C(\bar{P}_{2,1}) & C(\bar{P}_{2,2}) & \cdots & C(\bar{P}_{2,w}) \\ \vdots & \vdots & \ddots & \vdots \\ C(\bar{P}_{e,1}) & C(\bar{P}_{e,2}) & \cdots & C(\bar{P}_{e,w}) \end{bmatrix} \quad (6)$$

依据编码矩阵 C_{en} ,还可求出待分析区域电动汽车总充电负荷的等效编码矩阵 C_{all} ,作为整个区域电动汽车充电桩整体利用率的量化计算公式,具体如下:

$$C_{\text{all}} = [C_{\text{all}}(1) \quad C_{\text{all}}(2) \quad \cdots \quad C_{\text{all}}(w)] \quad (7)$$

式中, $C_{\text{all}}(1)$ 、 $C_{\text{all}}(2)$ 、 $C_{\text{all}}(w)$ 分别为整个待分析区域全天 24 h 中的第 1、2 个采样点和最后第 w 个采样点对应时刻的电动汽车充电桩整体利用率,其在第 i 个采样点的整体利用率为

$$C_{\text{all}}(i) = \sum_{j=1}^e C(\bar{P}_{j,i}) \quad (8)$$

式中, $C(\bar{P}_{j,i})$ 为典型日充电负荷矩阵中的第 j 行第 i 列元素。

通过上述步骤,可求得待分析区域每个充电桩日充电负荷的编码值,以及整个区域充电桩日充电负荷的整体等效编码值,据此可形成充电桩利用率的量化计算结果。

2 电动汽车充电负荷超短期预测模型

LSTM 是循环神经网络中的一种,在传统循环神经网络的基础上改良了内部结构,使其能够保持时间序列长距离的依赖关系,并有效避免梯度消失和梯度爆炸的情况。LSTM 单元的内部实现原理如图 1 所示。




图 1 LSTM 内部单元的实现原理

Figure 1 The implementation principle of LSTM internal units

图 1 所示的框内为传统神经网络的隐含层单元实现原理,不同于传统神经网络单元,LSTM 内部单元多输出了一个状态参数 $c(t)$,并将输出结果 $h(t)$ 和状态参数 $c(t)$ 循环送入该内部单元,与下一时刻数据 $x(t+1)$ 统一形成输入量;状态参数 $c(t)$ 位于图 1 的上半部分,是决定 LSTM 网络长期记忆的关键;sigmoid 函数与 tanh 函数的联合计算位于图 1 的下半部分,是决定 LSTM 网络短期记忆的关键。

激活函数一般采用 sigmoid 函数或者 tanh 函数, sigmoid 函数如下:

$$\text{sigmoid}(x) = \frac{1}{1 + \exp(-x)} \quad (9)$$

tanh 函数如下:

$$\text{tanh}(x) = \frac{\exp(x) - \exp(-x)}{\exp(x) + \exp(-x)} \quad (10)$$

本文选用历史充电负荷功率时间序列与上文求取的充电桩利用率编码值作为 LSTM 深度学习模型的输入变量,并构建合理的 LSTM 网络结构,建立电动汽车充电负荷超短期预测模型,如图 2 所示。

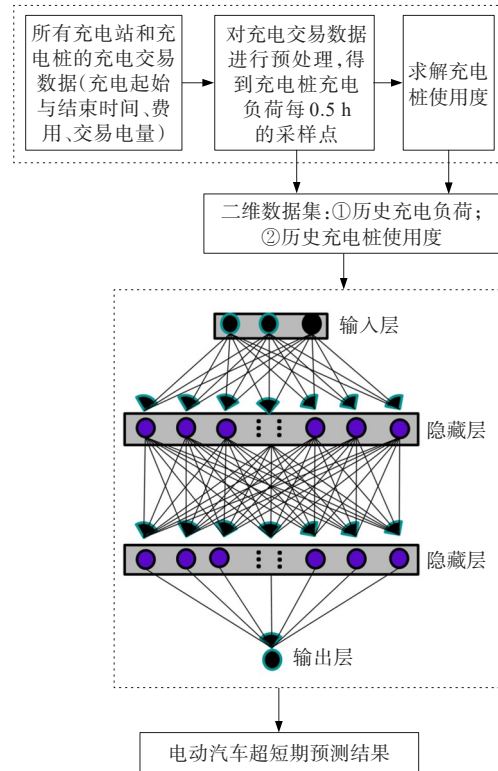


图 2 基于充电桩利用率的充电负荷超短期预测模型

Figure 2 Model of ultra-short-term forecasting of charging load based on charging pile utilization rate

由图 2 可知,开展电动汽车充电负荷超短期预测工作主要包括以下几点。

1) 获取所有充电站和充电桩的充电交易数据,包括充电起始与结束时间、充电交易费用、充电电量;据此,对充电交易数据进行预处理,得到充电桩充电负荷每 0.5 h 的采样点;根据求得的数据,可求解得出充电桩利用率。

2) 形成适用于电动汽车充电负荷超短期预测模型的二维输入数据集:历史充电负荷功率以及历史充电桩利用率编码值。

3) 根据 LSTM 模型时间步长要求,将历史数据转换为监督学习所需要的格式,并划分训练集和测试集。采用平均绝对百分比误差(mean absolute percentage error, MAPE)作为 LSTM 网络成本函数,以减小预测结果的 MAPE;使用 Adam 优化器进行优化训练;选取合适的 LSTM 学习率来控制模型的学习进度,避免过长的网络学习时间以及神经网络的不收敛。

根据真实充电站/充电桩的充电交易数据,其每一条交易数据包括充电起始时间、电量、费用、充电桩、所属充电站信息等。由于原始数据是交易订单格式,和传统的时间序列负荷数据格式有较大差

异,故采取如下具体的充电负荷数据预处理工作。

1) 将各充电交易订单按起止时间重新排为一列,用交易电量除以充电时间来表示该阶段的平均充电负荷功率。

2) 每天的充电交易订单起止时间比较随机,时间长度也不一致,不利于聚类分析和充电负荷预测研究,故需进行数据的插值补充。实际数据表明,存在较多持续时间为数分钟的临时充电行为,故充电数据插补时间尺度为 1 min。2 个充电交易订单之间的充电桩充电负荷功率插值为零,订单内的功率数据插补为固定值。

3 算例分析

收集了某城市由电网公司直接运营的所有充电站和充电桩的充电负荷交易数据,时间从 2018 年 1 月 1 日至 2021 年 12 月 31 日。整个充电交易数据约 200 万条,每条数据含 9 列数据,分别为月份、桩号、站名、电量、电费、服务费、交易金额、开始时间和结束时间。

为便于验证所提方法的有效性,选取该城市某行政区内的充电负荷进行分析与预测。

3.1 待分析区域充电负荷

通过对选定区域内充电负荷交易数据进行预处理,可得到该区域内的真实总充电负荷曲线。

图 3 给出了该区域总充电负荷在 2018 年 1 月的连续变化曲线。由图 3 可知,某区域电动汽车总充电负荷存在明显的以日为周期的变化规律。如图 4 所示,绘制了 31 d 的充电负荷日负荷曲线。可见,除了极个别日期内的日充电负荷曲线规律异常外,绝大部分日期内,充电负荷的高峰基本都出现在 09:00—10:00、13:00—17:00。不同日充电负荷具有很强的整体变化规律性。




图 3 某市行政区总充电负荷连续 31 d 功率曲线

Figure 3 The continuous 31 d power curves of the total charging load in a certain municipal administrative area




图 4 某市行政区总充电日负荷曲线

Figure 4 The daily charging load curves of the total charging load in a certain municipal administrative area

3.2 待分析区域充电桩利用率

运用 DBSCAN 算法对图 4 的日充电负荷进行聚类分析,聚类结果如图 5 所示。参数设置中,以日充电量的 10% 为扫描半径,以 2 为最小样本点数。




图 5 某市行政区总充电日负荷功率曲线聚类分析结果

Figure 5 The clustering analysis results of the daily charging load power curve of the total charging load in a certain municipal administrative area

图 5 中,虚线代表离群子,即不属于任何类。在 1 月,该地区电动汽车充电日负荷可聚为一类,仅有 1 月 5 日、6 日(虚线表示)的负荷不属于该类,即该地区电动汽车充电日负荷整体变化规律强。

剔除 1 月 5 日、6 日的负荷数据后,求取该地区 88 个充电桩的日平均充电负荷值,以 0.05 kW 为区间来划分充电负荷。可以发现,0~0.049 kW 的充电桩负荷值有 2 800 多个采样点,其原因是该区域充电桩存在大量闲置时间。负荷较小的区间负荷个数较多,而负荷较大的区间负荷个数较少。为合理量化充电桩各时刻的利用率指标,合并负荷值个数较小区间,调整后的该地区 1 月充电桩利用率的量化分析参数如表 1 所示。


不同区间的负荷编码值使用区间中值的倍数,从而表示出不同充电桩的日使用程度。

表1 某市行政区充电桩充电负荷区间分布和编码情况


Table 1 The distribution and encoding of charging pile charging load intervals in a certain municipal administrative area

充电负荷 区间	充电桩 数量/个	编码 值	充电负荷 区间	充电桩 数量/个	编码 值
0~0.049	2 873	1.0	0.450~0.949	209	14.5
0.050~0.149	333	2.5	0.950~1.699	222	27.0
0.150~0.249	191	4.5	1.700~7.699	240	94.5
0.250~0.449	156	7.5			

考虑充电负荷在节假日和工作日上的差异,筛选出节假日与工作日的充电桩充电负荷后再分别求取充电桩利用率编码值。图6给出了该区域所有充电桩平均用电负荷曲线分别在1月和10月对应的利用率整体等效编码值的日曲线。



(a) 1月



(b) 10月

图6 某市行政区总充电桩利用率

Figure 6 The total charging pile usage degrees in a certain municipal administrative area

对比图6(a)、(b)可以得出,1月中工作日的充电桩利用率比节假日高,而在10月,工作日和节假日的充电桩利用率相似,且利用率曲线有所差异的真实原因应该是电动汽车充电负荷空间分布受天气、出行规律、交通状况等因素影响。在1月和10月,13:00—17:00均为日充电桩利用率的峰值,但1月的另外一个利用率峰值在09:00—10:00,而10月另一个利用率峰值在00:00—02:00。

3.3 充电负荷超短期预测结果

对上述行政区总的充电负荷进行超短期预测。选用上述1月的历史充电负荷数据进行验证分析。采用该月前29 d的历史数据训练模型,最后2 d的数据用于验证预测结果。根据经验,设置LSTM预测模型为2层隐含层,每层隐含层含20个神经元,LSTM模型的学习率设置为0.1,迭代训练150次后可得到预测结果。

为对比验证本文所提方法的先进性,基准方法为仅将充电桩充电负荷历史数据作为输入变量,开展LSTM模型的训练以及后续充电负荷的超短期预测,后续命名为传统LSTM预测方法;本文所提方法则将充电桩利用率和充电桩充电负荷历史数据组成的二维数组送入LSTM模型中开展训练,并开展预测工作。

对于基于深度学习的负荷预测模型,受神经网络中参数初始过程的随机性影响,多次运行的预测结果会有所不同。为论证本文所提方法的有效性,对基础LSTM预测方法和本文所提方法均独立开展30次模型训练及充电负荷的超短期预测,图7为30次电动汽车充电负荷超短期预测结果的MAPE值。

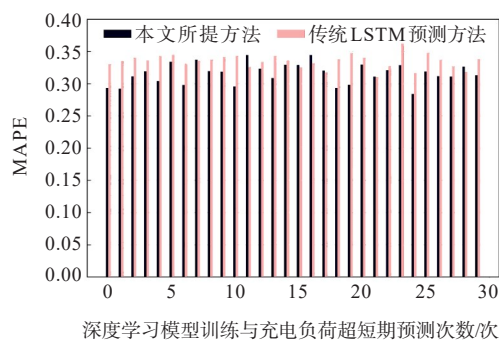


图7 某市行政区总充电负荷超短期预测误差

Figure 7 The ultra short-term forecasting errors of the total charging load in a certain municipal administrative area

从图7可以得出,30次深度学习模型训练与充电负荷超短期预测中,仅有6次传统LSTM预测方法的预测结果MAPE值小于本文方法,且二者非常接近,绝大多数情况下,本文所提方法的充电负荷超短期预测精度都要优于传统方法。

图8给出了30次充电负荷超短期预测结果的平均值。由图8可知,本文所提方法得到的电动汽车充电负荷超短期预测结果相比于传统LSTM预测方法的预测精度要高,本文所提方法的预测结果

MAPE 值为 28.9%,而传统 LSTM 预测方法所得结果的 MAPE 为 33.1%,预测精度提高了近 5%。




图 8 某市行政区总充电负荷超短期预测结果

Figure 8 The ultra short-term forecasting results of the total charging load in a certain municipal administrative area

上述分析结果是基于某城市某区域内所有充电桩交易数据验证得出,这些充电桩隶属于 10 个充电站,具有实际工程应用价值。该区域总充电负荷最大值仅为约 80 kW,波动性大,故预测结果的 MAPE 值较大。

为进一步论证本文所提方法对消除电动汽车空间分布不确定性对预测结果影响的有效性,将所提方法应用于该城市更大区域内的电动汽车充电负荷预测中,该区域内的总电站数量达到 69 个,总充电负荷最大值约为 140 kW,预测结果表明本文所提方法的预测结果 MAPE 值迅速下降到约 0.1,满足工程实际应用需求。

如表 2 所示,为进一步验证本文所提电动汽车充电负荷预测方法的有效性,将同样的方法应用在不同空间尺度区域内的 7 月、10 月电动汽车充电负荷超短期预测中,表 2 中给出了 1 月、7 月和 10 月的 30 次预测结果的 MAPE。

表 2 某市行政区充电桩充电负荷超短期预测结果误差

Table 2 The ultra short-term forecasting errors of the charging load in a certain municipal administrative area

区域	预测方法	MAPE		
		1 月	7 月	10 月
小区域(共 10 个充电站,约 100 km ²)	传统 LSTM 预测方法	0.331	0.316	0.353
	本文方法	0.289	0.253	0.299
大区域(共 69 个充电站,约 300 km ²)	传统 LSTM 预测方法	0.162	0.143	0.131
	本文方法	0.144	0.120	0.113

对于区域总充电负荷,分别对 1 月、7 月、10 月的最后 2 d 开展 30 次模型训练与超短期预测,多次预测结果的平均 MAPE 表明,对于 1 月、7 月和 10 月,在小区域内(共 10 个充电站,约 100 km²),本文所提方法的电动汽车超短期预测结果精度均比传统 LSTM 预测方法的精度提高了近 5%;在大区域内(共 69 个充电站,约 300 km²),本文所提方法的预测精度可提高近 2%。其原因是传统 LSTM 预测方法仅考虑了充电负荷在时间尺度上的内在规律与特征,而本文所提方法借助充电桩利用率将电动汽车空间分布特性进行了编码并纳入预测输入量中,一定程度上削弱了空间不确定性对预测精确度造成的负面影响。而区域越小,电动汽车临时选择该区域外进行充电的随机性越大,本文所提方法对提升充电负荷超短期预测精确度的效果越好。

4 结语

本文提出了一种基于充电桩利用率的电动汽车充电负荷超短期预测方法。提出并定义了区域充电桩利用率概念,将其与充电负荷历史数据进行有效融合,实现了考虑空间分布特性的电动汽车充电负荷超短期预测。相比传统基于深度学习算法的电动汽车负荷预测方法而言,所提方法计入了出行规律及交通状况等对区域充电负荷空间分布的影响。利用现场实际获取的充电数据进行分析验证,结果表明,以 MAPE 指标来看,所提方法相比传统深度学习预测方法所得的预测结果,精度提高了近 5%,可为配电网车网互动优化运行提供技术支撑。未来可在预测模型中引入新的影响因素,进一步提高充电负荷预测精度。

参考文献:

[1] 王靖添,马晓明. 中国交通运输碳排放影响因素研究——基于双层次计量模型分析[J]. 北京大学学报(自然科学版),2021,57(6):1133-1142.
WANG Jingtian, MA Xiaoming. Influencing factors of carbon emissions from transportation in China: empirical analysis based on two-level econometrics method[J]. Acta Scientiarum Naturalium Universitatis Pekinensis, 2021,57(6):1133-1142.

[2] 王海鑫,袁佳慧,陈哲,等. 智慧城市车一站一网一体化运行关键技术研究综述及展望[J]. 电工技术学报,2022, 37(1):112-132.
WANG Haixin, YUAN Jiahui, CHEN Zhe, et al. Review and prospect of key techniques for vehicle-station-

- network integrated operation in smart city[J]. Transactions of China Electrotechnical Society, 2022, 37(1):112-132.
- [3] 欧旭鹏,唐云,张凯,等.基于CEEMDAN-IDOA-BiLSTM的超短期风电功率预测[J].电网与清洁能源,2023,39(11):142-150.
OU Xupeng, TANG Yun, ZHANG Kai, et al. The ultra short term wind power prediction based on CEEMDAN-IDOA-BiLSTM[J]. Power System and Clean Energy, 2023, 39(11):142-150.
- [4] 雷旭,马鹏飞,宋智帅,等.计及风电预测误差的柔性负荷日内调度模型[J].发电技术,2022,43(3):485-491.
LEI Xu, MA Pengfei, SONG Zhishuai, et al. A flexible intraday load dispatch model considering wind power prediction errors[J]. Power Generation Technology, 2022, 43(3):485-491.
- [5] 彭鑫,刘俊,刘嘉诚,等.图像化数据驱动的电力系统暂态稳定性在线评估方法[J].智慧电力,2022,50(11):17-24.
PENG Xin, LIU Jun, LIU Jiacheng, et al. Graphical data-driven online assessment of power system transient stability[J]. Smart Power, 2022, 50(11):17-24.
- [6] 纪晓妍,方春华,游海鑫.基于多元非线性回归模型的220 kV电缆油终端缺陷场强预测[J].智慧电力,2023,51(8):96-103.
JI Xiaoyan, FANG Chunhua, YOU Haixin. Field strength prediction of 220 kV cable oil terminal defects based on multivariate nonlinear regression model[J]. Smart Power, 2023, 51(8):96-103.
- [7] 汪林光,谢小荣,贺静波,等.采用多元线性回归方法分析短路比对风电并网系统小干扰稳定性的影响[J].电力建设,2023,44(4):113-118.
WANG Linguang, XIE Xiaorong, HE Jingbo, et al. Multiple-linear-regression based analysis of the impact of short circuit ratio on small-disturbance stability of wind power grid-connection systems[J]. Electric Power Construction, 2023, 44(4):113-118.
- [8] 石立国,李延真,刘继彦,等.电动汽车充电站超短期充电负荷预测的改进GRU方法[J].供用电,2023,40(6):42-47.
SHI Liguang, LI Yanzhen, LIU Jiyan, et al. Improved GRU method for ultra-short-term charging load forecasting at electric vehicle charging stations[J]. Distribution & Utilization, 2023, 40(6):42-47.
- [9] 胡金迪,刘思,沈广,等.基于端对端通信的充电桩无功响应分布式模型预测控制策略[J].电力系统自动化,2022,46(4):25-35.
HU Jindi, LIU Si, SHEN Guang, et al. Distributed model predictive control strategy of reactive power response for charging piles based on peer-to-peer communication[J]. Automation of Electric Power Systems, 2022, 46(4):25-35.
- [10] 黄超,卜思齐,陈麒宇,等.元电力:新一代智能电网[J].发电技术,2022,43(2):287-304.
HUANG Chao, BU Siqi, CHEN Qiyu, et al. Meta-power: next-generation smart grid[J]. Power Generation Technology, 2022, 43(2):287-304.
- [11] 谭笑,陈杰,曹京荣,等.Logistic回归和支持向量机在电缆老化状态评估中的应用与比较[J].高压电器,2023,59(5):113-121.
TAN Xiao, CHEN Jie, CAO Jingying, et al. Application and comparison of logistic regression and support vector machine in condition assessment of cable aging condition [J]. High Voltage Apparatus, 2023, 59(5):113-121.
- [12] 赵阳,范文奕,安佳坤,等.基于智能加权混合模型的新型电力系统电量预测方法[J].电测与仪表,2022,59(12):56-63.
ZHAO Yang, FAN Wenyi, AN Jiakun, et al. A method of novel power system electricity forecasting based on intelligent weighted hybrid model[J]. Electrical Measurement & Instrumentation, 2022, 59(12):56-63.
- [13] 张美霞,叶睿琦,杨秀,等.基于多维状态空间MCMC充电负荷预测的充电站规划[J].电力科学与技术学报,2022,37(4):78-87.
ZHANG Meixia, YE Ruiqi, YANG Xiu, et al. Charging station planning for electric vehicle based on charging load forecast by MCMC method in multi-dimensional state space[J]. Journal of Electric Power Science and Technology, 2022, 37(4):78-87.
- [14] 牛牧童,廖凯,杨健维,等.考虑季节特性的多时间尺度电动汽车负荷预测模型[J].电力系统保护与控制,2022,50(5):74-85.
NIU Mutong, LIAO Kai, YANG Jianwei, et al. Multi-time-scale electric vehicle load forecasting model considering seasonal characteristics[J]. Power System Protection and Control, 2022, 50(5):74-85.
- [15] 曾亮,雷舒敏,王珊珊,等.基于OVMD-SSA-DELM-GM模型的超短期风电功率预测方法[J].电网技术,2021,45(12):4701-4710.
ZENG Liang, LEI Shumin, WANG Shanshan, et al. Ultra-short-term wind power prediction based on OVMD-SSA-DELM-GM model[J]. Power System Technology, 2021, 45(12):4701-4710.
- [16] 张秋桥,王冰,汪海珊,等.基于生长曲线与气温累积效应的气象负荷预测[J].现代电力,2021,38(2):171-177.
ZHANG Qiuqiao, WANG Bing, WANG Haishan, et al. Meteorological load forecasting based on growth curve and temperature accumulation effect[J]. Modern Electric Power, 2021, 38(2):171-177.
- [17] 朱继忠,董瀚江,李盛林,等.数据驱动的综合能源系统负荷预测综述[J].中国电机工程学报,2021,41(23):7905-7923.
ZHU Jizhong, DONG Hanjiang, LI Shenglin, et al. Review

- of data-driven load forecasting for integrated energy system [J]. Proceedings of the CSEE, 2021, 41(23): 7905-7923.
- [18] 刘文霞, 胡江, 吴方权, 等. 考虑温度—负荷相关性的调温负荷曲线拟合方法研究[J]. 电网与清洁能源, 2021, 37(4): 8-14.
LIU Wenxia, HU Jiang, WU Fangquan, et al. A study on the fitting method of temperature-adjusting load curve considering the temperature-load correlation[J]. Power System and Clean Energy, 2021, 37(4): 8-14.
- [19] 张红, 袁铁江, 谭捷. 统一能源系统氢负荷中长期预测[J]. 中国电机工程学报, 2021, 41(10): 3364-3372.
ZHANG Hong, YUAN Tiejiang, TAN Jie. Medium and long-term forecast of hydrogen load in unified energy system[J]. Proceedings of the CSEE, 2021, 41(10): 3364-3372.
- [20] 廖旒焕, 胡智宏, 马莹莹, 等. 电力系统短期负荷预测方法综述[J]. 电力系统保护与控制, 2011, 39(1): 147-152.
LIAO Nihuan, HU Zhihong, MA Yingying, et al. Review of the short-term load forecasting methods of electric power system[J]. Power System Protection and Control, 2011, 39(1): 147-152.
- [21] 韩富佳, 王晓辉, 乔骥, 等. 基于人工智能技术的新型电力系统负荷预测研究综述[J]. 中国电机工程学报, 2023, 43(22): 8569-8592.
HAN Fujia, WANG Xiaohui, QIAO Ji, et al. Review on artificial intelligence based load forecasting research for the new-type power system[J]. Proceedings of the CSEE, 2023, 43(22): 8569-8592.
- [22] 张淑清, 要俊波, 张立国, 等. 基于改进深度稀疏自编码器及FOA-ELM的电力负荷预测[J]. 仪器仪表学报, 2020, 41(4): 49-57.
ZHANG Shuqing, YAO Junbo, ZHANG Liguang, et al. Power load forecasting based on improved deep sparse auto-encoder and FOA-ELM[J]. Chinese Journal of Scientific Instrument, 2020, 41(4): 49-57.
- [23] 蔡舒平, 闫静, 刘国海, 等. 基于Fisher信息和在线SVR的智能电网气象敏感负荷预测动态建模技术[J]. 中国电机工程学报, 2020, 40(11): 3441-3451.
CAI Shuping, YAN Jing, LIU Guohai, et al. A dynamic modeling methodology based on Fisher information and on-line SVR for smart grids weather sensitive load forecasting[J]. Proceedings of the CSEE, 2020, 40(11): 3441-3451.
- [24] 陈振宇, 刘金波, 李晨, 等. 基于LSTM与XGBoost组合模型的超短期电力负荷预测[J]. 电网技术, 2020, 44(2): 614-620.
CHEN Zhenyu, LIU Jinbo, LI Chen, et al. Ultra short-term power load forecasting based on combined LSTM-XGBoost model[J]. Power System Technology, 2020, 44(2): 614-620.
- [25] 李玉志, 刘晓亮, 邢方方, 等. 基于Bi-LSTM和特征关联性分析的日尖峰负荷预测[J]. 电网技术, 2021, 45(7): 2719-2730.
LI Yuzhi, LIU Xiaoliang, XING Fangfang, et al. Daily peak load prediction based on correlation analysis and Bi-directional long short-term memory network[J]. Power System Technology, 2021, 45(7): 2719-2730.
- [26] 樊江川, 于昊正, 刘慧婷, 等. 基于多分支门控残差卷积神经网络的短期电力负荷预测[J]. 中国电力, 2022, 55(11): 155-162+174.
FAN Jiangchuan, YU Haozheng, LIU Huiting, et al. Short-term load forecasting based on multi-branch residual gated convolution neural network[J]. Electric Power, 2022, 55(11): 155-162+174.
- [27] 程杉, 赵子凯, 陈诺, 等. 计及耦合因素的电动汽车充电负荷时空分布预测[J]. 电力工程技术, 2022, 41(3): 194-201+208.
CHENG Shan, ZHAO Zikai, CHEN Nuo, et al. Prediction of temporal and spatial distribution of electric vehicle charging load considering coupling factors[J]. Electric Power Engineering Technology, 2022, 41(3): 194-201+208.
- [28] 裴振坤, 王学梅, 康龙云. 考虑用户充电计划的电动汽车辅助调频控制策略[J]. 电力工程技术, 2023, 42(1): 88-97.
PEI Zhenkun, WANG Xuemei, KANG Longyun. Auxiliary frequency regulation control strategy for electric vehicles considering users' charging plans[J]. Electric Power Engineering Technology, 2023, 42(1): 88-97.
- [29] 江里舟, 别朝红, 龙涛, 等. 能源交通一体化系统发展模式与运行关键技术[J]. 中国电机工程学报, 2022, 42(4): 1285-1301.
JIANG Lizhou, BIE Zhaohong, LONG Tao, et al. Development model and key technology of integrated energy and transportation system[J]. Proceedings of the CSEE, 2022, 42(4): 1285-1301.
- [30] 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 vehicle based on MDP random path simulation [J]. 2018, 42(20): 59-66.
- [31] 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, FIGUEIREDO Antonio. 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.

- 2022,55(9):38-45.
- [13] 冯小,张传林,崔承刚,等.基于 Stackelberg 博弈的孤岛式光储充电站调度优化[J].电网技术,2022,46(10):3989-4001.
FENG Xiao, ZHANG Chuanlin, CUI Chenggang, et al. Scheduling optimization of islanded electric vehicle charging station based on Stackelberg game[J]. Power System Technology, 2022, 46(10): 3989-4001.
- [14] 吴小汉,张谦,粟尧嘉,等.基于区块链的私有充电桩共享平台交易策略[J].发电技术,2022,43(3):439-451.
WU Xiaohan, ZHANG Qian, SU Yaojia, et al. Sharing platform trading strategy of private charging pile based on blockchain[J]. Power Generation Technology, 2022, 43(3): 439-451.
- [15] 祁晓笑,程静,王维庆,等.基于 SC 的光伏发电并网系统次同步振荡抑制方法[J].智慧电力,2023,51(5):88-95.
QI Xiaoxiao, CHENG Jing, WANG Weiqing, et al. Sub-synchronous oscillation suppression of photovoltaic grid-connected system based on SC[J]. Smart Power, 2023, 51(5): 88-95.
- [16] GHASEMIAN M, NAJAFIANASHRAFI Z, SEDAGHAT A. A review on computational fluid dynamic simulation techniques for Darrieus vertical axis wind turbines[J]. Energy Conversion and Management, 2017, 149: 87-100.
- [17] 于会群,蔡国顺,时珊珊,等.含规模化充电桩的微电网运行优化方法[J].电力系统及其自动化学报,2022,34(1):16-25.
YU Huiqun, CAI Guoshun, SHI Shanshan, et al. Operation optimization method of microgrid with large scale charging pile[J]. Proceedings of the CSU-EPSA, 2022, 34(1): 16-25.
- [18] 王晞,汪伟,王海燕,等.计及用户电池损耗的电动汽车分布式两阶段调度策略[J].电测与仪表,2022,59(1):120-126.
WANG Xi, WANG Wei, WANG Haiyan, et al. Distributed two-stage scheduling strategy of EV considering user battery consumption[J]. Electrical Measurement & Instrumentation, 2022, 59(1): 120-126.
- [19] 张夏韦,梁军,王要强,等.电动汽车充电负荷时空分布预测研究综述[J].电力建设,2023,44(12):161-173.
ZHANG Xiawei, LIANG Jun, WANG Yaoqiang, et al. Overview of research on spatiotemporal distribution prediction of electric vehicle charging[J]. Electric Power Construction, 2023, 44(12): 161-173.
- [20] 杨钰君,于艾清,丁丽青.基于停车需求的电动汽车移动储能多目标充放电协调控制[J].电力科学与技术学报,2022,37(4):65-77.
YANG Yujun, YU Aiqing, DING Liqing. Multi-objective coordinated control of charging and discharging for mobile energy storage of electric vehicles based on parking demand[J]. Journal of Electric Power Science and Technology, 2022, 37(4): 65-77.
- [21] 袁性忠,王辉,贾宏刚,等.基于储能型 APF 的微电网电能质量综合治理[J].高压电器,2022,58(8):238-244.
YUAN Xingzhong, WANG Hui, JIA Honggang, et al. Comprehensive power quality control for microgrid based on APF with energy storage[J]. High Voltage Apparatus, 2022, 58(8): 238-244.
- [22] 宋扬,石勇,刘宝泉,等.基于反向变异麻雀搜索算法的微电网优化调度[J].电力工程技术,2022,41(2):163-170.
SONG Yang, SHI Yong, LIU Baoquan, et al. Optimal dispatch of microgrid based on reverse mutation sparrow search algorithm[J]. Electric Power Engineering Technology, 2022, 41(2): 163-170.

(上接第 123 页 Continued from page 123)

- [32] 王浩林,张勇军,毛海鹏.基于时刻充电概率的电动汽车充电负荷预测方法[J].电力自动化设备,2019,39(3):207-213.
WANG Haolin, ZHANG Yongjun, MAO Haipeng. Charging load forecasting method based on instantaneous charging probability for electric vehicles [J]. Electric Power Automation Equipment, 2019, 39(3): 207-213.
- [33] 张美霞,孙铨杰,杨秀.考虑多源信息实时交互和用户后悔心理的电动汽车充电负荷预测[J].电网技术,2022,46(2):632-645.
ZHANG Meixia, SUN Quanjie, YANG Xiu. Electric vehicle charging load prediction considering multi-source information real-time interaction and user regret psychology[J]. Power System Technology, 2022, 46(2): 632-645.
- [34] 闫威,李南,沈月秀,等.基于 CNN-GAN 与半监督回归的电动汽车充电负荷预测[J].浙江电力,2023,42(2):83-89.
YAN Wei, LI Nan, SHEN Yuexiu, et al. Electric vehicle charging load forecasting based on CNN-GAN and semi-supervised regression[J]. Zhejiang Electric Power, 2023, 42(2): 83-89.
- [35] 赵厚翔,沈晓东,吕林,等.基于 GAN 的负荷数据修复及其在 EV 短期负荷预测中的应用[J].电力系统自动化,2021,45(16):143-151.
ZHAO Houxiang, SHEN Xiaodong, LÜ Lin, et al. Load data restoration based on generative adversarial network and its application in short-term load forecasting of electric vehicle[J]. 2021, 45(16): 143-151.