

# 基于多头注意力机制和门控循环单元神经网络的居民充电桩容量预测

谢 乐<sup>1\*</sup>, 杨 浙<sup>1</sup>, 刘 东<sup>2</sup>

(1. 国网浙江省电力有限公司 慈溪市供电公司,浙江 慈溪 315300;

2. 西南交通大学 电气工程学院,四川 成都 611756)

## Residential Charging Station Capacity Prediction Based on Multi-Head Attention and Gated Recurrent Unit Neural Network

XIE Le<sup>1\*</sup>, YANG Zhe<sup>1</sup>, LIU Dong<sup>2</sup>

(1. State Grid Cixi Power Supply, State Grid Zhejiang Electric Power Co., Ltd., Cixi 315300, China;

2. School of Electrical Engineering, Southwest Jiaotong University, Chengdu 611756, China)

**Abstract:** The capacity prediction of residential charging stations can provide a reference for its capacity selection and contribute to the carbon peaking and carbon neutrality goals. In this regard, a data-driven method for predicting the capacity of residential charging stations is proposed. Firstly, historical capacity data of residential charging stations are collected and preprocessed. Secondly, different-sized time windows are used to slice the data as input features. Finally, a prediction model combining multi-head attention mechanism and gated recurrent unit neural network is constructed, and the features are input into the model to achieve accurate prediction of future capacity. The results of the case analysis show that the exponential mean absolute error and exponential root mean square error of the model are 33.19 and 102.14% respectively. Compared to other models, the proposed model significantly improves the prediction accuracy and provides new insights for capacity prediction of residential charging stations.

**Key words:** data-driven; charging station; capacity prediction; multi-head attention mechanism; gated recurrent unit neural network

**摘要:** 居民充电桩的容量预测可为其定容选址提供参考,助力实现“双碳”目标,为此提出了一种基于数据驱动

**基金项目:** 国家自然科学联合基金(U1934204);四川省区域创新合作项目(21QYCX0096)

Joint Funds of the National Natural Science Foundation of China (U1934204); Sichuan Provincial Regional Innovation Cooperation Project (21QYCX0096)

的居民充电桩容量预测方法。首先,采集了居民充电桩的历史容量数据并进行预处理;其次,利用不同大小的时序窗口对其进行切片作为输入特征;最后,构建了结合多头注意力机制和门控循环单元神经网络的预测模型,将特征输入模型从而实现了对未来容量的精准预测。通过实例分析表明,该模型预测结果的平均绝对误差和均方根误差分别为 33.19 和 102.14%,预测精度相较于其他模型有较大提升,为居民充电桩的容量预测提供了新思路。

**关键词:** 数据驱动;充电桩;容量预测;多头注意力机制;门控循环单元神经网络

## 0 引言

为实现“碳达峰、碳中和”目标,大力开展电动汽车成为一条重要路径<sup>[1-2]</sup>。而充电桩作为电动汽车的基础配套设施,严重制约着电动汽车的发展。为了促进产业发展,国务院办公厅印发《关于加快电动汽车充电基础设施建设的指导意见》<sup>[3]</sup>。居民充电桩的容量预测研究对于充电桩选址定容、保障电网经济安全运行以及助力实现“双碳”目标具有重要意义。

目前国内外关于充电桩容量预测的研究主要集中在基于最优化理论的模型驱动方法<sup>[4-8]</sup>,即首先通过实际工程提取出数学模型,然后使用多种数学手段对该模型进行简化和处理,最后对简化后的模型利用相应的最优化算法进行求解。文献[4]考虑土地、交通、电网以及环境来构建评价指标,并建立充电桩容量预测模型。文献[5]以充

电站成本和用户经济损失最小为目标提出电动汽车充电站容量预测的数学模型,然后利用改进粒子群算法对该模型进行求解。文献[6]提出一种结合电动汽车充电负荷预测和充电需求系数来计算充电桩容量的预测方法。文献[7]利用变分不等式来描述电动汽车的均衡路径选择和充电行为,并通过邻域搜索策略求解优化问题,从而对充电桩的容量进行优化配置。文献[8]基于对规划区域电动汽车保有量的预测基础上,提出以综合总成本最小为目标的充电站容量预测模型。

然而,基于优化理论的模型驱动方法普遍存在着建模复杂、难以处理非线性和非平稳性问题以及缺乏对真实场景的适应性等缺点<sup>[9]</sup>。近些年来,随着人工智能技术的不断发展,基于数据驱动的方法逐渐被应用于各领域<sup>[10-14]</sup>。数据驱动原理是利用大量的历史实际运行数据作为学习样本,通过数据挖掘、机器学习和深度学习等人工智能技术构建系统输入数据和输出结果的映射关系。相比传统的模型驱动方法,数据驱动方法具有建模灵活、能有效处理非线性和非平稳性问题以及更加适应真实场景等优点<sup>[14-17]</sup>。

循环神经网络(Recurrent Neural Network, RNN)是一种用于时序数据预测的深度学习模型,其能够有效地处理序列数据,捕捉不同时间步序列的局部时间特征<sup>[18]</sup>。注意力机制是一种计算输入数据之间的时间关联信息和特征的方法,其参数量少,可以忽略时间间隔,并行地计算输入数据全局和局部之间的关联信息和特征,可以有效捕捉时序数据中的长期特征<sup>[19]</sup>。因此,结合RNN和注意力机制可以充分利用其各自优势,既能捕捉时序数据的局部时间特征,又能学习时序中的长期动态,从而提高模型整体的预测精度。

基于上述分析,本文提出了一种基于数据驱动的居民充电桩容量预测方法。其思路如下:首先采集居民充电桩历史容量数据进行预处理,并将预处理后的数据划分为训练集和测试集;其次构建结合多头注意力机制(Multi-Head Attention, MA)和门控循环单元(Gated Recurrent Unit, GRU)神经网络的深度学习预测模型;然后将训练集数据带入模型进行训练;最后将测试集数据带入训练后的模型进行预测。实例分析表明,相较于其他方法,本文所提方法的预测精准度更高,为居民充电桩选址定容提供了一定的参考。

## 1 基本理论

### 1.1 多头注意力机制

注意力机制是一种模仿人类视觉注意力的方法,其能使模型集中注意力于关键少数信息,从而提高模型的整体表现。多头注意力机制(MA)于2017年由谷歌团队提出,对序列自身通过计算注意力求取内部自相关权重,从而提高预测精度<sup>[20]</sup>。

图1为3个头的注意力得分计算过程,其中, $X$ 是时间步长为2,维度为3的输入序列; $W_n^Q$ 、 $W_n^K$ 和 $W_n^V$ 在本文中设置为全连接层,看作三个可学习的矩阵,分别用于生成 $Q_n$ 、 $K_n$ 和 $V_n$ 矩阵, $n$ 表示多头自注意力机制的头数。

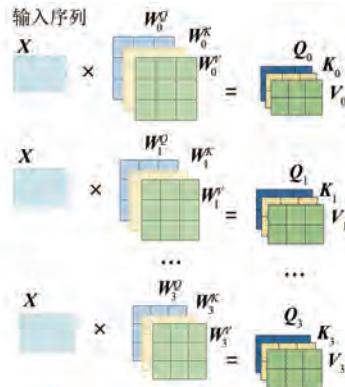


图1  $Q_n$ 、 $K_n$  和  $V_n$  矩阵生成过程

Fig.1 The process of generating  $Q_n$ ,  $K_n$  and  $V_n$  matrices

图2为attention-score矩阵的计算过程。图中 $K_n^T$ ( $n=0,1,\cdots,3$ )为矩阵 $K_n$ 的转置,对计算结果的每一行通过Softmax函数进行计算,获得数据之间关联度:

$$\text{Softmax}(z_i) = e^{z_i} / \sum_{j=1}^w e^{z_j} \quad (1)$$

式中: $z_i$ 和 $z_j$ 分别为图2中Softmax括号内矩阵某一行第*i*列和第*j*列数据值; $w$ 为矩阵列数。

将每个头计算出的 $S_n$ 矩阵按列拼接起来就得到了MA层的输出 $S$ 。

### 1.2 门控循环单元神经网络

GRU是RNN的一种结构,由Cho等人在2014年提出<sup>[21]</sup>。GRU的核心是门控机制,即通过重置门和更新门来控制信息的传递和遗忘,门

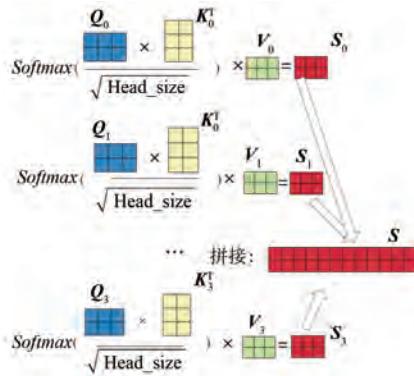


图 2 Attention-score 矩阵计算过程

Fig. 2 Generation process of attention-score

控机制使得 GRU 在处理时间序列数据时具有更好的表现。与传统的 RNN 和长短期记忆神经网络(Long Short-Term Memory, LSTM)相比,GRU 在处理序列数据时具有更好的预测精度和更快的训

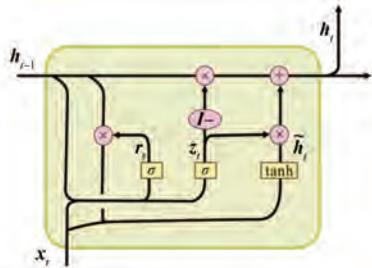


图 3 门控循环单元神经网络结构

Fig. 3 Structure of gated recurrent unit neural network

练速度。GRU 网络的基本结构如图 3 所示,数学描述如式(2)所示<sup>[22]</sup>:

$$\begin{cases} \mathbf{r}_t = \sigma(\mathbf{W}_r \cdot [\mathbf{h}_{t-1}, \mathbf{x}_t]) \\ \mathbf{z}_t = \sigma(\mathbf{W}_z \cdot [\mathbf{h}_{t-1}, \mathbf{x}_t]) \\ \tilde{\mathbf{h}}_t = \tanh(\mathbf{W}_h \cdot [\mathbf{r}_t \times \mathbf{h}_{t-1}, \mathbf{x}_t]) \\ \mathbf{h}_t = (\mathbf{I} - \mathbf{z}_t) \times \mathbf{h}_{t-1} + \mathbf{z}_t \times \tilde{\mathbf{h}}_t \\ \mathbf{y}_t = \sigma(\mathbf{W}_0 \cdot \mathbf{h}_t) \end{cases} \quad (2)$$

式中: $\sigma(\cdot)$ 为 sigmoid 激活函数; $\tanh(\cdot)$ 为 tanh 激活函数; $\mathbf{r}_t$ 为更新门的状态; $\mathbf{z}_t$ 为重置状态; $\tilde{\mathbf{h}}_t$ 为过程量; $\mathbf{h}_{t-1}$ 为上一时刻的状态记忆变量; $\mathbf{h}_t$ 为当前时刻的记忆状态变量; $\mathbf{x}_t$ 为当前时刻的输入量; $\mathbf{y}_t$ 为当前时刻的输出量; $\mathbf{W}_r$ 、 $\mathbf{W}_z$ 、 $\mathbf{W}_h$ 和 $\mathbf{W}_0$ 为训练所获得的权重参数; $\mathbf{I}$ 为单位矩阵。

## 2 整体预测模型

本研究基于数据驱动方法,提出了一种结合 MA 和 GRU 的充电桩容量预测模型,整体框架结构如图 4 所示。框架分为四个部分:数据采集与预处理、数据集构造、MA-GRU 预测模型以及模型验证。其中 MA-GRU 预测模型由输入层-GRU 层-MA 层-GRU 层-Dense 层-输出层构成,结合了 GRU 擅长捕捉序列的局部时间的特征以及 MA 擅长学习序列数据长期趋势的优势,从而提高模型的预测精度。

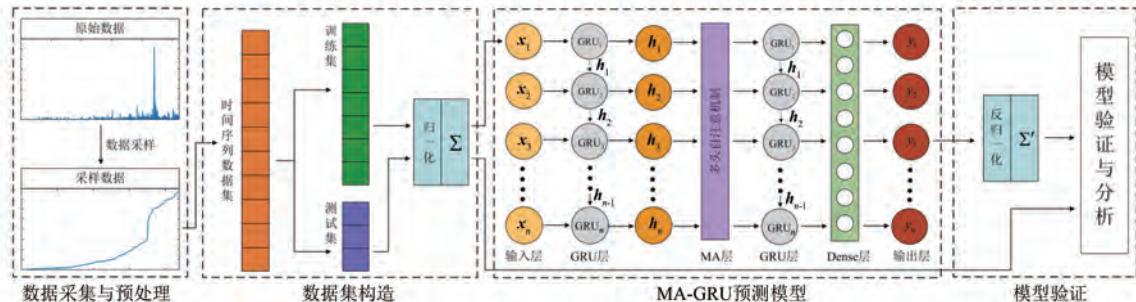


图 4 充电桩容量预测整体框架

Fig. 4 Overall framework for charging station capacity prediction

所提方法具体预测步骤如下:

- 1) 数据收集:采集每天新装充电桩的容量数据,并计算累计安装容量;
- 2) 数据采样:以 7 天为周期进行数据采样;
- 3) 划分训练集和测试集:将原始数据的前 70% 划分为训练集,后 30% 划分为测试集;

4) 数据归一化:将训练集和测试集归一化到 [0,1] 区间内;

5) 转换为时间序列:将训练集和测试集转换为时间窗口大小为 N 的序列作为特征输入,以及每个序列对应的结果输出;

6) 定义 MA-GRU 模型:构建结构为 GRU 层-

MA 层-GRU 层-Dense 层的预测模型;

7) 训练模型:将训练集带入 MA-GRU 模型进行训练;

8) 模型预测:将测试集带入训练好的模型进行测试,并输出预测结果;

9) 反归一化:将归一化的预测值和实际值转换回原始数值;

10) 评价模型:计算预测值和实际值的平均绝对误差(Mean Absolute Error, MAE)和均方根误差(Root Mean Square Error, RMSE),对模型进行评价。

### 3 算例分析

#### 3.1 数据选取与预处理

本研究数据来源为慈溪市某区域居民充电桩安装容量,选取的起止时间为 2018-8-7 至 2023-3-24,时间间隔为 1 天。该区域居民充电桩每日安装容量如图 5 所示。对图 5 中的充电桩安装容量随时间进行累加,然后再以 7 天为周期进行采样,共划分为 219 周,并对数据进行整合,最终得到充电桩累计安装容量随周数增长的曲线,如图 6 所示。

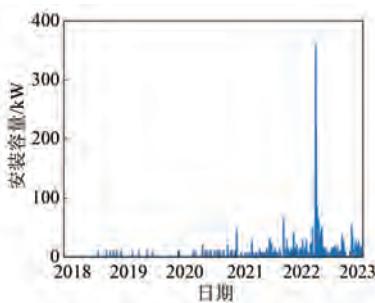


图 5 慈溪某区域充电桩安装容量

Fig. 5 Installed capacity of charging stations in a specific area of Cixi

根据式(3)将原始数据归一化到[0,1]区间内进行预处理:

$$X_{\text{norm}} = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (3)$$

式中: $X$  为原始数据; $X_{\max}$  为原始数据中的最大值; $X_{\min}$  为原始数据中的最小值; $X_{\text{norm}}$  为归一化后的值。

#### 3.2 模型评价指标

为了量化评价模型的预测性能,本研究采取

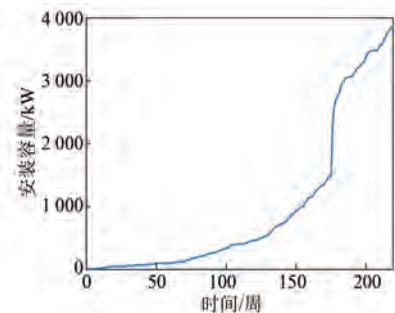


图 6 充电桩累计安装容量增长曲线

Fig. 6 Growth curve of accumulated installed capacity of charging stations

MAE 和 RMSE 作为模型评价指标,其值越小则表示模型预测精度越高,效果越好,MAE 和 RMSE 的数学表达式如下<sup>[23]</sup>:

$$e_{\text{MAE}} = \frac{1}{n} \sum_i^n |\hat{y}_i - y_i| \quad (4)$$

$$e_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_i^n (\hat{y}_i - y_i)^2} \times 100\% \quad (5)$$

式中: $e_{\text{MAE}}$  为平均绝对误差; $e_{\text{RMSE}}$  为均方根误差; $\hat{y}_i$  为预测值; $y_i$  为实际值; $n$  为预测验证数据的个数。

#### 3.3 模型预测结果

MA-GRU 模型基于 Python 语言和 TensorFlow 环境进行搭建,主要参数如下:GRU 层数为 350;激活函数选择“linear”;多头注意力机制中  $n=8$ ;全局参数中损失函数选择“mse”;梯度下降函数选择“adam”;迭代次数为 100。选取前 70% 周数据作为训练集,后 30% 周数据作为测试集。为了验证时间序列窗口大小的选取对模型预测结果的影响,分别选择时序窗口大小为 1~6 进行试验。最终模型预测结果如图 7(a)~(f) 所示,模型评价指标如图 8 所示。

从图 7 和图 8 可以看出:1)时序窗口分别选择为 1~6 时,MA-GRU 模型的预测值与真实值较为接近,偏差值较小,都能较好拟合真实值,从而验证了本研究模型的有效性和可靠性;2)随着时序窗口的不断增加, $e_{\text{MAE}}$  和  $e_{\text{RMSE}}$  也在不断增大,预测值也逐渐偏离真实值。综上可得,随着时间序列的增加,模型预测精度不断降低。

#### 3.4 对比分析

为进一步验证本研究所提模型的优越性,从

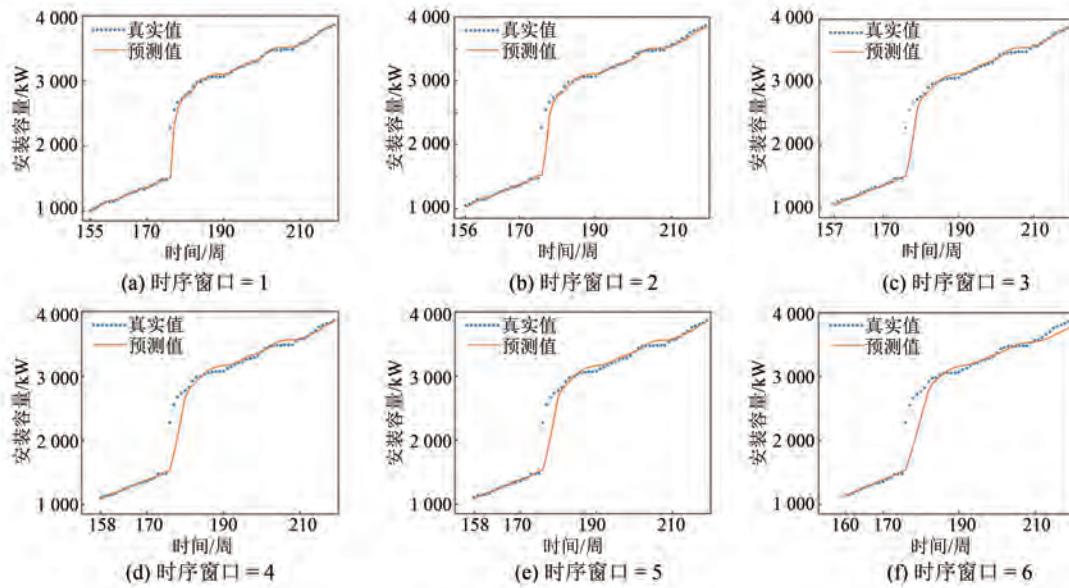


图 7 MA-GRU 模型预测结果

Fig. 7 Prediction results of the MA-GRU model

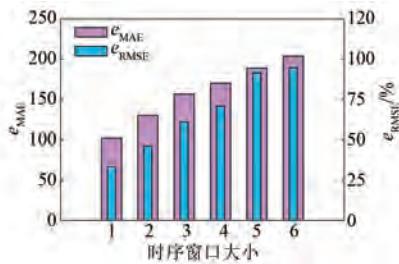


图 8 MA-GRU 模型评价指标

Fig. 8 Evaluation metrics of the MA-GRU model

以下两个维度进行对比:1)为验证所使用 GRU 模型的优越性,将 LSTM、RNN、反向传播神经(Back-Propagation, BP)和支持向量机(Support Vector Machine, SVM)预测模型与其进行对比;2)为验证 MA 机制在提升模型预测精度的有效性,分别将 MA-GRU、MA-LSTM、MA-RNN 预测模型与 GRU、LSTM、RNN 预测模型进行对比。上述 8 种预测模型的时序窗口大小分别选取 1~6,不同模型预测结果对比如图 9(a)~(f)所示,  $e_{MAE}$  评价指标对比如图 10 所示,  $e_{RMSE}$  评价指标对比如图 11 所示,整体评价指标对比如表 1 所示。

通过图 9 和表 1 分析可得:1)不同时序窗口大小下,GRU 模型的  $e_{MAE}$  和  $e_{RMSE}$  指标相较于其余 4 种模型均有所降低。以时序窗口 = 3 为例,GRU 模型相比于 LSTM、RNN、BP 和 SVM 模型,  $e_{MAE}$  指标分别降低 6.18%、14.08%、19.96% 和

69.31%,  $e_{RMSE}$  指标分别降低 1.61%、7.35%、24.12% 和 45.78%。可得本研究所选取的 GRU 模型比其他模型的预测精度更高,更具优越性。2)不同时序窗口大小下,加入 MA 机制的预测模型的  $e_{MAE}$  和  $e_{RMSE}$  指标比无 MA 机制的模型均有所降低。以时序窗口 = 3 为例,MA-GRU 比 GRU、MA-LSTM 比 LSTM、MA-RNN 比 RNN,  $e_{MAE}$  指标分别降低 26.03%、25.23% 和 19.97%,  $e_{RMSE}$  指标分别降低 9.58%、6.85% 和 12.47%。可得加入 MA 机制能提升模型的预测能力。3)纵向对比来看,随着时序窗口的增加,不同模型下的  $e_{MAE}$  和  $e_{RMSE}$  指标均逐渐增大,当时序窗口 = 1 时,不同模型下的预测精度均为最高,再一次验证了 3.3 节所得结论。

## 4 结语

- 1) 本研究提出了一种 MA 和 GRU 相结合的居民充电桩容量预测方法,并通过实例数据验证了所提方法的可靠性与优越性;
- 2) 通过对比分析表明,GRU 比其他模型的预测精度更高,且加入 MA 机制可进一步提升模型的预测精度;
- 3) 所提方法可为居民充电桩的容量预测提供新思路,为充电桩定容选址提供科学参考,助力实现“双碳”目标。

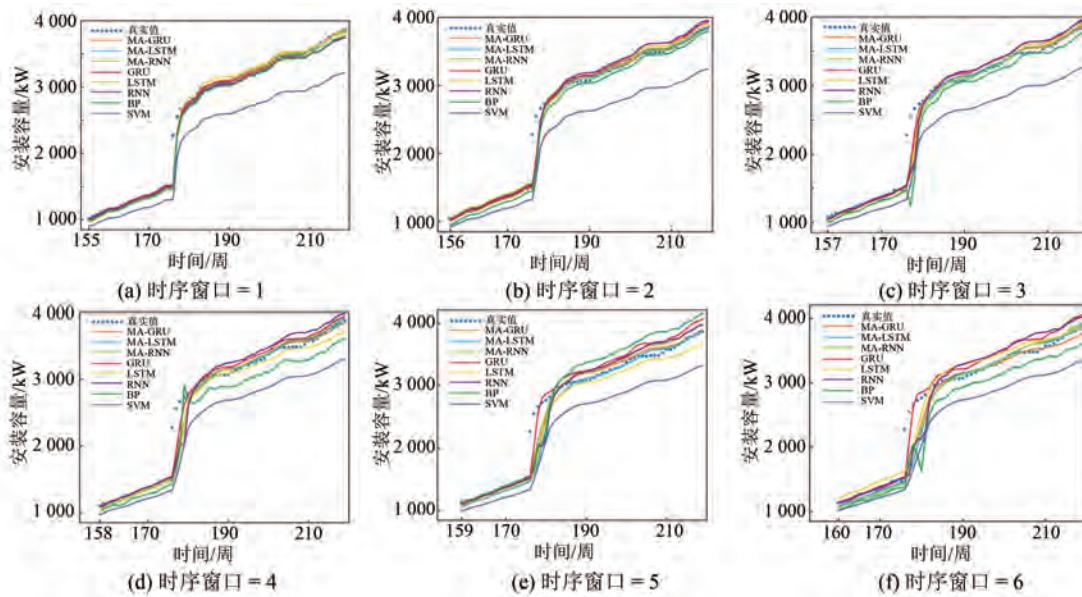


图 9 不同模型预测对比

Fig. 9 Comparison of predictions by different models

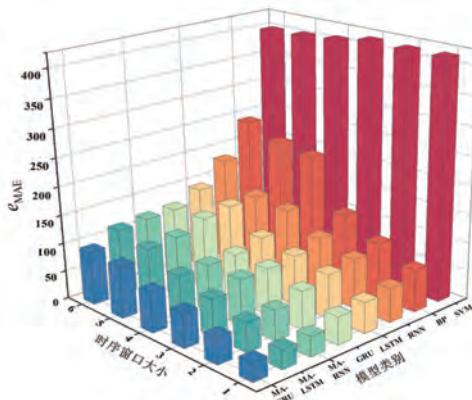
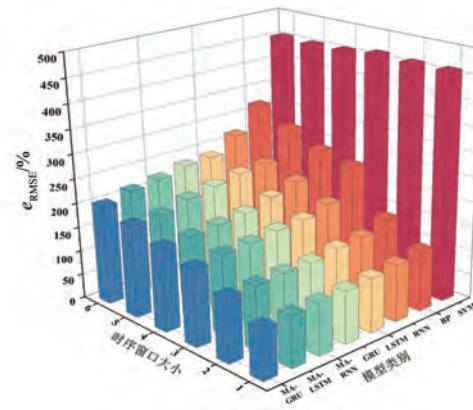
图 10 不同模型的  $e_{\text{MAE}}$  指标对比Fig. 10 Comparison of  $e_{\text{MAE}}$  metrics for different models图 11 不同模型的  $e_{\text{RMSE}}$  指标对比Fig. 11 Comparison of  $e_{\text{RMSE}}$  metrics for different models

表 1 不同模型预测评价指标对比

Tab. 1 Comparison of evaluation metrics for predictions by different models

时序窗口	评价指标	模型预测值							
		MA-GRU	MA-LSTM	MA-RNN	GRU	LSTM	RNN	BP	SVM
1	$e_{\text{MAE}}$	33.19	33.50	35.20	48.88	54.31	60.53	74.16	415.48
	$e_{\text{RMSE}}/\%$	102.14	103.43	105.71	107.10	110.37	116.28	125.08	460.38
2	$e_{\text{MAE}}$	46.19	51.64	53.18	67.22	78.28	87.08	98.65	414.57
	$e_{\text{RMSE}}/\%$	130.45	131.55	134.43	135.13	143.35	146.76	164.84	459.39
3	$e_{\text{MAE}}$	61.00	65.72	81.88	82.47	87.90	102.31	127.83	416.57
	$e_{\text{RMSE}}/\%$	156.76	164.12	166.46	173.36	176.19	190.17	250.62	462.23
4	$e_{\text{MAE}}$	70.88	81.35	82.22	84.17	98.13	131.36	213.94	406.61
	$e_{\text{RMSE}}/\%$	170.30	173.43	177.98	183.86	198.93	214.23	262.98	454.33
5	$e_{\text{MAE}}$	91.50	105.18	110.02	127.68	134.20	136.82	221.53	401.79
	$e_{\text{RMSE}}/\%$	189.05	192.22	206.44	216.53	225.87	229.39	288.77	452.24
6	$e_{\text{MAE}}$	94.63	116.83	121.44	123.43	144.84	184.13	243.20	399.48
	$e_{\text{RMSE}}/\%$	203.82	217.00	224.55	236.08	238.86	270.48	320.22	453.48

## 参考文献

- [ 1 ] 邢强, 陈中, 冷钊莹, 等. 基于实时交通信息的电动汽车路径规划和充电导航策略 [J]. 中国电机工程学报, 2020, 40(2): 534-550.  
XING Q, CHEN Z, LENG Z Y, et al. Route planning and charging navigation strategy for electric vehicles based on real-time traffic information [J]. Proceedings of the CSEE, 2020, 40(2): 534-550.
- [ 2 ] 刘洪, 阎峻, 葛少云, 等. 考虑多车交互影响的电动汽车与快充站动态响应 [J]. 中国电机工程学报, 2020, 40(20): 6455-6468.  
LIU H, YAN J, GE S Y, et al. Dynamic response of electric vehicle and fast charging stations considering multi-vehicle interaction [J]. Proceedings of the CSEE, 2020, 40(20): 6455-6468.
- [ 3 ] 钱进. 国务院发布《加快电动汽车充电基础设施建设的指导意见》[J]. 工程建设标准化, 2015, 10: 39-39.  
QIAN J. State council issues "guiding opinions on accelerating the construction of electric vehicle charging infrastructure" [J]. Standardization of Engineering Construction, 2015, 10: 39-39.
- [ 4 ] REN X Q, ZHANG H M, HU R H, et al. Location of electric vehicle charging stations: A perspective using the grey decision-making model [J]. Energy, 2019, 173: 548-553.
- [ 5 ] 严干贵, 刘华南, 韩凝晖, 等. 计及电动汽车时空分布状态的充电站选址定容优化方法 [J]. 中国电机工程学报, 2021, 41(18): 6271-6284.  
YAN G G, LIU H N, HAN N H, et al. An optimization method for location and capacity determination of charging stations considering spatial and temporal distribution of electric vehicles [J]. Proceedings of the CSEE, 2021, 41(18): 6271-6284.
- [ 6 ] 张娟, 杜欣慧. 电动汽车充电桩设施网合理规划研究 [J]. 计算机仿真, 2017, 34(10): 136-139.  
ZHANG J, DU X H. Study on reasonable planning of charging pile network of electric vehicle [J]. Computer Simulation, 2017, 34(10): 136-139.
- [ 7 ] WANG C Z, HE F, LIN X, et al. Designing locations and capacities for charging stations to support intercity travel of electric vehicles: An expanded network approach [J]. Transportation Research Part C: Emerging Technologies, 2019, 102: 210-232.
- [ 8 ] 于泉, 张浩楠, 刘芳亮, 等. 基于 EV 保有量预测的充电站选址规划 [J]. 交通世界, 2022, 28: 1-4.  
YU Q, ZHANG H N, LIU F L, et al. Charging station site planning based on EV ownership forecast [J]. Transpo World, 2022, 28: 1-4.
- [ 9 ] 范士雄, 李立新, 王松岩, 等. 人工智能技术在电网调控中的应用研究 [J]. 电网技术, 2020, 44(2): 401-411.  
FAN S X, LI L X, WANG S Y, et al. Application analysis and exploration of artificial intelligence technology in power grid dispatch and control [J]. Power System Technology, 2020, 44(2): 401-411.
- [ 10 ] 李兆飞. 数据驱动的轴承早期故障诊断技术综述 [J]. 机械传动, 2023, 47(3): 165-176.  
LI Z F. A survey of incipient fault diagnosis of bearings based on data-drive [J]. Journal of Mechanical Transmission, 2023, 47(3): 165-176.
- [ 11 ] 周广群. 基于数据驱动的船舶故障诊断技术综述 [J]. 船舶物资与市场, 2023, 31(1): 96-99.  
ZHOU G Q. A review of data-driven ship fault diagnosis based technologies [J]. Marine Equipment/Materials & Marketing, 2023, 31(1): 96-99.
- [ 12 ] 张亚超, 郑峰, 舒胜文, 等. 考虑多重不确定性的电-气-交通网络耦合系统数据驱动鲁棒优化调度 [J]. 中国电机工程学报, 2021, 41(13): 4450-4462.  
ZHANG Y C, ZHENG F, SHU S W, et al. A data-driven robust optimization scheduling of coupled electricity-gas-transportation systems considering multiple uncertainties [J]. Proceedings of the CSEE, 2021, 41(13): 4450-4462.
- [ 13 ] 王志杨, 张靖, 何宇, 等. 数据与模型混合驱动的区域综合能源系统双层优化调度决策方法 [J]. 电网技术, 2022, 46(10): 3797-3813.  
WANG Z Y, ZHANG J, HE Y, et al. Hybrid data-driven and model-driven bi-level optimal scheduling decision for regional integrated energy systems [J]. Power System Technology, 2022, 46(10): 3797-3813.
- [ 14 ] 侯慧, 朱韶华, 吴细秀, 等. 数据与模型驱动在输电杆塔风致灾损预测中的应用对比分析 [J]. 电网技术, 2023, 47(4): 1721-1728.  
HOU H, ZHU S H, WU X X, et al. Comparative

- analysis of data-driven method and model-driven method in wind-induced damage prediction of transmission towers [J]. Power System Technology, 2023, 47(4): 1721-1728.
- [15] 叶睿恺,王慧芳,张森,等. 数据驱动的含 IIDG 配电网短路电流计算多输出模型[J]. 电力自动化设备, 2022, 42(9): 119-125+132.  
YE R K, WANG H F, ZHANG S, et al. Data-driven multi-output model for short circuit current calculation in distribution network with IIDGs [J]. Electric Power Automation Equipment, 2022, 42(9): 119-125+132.
- [16] 刁晗,肖潭南,黄少伟,等. 数据驱动的电力系统关键断面筛选[J]. 电网技术, 2023, 47(10): 4035-4045.  
DIAO H, XIAO T N, HUANG S W, et al. Data-driven searching for power system key transmission sets [J]. Power System Technology, 2023, 47(10): 4035-4045.
- [17] 柳杰,苗宗成,王清云. 数据驱动的锂离子电池全生命周期状态参数评估[J]. 科学通报, 2023, 68(6): 644-655.  
LIU J, MIAO Z C, WANG Q Y. Data-driven full life-cycle state parameter assessment of Li-ion batteries [J]. Chinese Science Bulletin, 2023, 68(6): 644-655.
- [18] 王增平,赵兵,纪维佳,等. 基于GRU-NN模型的短期负荷预测方法[J]. 电力系统自动化, 2019, 43(5): 53-58.  
WANG Z P, ZHAO B, JI W J, et al. Short-term load forecasting method based on GRU-NN model [J]. Automation of Electric Power Systems, 2019, 43(5): 53-58.
- [19] 冯斌,张又文,唐昕,等. 基于BiLSTM-Attention神经网络的电力设备缺陷文本挖掘[J]. 中国电机工程学报, 2020, 40(增刊1): 1-10.  
FENG B, ZHANG Y W, TANG X, et al. Power equipment defect record text mining based on BiLSTM-Attention neural network [J]. Proceedings of the CSEE, 2020, 40(S1): 1-10.
- [20] 张振坤,张冬梅,李江,等. 基于多头自注意力机制的LSTM-MH-SA滑坡位移预测模型研究[J]. 岩土力学, 2022, 43(增刊2): 477-486+507.  
ZHANG Z K, ZHANG D M, LI J, et al. LSTM-MH-SA landslide displacement prediction model based on multi-head self-attention mechanism [J]. Rock and Soil Mechanics, 2022, 43(S2): 477-486+507.
- [21] DEY R, SALEM F M. Gate-variants of gated recurrent unit (GRU) neural networks [C] // 2017 IEEE 60th Midwest Symposium on Circuits and Systems (MWSCAS), Boston, 2017.
- [22] 谢乐,仇炜,李振伟,等. 基于变分模态分解和门控循环单元神经网络的变压器油中溶解气体预测模型[J]. 高电压技术, 2022, 48(2): 653-660.  
XIE L, QIU W, LI Z W, et al. Prediction model of dissolved gas in transformer oil based on variational modal decomposition and recurrent neural network with gated recurrent unit [J]. High Voltage Engineering, 2022, 48(2): 653-660.
- [23] 王萍,范凌峰,程泽. 基于健康特征参数的锂离子电池SOH和RUL联合估计方法[J]. 中国电机工程学报, 2022, 42(4): 1523-1534.  
WANG P, FAN L F, CHENG Z. A joint state of health and remaining useful life estimation approach for lithium-ion batteries based on health factor parameter [J]. Proceedings of the CSEE, 2022, 42(4): 1523-1534.

收稿日期:2023-10-31

收到修改稿日期:2023-12-15

作者简介:

谢乐(1997-),男,硕士,助理工程师,研究方向为基于人工智能的电力设备的故障预测与健康管理(PHM),leohfut@126.com。

\*通信作者:谢乐(1997-),男,硕士,助理工程师,研究方向为基于人工智能的电力设备的故障预测与健康管理(PHM),leohfut@126.com。

# Residential Charging Station Capacity Prediction Based on Multi-Head Attention and Gated Recurrent Unit Neural Network

XIE Le<sup>1\*</sup>, YANG Zhe<sup>1</sup>, LIU Dong<sup>2</sup>

(1. State Grid Cixi Power Supply, State Grid Zhejiang Electric Power Co., Ltd., Cixi 315300, China;

2. School of Electrical Engineering, Southwest Jiaotong University, Chengdu 611756, China)

**Key words:** data-driven; charging station; capacity prediction; multi-head attention mechanism; gated recurrent unit neural network

The global push for carbon peaking and carbon neutrality has elevated the importance of electric vehicles (EVs) in our pursuit of sustainable transportation solutions. However, the widespread adoption of electric vehicles is contingent upon the development of an efficient charging infrastructure, with residential charging stations playing a pivotal role. Recognizing the impediment to EV proliferation posed by inadequate charging infrastructure, the State Council issued comprehensive guidelines to expedite the construction of electric vehicle charging infrastructure, underscoring the strategic importance of this endeavor. In light of this, the accurate prediction of residential charging station capacity emerges as a critical aspect, influencing optimal site selection, and ensuring the economic security of the power grid.

Traditional research avenues have predominantly explored model-driven methods based on optimization theories. These approaches, while insightful, grapple with challenges such as modeling complexity, non-linear dynamics, and limited adaptability to the dynamic and diverse real-world scenarios inherent in the field of charging station infrastructure. Recent years have witnessed a paradigm shift towards embracing data-driven methodologies, leveraging artificial intelligence to overcome the limitations of traditional models.

This study represents a pioneering effort in proposing a data-driven approach for predicting the capacity of residential charging stations, integrating cutting-edge technologies such as multi-head attention (MA) mechanisms and gated recurrent unit (GRU) neural networks. This approach offers distinct

advantages over traditional model-driven methods, including enhanced flexibility in modeling, the ability to effectively handle non-linear and non-stationary dynamics, and increased adaptability to the complex and dynamic nature of real-world scenarios.

The steps to implement the proposed methodology are as follows: initially, historical capacity data for residential charging stations are systematically collected and subjected to rigorous preprocessing. Then, the dataset is intelligently divided into training and testing sets, ensuring a balanced representation of diverse operational scenarios. Following this, a sophisticated deep learning model is constructed, integrating MA mechanisms and GRU neural networks. This fusion of technologies allows the model to capture both local temporal features and long-term dynamics in time-series data, offering a holistic approach to predicting charging station capacity. The model is trained using the historical dataset, fine-tuning its parameters to achieve optimal predictive performance. Finally, the model is put to the test using the dedicated testing set, evaluating its ability to accurately forecast residential charging station capacity in real-world scenarios.

The results of the case analysis show that the superior predictive accuracy of the proposed methodology when compared to traditional model-driven methodologies. The incorporation of MA mechanisms and GRU neural networks allows the model to recognize intricate patterns in the historical data and providing more nuanced insights into the future capacity requirements of residential charging stations.