

基于堆叠异构空间图网络的电动汽车充电负荷预测

李璐¹, 王文龙¹, 刘楠¹, 杨威¹, 张佳夫¹, 王宇蛟²

(1. 国网辽宁省电力有限公司阜新供电公司, 辽宁 阜新 123000; 2. 沈阳工程学院, 沈阳 110136)

摘要: 随着电动汽车渗透率的不断提高, 充电设施和充电负荷将成为城市电网发展的关键增长点。准确预测电动汽车集中充电负荷的空间分布和时间变化对于确保城市电网的安全稳定运行至关重要。为此, 提出了基于堆叠异构时空图网络 (stacked heterogeneous spatio-temporal graph network, SHSGN) 模型的电动汽车充电负荷预测方法, 通过建模城市充电负荷的空间分布模式和用户多样化的充电方式, 提升电动汽车负荷的预测精度, 建立了表征充电站层级和区域层级负荷节点的双层异构图神经网络模型, 通过强化表征充电负荷特征的跨区域负荷转移模式, 提高挖掘负荷空间特征的能力, 建立了多 GRU 并行解码神经网络模型, 通过独立的解码任务准确表达每个充电站节点的差异化充电模式。以中国某城市的实际充电负荷数据为算例验证的结果表明, 所提出的方法将充电负荷预测误差降至 6.77%, 相比传统方法提高了 2.12%。

关键词: 电动汽车; 充电负荷预测; 时空图神经网络; 人工智能

DOI: 10.19753/j.issn1001-1390.2026.09.008

中图分类号: TM933

文献标识码: B

文章编号: 1001-1390(2026)09-0077-10

Electric vehicle charging load prediction based on stacked heterogeneous spatial graph network

Li Lu¹, Wang Wenlong¹, Liu Nan¹, Yang Wei¹, Zhang Jiafu¹, Wang Yujiao²

(1. Fuxin Power Supply Company, State Grid Liaoning Electric Power Co., Ltd., Fuxin 123000, Liaoning, China. 2. Shenyang Institute of Engineering, Shenyang 110136, China)

Abstract: With the increasing penetration of electric vehicles, charging facilities and load will become key growth areas for urban power grid development. Accurately forecasting the spatial distribution and temporal variation of electric vehicle charging load is crucial for ensuring the safe and stable operation of urban power grids. To address this, a forecasting method based on the stacked heterogeneous spatio-temporal graph network (SHSGN) model is proposed. This method improves the accuracy of electric vehicle load predictions by modeling the spatial distribution patterns of urban charging loads and the diverse charging behaviors of users. A two-layer heterogeneous graph neural network model is established to represent the charging station-level and regional-level load nodes. By enhancing the cross-regional load transfer patterns, this model improves the ability to capture spatial load characteristics. A multi-GRU parallel decoding neural network model is developed to accurately express the differentiated charging patterns of each charging station node through independent decoding tasks. Validation using real charging load data from a Chinese city demonstrates that the proposed method reduces the charging load prediction error to 6.77%, achieving a 2.12% improvement over traditional methods.

Keywords: electric vehicle, charging load prediction, spatiotemporal graph neural network, artificial intelligence

0 引言

随着全球环保意识的不断提升和能源结构的转型升级, 电动汽车作为绿色交通的重要代表, 其市场渗透率逐年攀升^[1-2]。在电动汽车日益普及的背景下, 为了保障城市电网的安全稳定运行, 我们

需要对电动汽车的充电需求有清晰的认识并进行准确预测^[3]。电动汽车集中充电负荷的空间分布与电网基础设施的布局和容量规划直接相关^[4]。在城市中心、商业区、住宅区等人口密集区域, 电动汽车的充电需求呈现出高峰时段集中、充电量大等特点, 这就要求电网具备足够的承载能力和调度能力。同时, 电动汽车充电负荷的时间变化也不容忽

基金项目: 国家电网公司科技资助项目 (2023YF-138)

视^[5]。由于电动汽车的充电行为受到用户出行习惯、电价政策、天气条件等多种因素的影响,电动汽车在一天、一周甚至一年内的充电负荷都会呈现出复杂的变化模式。因此,随着电动汽车的普及,充电设施和充电负荷将成为城市电网发展的关键要素。准确预测电动汽车的充电负荷对于优化电网调度、提高能源利用效率、降低电网运营成本具有重要意义。

目前,电动汽车充电负荷预测主要有三种方法^[6-8]:基于出行机理的预测方法、基于人工智能的数据驱动预测方法以及机理数据融合驱动的预测方法。

基于出行机理的预测方法主要依据交通流理论、出行者行为理论以及电动汽车的使用特性,通过建立数学模型来预测电动汽车的充电负荷^[9]。通常,这类模型会综合考虑行驶距离、行驶时间、车型、电池性能等多种因素,并结合历史数据和实时数据来预测电动汽车的充电需求。例如,文献[10]提出了一个活动出行与充电行为的链式模型,以模拟电动汽车的充电需求。该方法依次模拟了每个用户的出行链、每个目的地的充电选择及需求,从而实现了区域电动汽车充电需求的准确预测。文献[11]则考虑出行模式结构和充电基础设施的特点,提出了人们对不同类型电动汽车偏好的行为模型。文献[12]基于真实的城市街道网络模拟并建模了电动汽车的行驶轨迹,并准确预测了电动汽车的充电需求。基于出行机理的预测方法能够提供更为准确的预测结果,尤其是在车辆出行行为更为规律的情况下。然而,这类方法对复杂多变的交通状况和出行者行为的适应性较差,且模型建立和维护的成本较高。

随着大数据和人工智能技术的不断发展,基于人工智能的数据驱动预测方法在电动汽车充电负荷预测领域得到了广泛应用。这类方法通过收集和分析大量的历史数据和实时数据,利用机器学习、深度学习等算法训练模型,从而实现电动汽车充电负荷的预测^[13-14]。例如,文献[15]提出了一种基于改进决策树算法和时域卷积网络的混合动力汽车负荷预测方法。该方法首先利用梯度提升决策树(gradient boosting decision tree, GBDT)对电动

汽车充放电负荷数据集进行分类,然后利用时域卷积网络(time-domain convolutional networks, TCN)模型捕捉负荷的局部时间特征,探索时间序列变化的规律,从而准确预测电动汽车的充电负荷。文献[16]基于人工智能和机器学习分析了大量的电动汽车充电数据,并将环境因素作为输入,计算了不同环境下充电站的最优电力需求。文献[17]提出了一种数据驱动的出行链建模框架。该模型包括电动汽车使用模拟、电动汽车充电需求模拟、电动汽车负荷曲线生成等部分,实现了对电动汽车充电负荷的准确模拟。基于人工智能的数据驱动预测方法具有强大的适应性和鲁棒性,能够应对复杂多变的交通状况和出行者行为。然而,这类方法需要高质量且数量充足的数据,且模型的训练过程需要大量的计算资源^[18]。

机理数据融合驱动的预测方法结合了基于出行机理和人工智能数据驱动方法的优点^[19-20]。它通过整合交通流理论、出行者行为理论、电动汽车使用特性以及大数据和人工智能技术,实现了电动汽车充电负荷的预测。这类方法能够在保证预测精度的同时,提高模型的适应性和鲁棒性。机理数据融合驱动的预测方法还能够处理多源异构数据,充分利用各种信息资源。然而,这类方法的实施难度较大,需要出行、交通、移动轨迹等多方面数据才能实现全面地建模。

综上所述,现有的电动汽车充电负荷预测已经取得了显著进展。但面对分布越发密集的分布式充电站网络和充电规律,现有技术仍在数据基础和建模方法上存在改进空间。一方面,现有研究难以仅从充电站数据出发,建立复杂的充电负荷流向的空间关系,对区域性电站群的建模精度较低。其次,电动汽车的充电负荷受到多种因素的影响,站点间的负荷变化规律存在差异,使用单一模型来模拟电动汽车的出行行为的方法难以表征电动汽车的出行行为特点。

因此,从电动汽车充电负荷的时空特性出发,提出了基于堆叠异构时空图网络(stacked heterogeneous spatio-temporal graph network, SHSGN)的充电负荷预测方法,主要贡献如下:

首先,提出了表征充电站层级和区域层级负荷

节点负荷流向关系的双层异构图神经网络模型。通过强化表征充电负荷特征的跨区域负荷转移模式,提高挖掘负荷空间特性的能力。

然后,建立基于并行多门控循环单元(multi-gate recycling unit, GRU)的充电站节点负荷解码神经网络。通过独立的解码任务,实现对充电站节点差异化充电模式的准确表达。

最后,基于中国某城市电动汽车充电负荷的实际数据,验证了该方法的有效性。

1 材料与方法

1.1 模型总体描述

精确捕捉充电站与区域间的负荷转移模式,以及准确表达每个充电站节点的差异化充电模式,是提高电动汽车负荷预测准确性的关键。为此,本文提出了一种创新的双层异构图神经网络模型与并行 GRU 解码相结合的电动汽车充电负荷预测方法。模型结构与数据处理流程如图 1 所示。




图 1 电动汽车充电负荷预测模型框架

Fig. 1 Electric vehicle charging load prediction model framework

首先,双层异构图神经网络模型的构建基于图论与神经网络技术的结合。在充电桩层级,模型通过捕捉每个充电桩的充电负荷数据,形成节点级表示。这些节点不仅代表充电桩的物理位置,还包含诸如历史充电记录等详细信息。而在区域层级,模型将多个充电桩节点聚合成区域节点,通过考虑区域间的地理距离因素,揭示区域间的负荷转移模式。这种双层结构使模型能够捕捉局部和全局负荷特征,从而提高预测的准确性。

为了准确表达每个充电站节点的差异化充电模式,建立了多 GRU 并行解码神经网络模型。GRU

是一种常用的循环神经网络结构,能够有效处理序列数据中的时间依赖性。在此模型中,每个充电站节点对应一个独立的 GRU 解码器,它们并行工作且互不干扰。每个解码器基于其自身的输入(包括历史充电数据、当前状态等)和模型的内部状态,为对应的充电站生成充电负荷预测。这种方法确保了每个充电站节点的预测都是基于其独特特征和模式,从而提高了预测的准确性。

1.2 双层异构图神经网络模型

异构图神经网络结合了图神经网络(graph neural network, GNN)^[21-22]和异构数据的特性,能够捕捉节点间的异质性及其复杂关系,主要结构如图 2 所示。它包括底层图神经网络和顶层异构图神经网络。底层图神经网络主要用于提取和整合图数据的局部特征。通过聚合相邻节点的信息,底层可以为每个节点生成嵌入表示,这些表示能够反映图中节点的局部结构和属性。在此基础上,顶层异构图神经网络进一步整合这些特征,并考虑节点间的全局关系,最终生成更具表达力的全局嵌入表示。




图 2 异构图神经网络模型结构

Fig. 2 Heterogeneous graph neural network model structure

基于异构图架构,提出了表征电站级负荷变化和区域级负荷变化的双层异构图网络。首先,基于充电站之间的距离和交通连通性,我们建立了充电站节点之间的边关系,形成第一层图网络;然后基于行政区划,我们以每个行政区域的中心及其最小空间距离为中心建立连接图,作为第二层图网络;最后,将同一区域内的区域节点与每个充电站节点相连接,形成双层异构图神经网络结构图。

作为异构图的基本单元,GNN 基于邻域信息传播和聚合策略,通过整合相邻节点的信息来更新当前节点。通过堆叠层级,GNN 能够捕获各个邻域信息,有效融合图的拓扑结构信息。GNN 中定义的图

表示如式(1)所示:

$$G = (v, \varepsilon) \quad (1)$$

式中:每个节点 $v \in V$ 可表示以为向量 $\mathbf{X}_v$; ε 为图 2 中任意 2 个节点间的连接关系,如果图中节点或边的类型大于等于 2,则被视为异构图。

GNN 采用邻域聚合策略,聚合相邻节点的信息以获得新的表示,并将这些新的表示与目标节点的原始表示进行融合和更新。在堆叠层次图神经网络后,图上的任何节点都将融入其高阶邻域内的相邻节点信息和拓扑结构信息,如式(2)和式(3)所示:

$$a_v^k = \text{Aggregate}^k(\{h_v^{k-1}; u \in N(v)\}) \quad (2)$$

$$h_v^k = \text{Combine}^k(h_v^{k-1}, a_v^k), \quad h_v^0 = \mathbf{x}_v \quad (3)$$

式中: $\mathbf{x}_v$ 为节点的初始向量; $\mathbf{h}_v$ 为每个节点的学习向量; $\mathbf{h}_v^k$ 表示经过 k 次聚合操作后节点 v 的向量表示; $N(v)$ 表示节点 v 的邻居集合; Aggregate 表示聚合操作,即聚合相邻节点的信息,而 Combine 表示合并操作,即基于聚合后的向量表示与节点的原始表示进行融合。

同时,异构图神经网络使用基于注意力的机制对不同类型的节点和边进行加权,对于节点 i 和 j ,其注意力计算如式(4)所示:

$$\alpha_{ij} = \frac{\exp(\text{ReLU}(a^T[Wh_i \| Wh_j]))}{\sum_{k \in N(i)} \exp(\text{ReLU}(a^T[Wh_i \| Wh_k]))} \quad (4)$$

1.3 多 GRU 并行解码神经网络模型

多 GRU 并行解码神经网络模型是序列到序列学习任务中广泛使用的模型结构。该模型结合了 GRU 和并行计算的优势,在处理序列数据时能够同时考虑时间依赖性和计算效率。GRU 是循环神经网络(recurrent neural network, RNN)的一种变体,旨在解决传统 RNN 在处理长序列时遇到的梯度消失和梯度爆炸问题^[23-24]。GRU 通过引入门控机制(包括重置门和更新门)来控制信息的流动,有效地捕获序列中的长期依赖关系。由于解码器中的 GRU 单元可以并行操作,因此可以同时生成多个输出,从而提高计算效率。

在 GRU 模型中,重置门在整合新输入信息与先前记忆方面起着关键作用,而更新门则调节先前记忆对当前状态的贡献程度。这一过程由式(5)、式(6)描述。随后,使用式(7)和式(8)计算当前单

元的信息,并将其有效地传递给更广泛的神经网络。最终,根据式(9)得出所需的输出数据。GRU 模型结构的示意图如图 3 所示。




图 3 GRU 模型的结构

Fig. 3 Structure of the GRU model

$$z_u = \sigma(w_u * [h_{t-1}, x_t] + b_u) \quad (5)$$

$$z_r = \sigma(w_r * [h_{t-1}, x_t] + b_r) \quad (6)$$

$$z = \sigma(w * [h_{t-1} \odot z_r, x_t] + b) \quad (7)$$

$$h_t = z_u \odot c_{t-1} + (1 - z_u) \odot z \quad (8)$$

$$y_t = \sigma(w' h_t) \quad (9)$$

在双层图神经网络的解码过程中,每个充电站节点都被视为一个独立的时间序列数据点。它们各自拥有独特的充电历史、负载特性和用户行为模式。多 GRU 并行解码神经网络模型为每个充电站节点分配一个独立的 GRU 解码器。这些解码器可以并行处理各自的数据流,而不会相互干扰。每个 GRU 解码器都基于先前的充电记录和当前的环境条件,预测未来一段时间内的充电负载。通过这种并行解码方法,模型可以同时考虑多个充电站节点的充电需求。并且,它可以根据每个节点的独特特性做出差异化的预测。这不仅提高了预测的准确性,还使模型更加灵活和可扩展,能够适应不同规模和复杂度的充电网络。

2 结果与讨论

2.1 数据来源与模型配置

为了评估本研究中提出的算法性能,我们采用了一个包含中国北方某城市多个充电站一年充电负载数据的数据集。该数据集涵盖了 248 个充电站的信息,总容量为 1 200 kW,时间分辨率为五分钟。此外,数据集还包含了充电站的相对空间位置信息、通过直达交通路线的连接信息以及它们所属的行政区划信息。

在数据处理阶段,首先将数据归一化到 0 到 1

的范围内。随后,从数据集中删除了超出三倍标准差的异常数据点。剩余的数据按照 60%:20%:20% 的比例分别划分为训练集、验证集和测试集。基于上述数据,我们在不同层级节点之间建立了连接,形成了一个双层异构图网络,如图 4 所示。




图 4 堆叠异构空间图网络

Fig. 4 Stacked heterogeneous spatial graph network

首先,我们根据充电站之间的距离和交通连接性在充电站节点之间形成边,构建了图网络的第一层。随后,利用行政区划信息,围绕每个行政区域的中心及其最小空间距离构建了连接图,作为网络的第二层。最后,我们将区域节点与同一区域内的每个充电站节点连接起来,形成了双层异构图神经网络的结构。

文中的所有实验均通过 Python (版本 3.9.10) 实现,使用 PyTorch (版本 1.7.5) 作为深度学习框架。实验所用计算机配置为 Intel (R) Xeon (R) CPU E5-2620 v4 @ 2.10 GHz,操作系统为 Windows 11,模型参数设置如表 1 所示。

表 1 神经网络模型参数

Tab. 1 Neural network model parameters

HGNN	hidden units = 128, adj_type = 'Typical', n_layers = 3
Attention	Dmodel = 16, T_in = 12, D_model = 16, T_out = 7,
GRU	Dmodel = 48, inp_len = 48, opt_len = 48, Hidden = 16
Optimizer	Adam
Hyper Parameters	Learning_rate = 0.001, Bath_size = 32

2.2 评价指标

采用电力预测领域常用的指标—归一化均方根误差 (normalized root mean square error, NRMSE)、平均绝对误差 (mean absolute error, MAE) 和平均绝对百分比误差 (mean absolute percentage error, MAPE) 来评估各种预测模型的性能。

MAPE 通过比较每个预测中充电负荷预测误差与实际值的比例来评估相对误差。NRMSE 衡量预测结果与实际结果之间的平均百分比差异,通过残差平方来强调误差的主要部分。MAE 则关注误差的平均幅度。这些指标的值范围在 0 ~ 100% 之间,值越低表示准确性越高。

指标的计算方法如下:

$$\text{NRMSE}(Y_{\text{pred}}, Y_{\text{actual}}) = \sqrt{\frac{1}{T} \sum_{t=1}^T \left(\frac{y_{\text{pred}}^t - y_{\text{actual}}^t}{y_{\text{actual}}^{\max}} \right)^2} \quad (10)$$

$$\text{NMAE}(Y_{\text{pred}}, Y_{\text{actual}}) = \sqrt{\frac{1}{T} \sum_{t=1}^T \left| \frac{y_{\text{pred}}^t - y_{\text{actual}}^t}{y_{\text{actual}}^{\max}} \right|} \quad (11)$$

$$\text{MAPE}(Y_{\text{pred}}, Y_{\text{actual}}) = \frac{1}{T} \sum_{t=1}^T \frac{|y_{\text{pred}}^t - y_{\text{actual}}^t|}{|y_{\text{actual}}^t|} \quad (12)$$

式中: y_{pred}^t 是 t 时刻电动汽车充电负荷的预测值; y_{actual}^t 是时间 t 时电动汽车充电负荷的实际值; $y_{\text{actual}}^{\max}$ 是一个周期内电动汽车充电负荷的最大值; T 是时间序列的长度。

2.3 算例结果分析

从两个方面对所提出的方法进行了案例研究分析。首先,我们将其与常用的神经网络模型进行比较,以验证我们方法的有效性;其次,我们在内部分析模型中考察了每个模块的有效性,重点关注双层图网络结构和并行解码机制。

1) 和传统方法对比测试

设置传统的时空图神经网络模型为对照,验证所提 SHSGN 模型的有效性。对照模型包括 STGCN (spatiotemporal graph convolutional network)^[25]、TGCN (temporal graph convolutional network)^[26]、BEGCN (Bayesian ensemble graph attention network)^[27]、PAG、TCN、FCNN (fourier convolutional neural networks) 和 LSTM (long short-term memory)。

a) 区域级充电负荷预测结果

图 5 和图 6 展示了 SHSGN 在未来 15 min ~ 240 min (12 h) 时间窗口内的预测结果和逐步 NRMSE 预测预测误差逐步变化情况。由图可见,相比传统方法,所提方法和实际值的变化更加贴近,同时,误差幅值也相对最小。




图 5 电动汽车充电负荷预测结果
Fig. 5 EV charging load prediction results




图 6 电动汽车充电负荷预测结果的
NRMSE 误差随时间变化
Fig. 6 NRMSE error of EV charging load prediction
results varying with time

b) 电站级充电负荷预测结果

进一步分析各个电动汽车充电站节点的预测误差,绘制了如图 7 所示的误差分布热力图。其中横轴代表充电站的标识符,纵轴代表各个神经网络模型。其中,所提方法在绝大多数节点的预测误差均小于对比方法,并且在剩余节点上与对比方法的误差持平。可见,所提方法在总的充电站负荷和单个充电站负荷预测方面均显著优于传统模型,实现了更高的预测准确性。验证了所提方法在处理整体和特定充电站需求方面的优势。




图 7 每个电动汽车充电站的 NRMSE
Fig. 7 NRMSE for each EV charging station

表 2 ~ 表 4 记录了所提 SHSGN 模型在 15 min、60 min、180 min 和 240 min 上的预测误差。结果表明,SHSGN 在所有评估指标 (NRMSE、MAPE 和 NMAE) 上均一致优于其他模型,分别为 6.77%, 19.01%, 5.95%, 平均降低了 2.12%, 4.97% 和 1.52%。

表 2 各模型的 NRMSE 误差/%

Tab. 2 NRMSE error/% for each model

Model	15 min	60 min	180 min	240 min
SHSGN	6.08	6.37	7.37	7.26
STGCN	7.33	7.71	8.64	8.83
TGCN	8.37	8.57	9.28	9.66
BEGCN	7.72	8.35	8.78	11.75
PAG	6.7	7.9	8.32	9.77
TCN	8.82	8.9	10.39	11.77
LSTM	6.46	7.84	8.57	9.74
FCNN	8.17	8.86	9.6	12.15

表 3 各模型的 MAPE 误差/%

Tab. 3 MAPE errors/% for each model

Model	15 min	60 min	180 min	240 min
SHSGN	13.45	18.55	21.17	22.86
STGCN	16.42	21.18	24.11	27.84
TGCN	17.90	23.92	28.71	32.20
BEGCN	16.28	23.83	24.52	30.15
PAG	16.47	22.67	23.76	27.34
TCN	19.30	26.29	28.36	31.39
LSTM	15.12	21.73	23.21	26.36
FCNN	18.69	24.24	27.62	31.98

表 4 各模型的 MAPE 误差百分比/%

Tab. 4 Percentage of MAPE error/% for each model

Model	15 min	60 min	180 min	240 min
SHSGN	4.35	5.79	6.36	7.31
STGCN	4.71	6.88	7.62	8.17
TGCN	5.42	7.84	8.72	9.78
BEGCN	5.53	7.32	8.08	9.26
PAG	4.76	6.62	7.79	8.13
TCN	6.07	7.92	9.52	10.52
LSTM	4.70	6.65	7.16	8.41
FCNN	5.90	7.65	8.33	9.80

其中,在更长的预测时间范围内,如 240 min 尺度,SHSGN 模型的 MAPE 为 22.86%,显著低于 LSTM 的 26.36% 和 FCNN 的 31.98%。在较短的预测窗口(15 min 和 60 min)中 SHSGN 模型的 NMAE 表现较好,分别为 4.35% 和 5.79%。这突出了该模型准确捕捉短期负荷波动的能力,这对于实时充电管理和应急响应尤为重要。相比之下,TGCN 和 BEGCN 等模型误差较大。

2) 消融实验

通过表 5 中概述的消融研究,进一步分析单个模块的有效性。

表 5 消融实验设置

Tab. 5 Protocol settings for ablation experiments

Model	HGNN	GCN	GAT	n-GRU	1-GRU
SHSGN	1	0	0	1	0
GCN-n-GRU	0	1	0	1	0
GAT-n-GRU	0	0	1	1	0
HGNN-1-GRU	1	0	0	0	1
GCN-1-GRU	0	1	0	0	1
GAT-1-GRU	0	0	1	0	1

表 5 指定了不同的配置,以剖析模型中不同架构选择的贡献:

a)特征提取的图网络类型:所提 HGNN;GCN,不考虑节点异质性的传统图卷积网络;GAT(graph attention network 图注意力网络):在特征聚合期间应用注意力机制,以优先处理节点连接。

b)解码策略:n-GRU:并行使用多个 GRU 模块,每个模块从特定的数据子集中学习;1-GRU:将各种充电站负荷视为单个模块内的特征。

消融研究旨在评估这些配置如何影响模型进行准确负荷预测的能力。通过比较这些变体的性能,可确定在预测准确性和模型鲁棒性方面,哪种特征提取和解码机制的组合能产生最佳结果。

3) 区域级充电负荷预测结果

图 8 和图 9 展示了每个消融研究场景的 60 分钟总充电负荷预测结果以及相应的 NRMSE。为了清晰地展示误差结果,图 9 保留了 NRMSE 的符号。图 10 展示了各个电动汽车充电站节点的 60 min 预测误差,其中 x 轴代表充电站的标识符。比较结果

显示,无论是在整体还是单个充电站负荷预测方面,SHSGN 始终优于所有其他消融研究配置。




图 8 消融实验方案充电负荷预测结果

Fig. 8 EV charging load prediction results for each ablation experiment scenario




图 9 每个消融实验计划预测结果的 NRMSE 误差随时间的变化

Fig. 9 NRMSE error over time for the predicted results of each ablation experimental program




图 10 各消融实验的充电站负荷归一化均方根误差(NRMSE)

Fig. 10 NRMSE of charging station load for each ablation experiment

3) 电站级充电负荷预测结果

表 6 ~ 表 8 绘制了 SHSGN 模型在不同时间间隔(15 min、60 min、180 min 和 240 min)下在充电站级别的预测误差统计。

表 6 每个消融实验的 NRMSE 误差/%

Tab. 6 NRMSE errors for each
ablation experiment(%)

Model	15 min	60 min	180 min	240 min
SHSGN (HGNN-n-GRU)	6.08	6.37	7.37	7.26
GCN-n-GRU	7.65	8.86	9.37	9.79
GAT-n-GRU	7.84	8.64	9.64	10.64
HGNN-1-GRU	7.55	8.09	9.59	10.36
GCN-1-GRU	8.97	9.74	11.41	11.76
GAT-1-GRU	8.61	9.98	10.93	11.15

表 7 每个消融实验的 MAPE 误差/%

Tab. 7 MAPE errors for each ablation
experiment(%)

Model	15 min	60 min	180 min	240 min
SHSGN (HGNN-n-GRU)	13.45	18.55	21.17	22.86
GCN-n-GRU	18.32	24.33	26.79	31.53
GAT-n-GRU	18.10	25.05	26.55	30.01
HGNN-1-GRU	17.02	23.64	26.26	29.76
GCN-1-GRU	20.60	27.37	31.80	35.88
GAT-1-GRU	19.74	27.82	31.68	33.77

表 8 每个消融实验的 NMAE 误差/%

Tab. 8 NMAE errors for each ablation
experiment(%)

Model	15 min	60 min	180 min	240 min
SHSGN (HGNN-n-GRU)	4.35	5.79	6.36	7.31
GCN-n-GRU	5.84	7.45	8.55	9.96
GAT-n-GRU	5.52	7.82	8.24	9.26
HGNN-1-GRU	5.51	7.24	8.02	9.16
GCN-1-GRU	6.42	8.64	9.21	10.67
GAT-1-GRU	6.51	8.53	9.53	11.22

图 11 绘制了各个方法的误差条形图。可见,在 NRMSE、MAPE 和 NMAE 指标上,SHSGN 模型在所有时间窗口内均优于其他所有模型,验证了 SHSGN 在特征提取和解码方面的设计优势,如 SHSGN、GCN-n-GRU 和 GAT-n-GRU。并行解码结构有效提升了模型捕捉不同充电站多样负荷特征的能力。




图 11 消融实验预测误差

Fig. 11 Ablation experiment prediction error

在编码器方面,所提的异构图神经网络(HGNN)相比 GCN 和 GAT 也表现出更高的预测精度。以 15 min 尺度的 NRMSE 误差为例,在 n-GRU 配置中,HGNN 相比优于 GCN 和 GAT 分别提高了 1.57% 和 1.76%,在 1-GRU 配置中,则提高了 1.42% 和 1.06%。体现了异质图网络在捕捉图结构特征方面的优势,尤其是在处理具有复杂拓扑结构的数据时。

在解码器方面,“n-GRU”方案相比“1-GRU”优势明显。以 15 分钟尺度的预测结果为例,SHSGN (HGNN-n-GRU)的 NRMSE 误差为 6.08%,而 HGNN-1-GRU 为 7.55%,降低了 1.47%;同时采用“n-GRU”方案的平均误差为 7.19,相比“1-GRU”方案降低了 1.18%。同时,两类方案在 MAPE 和 NAME 指标方面也展现了一定优势,“n-GRU”方案的平均 MAPE 误差和 NAME 误差为 16.62% 和 5.23%,相比“1-GRU”方案降低了 2.50% 和 0.91%,验证了多个并行解码器在捕捉多主体动态负荷波动方面的优势。

总体而言,这些消融研究结果不仅验证了 SHSGN 模型组件设计的合理性,还为未来的模型优化提供了有价值的见解。并行解码策略的选择和异构图网络的使用对于提高预测准确性和稳定性尤为重要。

3 结论

文章引入的 SHSGN 模型通过结合双层异构图网络与多 GRU 并行解码机制,有效地预测了城市电动汽车充电负荷的时空分布。并通过中国某城市 248 个充电站的实际负荷数据验证了所提方法的有效性。

SHSGN 模型在多个时间窗口的 NRMSE、平 MAPE 和 NMAE 指标均优于传统模型,表现出更高的稳定性和准确性,相比传统方法降低了 2.12%, 4.97% 和 1.52%。消融实验进一步证实了 HGNN 编码器和多 GRU 解码机制在提高预测准确性方面的重要性。

综上所述,SHSGN 模型不仅提高了电动汽车充电负荷的预测准确性,还为城市电网优化和电动汽车充电服务的改善提供了有力支持。未来的工作可以进一步探索如何显式地建模充电负荷特征的跨区域负荷转移模式,以提升预测方法的可解释性,并在不同地区和更广泛应用场景中的性能,增强模型的实用性和适应性。

参考文献

- [1] Aggarwal S, Kumar Singh A, Singh Rathore R, et al. Revolutionizing load management: A novel technique to diminish the impact of electric vehicle charging stations on the electricity grid[J]. Sustainable Energy Technologies and Assessments. 2024, 65: 103784.
- [2] 庞松岭, 赵海龙, 张晨佳. 计及充电需求差异的电动汽车充电设施协同优化配置[J]. 电测与仪表, 2024, 61(12): 171-177.
Pang Songling, Zhao Hailong, Zhang Chenjia. Cooperative optimal allocation of electric vehicle charging facilities taking into account charging demand differences[J]. Electrical Measurement & Instrumentation, 2024, 61(12): 171-177.
- [3] Zhao Y, Jiang Z, Chen X, et al. Toward environmental sustainability: data-driven analysis of energy use patterns and load profiles for urban electric vehicle fleets[J]. Energy. 2023, 285: 129465.
- [4] Bamos Z N, Laitsos V M, Afentoulis K D, et al. Electric vehicles load forecasting for day-ahead market participation using machine and deep learning methods[J]. Applied Energy. 2024, 360: 122801.
- [5] Khan W, Somers W, Walker S, et al. Comparison of electric vehicle load forecasting across different spatial levels with incorporated uncertainty estimation[J]. Energy. 2023, 283: 129213.
- [6] Gschwendtner C, Knoeri C, Stephan A. The impact of plug-in behavior on the spatial-temporal flexibility of electric vehicle charging load[J]. Sustainable Cities and Society. 2023, 88: 104263.
- [7] 李崎勇, 宋子涵, 刘斌. 含垃圾能源化处理及电动汽车负载的区域综合能源系统协调优化[J]. 电测与仪表, 2024, 61(4): 109-115.
Li Jiyong, Song Zihan, Liu Bin. Coordinated optimization of regional integrated energy system with waste energy treatment and electric vehicle load[J]. Electrical Measurement & Instrumentation, 2024, 61(4): 109-115.
- [8] 宣羿, 樊立波, 孙智卿, 等. 考虑低碳交通的电动汽车充电站优化配置方法[J]. 浙江电力, 2024, 43(6): 69-79.
Xuan Yi, Fan Libo, Sun Zhiqing, et al. An optimal allocation method for electric vehicle charging stations considering lowcarbon transportation[J]. Zhejiang Electric Power, 2024, 43(6): 69-79.
- [9] Sadeghian O, Oshnoei A, Mohammadi-Ivatloo B, et al. A comprehensive review on electric vehicles smart charging: Solutions, strategies, technologies, and challenges[J]. Journal of Energy Storage, 2022, 54: 105241.
- [10] Li M, Wang Y, Peng P, et al. Toward efficient smart management: A review of modeling and optimization approaches in electric vehicle transportation network-grid integration[J]. Green Energy and Intelligent Transportation, 2024, 57: 100181.
- [11] Sica L, Defflorio F. Estimation of charging demand for electric vehicles by discrete choice models and numerical simulations: Application to a case study in Turin[J]. Green Energy and Intelligent Transportation, 2023, 2: 100069.
- [12] 张明泽, 栾文鹏, 艾欣, 等. 基于边缘计算的台区短期负荷预测方法[J]. 电测与仪表, 2024, 61(4): 93-99.
Zhang Mingze, Luan Wenpeng, Ai Xin, et al. A short-term load forecasting method for station areas based on edge computing[J]. Electrical Measurement & Instrumentation, 2024, 61(4): 93-99.
- [13] 黄敬尧, 张扬, 张丙旭. 计及电动汽车碳交易的电力系统经济调度方法[J]. 电测与仪表, 2025, 62(8): 11-19.
Huang Jingyao, Zhang Yang, Zhang Bingxu. An economic dispatch method of power system taking into account carbon trading of electric vehicles[J]. Electrical Measurement & Instrumentation, 2025, 62(8): 11-19.
- [14] Liu Y S, Tayarani M, Gao H O. An activity-based travel and charging behavior model for simulating battery electric vehicle charging demand[J]. Energy, 2022, 258: 124938.

- [15] Nazari F, Mohammadian A, Stephens T. Modeling electric vehicle adoption considering a latent travel pattern construct and charging infrastructure. *Transportation Research Part D* [J]. *Transport and Environment*, 2019, 72: 65-82.
- [16] Mahmoudi E, Santos Barros Tad, Filho Er. Forecasting urban electric vehicle charging power demand based on travel trajectory simulation in the realistic urban street network [J]. *Energy Reports*, 2024, 11: 4254-76.
- [17] 顾玮, 段敬, 张栋, 等. 基于数据与模型联合驱动的电动汽车充电负荷时空分布预测 [J]. *计算机科学*, 2024, 51 (S2): 1032-1037.
- Gu Wei, Du Jing, Zhang Dong, et al. Spatio-temporal distribution prediction of electric vehicle charging loads based on joint data and model driving [J]. *Computer Science*, 2024, 51 (S2): 1032-1037.
- [18] 毛建斌, 杨少兵, 杨湘彦, 等. 基于有限混合模型的规模化电动汽车充电负荷在线预测方法 [J]. *电网技术*, 2025, 49 (5): 1931-1940.
- Mao Jianbin, Yang Shaobing, Yang Xiangyan, et al. On-line prediction method of scaled electric vehicle charging load based on finite mixture model [J]. *Power System Technology*, 2025, 49 (5): 1931-1940.
- [19] 王子龙, 黄莉. 基于改进图时间卷积网络的农村地区电动汽车充电负荷预测及其对农网的影响 [J]. *电力需求侧管理*, 2024, 26 (5): 88-93.
- Wang Zilong, Huang Li. Electric vehicle charging load forecasting in rural areas based on improved graph time convolutional network and its impact on agricultural network [J]. *Electricity Demand Side Management*, 2024, 26 (5): 88-93.
- [20] 姜力杨, 盖晨昊, 齐航, 等. 数据驱动的电力系统动态安全评估研究综述 [J]. *山东电力技术*, 2024, 51 (4): 27-35.
- Jiang Liyang, Gai Chenhao, Qi Hang, et al. Review on data-driven dynamic security assessment of power systems [J]. *Shandong Electric Power*, 2024, 51 (4): 27-35.
- [21] 王佳昊, 黎文斌, 郭仕尧, 等. 基于全局时空图卷积神经网络的都市交通流量预测 [J]. *计算机科学*, 2024, 51 (S2): 544-552.
- Wang Jiahao, Li Wenbin, Guo Shiyao, et al. Urban traffic flow prediction based on global spatio-temporal map convolutional neural network [J]. *Computer Science*, 2024, 51 (S2): 544-552.
- [22] El-Azab H-Ai, Swief Ra, El-Amary Nh, et al. Seasonal electric vehicle forecasting model based on machine learning and deep learning techniques [J]. *Energy and AI*, 2023, 14: 100285.
- [23] Genov E, Cauwer Cd, Krieking Gv, et al. Forecasting flexibility of charging of electric vehicles: Tree and cluster-based methods [J]. *Applied Energy*. 2024, 353: 121969.
- [24] 温静. 基于RNN的电力负荷波动分析及预测研究 [J]. *电气开关*, 2024, 62 (5): 13-15, 19.
- Wen Jing. Research on power load fluctuation analysis and prediction based on RNN [J]. *Electrical Switch*, 2024, 62 (5): 13-15, 19.
- [25] Jauhar S K, Sethi S, Kamble S S, et al. Artificial intelligence and machine learning-based decision support system for forecasting electric vehicles' power requirement [J]. *Technological Forecasting and Social Change*, 2024, 204: 123396.
- [26] Liu Z, Borlaug B, Meintz A, et al. Data-driven method for electric vehicle charging demand analysis: Case study in Virginia. *Transportation Research Part D* [J]. *Transport and Environment*, 2023, 125: 103994.

收稿日期: 2024-12-26; 修回日期: 2025-10-29

作者简介:

李璐(1991—),女,高级工程师,研究方向为技术管理。

E-mail:348032643@qq.com

王文龙(1985—),男,硕士,助理工程师,研究方向为营销信息管理。E-mail:823087877@qq.com

刘楠(1982—),男,硕士,高级工程师,研究方向为企业。E-mail:857319068@qq.com

杨威(1981—),男,硕士,副高级工程师,研究方向为电能计量。E-mail:fxgdgshlwb@sina.com

张佳夫(1982—),男,工程师,研究方向为营销管理。E-mail:yngwei505@sohu.com

王宇蛟(2000—),女,通信作者,硕士研究生,研究方向为电力系统自动化。E-mail:2780447233@qq.com

(编辑 杜景飞)