

# 多因素融合驱动的电动汽车充电负荷时空预测\*

王继波, 丁卉, 刘明鑫, 郭悠游

南京邮电大学自动化学院/人工智能学院, 江苏南京 210023

**摘要:** 针对多因素影响下城市电动汽车充电负荷的预测问题, 提出了时空图卷积与多通道注意力网络融合模型 (STGC-SENet)。该模型构建了周期性时序片段提取模块以获取近期、日、周三尺度周期特征, 通过时空图卷积实现时序依赖与空间拓扑关联的同步建模, 引入 SE 通道注意力层对多因素特征通道进行重标定, 动态强化关键特征。基于真实数据的实验表明: 相比于长短时记忆网络 (LSTM)、多视角时空图卷积网络 (MSTGCN)、基于注意力的时空图卷积网络 (ASTGCN) 等基线模型, STGC-SENet 的平均绝对误差分别下降 3.36、0.56、1.10。在因素敏感性方面, 相比于近期、周时序片段, 日周期因子的加入对模型预测提升效果最为显著; 在历史充电负荷输入下, 充电桩占用数与实时电价融入能够获得最优的预测效果, 整体平均绝对误差下降至 5.08, 而充电桩数目和气象因素的融入并未带来较好的预测效果提升。

**关键词:** 电动汽车; 充电负荷; 多因素融合; 时空关联; 图卷积网络; 多通道注意力

**中图分类号:** TP399 **文献标志码:** A **文章编号:** 2097-0137(2026)01-0103-08

## Spatio-temporal prediction of electric vehicle charging load driven by multi factor integration

WANG Jibo, DING Hui, LIU Mingxin, GUO Youyou

College of Automation / College of Artificial Intelligence, Nanjing University of Posts and Telecommunication, Nanjing 210023, China

**Abstract:** To address the spatial-temporal prediction of urban electric vehicle charging load under multi-factor influences, a fusion model combining spatial-temporal graph convolutional and Squeeze-and-Excitation network (STGC-SENet) was proposed. A periodic temporal segment extraction block was constructed to acquire features across recent, daily and weekly scales. Temporal dependencies and spatial topological correlations were synchronously modeled through spatio-temporal graph convolution. A Squeeze-and-Excitation channel attention layer was introduced to recalibrate feature channels, dynamically enhancing key feature. Experiments based on real-world urban charging datasets demonstrate that: compared to baseline model (LSTM, MSTGCN, ASTGCN), STGC-SENet reduced the mean absolute error by 3.36, 0.56 and 1.10, respectively. Regarding factor sensitivity, incorporating the daily periodicity factor demonstrates the most significant prediction improvement compared to recent and weekly temporal segments. Under historical charging load inputting, integrating charging pile occupancy rate and real-time electricity price yields optimal prediction performance, with MAE decreasing to 5.08; conversely, incorporating the number of charging piles and meteorological

\* 收稿日期: 2025-09-02 录用日期: 2025-10-09 网络首发日期: 2025-10-27

基金项目: 江苏省高等学校基础科学(自然科学)研究项目(23KJB520028);

南京邮电大学引进人才科研启动基金(NY221125)

作者简介: 王继波(2004年生), 男; 研究方向: 机器学习; E-mail: b22051311@njupt.edu.cn

通信作者: 丁卉(1989年生), 女; 研究方向: 人工智能; E-mail: hui-gmid@njupt.edu.cn



ZR20250184

factors did not yield significant prediction improvement.

**Key words:** electric vehicle; charging load; multi-factor fusion; spatial-temporal correlation; graph convolutional network; multi-channel attention

大规模电动汽车出行带来的灵活性充电负荷,会对电网安全运行与稳定性产生影响(黄学良等, 2024),开展城市电动汽车(EV, electric vehicle)充电负荷的时空预测对充电设施布局,以及电网运行优化具有重要意义。

现有EV充电负荷预测方法主要有基于物理系统的机理模型和基于网络模型的机器学习方法。机理模型方法因其从理论出发,具有较强的可解释性(张夏韦等, 2023)。秦建华等(2023)研究了EV用户的充电行为特性,采用Monte Carlo随机模拟了各类型电动汽车的负荷曲线。Guo et al.(2019)运用Monte Carlo算法建立了EV用户的出行习惯概率分布函数,进而实现了EV充电负荷的关联性建模。此类方法验证往往需要依赖真实场景模拟实验,计算资源大,理论假设带来的结果不确定性较多。

机器学习方法从历史数据中自适应学习重要的特征表述以实现充电负荷预测,众多学者提出了基于CNN、长短时记忆网络(LSTM)、Transformer等深度神经网络模型的时空建模方法(马恒瑞等, 2025)。Kim et al.(2024)采用互残差图卷积提取充电设施的空间关联性,引入CBi-LSTM捕获时间相关性,并将时间与空间模块并行处理以实现充电需求预测。Wang et al.(2024)提出了融合STD分解法与LSTM的复合预测模型,通过分解原始充电负荷序列分量之间的关联特征,实现了充电负荷的预测与重构。上述研究方法(胡博等, 2022),证实了考虑EV充电负荷的时空特性对其预测具有重要意义。

EV充电负荷与充电桩性质、电价、气象等因素存在密切关联。李宏伟等(2025)基于交通拥挤度、城市兴趣点分布、用户出行行为数据的分析,直观反映了充电负荷的时空分布异质性。王长春等(2024)针对大型EV充电负荷短期预测任务提出了融合LSTM-SVR算法,并引入充电利用率和分时电价因素,证实了充电利用率与分时电价对EV负荷预测的提升作用。李波等(2024)采用基于LightGBM(light gradient boosting machine)与XGBoost(extreme gradient boosting)的组合算法,考虑交通流量、温度等环境因素进行了充电负荷预测,发现时间因素、历史充电负荷的统计值对于EV

充电负荷预测高度重要。

现有方法往往采用LSTM等建模时间序列,利用卷积对充电负荷空间特征进行独立处理,此类处理方式未能充分利用充电负荷在时间尺度下的周期依赖性,亦忽略了其空间图网络中的拓扑结构。在充电负荷与环境等多因素作为输入时,割裂了多因素间动态的时空隐式耦合关系。此外,充电负荷与多因素融合多采用特征拼接或加权融合等浅层融合方式,难以捕获不同因素的时空异质性,无法实现自适应识别关键驱动因素。

因此,本研究提出了时空图卷积与多通道注意力融合模型(STGC-SENet),采用时空图卷积实现时序特性与空间拓扑关联特征的同步建模。同时,引入三级时序片段输入,即近期、日周期和周周期性因子,捕获多种时间尺度的周期依赖性,以适应不同时间粒度下的EV充电负荷预测。针对充电负荷与相关因素的有效融合问题,嵌入Squeeze-and-Excitation(SE)轻量化注意力模块,对时空图卷积输出的特征通道进行重标定,动态增强关键特征的权重以凸显其对充电负荷的影响。最后,应用STGC-SENet预测模型,开展了充电负荷、充电桩占用数、气象、电价多种充电因素影响下的区域充电负荷预测实验,并进行了周期性因子敏感性和多因素敏感性分析。

## 1 充电负荷空间图结构与定义

将城市空间充电负荷表示为无向图 $G = (V, E, A)$ 。其中, $V$ 表示为空间节点的集合, $|V| = N$ 为空间节点的数量; $E$ 为边的集合,表示节点间的连通性; $A \in \mathbf{R}^{N \times N}$ 为图 $G$ 的邻接矩阵,用于表示拓扑关系,描述节点间的相关性(Guo et al., 2019)。相较于无权重的无向邻接矩阵,本文采用的加权邻接矩阵更有利于区分各个空间节点之间的相关性强度,且在预测任务中表现更好。其中,加权邻接矩阵 $A$ 中的每条边的权重等于两个空间节点中充电桩集群之间距离的倒数。即在空间上相邻的节点,其充电桩集群的距离越远,两者之间连接关系越弱。

图 $G$ 中每个节点在每个时序片段上记录着 $f$ 维特征的数据, $f \in \{1, \dots, F\}$ , $F$ 为特征总数。将 $t$ 时刻第 $i$ 节点上的第 $f$ 维特征定义为 $x_{t,i,f} \in \mathbf{R}$ , $x_t \in \mathbf{R}^{N \times F}$

表示在  $t$  时刻所有节点的所有特征值, 输入数据以时间-空间-特征的三维张量表示。令  $T_a$  表示输入序列在时间维度上的总长度, 则  $X_t = (x_1, x_2, \dots, x_{T_a})$ ,  $X_t \in \mathbf{R}^{T_a \times N \times F}$  为时间序列  $T_a$  在所有空间节点的所有维度的特征值(杨建喜等, 2021)。设所预测时间序列长度为  $T_p$ ,  $y_{t,i} \in \mathbf{R}$  表示预测的  $t$  时刻  $i$  节点的 EV 充电负荷量,  $Y_t = (y_1, y_2, \dots, y_{T_p})$ ,  $Y_t \in \mathbf{R}^{T_p \times N}$  表示未来时段  $T_p$  内所有节点的 EV 充电负荷量。由此, 本文 EV 充电负荷预测任务可以定义为一个多特征融合的时空预测问题: 给定历史时间序列  $T_a$  内所有空间节点所有特

征维度的三维时空张量  $X$  和图结构  $G$ , 通过学习模型预测未来时间段  $T_p$  上所有节点的 EV 充电负荷量  $Y_p = (y_1, y_2, \dots, y_{T_p})$ ,  $Y_p \in \mathbf{R}^{T_p \times N}$  (刘赏等, 2023)。

## 2 STGC-SENet模型

STGC-SENet模型的框架如图1所示, 由周期性时序片段提取模块(PTSE block, periodic temporal segment extraction block)、时空图卷积模块(STGC block, spatial-temporal graph convolutional block)、残差层(residual)、SE层和最终融合层(Final Fusion)组成。

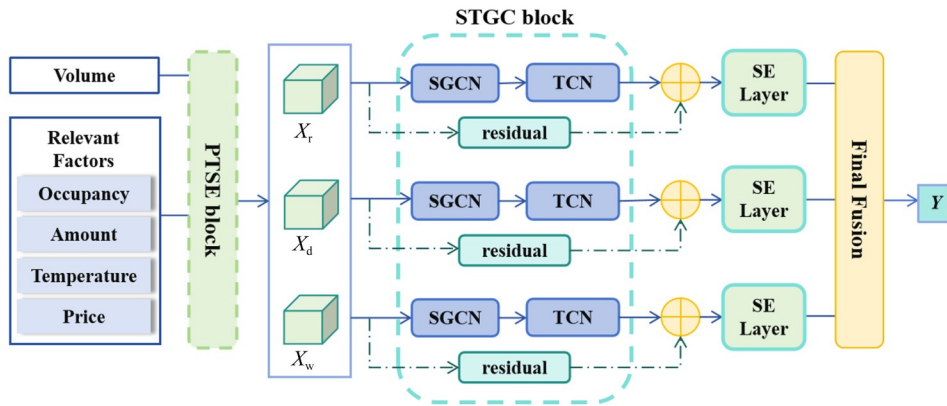


图1 STGC-SENet框架

Fig. 1 Framework for STGC-SENet

### 2.1 周期性时序片段提取模块

该模块沿时间轴从输入数据截取3种周期性时序片段, 采样频率为每天  $q$  次, 沿时间轴截取的近期、日和周时序片段的序列数量分别为  $r$ 、 $d$ 、 $w$ , 每一份时序片段长度皆为  $T_p$ , 3种周期时序片段的长度分别为  $T_r$ 、 $T_d$ 、 $T_w$ 。3种时序片段分别定义为(Guo et al., 2019; 杨建喜等, 2021):

$$X_r = (x_{t_0 - T_p \times r}, x_{t_0 - T_p \times r + 1}, \dots, x_{t_0 - T_p \times (r-1)}, \dots, x_{t_0 - T_p}, \dots, x_{t_0}) \in \mathbf{R}^{T_r \times N \times F};$$

$$X_d = (x_{t_0 - q \times d - T_p}, x_{t_0 - q \times d - T_p + 1}, \dots, x_{t_0 - q \times d}, x_{t_0 - q \times (d-1) - T_p}, \dots, x_{t_0 - q \times (d-1)}, x_{t_0 - q - T_p}, \dots, x_{t_0 - q}) \in \mathbf{R}^{T_d \times N \times F};$$

$$X_w = (x_{t_0 - 7 \times q \times w - T_p}, x_{t_0 - 7 \times q \times w - T_p + 1}, \dots, x_{t_0 - 7 \times q \times w}, x_{t_0 - 7 \times q \times (w-1) - T_p}, \dots, x_{t_0 - 7 \times q \times (w-1)}, x_{t_0 - 7 \times q - T_p}, \dots, x_{t_0 - 7 \times q}) \in \mathbf{R}^{T_w \times N \times F}.$$

以上由周期性时序片段提取模块所截取的各个时序片段将并行输入至后续模块处理。

### 2.2 时空图卷积模块

该模块采用切比雪夫多项式为核的图卷积获取相邻点位的空间依赖关系, 并通过时间维度的二维卷积捕获局部时间中的多尺度时间特征(Guo et

al., 2019)。

为分析空间图结构中的拓扑关系, 在每个片段上采用基于谱方法的图卷积网络, 用谱方法将图转化成代数形式(Yan et al., 2018)。图结构对应的拉普拉斯矩阵

$$L = I_N - D^{-\frac{1}{2}} A D^{-\frac{1}{2}} = U \Delta U^T, \quad L \in \mathbf{R}^{N \times N},$$

式中  $I_N$  为单位矩阵。对角矩阵  $D \in \mathbf{R}^{N \times N}$  为路网节点的度矩阵,  $D_{ii} = \sum_j A_{ij}$ 。  $\Delta = \text{diag}(\lambda_0, \dots, \lambda_{N-1})$ ,  $\Delta \in \mathbf{R}^{N \times N}$  是特征值的对角矩阵,  $U$  为傅里叶基。因此, 基于图的拉普拉斯矩阵  $L$  的特征分解, 可以得到谱域图卷积

$$g_\theta *_c x = g_\theta(U \Delta U^T) x = U g_\theta(\Delta) U^T x,$$

式中  $g_\theta$  为滤波器(卷积核),  $*_c$  为图卷积算子,  $x$  为输入的图信号。为了降低直接对矩阵  $L$  做特征值分解的计算成本, 引入切比雪夫多项式(Huang et al., 2021), 得

$$g_\theta *_c x = g_\theta(L) x = \sum_{k=0}^{K-1} \theta_k T_k(\tilde{L}) x,$$

式中  $\theta \in \mathbf{R}^K$  是切比雪夫系数,  $\tilde{L} = 2(L - I_N)/\lambda_{\max}$ ,

$\lambda_{\max}$  为拉普拉斯矩阵的最大特征值。将切比雪夫多项式扩展,通过图卷积提取每个节点来自第 0 至第  $K-1$  个邻节点的空间依赖性。最后,该图卷积模块采用 ReLU 函数  $\phi$  作为激活函数得到输出  $\phi(g_{\theta} * c x)$ 。

将空间图卷积层的输出维度转化为  $\mathbf{R}^{F \times N \times T_r}$  后,该模块在时序片段上采用尺度为  $1 \times 3$  的卷积核进行卷积,步长设置为  $1 \times N_r$  以调整时间跨度。为了确保输出的尺寸匹配,设置 padding=(0,1) 进行填充。以第  $r$  层为例,

$$X^{(r)} = \phi \left( \Phi * \left[ \text{ReLU}(g_{\theta} * c \hat{X}^{(r-1)}) \right] \right) \in \mathbf{R}^{F \times N \times T_r},$$

其中 \* 为标准卷积运算,  $\Phi$  为时间维度上的卷积核。

随着网络层数的增加,训练过程容易出现网络退化的问题。因此,在时空卷积模块后引入了残差学习 (He et al., 2016)。经过周期性提取模块所得到的时序片段输入至卷积核的尺度为  $1 \times 1$  的标准二维卷积层,将所得到的结果与时空卷积模块的输出连接加和得到  $P_c$ 。

### 2.3 SE 层

本文引入 SE 通道注意力层自适应校正通道特征的重要性 (Hu et al., 2019)。如图 2 所示,SE 层包含 Squeeze、Excitation 两个部分。




图 2 SE 层示意图

Fig. 2 Diagram of the SE layer

Squeeze 将每一个通道,即形状为  $N \times T_a$  的特征图通过全局平均池化操作,压缩成  $1 \times 1$  的通道描述符,用于表示该通道的全局空间信息。该操作的表达式为

$$z_c = F_{sq}(P_c) = \frac{1}{N \times T_a} \sum_{i=1}^N \sum_{j=1}^{T_a} P_c(i, j).$$

Excitation 捕获通道间的依赖关系,SE 层利用两层全连接网络参数化门机制。每层全连接网络后嵌套一层 ReLU 激活函数,用于限制模型复杂度和优化训练过程。

$$s_c = F_{ex}(z, \mathbf{W}) = \sigma \left[ \mathbf{W}_2 \text{ReLU}(\mathbf{W}_1 z) \right],$$

其中  $\mathbf{W}_1 \in \mathbf{R}^{C' \times C}$ 、 $\mathbf{W}_2 \in \mathbf{R}^{C \times C'}$  是全连接网络中所学习的参数,  $r'$  为降维率,  $C$  为通道数,因此第一个全连接网络用于降维,捕捉通道之间的非线性关系;

第二个全连接网络将维度回增,为每个通道生成相应的权重。 $\sigma$  为 sigmoid 函数,可将权重限制在 0~1。将上述操作得到的权重,通过乘法逐通道加权到各输入的特征上,完成在通道维度上对原始特征的重标定。所得结果为  $\tilde{Y}_c = P_c s_c$ 。

### 2.4 最终融合层

各个并行时序片段经过上述模块处理后,已实现了对不同周期性下的多特征时空信息的提取。该层将通过卷积操作自适应地学习近期、日、周 3 种尺度的权重系数,实现对 3 种周期时序片段的融合。该操作如以下公式所示:

$$\hat{Y} = \mathbf{V}_r \Theta \hat{Y}_r + \mathbf{V}_d \Theta \hat{Y}_d + \mathbf{V}_w \Theta \hat{Y}_w,$$

式中  $\mathbf{V}_r$ 、 $\mathbf{V}_d$ 、 $\mathbf{V}_w$  是模型所学习的参数,反映了 3 种时间尺度的输出因子的权重。

## 3 数据集与多因素分析

### 3.1 数据介绍

本文采用 2022 年 6 月 19 日至 7 月 18 日深圳市公共充电桩平台实时获得的每 5 min 充电数据,包含充电负荷、充电桩占用数、实时电价、充电桩数目(快/慢)等参数。依据深圳市第 6 次居民出行调查的区域划分,数据集被划分为 247 个交通小区,以呈现城市出行空间格局下电动汽车充电负荷特征。气象数据来自中央气象台,包含每小时降水量、温度。为实现小时气象数据与充电负荷数据的时间粒度匹配,采取最近邻插值法对气象数据进行处理。为避免数据之间量纲不同带来的误差,数据集进行了 Zero-Mean 标准化处理。

### 3.2 多因素相关性分析

通过 Pearson 系数 ( $p$ ) 分析,得到实时电价、充电桩占用数、气象(降水、气温)、充电桩数目(快/慢/总充电桩数目)与充电负荷的相关性,如图 3 所示。可以发现,采取动态电价收费的小区充电负荷明显高于不采用动态电价小区,证实了动态电价对充电负荷的正面影响作用。同时,充电桩占用数与充电负荷具有强相关性,不同时间点上两者的 Pearson 系数达到 0.9 以上 (图 3b)。通过影响出行行为,天气状况间接影响 EV 充电负荷 (黄一修等, 2025)。降水量与充电负荷的变化趋势图 (图 3c) 揭示了其中的弱相关特征 ( $p$  约为 0.1~0.3)。对于任一充电站或小区,由于大多数充电用户对快充服务的普遍偏好,快充桩数目成为影响充电负荷的关键因素。图 3d 中,快充桩数目与充电负荷的相关性达到 0.897,快充桩数目多的小区通常具有更高的充电负荷量。

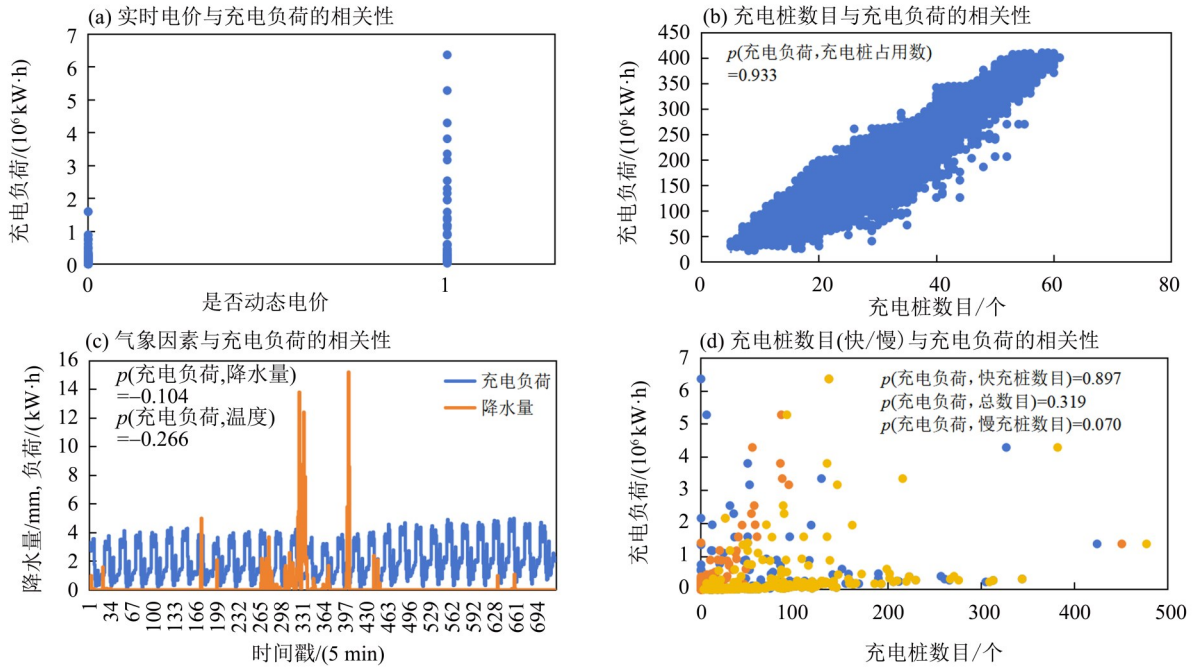


图3 多因素相关性分析

Fig. 3 Analysis of multiple factor correlations

## 4 模型验证与分析

### 4.1 模型参数与评价指标

充电负荷数据按照0.6、0.2、0.2的比例划分为训练集、验证集和测试集。将滑动窗口的长度设置为12,即预测未来1 h的负荷。模型中堆叠2个时空图卷积模块和SE层,空间图卷积中的切比雪夫多项式阶数设置为2,空间图卷积与时间卷积的卷积核大小均设置为64,SE层的reduction\_ratio(降维率)设置为4。实验采用均方误差(MSE)作为损失函数,批次大小设置为32,学习率设置为0.001。

为验证本研究方法的有效性,采用平均绝对误差

$$E_{MAE} = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|, \text{均方根误差 } E_{RMSE} =$$

$$\sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \text{ 和平均绝对百分比误差 } E_{MAPE} =$$

$$\frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right| \text{ 来评估模型的预测效果。}$$

### 4.2 多模型对比分析

为验证STGC-SENet模型的可行性,将STGC-SENet模型预测结果与LSTM(Su et al., 2023)、多视角时空图卷积网络(MSTGCN, multi-view spatial-temporal graph convolutional networks)(Guo et al., 2019)、基于注意力的时空图卷积网络(ASTGCN, attention based spatial-temporal graph convolutional network)(Guo et al., 2019)等基线模型的预测结果

进行了对比,具体情况如表1所示。

结果表明,STGC-SENet模型在3个评价指标上都取得了最优效果。STGC-SENet模型相比于基线模型(LSTM、MSTGCN、ASTGCN)的平均绝对误差分别下降了3.36、0.56、1.10,下降幅度分别为33.63%、7.78%、14.23%。其中,与基线模型中表现最好的MSTGCN相比,RMSE下降了0.38,下降幅度为1.44%;MAPE下降了0.19,下降幅度为47.50%;而训练一轮所需时间提升幅度为5.93%。STGC-SENet模型通过引入轻量级SE模块自适应校准各特征通道的权重,实现了重要特征的高效捕捉,在显著提升预测精度的同时,并未引入过多的计算开销。

### 4.3 多因素敏感性分析

**4.3.1 周期性因子的敏感性** 在不考虑其他因素的前提下,采用不同的周期性时序片段组合,评估分别加入近期(r)、日(d)、周(w)周期时序片段对模型预测性能的影响。如r1d2w0表示近期、日、周3种时序片段截取数量分别为1、2、0。当前时段充电负荷往往会直接作用于最近邻下一时间段,故3种周期性因子的对比实验皆以r1d0w0为原始对照组,实验结果如图4所示。

结果显示,伴随近期时序片段从r1d0w0增加到r4d0w0,模型预测误差不断增加。相反地,日周期时序片段数量的每一次增加,均给模型预测性能带

表 1 模型对比结果  
Table 1 Model comparison results

模型	MAE	RMSE	MAPE	训练一轮所需时间/s
LSTM	9.99	37.39	0.21	6.23
MSTGCN	7.19	26.28	0.40	18.2
ASTGCN	7.73	26.21	0.45	25.66
STGC-SENet	6.63	25.90	0.21	19.28

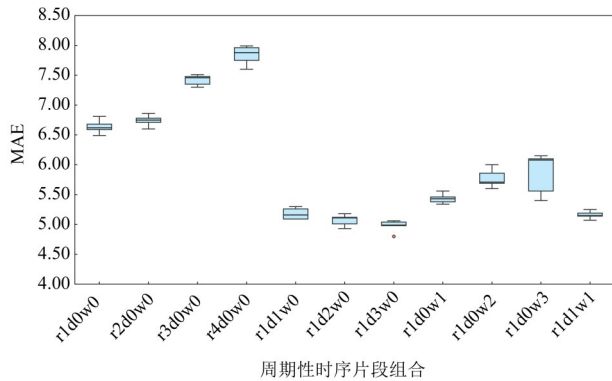


图 4 周期性因子的敏感性实验结果

Fig. 4 Results of the periodic factor sensitivity experiment

来一定程度的提升,  $r1d3d0$  相比于原始对照组, 其 MAE 从 6.63 降低至 4.97。由此可得, EV 充电负荷具有更强的日周期性, 日周期性因子的加入有效提高了模型预测精度。在周周期性因子融合实验中, 随着时序片段从  $r1d0w1$  到  $r1d0w3$ , 误差呈现上升趋势, 整体误差均高于日周期性因子融合下的预测效果。这一现象主要是因为实验所使用数据仅覆盖 1 个月, 截取 2 周甚至多周前的数据用于训练测试阶段将导致样本数量的不充足, 从而加剧了过拟合风险。然而, 相比于原始对照组  $r1d0w0$ , 融入最近邻周周期时序片段仍在一定程度上提升了预测效果, 证实了其有效性。

**4.3.2 输入因素的敏感性分析** 输入因素包括充电桩占用数  $F_o$ 、实时电价  $F_p$ 、充电桩数目加权系数  $F_n$  和降水量  $F_w$ 。将以上因素与充电负荷  $F_v$  进行组合, 形成  $T \times N \times F$  的张量输入至模型中。

$$F_n = 0.8 \times C_k + 0.2 \times C_m,$$

其中  $C_k$ 、 $C_m$  分别为快充数目、慢充数目, 以强化快充桩的贡献。本敏感性分析实验中, 所采取周期性因子组合为  $r1d1w1$ , 所有结果为多次实验的均值。不同因素组合下的预测结果如表 2 所示。

由表 2 可知, 同时融入充电桩占用数和实时电价, 模型预测效果最佳; 相比于只有充电负荷作为

输入的实验组, 其 MAE、RMSE、MAPE 的下降幅度分别为 1.74%、2.06% 和 11.11%。该结果证实了充电桩占用数与充电负荷高度相关, 反映了实时电价对充电行为的潜在作用。相反, 降水量的融入未能对模型预测效果带来性能上的提升, 可能的原因在于实验所使用的数据时间范围内, 罕有降雨天气或降水量较少, 且 1 h 间隔的降水量数据相对于 5 min 间隔的充电负荷数据存在大量数据缺失。尽管快充数目与充电负荷相关性较高, 但因充电桩数目加权系数的静态非时序变化属性, 其无法带来预测效果的提升, 需探索更精细的融合策略。对比表 2 中序号 6 与 9 的结果, 在同样的周期性时序片段组合与因素融合方式下, 本文 STGC-SENet 模型的表现仍优于 MSTGCN, 进一步验证了 STGC-SENet 对通道特征的重标定在多因素融合预测任务中的有效性。

#### 4.4 不同时间尺度的模型预测效果

从最优的模型预测结果中, 选取两个代表性交通小区(周期性强/弱的点位中各选取 1 个), 进行 5 min 和 1 h 时间尺度下的预测分析, 结果如图 5 所示。

对比图 5a 和 5b 可知, 强周期性小区预测效果明显优于弱周期性小区, 其误差曲线更平缓, 预测值更稳定。对比不同时间粒度下的预测值, 5 min 预测值与真实值贴合更为紧密, 1 h 预测值呈现一定滞后性。结果表明, 随着预测时长的增长, 模型预测误差逐渐增大。

## 5 结论

1) 本文的 STGC-SENet 模型在时空图卷积网络中嵌入了 SE 轻量化注意力模块。通过 Squeeze 和 Excitation 操作, 对时空图卷积输出的特征通道进行了重标定, 动态增强了关键特征的权重。充电负荷单独预测实验中, STGC-SENet 模型相比于基线模型(LSTM、MSTGCN、ASTGCN)的平均绝对误差分别下降了 3.36、0.56 和 1.10; 多因素融合实验中, 与

表 2 不同因素组合下的预测性能对比

Table 2 Prediction performance comparison under different factors fusion

序号	因素					MAE	RMSE	MAPE
	$F_v$	$F_o$	$F_p$	$F_n$	$F_w$			
1	√					5.17	16.50	0.27
2	√	√				5.10	16.36	0.25
3	√		√			5.16	16.29	0.27
4	√			√		5.32	16.54	0.34
5	√				√	5.26	16.41	0.30
6(STGC-SENet)	√	√	√			<b>5.08</b>	<b>16.16</b>	<b>0.24</b>
7	√	√		√		5.14	16.36	0.24
8	√	√			√	5.17	16.33	0.29
9(MSTGCN)	√	√	√			6.12	16.43	0.51

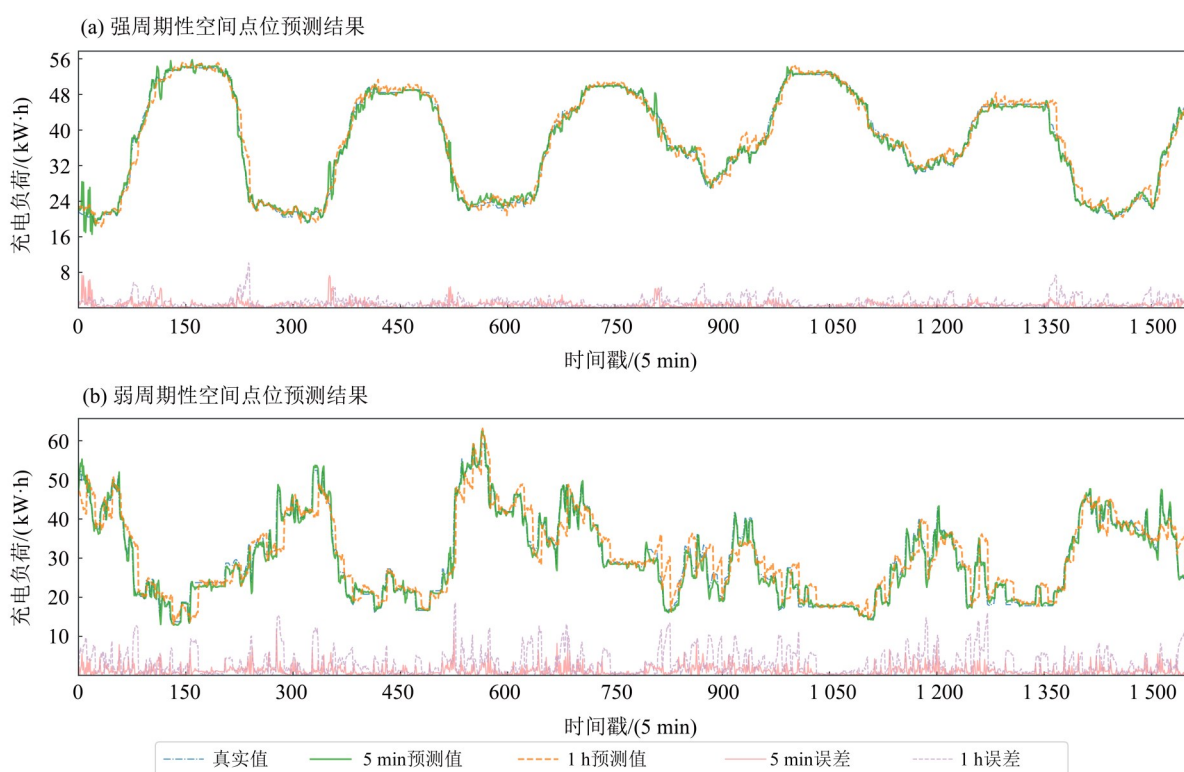


图 5 多时间尺度预测结果

Fig. 5 Multi-time-scale prediction results

最优基线模型 MSTGCN 相比, 本文模型也能实现预测效果提升, 证实了该模型在 EV 充电负荷多因素融合预测中的优势。

2) 实验采用多种周期性时序片段组合的方式, 分别评估了近期、日和周 3 类时序片段对模型性能的影响, 并证实了日周期时序片段的叠加与最近邻周周期片段的引入能够提升预测效果。

3) 本文融合了充电桩占用数、实时电价、充电

桩数目加权系数和降水量 4 种相关因素。实验表明, 在 EV 充电负荷预测任务中, 考虑充电桩占用数与实时电价的预测效果最优。

4) 未来的工作需扩大数据规模, 覆盖更长的时间跨度; 针对融合充电桩数目的充电负荷预测, 应探索更精细的融合策略。同时, 应引入交通流数据等, 研究与交通相关的因素对于 EV 充电负荷的影响。

## 参考文献:

- 黄学良,刘永东,沈斐,等,2024.电动汽车与电网互动:综述与展望[J].电力系统自动化,48(7):3-23.
- 黄一修,肖仕武,2025.考虑气象因素的高速公路服务区电动汽车充电负荷预测[J].电力自动化设备,45(1):192-199.
- 胡博,张鹏飞,黄恩泽,等,2022.基于图 WaveNet 的电动汽车充电负荷预测[J].电力系统自动化,46(16):207-213.
- 李波,王宁,吕叶林,等,2024.考虑环境因素的电动汽车充电站实时负荷预测模型[J].同济大学学报,52(6):962-969.
- 李宏伟,宋玉峰,李帅兵,等,2025.基于 ArcGIS 路网结构与交通拥挤度分析的电动汽车充电负荷预测方法[J].电网技术,49(5):1920-1930.
- 刘赏,陈浩,陈小玉,等,2023.面向交通流预测的双分支时空图卷积神经网络[J].信息与控制,52(3):391-404+416.
- 马恒瑞,袁傲添,王波,等,2025.基于深度学习的负荷预测研究综述与展望[J].高电压技术,51(3):1233-1250.
- 秦建华,潘崇超,张璇,等,2023.基于充电行为分析的电动汽车充电负荷预测[J].电测与仪表,60(4):19-26.
- 王长春,王果,赵倩宇,等,2024.考虑分时电价和充电利用率特征的大型电动汽车充电站负荷短期预测方法[J].南方电网技术,18(5):75-84.
- 杨建喜,郁超顺,李韧,等,2021.基于多周期组件时空神经网络的路网通行速度预测[J].交通运输系统工程与信息,21(3):112-119+139.
- 张夏韦,梁军,王要强,等,2023.电动汽车充电负荷时空分布预测研究综述[J].电力建设,44(12):161-173.
- GUO S, LIN Y, FENG N, et al, 2019. Attention based spatial-temporal graph convolutional networks for traffic flow forecasting [C]// AAAI Conference on Artificial Intelligence. Keystone, USA:922-929.
- HAO G J, YANG J, XU Q, et al, 2024. Prediction of urban electric vehicle charging load based on Monte Carlo method [C]//The 5th International Conference on Advanced Electrical and Energy Systems. Lanzhou, China:473-477.
- HE K, ZHANG X, REN, S, et al, 2016. Deep residual learning or image recognition [C]//IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, USA: 770-778.
- HU J, SHEN L, ALBANIE S, et al, 2019. Squeeze-and-Excitation networks [EB/OL]. (2019-05-16) [2025-05-20]. <https://arXiv.org/abs/1709.01507>.
- HUANG R Z, HUANG C Y, LIU Y B, et al, 2021. LSGCN: Long short-term traffic prediction with graph convolutional networks [C]// The 29th International Joint Conference on Artificial Intelligence. Yokohama, Japan: 2355-2361.
- KIM H J, KIM M K, 2024. Spatial-temporal graph convolutional-based recurrent network for electric vehicle charging stations demand forecasting in energy market[J]. IEEE Trans Smart Grid, 15(4):3979-3993.
- SU Z P, YU Z W, MA L, 2023. Short-term load prediction of electric vehicle charging station based on Long-short-term memory neural network [C]// International Conference on Computer Engineering and Intelligent Control. Guangzhou, China: 595-599.
- WANG Y C, LI X C, YUAN R M, et al, 2024. Electric vehicle charging load prediction model based on improved LSTM neural network [C]//International Conference on Energy Systems and Electrical Power. Wuhan, China:1505-1509.
- YAN S J, XIONG Y J, LIN D H, et al, 2018. Spatial temporal graph convolutional networks for skeleton-based action recognition [C]// AAAI Conference on Artificial Intelligence. New Orleans, USA:7444-7452.

(责任编辑 王海蓉)