

文章编号:1671-1637(2026)06-0186-12

融合前后文时空交叉注意力机制的 网约车需求预测

赵霞^{1,2}, 石卓雅^{1,2}, 李之红^{*1,2}, 刘剑锋³, 吴梦琳^{1,2}, 李晨继^{1,2}

(1. 北京建筑大学 人工智能+研究院, 北京 102616; 2. 北京建筑大学 智慧道路与交通研究中心,
北京 102616; 3. 北京城建交通设计研究院有限公司, 北京 100050)

摘要:为精准表征乘客在特定地理空间的频繁出行时间偏好或在特定时间范围的频繁访问空间喜好,提出了一种融合前后文时空交叉注意力机制的网约车需求预测模型 ST-BiAformer,通过构建前后文时间关联模块,捕捉出行需求在时序维度的依赖特性;设计时空交叉注意力机制模块,交叉捕捉特定时间(或空间)语境下的空间(或时间)关联信息,挖掘了出行需求在特定时空维度的频繁访问模式;在此基础上构建时空融合模块,增强了对出行需求单步及多步的预测性能;所提模型应用于多个数据集中,通过系列对比、消融和鲁棒性分析试验,评估了其在不同时空场景的预测性能。研究表明:平均绝对误差和均方根误差较最优基线模型分别降低了 7.21% 和 5.54%,验证了模型在整体预测性能上的提升;在 5、10、15 min 出行需求预测任务中,这 2 类误差均降低了 1%~7%,表明模型具备良好的单步及多步预测性能;当且仅当所建三大子模块共同作用时,模型能够全面建模出行需求在前后文时间及时空关联维度的依赖特性,进而取得最佳预测性能。所提模型有望精准匹配用户在不同时段(或空间)异质空间(或时间)场景的出行需求,为提升城市网约车的供需调度水平提供技术支持。

关键词:城市交通;出行;注意力机制;网约车需求预测;ST-BiAformer 模型;前后文时空关联;时空融合

中图分类号:U491 文献标志码:A DOI:10.19818/j.cnki.1671-1637.2026.075

Forecasting ride-hailing demand via contextual spatiotemporal cross-attention mechanism

ZHAO Xia^{1,2}, SHI Zhuo-ya^{1,2}, LI Zhi-hong^{*1,2}, LIU Jian-feng³, WU Meng-lin^{1,2}, LI Chen-ji^{1,2}

(1. Institute of Artificial Intelligence, Beijing University of Civil Engineering and Architecture, Beijing 102616, China; 2. Smart Road and Transportation Research Center, Beijing University of Civil Engineering and Architecture, Beijing 102616, China; 3. Beijing Urban Construction & Transportation Design & Research Institute Co., Ltd., Beijing 100050, China)

Abstract: To accurately characterize passengers' temporal preferences for frequent travel within specific geographic areas, or their spatial preferences for frequently visited locations within given time windows, this paper proposed a ride-hailing demand prediction model named ST-BiAformer

出版历程:2025-04-01 收稿,2025-08-24 修回,2025-09-26 录用

基金项目:国家自然科学基金项目(52402377);北京市自然科学基金项目(8252005)

作者简介:赵霞(1987-),女,江西鹰潭人,副教授,博士,E-mail:zhaoxia@bucea.edu.cn。

*通信作者:李之红(1981-),男,河北秦皇岛人,教授,博士生导师,博士,E-mail:lizhihong@bucea.edu.cn。

引用格式:赵霞,石卓雅,李之红,等.融合前后文时空交叉注意力机制的网约车需求预测[J].交通运输工程学报,2026,26(6):186-197.

Citation: ZHAO Xia, SHI Zhuo-ya, LI Zhi-hong, et al. Forecasting ride-hailing demand via contextual spatiotemporal cross-attention mechanism[J]. Journal of Traffic and Transportation Engineering, 2026, 26(6): 186-197.

(Spatiotemporal Bidirectional Association Transformer), which integrates a contextual spatiotemporal cross-attention mechanism. The model captured sequential dependencies in travel demand by constructing a contextual temporal correlation module; designed a spatiotemporal cross-attention mechanism to cross-extract spatial (or temporal) dependencies within specific temporal (or spatial) contexts, thereby revealing recurrent travel demand patterns along targeted spatiotemporal dimensions; and further developed a spatiotemporal fusion module to enhance the model's performance in both single-step and multi-step demand forecasting. The proposed model was evaluated on multiple datasets through a series of comparative, ablation, and robustness experiments, assessing its predictive performance under various spatiotemporal scenarios. Experimental results demonstrate that, compared with the optimal baseline model, the mean absolute error and root mean square error are reduced by 7.21% and 5.54%, respectively, demonstrating improved overall prediction accuracy. In the 5 min, 10 min, and 15 min forecasting tasks, both error metrics decrease by 1% - 7%, indicating sound single-step and multi-step predictive capability. The model achieves the best performance only when all three constituent submodules work jointly, enabling comprehensive modeling of travel demand dependencies along both contextual temporal and spatiotemporal correlation dimensions. The proposed model is expected to precisely match users' ride-hailing demands across heterogeneous spatiotemporal scenarios at different time periods or locations, thereby providing technical support for enhancing supply-demand scheduling in urban ride-hailing services.

Keywords: urban traffic; travel; attention mechanism; ride-hailing demand forecasting; ST-BiAformer model; contextual spatiotemporal correlation; spatiotemporal fusion

Publication history: Received 2025-04-01; Received in revised form 2025-08-24; Accepted 2025-09-26

Funding: National Natural Science Foundation of China (52402377); Natural Science Foundation of Beijing (8252005)

* **Corresponding author:** LI Zhi-hong, professor, PhD, E-mail: lizhihong@bucea.edu.cn.

0 引言

城市网约车在交通拥堵频发、车牌限号出行、互联网经济的大背景下应运而生,以便捷性、灵活性、经济性服务于广大居民,带动网约车出行市场迅速发展;但也因网约车出行需求预测不准面临供需失衡挑战^[1]。这种供需失衡现象在城市高峰时段、交通枢纽尤为严重^[2],诱发乘客等车时间长、司机空驶率高等问题。精准预测网约车出行需求,是优化网约车资源配置、提高网约车服务水平、提升乘客出行满意度的核心关键。

目前,国内外学者分别建模了网约车出行需求在空间、时间和时空维度的关联特性,来提升其预测精度^[3-4]。空间维度,现有研究主要利用图卷积网络模型建模道路交通网络的物理拓扑关系,在此基础上构建邻接矩阵,表征出行需求在局部空间的依赖性,构建交通需求预测的基础框架^[5-6]。时间维度,现有研究通过捕捉时间序列的长短时依赖特性,

以提升其预测精度。例如,LSTM与GRU通过门控机制刻画时间序列的短期滞后效应,但对长时依赖的捕获性能不佳^[7-8]。BiLSTM依托双向神经网络结构刻画时间序列的前后文关联特性,但受限于网络的迭代效率难以建模潜在的长时依赖特性^[9]。Transformer模型^[10-12]凭借自注意力机制有效突破上述局限。这种优势也体现在它的变体结构Informer和Autoformer中,前者通过ProbSparse注意力优化计算复杂度,实现时间序列的高效全局感知;后者将自相关机制替代自注意力,结合时间序列趋势-季节性分解机制,以适应非平稳时序数据的时空预测^[13-14]。然而,此类方法多关注在空间或时间的全局建模,尚未利用局部的关键时空序列来提升对目标序列的预测精度,致使对交通数据的突发波动预测不准^[15]。基于此,最新研究融合注意力机制,来增强对交通需求的预测性能。例如,Liu等^[16]提出融合六边形卷积网络与短时记忆结构,以应对空间粒度划分不均带来的数据缺失问题。Yan

等^[17]将注意力机制引入图卷积神经网络,构建了时空感知预测模型,有效捕捉了交通数据的关键时空特征,支撑提升其预测精度。Huo 等^[18]针对交通数据潜藏的时空异质性问题,提出一个融合多图卷积与 Transformer 的预测模型,用于交通需求的预测任务。为解决注意力机制局部建模不足的问题, Pdformer 构建了图掩码矩阵和局部数据感知矩阵,以提升模型对局部异质分布模式的表征能力^[11]。STFGNN 建模了多尺度空间与时间的耦合依赖特性,攻克了特定时间语境下的异质空间分布建模问题^[19]。GraphWaveNet 在未构建先验图结构的基础上学习数据的时空动态关联特性,增强模型对交通数据潜在时空关联特性的自适应建模能力^[20]。Prob-GNN 通过概率图神经网络量化交通数据的时空分布不确定性,有效应对大流量冲击下的预测不确定性^[21]。TSGDiff 融合出行环境、出行需求分布、道路拓扑网络等多源信息,对其进行扩散卷积操作,以有效感知特定环境下的交通数据时空分布特性,克服模型的跨场景不适应性^[22]。MoGERNN 则建模了异构空间下的交通数据时空演化特性,攻克了特定空间语境下的异质时间分布建模问题^[23]。上述预测模型在捕捉交通数据的时空关联特性方面各有特点,但对于特定空间(或时间)语境下的异质时间(或空间)分布建模能力仍有待提升,难以精准表征乘客在特定地理空间的频繁出行时间喜好或在特定时间范围的频繁访问空间喜好。有必要构建一种考虑前后文时空交叉注意力的网约车出行需求预测模型,使其有效建模出行需求在特定空间(或时间)语境下的异质时间(或空间)交叉分布特性,从而提升出行需求的预测性能。

基于此,本文提出一种融合前后文时空交叉注意力机制(Spatiotemporal Bidirectional Association Transformer, ST-BiAformer)模型,来开展网约车出行需求的预测研究。ST-BiAformer 模型首先立足时间维度,设计前后文时间关联规则,捕捉网约车出行需求的双向时间依赖特性;其次立足时空维度,设计时空交叉注意力机制模块,挖掘网约车出行需求在特定时空维度的频繁访问模式;最后构建时空融合模块,整合上述时空交叉关联特性,实现对网约车出行需求单步及多步的精准预测效果。研究将所提模型运用于多个出行数据集上,通过系列对比、消融和鲁棒性分析试验,证实它及其内置模块具有良好的预测性能。研究成果可为优化网约车资源配置、提高网约车服务水平、提升乘客出行满意度提供

有力决策支持。

1 问题描述

依托 3 个网约车出行数据集来开展相关研究。以厦门市 2019 年 1 月 1 日~2019 年 1 月 31 日的数据集为例,首先对网约车出行数据进行预处理操作,包括:删除重复订单;删除上下车时间一致、出行字段缺失等错误记录;删除乘车时间短于 2 min 的过短异常记录;聚焦网约车出行数据中的关键缺失字段,使用 K -近邻方法在特征空间中寻找与其相似的一个邻居,取它们的均值作为缺失字段的填充依据,最终获取 1.7 亿条的有效出行记录。

参考既有研究方法,以 5 min 为单位时间步长对所有出行记录进行切片,由此将研究范围划分为 8 928 个时间间隔^[2]。出于对乘客 1 km 最优步行距离、相对最优计算性能及数据输入规范性的考虑,进一步采用 1 km $\times$ 1 km 的栅格均匀分割研究范围,最终获取 2 519 个空间栅格。对应统计每个栅格在任一时间间隔的出行需求总量,构成出行需求时空分布矩阵 $\mathbf{X} \in \mathbf{R}^{N \times T}$,其中, N 为栅格总数, T 为时间间隔总数, $\mathbf{X}_t = (x_{t,1}, \dots, x_{t,N})$ 为所有栅格在时间间隔 t 的出行需求向量, $x_{t,n}$ 为第 n 个栅格在时间间隔 t 的网约车出行需求量。基于上述定义,将本文的出行需求预测任务抽象为:根据历史 M 个时间间隔的出行需求时空分布矩阵,预测未来 K 个时间间隔的出行需求时空分布矩阵为 $\hat{\mathbf{X}} = (\mathbf{X}_{t+1}, \mathbf{X}_{t+2}, \dots, \mathbf{X}_{t+K}), \hat{\mathbf{X}} \in \mathbf{R}^{N \times K}$ 。

2 ST-BiAformer 模型构建

ST-BiAformer 模型的总体架构如图 1 所示,它包含 3 个模块:①前后文时间关联模块,通过引入双向 Transformer 结构,分别建模时间序列中正向与逆向的依赖关系,捕捉乘客出行需求在时间维度的前后文关联特性;②时空交叉注意力机制模块,交叉捕捉特定时间(或空间)语境下的空间(或时间)关联信息,挖掘出行需求在特定时空维度的频繁访问模式;③时空融合模块,利用注意力机制融合①和②模块输出的特征,捕捉乘客出行需求在时空维度的加权关联特性,有效建模乘客在特定地理空间的频繁出行时间喜好或在特定时间范围的频繁访问空间喜好,进而增强模型对网约车出行需求的预测性能。

2.1 前后文时间关联模块

在时间维度上,出行行为受工作日与周末的时序规律、突发事件等因素的持续影响,在总体趋势上




图 1 ST-BiAformer 模型结构

Fig. 1 ST-BiAformer model structure

表现出明显的周期性及相邻时段间的高度关联性。因此,本文提出了一种考虑前后文时间关联的预测模块,在双向时间序列编码的基础上,显式整合当前时间点与其他时间点的前后文依赖关系,同时结合关联规则进行约束性增强。前后文时间关联模块将历史网约车出行需求数据序列进行编码,以捕获连续时间序列的模式和趋势,并创新性嵌入关联规则,将先验知识融入时间建模过程,增强模型对出行需求特征矩阵中潜在周期性和重复性的捕捉能力。

经过时序编码之后,将信息输入图 1 所示的前后文时间关联模块中,在时序编码中实现相对位置的编码,使模型更好地捕捉出行需求在连续多步的依赖关系。此外,ST-BiAformer 模型还嵌入关联规则,通过识别高度关联的关键信息来源,来增强多步预测的性能。具体来说,模型基于全区域、全时段的历史需求数据,计算各区域之间在完整时间维度上的出行行为模式关联性。关联度由指标 $R_{t,t+1} \in [0, 1]$ 表征,评估各区域历史出行行为模式之间的时间关联程度。当关联度 $R_{t,t+1} \geq 0.7$ 时,代表强关联度,可跳过预估计算,直接使用 Transformer 正向、逆向架构计算综合时间特征。关联度的计算方法如下所示

$$R_{t,t+1} = \frac{\text{Cov}(\tilde{\mathbf{X}}_t, \tilde{\mathbf{X}}_{t+1})}{\sigma_{\tilde{\mathbf{X}}_t} \sigma_{\tilde{\mathbf{X}}_{t+1}}} \quad (1)$$

式中: $\tilde{\mathbf{X}}_t$ 为时间步 t 对应的全区域需求量特征; $R_{t,t+1}$ 为时间步 t 与 $t+1$ 之间的关联度; $\text{Cov}(\tilde{\mathbf{X}}_t, \tilde{\mathbf{X}}_{t+1})$ 为 $\tilde{\mathbf{X}}_t$ 和 $\tilde{\mathbf{X}}_{t+1}$ 之间的协方差; $\sigma_{\tilde{\mathbf{X}}_t}$ 为 $\tilde{\mathbf{X}}_t$ 的标准差。

若关联度 $R_{t,t+1} < 0.7$, 模型则判定该区域行为不具备强关联性,使用式(2)估算需求量特征矩阵

$$\hat{\mathbf{X}}_{\text{opt}}$$

$$\begin{cases} \hat{\mathbf{X}}_{\text{opt}} = \alpha(\tilde{\mathbf{X}}_{\text{opt}} + m\Delta\tilde{\mathbf{x}}_{\text{opt}}) + \frac{\beta m^2 \Delta\tilde{\mathbf{x}}_{\text{opt}}^2}{2} \\ \Delta\tilde{\mathbf{x}}_{\text{opt}} = \tilde{\mathbf{X}}_{t+1} - \tilde{\mathbf{X}}_t \\ \Delta\tilde{\mathbf{x}}_{\text{opt}}^2 = \Delta\tilde{\mathbf{x}}_{t+1} - \Delta\tilde{\mathbf{x}}_t \end{cases} \quad (2)$$

式中: $\tilde{\mathbf{X}}_{\text{opt}}$ 为输入特征矩阵,包括输入正向输入需求特征矩阵 $\tilde{\mathbf{X}}_{t \rightarrow t+1}$ 和逆向输入需求特征矩阵 $\tilde{\mathbf{X}}_{t+1 \rightarrow t}$; m 为时间步间隔; α 和 β 均为动态调整的权重; $\Delta\tilde{\mathbf{x}}_{\text{opt}}$ 为需求量的变化矩阵; $\Delta\tilde{\mathbf{x}}_{\text{opt}}^2$ 为需求二阶变化矩阵; $\hat{\mathbf{X}}_{\text{opt}}$ 为初步预估需求量特征矩阵。

具体来说,式(2)是类比时间序列的泰勒展开思想设计的。引入了项 1: $\alpha(\hat{\mathbf{X}}_{\text{opt}} + m\Delta\tilde{\mathbf{x}}_{\text{opt}})$ (表示线性趋势外推,模拟需求平稳变化下的行为),项 2: $(\beta m^2 \Delta\tilde{\mathbf{x}}_{\text{opt}}^2)/2$ (捕捉突变趋势)构建初步预测结构。并通过可学习权重 α, β 控制趋势与加速度项的影响力,以增强模型对短期波动的适应能力。

前后文时间关联模块可以通过正向和逆向 Transformer 架构,使用多头注意力机制构建历史时间步之间的依赖关系,考虑网约车需求序列中每个位置的前后文信息,提升时序特征的表达能力,如下所示

$$\mathbf{B}_t = \text{Concat}[\text{Transformer}(\tilde{\mathbf{X}}_{t \rightarrow t+1}), \text{Transformer}(\tilde{\mathbf{X}}_{t+1 \rightarrow t})] \quad (3)$$

式中: $\mathbf{B}_t$ 为 BiAformer 的输出; $\text{Concat}(\cdot)$ 为拼接函数。

最终,将正向与逆向时间特征进行拼接,融合前后文信息,形成综合时间特征 $\mathbf{B}_t$ 。

2.2 时空交叉注意力机制模块

单纯建模乘客在邻近地理空间的出行依赖性难以刻画其频繁访问的时空分布区域,可能削弱出行

需求预测的效果。基于此,本文在构建前后文时间关联模块的基础上,进一步设计时空交叉注意力机制,包含空间交叉注意力机制和时间交叉注意力机制,并有机融合,确保在不丢失前后文时间关联特性(或空间关联特性)的基础上,有效捕捉乘客的最频繁访问空间分布区域(或时间分布区域),增强模型对目标单元出行需求的时空预测性能。

每类注意力机制的设计思路均遵循“加权相似度计算→权重归一化映射→关键信息提取”的工作原理。本文重点阐述空间交叉注意力机制的量化方式,使前后文时间关联特性有效融入出行需求的空间建模过程,实现“空间交叉时间”的建模效果,有效捕捉乘客在特定时间语境下的最频繁访问空间分布区域 A_s 。 A_s 的计算方式如式(4)所示

$$\begin{cases} Q_s = B_{st} W_q \\ K_s = B_s W_k \\ V_s = B_s W_v \\ A_s = \text{Attention}(Q_s, K_s, V_s) = \\ \quad \text{softmax}\left(\frac{Q_s K_s^T}{\sqrt{d_{k_t}}}\right) V_s \end{cases} \quad (4)$$

式中: W_q 、 W_k 、 W_v 分别为 Q_s 、 K_s 、 V_s 的权重矩阵; d_{k_t} 为查询或键向量的维度。

具体而言,所建模型依托全区域、全时段的历史需求数据 X ,利用 Transformer 模型,量化表征各区域的隐含空间特征 $B_s = \text{Transformer}(X)$ 。将空间特征 B_s 与第 2.1 节输出的前后文时间特征 B_t 逐元素相乘,获取时空融合特征 $B_{st} = B_s \odot B_t$,使每个空间节点交叉感知前后文时间关联特性,又使每个时间节点交叉感知空间关联特性。

进一步令时空融合特征 B_{st} 为查询向量的基础,确保在不丢失前后文时间关联特性的基础上,对其进行空间线性变换,生成空间查询向量 Q_s 。此外,对空间特征 B_s 进行 2 次不同的线性变换,分别生成空间键向量 K_s 和空间值向量 V_s ,并计算二者的加权乘积 $Q_s K_s^T$,获取目标单元(特定出行需求)与其他空间单元的空间加权相似度,表达它们在既定时间语境下的空间关联特性;并通过激活函数 softmax 将上述相似度归一,映射为 $[0, 1]$ 范围内的概率分布,支撑模型精准捕捉目标单元的时空强相关单元,实现“空间交叉时间”的建模效果,有效捕捉乘客在特定时间语境下的最频繁访问空间分布区域 A_s 。

依据上述空间交叉注意力机制的量化方式,可同理表征时间交叉注意力机制,使空间关联特性有效融入出行需求的前后文时间建模过程,实现“时间

交叉空间”的建模效果,有效捕捉乘客在特定空间语境下的最频繁访问时间分布区域。

2.3 时空融合模块

出行行为不仅受时间因素的影响,还受到空间位置、区域功能属性等综合影响,表现出明显的时空特性。因此,在时空交叉注意力机制模块聚焦于当前时空状态最具相关性的时间和空间区域后,使用时空融合模块通过时间解码器和空间解码器分别生成时间解码特征 H_t 和空间解码特征 H_s 表示后,分别进行变换拼接后,使用 Sigmoid 函数用于生成归一化的门控系数,以控制时间与空间特征在融合过程中的相对权重。其输出范围为 $[0, 1]$,能够调节对时间特征以及空间特征的偏好程度。通过逐元素乘法分别加权时间和空间特征,实现细粒度的信息融合。

本文在时空融合模块中引入了门控融合机制。该机制通过门控向量自适应调节 2 种特征的重要性,实现信息的深度融合,如式(5)、(6)所示

$$G = \sigma(W_t H_t + W_s H_s) \quad (5)$$

$$H_f = G \odot H_t + (1 - G) \odot H_s \quad (6)$$

式中: W_t 和 W_s 均为可学习的权重矩阵; $\sigma(\cdot)$ 为 Sigmoid 激活函数; G 为门控系数; $\odot$ 为逐元素乘法; H_f 为时空融合解码特征。

3 试验结果分析

所提模型应用于三大数据集上,即:厦门市网约车出行需求自有数据集、NYC_Taxi 和 BJ_Taxi 公开数据集,来验证本文模型的跨场景适用性。NYC_Taxi 数据集涵盖 2023 年 3 月纽约市出租车出行需求分布情况;BJ_Taxi 数据集包含 2017 年 4 月北京市出租车出行需求分布情况。通过系列对比、消融和鲁棒性分析试验,以评估所提模型及其内部模块的预测性能。基于 PyTorch 深度学习框架,完成第 2 节中模型架构与训练流程的构建。所有流程运行在“13th Gen Intel(R) Core(TM) i7-13700F @2.10 GHz”CPU 和“Nvidia GeForce RTX 4090”GPU 显卡环境。

3.1 基线模型选取及试验环境设置

选取 15 种基线模型与本文所提 ST-BiAformer 进行性能对比。它们分别为建模空间关联性的 GCN^[24],建模时间关联性的 LSTM^[7]、GRU^[8]、BiLSTM^[9]、Transformer^[12]、Informer^[13]、Autoformer^[14],建模时空关联性的 STGCN^[25]、GST-MGCN^[26]、MVSTGCN^[27]、STTN^[28]、STFGNN^[19]、

GraphWaveNet^[20]、Pdformer^[11]、MoGERNN^[29]。以下简要介绍近几年极具竞争力的几大基线模型的工作原理及参数配置方式。

Informer^[13]:通过提出 ProbSparse 注意力机制,减少时间序列建模的计算复杂度,同时保留全局注意力感知能力,适合连续时间跨度的高效预测任务。

Autoformer^[14]:是一种 Transformer 变体,提出了时间序列趋势-季节性分解机制,并引入自相关注意力机制替代传统自注意力,从而更适应具有非平稳趋势的时序数据。对于 Transformer 及 Informer、Autoformer 内置的 Transformer,其编码器和解码器的网络参数均配置为 512-1024-1024-512。

Pdformer^[11]:引入了 2 个图掩码矩阵以及交通延迟感知的特征转换模块,以建模空间不同尺度下的空间关联性,从而提升模型对动态传播模式的表征能力与预测准确性。

STFGNN^[19]:通过构建多尺度空间图结构,结合图注意力机制动态融合空间关系,构建分层式时空动态融合机制,建模数据的潜在时空分布模式。

GraphWaveNet^[20]:引入自适应邻接矩阵学习机制与门控卷积网络,建模动态时空依赖,在无先验图结构的条件下学习交通网络中潜在的图连接模式。

MoGERNN^[23]:构建图专家混合(MoGE)机制并结合图编码器-解码架构,实现节点的异质空间依赖捕捉和时间演化建模。对于 Pdformer、STFGNN、GraphWaveNet 和 MoGERNN,其时间模块网络参数配置为 256-512-512-256,空间模块网络参数配置为 256-512-512-512。

按照 7:2:1 的比例将数据集划分为训练集、验证集和测试集^[30]。采用滑动时间窗的方式,依据历史连续 3 个小时的出行需求时空分布,来分别预测未来 5、10、15 min 的出行需求时空分布。采用 AdamW 优化器对所有模型进行 100 次迭代训练;并引入十倍交叉验证方式,统计各项评估指标的平均值,作为最终评价结果,以减少随机性的影响^[29]。在对比试验中,所有对比模型均使用与本文所提出模型相同的输入时空矩阵。

为保障对比试验的公平性,参考被选基线模型的参数配置方式来设定所提 ST-BiAformer 模型的超参数。例如,将学习率设置为 0.001,批量大小设置为 32,将模型的 Transformer 网络结构层设置为

4 个,每层包含 8 个多头注意力机制。

3.2 评价指标选取

选取 2 种经典指标来评估各类模型的预测性能。它们分别是平均绝对误差(Mean Absolute Error, MAE) E_{MAE} 和均方根误差(Root Mean Square Error, RMSE) E_{RMSE} 。评估指标值越低,说明模型的性能越好,计算如下

$$E_{MAE} = \frac{1}{N} \sum_{i=1}^N |y_i - \bar{y}_i| \quad (7)$$

$$E_{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \bar{y}_i)^2} \quad (8)$$

3.3 对比试验结果分析

各模型对网约车出行需求的预测结果如表 1 所示。总体而言,给定时空预测模型的性能大都优于仅聚焦空间或时间的传统基线模型,如:GCN、LSTM、GRU、BiLSTM、Transformer。这类单一维度模型仅建模了网约车出行需求在空间或时间维度的关联特性,对潜在时空关联特性的考虑不足,致使预测性能不高。反观融合时空关联特性的模型,ST-BiAformer 仍能取得优于 STFGNN、GraphWaveNet、Pdformer、MoGERNN 等基线的预测性能,根源在于前者有效整合了前后文时间关联模块、时空交叉注意力机制模块和时空融合模块,使其有效捕捉乘客频繁访问的时空区域,以提升网约车出行需求的预测精度。需要指出的是,近 3 年涌现出若干时间交叉注意力机制驱动的时序模型,如 Informer、Autoformer,呈现出更好的时间关联特性捕捉能力,十分胜任时空数据的预测任务。尽管如此,ST-BiAformer 模型仍能在单步、两步及三步预测任务中呈现较高的时间鲁棒性,表现为单步预测性能最优,两步及三步预测性能次之。这证实了 ST-BiAformer 不仅具有强大的时空依赖特性建模能力,也能有效避免由多步预测引来的误差累积弊端。这些优势归根结底源于 ST-BiAformer 对前后文时间关联模块、时空交叉注意力机制和时空融合模块的整合优势。以三步预测任务为例,ST-BiAformer 模型的 MAE 和 RMSE 相较于次优模型 MoGERNN,在厦门数据集上分别降低了 1.54% 和 1.80%,在 NYC_Taxi 数据集上分别降低了 6.15% 和 5.31%,在 BJ_Taxi 数据集上分别降低了 7.21% 和 5.54%,可见所提模型在 3 个数据集上均能取得优于给定基线模型的预测性能。

3.4 消融试验结果分析

对所提模型的内置模块重新组合,生成如表 2

表 1 模型多步预测试验比较结果

Table 1 Compared results of multi-step prediction experiment models

模型	厦门数据集						NYC_Taxi 数据集						BJ_Taxi 数据集					
	5 min		10 min		15 min		5 min		10 min		15 min		5 min		10 min		15 min	
	E_{MAE}	E_{RMSE}	E_{MAE}	E_{RMSE}	E_{MAE}	E_{RMSE}	E_{MAE}	E_{RMSE}	E_{MAE}	E_{RMSE}	E_{MAE}	E_{RMSE}	E_{MAE}	E_{RMSE}	E_{MAE}	E_{RMSE}	E_{MAE}	E_{RMSE}
GCN ^[24]	3.44	4.80	4.92	5.99	5.94	7.55	3.83	5.02	4.32	5.93	5.15	6.25	4.46	6.42	4.59	6.81	5.17	7.23
LSTM ^[7]	3.08	4.64	3.81	4.96	4.31	5.56	2.98	4.09	3.01	4.32	3.04	4.39	4.07	5.56	4.25	5.79	4.51	6.19
GRU ^[8]	2.91	4.16	3.60	4.68	4.07	5.25	2.89	3.97	2.92	4.03	2.97	4.13	4.05	5.60	4.27	5.95	4.47	6.25
BiLSTM ^[9]	2.80	4.04	3.47	4.52	3.92	5.05	2.70	3.92	2.73	3.94	2.75	3.94	3.53	4.75	3.64	5.01	3.69	5.08
Transformer ^[12]	2.79	3.81	3.43	4.73	3.75	4.83	2.54	3.45	2.57	3.51	2.61	3.63	3.42	4.47	3.56	4.72	3.61	4.87
Informer ^[13]	2.56	3.43	2.88	3.87	3.34	4.56	1.89	2.51	1.92	2.62	1.96	2.68	3.15	4.02	3.19	4.07	3.27	4.21
Autoformer ^[14]	2.35	3.08	2.83	3.81	3.30	4.56	1.77	2.18	1.82	2.27	1.84	2.36	3.12	3.86	3.17	3.92	3.22	4.12
STGCN ^[25]	2.74	3.58	3.30	4.41	3.81	4.98	2.47	3.39	2.55	3.50	2.63	3.64	3.28	4.37	3.35	4.41	3.43	4.49
GST-MGCN ^[26]	2.52	3.30	2.93	4.21	3.45	4.71	2.23	3.13	2.31	3.23	2.45	3.51	3.25	4.21	3.31	4.35	3.39	4.45
MVSTGCN ^[27]	2.57	3.32	2.83	3.97	3.36	4.52	2.18	3.10	2.27	3.18	2.38	3.36	3.21	4.19	3.28	4.30	3.35	4.43
STTN ^[28]	2.56	3.34	2.90	3.98	3.31	4.43	2.15	2.81	2.19	2.87	2.26	3.21	3.18	4.15	3.25	4.26	3.32	4.39
STFGNN ^[19]	2.53	3.41	2.83	3.85	3.35	4.51	2.01	2.63	2.05	2.71	2.08	2.73	3.15	3.92	3.23	4.12	3.27	4.28
GraphWaveNet ^[20]	2.49	3.32	2.81	3.77	3.32	4.42	1.81	2.41	1.86	2.43	1.87	2.47	3.11	3.85	3.16	3.97	3.20	3.99
Pdformer ^[11]	2.41	3.25	2.79	3.72	3.27	4.48	1.79	2.27	1.80	2.32	1.83	2.39	3.09	4.28	3.13	4.40	3.18	4.53
MoGERNN ^[23]	2.39	3.17	2.81	3.74	3.25	4.45	1.74	2.14	1.77	2.19	1.79	2.26	3.04	3.78	3.10	3.86	3.19	3.97
ST-BiAformer (本文)	2.24	2.90	2.77	3.64	3.20	4.37	1.63	2.08	1.64	2.09	1.68	2.14	2.85	3.68	2.91	3.74	2.96	3.75

注:表中加粗的数据为最优预测结果,下划线标识的数据为次优预测结果。

表 2 消融试验结果分析

Table 2 Analysis of ablation study results

组合	前后文 时间关联 模块	时空交叉 注意力 机制模块	时空融合 模块	E_{MAE}	E_{RMSE}
①	×	×	√	4.43	5.58
②	×	√	√	4.08	4.83
③	√	×	√	3.72	4.63
④	√	√	×	3.57	4.51
⑤(本文)	√	√	√	3.20	4.37

所示的 5 种组合方式,来验证它们对网约车出行需求的预测性能。表 2 中的“√”和“×”分别表示拥有或没有某模块。组合①仅包含“时空融合模块”;组合②、③分别为该模块与“时空交叉注意力机制”和“前后文时间关联模块”的融合结果;组合④为“时空交叉注意力机制”和“前后文时间关联模块”的融合结果。

由表 2 可知,当组合①时空融合模块独立存在时,所提模型的 MAE 和 RMSE 分别为 4.43 和 5.58,此时对网约车出行需求的预测误差最高。但当其分别加入“前后文时间关联模块”“时空交叉注意力机制”后,变体后的组合②在 MAE 和 RMSE 指标上分别降低了 7.90%和 13.44%;同时,变体后的组合③在 MAE 和 RMSE 指标上分别降低了

16.03%和 17.03%。这说明增设这 2 个模块可分别建模出行需求的双向时间关联特性及最频繁访问时空区域,进而有利于提升出行需求的预测精度。所提模型相比于变体组合④无时空融合模块的 MAE 和 RMSE 分别降低了 10.36%和 3.10%。当且仅当所提模型全面协同“前后文时间关联模块”“时空交叉注意力机制”“时空融合模块”时,能充分利用时空信息,取得最优的需求预测性能。

进一步选取了厦门出行需求高和低的区域各 3 个,采用单因素方差分析方法,在 0.05 的显著水平下检验模型内部各个模块的预测性能是否呈现显著性差异。检验结果如表 3 所示。可见,当移除“时空融合模块”后,模型 MAE 和 RMSE 的检验 p 值均小于 0.001,低于显著性水平 0.05。类似的显著性差异也发生在移除“前后文时间关联模块”和“时空

表 3 显著性检验结果分析

Table 3 Analysis of significance test results

检验项	E_{MAE}		E_{RMSE}	
	检验值	显著性	检验值	显著性
高、低需求区域	0.798		0.835	
有无前后文时间关联模块	0.002	*	0.002	*
有无时空交叉注意力机制模块	0.003	*	0.003	*
有无时空融合模块	0.001	*	0.001	*

注:“*”是指检测结果呈现显著性差异。

交叉注意力机制”中。可见,移除所提模型中的任何一个模块,都将使出行需求的预测结果出现显著性差异。这也意味着:由2个及以上模块组成的任一模型变体,都将使出行需求预测结果出现显著性变化。

3.5 实例验证

网约车出行需求在工作日、节假日和周末无一例外存在供需失衡现象。例如,高峰时段网约车的出行需求远超供应能力,导致部分用户无法及时获得服务;而平峰时段部分区域的网约车供给能力过

剩,造成严重的资源浪费。基于此,本节依托对前述ST-BiAformer模型的预测结果,进一步从宏观和中微观视角,对厦门市网约车出行需求的时空分布模式进行画像分析,旨在精准揭示网约车时空出行需求的供给失衡问题,从而为智能调度提供有力支持。

3.5.1 宏观视角下网约车出行需求分布

图2为厦门市网约车出行需求在节假日、工作日和周末的空间宏观分布情况画像,可在一定程度揭示该市网约车出行需求在不同日期的共性及个性模式。




图2 三类日期下网约车出行需求的空间分布情况

Fig. 2 Spatial distribution of ride-hailing travel demand under three date categories

(1) 共性模式:3类日期交通枢纽均为稳定基座。该市高崎机场、厦门站、邮轮中心等交通枢纽均保持6000+的需求峰值,构成城市出行网络的刚性锚点,承载海量出行居民,并释放大量网约车出行需求。同时,岛内的网约车出行需求一般聚集于思明区、湖里区等范围;岛外则微弱集中于集美大学城、厦门北站等节点,凸显了网约车出行需求“岛强郊弱”的单中心结构。

(2) 个性模式:3类日期出行路径随主导目的动态可变。乘客通过切换旅游、通勤或休闲等主导出行目的,而动态重塑空间出行需求的异质分配模式。节假日形成“枢纽-景区”双核辐射网络,源自旅游乘客从枢纽向景区树状扩散出行需求,致使双核辐射需求流线显著增粗,全域活跃范围扩散至岛外旅游节点;工作日需求流线沿“居住区-产业区”轴向收缩,根源在于通勤刚性导致需求严格沿吕岭路、火炬路等产业走廊单向聚集,呈现“哑铃式”分布,旅游区退化为需求洼地;周末呈现“商圈锚点+社区基底”

星网结构,源自弹性消费与休闲需求驱动社区向商圈“星型发散”,形成多向均衡辐射结构,使岛内商圈与近郊休闲区联动增强。未来还需建立日期适配型的交通调度策略,使节假日扩容景区接驳能力,工作日增密产业走廊运力,周末强化商圈-社区循环,打破不同时段网约车出行需求供需严重失衡的困局。

3.5.2 中微观视角下网约车出行需求分布

图3依托前述选取的出行需求高低各异的六类典型区域(高需求区A~C,低需求区D~F),以三步(15 min)预测任务为例,立足中观视角实证所提模型的预测鲁棒性。每张图中,横轴为1天里的96个时间间隔分布;纵轴为每个时间间隔的网约车出行需求。由图3可知,基线模型Autoformer(黑色)对网约车出行需求的预测精度虽在各个时间步表现稳定,但始终处于最低水平,意味着它的鲁棒性不强。Pdformer(绿色)和MoGERNN(蓝色)的预测性能虽随时间推移有所提升,但仍无法超越ST-




图3 三步预测任务示例下给定模型的预测性能鲁棒性分析

Fig. 3 Robustness analysis of three-step prediction of given models

BiAformer(橘色)的预测性能。可见,所提模型在整体趋势拟合方面均优于其他基线模型,能够准确捕捉网约车出行需求随时间变化的周期性规律,较好还原实际出行需求的起伏结构。聚焦更微观视角,相对于所选的3种基线,ST-BiAformer在高峰时段或突发波动时段对出行需求的峰值刻画始终更加精准。这证实它可在不同时段、多空间场景下均

能生成最接近真实值的出行需求分布,且在各预测时间步保持显著鲁棒性。ST-BiAformer同样也能精准捕捉高需求区域的出行面貌,并还原低需求区域的波动情况。例如,对于高需求区域A(高崎机场)的早高峰激增时段(07:00~09:00),ST-BiAformer预测曲线与真实值几乎重叠,而Pdformer、Autoformer、MoGERNN分别出现不同

程度的滞后偏差;对于低需求区域D(岛外居住区)的午间需求谷值(12:00~14:00),仅ST-BiAformer准确复现了真实值的“平缓凹陷”形态,而选定基线模型则出现平滑过度的失真拟合情况。

图4可视化展示了图3中各子图在厦门市域的时空分布情况,并特别使用红色方框标出高误差预测事件。这也在一定程度暴露了ST-BiAformer应对复杂现实扰动的脆弱性,本质源于下列3类不可控因素的交织作用。

(1)外生扰动抗逆机制薄弱。对天气、事故、政策等外部变量的影响仅作被动响应,未构建主动感知-适应闭环。当突发因素改变空间关联规则时(如暴雨天景区需求转移至商圈),模型仍沿用既定图结构推理,产生“空间认知惯性”。

(2)长尾场景泛化能力不足。训练数据过度依赖高频场景模式(如通勤潮汐),对低概率高冲击事

件(如演唱会散场、春运高峰)缺乏专项建模。此类场景中时空依赖的非常规性(如多点同时爆发、无序扩散)超出模型表征边界。

(3)多尺度耦合建模缺失。宏观事件(台风过境)与微观响应(单路口拥堵)的跨尺度联动未被解构,模型将全市需求视为均匀响应体,未能区分不同区域对外部扰动的敏感性差异。例如机场在航班取消时需求锐减,而火车站周边因滞留旅客需求激增,这种“矛盾响应并存”现象导致预测失准。上述3点也是模型未来改进的方向。

4 结 语

(1)针对现有模型在刻画网约车出行需求的跨时间段和跨空间共性及个性模式方面存在不足,本文提出了一种网约车出行需求多步预测的深度学习模型ST-BiAformer,通过设计前后文时间关联模




图4 高、低需求区域内所提模型预测偏差结果的时空分布情况

Fig. 4 Spatiotemporal distribution of model prediction bias results in high- and low-demand regions

块、时空交叉注意力机制模块和时空融合模块,有效增强模型对关联时序与时空依赖关系的建模能力。其中,ST-BiAformer 内置的前后文时间关联模块可有效强化模型对时间序列双向依赖的建模能力,缓解因单向时间建模诱发的时间特征捕捉不足的局限;时空交叉注意力机制模块可有效实现模型对全局或局部时空关联需求的精细化建模,进而提升它对乘客频繁访问时空区域的挖掘能力;时空融合模块则有效整合上述机制,提升模型对网约车出行需求的总体预测性能。

(2)模型应用于 3 个数据集中对网约车出行需求进行预测,来验证它的单步及多步预测性能。实证结果表明:所提模型在整体预测精度与时间鲁棒性维度均能取得优于给定主流基线模型的性能。这一优势也同时出现在单步及多步预测任务。消融试验也证明:当且仅当 ST-BiAformer 全面协同“前后文时间关联模块”“时空交叉注意力机制”“时空融合模块”时,才能取得最优的出行需求预测性能。同时,关键模块的设定及协同作用是显著提升模型预测性能的关键。可见,所提模型能够适配不同时间粒度和异质空间场景的网约车出行需求预测任务,这为优化网约车资源配置、提高网约车服务水平、提升乘客出行满意度提供有力决策支持。

(3)未来可将经济、天气等外部因素纳入建模框架,采用数据-知识-模型复合驱动的深度建模方法,针对性建立日期适配型的交通调度策略,使节假日扩容景区接驳能力,工作日增密产业走廊运力,周末强化商圈-社区循环,打破不同时段网约车出行需求供需严重失衡的困局。也可进一步探索跨区域、多系统、全方位的出行需求潜在时空关联模式建模方法;在此基础上,设计外生环境扰动抗逆的机制,突破单尺度、纯数据驱动等场景泛化不足诱发的预测失准困境,降低模型应对复杂现实扰动的脆弱性。

参 考 文 献 :

References :

- [1] 李之红,申天宇,文琰杰,等. 基于混合机器学习框架的网约车订单需求预测与异常点识别[J]. 交通信息与安全, 2023, 41(3): 157-165, 174.
LI Zhi-hong, SHEN Tian-yu, WEN Yan-jie, et al. Order demand prediction and anomaly-point identification for online car-hailing orders based on hybrid machine learning framework[J]. Journal of Transport Information and Safety, 2023, 41(3): 157-165, 174.
- [2] ZHAO X, CUI M Y, LEVINSON D. Exploring temporal variability in travel patterns on public transit using big smart card data[J]. Environment and Planning B: Urban Analytics and City Science, 2023, 50(1): 198-217.
- [3] WEN Y J, LI Z H, WANG X Y, et al. Traffic demand prediction based on spatial-temporal guided multi graph Sandwich-Transformer[J]. Information Sciences, 2023, 643: 119269.
- [4] 崔建勋, 要 甲, 赵泊媛. 基于深度学习的短期交通流预测方法综述[J]. 交通运输工程学报, 2024, 24(2): 50-64.
CUI Jian-xun, YAO Jia, ZHAO Bo-yuan. Review on short-term traffic flow prediction methods based on deep learning[J]. Journal of Traffic and Transportation Engineering, 2024, 24(2): 50-64.
- [5] LIANG G J, KINTAK U, NING X, et al. Semantics-aware dynamic graph convolutional network for traffic flow forecasting[J]. IEEE Transactions on Vehicular Technology, 2023, 72(6): 7796-7809.
- [6] XIA M R, JIN D W, CHEN J Y. Short-term traffic flow prediction based on graph convolutional networks and federated learning[J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24(1): 1191-1203.
- [7] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [8] CHO K, VAN MERRIENBOER B, GULCEHRE C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation[C]//ACL. Proceedings of the 2014 conference on empirical methods in natural language processing (EMNLP). Baltimore: ACL, 2014: 1724-1734.
- [9] GRAVES A, SCHMIDHUBER J. Framewise phoneme classification with bidirectional LSTM and other neural network architectures[J]. Neural Networks, 2005, 18(5): 602-610.
- [10] LI Z H, XU H, GAO X L, et al. Fusion attention mechanism bidirectional LSTM for short-term traffic flow prediction[J]. Journal of Intelligent Transportation Systems, 2024, 28(4): 511-524.
- [11] JIANG J W, HAN C K, ZHAO W X, et al. PDFormer: Propagation delay-aware dynamic long-range transformer for traffic flow prediction[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2023, 37(4): 4365-4373.
- [12] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J]. Advances in Neural Information Processing Systems, 2017, 30.
- [13] ZHOU H Y, ZHANG S H, PENG J Q, et al. Informer: Beyond efficient transformer for long sequence time-series forecasting[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2021, 35(12): 11106-11115.
- [14] WU H, XU J, WANG J, et al. Autoformer: Decomposition transformers with auto-correlation for long-term series forecasting[J]. Advances in Neural Information Processing Systems, 2021, 34: 22419-22430.
- [15] 姚俊峰, 何 瑞, 史童童, 等. 基于机器学习的交通流预测方法综述[J]. 交通运输工程学报, 2023, 23(3): 44-67.
YAO Jun-feng, HE Rui, SHI Tong-tong, et al. Review on

- machine learning-based traffic flow prediction methods[J]. Journal of Traffic and Transportation Engineering, 2023, 23(3): 44-67.
- [16] LIU K, CHEN Z J, YAMAMOTO T, et al. Exploring the impact of spatiotemporal granularity on the demand prediction of dynamic ride-hailing[J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24(1): 104-114.
- [17] YAN H Y, MA X L, PU Z Y. Learning dynamic and hierarchical traffic spatiotemporal features with transformer[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(11): 22386-22399.
- [18] HUO G Y, ZHANG Y, WANG B Y, et al. Hierarchical spatio-temporal graph convolutional networks and transformer network for traffic flow forecasting[J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24(4): 3855-3867.
- [19] LI M Z, ZHU Z X. Spatial-temporal fusion graph neural networks for traffic flow forecasting[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2021, 35(5): 4189-4196.
- [20] WU Z H, PAN S R, LONG G D, et al. Graph WaveNet for deep spatial-temporal graph modeling [C] // IJCAI. Proceedings of the Twenty-Eighth International Joint Conference on Artificial Intelligence. Macao: International Joint Conferences on Artificial Intelligence Organization, 2019: 1907-1913.
- [21] WANG Q Y, WANG S H, ZHUANG D Y, et al. Uncertainty quantification of spatiotemporal travel demand with probabilistic graph neural networks[J]. IEEE Transactions on Intelligent Transportation Systems, 2024, 25(8): 8770-8781.
- [22] ZHANG H P, DONG H H, YANG Z Q. TSGDiff: Traffic state generative diffusion model using multi-source information fusion[J]. Transportation Research Part C: Emerging Technologies, 2025, 174: 105081.
- [23] ZHOU Q S, ZHANG Y F, MAKRIDIS M A, et al. MoGERNN: An inductive traffic predictor for unobserved locations[J]. Transportation Research Part C: Emerging Technologies, 2025, 174: 105080.
- [24] LIU XUN, LEI F Y, XIA G Q, et al. AdjMix: Simplifying and attending graph convolutional networks[J]. Complex & Intelligent Systems, 2022, 8(2): 1005-1014.
- [25] YU B, YIN H T, ZHU Z X. Spatio-temporal graph convolutional networks: A deep learning framework for traffic forecasting[C] // IJCAI. Proceedings of the Twenty-Seventh International Joint Conference on Artificial Intelligence. Stockholm: International Joint Conferences on Artificial Intelligence Organization, 2018: 3634-3640.
- [26] LV M Q, HONG Z X, CHEN L, et al. Temporal multi-graph convolutional network for traffic flow prediction[J]. IEEE Transactions on Intelligent Transportation Systems, 2021, 22(6): 3337-3348.
- [27] WEI S Q, FENG S Y, YANG H. Multi-view spatial-temporal graph convolutional network for traffic prediction[J]. IEEE Transactions on Intelligent Transportation Systems, 2024, 25(8): 9572-9586.
- [28] LI G Y, ZHONG S H, DENG X D, et al. A lightweight and accurate spatial-temporal transformer for traffic forecasting [J]. IEEE Transactions on Knowledge and Data Engineering, 2023, 35(11): 10967-10980.
- [29] WANG M, ZHANG Y, ZHAO X, et al. Traffic origin-destination demand prediction via multichannel hypergraph convolutional networks[J]. IEEE Transactions on Computational Social Systems, 2024, 11(4): 5496-5509.
- [30] WEN Y J, XU P, LI Z H, et al. RPConvformer: A novel Transformer-based deep neural networks for traffic flow prediction [J]. Expert Systems with Applications, 2023, 218: 119587.