

基于时空关联的时空图卷积神经网络 城市轨道交通进站客流预测^{*}

王润祺 郝妍熙 胡华 方勇 刘志钢

(上海工程技术大学城市轨道交通学院, 201620, 上海)

摘要 [目的] 准确的短时客流预测对于提高超大规模城市轨道交通线网的运营和管理效率具有重要意义,而目前现有研究对于深度挖掘时空关联性仍不够充分,为此基于短时客流的时空规律提出了基于客流时空关联特征的STGCN(时空图卷积神经网络)模型。[方法]首先,通过切比雪夫图卷积网络捕捉超大规模城市轨道交通网络的空间相关性,借助门控循环单元挖掘多时空关联特征下客流的时间相关性;然后,分析待预测车站历史客流数据相关性及OD(起讫点)客流数据相关性,以深入提取时空相关性;最后,结合客流时空关联特征建立STGCN模型。[结果及结论]以上海地铁江苏路站为例,进行短时进站客流预测,结果表明采用时空关联特征参数的预测结果较未加入特征参数的预测精度提高了16%,预测效果较优。

关键词 城市轨道交通; 短时进站客流预测; 时空关联性; 时空图卷积神经网络

中图分类号 TP183; U293.13

DOI:10.16037/j.1007-869x.2024.09.016

Inbound Passenger Flow Prediction of Spatio-temporal Graph Convolutional Neural Network for Urban Rail Transit Based on Spatio-temporal Correlation

WANG Runqi, HAO Yanxi, HU Hua, FANG Yong,
LIU Zhigang

(School of Urban Railway Transportation, Shanghai University of Engineering Science, 201620, Shanghai, China)

Abstract [Objective] Accurate short term passenger flow prediction is of great significance to improve the operation and management efficiency of the ultra-large scale of urban rail transit network. However, the current research on deep exploration of the spatio-temporal correlations is still insufficient. Therefore, according to the spatio-temporal law of short term passenger flow, a STGCN (spatio-temporal graph convolutional neural network) model based on spatio-temporal correlation characteristics of passenger flow is proposed. [Method] First-

ly, the spatial correlation of ultra-large scale urban rail transit network is captured by ChebyNet (Chebyshev graph convolutional network), and the temporal correlation of the passenger flow under multi-temporal correlation characteristics is explored with the help of GRU (gated recurrent unit). Secondly, the correlation of the historical passenger flow data of the station to be predicted and that of OD (origin-destination) passenger flow data are analyzed to extract the spatio-temporal correlation deeply. Finally, a STGCN model is established in combination with the spatio-temporal correlation characteristics of the passenger flow. [Result & Conclusion] Taking Jiangsu Road Station of Shanghai Metro Line as an example, a short-term inbound passenger flow prediction is conducted. The result shows that the prediction accuracy with spatio-temporal correlation characteristic parameters is 16% higher than that without the parameters, indicating a better prediction effect.

Key words urban rail transit; short term inbound passenger flow prediction; spatio-temporal correlation; spatio-temporal graph convolutional neural network

日趋复杂的城市轨道交通网络及客流特征易造成线网单点客流量突变,增加线路短时瘫痪的可能性。充分利用城市轨道交通线网条件下的客流规律及其时空关联性^[1-2],能够降低客流量的预测误差,提高客流量预测精度,为保障城市轨道交通的网络化运营管理效率提供理论依据。

目前,客流时空特征分析及客流预测方法大多在线路换乘站之间或者相邻站之间进行空间关联性分析,考虑网络条件下的空间关联性研究还不够全面。文献[1]选用Spearman相关系数在时间上对车站客流进行相关性分析,在空间上得到各车站的相关系数;文献[3]使用多维标度法分析断面客流相关性时,通过拟合坐标的欧氏距离来反映样本间的关联程度;文献[4]在进行交通流空间相关性

* 上海市科委地方院校能力建设项目(19030501400);国家自然科学基金项目(52072235)

分析时将皮尔逊相关系数进行扩展,引入时间延迟和空间权重矩阵来计算空间相关性;文献[5]构建单条件多规则不确定性预测云模型,证明云模型用于短时进站客流预测的有效性。

同时随着人工智能的快速发展,利用深度学习的思想来解决交通流预测问题成为了主流,其中 CNN(卷积神经网络)和 RNN(循环神经网络)最为通用。文献[6]在 CNN 的基础上提出了 GCN(图卷积神经网络)来挖掘交通网络中的空间特征,以提高交通流预测的精度。文献[7]基于 GCN 模型提出了一种时空图卷积神经网络,通过对多尺度交通路网建模,能够将时空相关性有效、全面地捕获。文献[8]提出基于谱图卷积的时空图卷积神经网络,通过将机场网络转换为规则的网络结构来预测离港航班延误状况,结果表明预测精度提升显著。

从结果上看,此类神经网络模型及其变体预测性能较好、稳定性较高。但在城市轨道交通客流的应用方面,现有的研究较少且大多针对断面客流,对于存在车站特征及客流 OD(起讫点)关联等的进出站客流而言,其时空关联性的挖掘深度仍然不够。因此,本文以上海城市轨道交通全网客流数据为基础,以地铁江苏路站为例进行进站客流预测,并基于预测结果进行特征有效性分析和模型有效性分析。

1 时间图卷积神经网络模型

1.1 问题定义

城市轨道交通网络是非欧式空间结构的复杂拓扑网络,其包含了自身的节点特征和各节点之间的结构特征,这使得城市轨道交通线网满足图的生成条件。因此,本文针对城市轨道交通线网车站客流的预测问题,构建一个无向图 $\mathbf{G}(V, E, A)$ 来描述线网的拓扑结构,其中:城市轨道交通车站看作节点, V 为网络车站节点的集合, $V = \{v_1, v_2, \dots, v_N\}$, N 为节点数量;连接节点的为边, E 为边的集合,表示轨道车站间的连通性; A 为图 \mathbf{G} 的邻接矩阵, $A \in \mathbf{R}^{N \times N}$ 表示节点之间的连接关系。

其预测客流的函数形式可以表示为^[9]:

$$Y_{t+T} = f(\mathbf{G}; \mathbf{X}_{t-n}, \dots, \mathbf{X}_{t-1}, \mathbf{X}_t) \quad (1)$$

式中:

Y_{t+T} —— $t+T$ 时刻线路网络的客流量预测值;

n ——历史时间序列的长度;

T ——预测时间的长度;

X_t ——在 t 时刻线路网络节点的特征矩阵, $X_t \in \mathbf{R}^{N \times M}$, 其中, \mathbf{R} 表示实数集合, M 为节点特征个数。

1.2 双层时间图卷积神经网络(T-GCN)

GCN 是一种以 CNN 为基础改进的图卷积神经网络,本质为从图网络中捕捉空间特征,并将其用于点分类、图分类、边预测等。但由于 GCN 仅限于一阶邻域中提取空间相关性,导致多阶邻域之间的空间信息被忽略,因此本文采用双层 GCN 来研究城市轨道交通网络的空间特征。

首先,对网络中节点的特征进行分析,将网络图的邻接矩阵 A 和特征矩阵 X 输入到模型中,并聚合多个卷积层以构建双层 GCN 单元来获得空间的相关性,相关计算公式采用文献[10]。

其次,将双层 GCN 与 GRU(门控循环单元)结合,进而学习线网节点间的关联关系及时间序列的相关规律(见图 1),从而分析记忆单元间的信息传递以捕捉时间相关性,相关计算公式引自文献[10]。

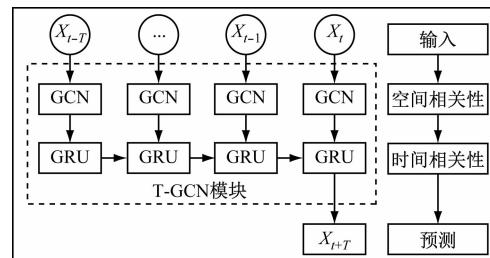


图 1 T-GCN 模型结构

Fig. 1 T-GCN model structure

2 基于时空关联的时空图卷积神经网络

2.1 时空图卷积神经网络(STGCN)

GCN 由切比雪夫图卷积(ChebNet) $k=1$ 时推导得到,仅限于在一阶邻域中提取空间相关性。因此,本文通过分析图中节点的特征构建邻接矩阵 A 和特征矩阵 X 作为模型的输入,利用 k 阶切比雪夫图卷积对 T-GCN 单元的双层图卷积进行改进^[11],其 k 阶切比雪夫图卷积的函数形式为:

$$\text{ChebNet}(X) = \sigma \left(\sum_{k=0}^{K-1} \beta_k T_k(\tilde{\mathbf{L}}) X \right) \quad (2)$$

$$T_k(\tilde{\mathbf{L}}) = 2\tilde{\mathbf{L}}\mathbf{T}_{k-1}(\tilde{\mathbf{L}}) - \mathbf{T}_{k-2}(\tilde{\mathbf{L}}) \quad (3)$$

$$\tilde{\mathbf{L}} = \frac{2\mathbf{L}}{\lambda_{\max}} - \mathbf{I}_N \quad (4)$$

$$\mathbf{L} = \mathbf{I} - \mathbf{D}^{-\frac{1}{2}} \mathbf{A} \mathbf{D}^{-\frac{1}{2}} \quad (5)$$

式中：

K ——拉普拉斯算子多项式的阶数；

σ ——Sigmoid 函数；

$T_k(\tilde{L})$ —— k 阶切比雪夫多项式； $T_0(\tilde{L}) = I$ ， $T_1(\tilde{L}) = \tilde{L}$ ；

L ——拉普拉斯矩阵；

\tilde{L} ——缩放后的特征值对角矩阵，约束切比雪夫多项式图半径在[−1,1]之间；

I_N —— N 阶的单位矩阵；

λ_{\max} —— L 的最大特征值；

β_k ——训练的权重参数，与 T_k 构成卷积核；

D ——无自连接的度矩阵。

2.2 时空关联

2.2.1 时间关联特征

为深度挖掘城市轨道交通网络的客流时间关联，本文使用斯皮尔曼等级相关方法对历史客流数据进行时间相关性分析。Spearman(斯皮尔曼)相关通常被看作积差相关的特殊形式，因此常用来度量变量之间的强弱关系。在预测输入时，选取可能相关性较强的时段客流作为相关性分析的研究对象，如表 1 所示对待预测时段进出站客流量与其当天前个别时段、前一周个别时段等的进站客流量进行相关性研究。表 1 中 a, b, c, d, e, f, g, h 分别为各时段客流与待预测时段客流的斯皮尔曼相关系数，其数值大小用以确定与待预测时段相关性较高的时段客流即作为提取城市轨道交通客流时间特征矩阵 X_q 。

表 1 待验相关性时段

Tab. 1 Correlation period to be tested

相关时段	相关性
待预测时段	1
前一 5 min	a
前二 5 min	b
前一天同一时段	c
前一天前一 5 min	d
前一周同一时段	e
前一周前一 5 min	f
前一月同一时段	g
前一月前一 5 min	h

2.2.2 空间关联特征

本文通过城市轨道交通网络 OD 客流数据来挖掘城市轨道交通网络的客流空间关联。首先使用车站间的进出站 OD 客流量来表达城市轨道交通网

络的空间相关性；其次，结合列车旅行时间差计算出目标车站与其关联车站的 OD 量占比；最后将关联车站的进站或出站历史时段客流占比作为预测模型的空间特征输入参数 X_o 。两站之间的 OD 量所占比重计算方法如式(6)、(7)。

$$q_{\text{进}} = D_{i,j}/O_i \quad (6)$$

$$q_{\text{出}} = D_{j,i}/O_j \quad (7)$$

式中：

$q_{\text{进}}, q_{\text{出}}$ ——进、出站 OD 客流比重；

D_{ij} ——从 i 站进从 j 站出的客流；

D_{ji} ——从 j 站进从 i 站出的客流；

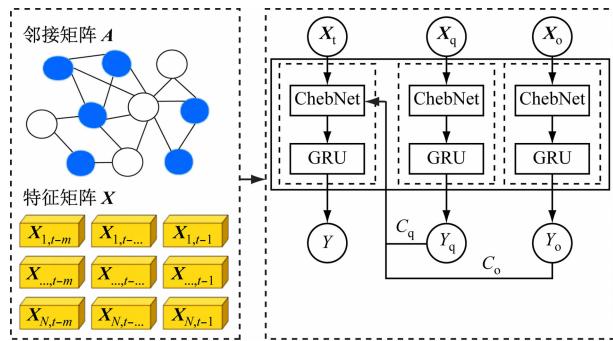
O_i —— i 站的进站客流；

O_j —— j 站的进站客流。

2.3 基于时空关联的 STGCN 模型

本文通过分析城市轨道交通网络的客流时空关联特征，构建 3 个时空图 X_t, X_q, X_o 融合组建基于时空关联特征的 STGCN 模型，如图 2 所示。将图 X_q, X_o 的输出通过编码语句 C 作为图 X_t 的输入，最终完成时空图的融合，得到预测值 Y 。

本文提出的基于时空关联特征的 STGCN 模型分别提取待预测时段相关邻近时间、OD 客流关联时间的城市轨道交通客流进出站数据，通过 3 个时空图与编码语句 C 网络结构融合来挖掘城市轨道交通网络客流在不同历史时间窗口下的相关性，以及存在旅行时间差的 OD 客流在时序上的关联性。



注：ChebNet 为切比雪夫图卷积； Y 为预测值。

图 2 基于时空关联的 STGCN 模型结构

Fig. 2 STGCN model structure based on spatio-temporal correlation

3 基于时空关联的 STGCN 预测实例

3.1 试验数据

以上海轨道交通全网进出站客流数据为依据，选择江苏路站进行实例验证，江苏路站是 2 号线和

11 号线的换乘站,客流量大,客流时空结构复杂,可以很好地验证模型的适用性。选取 2019 年 6 月每日 06:00 到 23:00 的 5 min 客流量作为样本数据,每日共 204 个数据。

3.2 特征分析

首先,在表 2 的江苏路站历史时段进站客流量周相关性中,由于相关性最显著的前一天同一时段与待预测时段属于同一历史时间序列,相关性次之的前一天前—5 min 和前—5 min 时段为同一历史时间序列,因此选取待预测时段前—5 min 时段客流作为时间特征输入 X_q 。

其次,以上海轨道交通全网 OD 客流数据为基础,进行全网 OD 占比分析。然后采用 Pearson 相关系数法对江苏路站在上海全网车站的历史 OD 分时客流占比做相关性分析,发现由江苏路站进站的 OD 分时客流占比相关性高达 0.94,可以认为由江苏路分时进站的全网客流 OD 占比变化幅度小、较为稳定。由于经江苏路站进站到其他车站出站间

存在旅行时间差,因此选取由 06:00 至 23:00 江苏路进站,经过对应旅行时间后从其他车站出站的客流为空间特征矩阵 X_o 。江苏路站进站客流在上海全网车站的出站 OD 占比见图 3。

表 2 江苏路站历史时段客流时间相关性分析

Tab. 2 Correlation analysis of passenger flow and time during the historical periods in Jiangsu Road Station

相关时段	相关性
待预测时段	1
前—5 min	0.945
前二 5 min	0.928
前一天同一时段	0.984
前一天前—5 min	0.965
前一周同一时段	0.798
前一周前—5 min	0.784
前一月同一时段	0.899
前一月前—5 min	0.892

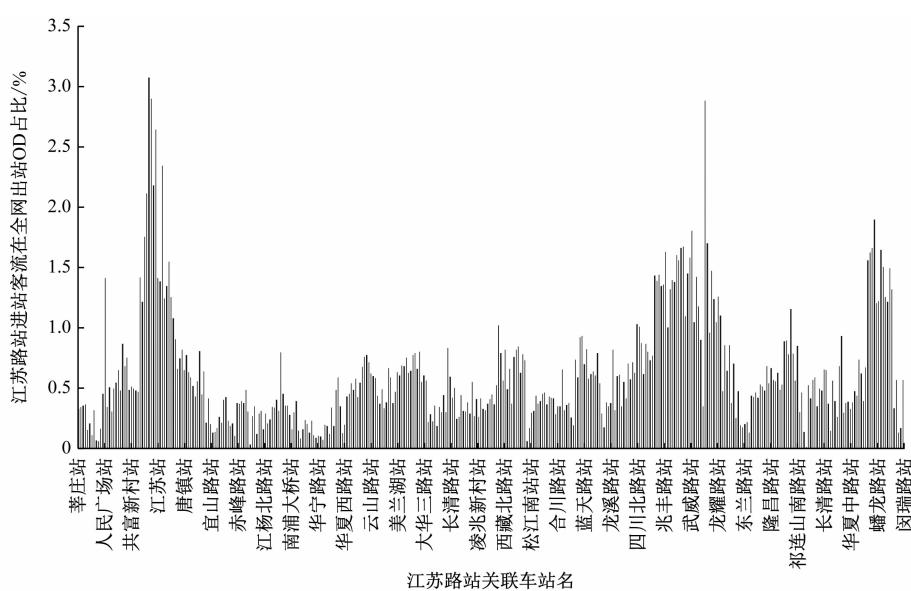


图 3 江苏路站进站客流在上海全网车站的出站 OD 占比

Fig. 3 Proportion of inbound passenger flow at Jiangsu Road Station to the outbound OD of the whole Shanghai urban rail transit network stations

3.3 模型评价

本文在城市轨道交通短时客流预测的过程中,对预测模型的有效性评估选取 RMSE(均方根误差)、MAE(平均绝对误差)、MAPE(平均绝对百分比误差)三个典型的评价指标,用于对模型的预测效果进行评价^[12],并将其预测性能与不同模型做对比。

3.4 预测实例

STGCN 模型输入江苏路站的时间特征 X_t 、空间特征 X_o 以及相关历史时段特征 X_q 数据。其中: X_q 图是由前—5 min 时段的历史客流数据组成; X_o 是基于江苏路站 OD 数据建立,本文研究共 315 座车站,所以形成一个 315 乘 315 的邻接矩阵,设置 64 个卷积核; X_t 隐藏层设置为 3 层, X_q 、 X_o 隐藏层

设置为2层;ChebNet(切比雪夫图卷积)设置为 $k=2$ 、学习率为0.001,训练集设置为数据集的前75%,测试集设置为数据集的后25%,得到测试集预测结果MAE为8.16、RMSE为13.61、MAPE为2.38%,预测值与真实值对比如图4所示。

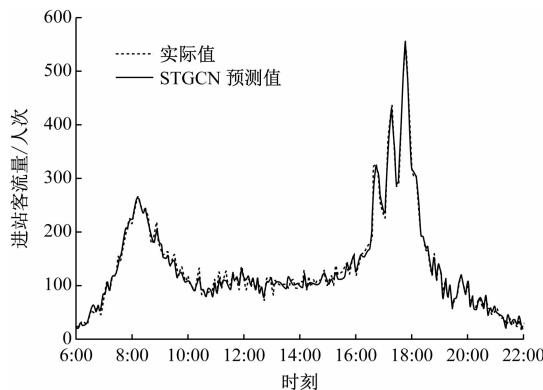


图4 STGCN 客流预测结果

Fig.4 STGCN passenger flow prediction results

3.5 预测效果分析

对预测效果进行分析,为验证本文所研究的时空关联特征有效性,将不同的特征分别输入模型以验证特征有效性;为验证模型的有效性,将具有相同特征的模型预测结果进行比较。

3.5.1 特征有效性分析

对于进出站客流预测的STGCN效果评价时,分别对输入待预测时段的历史时段 X_t 的模型、输入 X_t 和相关历史时段特征 X_q 的模型以及输入 X_t 、 X_q 和OD相关客流历史时段 X_o 的模型,进行日客流预测效果评价,如表3所示。从表3可以看出,相对于传统的预测模型,加入时空特征后STGCN的MAPE降低了0.47%,预测精度提升了16%,加入时空特征的模型比未加入的模型预测效果好。

表3 进站客流预测的STGCN效果评价

Tab. 3 STGCN result evaluation of inbound passenger flow prediction

输入的参数	评价指标		
	MAE	RMSE	MAPE/%
X_t	13.29	17.24	2.85
$X_t + X_q$	10.65	14.35	2.53
$X_t + X_o + X_q$	8.16	13.61	2.38

3.5.2 模型有效性分析

对于进站客流预测选取不同预测模型输入相同特征进行效果评价,其中:HA是历史均值法;

LSVR是一种常用于预测的线性支持向量机回归预测方法;LSTM是一种门控循环神经网络,主要是与GRU进行对比,验证本文模型中使用GRU是否预测效果较好;RF是随机森林模型;STGCN为本文所建模型。试验结果如表4所示。

表4 不同预测模型效果评价

Tab. 4 Result evaluation of different prediction models

模型名称	评价指标		
	MAE	RMSE	MAPE/%
HA	14.52	19.48	2.98
LSVR	13.52	18.28	2.86
LSTM	12.37	17.13	2.72
GRU	10.28	15.35	2.59
RF	9.23	14.82	2.46
STGCN	8.16	13.61	2.38

由表4可以看出,与其他常用短时客流预测模型相比,本文加入时空关联特征的STGCN模型预测效果最优,其MAPE比RF降低了3.3%、比GRU降低了8.1%;且其中GRU的MAPE比LSTM提高了4.8%,同时也说明了本文模型中加入GRU在提取时间关联上的优越性要强于LSTM。

4 结语

1)建立了基于时空关联特征的STGCN城市轨道交通客流预测模型,弥补了切比雪夫卷积对于存在旅行时间差的较远关联车站的不可达性或者可达过程中的损失误差。

2)以上海轨道交通线江苏路站进站客流为例进行实例验证,结果表明本文所建STGCN模型相比较其他单一特征参数短时客流预测模型的预测效果更优,MAPE指标相对于未加入时空特征的降低了0.47%,精度提高了16%。

3)本文所提出的基于时空关联的STGCN城市轨道交通进站客流预测方法提取城市轨道交通线网条件下的客流规律及其时空关联性,可提高城市轨道交通短时客流预测精度,有益于保障城市轨道交通的网络化运营管理效率的提高。

参考文献

[1] 黄梓荣. 轨道交通线网客流预测方法研究[D]. 广州: 华南理工大学, 2015.

HUANG Zirong. Research of urban rail network passenger volume forecast method [D]. Guangzhou: South China University of

- Technology, 2015.
- [2] 袁坚, 王鹏, 王锐, 等. 基于时空特征的城市轨道交通客流预测方法[J]. 北京交通大学学报, 2017, 41(6): 42.
YUAN Jian, WANG Peng, WANG Yue, et al. A passenger volume prediction method based on temporal and spatial characteristics for urban rail transit[J]. Journal of Beijing Jiaotong University, 2017, 41(6): 42.
- [3] 周思源. 城市轨道交通基于时空相关性分析的短时客流预测及行车组织研究[D]. 西安: 长安大学, 2018.
ZHOU Siyuan. Short time prediction and traffic organization research of urban rail transit based on spatio-temporal correlation analysis[D]. Xi'an: Changan University, 2018.
- [4] 王玺铭. 基于时空相关性分析的短时交通流量预测方法研究[D]. 杭州: 浙江工业大学, 2020.
WANG Ximing. Short-term traffic flow forecasting method based on spatio-temporal correlation analysis[D]. Hangzhou: Zhejiang University of Technology, 2020.
- [5] 蔡昌俊. 城市轨道交通进出站短时客流预测模型研究[J]. 城市轨道交通研究, 2021, 24(9): 14.
CAI Changjun. Study on urban rail transit entry and exit short-term passenger flow prediction model[J]. Urban Mass Transit, 2021, 24(9): 14.
- [6] DENG S, JIA S, CHEN J. Exploring spatial-temporal relations via deep convolutional neural networks for traffic flow prediction with incomplete data [J]. Applied Soft Computing, 2019, 78: 712.
- [7] YU B, YIN H, ZHU Z. Spatio-temporal graph convolutional networks: a deep learning framework for traffic forecasting[C]// Proceedings of the 27th International Joint Conference on Artificial Intelligence. Stockholm, Sweden: New York: ACM, 2018: 3634.
- [8] 姜雨, 陈名扬, 袁琪, 等. 基于时空图卷积神经网络的离港航班延误预测[J]. 北京航空航天大学学报, 2023, 49(5): 1044.
JIANG Yu, CHEN Mingyang, YUAN Qi, et al. Departure flight delay prediction based on spatio-temporal graph convolutional networks[J]. Journal of Beijing University of Aeronautics and Astronautics, 2023, 49(5): 1044.
- [9] 夏英, 刘敏. 基于时空注意力卷积神经网络的交通流量预测[J]. 西南交通大学学报, 2023, 58(2): 340.
XIA Ying, LIU Min. Traffic flow prediction based on spatial-temporal attention convolutional neural network[J]. Journal of Southwest Jiaotong University, 2023, 58(02): 340.
- [10] ZHAO L, SONG Y, ZHANG C, et al. T-GCN: a temporal graph convolutional network for traffic prediction[J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 21(9): 3848.
- [11] 戴俊明, 曹阳, 沈琴琴, 等. 基于多时空图卷积网络的交通流预测[J]. 计算机应用研究, 2022, 39(3): 780.
DAI Junming, CAO Yang, SHEN Qinjin, et al. Traffic flow prediction based on multi-spatial-temporal graph convolutional network[J]. Application Research of Computers, 2022, 39(3): 780.
- [12] 马茜, 梁奕, 段毅, 等. 基于动态稀疏注意力的地铁客流预测模型[J]. 城市轨道交通研究, 2022, 25(4): 22.
MA Qian, LIANG Yi, DUAN Yi, et al. Metro passenger flow prediction model based on dynamic sparse attention[J]. Urban Mass Transit, 2022, 25(4): 22.

· 收稿日期:2022-06-06 修回日期:2022-08-03 出版日期:2024-09-10

Received:2022-06-06 Revised:2022-08-03 Published:2024-09-10

· 第一作者:王润祺,硕士研究生,wrq61898@163.com

通信作者:郝妍熙,讲师,haoyanxi@sues.edu.cn

· ©《城市轨道交通研究》杂志社,开放获取 CC BY-NC-ND 协议

© Urban Mass Transit Magazine Press. This is an open access article under the CC BY-NC-ND license

敬请关注《城市轨道交通研究》微信视频号

《城市轨道交通研究》微信视频号聚焦轨道交通行业内的热点问题、焦点问题,以及新技术、新成果,邀请相关专业领域内的专家学者及高级管理人员以视频方式解读和评述,是您及时获知行业资讯、深度了解轨道交通各专业领域的最佳平台。您还可以通过该平台查阅往期论文、查询稿件进度、开具论文录用通知书。敬请关注。

