

DOI: 10.19951/j.cnki.1672-9331.20221122002

文章编号: 1672-9331(2025)01-0154-09

引用格式: 卢毅, 王宇阳, 李媛. 基于深度学习的城市公交站点客流预测[J]. 长沙理工大学学报(自然科学版), 2025, 22(1): 154-162.

Citation: LU Yi, WANG Yuyang, LI Yuan. Passenger flow prediction of urban bus stops based on deep learning[J]. J Changsha Univ Sci Tech (Nat Sci), 2025, 22(1): 154-162.

基于深度学习的城市公交站点客流预测

卢毅^{1,2}, 王宇阳¹, 李媛¹

(1. 长沙理工大学 交通学院, 湖南 长沙 410114; 2. 长沙理工大学 智能交通与现代物流研究院, 湖南 长沙 410114)

摘要:【目的】城市公交站点客流的变化趋势和时空特征密不可分。本文目的为捕捉公交站点客流的时空特征。【方法】首先,使用图卷积网络捕捉客流的空间特征;接着,借助门控递归单元捕捉客流的时间特征;然后,构建基于深度学习的公交站点客流预测模型,即门控图卷积网络(gated-graph convolutional network, G-GCN)模型;最后,将驻马店市内的512个公交站点的客流数据按照30、45和60 min三种时间粒度进行划分,利用G-GCN模型进行预测,并将该预测结果与基线模型的预测结果进行对比。【结果】在上述三种时间粒度划分下,G-GCN模型的三种均方根误差分别为2.35、3.00和3.57,分别比其他基线模型的平均降低了19.60%、24.40%和26.40%。【结论】本研究成果突破了以往只在规则区域内对公交客流进行预测的局限,为城市公交组织优化提供了技术参考。

关键词: 客流和客运量调查与预测;智能交通;深度学习;图卷积网络;门控递归单元

中图分类号: U492.4*13

文献标志码: A

Passenger flow prediction of urban bus stops based on deep learning

LU Yi^{1,2}, WANG Yuyang¹, LI Yuan¹

(1. College of Transportation Engineering, Changsha University of Science & Technology, Changsha 410114, China;
2. School of Intelligent Transportation and Logistics, Changsha University of Science & Technology, Changsha 410114, China)

Abstract: [Purpose] The changing trend of passenger flow at urban bus stops is inseparable from the temporal and spatial characteristics. This paper aims to capture the temporal and spatial characteristics in passenger flow of bus stops. [Methods] Firstly, the graph convolutional network (GCN) was used to capture the spatial characteristics of the passenger flow; secondly, the gated recurrent unit (GRU) was employed to capture the temporal characteristics of the passenger flow; thirdly, a passenger flow prediction model of bus stops based on deep learning was developed and named gated-graph convolutional network (G-GCN). Finally, the passenger flow data of 512 bus stops in Zhumadian City were divided into three time granularities of 30, 45, and 60 min, and the G-GCN model was utilized for prediction. The prediction results were compared with those of the baseline model. [Findings] The root mean square errors of the G-GCN model are 2.35, 3.00, and 3.57 at the three time granularities, reducing by 19.60%, 24.40%, and 26.40% compared with

收稿日期: 2022-02-26; 修回日期: 2022-04-20; 接受日期: 2022-04-27

基金项目: 湖南省交通运输厅科技进步与创新项目(202030); 长沙理工大学研究生科研创新项目(CX2021SS12)

通讯作者: 卢毅(1964—)(ORCID:0000-0002-5426-2343), 男, 教授, 主要从事智能交通方面的研究。

E-mail: 2985086508@qq.com

投稿网址: <http://cslgxbzk.csust.edu.cn/cslgdxxbzk/home>

those of the other baseline models. [**Conclusions**] The research results break through the limitations of predicting passenger flows in public transport within regular areas and provide technical support for the optimization of urban public transport organizations.

Key words: survey and prediction of passenger flow and passenger volume; intelligent transportation; deep learning; graph convolutional network; gated recurrent unit

Foundation items: Project (202030) supported by Science & Technology Progress and Innovation Project from Department of Transportation of Hunan Province; Project (CX2021SS12) supported by Graduate Research Innovation Project from Changsha University of Science & Technology

Corresponding author: LU Yi (1964—) (ORCID: 0000-0002-5426-2343), male, professor, research interest: intelligent transportation. E-mail: 2985086508@qq.com

0 引言

城市交通领域的拥堵问题逐渐受到重视。解决该问题的有效途径之一为优先发展公共交通。公共交通的运转效率决定整体城市交通系统的性能,而公交站点客流预测研究是其中一个热点。站点客流反映了居民出行的时空规律,与交通出行目的息息相关。预先掌握客流数量与变化趋势可为公交管理方案的制定提供技术参考。

目前,国内外学者使用不同的理论模型进行公交客流预测研究。早期的预测模型主要包括排队论模型、微观基本图模型和细胞传输模型^[1-3]等。王茜竹等^[4]构建了奇异谱分析-自回归移动平均模型,并对短时公交客流进行了预测;武腾飞等^[5]建立了剔除无效值的自回归移动平均模型,提高了公交上下站客流的预测精度;张春辉等^[6]验证了卡尔曼滤波在公交站点客流预测上的有效性,且该模型具有良好的鲁棒性;陆百川等^[7]建立了基于径向基神经函数的短时客流预测模型,证实该模型具有较高的预测精度;黄益绍等^[8]提出了一种基于改进粒子群算法的优化极限学习机的公交站点短时预测模型,且该模型具有很好的可靠性和泛化性能;LIU等^[9]通过运用GPS数据聚合公交车站来形成虚拟的区域公交车站,利用支持向量机建立区域公交客流预测模型,并提供预警服务;SUN等^[10]分析客流特征,采用基于遗传算法的外部输入非线性自回归神经网络预测公交线路客流;MA等^[11]借鉴图像识别的方法来预测交通流量,取得显著的预测效果;李高盛等^[12]通过长短期

记忆网络(long short-term memory, LSTM)预测公交上下车站客流,并且验证该网络具有一定的泛化能力;LIU等^[13]将城市区域划分为规则网格,提出使用改进时空残差网络来预测区域公交客流,从而有效避免了梯度爆炸问题;ZHAO等^[14]搭建了一种融合图卷积网络(graph convolutional network, GCN)和门控递归单元(gated recurrent unit, GRU)的时间图卷积网络(temporal graph convolutional network, T-GCN)模型,并且在不同的数据集上验证了该模型的性能。

目前,对客流预测领域的研究取得了较多成果,但与公交站点客流预测相关的研究较少。其原因可能在于城市公交站点客流数据的收集具有一定的难度。此外,预测方法因其自身限制无法满足预测精度的要求。早期的历史平均(history average, HA)模型只依靠数据来预测未来信息,且其精确度较低。客流的变化趋势一般具有非线性特征,故以支持向量回归(support vector regression, SVR)为代表的统计回归模型仅能捕捉客流的线性特征。机器学习具有能够学习非线性特征的优点,关注了客流的时间相关性,但忽略了客流的时空相关性。深层神经网络的发展使得提取客流的时空相关性成为可能,也为公交站点客流预测研究提供了理论指导。

本研究首先使用时间粒度划分城市公交站点客流数据;然后,使用GCN和GRU搭建一种公交站点客流预测新模型,即门控图卷积网络(gated-graph convolutional network, G-GCN)模型,并捕捉公交站点客流的时空相关性;最后,在不同时间粒度下预测了公交站点客流,并分析了该模型的预测效果。

1 公交站点客流特征分析

1.1 空间特征分析

公交站点客流具有强烈的空间相关性,会影响其所在公交线路上相邻公交站点的客流,更有可能波及公交线路的所有站点。因此,借助公交线路中的站点连接性来构建站点网络无向图,即邻接权重矩阵 \mathbf{A} ,以充分捕捉公交站点客流的空間相关性。

$$\mathbf{A} = \begin{bmatrix} w_{11} & w_{12} & \cdots & w_{1j} \\ w_{21} & w_{22} & \cdots & w_{2j} \\ \vdots & \vdots & & \vdots \\ w_{i1} & w_{i2} & \cdots & w_{ij} \end{bmatrix} \quad (1)$$

式中: \mathbf{A} 为网络无向图的内部结构; i 和 j 均为网络无向图的节点; w_{ij} 为节点 i 和 j 的连接程度,即站点之间的相关性或相关性强度。

若相连节点之间的相关性强度设为1,不相连节点之间的相关性强度设为0,则式(1)转化为式(2)。

$$\mathbf{A} = \begin{bmatrix} 0 & 1 & \cdots & 0 \\ 1 & 0 & \cdots & 0 \\ \vdots & \vdots & & \vdots \\ 0 & 0 & \cdots & 0 \end{bmatrix} \quad (2)$$

1.2 时间特征分析

公交站点客流随着时间推移而不断变化。在不同日期的相同时刻,客流具有相似规律性。因此,历史时段的客流会对未来时段的客流产生一定程度的影响。本文借助公交站点前一周、前一天和当天的历史时刻客流信息来构建特征矩阵,即

$$\mathbf{X}_{n,t} = \mathbf{X}_{n,t}^{(QZ)} \mathbf{X}_{n,t}^{(QT)} \mathbf{X}_{n,t}^{(DT)} \quad (3)$$

$$\mathbf{X}_{n,t}^{(QZ)} = \begin{bmatrix} x_{1,t-m}^{(QZ)} & x_{1,t-m+1}^{(QZ)} & \cdots & x_{1,t}^{(QZ)} \\ x_{2,t-m}^{(QZ)} & x_{2,t-m+1}^{(QZ)} & \cdots & x_{2,t}^{(QZ)} \\ \vdots & \vdots & & \vdots \\ x_{n,t-m}^{(QZ)} & x_{n,t-m+1}^{(QZ)} & \cdots & x_{n,t}^{(QZ)} \end{bmatrix} \quad (4)$$

$$\mathbf{X}_{n,t}^{(QT)} = \begin{bmatrix} x_{1,t-m}^{(QT)} & x_{1,t-m+1}^{(QT)} & \cdots & x_{1,t}^{(QT)} \\ x_{2,t-m}^{(QT)} & x_{2,t-m+1}^{(QT)} & \cdots & x_{2,t}^{(QT)} \\ \vdots & \vdots & & \vdots \\ x_{n,t-m}^{(QT)} & x_{n,t-m+1}^{(QT)} & \cdots & x_{n,t}^{(QT)} \end{bmatrix} \quad (5)$$

$$\mathbf{X}_{n,t}^{(DT)} = \begin{bmatrix} x_{1,t-m}^{(DT)} & x_{1,t-m+1}^{(DT)} & \cdots & x_{1,t}^{(DT)} \\ x_{2,t-m}^{(DT)} & x_{2,t-m+1}^{(DT)} & \cdots & x_{2,t}^{(DT)} \\ \vdots & \vdots & & \vdots \\ x_{n,t-m}^{(DT)} & x_{n,t-m+1}^{(DT)} & \cdots & x_{n,t}^{(DT)} \end{bmatrix} \quad (6)$$

式中: $\mathbf{X}_{n,t}$ 为节点历史客流; n 为节点数,即公交站点数量; t 为当前时刻;上标(QZ)、(QT)和(DT)分别为前一周、前一天和当天; $\mathbf{X}_{n,t}^{(QZ)}$ 、 $\mathbf{X}_{n,t}^{(QT)}$ 和 $\mathbf{X}_{n,t}^{(DT)}$ 分别为公交站点 n 在前一周、前一天和当天的 t 时刻的历史客流输入; m 为时间窗口步长,即公交站点客流的历史时间序列数量。

2 公交站点客流预测模型

2.1 图卷积网络

图卷积网络源自卷积神经网络,能够处理复杂图结构信息,受到研究学者广泛的关注。目前,图卷积网络已成功地应用于交通预测、图分类、目标检测等领域,并且展现出突出的研究效果^[15-17]。

给定一个邻接权重矩阵 $\mathbf{A} \in \mathbf{R}^{n \times n}$ 后,图卷积网络借助多层卷积处理特征信息,提取公交站点客流的空间相关性,即:

$$\mathbf{X}^{(l+1)} = R_{\text{elu}}(\mathbf{D}^{-1/2} \mathbf{B} \mathbf{D}^{-1/2} \mathbf{X}^{(l)} \mathbf{W}^{(l)} + \mathbf{b}) \quad (7)$$

$$\mathbf{B} = \mathbf{A} + \mathbf{I} \quad (8)$$

式中: $\mathbf{X}^{(l+1)}$ 为图卷积网络第 $l+1$ 层的特征矩阵; R_{elu} 为激活函数; $\mathbf{D} \in \mathbf{R}^{n \times n}$ 为 \mathbf{A} 的节点度矩阵; \mathbf{B} 为自连接矩阵; $\mathbf{X}^{(l)} \in \mathbf{R}^{n \times m}$ 为 n 个节点第 l 层的特征矩阵,其中 m 为特征矩阵的列序号; $\mathbf{W}^{(l)} \in \mathbf{R}^{m \times k}$ 为 m 个节点第 l 层训练得到的权重矩阵,其中 k 为权重矩阵的列序号; $\mathbf{b} \in \mathbf{R}^{k \times 1}$ 为偏置向量; $\mathbf{I} \in \mathbf{R}^{n \times n}$ 为单位矩阵。

图卷积网络的原始节点图和操作原理如图1~2所示。从不规则结构图1~2可以看出,GCN能够对图中节点进行有效的分类聚合:首先,GCN捕捉相邻节点1、2的特征信息到节点3进行融合,捕捉相邻节点7、8的特征信息到节点6进行融合;接着,GCN捕捉相邻节点3、5和6的特征信息到节点4进行融合;然后,GCN使用邻接权重矩阵 \mathbf{A} 和历史

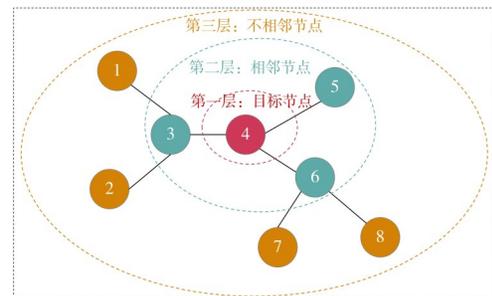


图1 原始节点图

Fig. 1 Original nodes

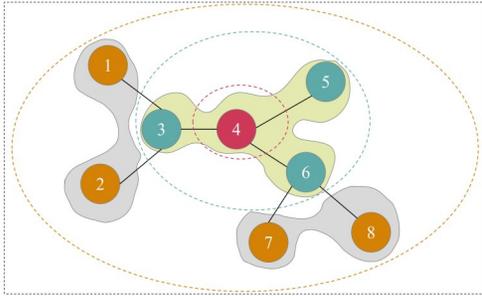


图 2 图卷积操作原理

Fig. 2 GCN operation principle

客流 $X_{n,t}$ 作为输入,经过卷积层堆叠收集不规则结构图中所有相关节点(包括不相邻节点)的特征信息;最后,GCN 训练特征信息迭代更新权重,并输出最佳的权重矩阵,以获取最优的空间相关特征。

2.2 门控递归单元

客流信息的时间相关性是影响公交站点客流预测的关键因素之一。目前,大多数研究学者使用递归神经网络(recursive neural network, RNN)来捕捉时间相关性^[18-20]。RNN 擅长捕捉短期时间相关性,但是缺乏捕捉长期时间相关性的能力。LSTM 和 GRU 可以用作递归神经网络的变体,弥补了上述缺点^[21-24]。LSTM 和 GRU 依据相同的基本原理,选择性地删除输入信息,同时借助门控机制来捕捉长期有效信息。两者的区别在于 GRU 具有模型结构简单、参数较少、训练速度大的优点。因此,本文使用 GRU 来捕捉时间相关性。相关计算方法为式(9)~(12)。

$$z_t = \sigma \{W_z[X_t, h_{t-1}] + b_z\} \quad (9)$$

$$r_t = \sigma \{W_r[X_t, h_{t-1}] + b_r\} \quad (10)$$

$$g_t = T \{W_g[X_t, r_t \times h_{t-1}] + b_g\} \quad (11)$$

$$h_t = (1 - z_t) \times h_{t-1} + z_t \times g_t \quad (12)$$

式中: z_t 为更新门,即 t 时刻历史信息的传递程度; W_z 为传递程度 z_t 的权重; X_t 为公交站点在 t 时刻交通特征信息; h_t 和 h_{t-1} 分别为 t 和 $t-1$ 时刻输出的客流信息; r_t 为重置门,即 t 时刻历史信息的遗忘程度; σ 为激活函数; W_r 为遗忘程度 r_t 的权重; g_t 为 t 时刻经过重置处理需要存储的特征信息; T 为激活函数; W_g 为获取程度的权重; b_z 、 b_r 和 b_g 分别为相应的偏置向量。

同理,在 t 时刻,将 X_{t+1} 和 h_t 作为输入进行上述类似的操作,并输出信息 h_{t+1} ,如图3所示。

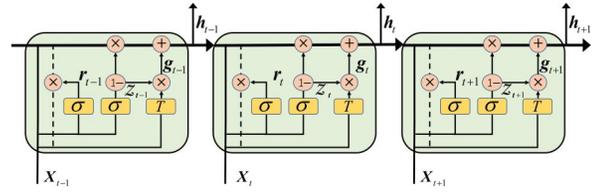


图 3 门控递归单元结构

Fig. 3 Structure of GRU

2.3 G-GCN 模型框架

G-GCN 工作步骤如下:首先,借助 GCN 捕捉公交站点客流的时空相关性;接着,采用 GRU 捕捉公交站点客流的时间相关性;然后,将 $X_{n,t}$ 作为输入数据,预测模型融合客流的时空特征信息;最后,输出预测结果 $X_{n,t+1}$ 。上述过程的数据流动过程和模型框架分别如图4~5所示。本研究采用双层门控递归单元捕捉时间相关性。

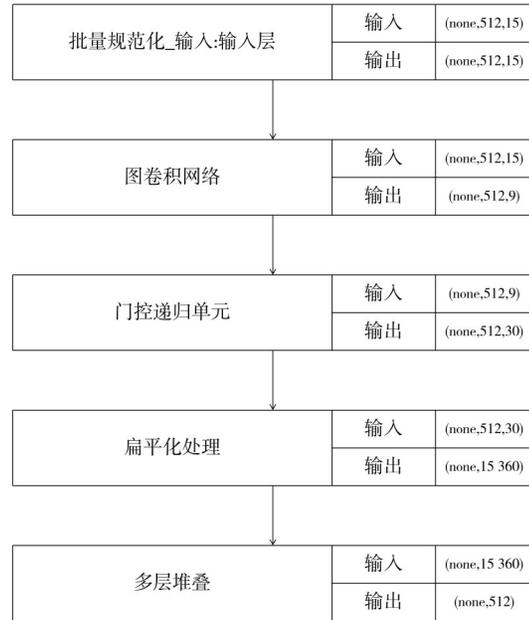


图 4 数据流动过程

Fig. 4 Data flow process

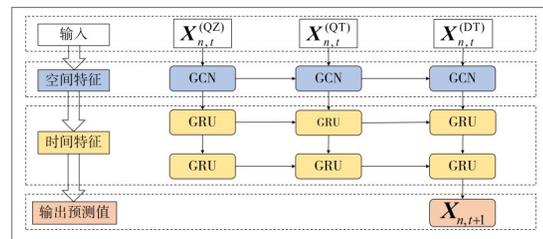


图 5 公交站点客流预测模型框架

Fig. 5 Passenger flow prediction model framework for bus stops

3 数据处理与参数确定

3.1 数据预处理

本文以驻马店市公交刷卡系统的客流记录为测试数据。目前,驻马店市公交刷卡系统采用“一站计价制”,且乘客只要登上公交车入口时刷卡。测试数据涉及驻马店市区的512个公交站点;数据的起始日期为2020年10月12日,结束日期为2020年11月29日。为了避免非工作日的不规则客流对预测结果造成的干扰,本研究选取每周工作日7:00—19:00为研究时间段,如表1所示。

表1 IC卡刷卡记录

Table 1 IC card swipe record

交易时间	...	刷卡站点
2020-10-12 07:10:17	...	乐山大道
2020-10-12 07:11:24	...	天中老街
...
2020-11-29 18:59:45	...	公交西站
2020-11-29 18:59:48	...	实验小学

处理过程中,分别以30、45和60 min为时间粒度对数据进行统计划分,并将划分结果作为输入数据,其中以60 min为时间粒度的客流统计如表2所示。在被输入模型之前,所有的数据都通过最小-最大标准化方法被调整为[0,1]的数据。在对比评价中,预测客流信息将会重新调整为正常值,并与真实客流信息进行对比。另外,前六周的数据被用来训练模型,最后一周的数据被用来测试模型。

表2 60 min时间粒度下公交站点客流统计

Table 2 Passenger flow statistics at bus stops under time granularity of 60 min

公交站点	7:00—8:00	8:00—9:00	...	18:00—19:00
爱家百货	34	11	...	37
儿童公园	24	19	...	30
...
天中老街	35	24	...	55
第一高中	30	23	...	46

3.2 评价指标

本文采用预测客流信息和真实客流信息之间的误差作为指标,并用来评价模型的预测性能。相关计算方法为式(13)~(15)。

$$E_{RMSE} = \sqrt{\sum_{i=1}^n (x_i - \tilde{x}_i)^2 / n} \quad (13)$$

$$E_{MAE} = \sum_{i=1}^n |x_i - \tilde{x}_i| / n \quad (14)$$

$$E_{WMAPE} = \sum_{i=1}^n \left(\frac{x_i}{\sum_{j=1}^n x_j} \left| \frac{x_i - \tilde{x}_i}{x_i} \right| \right) \quad (15)$$

式中: E_{RMSE} 、 E_{MAE} 、 E_{WMAPE} 分别为均方根误差、平均绝对误差、加权平均绝对百分比误差; n 为所有需要预测的公交站点数量; x_i 和 x_j 均为公交站点客流的真实值; \tilde{x}_i 为预测值。

3.3 参数设置

本文模型的参数主要包括时间窗口步长(4、5、6、7、8)、训练批次(8、16、32、64、128)和图卷积核(6、9、12、15、18)。本研究采用控制变量法分别预测客流信息,借助评价指标确定模型的各项参数,并以60 min时间粒度为例,对比各项参数在不同取值情况下的评价指标。不同时间窗口步长、不同训练批次、不同图卷积核的预测效果分别如图6~8所示。

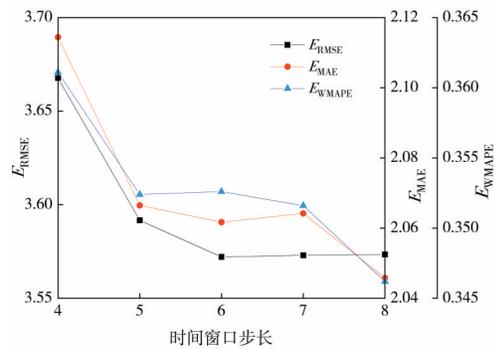


图6 不同时间窗口步长的预测效果

Fig. 6 Prediction effect of different time window step sizes

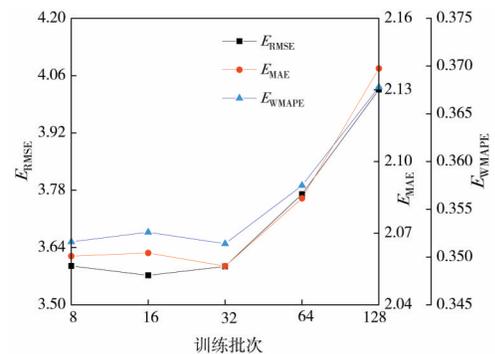


图7 不同训练批次的预测效果

Fig. 7 Prediction effect of different training batches

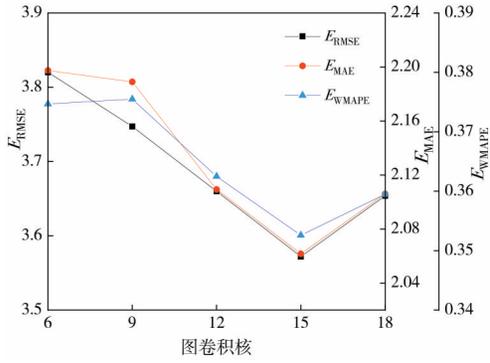


图8 不同图卷积核的预测效果

Fig. 8 Prediction effect of different graph convolution kernels

由图6~8可知:当设置参数时间窗口步长为6、训练批次为16、图卷积核为15时,预测效果的评价指标取得最小值。这说明本文模型能够获得最优异的预测表现。

4 预测结果分析

4.1 预测结果对比

为了评价本文G-GCN模型的预测性能,本研究以驻马店市域内的512个公交站点客流记录为测试数据,将G-GCN与HA、SVR、GCN、GRU和T-GCN这五种基线模型进行对比,如图9~11所示。

与统计回归模型及机器学习方法相比,深度学习方法的预测效果更加出色,这归因于深度学习方法的预测效果更加出色,这归因于深度学习方法的预测效果更加出色,这归因于深度学习方法的预测效果更加出色。

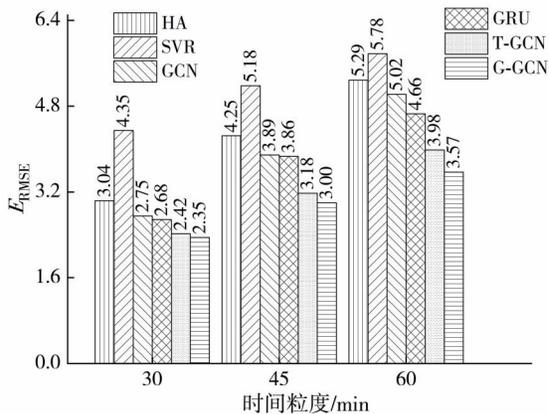


图9 三种时间粒度下不同预测模型的均方根误差

Fig. 9 Root mean square errors of different prediction models under three time granularities

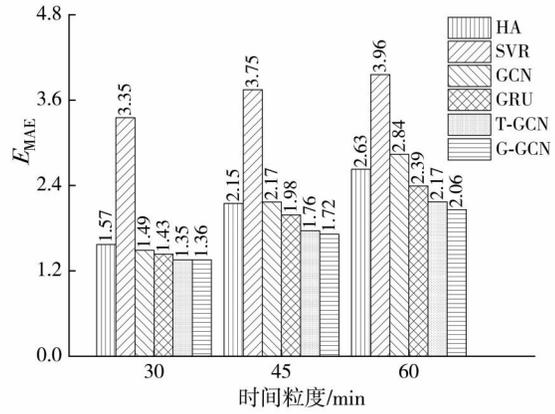


图10 三种时间粒度下不同预测模型的平均绝对误差

Fig. 10 Mean absolute errors of different prediction models under three time granularities

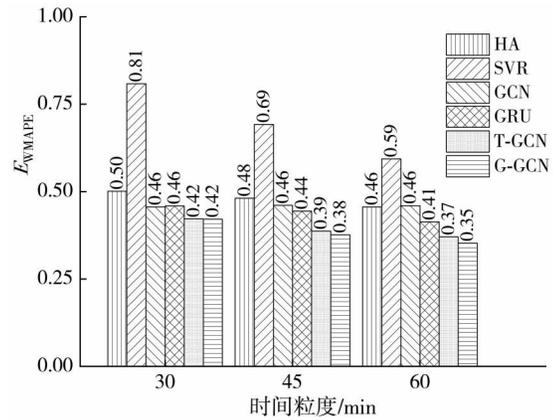


图11 三种时间粒度下不同预测模型的加权平均绝对百分比误差

Fig. 11 Weighted mean absolute percentage error of different prediction models under three granularities

GRU的。这表明,时间特征与空间特征都能够对公交站点客流的变化产生一定的影响。

通过对比上述所有模型在30、45、60 min三种时间粒度下的预测效果,可知:相对其他五种基线模型,G-GCN表现最优,其均方根误差 E_{RMSE} 平均降低了19.60%、24.40%和26.40%,平均绝对误差 E_{MAE} 平均降低了17.00%、22.00%和23.20%,加权平均绝对百分比误差 E_{WMAPE} 平均降低了16.40%、19.80%和21.80%。

4.2 个案分析

本文选取某一站点在30、45和60 min时间粒度下,未来五天和其中一天的真实客流信息与预测客流信息进行拟合分析,并展示模型的预测性能。由图12~14可知:在三种时间粒度下,深度学习模型拥有平稳的预测性能和良好的拟合效果。

这进一步说明:基于深度学习的公交站点客流预测模型擅于捕捉客流信息的空间特征和时间特征,这有助于将其更广泛地应用于交通领域。

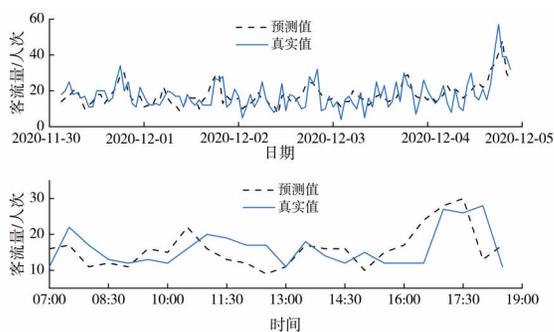


图12 30 min时间粒度下某一站点的拟合预测效果

Fig. 12 Fitting prediction effect of a certain stop under time granularity of 30 min

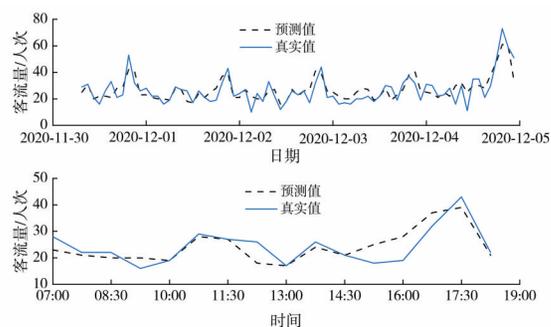


图13 45 min时间粒度下某一站点的拟合预测效果

Fig. 13 Fitting prediction effect of a certain stop under time granularity of 45 min

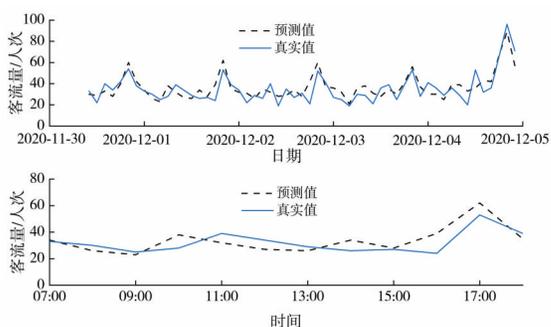


图14 60 min时间粒度下某一站点的拟合预测效果

Fig. 14 Fitting prediction effect of a certain stop under time granularity of 60 min

5 讨论

已有公交客流预测研究主要是关于具体公交线路客流和特定区域站点客流^[10, 13, 25]。然而,对城市全域公交站点客流的预测工作缺乏关注,这

是因为城市尺度客流数据不容易获取。本文通过深度学习方法来捕捉城市全域公交站点客流的时间和空间特征,并用于预测未来客流,且已取得良好的效果。

本文可为城市公交企业的排班计划和发车频率提供技术支持。另外,对于以公交车为主要出行方式的城市居民而言,预先掌握公交站点客流和有效地避开交通高峰时段出行是必要的。这种主动规避行为能够提高公交企业的服务水平和居民的出行满意度。

本文中的时间粒度较大,这是与试验对象有关的。对于三线城市而言,公交站点客流在较小时间粒度下的统计数量较小,因此必须增大时间粒度以满足试验需要。后续研究可考虑使用其他城市的客流数据来验证本文模型的预测能力。另外,天气环境对公交客流具有显著的影响,但限于数据获取及指标量化均存在一定困难,故本文模型仅考虑客流数据本身的时空相关性。后续研究也可尝试构建包含天气环境等影响因素在内的预测模型。

6 结论

本文以公交站点客流预测为研究目标,借助深度学习方法来展开研究工作。主要结论如下:

1) 城市范围内不仅相邻公交站点客流相互影响,而且同一条公交线路的不相邻站点客流同样具有一定的相互影响,即相似时空下客流变化趋势具有一致性。

2) 时间粒度越大,时间相关性对客流影响越显著。空间相关性则不受时间粒度的干扰,其在不同时间粒度时对客流的影响大致相同。

[参考文献]

- [1] XU X Y, LIU J, LI H Y, et al. Analysis of subway station capacity with the use of queueing theory [J]. Transportation Research Part C: Emerging Technologies, 2014, 38: 28-43. DOI: 10.1016/j.trc.2013.10.010.
- [2] 许菲菲,何兆成,沙志仁. 交通管理措施对路网宏观基本图的影响分析[J]. 交通运输系统工程与信息, 2013, 13(2): 185-190. DOI: 10.3969/j.issn.1009-6744.2013.02.028.

- XU Feifei, HE Zhaocheng, SHA Zhiren. Impacts of traffic management measures on urban network microscopic fundamental diagram [J]. *Journal of Transportation Systems Engineering and Information Technology*, 2013, 13(2): 185-190. DOI: 10.3969/j.issn.1009-6744.2013.02.028.
- [3] WEI P, CAO Y, SUN D. Total unimodularity and decomposition method for large-scale air traffic cell transmission model [J]. *Transportation Research Part B: Methodological*, 2013, 53: 1-16. DOI: 10.1016/j.trb.2013.03.004.
- [4] 王茜竹, 江德潮, 徐瑞. 基于SSA-ARMA的公交短时客流实时预测[J]. *计算机工程与设计*, 2019, 40(5): 1489-1494. DOI: 10.16208/j.issn1000-7024.2019.05.052.
- WANG Qianzhu, JIANG Dechao, XU Rui. Short-term bus passenger flow forecasting based on singular spectrum analysis and ARMA [J]. *Computer Engineering and Design*, 2019, 40(5): 1489-1494. DOI: 10.16208/j.issn1000-7024.2019.05.052.
- [5] 武腾飞, 徐慧智, 卢俊. 基于到站间隔的公交站上下客流短时预测[J]. *武汉理工大学学报(交通科学与工程版)*, 2020, 44(6): 1098-1102. DOI: 10.3963/j.issn.2095-3844.2020.06.030.
- WU Tengfei, XU Huizhi, LU Jun. Short-term prediction of up and down passenger flow at bus station based on arrival spacing [J]. *Journal of Wuhan University of Technology (Transportation Science & Engineering)*, 2020, 44(6): 1098-1102. DOI: 10.3963/j.issn.2095-3844.2020.06.030.
- [6] 张春辉, 宋瑞, 孙杨. 基于卡尔曼滤波的公交站点短时客流预测[J]. *交通运输系统工程与信息*, 2011, 11(4): 154-159. DOI: 10.3969/j.issn.1009-6744.2011.04.024.
- ZHANG Chunhui, SONG Rui, SUN Yang. Kalman filter-based short-term passenger flow forecasting on bus stop [J]. *Journal of Transportation Systems Engineering and Information Technology*, 2011, 11(4): 154-159. DOI: 10.3969/j.issn.1009-6744.2011.04.024.
- [7] 陆百川, 邓捷, 马庆禄, 等. 基于IC卡和RBF神经网络的短时公交客流量预测[J]. *重庆交通大学学报(自然科学版)*, 2015, 34(6): 106-110. DOI: 10.3969/j.issn.1674-0696.2015.06.20.
- LU Baichuan, DENG Jie, MA Qinglu, et al. A short-term public transit volume forecasting model based on IC card and RBF neural network, *Journal of Chongqing University (Natural Science)*, 2015, 34(6): 106-110. DOI: 10.3969/j.issn.1674-0696.2015.06.20.
- [8] 黄益绍, 韩磊. 基于改进极限学习机的公交站点短时客流预测方法[J]. *交通运输系统工程与信息*, 2019, 19(4): 115-123. DOI: 10.16097/j.cnki.1009-6744.2019.04.017.
- HUANG Yishao, HAN Lei. Short-term passenger flow prediction method on bus stop based on improved extreme learning machine [J]. *Journal of Transportation Systems Engineering and Information Technology*, 2019, 19(4): 115-123. DOI: 10.16097/j.cnki.1009-6744.2019.04.017.
- [9] LIU W S, TAN Q, WU W. Forecast and early warning of regional bus passenger flow based on machine learning [J]. *Mathematical Problems in Engineering*, 2020, 2020: 6625435. DOI: 10.1155/2020/6625435.
- [10] SUN F, WANG X L, ZHANG Y, et al. Analysis of bus trip characteristic analysis and demand forecasting based on GA-NARX neural network model [J]. *IEEE Access*, 2020, 8: 8812-8820. DOI: 10.1109/ACCESS.2020.2964689.
- [11] MA X L, DAI Z, HE Z B, et al. Learning traffic as images: a deep convolutional neural network for large-scale transportation network speed prediction [J]. *Sensors*, 2017, 17(4): 818. DOI: 10.3390/s17040818.
- [12] 李高盛, 彭玲, 李祥, 等. 基于LSTM的城市公交车站短时客流量预测研究[J]. *公路交通科技*, 2019, 36(2): 128-135. DOI: 10.3969/j.issn.1002-0268.2019.02.017.
- LI Gaosheng, PENG Ling, LI Xiang, et al. Study on short-term traffic forecast of urban bus stations based on LSTM [J]. *Journal of Highway and Transportation Research and Development*, 2019, 36(2): 128-135. DOI: 10.3969/j.issn.1002-0268.2019.02.017.
- [13] LIU P B, ZHANG Y, KONG D H, et al. Improved spatio-temporal residual networks for bus traffic flow prediction [J]. *Applied Sciences*, 2019, 9(4): 615. DOI: 10.3390/app9040615.
- [14] ZHAO L, SONG Y J, ZHANG C, et al. T-GCN: a temporal graph convolutional network for traffic prediction [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2020, 21(9): 3848-3858. DOI: 10.1109/TITS.2019.2935152.
- [15] YU B, LEE Y J, SOHN K. Forecasting road traffic speeds by considering area-wide spatio-temporal dependencies based on a graph convolutional neural network (GCN) [J]. *Transportation Research Part C: Emerging Technologies*, 2020, 114: 189-204. DOI: 10.1016/j.trc.2020.02.013.
- [16] MOU L C, LU X Q, LI X L, et al. Nonlocal graph convolutional networks for hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, 58(12): 8246-8257. DOI: 10.1109/TGRS.2020.2973363.
- [17] QI Y L, LI Q, KARIMIAN H, et al. A hybrid model

- for spatiotemporal forecasting of $PM_{2.5}$ based on graph convolutional neural network and long short-term memory[J]. *Science of The Total Environment*, 2019, 664: 1-10. DOI: 10.1016/j.scitotenv.2019.01.333.
- [18] ZHOU M F, QU X B, LI X P. A recurrent neural network based microscopic car following model to predict traffic oscillation [J]. *Transportation Research Part C: Emerging Technologies*, 2017, 84: 245-64. DOI: 10.1016/j.trc.2017.08.027.
- [19] HAN Y, WANG C, REN Y B, et al. Short-term prediction of bus passenger flow based on a hybrid optimized LSTM network [J]. *ISPRS International Journal of Geo-Information*, 2019, 8(9): 366. DOI: 10.3390/ijgi8090366.
- [20] WANG S Y, ZHAO J, SHAO C F, et al. Truck traffic flow prediction based on LSTM and GRU methods with sampled GPS data [J]. *IEEE Access*, 2020, 8: 208158-208169. DOI: 10.1109/ACCESS.2020.3038788.
- [21] 张国赞, 金辉. 基于改进 ARIMA 模型的城市轨道交通短时客流预测研究[J]. *计算机应用与软件*, 2022, 39(1): 339-344. DOI: 10.3969/j.issn.1000-386x.2022.01.052.
- ZHANG Guoyun, JIN Hui. Research on the prediction of short-term passenger flow of urban rail transit based on improved ARIMA model[J]. *Computer Applications and Software*, 2022, 39(1): 339-344. DOI: 10.3969/j.issn.1000-386x.2022.01.052.
- [22] 王福建, 俞佳浩, 赵锦焕, 等. 基于站点实时关联度的短时公交客流预测方法[J]. *交通运输系统工程与信息*, 2021, 21(6): 131-144. DOI: 10.16097/j.cnki.1009-6744.2021.06.015.
- WANG Fujian, YU Jiahao, ZHAO Jinhuan, et al. Short-term public traffic passenger volume forecasting method based on real-time relevance of stations [J]. *Journal of Transportation Systems Engineering and Information Technology*, 2021, 21(6): 131-144. DOI: 10.16097/j.cnki.1009-6744.2021.06.015.
- [23] 段中兴, 温倩, 周孟, 等. 基于改进蝙蝠算法优化 LSTM 网络的短时客流预测[J]. *铁道科学与工程学报*, 2021, 18(11): 2833-2840. DOI: 10.19713/j.cnki.43-1423/u.T20201153.
- DUAN Zhongxing, WEN Qian, ZHOU Meng, et al. Short-term passenger flow prediction based on improved bat algorithm to optimize LSTM network [J]. *Journal of Railway Science and Engineering*, 2021, 18(11): 2833-2840. DOI: 10.19713/j.cnki.43-1423/u.T20201153.
- [24] ZHENG Z H, LING X M, WANG P, et al. Hybrid model for predicting anomalous large passenger flow in urban metros [J]. *IET Intelligent Transport Systems*, 2020, 14(14): 1987-1996. DOI: 10.1049/iet-its.2020.0054.
- [25] 赵建东, 申瑾, 刘麟玮. 多源数据驱动 CNN-GRU 模型的公交客流量分类预测[J]. *交通运输工程学报*, 2021, 21(5): 265-273. DOI: 10.19818/j.cnki.1671-1637.2021.05.022.
- ZHAO Jiandong, SHEN Jin, LIU Linwei. Bus passenger flow classification prediction driven by CNN-GRU model and multi-source data[J]. *Journal of Traffic and Transportation Engineering*, 2021, 21(5): 265-273. DOI: 10.19818/j.cnki.1671-1637.2021.05.022.

(责任编辑:彭三军;校对:刘平)