



计算机科学

COMPUTER SCIENCE

探索站点时空移动模式:长短期交通预测框架

沈哲辉, 王开来, 孔祥杰

引用本文

沈哲辉, 王开来, 孔祥杰. [探索站点时空移动模式:长短期交通预测框架](#) [J]. 计算机科学, 2023, 50(7): 98-106.

SHEN Zhehui, WANG Kailai, KONG Xiangjie. [Exploring Station Spatio-Temporal Mobility Pattern:A Short and Long-term Traffic Prediction Framework](#) [J]. Computer Science, 2023, 50(7): 98-106.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于遗传算法的恶意软件对抗样本生成方法](#)

Adversarial Malware Generation Method Based on Genetic Algorithm

计算机科学, 2023, 50(7): 325-331. <https://doi.org/10.11896/jsjcx.220800176>

[基于深度学习的活跃IPv6地址预测算法](#)

Deep Learning-based Algorithm for Active IPv6 Address Prediction

计算机科学, 2023, 50(7): 261-269. <https://doi.org/10.11896/jsjcx.220700076>

[基于时序知识图谱嵌入的短期地铁客流量预测](#)

Short-term Subway Passenger Flow Forecasting Based on Graphical Embedding of Temporal Knowledge

计算机科学, 2023, 50(7): 213-220. <https://doi.org/10.11896/jsjcx.220600120>

[面向单一背景改进RetinaNet目标检测方法研究](#)

Study on Single Background Object Detection Oriented Improved-RetinaNet Model and Its Application

计算机科学, 2023, 50(7): 137-142. <https://doi.org/10.11896/jsjcx.220500066>

[面向自动驾驶的三维目标检测综述](#)

Review of 3D Object Detection for Autonomous Driving

计算机科学, 2023, 50(7): 107-118. <https://doi.org/10.11896/jsjcx.220700090>

探索站点时空移动模式:长短期交通预测框架

沈哲辉¹ 王开来² 孔祥杰¹

¹ 浙江工业大学计算机科学与技术学院 杭州 310023

² 大连理工大学软件学院 大连 116620

(shenzhehui198@outlook.com)

摘要 随着智慧城市系统的技术发展与城市时空数据的急剧增加,公共服务需求也日益受到重视。公共交通作为城市交通中至关重要的组成部分,同样面临着巨大的挑战,并且交通网络的时空预测任务往往是解决各种交通问题的核心一环。交通中的移动模式可以体现城市人群的出行行为及其规律,大多数交通预测任务研究中,移动模式的重要性经常被忽视。针对现有工作的问题,提出了一种多模式的交通预测框架(MPGNNFormer),使用基于图神经网络的深度聚类的方法提取站点的移动模式,并设计了一种基于Transformer的时空预测模型,在充分利用时间依赖关系和空间依赖关系的同时,提高了计算效率。在现实的公交车数据集上展开了一系列实验以进行评估和测试,包括移动模式的分析和预测结果对比,实验结果证明了所提方法在交通网络的长短期交通预测上的有效性。最后讨论了所提方法可扩展性。

关键词: 时空数据挖掘;长短期交通预测;移动模式;深度学习

中图法分类号 TP183

Exploring Station Spatio-Temporal Mobility Pattern: A Short and Long-term Traffic Prediction Framework

SHEN Zhehui¹, WANG Kailai² and KONG Xiangjie¹

¹ College of Computer Science and Technology, Zhejiang University of Technology, Hangzhou 310023, China

² School of Software, Dalian University of Technology, Dalian, Liaoning 116620, China

Abstract With the technological development of intelligent transportation system and the surging spatio-temporal data in urban, the demand for public services is increasingly emphasized. As a vital part of urban transportation, public transportation also faces enormous challenges, and the spatio-temporal prediction task in transportation network is the core of the solutions for various traffic problems. Mobility pattern in traffic can reflect the travel behaviors of people and their rules. In most studies on traffic prediction task, the importance of mobility pattern is neglected. In view of the problem of existing work, a multi-pattern traffic prediction framework, MPGNNFormer, is proposed, in which based-graph neural network deep clustering method is used to extract mobility patterns of stations, and a Transformer-based spatio-temporal prediction model is designed to learn temporal dependence and spatial dependence of stations and to improve the computational efficiency. Then, a series of experiments are conducted on real bus dataset for evaluation and testing, including analysis of mobility patterns and comparison of prediction results. Finally, experimental results prove the efficacy of proposed method in the short and long-term traffic prediction of traffic networks, and its scalability is discussed.

Keywords Spatio-Temporal data mining, Short and long-term traffic prediction, Mobility pattern, Deep learning

1 引言

近年来,包括物联网(Internet of Things, IoT)、云计算、边缘计算等在内的网络、信息与通信技术的飞速发展,推动了智慧城市的建设^[1-2]。其中一个最重要的应用场景就是智慧交通系统(Intelligent Transportation System, ITS)。同时,现有

的大多数交通问题都和交通流量状况息息相关,与其变化存在紧密的因果关系^[3-4]。此外,随着信息化的城市交通工业的发展,每天都会产生大量的时空数据,且这些数据的来源、结构复杂多样^[5-6]。

然而,城市中仍然不断出现公共交通拥堵和资源分配不合理等新的交通问题,促使学者们对此展开研究^[7]。目前,

到稿日期:2022-09-13 返修日期:2022-12-01

基金项目:国家自然科学基金(62072409);浙江省自然科学基金(LR21F020003)

This work was supported by the National Natural Science Foundation of China(62072409) and Natural Science Foundation of Zhejiang Province, China(LR21F020003).

通信作者:孔祥杰(xjkong@ieee.org)

交通流量预测主要是基于时序预测算法来完成的,主要的技术有:基于传统的数理统计的算法和基于深度学习的预测算法^[8-10]。但这些研究工作在解决交通流量预测任务时,忽略了人群移动行为的存在,针对不同群体或不同区域的预测效果并不尽如人意。

此外,图(Graph)数据结构长久以来都被作为一种抽象且有效的数据结构,它能够更直观地发现数据中的关系或交互行为。而图学习技术在提取拓扑网络结构的空关系特征方面有着很好的表现,尤其是图神经网络(Graph Neural Network, GNN),其能够显式地将图、节点、边等在低维空间表示成向量形式,也被称作图嵌入(Graph Embedding),并将重要的属性、关系等信息保留在向量中,大大提高下游分析任务的表现^[11]。

本文的主要贡献如下:

(1)提出了一种新颖的交通预测框架(MPGNNFormer),在长短期交通时空预测中结合站点移动模式提高预测的表现和效率。

(2)针对长短期的复杂交通预测场景,设计了一种基于Transformer的时空预测模型(STGNNFormer)。在时间依赖关系的提取上,融入时序分解、自相关机制来降低时序计算的复杂度,而空间依赖关系的提取利用的是可学习的自适应图。

(3)基于真实的公交车数据集展开了一系列实验,包括移动模式的分析、短期和长期交通预测,实验结果证明了本文方法的有效性。

本文第2节介绍图神经网络和交通预测的相关工作;第3节主要介绍所提框架模型(MPGNNFormer)的具体细节;第4节展示实验过程和结果并分析得出结论;最后总结全文。

2 相关工作

2.1 图神经网络

过去几年里,传统的神经网络方法在提取欧氏空间(Euclidean Space)数据特征上获得了优秀的成绩,但实际工业场景的很多数据是从非欧氏空间生成的,使得传统的神经网络很难直接应用于这类数据。随着学者们对深度学习在图上的扩展越来越感兴趣,在其他深度学习算法获得成功的基础上,引入CNN(Convolutional Neural Network)、RNN(Recurrent Neural Network)和深度自动编码器(Auto-Encoder)的思想,产生了一个新的研究热点——图神经网络(Graph Neural Network, GNN)^[12-13],特别是图卷积(Graph Convolutional)被广泛应用于各个领域。GCN也可被视为计算机视觉领域中的CNN在图数据结构上的一个扩展,Bruna等最早提出在图数据结构上进行卷积操作^[14]。由于GCN对图数据结构的强大的表示能力,大量研究和应用任务得以进一步发展,常见的任务有节点分类^[15]、节点聚类^[16]、链路预测^[17]等。

2.2 交通预测

交通流量预测在智能交通系统中起着至关重要的作用^[18],而交通流量预测任务中的相关算法与时序预测算法息息相关。代表性的带参的数理统计方法有:历史平均(Historical Average, HA)、自回归(Auto-Regressive, AR)、向量自回归(Vector Auto-Regressive, VAR)、自回归积分移动平均

(Auto-Regressive Integrated Moving Average, ARIMA)及其变体算法等^[8]。传统机器学习的方法有支持向量机(Support Vector Regression, SVR)^[19]、最近邻回归(Nearest Neighbor Regression, NNR)等^[20]。

对于愈发复杂多样的数据,深度学习模型可以将基本的学习模块进行堆叠,形成深层结构体系。Liu等使用无监督的堆叠自编码器(SAE)和有监督的神经网络设计了一种交通预测模型^[21]。另外,RNN和CNN也可以很好地适用于交通预测。如LSTM^[22]、ConvLSTM^[23]及其变体。

此外,对于交通网络的动态特征捕捉和预测,除了时间上的相关性,空间上的相关性也起着至关重要的作用^[24]。作为最有效的解决方案之一,时空图神经网络(Spatial-Temporal Graph Neural Network, STGNN)可以同时兼顾图的空间和时间的依赖性,在交通网络的时空预测中被广泛应用和研究。一般来说,时间上的依赖性可以通过基于RNN的方法获取,而空间上的依赖性则通过图卷积来捕捉,如GCRN(Graph Convolutional Recurrent Network)^[25]、DCRNN(Diffusion Convolutional Recurrent Neural Network)^[26]等。为了解决RNN存在的计算复杂度较高和梯度爆炸/消失的问题,采用基于CNN的方法,以非递归的方式处理时空图,以此保证模型的并行计算,稳定梯度和降低内存需求。ST-GCN^[27]将卷积层和图卷积层相结合来提取时空特征,并在一定程度上降低了计算复杂度;ASTGCN^[28]引入注意力机制学习潜在的动态时空依赖;STSGCN^[29]能够额外捕获时空的异质性。除了利用预定义的图结构,也可以自适应地从数据中学习潜在的静态图结构,如Graph WaveNet^[30]和AGCRN^[31]引入了自适应邻接矩阵,在没有给出邻接矩阵时,也具有较好的预测效果。

基于自注意力机制^[32](Self-Attention Mechanism)的Transformer类的模型在序列数据的处理任务中有着强劲的表现,然而对于长期时序预测,自注意力机制的计算复杂度为 $O(L^2)$,并不适用于长期时序预测。因此,许多研究工作致力于降低其计算复杂度,如LogTrans^[33]、ReForm^[34]、Informer^[35]、Autoformer^[36]等。本文结合公交车乘客流量预测的长短期时空预测场景,将同时考虑计算的效率和预测的准确性设计一种高效的时空预测模型^[37-38]。

3 方法设计

3.1 整体框架

为了更准确和高效地展开长短期交通时空预测任务,本文提出了MPGNNFormer,其整体算法流程框架如图1所示。在对数据进行预处理和清洗后,得到标准的时空数据、站点特征信息和预定义关系网络,包括站点的线路网络和距离网络。其次,采用深度聚类模型,利用站点特征和距离网络进行站点移动模式的提取,得到各自的模式标签。然后,采取多模式的方式进行预测工作,即对各个移动模式分别训练时空预测模型(STGNNFormer),再进行整合得到最终的站点的交通预测结果。这里假设共有 K 个站点移动模式,于是可以得到模式 p_i 的节点数量为 $N_{v,i}$,且 $|V_s| = \sum_{i=1}^K N_{v,i}$ 。与单独训练相比,这样做可以有效地减少对内存空间的需求,在有限的硬件资源下,使得内存空间开销从 $O(|V_s|^2)$ 优化为 $O(\sum |N_{v,i}|^2)$ 。

最后的预测结果是由每个模式的预测结果拼接而成,即 $\hat{\mathbf{Y}} = \text{concat}(\hat{\mathbf{Y}}_1, \dots, \hat{\mathbf{Y}}_K)$.




图1 MPGNNFormer 算法流程框架

Fig. 1 MPGNNFormer algorithmic process framework

3.2 站点移动模式提取

为了能够有效地提取站点的空间关系,这里将公交车站点网络设置为距离关系网络,可以表示为一个无向图 $\mathcal{G}_s^{\text{dist}} = (V_s, \epsilon_s^{\text{dist}}, \mathbf{A}_s^{\text{dist}})$ 。站点关系的定义和邻接矩阵的计算由实际交通网络中站点之间的空间距离决定。 $\mathbf{A}_s^{\text{dist}} \in \mathbb{R}^{|V_s| \times |V_s|}$ 的各个元素值的计算式如下:

$$a_{ij}^{\text{dist}} = \begin{cases} \exp\left(-\frac{\text{dist}(v_i, v_j)^2}{\sigma^2}\right), & i \neq j \text{ 且 } \exp\left(-\frac{\text{dist}(v_i, v_j)^2}{\sigma^2}\right) \geq \epsilon \\ 0, & \text{否则} \end{cases} \quad (1)$$

其中, $\text{dist}(v_i, v_j)$ 表示站点 v_i 和 v_j 的空间距离(由经纬度计算得到); σ^2 和 ϵ 为两个阈值,分别控制邻接矩阵的分布和稀疏性(这里分别设置为 1000^2 和 0.1)。 ϵ_s^{dist} 中的元素取决于 $\mathbf{A}_s^{\text{dist}}$ 各元素的数值,即当 $a_{ij}^{\text{dist}} > 0$, $e_{i,j} \in \epsilon_s^{\text{dist}}$ 成立。

另外,为了对该潜在问题进行优化,在构建各个站点的特征时,我们利用训练集中的时序数据作为站点的特征时间向量。在这里一天的时间步长数为 156(一天有 13 个小时的数据,每小时每 5 分钟进行一次采样,即一个小时的时间步长数为 12),由此,站点的特征维度 $d_s = 156$,站点的特征矩阵可以表示为 $\mathbf{X}_s \in \mathbb{R}^{|V_s| \times d_s}$ 。

在提取站点移动模式^[39]的方法上,所提深度聚类模型与文献[39]中基于 GCN 的深度聚类方法一致。在数据上,将输入替换为站点距离关系网络 $\mathcal{G}_s^{\text{dist}}$ 和站点的特征矩阵 \mathbf{X}_s ,并在模型参数上进行了一定的修改。

3.3 STGNNFormer

在一般的短期预测中,Transformer 模型的自注意力机制可以有效地提取时间依赖关系。然而在长期预测问题中,长时序的时间依赖关系变得更加复杂。受到文献[33]的启发,在各个移动模式的长短期时空预测问题中,为了同时提高计算效率和对时空信息的利用,对 Transformer 设计了一种高效的时空预测模型(STGNNFormer),如图 2 所示。时间依赖关系提取的主要核心在于将时序分解(Series Decomposition)的思想融入编码器-解码器架构,并且利用自注意力机制和自相关机制(Auto-Correlation Mechanism)分别获取短期和长期时间依赖关系,空间依赖关系的提取由数据自适应图(Data Self-Adaptive Graph)的 GNN 层来实现。此外,对原始时序数据的嵌入模块也进行了一定的修改,设计了一种时空嵌入(Spatial-Temporal Embedding)的方法,使得输入数据不仅包含数据本身的信息,还包含时序位置顺序信息、时间戳信息和空间位置信息。

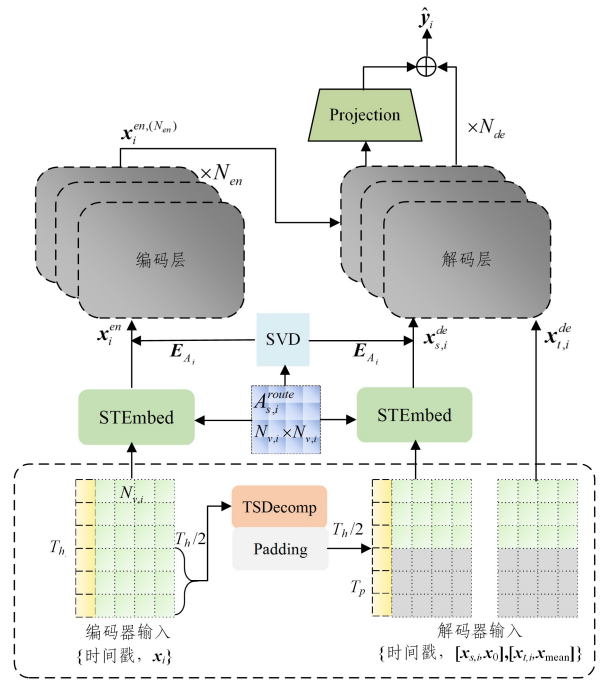


图2 STGNNFormer 模型架构

Fig. 2 STGNNFormer model framework

在站点网络的交通流量预测中,预定义的公交车站点网络取决于公交线路网络,其定义表示为一个有向图 $\mathcal{G}_s^{\text{route}} = (V_s, \epsilon_s^{\text{route}}, \mathbf{A}_s^{\text{route}})$ 。其中, V_s 表示公交车站点集合; $\epsilon_s^{\text{route}}$ 表示站点关系边的集合,其边的建立依赖于实际公交线路的连接,例如在某一公交线路中站点 v_i 的下一站为 v_j ,则 $e_{i,j} \in \epsilon_s^{\text{route}}$ 成立(注意,由于是有向图, $e_{j,i}^{\text{route}}$ 并不一定存在)。 $\mathbf{A}_s^{\text{route}} \in \mathbb{R}^{|V_s| \times |V_s|}$ 是由 $\epsilon_s^{\text{route}}$ 建立的带权邻接矩阵,即 $e_{i,j} \in \epsilon_s^{\text{route}}$,则 $a_{ij}^{\text{route}} > 0$,其数值将由实际世界的空间地理决定,否则 $a_{ij}^{\text{route}} = 0$ 。

接下来,对 STGNNFormer 的细节进行详细说明。

3.3.1 基于时序分解的编码器-解码器架构

首先,对于输入 $X \in \mathbb{R}^{T \times N_s \times d}$, T, N_s, d 分别表示时序长度、图的节点数量和嵌入向量特征维度。时序分解块的计算过程为:

$$\begin{aligned} \mathbf{X}_t &= \text{AvgPool}(\mathbf{X}) \\ \mathbf{X}_s &= \mathbf{X} - \mathbf{X}_t \end{aligned} \quad (2)$$

其中, $\mathbf{X}_s, \mathbf{X}_t \in \mathbb{R}^{T \times N_s \times d}$ 分布表示分解得到的季节性部分和趋势部分, $\text{AvgPool}(\cdot)$ 通过平均池化操作来实现移动平均,在平均池化前需要进行复制填补。此外,时序分解块是一个内部计算,不需要额外参数,可以用 $\mathbf{X}_s, \mathbf{X}_t = \text{TSDecomp}(\mathbf{X})$ 表示该模块操作。

接下来,在解码器部分借鉴自然语言处理中利用起始标记(Start Token)的动态解码的思路。这里选择历史时序数据的后半段作为起始标记,并用特定值进行填充拼接,拼接长度为所需预测长度,将其作为待预测的目标时序的占位符(Placeholder)。设定原始输入时空数据为 $\mathbf{X} \in \mathbb{R}^{T_h \times N_s \times C}$ (C 为真实时序数据特征维度),通过时空嵌入(STEmbed)后得到编码器的输入数据为 $\mathbf{X}^{\text{en}} \in \mathbb{R}^{T_h \times N_s \times d}$,如图 2 中的编码器和解码器输入部分,在引入时序分解后的解码器包含趋势和季节性两部分,将其作为输入 $\mathbf{X}_t^{\text{de}} \in \mathbb{R}^{\left(\frac{T_h}{2} + T_p\right) \times N_s \times C}$, $\mathbf{X}_s^{\text{de}} \in$

$\mathbb{R}^{\left(\frac{T_h}{2}+T_p\right)\times N_v\times d}$,公式化后如下:

$$\begin{aligned} \mathbf{X}_s, \mathbf{X}_t &= \text{TSDecom}p\left(\mathbf{X}\left[\frac{T_h}{2}:T_h\right]\right) \\ \mathbf{X}_s^{de} &= \text{STEmbed}(\text{Concat}(\mathbf{X}_s, \mathbf{X}_0)) \\ \mathbf{X}_t^{de} &= \text{Concat}(\mathbf{X}_t, \mathbf{X}_{\text{mean}}) \end{aligned} \quad (3)$$



图3 STGNNFormer的编码层和解码层网络结构细节

Fig. 3 Network structure details of STGNNFormer's encoding layer and decoding layer

从图3中可以看出,与Transformer不同,STGNNFormer将自注意力层替换为自相关层(AutoCorr)学习时间上的依赖关系,将全连接的前馈网络层替换为自适应GNN层(AdaGNN)来学习空间上的依赖关系,中间穿插时序分解模块,这里去除了Transformer中的层标准化操作。假设编码器有 N_{en} 个编码层组成,第 l 层的编码层可以简单总结为 $\mathbf{X}^{\text{en},(l)} = \text{Encoder}(\mathbf{X}^{\text{en},(l-1)})$ 。如图3(a)所示,使用 $\mathbf{X}_{s2}^{\text{en},(l)}$ (编码层中TSDecom₂的季节性部分)作为每一层的输出 $\mathbf{X}^{\text{en},(l)}$, $l \in \{1, 2, \dots, N_{\text{en}}\}$,且 $\mathbf{X}^{\text{en},(0)} = \mathbf{X}^{\text{en}}$,在该过程中并没有使用趋势部分,编码器的最终输出 $\mathbf{X}^{\text{en},(N_{\text{en}})}$ 将作为交叉信息用于解码器。

3.3.2 数据自适应图

这里采用一种数据自适应图的构建方法,用于图卷积操作。自适应图的邻接矩阵构建需要使用一个可学习的节点嵌入 $\mathbf{E}_A \in \mathbb{R}^{N_v \times d_v}$ 作为基础,其中 d_v 为超参,表示节点嵌入的特征维度。如果存在预先定义的邻接矩阵,可以将矩阵的奇异值分解(Singular Value Decomposition)用于节点嵌入的初始化,否则随机初始化即可。由此,图卷积操作中使用到的归一化后的邻接矩阵可以表示为:

$$\hat{\mathbf{A}} = \tilde{\mathbf{D}}^{-\frac{1}{2}} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-\frac{1}{2}} = \mathbf{I}_{|N_v|} + \mathbf{D}^{-\frac{1}{2}} \mathbf{A} \mathbf{D}^{-\frac{1}{2}} = \mathbf{I}_{|N_v|} + \text{Softmax}(\text{ReLU}(\mathbf{E}_A \cdot \mathbf{E}_A^T)) \quad (4)$$

其中,Softmax(\cdot)和ReLU(\cdot)均为激活函数,前者的作用是对生成得到的邻接矩阵进行归一化。这样,在训练过程中会自适应地学习和更新节点嵌入,学习潜在的空间依赖关系,具有更好的可解释性,同时也在不断更新邻接矩阵,得到的自适应邻接矩阵可用于图卷积操作(AdaGNN)。

3.3.3 自注意力机制和自相关机制

自注意力机制主要用于短期预测任务中,它是Transformer中的一个重要模块,其计算流程实现如图4(a)所示,可以简单将其描述为将查询(Query)和一组键值对(Key-Value pairs)映射到输出中。在这里,注意力函数的计算式如下:

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_k}}\right)\mathbf{V} \quad (5)$$

其中, $\mathbf{X}_s, \mathbf{X}_t \in \mathbb{R}^{\frac{T_h}{2} \times N_v \times c}$ 表示对历史时序数据 \mathbf{X} 的后半段进行时序分解后的结果; $\mathbf{X}_0, \mathbf{X}_{\text{mean}} \in \mathbb{R}^{T_p \times N_v \times c}$ 表示预测时序数据的占位符,分别代表0值和 \mathbf{X} 的均值。时空嵌入的方法(STEmbed)将在下文详细介绍。

编码器和解码器每层的网络结构如图3所示。

其中, $\mathbf{Q}, \mathbf{K}, \mathbf{V}$ 分别为查询、键、值的向量矩阵, d_k 是特征维度,用于归一化处理。

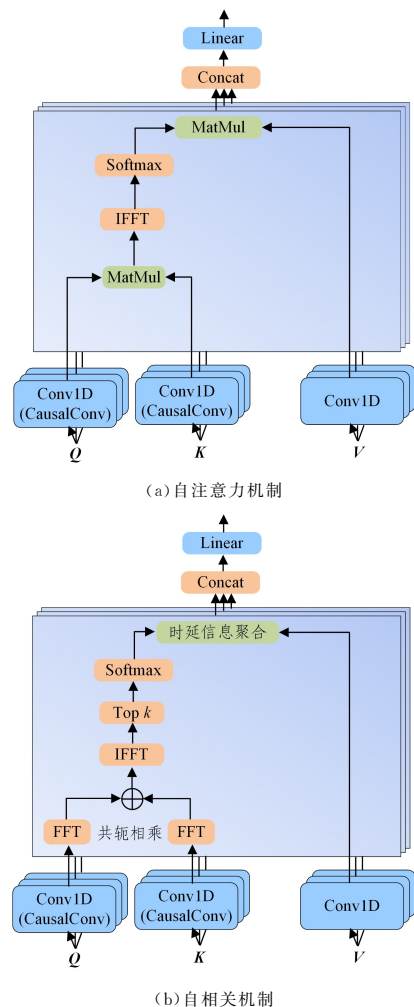


图4 自注意力机制和自相关机制的计算过程

Fig. 4 Calculation process of autoattention mechanism and autocorrelation mechanism

在自注意力机制中,时序数据在时间依赖关系中的获取往往是通过点向(Point-wise)连接聚合的方式进行的,其计算复杂度为 $O(T^2)$,在长时序预测上不仅计算效率会大打折扣,而且很难发现有效的时间依赖关系,因此这里使用自相关机制来取代之。

首先,对于周期时间段的时间依赖关系的挖掘,可以通过序列的自相关计算来表示。基于随机过程理论(Stochastic Process Theory),时间序列可被视为离散时间过程 $\{X_t\} \in \mathbb{R}^T$,由此其自相关系数 $\mathcal{R}_{X,X}(\tau)$ 的计算可以写成如下形式:

$$\mathcal{R}_{X,X}(\tau) = \lim_{T \rightarrow \infty} \frac{1}{T} \sum_{t=1}^T X_t X_{t-\tau} \quad (6)$$

其中, $\mathcal{R}_{X,X}(\tau)$ 表示序列 $\{X_t\}$ 与其自身在延迟 τ 步的序列 $\{X_{t-\tau}\}$ 的相似性,也可以理解为未归一化的时间段长为 τ 下的置信度。并且,可以基于维纳-辛钦(Wiener-Khinchin)定理,利用快速傅立叶变换(Fast Fourier Transforms)来优化自相关计算过程:

$$\begin{aligned} \mathcal{F}_{X,X}(f) &= \mathcal{F}(X_t) * \overline{\mathcal{F}(X_t)} \\ &= \int_{-\infty}^{\infty} X_t e^{-i2\pi f t} dt \int_{-\infty}^{\infty} X_t e^{-i2\pi f t} dt \end{aligned} \quad (7)$$

$$\mathcal{R}_{X,X}(\tau) = \mathcal{F}^{-1}(\mathcal{F}_{X,X}(f)) = \int_{-\infty}^{\infty} \mathcal{F}_{XX}(f) e^{i2\pi f \tau} df$$

其中, $\mathcal{F}(\cdot)$ 和 $\mathcal{F}^{-1}(\cdot)$ 分别表示快速傅立叶变换和其逆变化, $*$ 表示共轭相称, $\mathcal{F}_{XX}(f)$ 为时序在频域的表达形式。通过该优化,可以有效地将复杂度降为 $O(T \log T)$ 。

接下来,对相似度最高的若干个子序列进行时延信息聚合操作。计算得到自相关,即序列在各种步长延迟情况下的相似度后,首先取前 $k = \lfloor \epsilon \times \log T \rfloor$ 个相似度最高的时间段,其长度为 $\tau_1, \dots, \tau_k = \arg \text{Top } k \mathcal{R}_{Q,K}(\tau)$,并使用 $\text{Roll}(\cdot)$ 操作时延信息对齐相似的子序列和待估计序列的位置。在信息聚合时,先使用 $\text{Softmax}(\cdot)$ 对原自相关值进行归一化得到 $\hat{\mathcal{R}}_{Q,K}(\tau)$,并将其作为各子序列权重以完成时延信息聚合。最终,自相关机制计算过程如图 4(b) 所示,可以写成如下形式:

$$\text{AutoCorr}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \sum_{i=1}^k \text{Roll}(\mathbf{V}, \tau_i) \hat{\mathcal{R}}_{Q,K}(\tau_i) \quad (8)$$

其中, ϵ 为超参,用于选择相似子序列数量, $\mathbf{Q}, \mathbf{K}, \mathbf{V}$ 对应自注意力机制中的查询、键、值,因此,可以用其直接替换自注意力机制模块。

另外,与一般的注意力机制不同的是,STGNNFormer 在编码器中的自相关层使用一维卷积操来替代原本的线性投影($\text{Linear}(\cdot)$)操作。同样,为了遮掩未来信息,解码器中会使用因果卷积来代替标准的一维卷积。图 5 清晰地显示了自相关机制和自注意力机制在计算时间依赖关系上的差异。




图 5 点向的自注意力机制和序列向的自相关机制对比

Fig. 5 Comparison of point-directed autoattention mechanism and sequential autocorrelation mechanism

3.3.4 时空嵌入

时空数据的特征非常复杂,有效的嵌入表示可以帮助模型更有效地学习。因此,这里设计了一种具有针对性的时空嵌入方式,包括数据上下文嵌入(Context Embedding, CEmbed)、时序位置编码嵌入(Temporal Positional Embedding, TPEmb)、时间戳特征嵌入(Stamp Feature Embedding, TFEmb)和空间位置嵌入(Spatial Positional Embedding, SPEmb)。

数据上下文嵌入指对原始时序数据进行编码,简单地采用一维卷积来实现。时序位置编码嵌入与 Transformer 的位置编码计算一致。虽然时序位置编码可以在一定程度上反映时间关系,但它只能表示局部的上下文关系。因此,这里使用时间戳特征嵌入,融入全局的时间戳特征,即利用时序数据某一位置的时间戳信息(如分钟、小时、周、月等),由离散的信息转换成连续的表示向量。最后,为了捕捉不同节点的静态的空间拓扑结构特征,先将每个节点的索引号投影成模型嵌入向量特征维度,再通过多层平滑的图卷积得到节点的空间位置嵌入。因此,时空嵌入的过程可以表示成如下形式:

$$\text{STEmbed}(\mathbf{X}) = \text{CEmb}(\mathbf{X}) + \text{TPEmb}(\mathbf{X}) + \text{TFEmb}(\mathbf{X}) + \text{SPEmb}(\mathbf{X}) \quad (9)$$

4 实验与分析

本节进一步展开交通网络的时空预测实验,包括短期和长期预期,验证 MPGNNFormer 在真实世界数据下的预测的有效性。首先给出数据描述、实验中模型的具体参数设定和实现细节;然后对多模式预测效果进行评估,并对最佳效果的各站点移动模式展开分析;最后通过与其他预测算法的对比,评估 MPGNNFormer 的性能,证明其有效性。

4.1 数据描述

实验采用真实世界的公交数据集,该数据集由江苏熊猫公交公司生成并提供,包括从 2020 年 4 月 1 日至 2020 年 5 月 31 日共 58 天的时空数据(除去了 3 天缺失的异常数据),且这里截取一天的数据时长为 13 h(时间范围从 6 点至 19 点)。通过对原始数据的处理,包括站点匹配、OD 匹配、路径扩充和缺失填补,最后以每 5 min 为一个时间步,得到时空预测所需的交通网络的流量分布,整个流量数据包括 1120 个站点以及 9048 个时间步数,取最后 7 天的数据用于测试评估。

4.2 实验参数和实现细节

深度聚类模型保持 4 层自编码器和 5 层 GCN 对站点移动模式进行提取,将堆叠自编码器的网络维度设置改为 $|V_s| - 256 - 256 - 1024 - 128$,训练过程中的学习率和训练次数分别为 0.001 和 500。聚类数选取范围为设 $K \in \{2, 3, 4, 5, 6\}$ 。

单一模式下的时空预测模型 STGNNFormer 经过一定的调参并对比结果后,网络模型的各参数设置细节如表 1 所列。训练过程中,采用 MAE 作为损失函数,使用 Adam 作为优化器,初始学习率设置为 0.001,此外使用单步的学习率调整策略,即每轮训练会减小学习率,衰减比率为 0.5,训练次数设为 10。

表1 STGNNFormer网络参数细节

Table 1 STGNNFormer network parameter details

参数	描述	设定
e_layers	编码器层数 N_{en}	3
d_layers	解码器层数 N_{de}	2
$dropout$	dropout 选择概率 p	0.1
$conv_kernel$	Conv1d 的核大小	3
n_smooth/n_order	GNN 的图卷积层数	2
t_freq	时间戳信息选择的特征数	3
d_model	数据嵌入特征维度 d	32
$decomp_kernel$	时序分解模块的 AvgPool 的核大小	12
$factor$	自相关模块的 top k 超参 ϵ	2
n_head	多头的数量	4
$node_embed$	自适应的可学习节点特征 d_v	10

在该时空预测任务的评估中,使用的评估指标为平均绝对误差 (Mean Absolute Error, MAE)、均方根误差 (Root Mean Square Error, RMSE) 和平均绝对百分比误差 (Mean Absolute Percentage Error, MAPE)。各计算指标的定义表达式如表 2 所列,其中所有表达式中的 \hat{y}_i 和 y_i 分别表示预测值和真实值。

表2 交通预测任务的评估指标及其表达式

Table 2 Evaluation index of traffic prediction task and its expression

预测指标	公式定义表达式
MAE	$MAE = \frac{1}{n} \sum y_i - \hat{y}_i $
RMSE	$RMSE = \sqrt{\frac{\sum (y_i - \hat{y}_i)^2}{n}}$
MAPE	$MAPE = \frac{1}{n} \sum \left \frac{y_i - \hat{y}_i}{y_i} \right $

所有深度模型网络的实现、训练和测试等均由 Pytorch 实现,在 Google Colab 平台上运行。

4.3 站点移动模式分析

站点的移动模式同样在时间和空间上存在明显的规律性。以一天的流量分布作为站点的特征属性时,不同的站点具有明显的分布规律。图 6 给出了随机挑选的 4 个站点特征的分布情况,可以看出,特征在数值和整体规律上都有一定的相似性和差异性。因此,站点进行移动模式旨在有效地将具有相似移动规律的站点划分成一类。在时空预测任务中,为了验证在移动模式下的多模式预测的有效性,这里分别设置 $T_h - T_p$ 为 12-12 和 72-72,移动模式数量设置为 $K \in \{2, 3, 4, 5, 6\}$,并展示了模型在长期时空预测中的计算时间开销。实验结果如表 3 所列。




图6 随机选取的站点的特征分布示例

Fig. 6 Example of feature distribution for a randomly selected site

表3 不同移动模式数下的预测结果

Table 3 Prediction results for different number of movement modes

$T_h - T_p$	评估	移动模式数					
		1	2	3	4	5	6
12-12	RMSE	1.395	1.382	1.375	1.393	1.394	<u>1.381</u>
	计算时间/ms	51	37	28	28	26	<u>27</u>
72-72	RMSE	1.388	1.387	1.365	1.375	1.380	<u>1.372</u>
	计算时间/ms	177	95	76	71	<u>72</u>	80

通过观察可以看到,多模式的预测方式可以有效地减少计算开销,提高预测的精度。我们选取预测效果最好的移动模式数量,即 $K=3$,各模式的站点数量分别为 396, 478 和 246。接下来,对各模式进行聚类分析的可视化:对同一移动模式下的站点流量分布进行平均并展示;对站点聚类结果进行 PCA 降维并展示,结果如图 7 所示,不同颜色代表不同的移动模式。观察发现,不同移动模式下的站点各有差异,例如,各自的高峰时间段存在差异,不同移动模式的特征降维后具有明显区分度。

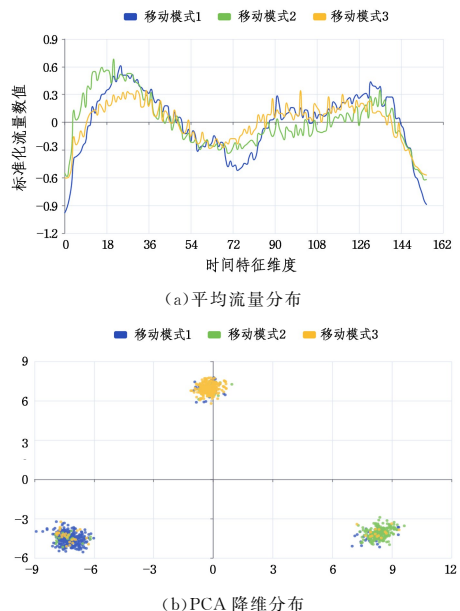


图7 站点移动模式可视化分析(电子版为彩图)

Fig. 7 Visual analysis of site movement modes

本文将站点移动模式分成 3 类,即对站点做划分,并且保证划分后的站点具有一定的规律,此举能够给预测提供帮助。本文提取的移动模式是一种潜在的模式,各个模式没有特定的语义上的定义但是存在各自的潜在规律。

4.4 站点网络的交通预测

首先,我们使用 STGNNFormer 和 MPGNNFormer 进行短期时空预测,并评估其预测表现。另外,由于自相关机制在短期时空预测上无法体现其优势,因此我们使用自注意力机制进行预测。基线对比方法包括最新的基于 GCN 的时空预测模型: STGCN, ASTGCN, STSGCN, Graph WaveNet, AGCRN。在短期时空预测任务中,各个模型的输入步长为 $T_{in}=12$,评估的输出步长为 $T_p \in \{3, 6, 12\}$,评估结果如表 4 所列。从表中可以看出,本文的 MPGNNFormer 实现了最优的预测效果。另外,随着时序长度的增加,其他的基于 GCN 的方法在效果上普遍下降,而 STGNNFormer 和 MPGN-

NFormer 对短期的时序长度的变化并不敏感,具有一定的优势。虽然 STGNNFormer 和 MPGNNFormer 在预测效果上

有所提升,但其在模型参数量、计算效率上不如其他基线方法,因此其优势在短期时空预测任务中并不是特别突出。

表 4 短期预测评估结果对比

Table 4 Comparison of short-term forecast evaluation results

方法	$T_p=3(15\text{ min})$			$T_p=6(30\text{ min})$			$T_p=12(60\text{ min})$		
	RMSE	MSE	MAPE	RMSE	MSE	MAPE	RMSE	MSE	MAPE
STGCN	1.460	2.131	3.010	1.486	2.207	3.122	1.526	2.330	3.357
ASTGCN	<u>1.370</u>	<u>1.878</u>	2.950	1.395	<u>1.945</u>	3.602	1.432	2.051	3.795
STSGCN	1.411	1.990	<u>2.930</u>	1.426	2.032	<u>3.007</u>	1.454	2.115	<u>3.092</u>
Graph WaveNet	1.439	2.069	3.379	1.444	2.084	3.442	1.458	2.125	3.505
AGCRN	1.438	2.066	3.036	1.447	2.093	3.324	1.486	2.209	4.081
STGNNFormer	1.394	1.960	3.080	<u>1.388</u>	1.946	3.771	<u>1.395</u>	<u>1.963</u>	3.501
MPGNNFormer($K=3$)	1.361	1.853	2.853	1.372	1.883	2.594	1.375	1.892	2.379

STGNNFormer 和 MPGNNFormer 的设计主要是针对长时序的时间依赖关系获取,因此,我们进一步测试了其在长期时空预测中的表现,以及其在计算效率上的情况。基线对比方法为 Transformer 以及两个最新的基于 Transformer 的长时序预测模型:Informer 和 Informer * (Informer 的一个变体)。在长期时空预测任务中,各个模型的输入步长为 $T_h=72$,评估的输出步长为 $T_p \in \{12, 36, 72, 108, 156\}$ (分别对应真实小时数:1, 3, 6, 9, 13),最长的预测时间步长(156)恰好为

一天的时空数据,预测表现和计算效率的评估结果如表 5 所列。可以看出,相较于基线方法,STGNNFormer 和 MPGNNFormer 在预测精度的表现上几乎都是最优的,但是由于需要计算空间上的依赖关系,STGNNFormer 的计算效率较低,而 MPGNNFormer 采取多模式的方式不仅可以一定程度地提高预测精度,还能大大减少每次训练所需的节点数量,计算效率高,也足以实现实时预测。这表明在站点网络的交通流量预测中,预测框架(MPGNNFormer)是有效的。

表 5 长期预测评估结果对比

Table 5 Comparison of long-term forecast evaluation results

T_p	评估	方法				
		Transformer	Informer	Informer *	STGNNFormer	MPGNNFormer ($K=3$)
12 (1h)	RMSE	1.384	1.392	1.387	1.363	<u>1.365</u>
	MSE	1.916	1.938	1.925	1.859	<u>1.862</u>
	MAPE	<u>1.662</u>	2.176	1.965	2.062	1.261
	计算时间/ms	83	<u>59</u>	78	118	57
36 (3h)	RMSE	1.390	1.406	1.389	<u>1.366</u>	1.355
	MSE	1.932	1.977	1.928	<u>1.865</u>	1.835
	MAPE	1.604	1.916	1.722	1.852	<u>1.660</u>
	计算时间/ms	96	65	86	139	<u>73</u>
72 (6h)	RMSE	1.394	1.414	1.442	<u>1.388</u>	1.365
	MSE	1.943	1.999	2.079	<u>1.925</u>	1.864
	MAPE	<u>2.206</u>	2.301	3.023	2.349	2.110
	计算时间/ms	121	75	97	177	<u>76</u>
108 (9h)	RMSE	1.390	1.413	1.404	1.356	1.350
	MSE	1.933	1.997	1.971	1.840	1.824
	MAPE	2.942	3.211	3.083	2.453	2.302
	计算时间/ms	140	84	104	209	89
156 (13h)	RMSE	<u>1.387</u>	1.433	1.416	1.362	<u>1.387</u>
	MSE	1.924	2.052	2.004	1.855	<u>1.923</u>
	MAPE	3.075	3.261	2.868	2.353	<u>2.670</u>
	计算时间/ms	178	<u>110</u>	121	306	106

结束语 本文主要研究了移动模式在交通时空预测问题上的作用,并提出了一种多模式的长短期交通预测框架(MPGNNFormer),包括站点移动模式的提取和多模式的时空预测。特别地,本文设计了一种新颖的时空预测模型(STGNNFormer)。最后,本文在真实世界公交车数据集上进行了实验,分析了移动模式的有效性,并取得了较好的效果,实验结果证明了预测框架在客流预测中是有效的。

多样的。如果能够得到有效的移动模式,并且具备合理的解释性,其应用价值可以在更多交通任务中得以体现,甚至可以辅助制定一些个性化的服务。

参考文献

- [1] WANG Y, CHEN Q X, ZHANG N, et al. Convergence of 5G Communications and Ubiquitous Power Internet of Things: Application Analysis and Research prospects [J]. Power System Technology, 2019, 43(5): 1575-1585.

另外,对于复杂的交通预测问题,移动模式的分析角度是

- [2] KONG X, TONG S, GAO H, et al. Mobile edge cooperation optimization for wearable internet of things: a network representation-based framework[J]. *IEEE Transactions on Industrial Informatics*, 2020, 17(7): 5050-5058.
- [3] RUAN S, BAO J, LIANG Y, et al. Dynamic public resource allocation based on human mobility prediction[J]. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 2020, 4(1): 1-22.
- [4] KONG X, LI M, TANG T, et al. Shared subway shuttle bus route planning based on transport data analytics [J]. *IEEE Transactions on Automation Science and Engineering*, 2018, 15(4): 1507-1520.
- [5] WANG S, CAO J, YU P. Deep learning for spatio-temporal data mining: A survey [J]. *IEEE Transactions on Knowledge and Data Engineering*, 2020, 34(8): 3681-3700.
- [6] WANG Z W, CHEN T, SONG M Q. At the same time, the coordination and optimization of responsive feeder bus routing and scheduling in pickup mode[J]. *Journal of Traffic and Transportation Engineering*, 2019, 19(5): 139-149.
- [7] MOURAD A, PUCHINGER J, CHU C. A survey of models and algorithms for optimizing shared mobility [J]. *Transportation Research Part B: Methodological*, 2019, 123: 323-346.
- [8] GAN M, CHENG Y, LIU K, et al. Seasonal and trend time series forecasting based on a quasi-linear autoregressive model[J]. *Applied Soft Computing*, 2014, 24: 13-18.
- [9] BAI Y, SUN Z, ZENG B, et al. A multi-pattern deep fusion model for short-term bus passenger flow forecasting[J]. *Applied Soft Computing*, 2017, 58: 669-680.
- [10] DU B, PENG H, WANG S, et al. Deep irregular convolutional residual LSTM for urban traffic passenger flows prediction[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2019, 21(3): 972-985.
- [11] XIA F, SUN K, YU S, et al. Graph learning: A survey[J]. *IEEE Transactions on Artificial Intelligence*, 2021, 2(2): 109-127.
- [12] XU K, HU W, LESKOVEC J, et al. How powerful are graph neural networks? [C]// *International Conference on Learning Representations (ICLR)*. 2019.
- [13] WU Z, PAN S, CHEN F, et al. A comprehensive survey on graph neural networks[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2020, 32(1): 4-24.
- [14] BRUNA J, ZAREMBA W, SZLAM A, et al. Spectral networks and locally connected networks on graphs [C]// *International Conference on Learning Representations (ICLR)*. 2014.
- [15] KIPF T N, WELING M. Semi-supervised classification with graph convolutional networks[C]// *International Conference on Learning Representations (ICLR)*. 2017.
- [16] BO D, WANG X, SHI C, et al. Structural deep clustering network [C]// *Proceedings of the Web Conference*. 2020: 1400-1410.
- [17] ZHANG M, CHEN Y. Link prediction based on graph neural networks [C]// *Advances in Neural Information Processing Systems*. 2018: 5165-5175.
- [18] KONG X, CHEN Q, HOU M, et al. RMGen: A Tri-Layer Vehicular Trajectory Data Generation Model Exploring Urban Region Division and Mobility Pattern [J]. *IEEE Transactions on Vehicular Technology*, 2022, 71(9): 9225-9238.
- [19] CHEN R, LIANG C Y, HONG W C, et al. Forecasting holiday daily tourist flow based on seasonal support vector regression with adaptive genetic algorithm [J]. *Applied Soft Computing*, 2015, 26: 435-443.
- [20] DELL'ACQUA P, BELLOTTI F, BERTA R, et al. Time-aware multivariate nearest neighbor regression methods for traffic flow prediction [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2015, 16(6): 3393-3402.
- [21] LIU L, CHEN R C. A novel passenger flow prediction model using deep learning methods [J]. *Transportation Research Part C: Emerging Technologies*, 2017, 84: 74-91.
- [22] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. *Neural computation*, 1997, 9(8): 1735-1780.
- [23] SHI X, CHEN Z, WANG H, et al. Convolutional LSTM network: A machine learning approach for precipitation nowcasting [C]// *Proceedings of the 28th International Conference on Neural Information Processing Systems*. 2015: 802-810.
- [24] KONG X, ZHU B, SHEN G, et al. Spatial-Temporal-Cost Combination based Taxi Driving Fraud Detection for Collaborative Internet of Vehicles [J]. *IEEE Transactions on Industrial Informatics*, 2021, 18(5): 3426-3436.
- [25] SEO Y, DEFFERRARD M, VANDERGHEYNST P, et al. Structured sequence modeling with graph convolutional recurrent networks [C]// *International Conference on Neural Information Processing*. Cham: Springer, 2018: 362-373.
- [26] LI Y, YU R, SHAHABI C, et al. Diffusion convolutional recurrent neural network: Data-driven traffic forecasting [C]// *International Conference on Learning Representations (ICLR)*. 2018.
- [27] YU B, YIN H, ZHU Z. Spatio-temporal graph convolutional networks: A deep learning framework for traffic forecasting [C]// *International Joint Conference on Artificial Intelligence*. 2018: 3634-3640.
- [28] GUO S, LIN Y, FENG N, et al. Attention based spatial-temporal graph convolutional networks for traffic flow forecasting [C]// *Proceedings of the AAAI Conference on Artificial Intelligence*. 2019: 922-929.
- [29] SONG C, LIN Y, GUO S, et al. Spatial-temporal synchronous graph convolutional networks: A new framework for spatial-temporal network data forecasting [C]// *Proceedings of the AAAI Conference on Artificial Intelligence*. 2020: 914-921.
- [30] WU Z, PAN S, LONG G, et al. Graph wavenet for deep spatial-temporal graph modeling [C]// *International Joint Conference on Artificial Intelligence*. 2019: 1907-1913.
- [31] BAI L, YAO L, LI C, et al. Adaptive graph convolutional recurrent network for traffic forecasting [J]. *Advances in Neural Information Processing Systems*, 2020, 33: 17804-17815.
- [32] SHEN G, HAN X, CHIN K, et al. An Attention-Based Digraph Convolution Network Enabled Framework for Congestion Re-

cognition in Three-Dimensional Road Networks[J]. IEEE Transactions on Intelligent Transportation Systems, 2021, 23(9): 14413-14426.

- [33] LI S, JIN X, XUAN Y, et al. Enhancing the locality and breaking the memory bottleneck of transformer on time series forecasting [J]. arXiv:1907.00235, 2019.
- [34] KITAEV N, KAISER Ł, LEVSKAYA A. Reformer: The efficient transformer [C] // International Conference on Learning Representations (ICLR), 2020.
- [35] ZHOU H, ZHANG S, PENG J, et al. Informer: Beyond efficient transformer for long sequence time-series forecasting [C] // Proceedings of AAAI, 2021.
- [36] XU J, WANG J, LONG M. Autoformer: Decomposition transformers with auto-correlation for long-term series forecasting [J]. Advances in Neural Information Processing Systems, 2021, 34: 22419-22430.
- [37] LAI C G, LI L, ZHOU Y T, et al. Air duct improvement and occupant thermal comfort optimization of an automobile air conditioner with intelligent algorithm [J]. Journal of Chongqing University of Technology (Natural Science), 2022, 36(4): 19-27.
- [38] WEI S J, WANG X, DAI J, et al. A location prediction framework based on trust circle and mobility pattern [J]. Journal of

Chongqing University of Technology (Natural Science), 2022, 36(8): 182-192.

- [39] KONG X, WANG K, HOU M, et al. Exploring Human Mobility for Multi-Pattern Passenger Prediction: A Graph Learning Framework [J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(9): 16148-16160.



SHEN Zhehui, born in 1999, postgraduate. His main research interests include urban science, social computing and so on.



KONG Xiangjie, born in 1981, Ph. D. professor, Ph. D supervisor, is a distinguished member of China Computer Federation. His main research interests include network science, mobile computing and computational social science.

(责任编辑:何杨)