

基于时空注意力机制的网约车出行需求预测模型

王宁, 马洪恩

(同济大学汽车学院, 上海 201804)

摘要: 解决网约车运营中的乘客出行需求预测问题, 以降低车辆空载率、减少乘客等待时间。在考虑乘客出行需求的动态时空依赖性的基础上, 提出一种基于空间数据可视化和格兰杰因果检验的乘客出行需求空间依赖性分析方法, 并结合卷积神经网络和注意力机制, 建立了一种基于注意力机制的时空图卷积神经网络模型来预测乘客出行需求。实例研究表明, 本模型能有效捕获乘客出行需求时空依赖性的动态特征, 提升模型的预测性能, 具有较高的准确性和实用性。

关键词: 出行需求预测; 注意力机制; 时空依赖性; 时空图卷积神经网络

中图分类号: U491.1 文献标志码: A DOI: 10.3969/j.issn.2095-1469.2024.05.16

A Travel Demand Prediction Model for Ride-Hailing Services Based on Spatio-Temporal Attention Mechanism

WANG Ning, MA Hongen

(School of Automotive Studies, Tongji University, Shanghai 201804, China)

Abstract: The paper aims to solve the problem of forecasting passenger travel demand in e-hailing car operations, thereby reducing vehicle idle rates and minimizing passenger waiting times. Considering the dynamic spatiotemporal dependencies of passenger travel demand, this study proposes a method based on spatial data visualization and the Granger causality test for analyzing the spatial dependency. A spatiotemporal graph convolutional neural network model incorporating attention mechanisms is established to predict passenger travel demand. The case study shows that this model effectively captures the dynamic characteristics of the time-space dependencies of passenger travel demand, improves the prediction performance of the model, and achieves high accuracy and practicability.

Keywords: travel demand forecasting; attention mechanism; spatiotemporal dependence; attention based spatial temporal graph convolutional networks

随着我国信息化水平的提高以及移动互联网的高速发展, 网约车行业近年来蓬勃发展, 越来越多的消费者开始选择网约车服务。精准预测网约车出

行需求对于提高网约车匹配和调度效率, 解决时空供需不平衡问题, 提升乘客出行体验具有重要意义。出行需求预测研究是分析区域出行强度和解决

收稿日期: 2023-07-16 改稿日期: 2023-08-31 网络首发日期: 2024-05-30

基金项目: 同济大学学科交叉联合攻关项目(2023-4-YB-04)

参考文献引用格式:

王宁, 马洪恩. 基于时空注意力机制的网约车出行需求预测模型[J]. 汽车工程学报, 2024, 14(5): 898-910.

WANG Ning, MA Hongen. A Travel Demand Prediction Model for Ride-Hailing Services Based on Spatio-Temporal Attention Mechanism[J]. Chinese Journal of Automotive Engineering, 2024, 14(5): 898-910. (in Chinese)



出行供需矛盾的重要依据，一直都是国内外学者的关注热点。因此，研究如何进行精准的网约车出行需求预测，成为解决网约车行业供需不平衡问题的重要措施之一。经过对近几年相关学者研究成果的梳理分析，相关预测方法主要分为：基于统计分析、基于非线性理论、智能预测模型和组合预测模型。

早期学者使用基于统计分析的模型，如历史平均模型、时间序列模型和卡尔曼滤波模型等^[1-5]。但这类模型难以处理复杂场景，适用于路况简单的路段。近年来，学者开始采用基于非线性理论的模型，这类模型计算量大，模型复杂度较高，适用于分析复杂度高及非线性的数据，但单一模型具有局限性，难以在其他研究对象中推广^[6-10]。随着研究的逐渐深入，智能预测模型成为更多学者的选择，通过训练大规模的数据集，智能预测模型能自动学习交通动态信息特征，从而进行针对性的预测。智能预测模型相对于上述2种预测方法而言，其预测精度较高，但是模型参数设置较复杂，计算量大，且预测精度受参数选择影响较大。主要的代表模型有神经网络模型、支持向量机等^[11-17]。组合预测模型是将上述模型或者算法进行组合预测，发挥不同模型提取数据特征的优势，从而提高预测效果，对比单一模型，组合模型的预测精度更高^[18-19]。

综合来看，针对出租车出行需求预测问题，目前学者的研究思路主要体现在2个方向：一是针对单个区域的乘客出行需求预测问题；二是针对多区域出行需求预测问题。王维^[20]对历史需求订单、天气和兴趣点等各类影响因素与出行需求量进行相关性分析，针对区域需求预测问题，利用长短期记忆神经网络（Long Short Term Memory, LSTM）、卷积神经网络（Convolutional Neural Network, CNN）和卷积长短期记忆神经网络（Convolutional Long Short Term Memory, Conv-LSTM），捕捉出行需求的时空变化规律。张晓鹏^[21]收集温度、天气等城市多源数据，提出基于多源数据融合的出行需求预测模型，提升了预测的精确度。WANG Dong等^[22]结合天气情况、网约车数据、实时交通运行

状态等数据，对出租车乘客出行需求进行预测。吴佳昊^[23]提出一种基于时空图卷积神经网络的深度学习多区域（Origin-Destination, OD）矩阵预测模型，将城市区域划分多个交通小区，采用嵌套式长短期记忆网络捕获长时间层次结构，利用基于光谱域的切比雪夫图神经网络提取区域的空间依赖性，通过实例分析证明了预测模型效果的有效性。孔瑶瑶^[24]针对多区域出行需求预测问题，考虑网约车出行需求的时空特征与历史流入量的时间依赖性，提出了一种注意力卷积长短期记忆出行需求预测模型，最后通过实例分析验证了模型方法的有效性和适用性。

单个区域的乘客出行需求预测问题结合了需求的时序规律、天气、气温等影响因素进行时序预测，但其一次只能预测某一个区域的出行需求量，导致此类预测方法有一定的局限性。而针对多区域出行需求预测问题则同时考虑出行需求之间的时空依赖性，进行时空序列预测，可以实现多个区域的出行需求量预测。在实际应用中，网约车服务资源调度平台需要同时预测多个区域的需求量，并根据预测结果进行运营调度。因此，本文将面向多区域出行需求预测问题，考虑乘客出行需求之间的动态时空依赖性，进行时空序列预测。

目前针对多区域乘客出行需求预测问题，多数学者忽视了乘客出行需求的动态时空依赖性，即区域间乘客出行需求的时空依赖关系是动态的，会随时间变化而发生改变。随着国内外学者对注意力机制研究的不断深入，在交通出行预测领域中，注意力机制已经成为捕获交通出行数据时空依赖性动态变化特征的一种常用模型设计。赵恒辉等^[25]提出一种基于时空注意力的双向LSTM短时交通流预测模型。张钊^[26]使用多头注意力模型和2种图神经网络构建时空注意力网络以更好地捕获时空依赖性。陈萌^[27]提出一种基于改进图注意力网络的交通流预测模型，对于长时的交通流量预测取得较好的预测结果。基于注意力机制在交通出行数据时空依赖性问题上的成熟应用，此次研究选择利用注意力机制构建模型捕获出行需求问题中的时空依赖性

动态变化特征。

综上所述，在本研究中，将利用深度学习神经网络对乘客出行需求的时空依赖性建模，同时，引入注意力机制捕获乘客出行需求时空依赖性的动态变化特征，进而进行多区域出行需求预测。一方面，深度学习神经网络模型可以在乘客出行需求数据训练中自行学习数据特征。另一方面，模型可以从乘客出行需求的时空依赖性出发，分别对时间依赖性和空间依赖性进行建模，并捕获乘客出行需求时空依赖性的动态变化规律，进而实现精准的出行需求预测。

1 出行需求的时空依赖性分析

本文采用2016年11月1日至2016年11月30日四川省成都市的网约车乘客出行数据，通过分析乘客的历史上下车位置数据进行出行需求的预测。乘客出行需求的上下车位置数据是一种时空事件数据，每个样本中都包含了乘客出行时空事件发生时的位置和时间信息，因此，各样本之间存在时间维度和空间维度的相关性。分析网约车的运营特性，对乘客的出行需求进行时空依赖性分析，是开展本文研究的基础。

1.1 网约车运营特性

网约车在实际运营中，采用网络预约出租汽车经营服务的方式，即以互联网技术搭建信息平台，接入符合条件的运营车辆，通过整合乘客和车辆的供需信息，提供预约出租汽车的经营服务活动以满足乘客出行需求。具体而言，如图1所示，网约车出行服务平台在满足乘客出行需求时，平台主要完成派单任务和调度任务。在实际应用中，面对各区域实时变化的乘客出行需求，各区域随时会出现车辆供给不足导致乘客等待时间过长，或车辆供给过剩导致车辆长时间巡游等问题。仅仅依赖派单任务，网约车出行服务平台无法有效满足各区域内实时变化的乘客出行需求。因此，网约车出行服务平台还需要通过多区域的乘客出行需求预测，来实时判断各区域内的乘客出行需求与运营车辆供给的

相对情况，从而实时调度运营车辆，以满足各个区域乘客出行需求。

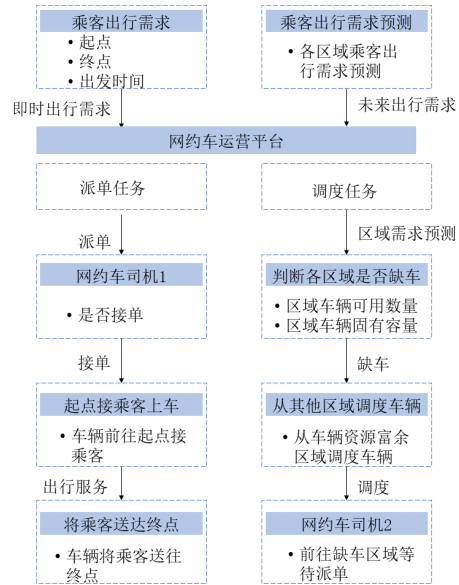


图1 网约车运营模式

1.2 乘客出行需求的时间依赖性分析

在时间维度上，乘客出行需求是一个连续变化的过程，如图2所示，展示了某天13:00-20:00的乘客出行需求强度变化情况，所以乘客出行需求预测的本质是一个时间序列数据预测问题。而在时间序列数据预测问题中，历史数据是实现准确预测的重要依序，利用预测点前临近时间的数据进行预测是常用方法，所以为实现准确的预测，本文的出行需求预测模型首先将临期数据作为输入特征。




图2 乘客出行需求的连续变化示意图

同时，乘客出行需求数据在时间维度上呈现明显的日周期性和周周期性。

图3展示了采用数据某一周的乘客出行需求强度变化情况。经观察可知，每天的乘客出行需求变化呈现一定程度的相似性和规律性，每天较早时刻的出行需求都处在较低的范围，随着时间的变化，

乘客的出行需求不断上升达到高峰，当时间来到晚间，出行需求不断下降，直至次日凌晨。同时，乘客出行需求数据随着时间变化，表现出明显相似的波峰与波谷，波谷出现的时间段为晚上，是一种典型的受人们生活作息影响才会出现的出行需求数据。乘客出行需求数据在每天的同一时刻存在很强的相似性，因此，在本文的出行需求预测模型中应当考虑乘客出行需求中存在的日周期性。




图3 乘客出行需求的日周期性示意图

图4展示了采用的数据2016年11月第1~2周的乘客出行需求强度变化情况。经观察可知，这2周的乘客出行需求数据具有相似性，且这2周的不同工作日和休息日乘客出行需求变化趋势也高度相似，乘客出行需求的时间分布保持了一定的稳定性，同时，乘客出行需求数据随着时间变化，表现出明显相似的波峰与波谷，因此，在本文的出行需求预测模型中应当考虑乘客出行需求中存在的周周期性。

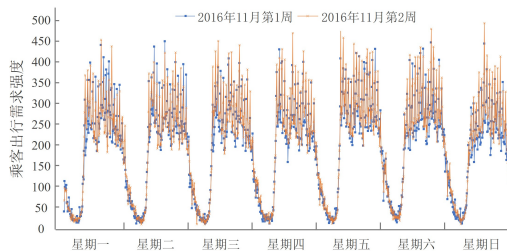


图4 乘客出行需求的周周期性示意图

1.3 乘客出行需求的空间依赖性分析

在空间维度上，不同区域的乘客出行需求会相互影响且存在空间依赖关系。格兰杰因果关系检验是一种假设检验的统计方法，能检验1组变量是否受另1组变量的滞后影响。若这2组变量之间存在影响，则它们具有格兰杰因果关系。具体分析流程

如图5所示，其中，VAR模型为基于数据的统计属性建立的二元或者多元向量自回归模型。本小节利用格兰杰因果检验分析特定区域出行需求时间序列与对应的出行需求热点区域的到达需求时间序列是否存在因果关系，进而表征区域间乘客出行需求的空间依赖性强弱，从而建立区域之间的空间依赖性矩阵 $A = A_{adj}$ 。具体来说，对于区域 i 和区域 j ，区域 j 为区域 i 的热点出行区域，如果区域 j 的到达需求时间序列 L_j 被验证为区域 i 的出行需求时间序列 L_i 的格兰杰因，则将两区域的依赖关系 $a_{adj}^{i,j}$ 设置为1，否则，将 $a_{adj}^{i,j}$ 设置为0。从而空间依赖性矩阵 A_{adj} 可表示为：

$$a_{adj}^{i,j} = \begin{cases} 1 & i \neq j (i, j \in U^m), L_j \text{ 是 } L_i \text{ 的格兰杰因} \\ 0 & L_j \text{ 不是 } L_i \text{ 的格兰杰因} \end{cases} \quad (1)$$




图5 基于格兰杰因果检验的分析流程

以采用数据划分的某个特定区域为例，将该特定区域命名为区域A， L_a 代表所有上车位置在A区域内乘客出行需求的时间序列，利用地理空间数据可视化工具Kepler.gl进行乘客出行热点需求区域分析，输入区域A乘客出行的下车位置的经纬度数据，基于Kepler.gl的空间数据可视化结果如图6所示，图像中柱形高度代表乘客出行下车位置在柱形所处区域内出现的频数。




图6 基于Kepler.gl的空间数据可视化结果


对频数阈值进行设定, 得到 5 个区域 A 的热点出行区域, 将其分别命名为区域 B、C、D、E、F, L_b 、 L_c 、 L_d 、 L_e 、 L_f 代表所有下车位置在对应热点区域的乘客到达需求的时间序列。通过 VAR 模型和格兰杰因果检验分析 L_b 、 L_c 、 L_d 、 L_e 、 L_f 是否为 L_a 的格兰杰因, 以确定各区域与区域 A 在乘客出行需求方面的在空间依赖性, 脉冲响应图、格兰杰因果检验分析结果和 VAR 模型方差分解结果分别如图 7、表 1~2 所示, 三者具有较高的一致性, 表明此次模型具有较高的可信度。可分析得出, 变量 L_a 受到变量 L_c 、 L_e 的滞后影响, 所以变量 L_a 和后两者之间存在格兰杰因果关系, 可将变量 L_c 、 L_e 用于变量 L_a 的预测。

2 出行需求预测模型

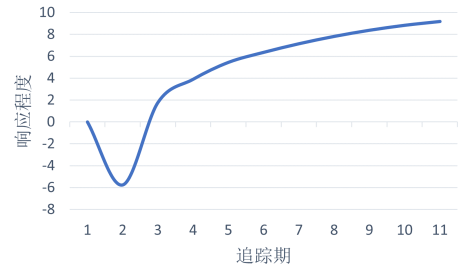
2.1 出行需求预测模型设计

本文引入了基于注意力机制的时空图卷积神经网络 (Attention Based Spatial-Temporal Graph Convolutional Networks, ASTGCN) 作为网约车出行需求的预测模型, 模型的结构如图 8 所示。

首先模型考虑乘客出行需求的时间依赖性, 利用临近依赖组件、日周期组件和周周期组件对预测目标的临近依赖性、日周期性和周周期性建模。其中, 临近依赖组件、日周期组件和周周期组件的输入分别为临近时间序列片段、日周期时间序列片段和周周期时间序列片段。临近时间序列片段表示与



(a) 变量 L_c 对变量 L_a 的脉冲响应



(b) 变量 L_e 对变量 L_a 的脉冲响应

图 7 脉冲响应

表 1 变量 L_a 格兰杰因果分析

原假设	F 值	p 值	df
L_b 不是 L_a 的格兰杰因	0.011	0.916	1
L_c 不是 L_a 的格兰杰因	11.952	0.001	1
L_d 不是 L_a 的格兰杰因	2.433	0.122	1
L_e 不是 L_a 的格兰杰因	15.716	0.000	1
L_f 不是 L_a 的格兰杰因	0.661	0.418	1

预测目标时间段直接相连的一段历史时间序列片段, 长度为 T_h 。日周期时间序列片段表示与预测目标时间段相对应的若干天之前的历史时间序列片

表 2 变量 L_a 的 VAR 模型方差分解结果

期数	S.E.	L_a	L_b	L_c	L_d	L_e	L_f
1	31.464	100.000	0	0	0	0	0
2	46.575	75.605	2.617	3.334	3.737	13.178	1.529
3	55.512	67.769	2.340	4.157	3.427	21.128	1.180
4	62.432	62.069	2.088	4.698	3.846	25.973	1.325
5	67.878	58.265	1.824	5.359	4.369	28.416	1.767
6	72.380	55.330	1.608	6.200	4.966	29.567	2.328
7	76.214	52.845	1.458	7.174	5.568	29.973	2.982
8	79.560	50.609	1.381	8.229	6.160	29.917	3.705
9	82.533	48.537	1.376	9.323	6.729	29.559	4.477
10	85.213	46.593	1.440	10.424	7.266	29.000	5.277

段，长度为 T_d 。周周期时间序列片段表示与预测目标时间段相对应的若干周之前的历史时间序列片段，长度为 T_w 。假设当前时刻为 t_0 ，被预测的网约车出行需求数据时间序列为 T_p ，本研究中 T_h 、 T_d 、 T_w 取被预测的网约车出行需求数据时间为 T_p 的整数倍，则 T_h 、 T_d 、 T_w 的构建方式如图 9 所示，示例中 T_p 的时间跨度为 1 h，取 2 倍。

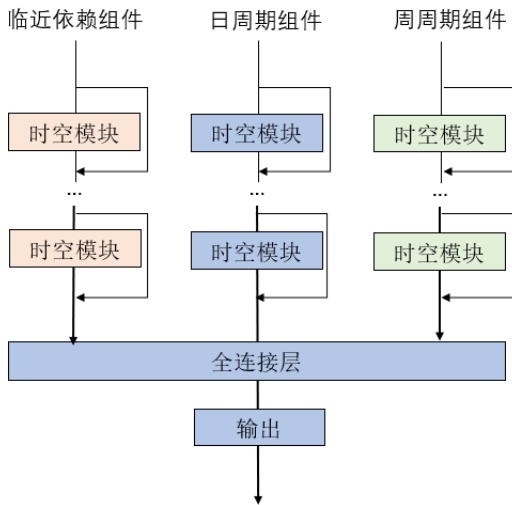


图 8 ASTGCN 网络结构

然后再通过 ASTGCN 模型结构中的多个时空模块，提取网约车出行需求时空依赖性的动态特征。时空模块结构如图 10 所示，由时空注意力模块和时空图卷积模块组成。时空注意力模块通过学习当前时空节点的输入数据，生成注意力矩阵，进而对下一时空节点输入数据的注意力进行分配。时空图卷积模块包含空间维度 ChebNet（切比雪夫网络）卷积模块和时间维度一维卷积模块，前者提取空间维度上的数据特征，描述出行需求数据在空间维度上的依赖性，后者提取时间维度上的数据特征，描述出行需求数据在时间维度上的依赖性。

最后，通过全连接层调整临近特性、日周期性

和周周期性组件的输出维度，使之和预测对象输出维度统一，再将 3 个组件的输出进行融合形成最终的预测结果。由于临近特性、日周期性和周周期性组件的重要程度在不同的空间区域上存在差异，如在日常上下班出行的写字楼等地区日周期性和周周期性组件的重要程度更高，在公园等出行需求不存在明显周期性的区域，日周期性和周周期性组件的重要程度则较低。因此，全连接层中还需要从历史数据中进行学习，提取 3 个组件对不同空间区域的重要程度大小，融合过程如式 (2) 所示。

$$\hat{Y} = U_a \odot \tilde{Y}_a + U_b \odot \tilde{Y}_b + U_c \odot \tilde{Y}_c \quad (2)$$

式中： \odot 为基本积； U_a 、 U_b 、 U_c 为神经网络从历史数据中所学习得到的参数，反映了乘客出行需求的临近特性、日周期性和周周期性对下一阶段需求预测的影响程度。

2.2 时空注意力模块

不同区域的出行需求之间会动态影响，对同一区域来说，其他的不同区域对该区域的影响程度不同，且影响程度会随着区域和时间的变化而发生改变，在本节中通过自注意力机制提取空间维度上不同区域之间的依赖性变化特征，根据输入数据自适应调整不同区域的乘客出行需求数据之间的相关性。空间维度的注意力特征提取如式 (3)~(4) 所示。

$$E = V_j \times \sigma((\chi_h^{k-1} Y_1) Y_2 (Y_3 \chi_h^{k-1})^T + b_j) \quad (3)$$

$$E'_{m,n} = \frac{\exp(E'_{m,n})}{\sum_{n=1}^N \exp(E'_{m,n})} \quad (4)$$

式中： $\chi_h^{k-1} = (X_1, X_2, \dots, X_{T_{k-1}}) \in R^{N \times C_{k-1} \times T_{k-1}}$ 为第 k 层时空模块的输入数据； C_{k-1} 为第 k 层时空模块的输入数据的通道数； T_{k-1} 为第 k 层时空模块的输入数据的时间维长度。

V_j 、 b_j 、 Y_1 、 Y_2 、 Y_3 都是基于注意力机制所学习




图 9 输入时间序列片段构建

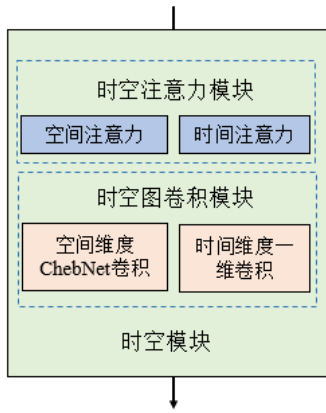


图 10 时空模块结构

到的参数，空间的注意力矩阵 E 是从当前的输入数据中学习得到的，其中 $E_{m,n}$ 为节点 m 和 n 之间的相关程度。对矩阵 E 使用 Softmax 函数进行归一化得到空间注意力矩阵 $E' \in R^{M \times M}$ ，通过归一化将保证概率和为 1。空间注意力矩阵中的每一个值都表示每个区域之间的分配权重系数，通过组合空间注意力矩阵和图结构的信息矩阵，可以使城市各区域的空间维度注意力得到合理分配。空间注意力模块如图 11 所示。

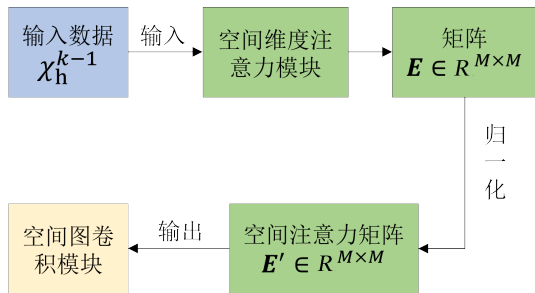


图 11 空间注意力模块

同一区域的出行需求存在时间维度的依赖性，这种依赖性会随着区域和时间的变化而变化，本节使用自注意力机制提取出行需求数据中的依赖性变化特征，并根据输入数据调整出行需求在时间维度上的相关性。时间维度的注意力特征提取如式 (5) ~ (6) 所示。

$$S = V_i \times \sigma((\chi_h^{k-1} Z_1) Z_2 (Z_3 \chi_h^{k-1})^T + b_i) \quad (5)$$

$$S'_{m,n} = \frac{\exp(E'_{m,n})}{\sum_{n=1}^{T_{j-1}} \exp(E'_{m,n})} \quad (6)$$

式中： V_i 、 b_i 、 Z_1 、 Z_2 、 Z_3 均为时间维度注意力模块

从输入数据中学习到的参数。

时间的相关性矩阵 E 是时间维度注意力模块从当前时刻的输入数据中学习得到的，通过 Softmax 函数对时间的相关性矩阵 E 进行归一化时，可以得到时间注意力矩阵 $S' \in R^{T, j-1 \times T, j-1}$ ，其中 $S_{m,n}$ 为节点 m 和 n 之间的相关程度。通过动态调整输入数据可以进一步对输入数据的特征进行提取，归一化后的时间注意力矩阵 $S' \in R^{T, j-1 \times T, j-1}$ 应用到当前的输入数据中，得到 $\hat{\chi}_h^{k-1} = (\hat{X}_1, \dots, \hat{X}_{T, k-1}) = (X_1, \dots, X_{T, k-1})$ 。 $S' \in R^{M \times C, k-1 \times T, k-1}$ ，基于调整后的数据对下一阶段再进行特征挖掘。时间注意力模块如图 12 所示。




图 12 时间注意力模块

2.3 时空图卷积模块

为描述乘客出行需求数据在空间维度上的相关性，本节通过谱图方法将数据视为图信息，将卷积操作应用到图结构的数据中对数据进行处理。由于图结构的稳定性不如二维网格，难以通过普通的卷积神经网络直接在空间域上为所有空间节点建立一样大小的局部图卷积核，需要通过在频域上定义卷积实现。但传统的频谱图卷积操作因为卷积核大小与输入信号相同，参数量和图节点数相同，导致图卷积核是全局的且参数量过大，计算过程还涉及高复杂度的特征分解，会导致图卷积计算复杂度过高。为此，本文采用 ChebNet 图卷积来提取空间维度上的数据特征，它能对参数化的频率响应函数进行多项式近似，克服卷积核过大的缺点，并通过迭代定义的切比雪夫多项式作近似，进一步降低计算复杂度。最终对乘客出行需求数据在空间维度上的相关性的建模结果如式 (7) 所示。

$$\text{ChebNet}(x) = \sum_{k=0}^{K-1} \theta_k T_k(\tilde{L})x \quad (7)$$

式中： $x = (x_{i,1}^b, x_{i,2}^b, \dots, x_{i,M}^b) \in R^M$ 为乘客出行数据中第 M 个区域中第 t 个时刻的图信号矩阵特征； $\theta \in R^K$ 为待神经网络模型学习的参数； \tilde{L} 为归一化后的拉普拉斯矩阵。

为描述乘客出行需求数据在时间维度上的相关性，本节采用一维卷积模型沿着乘客出行需求数据的时间维度对数据进行了特征提取，建立了乘客出行需求数据在时间维度的相关性模型，如式 (8) 所示。

$$\chi_h^{(r)} = \text{ReLU}(\Phi \times (\text{ReLU}(g_{\theta} *_{G} \chi_h^{(r-1)}))) \quad (8)$$

式中： ReLU 为激活函数； Φ 为时间维度的卷积和参数。

通过时间维度的一维卷积的操作，乘客出行需求数据上每个区域的前后时刻上的需求都会对当前的实时需求进行更新。

2.4 基于注意力机制的时空图卷积神经网络模型

在模型中，首先需要提取空间维度上图结构数据的特征，利用切比雪夫多项式实现近似展开的图卷积操作，并考虑注意力机制中切比雪夫多项式中的空间依赖关系的矩阵 $T_n(\tilde{L})$ 会和空间注意力矩阵 E' 进行组合，最终基于空间注意力机制的 ChebNet 图卷积操作可形式化表达为：

$$g_{\theta} *_{G} x = g_{\theta}(L)x \approx \sum_{n=0}^{N-1} \theta_n T_n(\tilde{L}) \odot (E')x \quad (9)$$

然后进行时间维度的一维卷积操作，通过时间维度的标准卷积操作利用相邻时间的信息对该节点的信息进行更新，形式化的表达如式 (10) 所示。

$$\chi_h^{(k)} = \text{ReLU}(\Phi \times (\text{ReLU}(g_{\theta} *_{G} \hat{\chi}_h^{(k-1)}))) \quad (10)$$

通过对时空注意力机制与时空卷积模块的层层组合，共同构成基于注意力机制的时空图卷积神经网络，从而提取时间维度和空间维度的特征信息，第 k 层时空模块的输入与输出如图 13 所示。然后通过残差学习的方式，对每一层时空注意力机制与时空卷积模块的组合进行训练。

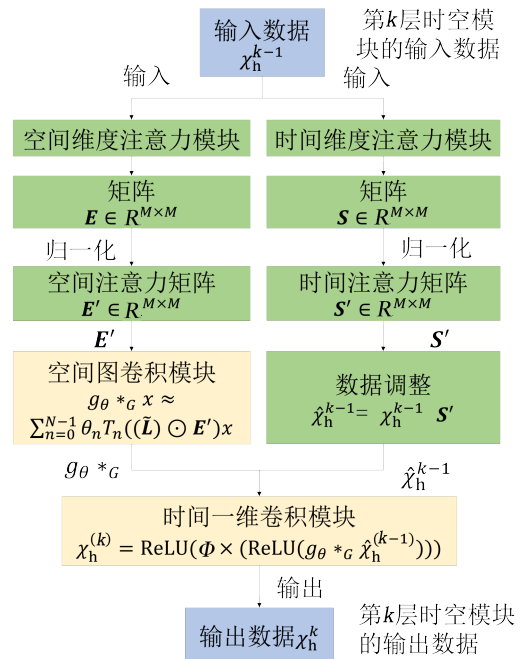


图 13 第 k 层时空模块的输入与输出

3 出行需求预测模型实例验证

3.1 乘客出行轨迹数据集介绍

本文通过网约车车辆出行过程中所产生的 GPS 数据，采集了四川省成都市网约车乘客的出行数据，数据时间跨度为 2016 年 11 月 1 日至 2016 年 11 月 30 日，信息共超过 10 亿条，数据具体字段信息见表 3。

表 3 原始数据格式示例

司机编号	乘客编号	时间	经度/(°)	纬度/(°)
8f20c9188561b796ef8e26196de30be4	39a096b71376b82f35732eff6d95779b	1477969147	104.075 13	30.727 24
8f20c9188561b796ef8e26196de30be4	39a096b71376b82f35732eff6d95779b	1477969150	104.075 13	30.727 02
8f20c9188561b796ef8e26196de30be4	39a096b71376b82f35732eff6d95779b	1477969154	104.075 04	30.726 72
8f20c9188561b796ef8e26196de30be4	39a096b71376b82f35732eff6d95779b	1477969193	104.075 06	30.722 98
8f20c9188561b796ef8e26196de30be4	39a096b71376b82f35732eff6d95779b	1477969195	104.075 39	30.723 01
8f20c9188561b796ef8e26196de30be4	39a096b71376b82f35732eff6d95779b	1477969198	104.075 76	30.723 08

原始数据共有 5 列, 分别为司机编号、乘客编号、时间、车辆经度和车辆纬度, 其中, 司机编号和乘客编号已经过脱敏处理, 时间采用 Unix 时间戳格式, 结合车辆经纬度信息, 每一行数据代表车辆所处的实时位置。

3.2 数据预处理

本文所用原始数据为反映车辆实时位置的时间连续型数据, 对于本文所针对的出行需求预测研究而言, 乘客出行起始点的经纬度和时间信息是所需的关键信息。因此, 对乘客出行轨迹数据进行预处理, 提取乘客上下车位置的经纬度及时间信息。处理后的数据共有 7 列, 字段名分别为司机编号、上车时间、下车时间、上车经度、上车纬度、下车经度、下车纬度。每一行数据代表每一个乘客出行订单的上下车位置经纬度和时间信息。

将预处理得到的乘客出行上下车位置数据导入地图进行热度分析, 可发现乘客出行上下车位置分布呈现出明显的区域性, 靠近市中心地区的订单数量较多, 靠近郊区的订单数量较少, 乘客出行上下车位置分布如图 14 所示。



图 14 乘客出行上下车位置分布

乘客出行上下车位置较分散, 所以将其划分为不同区域进行研究。本文采用 Geohash 地理编码系统, 综合考虑乘客的区域分布和计算机运算能力, 选取编码长度为 5 的矩形区域对乘客出行上下车位置数据进行划分, 将成都市划分为不同的区域, 根据乘客出行上下车位置的经纬度数据匹配对应区

域, 最终生成不同区域的乘客出行需求数据集。基于 Geohash 的成都市区域划分如图 15 所示。



图 15 成都市区域划分

设定时间步长, 将区域乘客出行需求数据按时间步长转化为时间序列, 每一个数据点均代表单位时间步长内该区域的订单总数。

试验最终的输入数据为不同区域的乘客出行需求时间序列数据及乘客出行空间依赖性矩阵。按照 6 : 2 : 2 的比例将乘客出行需求时间序列数据集划分成训练集、验证集和测试集, T_p 的时间跨度取 1 h, 初步设定 T_h 、 T_d 、 T_w 时间跨度为 T_p 的 2 倍, 初步设定时间步长为 5 min。经过寻优试验, 选择最优学习率 0.001, 最优训练批次大小 32。

3.3 试验结果

ASTGCN 模型在训练过程中, 训练集和验证集损失值的训练指标变化过程如图 16 所示, 可发现训练集、验证集损失值在不断下降, 之后在迭代次数为 50 左右趋于稳定, 说明模型达到了较理想的拟合状态。

接着分别使用门控循环神经网络 (GRU)、时间卷积神经网络 (TCN)、LSTM、TCN+LSTM、时空图卷积神经网络 (STGCN) 作为基准模型, 与 ASTGCN 模型进行对比, 某区域某天 10:00-16:00 的订单需求预测结果如图 17 所示。

选择平均绝对误差 (MAE) 和均方根误差 (RMSE) 作为评价指标, 预测评价结果见表 4, 可

知在 5 min 的时间步长下，ASTGCN 模型的平均绝对误差 (MAE) 和均方根误差 (RMSE) 均低于其他基准模型，实现了最佳的预测性能，证明了 ASTGCN 模型可以通过提取乘客出行数据在时间维度和空间维度上的特征，建立乘客出行需求数据的时间依赖性和空间依赖性模型，进而提升预测精度。同样地，通过 ASTGCN 模型和 STGCN 模型的预测性能指标对比，可以发现注意力机制的引入对提升模型预测精准度的有效性，证明了通过引入注意力机制，建立乘客出行需求数据的动态时空相关性模型，可以提高模型预测性能。

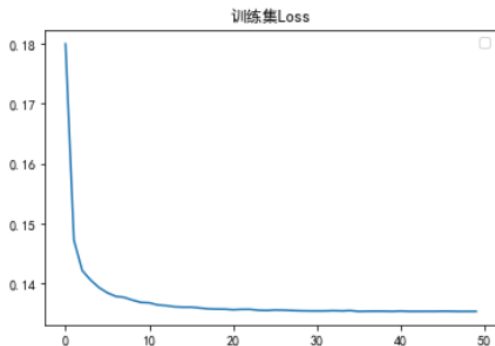
表 4 5 min 时间步长模型预测结果对比

模型	MAE	RMSE
GRU	10.44	28.39
TCN	10.29	27.31
TCN+LSTM	4.79	13.29
LSTM	4.25	12.38
STGCN	4.18	10.48
ASTGCN	3.40	9.33

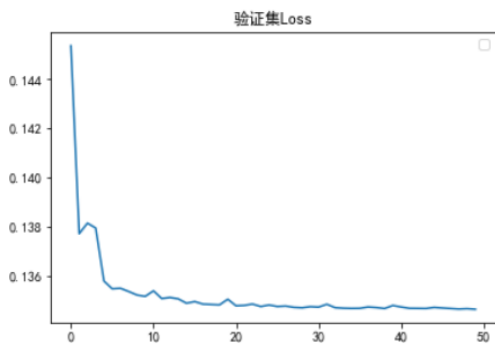
为探究时间步长对于需求预测的影响，分别以 2.5、5、7.5 和 10 min 作为时间步长，将乘客出行需求数据转化为时间序列，ASTGCN 模型与各基准模型在不同时间步长上的预测性能如图 18 所示。由图可知，ASTGCN 模型在所有不同时间步长的乘客出行需求时间序列中都取得了最佳的预测效果，充分表明了其针对乘客出行需求数据预测性能的相对稳定性和准确性。此外，与其他基准模型对比，随着时间步长的增加，基于注意力机制的时空图卷积神经网络预测性能恶化速度更慢，体现了其预测性能的相对稳定性，能同时应用于短期和长期乘客出行需求的预测。上述结果表明，ASTGCN 模型可以通过提取乘客出行需求数据中的时空相关性，进而提升预测效果。

此研究以临近依赖组件、日周期组件和周周期组件作为输入，输入数据片段长度分别为 T_h 、 T_d 、 T_w ，为被预测的网约车出行需求数据时间 T_p 的整数倍。为探究它们的片段长度对于预测结果的影响，本文设计 3 组试验，这 3 组试验中以 ASTGCN 作为模型， T_h 、 T_d 、 T_w 分别为 T_p 的 1 倍、2 倍和 3 倍。选择不同的时间步长，试验结果见表 5。结果表明， T_h 、 T_d 、 T_w 为 T_p 的 1 倍时，输入数据较少，会导致模型无法有效捕获乘客出行需求的特征信息，造成预测精度较低。 T_h 、 T_d 、 T_w 为 T_p 的 3 倍时，输入数据较多，所带来的额外信息开销会导致模型预测精度较低。当 T_h 、 T_d 、 T_w 为 T_p 的 2 倍，模型的预测性能最佳。

MAE 和 RMSE 均为绝对值指标，其值的大小受乘客出行需求时间序列中每个元素值的大小影响。因此，本节进一步探究不同时间步长对基于注



(a) ASTGCN 模型训练集损失值变化



(b) ASTGCN 模型验证集损失值变化

图 16 ASTGCN 模型损失值变化

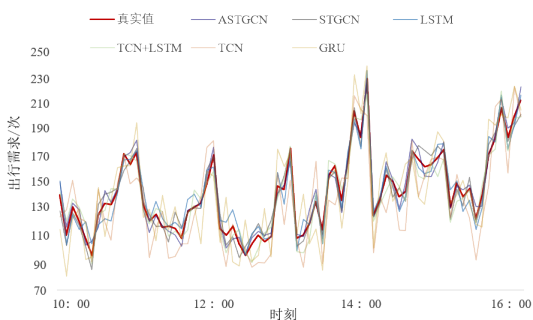


图 17 不同模型出行需求预测结果对比

注意力机制的时空图卷积神经网络模型的预测准确度的影响, 选取加权平均绝对误差百分比 (WMAPE) 作为模型预测准确度的评价指标, T_h 、 T_d 、 T_w 时间跨度为 T_p 的 2 倍, 不同时间步长下的基于注意力机制的时空图卷积神经网络模型的 WMAPE 如表 6 和图 19 所示。

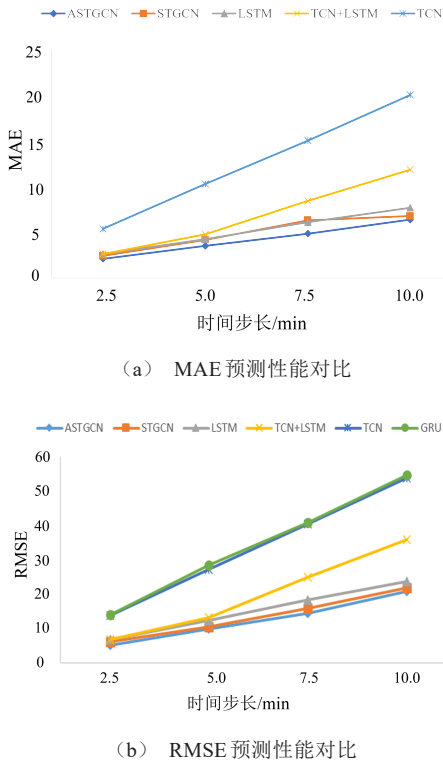


图 18 不同时间步长模型与基准模型 RMSE 预测性能对比

表 5 不同输入数据长度的预测结果对比

评价指标	试验组	2.5 min	5 min	7.5 min	10 min
MAE	1	2.10	3.52	4.85	5.98
	2	2.05	3.40	4.45	5.79
	3	2.07	3.42	4.75	5.81
RMSE	1	5.14	9.97	14.49	20.24
	2	4.99	9.33	12.77	18.42
	3	5.04	9.84	14.33	18.52

表 6 不同时间步长模型 WMAPE 预测性能对比

模型	15 s	30 s	1 min	2.5 min	5 min	7.5 min	10 min
ASTGCN	57.5%	30.5%	13.6%	5.0%	2.2%	1.4%	1.0%

经分析可知, 在时间步长为 15 s 时, 基于注意力机制的时空图卷积神经网络对乘客出行需求时间




图 19 不同时间步长模型 WMAPE 预测性能对比

序列的预测准确度较低。而随着时间步长增加到 2.5 min, 基于注意力机制的时空图卷积神经网络对乘客出行需求时间序列的预测准确度快速提高, 时间步长为 2.5 min 时, 预测模型 WMAPE 提高到 5.0%。随着时间步长从 2.5 min 增加到 10 min, 模型预测准确度提升较缓慢, WMAPE 在时间步长等于 10 min 时为 1.0%。上述结果表明, 时间步长的增加能有效提高基于注意力机制的时空图卷积神经网络对乘客出行需求时间序列预测的准确度, 但当时间步长达到一定值时, 时间步长的进一步提高对模型预测准确度的影响程度逐渐减弱。

4 结论

本文以乘客出行数据为基础, 面向多区域的乘客出行需求预测问题, 综合考虑了乘客出行需求的动态时空依赖性, 针对乘客出行需求的时间依赖性, 考虑并建立了乘客出行需求的临近依赖性、日周期性和周周期性模型。针对乘客出行需求的空间依赖性, 提出了一种基于格兰杰因果检验的乘客出行需求空间依赖性分析方法, 并建立了乘客出行需求的空间依赖性矩阵。针对乘客出行需求时空依赖性的动态特征, 引入了一种注意力机制, 模拟了乘客出行需求的动态时空相关性, 提高了算法的预测性能。以成都市乘客出行数据为例进行实例验证, 对比分析了基于注意力机制的时空图卷积神经网络模型和基准模型之间的预测性能差异, 最后考虑了不同预测时间步长对基于注意力机制的时空图卷积神经网络模型的预测准确度的影响。通过以上研究, 得到了以下 3 个方面的结论。

1) 通过对文献的系统梳理和总结, 以及针对

乘客出行需求的时空依赖性分析,发现乘客出行需求的时空依赖性是影响乘客出行需求的关键因素,并且区域间乘客出行需求的时空依赖关系是动态的,会随时间变化而发生改变。

2) 本文提出的ASTGCN模型,通过注意力机制捕获乘客出行需求数据时空依赖性的动态特征,能得到比GRU、TCN、LSTM、TCN+LSTM、STGCN模型更佳的预测精度,从而更加准确地预测网约车运

营中的乘客出行需求,对解决车队规模配置、降低车辆空载率、减少乘客等待时间等问题具有积极意义。

3) 预测时间步长的增加能有效提高基于注意力机制的时空图卷积神经网络对乘客出行需求时间序列预测的准确度,但当时间步长达到一定阈值时,增加预测时间步长对模型预测准确度的影响程度逐渐减弱。

参考文献 (References)

- [1] LI Xiaolong, PAN Gang, WU Zhaohui, et al. Prediction of Urban Human Mobility Using Large-Scale Taxi Traces and Its Applications [J]. *Frontiers of Computer Science*, 2012, 6(1): 111-121.
- [2] OKUTANI I, STEPHANEDES Y J. Dynamic Prediction of Traffic Volume Through Kalman Filtering Theory [J]. *Transportation Research Part B: Methodological*, 1984, 18(1): 1-11.
- [3] KIM C, HOBEIKA A G. Short-Term Demand Forecasting Model from Real-Time Traffic Data [J]. *Proceedings of the Infrastructure Planning and Management*, 1993, 15(2): 540-550.
- [4] DAVIS G A, NIHAN N L. Using Time-Series Designs to Estimate Changes in Freeway Level of Service, Despite Missing Data [J]. *Transportation Research, Part A (General)*, 1984, 18(6): 431-438.
- [5] 杨高飞, 徐睿, 秦鸣, 等. 基于ARMA和卡尔曼滤波的短时交通预测[J]. *郑州大学学报(工学版)*, 2017, 38(2): 36-40.
YANG Gaofei, XU Rui, QIN Ming, et al. Short-Term Traffic Volume Forecasting Based on ARMA and Kalman Filtering [J]. *Journal of Zhengzhou University (Engineering Science)*, 2017, 38(2): 36-40. (in Chinese)
- [6] 董军, 张勇. 快速路交通流时间序列的多重分形分析[J]. *计算机工程与应用*, 2016, 52(10): 227-230.
DONG Jun, ZHANG Yong. Analysis of Multifractal Properties of Traffic Flow Time Series on Expressway [J]. *Computer Engineering and Applications*, 2016, 52(10): 227-230. (in Chinese)
- [7] 曹征. 基于小波变换的交通流短时预测模型研究[D]. 北京: 北京交通大学, 2010.
CAO Zheng. Study of the Forecasting Model of Short-Term Traffic Flow Based on Wavelet Transform [D]. Beijing: Beijing Jiaotong University, 2010. (in Chinese)
- [8] 张勇. 交通流的非线性分析、预测和控制[D]. 北京: 北京交通大学, 2011.
ZHANG Yong. Nonlinear Characteristics Analysis, Prediction and Control of Traffic Flow [D]. Beijing: Beijing Jiaotong University, 2011. (in Chinese)
- [9] 张洪宾, 孙小端, 贺玉龙. 短时交通流复杂动力学特性分析及预测[J]. *物理学报*, 2014, 1(4): 1-8.
ZHANG Hongbin, SUN Xiaoduan, HE Yulong. Analysis and Prediction of Complex Dynamical Characteristics of Short-Term Traffic Flow [J]. *Acta Physica Sinica*, 2014, 1(4): 1-8. (in Chinese)
- [10] 贺国光, 马寿峰, 李宇. 基于小波分解与重构的交通流短时预测法[J]. *系统工程理论与实践*, 2002, 22(9): 101-106.
HE Guoguang, MA Shoufeng, LI Yu. Study on the Short-Term Forecasting for Traffic Flow Based on Wavelet Analysis [J]. *Systems Engineering—Theory & Practice*, 2002, 22(9): 101-106. (in Chinese)
- [11] 席殷飞, 刘钟锴, 杨佩云, 等. 网约车出行需求预测方法[J]. *上海大学学报(自然科学版)*, 2020, 26(3): 328-341.
XI Yinfei, LIU Zhongkai, YANG Peiyun, et al. Travel Demand Forecast Methods for Internet Private Hire Vehicles [J]. *Journal of Shanghai University (Natural Science Edition)*, 2020, 26(3): 328-341. (in Chinese)
- [12] RODRIGUES F, MARKOU I, PEREIRA F C. Combining Time-Series and Textual Data for Taxi Demand Prediction in Event Areas: A Deep Learning Approach [J]. *Information Fusion*, 2019, 49: 120-129.
- [13] GENG Xu, WU Xiyu, ZHANG Lingyu, et al. Multi-Modal Graph Interaction for Multi-Graph Convolution Network in Urban Spatiotemporal Forecasting [Z]. arXiv: 1905.11395, 2019.
- [14] BAI Lei, YAO Lina, WANG Xianzhi, et al. Deep Spatial-Temporal Sequence Modeling for Multi-Step Passenger Demand Prediction [J]. *Future Generation Computer Systems*, 2021, 121: 25-34.

- [15] TANG Jinjun, LIANG Jian, LIU Fang, et al. Multi-Community Passenger Demand Prediction at Region Level Based on Spatio-Temporal Graph Convolutional Network [J]. *Transportation Research Part C: Emerging Technologies*, 2021, 124: 102951.1–102951.18.
- [16] 孙立山, 贾琳, 魏中华, 等. 基于 GPS 数据的出租车出行需求预测研究 [J]. *交通信息与安全*, 2021, 39(5): 128–136.
- SUN Lishan, JIA Lin, WEI Zhonghua, et al. Demand Forecasting of Taxi Travel Based on GPS Data [J]. *Journal of Traffic Information and Safety*, 2021, 39(5): 128–136. (in Chinese)
- [17] LUO Huimin, CAI Jianmin, ZHANG Kunpeng, et al. A Multi-Task Deep Learning Model for Short-Term Taxi Demand Forecasting Considering Spatiotemporal Dependences [J]. *Journal of Traffic and Transportation Engineering(English Edition)*, 2021, 8(1): 83–94.
- [18] GENG Xu, LI Yaguang, WANG Leye, et al. Spatio-temporal Multi-Graph Convolution Network for Ride-Hailing Demand Forecasting [C]//*Proceedings of the AAAI'19: AAAI Conference on Artificial Intelligence*, Jan. 27–Feb. 1, 2019, Honolulu Hawaii USA. New York: AAAI, c2019: 3656–3663.
- [19] 段宗涛, 张凯, 杨云, 等. 基于深度 CNN-LSTM-ResNet 组合模型的出租车需求预测 [J]. *交通运输系统工程与信息*, 2018, 18(4): 215–223.
- DUAN Zongtao, ZHANG Kai, YANG Yun, et al. Taxi Demand Prediction Based on CNN-LSTM-ResNet Hybrid Depth Learning Model [J]. *Journal of Transportation Systems Engineering and Information*, 2018, 18(4): 215–223. (in Chinese)
- [20] 王维. 基于深度神经网络的网约车出行需求短时预测 [D]. 北京: 北京交通大学, 2020.
- WANG Wei. Short-Term Prediction of Car-Hailing Demand Based on Deep Neural Network [D]. Beijing: Beijing Jiaotong University, 2020. (in Chinese)
- [21] 张晓鹏. 基于多源数据融合的城市出行需求预测方法研究 [D]. 长春: 吉林大学, 2018.
- ZHANG Xiaopeng. Urban Travel Demand Forecasting Method Based on Multi-Source Data Fusion [D]. Changchun: Jilin University, 2018. (in Chinese)
- [22] WANG Dong, CAO Wei, LI Jian, et al. DeepSD: Supply-Demand Prediction for Online Car-Hailing Services Using Deep Neural Networks [C]//*2017 IEEE 33rd International Conference on Data Engineering (ICDE)*, April 19–22, 2017, San Diego, CA, USA. Piscataway NJ: IEEE, c2017: 243–254.
- [23] 吴佳昊. 基于深度神经网络的网约车出行需求预测研究 [D]. 北京: 北京建筑大学, 2022.
- WU Jiahao. Research on Online Car-Hailing Travel Demand Prediction Based on Deep Neural Network [D]. Beijing: Beijing University of Civil Engineering and Architecture, 2022. (in Chinese)
- [24] 孔瑶瑶. 基于网约车订单数据的热点区域出行需求预测 [D]. 北京: 北京交通大学, 2021.
- KONG Yaoyao. Online Car-Hailing Travel Demand Forecasting in Pick-up Hotspots Areas Based on Order Data [D]. Beijing: Beijing Jiaotong University, 2021. (in Chinese)
- [25] 赵恒辉, 黄德启, 曾蓉, 等. 基于时空注意力 Bi-LSTM 模型的短时交通流预测 [J]. *计算机仿真*, 2022, 39(9): 177–181.
- ZHAO Henghui, HUANG Deqi, ZENG Rong, et al. Short Term Traffic Flow Prediction Based on Spatial-Temporal Attention Bi-LSTM Model [J]. *Computer Simulation*, 2022, 39(9): 177–181. (in Chinese)
- [26] 张钊. 基于时空注意力网络的交通流预测研究 [D]. 武汉: 华中师范大学, 2021.
- ZHANG Zhao. Research on Traffic Flow Forecasting Based on Spatio-Temporal Attention Network [D]. Wuhan: Central China Normal University, 2021. (in Chinese)
- [27] 陈萌. 基于改进的图注意力网络的交通流预测研究 [D]. 上海: 上海师范大学, 2021.
- CHEN Meng. Research on Traffic Flow Prediction Based on Improved Graph Attention Network [D]. Shanghai: Shanghai Normal University, 2021. (in Chinese)

作者简介



王宁 (1977–), 男, 山东烟台人, 博士, 副教授, 主要研究方向为智能驾驶与智能汽车共享出行、汽车行业大数据分析。

Tel: 13321987816

E-mail: wangning@tongji.edu.cn

通信作者



马洪恩 (1998–), 男, 吉林长春人, 硕士研究生, 主要研究方向为共享出行需求预测及车辆调度。

Tel: 18117169020

E-mail: mayor_ma@163.com