

# 基于 GCN 和 TCN 的多因素城市路网出租车需求预测

陈 柘<sup>†</sup>, 刘嘉华, 赵 斌, 袁绍欣, 康 军

(长安大学信息工程学院, 陕西西安 710064)

**摘要:** 目前, 在巡游模式下, 出租车与乘客间供需不易匹配, 造成出租车空载和乘客打车难现象并存, 准确高效地实现路网出租车需求预测有利于有效缓解这一问题. 针对现有交通流预测模型对空间特征提取不充分, 特别是对城市路网内路段之间的空间关系没有全面挖掘这一问题, 充分考虑了路网内路段间的三种空间关系, 对其分别构建路段间的局部关系图、路段全局关系图和路段 OD 次数关系图. 提出了一种由图卷积网络和时间卷积网络相结合构成的出租车需求预测模型. 其中, 采用图卷积网络对城市路网内路段的空间关系特征进行挖掘, 采用时间卷积网络对交通数据集中的时间序列特征进行挖掘, 并且考虑了外部因素的影响. 实验中, 首先从真实出租车 GPS 轨迹数据中提取城市路网中各个路段的出租车出行量, 并利用道路上在多个时隙形成的出行量序列对预测模型进行验证. 结果表明, 相比其它交通流预测模型所提出的预测模型具有较优的平均绝对误差、均方根误差和平均绝对百分误差.

**关键词:** 出租车需求预测; 深度学习; 图卷积神经网络; 时间卷积神经网络; GPS 轨迹数据

中图分类号: TP39

文献标志码: A

DOI: 10.13195/j.kzyjc.2021.0814

## Multi Factor Taxi Demand Forecasting for Urban Road Network Based on GCN and TCN

CHEN Zhe<sup>†</sup>, LIU Jia-hua, ZHAO Bin, YUAN Shao-xin, KANG Jun

(School of Information Engineering, Chang'an University, Xi'an 710064, China)

**Abstract:** At present, in the cruise mode, the supply and demand between taxis and passengers is not easy to match, resulting in the coexistence of empty taxis and hard hailing phenomenon. Accurate and efficient realization of the road network taxi demand forecast is conducive to effectively alleviate this problem. In the view of that the existing traffic flow prediction models can not sufficiently extract spatial features, especially the spatial relationship between sections in urban road network, full consideration was given to the three kinds of spatial relationship between segments within the road network, and three types of graph were constructed correspondingly, i.e. the local relationship graph, the global relationship graph and the OD frequency relationship graph. This paper proposes a taxi demand prediction model which is composed of graph convolutional network and temporal convolutional network. The graph convolutional network is used to mine the spatial relationship features of sections in the urban road network, and the temporal convolutional network is used to mine the time series features of traffic data, and the influence of external factors is considered. In the experiment, the number of taxi trips in each section of the urban road network is extracted from the real taxi GPS trajectory data, and the series of trips number formed in multiple time slots on the road is used to verify the prediction model. The results show that the proposed model is superior to the common traffic prediction models, and has smaller mean absolute error, root mean square error and mean absolute percentage error.

**Keywords:** taxi demand forecast; deep learning; graph convolutional network; temporal convolutional network; GPS trajectory data

收稿日期: 2021-05-11; 录用日期: 2021-02-25.

基金项目: 国家重点研发计划 (2020YFB1600400); 陕西省重点研发计划 (2019ZDLGY03-09-01, 2020ZDLGY09-02, 2022GY-063)

<sup>†</sup>通讯作者. E-mail: zchen@chd.edu.cn.

## 0 引言

出租车是城市公共交通的重要组成,具有可灵活选择起终点的便利,在大众出行中发挥着重要作用.然而,由于目前仍有大量出租车采用巡游揽客模式,出租车和乘客之间的供需得不到有效匹配.因此,一方面造成出租车空载,另一方面又有乘客打不到车.为了有效提升城市出租车运行效率,减少无效能耗,更好满足乘客出行需求,解决城市路网中的出租车需求预测问题显得尤为重要.

出租车需求预测是交通预测问题中的一个分支.交通预测基于历史数据对未来交通状况,如交通流、车辆速度、行程时间等进行预测<sup>[1]</sup>.目前,在城市交通预测研究中,主流的研究方法是基于数据驱动的方法,其技术核心是机器学习算法.

近十多年来,深度学习方法逐步发展.由于其具有深层次的网络结构,可以提取表达力强的数据特征,具有逼近复杂函数的能力,因此被广泛用于交通预测,并且展现出良好的预测性能.依据技术的发展状况,可以将基于深度学习的交通预测划分为三个技术阶段.

第一个阶段,即早期应用阶段.研究中使用有限结构的深度网络模型,如 FNN(Feed-forward Neural Network)<sup>[2]</sup>,DBN(Deep Belief Network)<sup>[3]</sup>,以及 SAE(Stacked Auto Encoder)<sup>[4]</sup>等.这些网络模型将交通数据看作数值序列,对交通数据进行建模,较传统机器学习算法,预测性能有所提升.但是,这些工作将交通预测局限在某一路段或路网中的某一点,而且更适合短时预测,对长时预测的性能并不理想.

第二个阶段,基于卷积和循环网络对交通数据建模阶段.这个阶段为了更有效提取交通数据中的长时相关性,引入了 RNN(Recurrent Neural Network),如 LSTM(Long Short-Term Memory)和 GRU(Gated Recurrent Unit)等模型,将其用于车辆速度<sup>[5]</sup>,交通流<sup>[6]</sup>和行程时间<sup>[7]</sup>的估计.但这种方法忽视了交通数据在空间上的相关性,如邻近道路的交通存在相互影响.为了考虑这种空间上的相关性,研究人员开始利用 CNN(Convolutional Neural Network)进行交通流的预测,如 Yu 等将路网的车辆速度转换为图像序列,而后组合使用 CNN 和 LSTM 联合捕获数据中存在的时空相关性<sup>[8]</sup>.从此拉开了交通数据时空联合分析的序幕,之后涌现出大量类似的工作,如 [9-11].这些方法的共同特点是需要将路网中产生的交通数据转换为类似图像的规则点阵数据,而这种方法无法反映真实的路网拓扑结构,因此无法准确捕获交

通数据的空间相关性.

第三个阶段,即最新的研究阶段.特点是利用神经网络对交通流数据进行建模.由于交通路网具有天然的图结构特征,可以将道路看作图的顶点,用边表示道路之间的邻接关系.这样,道路的拓扑结构和路网的交通流变化即可以用图构成的张量来表达.在深度学习研究中,为了使用神经网络的方法处理这种图结构数据,催生出了图神经网络(Graph Neural Network,GNN)<sup>[12-13]</sup>.在此基础上,借助于谱图卷积<sup>[14-15]</sup>和扩散图卷积理论<sup>[16]</sup>,将 CNN 中的卷积操作扩展到图域,形成图卷积网络(Graph Convolutional Network,GCN).由于其可有效描述路网的拓扑结构和提取图结构数据中的特征,非常适合分析路网交通预测问题.目前,已有不少基于 GCN 对路网交通预测的工作,如 [17-22].

在利用 GCN 对路网交通进行分析时,需要充分挖掘和利用路网中存在的时空相关性.研究发现,路网中相邻路段的交通状态紧密相关.例如,当道路发生拥堵时,其拥堵效应会向邻近道路扩散;其次,对于非邻近但具有相似城市功能的区域,如城市商业区、居住区、工作区等,其邻近的道路交通状况通常具备相似性,如早晚通勤高峰时,表现出的相似的交通状态变化.另外,路段间 OD 次数反映了路段对人流的吸引和发出特性,相近的 OD 次数变化也间接反映了不同道路交通状态的关联特性,例如不同地点的出发流与一些地点的输入流存在关联关系.

目前,在交通流预测中,由于很少有工作考虑将路网中多样的关联关系进行建模,因此图网络的构图方法较为简略,对交通数据中隐含的关联关系的发掘造成了影响.并且,如:天气状况、气温、是否工作日、空气污染等级等外部因素也会对路网中的交通状态造成影响.故在对交通流进行预测时,外部因素的影响不可忽视.

本文通过对路网中路段之间的三种隐含关系进行建模,构建三种关系图.分别是路段出行量局部关系图、路段出行量全局关系图和路段出行量 OD 次数关系图.局部关系图表示相邻路段之间的局部关联关系,全局关系图表示出行量相似但不相邻路段之间的全局关联关系<sup>[23]</sup>,OD 次数关系图表示路段间 OD 次数的关联关系.三种图的构建挖掘了交通数据中路段间的时间与空间特征,进一步提高出行量预测模型准确度.

同时,构建了一种考虑多因素的出租车出行量预测模型,称为多因素 GCN-TCN 网络,简称 MFGTN

(Multi Factor GCN-TCN Network), 实现路网级别的出租车出行量短时预测. 该模型基于图卷积神经网络 (GCN) 和时间卷积神经网络 (Temporal Convolutional Network, TCN) [24] 分别对交通数据集中的空间与时间特征进行挖掘, 并基于星期几、天气、温度、空气质量等外界因素构建外部因素特征矩阵, 使用全连接层对其进行特征挖掘, 通过卷积层实现多种特征融合. 并且, 基于真实的出租车轨迹数据对预测模型进行实验验证, 结果具有较优的 RMAE、MAE 和 MAPE 值, 与常用交通流预测模型相比有更准确的预测效果.

## 1 基于 MFGTN 的出租车需求预测方法

### 1.1 网络输入图构建

本节对网络所输入的三种城市路网路段间的关系图以及外部因素特征矩阵的构建进行介绍. 包括路段出行量局部关系图、路段出行量全局关系图和路段出行量 OD 次数关系图, 以及外部因素特征矩阵. 给定图  $G = (V, A, E)$ , 其中,  $V = \{v_1, v_2, \dots, v_N\}$ , 表示  $N$  个节点组成的节点集合,  $E = \{e_1, e_2, \dots, e_M\}$ , 表示输入图的边集, 共  $M$  个边.  $A \in \mathbb{R}^{N \times N}$  则为输入图的邻接矩阵.

#### 1) 路段出行量局部关系图

在路段出行量局部关系图中, 图的节点为路段.  $X \in \mathbb{R}^{N \times K}$  作为该图的特征矩阵, 表示研究路段在历史时隙内的出租车出行量序列.  $N$  表示路段总个数,  $K$  表示出行量序列的长度. 即总路段数为  $N$ , 共  $K$  个历史时隙的出租车出行量. 图的边是由路网中路段之间是否相邻决定的. 若邻接矩阵  $A$  中的对应元素  $a_{ij} = a_{ji} = 1$ , 则表示路段  $i$  与路段  $j$  在真实路网中相邻. 同理,  $a_{ij} = a_{ji} = 0$  表示路段  $i$  与路段  $j$  在真实路网中不相邻.

#### 2) 路段出行量全局关系图

在路段出行量全局关系图中, 通过路段之间的出行量相似度  $\omega_{ij}$  得到图的边. 路段  $i$  与路段  $j$  间的出行量序列相似度  $\omega_{ij}$  根据式 (1) 计算得出, 且相似度  $\omega_{ij}$  作为图的邻接矩阵中的元素, 表示为  $a_{ij} = a_{ji} = \omega_{ij}$ .  $X \in \mathbb{R}^{N \times K}$  作为该图的特征矩阵, 表示研究路段在历史时隙内的出租车出行量序列.

$$\omega_{ij} = \begin{cases} e^{-\frac{L^2(X_i, X_j)}{\sigma^2}}, & i \neq j \text{ and } e^{-\frac{L^2(X_i, X_j)}{\sigma^2}} \geq \varepsilon, \\ 0, & \text{otherwise.} \end{cases} \quad (1)$$

式中, 通过快速时间动态归整算法 (Fast Dynamic Time Warping, FastDTW) [25] 计算得到

$L(X_i, X_j)$ , 表示路段  $i$  与路段  $j$  的出租车出行量序列  $X_i$  与  $X_j$  间的距离, 且此处的距离选为欧氏距离衡量. 此处,  $\varepsilon$  和  $\sigma^2$  根据经验确定, 取  $\varepsilon$  为 0.5,  $\sigma^2$  为 1000.

#### 3) 路段出行量 OD 次数关系图

在路段出行量 OD 次数关系图中, 各路段作为图的节点, 通过路段之间的 OD 次数生成图的边. 首先对各研究路段之间的日均 OD 进行统计, 然后采用 Min-Max 归一化, 将原数据转换至  $[0, 1]$  的范围. 归一化后的路段  $i$  与路段  $j$  之间的日平均 OD 次数作为邻接矩阵中的元素  $a_{ij}$ .  $X \in \mathbb{R}^{N \times K}$  作为该图的特征矩阵.

#### 4) 外部因素特征矩阵

外部因素矩阵的构建过程中考虑了天气、周几、空气污染、温度四种因素. 使用 7 位独热向量编码表示数据采集时刻的工作日信息, 若第 1 位为 1 就则当前向量代表星期一, 以此类推, 可用 7 为独热编码具体表示处在周几; 使用 6 位独热向量编码表示天气因素, 分别表示多云、晴、小雨、中雨、大雨、阴六种不同天气变化; 使用 15 位独热向量编码表示空气质量指数 (Air Quality Index, AQI), 说明空气污染等级. 以 10 作为间隔表示取值范围从 0 至 150 的 AQI 指数; 可用 7 位独热向量编码表示研究时段从  $10^\circ\text{C}$  至  $24^\circ\text{C}$  的温度因素. 最终, 外部因素特征矩阵可用长度为 35 的独热向量编码表示, 如图 1 所示.




图 1 外部因素独热向量示意图

路段间对出租车出行量预测的问题可以定义为: 给出在历史  $k$  个时隙内所有研究路段的出租车出行量  $X^1, X^2, \dots, X^k$ , 对在第  $k+1$  个时隙内各路段的出租车出行量  $X^{k+1}$  进行预测.

### 1.2 MFGTN 的网络结构

MFGTN 基于 GCN 和 TCN 构成, 结构如图 2 所示. 网络输入包括路段出行量全局关系图、路段出行量局部关系图和路段出行量 OD 次数关系图, 以及外部因素特征矩阵. 其中, TCN 的主要作用是挖掘交通数据中序列的时间特征, GCN 的主要作用则是挖掘城市路网路段间的空间特征.

路段出行量全局关系图构建过程中, 能够挖掘存在相似出租车出行量序列的城市路网路段之间的隐含空间关联, 可以反映城市中不同功能区域的分布对出租车需求预测的影响; 路段出行量局部关系图构建过程中, 能够挖掘真实路网中相邻路段之间

的隐含空间关联,可以反映路网拓扑结构对出租车需求预测的影响;路段出行量 OD 次数关系图的构建过程中,能够挖掘存在 OD 关系的城市路网路段之间的隐含空间关联,可以反映路段间的 OD 关系对出租车需求的影响。

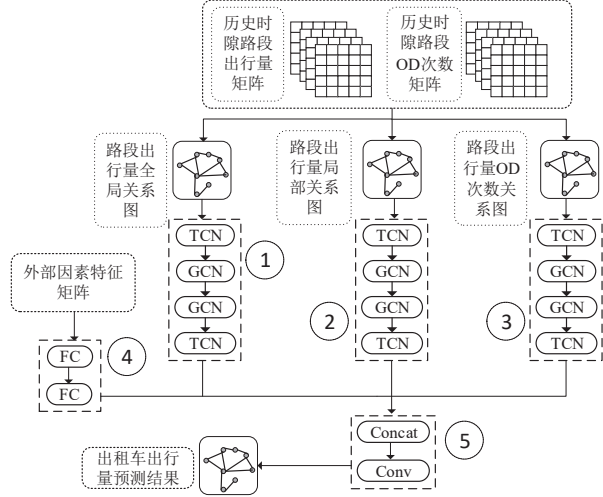


图2 MFGTN 网络结构图

图2中由TCN和GCN构成的模块,称为图处理模块.自左向右共有3个图处理模块,分别编号为模块1、2和3,见图2中圆圈数字1-3指示的虚线框.另外,由2层全连接层构成外部因素处理模块,由级联操作和卷积层构成级联卷积模块,见图2中标有圆圈数字4和5的虚线框.在每个图处理模块中,先通过一个TCN网络模块对时间特征进行挖掘.每个TCN模块中包含两个相同的块,每个块中依次包含一个因果膨胀卷积层(Dilated causal convolution)、一个权重归一化层(WeightNorm)、一个Relu激活函数层和一个Dropout层,而且为了让网络可以跨层传递信息以便于网络训练,采用了残差连接(Residual Connections)的方法.TCN的网络结构如图3所示.

若研究路段总数为 $N$ ,历史时段数为 $K$ ,则所构建图的特征矩阵为 $X \in \mathbb{R}^{N \times K}$ .当残差块的输入与输出维度不同时,添加一个 $1 \times 1$ 的卷积,使得经过一层TCN后,输出的矩阵大小不变,仍为 $N \times K$ .本文采用GCN对空间特征进行挖掘,故接着堆叠两个GCN模块,且固定输出矩阵大小为 $1 \times N$ .GCN的运算公式如式(2)所示.在对空间特征挖掘后,再通过

一层TCN进行时间特征挖掘.同样,TCN中设置一个 $1 \times 1$ 的卷积,使得输出矩阵大小仍为 $1 \times N$ .最后,完成对出租车数据中的时间与空间特征的挖掘.

通过两个堆叠的全连接层进行特征映射完成对外部因素特征矩阵的特征挖掘,且令输出矩阵大小也为 $1 \times N$ .至此,共得到了四个特征向量且大小都为 $1 \times N$ . $O_{local}$ 为局部关系特征向量, $O_{global}$ 为全局关系特征向量, $O_{od}$ 为OD次数关系特征向量, $O_{ext}$ 为外部因素特征向量.将上述四个向量进行级联,得到 $O_{pre} \in 4 \times N$ .最后使用卷积核大小为 $4 \times 1$ ,步长为1,padding为VALID,对矩阵 $O_{pre}$ 进行卷积处理,完成特征融合.输出的最终预测结果 $X^{k+1} \in 1 \times N$ ,表示研究路段在 $k+1$ 时隙的出租车出行量预测值.

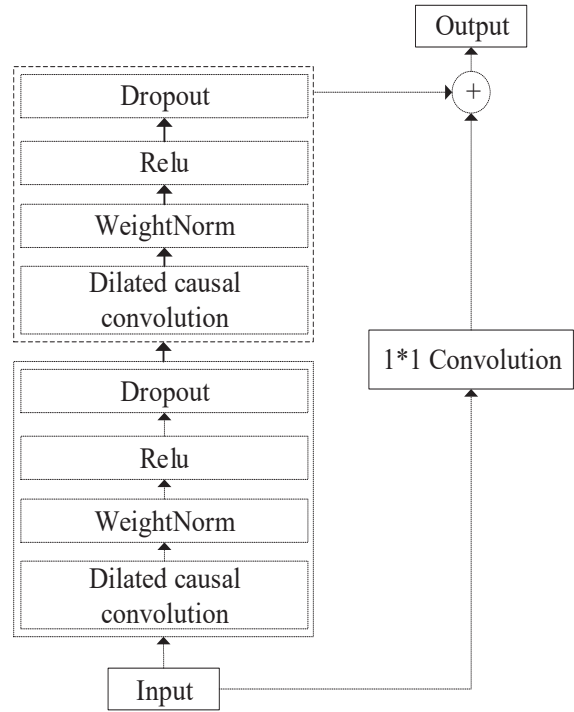


图3 TCN 结构示意图

$$X^{k+1} = \sigma(\hat{A}X^k\Theta) \quad (2)$$

式中, $\hat{A} = \tilde{D}^{-\frac{1}{2}}\tilde{A}\tilde{D}^{-\frac{1}{2}}$ , $\tilde{A} = A + I_N$ , $\tilde{D}_{ii} = \sum_j \tilde{A}_{ij}$ , $\Theta$ 表示图卷积核的参数, $\sigma(\cdot)$ 表示激活函数.该式表示网络中第 $k+1$ 层图卷积运算的结果.

为清晰起见,将MFGTN网络的输入和输出变量列于表1中.

表1 MFGTN 网络输入/输出变量表

模块	输入/输出	变量	含义
图像处理模块1	输入	出行量全局关系图相似度矩阵 $A_{global} \in \mathbb{R}^{N \times N}$	矩阵元素 $a_{ij}$ 为路段 $v_i$ 和 $v_j$ 间出行量序列的相似度
	输入	出行量全局关系图节点特征矩阵 $X_{global} \in \mathbb{R}^{N \times K}$	矩阵的第 $i$ 行表示路段 $v_i$ 在 $K$ 个时隙的出行量序列 $\in \mathbb{R}^{1 \times K}$
	输出	$O_{global} \in \mathbb{R}^{1 \times N}$	矢量的第 $i$ 个元素表示路段 $v_i$ 出行量的预测值

图像 处理 模块 2	输入	出行量局部关系图邻接矩阵 $A_{local} \in \mathbb{R}^{N \times N}$	矩阵元素 $a_{ij}$ 表示路段 $v_i$ 和 $v_j$ 间是否邻接
	输入	出行量局部关系图节点特征矩阵 $X_{local} \in \mathbb{R}^{N \times K}$	矩阵的第 $i$ 行表示路段 $v_i$ 在 $K$ 个时隙的出行量序列 $\in \mathbb{R}^{1 \times K}$
	输出	$O_{local} \in \mathbb{R}^{1 \times N}$	矢量的第 $i$ 个元素表示路段 $v_i$ 出行量的预测值
图像 处理 模块 3	输入	出行量 OD 次数关系图 OD 关系矩阵 $A_{od} \in \mathbb{R}^{N \times N}$	矩阵元素 $a_{ij}$ 表示路段 $v_i$ 和 $v_j$ 间 OD 次数
	输入	出行量 OD 次数关系图节点特征矩阵 $X_{od} \in \mathbb{R}^{N \times K}$	矩阵的第 $i$ 行表示路段 $v_i$ 在 $K$ 个时隙的出行量序列 $\in \mathbb{R}^{1 \times K}$
	输出	$O_{od} \in \mathbb{R}^{1 \times N}$	矢量的第 $i$ 个元素表示路段 $v_i$ 出行量的预测值
外部因 素模块	输入	外部特征矢量 $\in \mathbb{R}^{1 \times 35}$	矢量的元素表示某个特定外部因素
	输出	$O_{ext} \in \mathbb{R}^{1 \times N}$	矢量的元素表示对路段 $i$ 出行量的影响权重
级联卷 积模块	输入	$O_{pre} \in \mathbb{R}^{4 \times N}$	$O_{global}$ 、 $O_{local}$ 、 $O_{od}$ 和 $O_{ext}$ 的级联
	输出	$O \in \mathbb{R}^{1 \times N}$	矢量的第 $i$ 个元素表示路段 $v_i$ 出行量的预测值

## 2 实验设计与验证

### 2.1 数据集描述

本实验数据集为西安市出租车 GPS 真实数据记录, 数据集中出租车车辆总数超过 10000 辆, 总路段数超过 20000 条, 包含西安三环内所有路网. 通过 GPS 设备每 30 秒对当前车辆进行一次数据采集. 采集字段包括车牌号、采集时间、经度、纬度、速度、航向角、车辆状态. 其中, 车辆状态为“4”表示车辆为空车, 车辆处于未载客状态; 车辆状态为“5”表示车辆为重车, 车辆处于载客状态. 若车辆状态从“4”变为“5”则表示乘客上车, 车辆状态从“5”变为“4”表示乘客下车. 故可对每辆出租车的 OD 进行统计, 进而通过经纬度定位至路段, 得到路段的出租车出行量序列.

实验中, 从 2016 年 10-11 月西安市出租车轨迹数据中抽取了 4 周 (10 月 10 日-11 月 6 日) 共 28 天的轨迹数据. 考虑到本文所提出的模型主要用于短时预测, 故以 5 分钟为一个时隙, 使用前 24 个时隙的出行量预测下一个时隙的出行量. 这样, 28 天的数据, 共可分为  $28 \times 24 \times 12 = 8064$  个时隙. 而后, 将每 25 个连续的时隙视作一个训练样本, 即 1-25, 2-26, 3-27, …, 8040-8064, 共可得到 8040 个样本. 通过随机抽取, 将这些样本等分为 7 份, 进行 7 折交叉验证.

由于车流量小的路段通常人们不会重视, 且对这些路段进行车流量预测的意义较小. 故在本实验中, 选取每日平均 OD 次数大于 15 次的路段作为研究路段, 经数据筛选, 最终得到 851 个路段.

### 2.2 评价指标

为了能够有效地对本文中提出的模型进行评估, 本文主要在三种指标上进行了测定, 分别是均方根误差 (Root Mean Squared Error, RMSE)、平均绝对误差 (Mean Absolute Error, MAE) 和平均绝对百分比误差 (Mean Absolute Percentage Error, MAPE), 其定义

式依次如式 (3)(4)(5) 所示<sup>[26]</sup>:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (3)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (4)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (5)$$

其中,  $N$  表示路段的总数目,  $y_i$  表示预测路段  $i$  在预测时隙内出租车出行量的真实值,  $\hat{y}_i$  则表示预测路段  $i$  在预测时隙内出租车出行量的预测值.

### 2.3 与常用交通预测模型的对比实验

为了验证 MFGTN 模型的有效性, 本节对 MFGTN 模型的预测性能进行实验. 运行环境为两个 Intel (R) Xeon (R) E5-2690 CPU 和一块内存大小为 256GB 的 RTX2080TI GPU 加速卡. 模型的搭建基于 TensorFlow 深度学习框架. 依据经验值, 批次大小设置为 32, 迭代次数设置为 500, 学习率设置为 0.0001, 并且通过提前终止策略 (Early Stopping) 防止过拟合, 优化器采用 Adam 优化器. 对比交通流预测模型如下.

1) 历史平均值 (Historical Average, HA). 通过历史交通流的平均值对未来时隙的交通流进行预测. 本实验中历史时隙为预测时隙之前的所有时隙.

2) 差分整合移动平均自回归模型 (Autoregressive Integrated Moving Average Model, ARIMA). 该方法由 AR 模型 (自回归模型)、MA 模型 (滑动平均模型) 和差分法组成, 是时间序列预测分析方法之一.

3) MLP, 既多层感知机网络. 本实验中 MLP 的层数设置为 3, 每层都为全连接层. 输入为分割好的 24 个时隙, 对下一时隙进行预测.

4) 支持向量回归 (Support Vector Regression,

SVR).SVR 是 SVM (支持向量机 support vector machine) 对回归问题的一种运用. 是通过核函数 (kernel function) 将特征由低维映射至高维特征空间, 然后再进行回归的一种方法.

5) 长短时记忆神经网络 (LSTM).LSTM 是通过引入门控机制控制特征的流通和损失的一种循环神经网络. 克服了 RNN 中的捕获序列长期依赖问题, 并且在训练过程可以防止 RNN 中的梯度爆炸或消失的问题. 是常用的时间序列预测模型之一.

6) 图卷积神经网络 (GCN).GCN 是基于 CNN 思想, 将卷积运算扩展至图结构中. 在被定义的图结构中,GCN 能够提取图中节点与边的结构特征, 对空间特征的提取能力较强. 在交通流预测中, 城市路网的拓扑结构具有图的特征, 可用 GCN 对城市路网中路段间的空间关系进行特征提取. 本实验中通过堆叠三层 GCN 网络完成对路段出行量全局关系图的空间特征提取.

7) T-GCN<sup>[21]</sup>.T-GCN 结合了图卷积网络 (GCN) 和门控递归单元 (GRU) 进行预测. 前者用于学习复杂的城市路网拓扑结构并捕捉空间相关性, 后者则用于学习路段出行量序列间的时间相关性. 本实验中的网络输入图为路段出行量局部关系图.

表 2 对比实验结果

模型	RMSE	MAE	MAPE
HA	0.7851	0.4493	9.637%
ARIMA	1.3734	1.1719	12.7381%
MLP	0.8066	0.4659	10.3173%
SVR	0.7202	0.3869	8.4248%
LSTM	0.6768	0.3768	8.3572%
GCN	0.6114	0.3475	8.262%
T-GCN	0.6108	0.3314	8.256%
MFGTN	<b>0.6018</b>	<b>0.2988</b>	<b>7.085%</b>

对比实验结果如表 2 所示.HA、ARIMA 模型不能对交通数据中的长时间序列特征进行充分分析.MLP 和 SVR 由于其网络结构问题, 表达能力不足, 无法对数据中的时间与空间关系特征进行显式建模.LSTM 虽然通过门控机制实现对长时间序列之间的相关性分析, 但忽略了城市路网的拓扑结构, 无法对空间关系特征进行处理.GCN 可以提取复杂城市路网中的拓扑结构, 但无法对交通数据中的时间序列间的特征进行挖掘.T-GCN 中, 虽采用 GRU 与 GCN 实现时间序列与空间关系分析. 但 GRU 对长时间序列分析能力不如 LSTM, 并且此处 GCN 只考虑了城市路网中的路段出行量局部关系, 没有考虑路

段间具有相似出行量特征的全局关系.MFGTN 网络的 RMSE、MAE 和 MAPE 均优于其他对比模型. 这是由于 MFGTN 网络通过堆叠 TCN 与 GCN 网络对时间与空间特征进行提取. 并且同时考虑了路段间的局部关系、全局关系、OD 关系以及外部影响因素. 故在对比模型中预测性能最优.

## 2.4 多因素消融分析实验

本节对网络送入不同的输入进行预测, 分析不同的输入对模型预测效果的影响. 分别用  $G_{local}$ 、 $G_{global}$ 、 $G_{od}$  和  $X_{ext}$  表示路段出行量局部关系图、路段出行量全局关系图、路段出行量 OD 次数关系图和外部因素特征矩阵. 其中外部因素特征矩阵根据考虑因素不同可分为  $X_d$ 、 $X_w$ 、 $X_a$  和  $X_t$ , 分别表示工作日因素矩阵、天气状态因素矩阵、空气污染因素矩阵和温度因素矩阵.

表 3 多因素消融实验结果

网络输入	RMSE	MAE	MAPE
$G_{local}$	0.6076	0.3194	7.7723%
$G_{global}$	0.6081	0.3202	7.8155%
$G_{od}$	0.6086	0.3209	7.9723%
$G_{local} + G_{global}$	0.6052	0.3076	7.2917%
$G_{local} + G_{od}$	0.6059	0.3082	7.3473%
$G_{global} + G_{od}$	0.6067	0.3104	7.3812%
$G_{local} + G_{global} + G_{od}$	0.6044	0.3042	7.2145%
$G_{local} + G_{global} + G_{od} + X_d$	0.6036	0.3007	7.1562%
$G_{local} + G_{global} + G_{od} + X_w$	0.6038	0.3011	7.1593%
$G_{local} + G_{global} + G_{od} + X_a$	0.6034	0.3003	7.1468%
$G_{local} + G_{global} + G_{od} + X_t$	0.6032	0.2998	7.1381%
$G_{local} + G_{global} + G_{od} + X_{ext}$	<b>0.6018</b>	<b>0.2988</b>	<b>7.085%</b>

(MFGTN)

实验结果如表 3 所示. 单独以一种图, 尤其以  $G_{od}$  作为输入的模型预测结果最差.RMSE 为 0.6086, MAE 为 0.3209, MAPE 为 7.9723%. 可得, 在输入为单一的  $G_{local}$ 、 $G_{global}$  和  $G_{od}$  中, $G_{local}$  作为输入预测结果最优. 说明真实路网中路段间是否相邻的空间关系对模型预测的作用最大. 当将两种图作为输入时, 预测误差相比于单一图输入减小. 并且, 以  $G_{local}$  和  $G_{global}$  作为网络输入时, RMSE、MAE 和 MAPE 分别为 0.6052、0.3076 和 7.2917%, 模型预测效果最好. 当将  $G_{local}$ 、 $G_{global}$  和  $G_{od}$  三种图输入时, RMSE、MAE 和 MAPE 分别为 0.6044、0.3042、7.2145%, 可得, 考虑城市路网路段之间的多种隐含空间关系能够对交通数据中的空间特征充分提取, 提高模型精度. 此外, 将  $X_d$ 、 $X_w$ 、 $X_a$  和  $X_t$  分别加入网络, 误差进一步降低, 说明外部影响因素对模型预测结果的影响不可忽略.

进而,MFGTN 将三种关系图与所有外部因素进行考虑,充分提取交通数据中的时空相关性与外部因素,模型效果达到最优。

## 2.5 时隙大小对网络的影响实验

本节通过对 MFGTN 网络分别设置不同的时隙大小进行模型预测结果分析. 图 4 为时隙大小对 MFGTN 网络的影响结果图. 设置时隙大小分别为 5 分钟、15 分钟和 30 分钟,模型预测效果随着时隙的增大而降低. 由于较近历史时隙的出租车出行量相比较远时隙的出租车出行量对预测时隙的出行量影响较大,说明本文模型在对较短时的交通流预测任务中效果较好。




图 4 时隙大小对网络的影响

## 2.6 预测步长对网络的影响实验

本节通过对 MFGTN 网络分别设置不同的预测步长进行模型预测结果分析. 这里 1 个步长表示 1 个时隙的长度. 图 5 为不同预测步长对 MFGTN 网络的影响结果图. 设置预测步长大小为 1 至 5,随着预测步长的增加,网络的预测误差逐渐增大,呈现逐步上升趋势. 由于多步预测是将前一待预测时隙的预测结果作为下一待预测时隙的输入,当预测步长增加,误差会随之积累. 影响模型的长时序预测效果。




图 5 预测步长对网络的影响

## 3 结论

目前交通流预测模型中对空间特征的提取不充分,特别是对城市路网路段之间的空间关系没有进行全面的挖掘. 本文提出了一种由图卷积网络和时间卷积网络相结合的出租车需求预测模型 MFGTN 对交通数据进行时空特征挖掘. 并且模型在真实的

出租车数据集上进行了有效验证. 经实验结果表明,本文所提出的出租车需求预测方法优于其他常用的交通流预测方法. 因为本文对城市路网路段之间的多种隐含空间关系进行了建模,并且考虑了多种外部因素特征对预测结果的影响. 进一步的研究重点考虑如何将城市路网中的兴趣点 (Point of Interest, POI) 信息进行建模,能够使网络挖掘不同功能路段之间的关系,利于网络充分挖掘交通数据中的空间关系,进一步提升模型精度。

## 4 参考文献

### 参考文献 (References)

- [1] Yin X, Wu G, Wei J, et al. A comprehensive survey on traffic prediction[EB/OL]. (2020-04-18) [2021-05-01]. <https://arxiv.org/pdf/2004.08555.pdf>.
- [2] Park D, and Rilett L R. Forecasting freeway link travel times with a multilayer feedforward neural network[J]. Computer-Aided Civil and Infrastructure Engineering, 1999, 14(5): 357-367.
- [3] Huang W, Song G, Hong H, et al, Deep architecture for traffic flow prediction: Deep belief networks with multitask learning[J]. IEEE Transactions on Intelligent Transportation Systems, 2014, 15(5): 2191-2201.
- [4] Lv Y, Duan Y, Kang W, et al. Traffic flow prediction with big data: A deep learning approach[J]. IEEE Transactions on Intelligent Transportation Systems, 2015, 16(2): 865-873.
- [5] Ma X, Tao Z, Wang Y, et al. Long short-term memory neural network for traffic speed prediction using remote microwave sensor data[J]. Transportation Research, Part C: Emerging Technologies, 2015, 54: 187-197.
- [6] Zhao Z, Chen W, Wu X, et al. LSTM network: A deep learning approach for short-term traffic forecast[J]. IET Intelligent Transport Systems, 2017, 11(2): 68-75.
- [7] Duan Y, Lv Y, and Wang F. Travel time prediction with LSTM neural network[C]. Proceedings of IEEE 19th International Conference on Intelligent Transportation Systems. Rio de Janeiro: IEEE, 2016: 1053-1058.
- [8] Yu H, Wu Z, Wang S, et al. Spatiotemporal recurrent convolutional networks for traffic prediction in transportation networks[J]. Sensors, 2017, 17(7): 1501.
- [9] Yao H, Wu F, Ke J, et al. Deep multi-view spatial-temporal network for taxi demand prediction[C]. Proceedings of AAAI Conference on Artificial Intelligence. New Orleans: AAAI, 2018: 2588-2595.
- [10] Zhang J, Zheng Y, Sun J, et al. Flow prediction in spatio-temporal networks based on multitask deep learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2019, 32(3): 468-478.
- [11] Guo S, Lin Y, Li S, et al. Deep spatial-temporal 3D convolutional neural networks for traffic data forecasting[J]. IEEE Transactions on Intelligent Transportation Systems, 2019, 20(10): 3913-3926.

- [12] Scarselli F, Gori M, Tsoi A C, et al. The graph neural network model[J]. IEEE Transactions on Neural Networks, 2008, 20(1): 61-80.
- [13] Henaff M, Bruna J, and LeCun Y. Deep convolutional networks on graph-structured data[EB/OL]. (2015-06-16) [2021-05-01]. <https://arxiv.org/pdf/1506.05163.pdf>.
- [14] Bruna J, Zaremba W, Szlam A, et al. Spectral networks and locally connected networks on graphs[C]. Proceedings of International Conference on Learning Representations. Banff: ICLR, 2014: 1-14.
- [15] Defferrard M, Bresson X, and Vandergheynst P. Convolutional neural networks on graphs with fast localized spectral filtering[C]. Proceedings of 30th Conference on Neural Information Processing Systems. Barcelona: ACM, 2016: 3837-3845.
- [16] Atwood J, and Towsley D. Diffusion-Convolutional Neural Networks[C]. Proceedings of 30th Conference on Neural Information Processing Systems. Barcelona: ACM, 2016: 1993-2001.
- [17] Yu B, Yin H, and 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: ACM, 2018: 3634-3640.
- [18] 冯宁, 郭晟楠, 宋超, 等. 面向交通流量预测的多组件时空图卷积网络 [J]. 软件学报, 2019, 30(3): 759-769. (Feng Y, Guo S N, Song C, et al. Multi-component spatial-temporal graph convolution networks for traffic flow forecasting[J]. Journal of Software, 2019, 30(3): 759-769.)
- [19] Li Y, Yu R, Shahabi C, et al. Diffusion convolutional recurrent neural network: Data-driven traffic forecasting[C]. Proceedings of the International Conference on Learning Representations. Palais des Congrès Neptune: ICLR, 2017: 1-16.
- [20] 谷振宇, 陈聪, 郑家佳, 等. 基于时空图卷积循环神经网络的交通流预测 [J/OL]. 控制与决策, <https://doi.org/10.13195/j.kzyjc.2020.1445>. (Gu Z Y, Chen C, Zheng J J, et al. Traffic flow prediction based on STGCRNN[J/OL]. Control and Decision, <https://doi.org/10.13195/j.kzyjc.2020.1445>.)
- [21] Geng X, Li Y, Wang L, et al. Spatiotemporal multi-graph convolution network for ride-hailing demand forecasting[C]. Proceedings of the AAAI Conference on Artificial Intelligence. Hawaii: AAAI, 2019: 3656-3663.
- [22] 陈喜群, 周凌霄, 曹震. 基于图卷积网络的路网短时交通流预测研究 [J]. 交通运输系统工程与信息, 2020, 20(4): 49-55. (Chen X Q, Zhou L X, Cao Z. Short-term network-wide traffic prediction based on graph convolutional network[J]. Journal of Transportation Systems Engineering and Information Technology, 2020, 20(4): 49-55.)
- [23] Wang Y, Yin H, Chen H, et al. Origin-destination matrix prediction via graph convolution: A new perspective of passenger demand modeling[C]. Proceedings of ACM SIGKDD Conference on Knowledge Discovery and Data Mining. New York: ACM, 2019: 1227-1235.
- [24] Bai S, Kolter J Z, and Koltun V. An empirical evaluation of generic convolutional and recurrent networks for sequence modelling[EB/OL]. (2018-03-04) [2021-05-01]. <https://arxiv.org/pdf/1803.01271.pdf>.
- [25] Salvador S, Chan P. Toward accurate dynamic time warping in linear time and space[J]. Intelligent Data Analysis, 2007, 11(5): 561-580.
- [26] Wang Y, Zhang D, Liu Y, et al. Enhancing transportation systems via deep learning: A survey[J]. Transportation Research Part C: Emerging Technologies, 2019, 99:144-163.

### 作者简介

陈柘(1969—), 男, 副教授, 博士, 从事数据挖掘、智能交通等研究, E-mail: zchen@chd.edu.cn.

刘嘉华(1998—), 男, 硕士生, 从事交通运输工程、智能交通等研究, E-mail: 1351912346@qq.com.

赵斌(1996—), 男, 硕士生, 从事数据挖掘、智能交通等研究, E-mail: 2806391312@qq.com.

袁绍欣(1972—), 男, 副教授, 博士, 从事交通数据建模分析、软件工程等研究, E-mail: shxyuan@chd.edu.cn.

康军(1975—), 男, 副教授, 博士, 从事时空轨迹数据挖掘、城市计算等研究, E-mail: junkang@chd.edu.cn.