

# 面向出租车空载时间预测的多任务时空图卷积网络



宋龙泽 万怀宇 郭晟楠 林友芳

北京交通大学计算机科学与技术学院 北京 100044

交通数据分析与挖掘北京重点实验室 北京 100044

(songlongze@bjtu.edu.cn)

**摘要** 出租车空载时间严重影响交通资源的利用效率和司机的收益。准确的出租车空载时间预测可以有效地指导司机进行合理的路径规划,辅助打车平台进行高效的资源调度。然而,在实际场景中,城市不同区域的空载时间受到区域车流量、客流量以及历史空载时长等多方面因素的影响。为解决该问题,提出一种基于多任务框架的时空图卷积网络(MSTGCN)模型。MSTGCN采用一种新颖的时空图卷积结构,全面建模上述影响空载时间的各种时、空相关性因素。使用多任务学习框架从不同视角学习数据的特征表示,并提出一种多任务注意力融合机制,通过对辅助任务信息的筛选来提升主任务的信息获取能力和预测性能。将所提模型在两个公开的滴滴数据集上进行了充分的实验,其取得了优于其他方法的预测效果。

**关键词:** 时空数据预测;出租车空载时长;图卷积网络;多任务学习;注意力机制

**中图分类号** TP183

## Multi-task Spatial-Temporal Graph Convolutional Network for Taxi Idle Time Prediction

SONG Long-ze, WAN Huai-yu, GUO Sheng-nan and LIN You-fang

School of Computer and Information Technology, Beijing Jiaotong University, Beijing 100044, China

Beijing Key Lab of Traffic Data Analysis and Mining, Beijing 100044, China

**Abstract** The taxi idle time seriously affects the utilization efficiency of transportation resources and the driver's income. Accurate taxi idle time prediction can effectively guide drivers to make reasonable path planning, and assist taxi platforms for efficient resource scheduling. However, in actual scenarios, the idle time in different areas of the city is affected by various factors such as regional traffic, passenger flow, and historical idle time. A spatial-temporal graph convolution network (MSTGCN) model based on multi-task framework is proposed to solve this problem. MSTGCN adopts a novel convolutional structure of spatial-temporal graph to comprehensively model the various spatial and temporal correlation factors that affect the idle time. A multi-task attention fusion mechanism is also proposed to improve the information acquisition ability and prediction performance of each task. Extensive experiments are carried out on two public data sets provided by Didi Chuxing GAIA Initiative, and the prediction results of the proposed model are better than that of other methods.

**Keywords** Spatial-temporal data prediction, Taxi idle time, Graph convolutional network, Multi-task learning, Attention mechanism

## 1 引言

随着城市规模的不断扩大,城市中的出租车数量越来越多,其为人们提供生活便利的同时,也给出租车行业的经营、管理带来了很大的挑战。对于出租车司机而言,合理规划路线、尽量降低出租车的空载率是提高其收益的关键因素;对于出租车公司或打车平台而言,优化调度公司的所有车辆资源、提高整体载客率是体现企业竞争力的核心环节。然而,当前关于出租车空载时间的研究还很少。准确的出租车空载时间预测对于指导出租车司机规划路线、辅助相关企业优化资源

调度有着重要意义。对于一个特定的城市区域,出租车空载时间预测本质上是一个时间序列预测任务:基于该区域历史空载时间数据,预测其未来空载时间。传统的时间序列预测方法,如整合移动平均自回归模型(Autoregressive Integrated Moving Average model, ARIMA)等,已广泛应用于交通预测问题<sup>[1]</sup>。但是此类方法分别研究了各区域的时间序列并假设时间序列中存在线性相关性,同时忽略了区域间的空间影响。而在实际场景中,一个区域的空载时间序列往往存在复杂的非线性相关性且受到其他区域交通状况的影响<sup>[2]</sup>。

近年来,深度学习在很多任务中取得了巨大的成功<sup>[3]</sup>,由

收稿日期:2020-10-17 返修日期:2020-12-10 本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。

基金项目:教育部-中国移动科研基金(MCM20180202)

This work was supported by the Science Foundation of China Mobile-Ministry of Education(MCM20180202).

通信作者:万怀宇(hywan@bjtu.edu.cn)

此激发了大量基于深度学习的时空交通预测研究<sup>[4]</sup>。例如,使用卷积神经网络(Convolutional Neural Network, CNN)来捕获非线性的空间依赖性<sup>[4]</sup>,或使用循环神经网络(Recurrent Neural Network, RNN)来捕获非线性的时间依赖性<sup>[5]</sup>。Shi等<sup>[6]</sup>进一步提出一种整合了CNN和RNN、分别对空间和时间维度进行建模的方法。

尽管上述方法都对时空数据中存在的空间和时间依赖性进行了建模,但在空间维度上,传统的CNN只能捕获网格结构数据上各位置的局部空间相关性,而无法考虑更大空间范围的信息。近年来,适用于图结构数据特征提取与学习的图卷积网络(Graph Convolutional Network, GCN)逐渐兴起,人们通过设计基于图结构的时空数据表示方法,来表达网格结构无法描述的信息,并利用GCN进行特征学习。在时间维度的依赖性建模方面,RNN同样存在难以捕获长距离依赖的问题。近年来,有学者使用注意力机制(Attention Mechanism)来捕获不同尺度的时间依赖<sup>[7]</sup>。虽然图卷积网络和注意力机制能在一定程度上解决CNN和RNN存在的问题,但上述工作都是分别对时间和空间特征进行建模,忽略了时间和空间之间的依赖性。事实上,一个区域的交通状态可能与该区域的历史状态相关,也可能与其他区域的历史或当前状态相关。

Li等<sup>[8]</sup>使用多任务学习(Multi-Task Learning)框架来进行时空数据预测,从不同的角度捕获数据特征,并取得了良好的效果。但当前的多任务框架在进行任务融合时大多采用相加或者拼接的方式,不能体现出不同任务之间的差异性,使得各任务无法更好地捕获其需要的有价值的信息。

为了应对上述挑战,本文提出一种新颖的多任务时空图卷积网络(Multi-task Spatial-Temporal Graph Convolutional Network, MSTGCN)模型。MSTGCN针对出租车空载时间预测目标,同时建模多种交通因素(历史空载时间、区域车流量、区域客流量信息)对区域未来空载时长的影响。本文提出一种新颖的时空图卷积结构来同时捕获数据在时间、空间以及时空之间的依赖性;然后采用多任务框架来获取不同角度的数据表示,并提出基于注意力机制的多任务融合方法,使各任务有选择地获得更有价值的信息以提升预测效果;最后使用长短期记忆(Long Short Term Memory, LSTM)来进一步提取交通数据的时间维度依赖性。

本文的主要贡献如下:

(1)首次提出了出租车空载时间预测问题,对出租车司机及打车平台均有着重要意义。并且提出了MSTGCN模型,其在两个公开数据集上均取得了优于其他方法的效果。

(2)提出了一种新的时空图卷积结构,用于建模区域车流量、区域客流量和空载时间3种交通数据之间的时间依赖、空间依赖以及时空依赖。

(3)使用多任务学习框架同时预测空载时间与空载时间等级,设计了有效的多任务融合机制,使各任务能更好地获取有价值的信息,进一步提升预测性能。

## 2 相关工作

时空数据预测是时空数据挖掘领域一个重要的研究方

向。传统的时间序列预测方法如ARIMA等只考虑了时空数据在时间维度上的信息。随着深度学习的发展,许多研究工作开始尝试采用深度学习来进行时空数据的预测。ConvLSTM<sup>[6]</sup>结合CNN和RNN分别对时、空维度进行建模;ST-ResNet<sup>[4]</sup>是基于CNN的深度残差网络,显示了CNN与残差网络在时空预测方面的强大能力;ST-3DNet<sup>[9]</sup>使用3D卷积进行时空数据预测,同时从空间和时间两个维度提取特征,并使用多组件进行建模;STDN<sup>[10]</sup>使用局部CNN来捕获空间依赖,使用LSTM和注意力机制来捕获长期依赖性。以上都是针对时空网格数据的相关工作,难以处理非欧氏时空数据及其依赖关系。

随着图神经网络的发展,许多工作尝试将图卷积引入时空数据预测问题,以更好地捕获空间信息。DCRNN<sup>[11]</sup>使用扩散图卷积来描述信息在空间的扩散过程;STGCN<sup>[12]</sup>在使用图卷积的同时加入了CNN来捕获时间依赖性;AST-GCN<sup>[13]</sup>使用两种注意力层来捕获时间与空间的动态相关性;STSGCN<sup>[14]</sup>提出时间同步图卷积网络来捕获复杂时空相关性与异质性。

为了从不同的角度捕获数据特征以提升预测效果,许多工作将多任务学习引入时空预测。例如,Li等<sup>[8]</sup>使用多任务来进行到达时间的预测;Zhang等<sup>[15]</sup>使用多任务学习来预测不同区域的需求。

空载时间预测属于时空数据预测问题,需要同时考虑区域的车流量、乘客需求、历史空载时间等因素的影响,因此需要设计一种可以捕获多种数据的时间、空间以及时空相关性的模型。此外,多任务在时空预测问题上的应用也启发我们设计空载时间预测的相关辅助任务来提升预测的准确性。

## 3 符号与问题定义

本文将整个城市沿着经纬度均匀等分成 $N$ 个网格( $N = a \times b$ ),以 $\tau$ 为时间间隔将历史时间划分为 $T$ 个时间段。

**定义1(区域车流量)** 区域 $\mathbf{F}^{i,t} \in \mathbb{R}^{N \times T \times 2}$ 由车辆流入量 $\mathbf{F}_{in}^{i,t} \in \mathbb{R}^{N \times T}$ 和车辆流出量 $\mathbf{F}_{out}^{i,t} \in \mathbb{R}^{N \times T}$ 组成,两者分别表示在时间段 $t$ 进入和离开区域 $i$ 的车辆数。

**定义2(区域上下客量)** 区域上下客量 $\mathbf{P}^{i,t} \in \mathbb{R}^{N \times T \times 2}$ 由上客量 $\mathbf{P}_{on}^{i,t} \in \mathbb{R}^{N \times T}$ 和下客量 $\mathbf{P}_{off}^{i,t} \in \mathbb{R}^{N \times T}$ 组成,两者分别表示在时间段 $t$ 、在区域 $i$ 接到(以 $i$ 为出发地)的订单数和在区域 $i$ 完成(以 $i$ 目的地)的订单数,前者在一定程度上反映了该区域的乘客打车需求。

**定义3(区域空载时间)** 区域空载时间 $\mathbf{E}_{i,t} \in \mathbb{R}^{N \times T}$ 表示在时间段 $t$ 、区域 $i$ 的非载客状态的出租车接到下一个订单所需的平均时长。

**定义4(区域空载时间等级)** 区域空载时间等级 $\mathbf{L}_{i,t} \in \mathbb{R}^{N \times T}$ 表示在时间段 $t$ 、区域 $i$ 的非载客状态的出租车接到下一个订单所需的平均时长所属的等级,等级的划分如表1所列。

**定义5(空间图与时空图)** 空间图 $G_S = (V_S, E_S, \mathbf{A}_S)$ 为一个无向图,其中 $V_S$ 为节点集, $|V_S| = N$ 为节点个数,每个节点表示一个网格区域; $E_S$ 为边集,表示节点之间的连通性; $\mathbf{A}_S \in \mathbb{R}^{N \times N}$ 为图 $G$ 的邻接矩阵。时空图 $G = (V, E, \mathbf{A})$ 为一个

无向图,其中 $V$ 为节点集, $|V|=M$ 为节点个数, $M=N \times T$ ( $T$ 为时间段数量); $E$ 为边集; $A \in \mathbb{R}^{M \times M}$ 为图 $G$ 的邻接矩阵。空间图和时空图的构造详见4.1.1节和4.1.2节。

表1 空载时间等级划分

Table 1 Idle time rating

Idle time level	The range of idle time/min
1	0~10
2	10~20
3	20~30
4	30~60
5	> 60

**定义6(空载时间周期序列)** 空载时间周期序列体现了空载时间的周期性。设1天共有 $m$ 个时间段,目标为预测今天第 $T+1$ 个时间段各区域的空载时间,则相应的周期性序列 $E_{period} \in \mathbb{R}^{N \times 9}$ 由前3天在 $\{T, T+1, T+2\}$ 时间段内的区域空载时间矩阵构成,即:

$$E_{period} = (E_{T-m \times 3}, E_{T+1-m \times 3}, E_{T+2-m \times 3}, E_{T-m \times 2}, E_{T+1-m \times 2}, E_{T+2-m \times 2}, E_{T-m}, E_{T+1-m}, E_{T+2-m})$$

**主任务定义(空载时间预测)** 给定各区域历史 $T$ 个时间段的输入 $X = (x_1, x_2, \dots, x_T) \in \mathbb{R}^{N \times T \times R}$ ,以及相应的时空图 $G$ 、空载时间周期序列 $E_{period}$ ,预测 $T+1$ 时间段各区域的空载时间 $E_{T+1}$ 。其中 $R=5$ 表示输入的特征维度, $X=[E; P; F]$ 表示输入为历史区域空载时间、车流量、上下客量沿着特征维度的拼接。

**辅助任务定义(空载时间等级预测)** 给定所有区域历史 $T$ 个时间段的输入 $X$ ,时空图 $G$ 、空载时间周期序列 $E_{period}$ ,预测 $T+1$ 时间段所有区域的空载时间等级。

## 4 多任务时空图卷积网络

MSTGCN的总体架构如图1所示,包括时空图卷积模块、时间模块、多任务融合模块以及输出层。

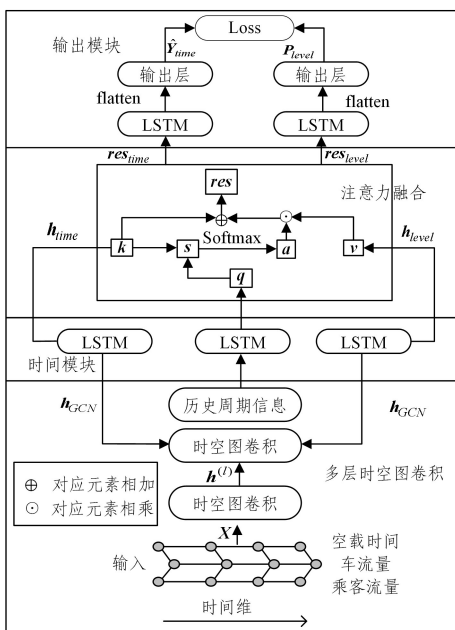


图1 MSTGCN模型框架

Fig. 1 Architecture of MSTGCN

模型的输入由历史空载时间、区域出租车流量、区域上下

客数量3类交通指标组成。时空图卷积模块采用一种新颖的时空图卷积操作来捕获基于时空图表示的交通指标中存在的时间相关性、空间相关性及时空相关性。时间模块使用LSTM来提取数据的顺序依赖性。多任务融合模块使用注意力机制为各任务提取针对其预测目标更有价值的信息。

### 4.1 时空卷积模块

#### 4.1.1 空间图的构造

网格数据仅能表达欧氏空间上距离的临近关系,而无法表达数据更丰富的空间相关性。因此学者们<sup>[13]</sup>尝试通过设计图结构来表达数据中蕴含的非欧氏相关性。在空载时间预测问题中,区域的出租车需求量是影响空载时间的关键因素,因此我们以区域出租车需求量相似程度为依据,构建图来表示区域之间的相关性,并称其为空间图。本研究中以区域中的上客数来近似区域的打车需求,并使用动态时间规整(Dynamic Time Warping, DTW)算法来计算区域 $i$ 和区域 $j$ 的需求时间序列的相似性 $u_{ij}$ 。

$$u_{ij} = DTW(i, j)$$

此时邻接矩阵 $A_S$ 由式(2)计算:

$$A_S = \begin{cases} 0, & u_{ij} > u \\ 1, & u_{ij} \leq u \end{cases} \quad (2)$$

其中, $u$ 为超参数,表示两个区域是否相关的相似性阈值。

#### 4.1.2 时空图的构造

以往的研究<sup>[13]</sup>在构建图时通常只考虑构建空间维度的图,并使用GNN和RNN分别获取时空依赖。这种分开获取时空关系的方式无法捕获跨越时间与空间维度之间的依赖关系。如图2所示,点 $A_2$ 在空间上可能与其相邻的点 $B_2$ 相关,在时间上可能与上一个时刻的点 $A_1$ 相关;在时空维度上,点 $B_1$ 也可能对点 $A_2$ 产生影响<sup>[13-14]</sup>,因此我们需要构建时空图来捕获这种时空相关性。




图2 时空依赖关系

Fig. 2 Spatial-temporal correlations

时空图 $G$ 的构成如图3所示,其在时间维度和空间维度上都有边的连接。在空间维度,每个时间步都有一个空间图 $G$ ;在时间维度,同一节点与其自身前后时间步的节点相连。本文构造的时空图结构可以直接反映数据的时间相关性、空间相关性以及时空相关性。

#### 4.1.3 时空图卷积

在完成时空图的构建后,我们使用图卷积来捕获其中的时空依赖。图卷积的输入为 $X = (x_1, x_2, \dots, x_T) \in \mathbb{R}^{M \times R}$ 与 $G$ 。用 $\Gamma(i)$ 表示节点 $i$ 的邻居集合,图卷积<sup>[16]</sup>的计算公式为:

$$h_i^{(l+1)} = \sigma \left( \sum_{j \in \Gamma(i)} \frac{1}{c_{ij}} h_j^{(l)} W^{(l)} \right) \quad (3)$$

其中, $h_i^{(l+1)} \in \mathbb{R}^{M \times d_{l+1}}$ 表示第 $l$ 层卷积的输出, $d_{l+1}$ 表示第 $l$ 层卷积的输出维度, $\sigma$ 代表激活函数, $c_{ij} = \sqrt{|\Gamma(i)|} \sqrt{|\Gamma(j)|}$ 表示节点 $i$ 和 $j$ 的度的平方根乘积, $h_j^{(l)} \in \mathbb{R}^{M \times d_l}$ 为第 $l$ 层节点 $j$ 的表示, $W^{(l)} \in \mathbb{R}^{d_l \times d_{l+1}}$ 为第 $l$ 层卷积的参数矩阵。为简

洁起见,式(3)中没有写出偏置项。

基于时空图结构,在进行一次图卷积操作时,模型可以通过该图结构获取一阶邻居信息,即时间依赖与空间依赖;进行第二次卷积操作时,模型可以获取二阶邻居的信息,即时空依赖。

## 4.2 时间模块

虽然时空图卷积模块已经对时空关系进行了捕获,但由于图卷积在捕获时间信息时会忽略节点的前后顺序,无法捕获时间序列信息。因此,本文将时空图卷积模块的输出输入到 LSTM 中(见图 1),来捕获时间节点之间的序列信息。首先我们将时空图卷积模块输出的空间维度和属性维度合并,得到  $\mathbf{h}_{GCN} \in \mathbb{R}^{T \times N_{LSTM}}$ ,其中  $N_{LSTM} = N \times d$ , $d$  为时空图卷积的输出维度。然后将其输入到 LSTM 中得到隐藏状态表示  $\mathbf{h}_{LSTM} \in \mathbb{R}^{T \times d_{LSTM}}$ :

$$\mathbf{h}_{LSTM} = LSTM(\mathbf{h}_{GCN}) \quad (4)$$




图 3 时空图

Fig. 3 Spatial-temporal graph

## 4.3 多任务模块

### 4.3.1 多任务学习

在出租车空载时间序列中经常会出现空载时间骤变的点,如图 4 中的最高点所示,增加了预测难度。虽然时空卷积模块通过结合其他区域和时间的信息在一定程度上降低了突变点的预测难度,但仍有进一步提升的空间。因此本文引入了空载时间等级预测这一辅助任务进行多任务学习来应对这一问题。通过对空载时间等级的预测,模型可以从简化任务的角度来提取特征,得到目标时间段的空载时间的大致范围,使主任务空载时间预测的结果更加精准。具体地,如图 1 所示,将时空图卷积模块的输出分别输入到空载时间预测的时间模块和空载时间等级预测的时间模块,并在两个多层 LSTM 之间使用注意力机制进行信息融合。




图 4 出租车空载时间序列示例

Fig. 4 Example of taxi idle time series

### 4.3.2 多任务融合

虽然多任务框架在时空预测中取得了一定的效果<sup>[17]</sup>,但当前的工作大多使用硬融合或直接相加的方式进行信息融合。这种方式虽然简单,但忽略了任务之间的差异性,即不同任务之间的影响以及各自的信息需求是不同的,导致融合效果欠佳。为此,我们设计了基于注意力的多任务融合模块,通

过注意力分数来决定流入各任务的信息,提取对任务有价值的信息,进而提升预测性能。

首先我们从历史数据中提取空载时间周期序列  $\mathbf{X}_{period}$ ,并使用 LSTM 进行处理,得到隐藏变量  $\mathbf{h}_{period}$ 。周期序列包含了目标时间段前 3 天同一时间段前后 3 个时间段共 9 个时间段的空载时间数据(见定义 6),体现了数据周期信息。设  $\mathbf{q} = \mathbf{h}_{period} \in \mathbb{R}^{T \times d_{LSTM}}$  为周期序列经过 LSTM 后的输出,  $\mathbf{k} = \mathbf{h}_{time} \in \mathbb{R}^{T \times d_{LSTM}}$  为空载时间预测任务的 LSTM 中间输出,  $\mathbf{v} = \mathbf{h}_{level} \in \mathbb{R}^{T \times d_{LSTM}}$  为空载时间等级预测任务的 LSTM 中间输出。注意力融合机制针对空载时间预测任务的输出的计算过程如下:

$$\mathbf{s} = \sigma((\mathbf{q} + \mathbf{k})\mathbf{W}_{att1})\mathbf{W}_{att2} \quad (5)$$

$$\mathbf{a} = \text{softmax}(\mathbf{s}) \quad (6)$$

$$\mathbf{res}_{time} = \mathbf{a} \odot \mathbf{v} + \mathbf{k} \quad (7)$$

其中,  $\mathbf{res}_{time} \in \mathbb{R}^{T \times d_{LSTM}}$  代表多任务融合针对空载时间预测任务的结果。我们首先使用  $\mathbf{q}$  和  $\mathbf{k}$  计算出注意力权重  $\mathbf{s}$ ,其中  $\mathbf{W}_{att1} \in \mathbb{R}^{d_{LSTM} \times d_{LSTM}}$  和  $\mathbf{W}_{att2} \in \mathbb{R}^{d_{LSTM} \times d_{LSTM}}$  皆为参数矩阵,  $\sigma$  为激活函数。然后使用  $\text{softmax}$  函数将注意力权重  $\mathbf{s}$  归一化得到注意力分数  $\mathbf{a}$ ,将  $\mathbf{a}$  与  $\mathbf{v}$  进行哈达玛积得到需要流入空载时间预测任务的信息,并与空载时间预测任务本身的信息相加得到最终的融合结果。

由于空载时间等级预测任务的计算方式与空载时间预测任务的计算方式相同,只需将  $\mathbf{k}$  和  $\mathbf{v}$  互换即可。计算出多任务融合信息后将其继续输入到下层 LSTM。

## 4.4 输出层

本文使用两个不同的全连接层对空载时间和空载时间等级的预测结果进行输出。具体地,对空载时间预测任务的 LSTM 输出  $\mathbf{h}_{time} \in \mathbb{R}^{T \times d_{LSTM}}$ ,将其展平并输入到全连接层中,得到  $\hat{\mathbf{Y}}_{time} \in \mathbb{R}^{N \times 1}$ :

$$\hat{\mathbf{Y}}_{time} = \mathbf{W}_t \mathbf{h}_{time} + \mathbf{b}_t \quad (8)$$

其中,  $\mathbf{W}_t \in \mathbb{R}^{N \times (T \times d_{LSTM})}$  和  $\mathbf{b}_t \in \mathbb{R}^N$  为可学习参数。

对空载时间等级预测任务的 LSTM 输出  $\mathbf{h}_{level} \in \mathbb{R}^{T \times d_{LSTM}}$ ,将其展平并输入到另一个全连接层中,使用  $\text{softmax}$  归一化,得到对应类别的概率  $\mathbf{P}_{level} \in \mathbb{R}^{N \times C}$ , $C$  表示类别数量。

$$\mathbf{P}_{level} = \text{softmax}(\mathbf{W}_l \mathbf{h}_{level} + \mathbf{b}_l) \quad (9)$$

其中,  $\mathbf{W}_l \in \mathbb{R}^{(T \times d_{LSTM}) \times (N \times C)}$ ,  $\mathbf{b}_l \in \mathbb{R}^{(N \times C)}$  为可学习参数。

## 4.5 损失函数

空载时间预测任务采用平方误差损失函数:

$$\mathcal{L}_{time} = \sum_{i=1}^N (y_{T+1}^i - \hat{y}_{T+1}^i)^2 \quad (10)$$

空载时间等级预测任务采用交叉熵损失函数:

$$\mathcal{L}_{level} = - \sum_{i=1}^N \sum_{j=0}^{C-1} y_{i,j} \log(p_j) \quad (11)$$

其中,  $\mathbf{p} = [p_0, \dots, p_{C-1}]$  是一个概率分布,每个元素  $p_i$  表示样本属于第  $i$  类的概率;  $\mathbf{y}_i = [y_{i,0}, \dots, y_{i,C-1}]$  是样本标签的 one-hot 表示,当样本属于类别  $j$  时,  $y_{i,j} = 1$ ,否则  $y_{i,j} = 0$ ;  $C$  是样本标签类别数量。

最终我们采用 Kendall 等<sup>[18]</sup>提出的多任务损失函数作为本模型的损失函数,具体计算过程如下:

$$\mathcal{L} = \frac{1}{2 \exp(s_1^2)} \mathcal{L}_{time}(\theta) + \frac{1}{2 \exp(s_2^2)} \mathcal{L}_{level}(\theta) + s_1^2 + s_2^2$$

其中,  $s_1 \in \mathbb{R}$ ,  $s_2 \in \mathbb{R}$  为可学习参数。

## 5 实验部分

### 5.1 数据集与数据处理

本文使用的数据来自滴滴出行“盖亚”数据开放计划<sup>1)</sup>中公开的 2016 年 10 月—11 月成都市与西安市 61 天的局部区域轨迹数据集。我们以  $800\text{ m} \times 800\text{ m}$  的网格大小为标准, 将成都市的数据范围划分为  $8 \times 8$  的网格, 将西安市的数据范围划分成  $13 \times 13$  的网格, 并以  $\tau = 30\text{ min}$  为时间间隔, 根据轨迹数据计算出各个时间段、各个区域的车流量、客流量以及空载时间。其中网格大小的划分以及时间间隔长短的选择标准为: 保证大部分区域和时间段都有样本的情况下使区域和时间粒度尽可能小, 其中训练集、验证集、测试集按照 7:2:1 的比例划分。

### 5.2 基准方法与评价指标

本文将 MSTGCN 模型与其他 6 种现有的时空预测方法进行对比。

XGBoost<sup>[19]</sup>: 一种强大的提升树方法, 广泛应用于各种回归任务中。

ConvLSTM<sup>[6]</sup>: LSTM 网络的变形, 是一种可以捕获时间关系和空间关系的深度学习模型。

STDN<sup>[10]</sup>: 时空动态网络, 使用 CNN 和 RNN 分别建模时间和空间依赖的深度学习模型。

ST-3DNet<sup>[9]</sup>: 深度时空 3D 卷积网络, 使用 3D 卷积、残差网络以及多组件进行时空依赖捕获的深度学习模型。

STGCN<sup>[12]</sup>: 时空图卷积网络, 使用图卷积和 2D 卷积分别捕获空间依赖性和时间依赖性。

DCRNN<sup>[11]</sup>: 扩散卷积递归神经网络, 利用扩散图卷积和编码解码器分别对空间信息和时间信息进行编码。

上述所有模型的输入数据与 MSTGCN 模型的输入相同, 但根据不同模型所需的数据格式进行了相应的调整。另外, 各类图卷积方法使用的图结构是本文构造的空间图。

本文采用均方误差 (Root Mean Square Error, RMSE) 和平均绝对误差 (Mean Absolute Error, MAE) 作为评价指标, 具体公式如下:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2} \quad (12)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_i - \hat{x}_i| \quad (13)$$

### 5.3 实验设置

我们基于 PyTorch 框架实现了 MSTGCN 模型, 堆叠了 2 层时空图卷积模块, 其中图卷积的维度为 64; 堆叠了 3 层 LSTM, 其中 LSTM 的维度为 128; 输入数据的时间步长  $T=8$ 。

### 5.4 实验结果与分析

我们以秒为单位进行预测, 并将 MSTGCN 模型与前述 6 种基准方法进行了比较, 表 2 与表 3 列出了其在成都以及西安数据集上的预测结果。作为参照, 成都市各区域、各时间段的空载时间均值为 1380 s (23 min)。

表 2 不同方法在成都数据集上的预测结果

Table 2 Performance of different methods on Chengdu dataset

Model	MAE	RMSE
XGBoost	319.94	510.81
ConvLSTM	290.30	487.81
STDN	283.19	475.47
ST-3DNet	294.11	487.01
STGCN	277.23	471.21
DCRNN	276.17	471.07
MSTGCN	272.21	466.66

表 3 不同方法在西安数据集上的预测结果

Table 3 Performance of different methods on Xian dataset

Model	MAE	RMSE
XGBoost	358.79	560.72
ConvLSTM	337.34	535.59
STDN	328.94	528.13
ST-3DNet	341.70	546.26
STGCN	326.78	527.26
DCRNN	324.17	527.50
MSTGCN	318.19	525.34

从表中可以看出, 本文模型在两种评价指标中均达到了最佳性能。传统的机器学习方法 XGBoost 由于不能捕获区域间的空间相关性, 预测效果并不理想。基于深度学习的方法获得了比传统方法更好的预测结果, 其中 ConvLSTM, STDN, ST-3DNet 是应用于时空数据网格的模型, 因此我们输入的是网格形式的数据; 而 DCRNN 与 STGCN 是应用于时空图数据的模型, 因此我们将空间图  $G_s$  作为其输入。由于使用图卷积的 DCRNN 与 STGCN 能够捕获到图结构中蕴含的更丰富的空间相关性, 因此其效果优于其他网格预测的模型, 而 ST-3DNet 由于使用 3D 卷积来捕获时空关系, 难以捕获时间信息中的远距离信息与顺序依赖关系, 因此相比其他模型效果较差。

为了进一步研究 MSTGCN 中不同模块的效果, 我们设计了原模型的 4 个变体, 并将这 4 个变体与 MSTGCN 进行比较, 各模型的描述如下。1) MSTGCN: 本文介绍的完整模型。2) MGCN: 在 MSTGCN 的基础上, 不使用时空图, 只使用需求相似性构建的空间图进行计算。3) MGCN\_G: 空间图的构建标准由需求时间序列的相似性变为空载时间序列的相似性。4) MSTGCN\_att: 在 MSTGCN 的基础上将原先的注意力融合机制变为 3 个任务时间模块输出的特征向量直接相加的方法进行多任务融合。5) SSTGCN: 在 MSTGCN 的基础上, 去除多任务架构, 只对空载时间进行单任务预测。

实验结果如表 4 与表 5 所列。其充分证明了 MSTGCN 中时空图卷积模块、多任务框架以及多任务融合模块的有效性。

表 4 MSTGCN 不同变体在成都数据集上的结果对比

Table 4 Performance comparisons of different variants of MSTGCN on Chengdu dataset

Model	MAE	RMSE
MSTGCN	272.21	466.66
MGCN	274.93	469.52
MGCN_G	274.15	470.72
MSTGCN_att	277.80	473.98
SSTGCN	277.18	475.63

<sup>1)</sup> <http://gaia.didichuxing.com>

表5 MSTGCN不同变体西安数据集上的结果对比

Table 5 Performance comparisons of different variants of MSTGCN on Xian dataset

Model	MAE	RMSE
MSTGCN	318.19	525.34
MGCN	324.76	526.44
MGCN_G	325.42	526.58
MSTGCN_att	322.03	525.94
SSTGCN	324.04	525.80


**结束语** 本文首次提出了出租车空载时间预测问题,对出租车司机及打车平台均有着重要意义,并针对此研究目标提出了一种新颖的多任务时空图卷积网络模型。该模型根据节点相似性构造时空图,使用时空图卷积来捕获时间依赖、空间依赖以及时空依赖性;同时该模型创新性地采用注意力机制进行多任务信息融合,使各任务高效获取有价值的信息,进而提升预测性能。实验证明,本文模型优于其他已有的时空预测方法,验证了该模型在空载时间预测方面的优势。事实上,除空载时间预测任务外,本模型同样适用于其他时空交通数据的预测<sup>[20]</sup>。未来,我们将进一步改进图的构造方法以及计算方式来优化模型的网络结构,进一步提升模型的预测能力。

### 参考文献

- [1] LIPPI M, BERTINI F P. Short-Term Traffic Flow Forecasting: An Experimental Comparison of Time-Series Analysis and Supervised Learning[J]. Transactions on Intelligent Transportation Systems, 2013, 14(2): 871-882.
- [2] WANG D, YANG Y, NING S. Deepstcl: A deep spatio-temporal convlstm for travel demand prediction[C]// 2018 International Joint Conference on Neural Networks (IJCNN). IEEE, 2018: 1-8.
- [3] LECUN Y, BENGIO Y, HINTON G. Deep Learning[J]. Nature, 2015, 521(7553): 436-444.
- [4] ZHANG J, ZHENG Y. Deep Spatio-Temporal Residual Networks for Citywide Crowd Flows Prediction[C]// AAAI Conference on Artificial Intelligence. 2017: 1655-1661.
- [5] YAO H X, WU F, KE J T, et al. Deep Multi-View Spatial-Temporal Network for Taxi Demand Prediction[J]. arXiv: 1802.08714, 2018.
- [6] XING S J, CHEN Z R, WANG H, et al. Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting[J]. arXiv: 1506.04214, 2015.
- [7] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is All You Need[J]. arXiv: 1706.03762, 2017.
- [8] LI Y, FU K, WANG Z, et al. Multi-Task Representation Learning for Travel Time Estimation[C]// ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. 2018: 1695-1704.
- [9] GUO S, LIN Y, LI S, et al. Deep Spatial-Temporal 3D Convolutional Neural Networks for Traffic Data Forecasting[J]. Transactions on Intelligent Transportation Systems, 2019, 20(10): 3913-3926.
- [10] YAO H X, TANG X F, WEI H, et al. Revisiting Spatial-Tem-

poral Similarity: A Deep Learning Framework for Traffic Prediction[C]// AAAI Conference on Artificial Intelligence. 2019: 5668-5675.

- [11] LI Y G, YU R, SHAHABI C, et al. Diffusion Convolutional Recurrent Neural Network: Data-Driven Traffic Forecasting[J]. arXiv: 1707.01926, 2018.
- [12] YU B, YIN H T, ZHU Z X. Spatio-Temporal Graph Convolutional Networks: A Deep Learning Framework for Traffic Forecasting[J]. arXiv: 1709.04875, 2018.
- [13] GUO S, LIN Y, FENG N, et al. Attention Based Spatial-Temporal Graph Convolutional Networks for Traffic Flow Forecasting[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2019, 33: 922-929.
- [14] SONG C, LIN Y, GUO S, et al. Spatial-Temporal Synchronous Graph Convolutional Networks: A New Framework for Spatial-Temporal Network Data Forecasting[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(1): 914-921.
- [15] ZHANG K, LIU Z, ZHENG L. Short-Term Prediction of Passenger Demand in Multi-Zone Level: Temporal Convolutional Neural Network with Multi-Task Learning[J]. IEEE Transactions on Intelligent Transportation Systems, 2019, 21(4): 1480-1490.
- [16] KIPF T N, WELING M. Semi-Supervised Classification with Graph Convolutional Networks[J]. arXiv: 1609.02907, 2017.
- [17] 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.
- [18] KENDALL A, GAL Y, CIPOLLA R. Multi-Task Learning Using Uncertainty to Weigh Losses for Scene Geometry and Semantics[J]. arXiv: 1705.07115, 2018.
- [19] CHEN T, GUESTRIN C. XGBoost: A Scalable Tree Boosting System[C]// ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. 2016: 785-794.
- [20] WANG Y K, WANG H Y, PAN P J, et al. A survey of data mining on spatial-temporal user behavior data for public safety[J]. Journal of Chongqing University of Posts and Telecommunications (Natural Science Edition), 2018, 30(1): 40-52.



**SONG Long-ze**, born in 1996, postgraduate. His main research interests include spatial-temporal data mining and so on.



**WAN Huai-yu**, born in 1981, Ph.D, associate professor, Ph.D supervisor, is a member of China Computer Federation. His main research interests include social network mining, text mining, user behavior analysis and spatial-temporal data mining.