

## 基于图对比学习的多模态交通流量协同预测方法

肖杨, 秦建阳, 李肯立, 王鸽, 李瑞, 廖清

引用本文

肖杨, 秦建阳, 李肯立, 王鸽, 李瑞, 廖清. 基于图对比学习的多模态交通流量协同预测方法[J]. 计算机科学, 2023, 50(10): 135-145.

XIAO Yang, QIN Jianyang, LI Kenli, WANG Ge, LI Rui, LIAO Qing. Co-Forecasting for Multi-modal Traffic Flow Based on Graph Contrastive Learning [J]. Computer Science, 2023, 50(10): 135-145.

---

## 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)

### 基于多模态特征融合的人脸物理对抗样本性能预测算法

Facial Physical Adversarial Example Performance Prediction Algorithm Based on Multi-modal Feature Fusion

计算机科学, 2023, 50(8): 280-285. <https://doi.org/10.11896/jsjcx.221100124>

### 说话人生成研究现状与发展趋势

Review of Talking Face Generation

计算机科学, 2023, 50(8): 68-78. <https://doi.org/10.11896/jsjcx.221000031>

### 基于注意力机制的多模态在线评论有用性预测研究

Study on Multimodal Online Reviews Helpfulness Prediction Based on Attention Mechanism

计算机科学, 2023, 50(8): 37-44. <https://doi.org/10.11896/jsjcx.220600204>

### 基于信息熵-切分概率模型的新词发现方法

New Word Detection Based on Branch Entropy-Segmentation Probability Model

计算机科学, 2023, 50(7): 221-228. <https://doi.org/10.11896/jsjcx.220700074>

### 面向交通流量预测的时空Graph-CoordAttention网络

Spatial-Temporal Graph-CoordAttention Network for Traffic Forecasting

计算机科学, 2023, 50(6A): 220200042-7. <https://doi.org/10.11896/jsjcx.220200042>

# 基于图对比学习的多模态交通流量协同预测方法

肖杨<sup>1</sup> 秦建阳<sup>1</sup> 李肯立<sup>2</sup> 王鸽<sup>3</sup> 李瑞<sup>4</sup> 廖清<sup>1,5</sup>

1 哈尔滨工业大学(深圳)计算机科学与技术学院 广东 深圳 518055

2 湖南大学信息科学与工程学院 长沙 410082

3 西安交通大学计算机学院 西安 710049

4 西安电子科技大学计算机科学与技术学院 西安 710071

5 鹏城实验室 广东 深圳 518000

(curlyxiao897@163.com)

**摘要** 准确的城市区域交通流量预测对市区车辆调度、公交系统优化等具有重要指导意义。目前,大多数现有的交通流量预测方法只考虑规则网格区域上单一类型的交通流量预测,忽略了交通网络中空间的不规则性和异质性以及不同出行模式交通流的交互性。针对上述问题,提出了一种基于图对比学习的多模态交通流量协同预测方法(CoF-MGCL),以揭示各类出行方式之间的交互对不规则异构区域的交通需求的影响。具体而言,根据现实中城市的不规则区域采集多模态流量数据,包括各类出行模式流量(如自行车和出租车流量)和总流量;并对不规则区域构建多关系异构图,包括地理邻近和功能相似关系。通过异构图编码模块,可以结合异构图中不同的关系来学习各区域各类交通流量的高质量表征信息。学习到的单一交通流量表征经过注意力机制加权融合后与总交通流量表征进行图对比学习,以捕获不同出行模式之间的交互关系。最后,使用互信息约束实现多模态流量的协同预测,确保多模态信息学习最大化。为了实现不规则区域的多模态交通流量预测,自行构建了新的纽约市曼哈顿区和芝加哥市两地多模态交通流量数据集,并在此基础上进行实验。实验结果表明,所提方法可以结合现有的单模态交通流量预测模型,在均方误差(RMSE)和平均绝对误差(MAE)两个预测指标上实现 0.43%~12.13%的性能提升,验证了所提方法的有效性。

**关键词:** 交通流量预测;多模态;异构图表示;图对比学习;互信息

**中图法分类号** TP183

## Co-Forecasting for Multi-modal Traffic Flow Based on Graph Contrastive Learning

XIAO Yang<sup>1</sup>, QIN Jianyang<sup>1</sup>, LI Kenli<sup>2</sup>, WANG Ge<sup>3</sup>, LI Rui<sup>4</sup> and LIAO Qing<sup>1,5</sup>

1 School of Computer Science and Technology, Harbin Institute of Technology(Shenzhen), Shenzhen, Guangdong 518055, China

2 College of Computer Science and Electronic Engineering, Hunan University, Changsha 410082, China

3 School of Computer Science and Technology, Xi'an Jiaotong University, Xi'an 710049, China

4 School of Computer Science and Technology, Xidian University, Xi'an 710071, China

5 Pengcheng Laboratory, Shenzhen, Guangdong 518000, China

**Abstract** An accurate traffic flow prediction in urban areas is of important significance to provide guidance for urban vehicle scheduling and public transportation system optimization. So far, most existing traffic flow prediction methods only consider a single type of traffic flow prediction in a regular grid area, ignoring the spatial irregularity and heterogeneity in the traffic network and the interactivity among different kinds of traffic flow. To address these problems, this paper proposes a co-forecasting method for multi-modal traffic flow based on graph contrastive learning, named CoF-MGCL, so as to reveal the effect of the interaction among various traffic flows on the traffic demand in irregular and heterogeneous areas. Specifically, this paper collects multi-model traffic data, including the individual and total traffic flow of various travel types(e.g., the traffic flow of bike and taxi); then, constructs a heterogeneous graph with multiple relations, including geographical proximity and functional similarity relations, for irregular areas. By using a heterogeneous graph coding module, this paper can fuse multiple relations in a heterogeneous graph to learn high-quality representations for various traffic flows in different areas. The learned representations of each individual traffic flow are integrated via an attention mechanism, which is compared with the representation of total traffic flow via a graph contrastive learning, so as to capture the interactive correlation among different traffic flows. Finally, this paper introduces a mutual

到稿日期:2023-07-18 返修日期:2023-09-18

基金项目:国家重点研发计划(2020YFB2104003)

This work was supported by the National Key Research and Development Program of China(2020YFB2104003).

通信作者:廖清(liaoqing@hit.edu.cn)

information regularization for multi-modal traffic flow co-forecasting, maximizing multi-modal information learning. To achieve multi-modal traffic flow forecasting in irregular areas, two new multi-modal traffic flow datasets for the Manhattan Borough of New York and Chicago have been constructed and used for experiments. Experimental results demonstrate that the proposed method can be combined with existing uni-modal traffic flow forecasting methods to obtain 0.60%~12.13% performance gains in terms of root-mean-square error(RMSE) and mean-absolute error(MAE), verifying the effectiveness of the proposed method.

**Keywords** Traffic flow forecasting, Multi-modal, Heterogeneous graph representation, Graph contrastive learning, Mutual information

## 1 引言

交通系统作为现代城市最重要的基础设施之一,支持着数百万城市居民的日常通勤和出行。近年来,随着城市现代化进程的推进和人口增长,城市交通系统面临着严峻的挑战。城市中不同区域的交通流量反映了城市居民的出行需求,精准高效地预测不同城市区域的交通流量,是实现城市公交系统优化、车辆精准调度的基础,对推动智慧城市的发展至关重要。

城市交通流量预测是根据城市区域若干历史交通流量数据,预测未来一段时间内的交通流量。随着时空数据分析技术的不断发展和城市交通出行数据库的不断完善,城市区域交通流量预测已经具有多种基于深度学习的可行方案,表现出良好的预测性能。例如,2016年,Fu等<sup>[1]</sup>首次探索了长短期记忆网络(LSTM)和门控递归单元(GRU)在交通流量预测中的应用。Zhang等<sup>[2]</sup>提出了一种深度时空残差网络(ST-ResNet),结合卷积神经网络和残差单元来捕获交通流数据的空间相关性,用于对城市区域人群流量的预测。面对智慧交通精细化管理的要求,Liang等<sup>[3]</sup>提出了一种时空关系模型(STRN),通过全局关系建模以及轻量级元学习实现了细粒度的城市流量预测。

然而,现有的城市区域交通流量预测方法仍存在以下几个方面的问题:

1)多种交通模式的出行需求在空间和时间上的交互关系由于难以建模而被忽略。在现实生活中,各种出行方式的需求变化既具有相关性又具有差异性。如图1所示,每日上班和下班出行的高峰期间(如7:00am-9:00am和5:00pm-7:00pm),共享单车和出租车的流量同时大幅增加;而夜晚时间段(如11:00pm-3:00am),出于紧急需求(如前往医院就医)或远距离出行的安全性(如从电影院回家)等因素,人们通常选择出租车方式出行。




图1 现实世界多模式出行

Fig.1 Real-world multi-modal travel

2)城市区域流量预测缺乏对多种相关区域关系的复杂依赖性挖掘。由于区域交通流量的跨区流动势必会导致周围区域交通流量流入流出的变动,因此邻近区域流量具有变化相关性。目前,许多模型也考虑到这点,从距离单一关系中提取空间特征。但是,区域流量变化还存在多样关系下的时空依赖性,仅建模距离关系无法揭示区域间的其他语义信息。

3)城市按照规则区域划分成网格进行流量预测是不准确的。在实际城市交通环境中,通过城市路网和行政边界得到的区域通常是不规则的,但是目前大多数城市交通数据集(见图2)都是以栅栏结构采集统计的。



图2 北京市规则分区

Fig.2 Rules zoning in Beijing

为了解决上述问题,本文提出了一种新的基于图对比学习的多模态交通流量协同预测方法 CoF-MGCL(Co-Forecasting for Multi-modal Traffic Flow Based on Graph Contrastive Learning),该方法将图对比学习引入交通流量预测领域,以若干出行方式在不规则划分区域上的历史数据作为输入,通过学习这些出行模式的交互信息,实现城市中多种出行方式交通流量的协同预测。本文的主要贡献包括以下3个方面:

1)提出了一种基于图对比学习的多模态交通流量协同预测方法,利用图对比学习有效地建模不同出行模式交通流量的交互关系,实现多种出行模式交通流量的同时预测。

2)构建了具有地理和功能相关性的异构图,对异构图进行编码,从而捕获不同区域间的多种空间语义关系。

3)使用纽约市和芝加哥市两地的交通和地图数据,构建了新的基于不规则区域的多模态交通流量数据集,并在数据集上进行实验,验证了本文方法的有效性。

## 2 相关工作

交通流量预测作为智能交通系统中的一个重要组成

部分,在过去的十几年里引起了广泛的关注。

在初期阶段,对交通量的预测主要是通过一些基于统计学的方法。其中,比较具有代表性的有历史平均分析(Historical Average, HA)和卡尔曼滤波分析(Kalman Filter, KF)<sup>[4]</sup>等。在这些方法中,研究者将交通数据当作线性时间序列,尽管有数学理论依据的支持,但由于现实世界中交通数据变化复杂,交通流的相关性往往都是非线性的,导致其表现效果不佳。

机器学习的出现为交通流量预测提供了新的契机。Support Vector Regression (SVR)<sup>[5]</sup>, K-Nearest Neighbors (KNN)<sup>[6]</sup>等机器学习方法被用于交通流的预测。当给出高质量的交通流量数据特征时,这些方法可以建模更复杂的非线性依赖关系,提供比线性模型更好的预测效果,但通常都需要比较复杂的特征工程进行预处理。

后来,深度学习进入交通流量预测领域,在预测准确性方面有了相当大的提高。在时间特征提取方面,Zhang等<sup>[1]</sup>研究了LSTM和GRU模型在短期交通流量预测中的应用,Zhao等<sup>[7]</sup>提出了一种基于时间卷积网络(Temporal Convolution Network, TCN)的框架,用于城市交通流量的短期预测。在空间特征提取方面,受到计算机视觉领域的启发,研究者将预测的区域划分为规则的二维或三维的网格单元并使用卷积神经网络(CNN)来预测交通流量。例如,Zhang等<sup>[8]</sup>提出组合卷积长短时记忆网络(Convolutional Long-Short Term Memory, ConvLSTM)和3维卷积神经网络(3D Convolutional Neural Network, 3D-CNN),将交通流量数据的长期趋势和短期变化同时建模。Yao等<sup>[9]</sup>提出了一种时空动态网络(Spatial-Temporal Dynamic Network, STDN),使用基于卷积神经网络(CNN)的门控机制来处理空间的动态相似性。然而,基于CNN的方法只能处理规则的欧几里得区域,而在实际交通网络中,区域往往由复杂的拓扑结构构成。为了对交通系统中的拓扑结构进行建模,近年来,部分研究者直接使用图卷积网络(GCN)来进行预测。Wu等<sup>[10]</sup>将序列生成模型(Wave Network, WaveNet)融合到GCN中形成图序列模型(Graph Wave Network, GraphWaveNet)用于时空关系建模,自适应地捕获数据的隐含关系。Yu等<sup>[11]</sup>提出时空图卷积网络(Spatial-Temporal Graph Convolutional Network, STGCN)来进行交通流量预测。同时考虑到交通系统的路段和区域两级特征,Guo等<sup>[12]</sup>设计了一种层次图卷积模型(Hierarchical Graph Convolutional Network, HGCN),集成多层GCN用于城市交通流的预测。

综上,交通流预测已经取得了许多不错的成果。但目前大多城市交通流研究都是针对单种出行方式流量或是总车流量在规则区域下的预测,未能发掘不同出行方式之间的相互关联性。

## 3 方法介绍

### 3.1 基础概念

**定义 1(不规则区域、时间间隔)** 预测地区按照shp文件分区信息划分为  $N$  个不规则区域,区域定义为  $\mathcal{R} = \{r_1, r_2, \dots, r_N\}$ 。时间间隔定义为交通流量统计的起止时间的间距,本文

使用 30 min 和 1 h 两种时间间隔。根据时间间隔,交通流量数据可划分成  $T$  个时间段,集合为  $S = \{s_1, s_2, \dots, s_T\}$ 。

**定义 2(轨迹记录)** 符号  $Tr$  用来表示一条轨迹记录。 $Tr_C = \{r_C^O, t_C^O, r_C^D, t_C^D\}$  表示出租车订单轨迹记录, $r_C^O$  和  $r_C^D$  代表出租车上下车点所处的不规则分区区域, $t_C^O$  和  $t_C^D$  是乘客上下出租车时刻。 $Tr_B = \{l_B^O, t_B^O, l_B^D, t_B^D\}$  表示共享单车订单轨迹记录。 $l_B^O$  和  $l_B^D$  代表共享单车开关位置的坐标经纬度, $t_B^O$  和  $t_B^D$  是共享单车开关锁时刻。

**定义 3(多关系异构图)** 多关系异构图是一个无向加权图  $\mathcal{G} = (V, \mathcal{E}, R)$ ,  $\mathcal{E}$  包含了区域在多个关系下的相互关联边, $R = \{r_{\text{地理位置}}, r_{\text{功能场景}}\}$  为多种异构关系类型。特殊地,两个区域之间不存在关系或存在一种以上关系。

**定义 4(多模态交通流量)** 一种交通模式流量指给定时间间隔内流入和流出区域的车辆数量。第  $t$  个时间间隔编号为  $i$  的区域的共享单车和出租车交通流量的流入  $x_i^{\text{in},r_i}$  和流出  $x_i^{\text{out},r_i}$  定义如下:

$$x_i^{\text{B},\text{in},r_i} = |\{Tr_B : t_B^D \in s_i \wedge l_B^D \in r_i\}| \quad (1)$$

$$x_i^{\text{B},\text{out},r_i} = |\{Tr_B : l_B^O \in s_i \wedge l_B^O \in r_i\}|$$

$$x_i^{\text{C},\text{in},r_i} = |\{Tr_C : t_C^D \in s_i \wedge r_C^D = r_i\}| \quad (2)$$

$$x_i^{\text{C},\text{out},r_i} = |\{Tr_C : l_C^O \in s_i \wedge r_C^O = r_i\}|$$

多模态交通流量定义为各类出行方式的交通流量和总流量的集合,这里具体包含自行车流量、出租车流量以及总流量。其中,总流量的流入和流出是各类交通模式流量(如自行车流量、出租车流量)的和,即:

$$x_i^{\text{A},\text{in},r_i} = x_i^{\text{B},\text{in},r_i} + x_i^{\text{C},\text{in},r_i} \quad (3)$$

$$x_i^{\text{A},\text{out},r_i} = x_i^{\text{B},\text{out},r_i} + x_i^{\text{C},\text{out},r_i}$$

### 3.2 问题定义

第  $t$  个时间间隔的多模态流量包括  $N$  个区域的共享单车流量  $\mathbf{X}_t^B = \{x_t^{B,r_1}, \dots, x_t^{B,r_n}\}$ 、出租车流量  $\mathbf{X}_t^C = \{x_t^{C,r_1}, \dots, x_t^{C,r_n}\}$  和总流量  $\mathbf{X}_t^A = \{x_t^{A,r_1}, \dots, x_t^{A,r_n}\}$ 。给定一组长度为  $T$  且截止时间间隔为  $t$  的历史多模态流量值,多模态交通流量预测问题就被描述为根据所有区域  $T$  个时间步长的多模态历史交通流量数据来预测下一个时间步  $t+1$  的多模态流量,即预测问题表示为:

$$\begin{bmatrix} \mathbf{X}_{t-T+1}^B, \dots, \mathbf{X}_t^B \\ \mathbf{X}_{t-T+1}^C, \dots, \mathbf{X}_t^C \\ \mathbf{X}_{t-T+1}^A, \dots, \mathbf{X}_t^A \end{bmatrix} \xrightarrow{\mathcal{F}(\cdot)} [\mathbf{X}_{t+1}^B, \mathbf{X}_{t+1}^C, \mathbf{X}_{t+1}^A] \quad (4)$$

### 3.3 预测方法 CoF-MGCL

本文提出的基于图对比学习的多模态交通流量协同预测方法框架如图 3 所示,主要由 3 个组件构成,分别是异构图构建模块、异构图编码模块和图对比判别模块。基于不同方面的语义信息衡量流量变化关系以构建多关系异构图,包含地理位置、功能场景等不同关系属性。采用异构图编码分别得到聚合丰富语义信息不同模态交通流量特征编码和全局总流量特征编码。同时,使用一种多模态交互约束以促进判别性信息的获取。将得到的各种不同交通模式流量的编码特征通过注意力融合得到融合特征图,把融合特征图与总流量特征图作为互相对比的两个子视角进行对比学习,学习得到更具代表性的特征表示,用于后续流量预测。

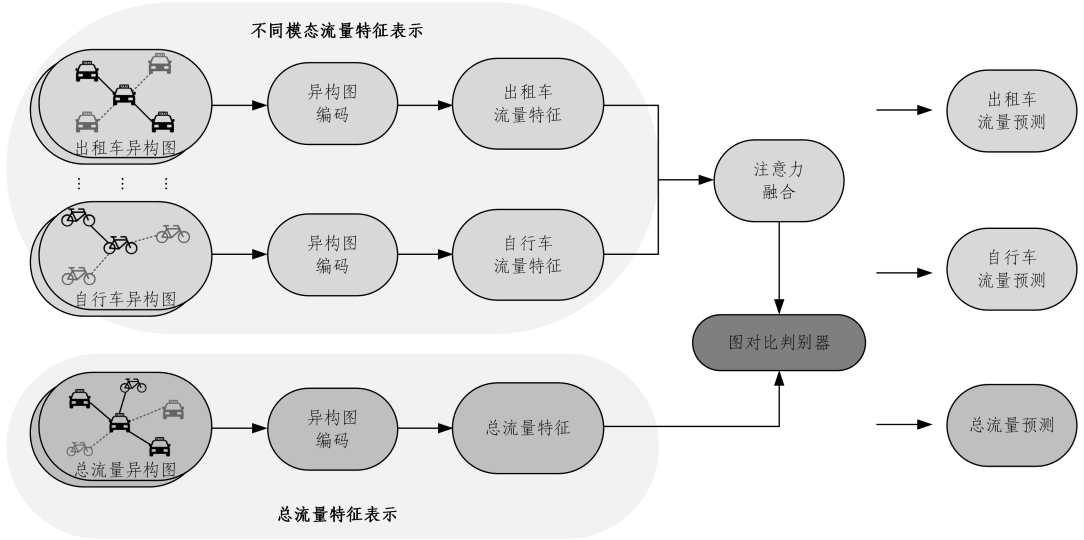


图3 基于图对比学习的多模态交通流量协同预测方法框架

Fig. 3 Framework of CoF-MGCL

### 3.3.1 异构关系构建

目前许多城市时空交通流量预测模型对空间上的建模都是基于距离临近性的,但是仅使用单一位置关系难以全面表征区域流量特征。为了解决这一问题,在本模块中提出对交通流量构建如图4所示的多关系异构图,从而充分地描述多模态交通流量的空间关系特征。




图4 不同交通模式多关系异构图

Fig. 4 Multi-relationship heterogeneous graph of different traffic modes

在表示不同关系连接时,考虑到人群的流动势必会在多种出行方式的相邻区域以及站点之间进行,因此先将地理位置关系进行表示。同时,若两个区域的距离较远但它们之间的功能环境类似,比如有类似的商场、娱乐设施等,其流量的变化情况也会存在相似性。因此,也将功能场景关系属性纳入异构图关系构建过程中。

对于地理相关性邻域,通常距离越近的两个区域之间流量的变化越相关,而距离较远的两地之间的流量变化会存在较大差异性。设计了如下关系计算式:

$$\mathcal{E}_{ij,dis} = \begin{cases} \exp(-dis_{ij}), & dis_{ij} < \gamma \\ 0, & dis_{ij} \geq \gamma \end{cases} \quad (5)$$

其中,  $dis_{ij}$  表示区域间的质心距离;  $\gamma$  为地理位置是否相关的阈值,用于控制地理位置邻接关系的稀疏程度。

对于功能相关邻域,将区域功能场景表示为向量形式,每一维都代表了该地区该类功能兴趣点的数量。易知功能场景表达越相似的两个区域之间流量的变化越相关,而功能场景不一样的两地之间的流量会存在较大差异。设计的关系计算

式如下:

$$\mathcal{E}_{ij,poi} = \begin{cases} \cos(\mathbf{F}_i, \mathbf{F}_j), & \cos(\mathbf{F}_i, \mathbf{F}_j) \geq \theta \\ 0, & \cos(\mathbf{F}_i, \mathbf{F}_j) < \theta \end{cases} \quad (6)$$

其中,  $\mathbf{F}_i$  为第  $i$  个区域功能场景的向量表示;  $\theta$  为功能性是否相关的阈值,用于控制功能相似度邻接矩阵的稀疏程度;  $\cos(\cdot, \cdot)$  是余弦相似度函数。

### 3.3.2 异构图编码器

异构图的优点在于可以整合多方面的关系信息,但是目前异构图表示学习中也存在难以有效地对齐利用各类异质信息以及合理地聚合丰富语义的问题。为了更加全面地获取异构图所包含的空间表示关系,在本模块中,将前一部分获取到的不同模式的异构图显式地进行建模编码,并将其映射为聚合了异构图信息的目标区域流量编码信息。

图5给出了异构图编码的细节,对于各模式的交通流量输入构建的多关系异构图,根据异构图中的若干不同关系属性提取各类关系下的流量异构子图,这里主要包括地理位置异构子关系图和功能属性异构子关系图。然后,分别设计这些异构子关系图的图卷积网络聚合目标区域的邻域流量特征信息,再将多关系下的编码信息进行求和,融合为最终的输出编码。




图5 异构图编码过程

Fig. 5 Process of heterogeneous graph encoding

对于各种交通模式流量的历史输入  $\mathbf{X}_t^{\text{mode}} = \{\mathbf{X}_{t-T+1}^{\text{mode}}, \dots, \mathbf{X}_t^{\text{mode}}\}$ , 异构图编码过程输出可表示为:

$$\mathbf{Z}_t^{\text{mode}} = \delta \left( \sum_r f(\mathbf{A}_r) \mathbf{X}_t^{\text{mode}} \mathbf{M}_r \right) \quad (7)$$

其中,  $r_t$  代表不同异构关系类型,  $\mathbf{A}_r \in \mathbb{R}^{N \times N}$  是不同异构关系下提取的邻接矩阵,  $f(\cdot)$  代表从不同邻接关系中构建图的滤波器,  $\mathbf{M}_r \in \mathbb{R}^{F_{in} \times F_{out}}$  是可经训练的特征转换矩阵,  $F_{in}$  是输入特征维度,  $F_{out}$  是输出特征维度。激活函数  $\delta$  采用 Relu,

$\mathbf{Z}^{\text{mode}}$  则是各模态流量异构编码的输出。

### 3.3.3 图对比判别器

由于全局总流量是不同出行方式局部流量累加和的结果,因此不同出行方式的局部流量特征与全局流量特征互相之间一定具有相关性。为了表达这种相关性,这里提出图对比学习目标,即一个判别器,将各出行方式的流量特征编码进行融合并与总流量特征编码进行对比学习。

总流量的异构编码输出作为一个视图,为了得到图对比的第二个子图,将各出行方式的流量特征编码进行融合。作为总流量对比视角,为了获取到更加关键的融合图特征信息,如图6所示,不再仅将各交通模式的流量特征编码进行简单相加,而是通过注意力特征融合机制将若干不同出行方式局部流量异构图的流量特征融合成全局融合流量特征,形成一种高效的异构融合流量图,融合式表达为:

$$\mathbf{Z}^{\text{fusion}} = \text{Attention}(\mathbf{Z}_T^B, \mathbf{Z}_T^C) \quad (8)$$

其中,  $\mathbf{Z}_T^B$  和  $\mathbf{Z}_T^C$  是共享单车和出租车两种出行方式的异构图特征编码,  $\mathbf{Z}^{\text{fusion}}$  是融合特征编码输出。




图6 各交通模式编码特征融合

Fig. 6 Fusion of coding features of each traffic mode

然后,将该融合的全局流量特征与真实的全局总流量编码特征输入图对比判别器。从多模态交通流量的统计过程可以看到,各出行方式的流量异构图是总流量图的子图,因此总流量特征可以看作是粗粒度的特征,各出行方式局部流量是细粒度的特征。这里采用图对比学习设计判别器将同一区域在各出行方式特征编码形成的全局融合流量图与总流量特征图这两个不同视图中的表示与其他区域的编码做对比区分,利用各出行方式的细粒度特征表达来帮助总流量的粗粒度特征的表达,反之亦然。将学习到各模态以及总流量更具代表性的特征表达用于后续预测任务,从而提升总流量预测和各出行方式预测的准确性。

在设计判别器的过程中,通过计算目标区域流量特征正例与负例间的比值以保证各模态出行方式局部流量特征与全局流量特征相互间的相关性,正例对为两个对比图相对应的区域,负例包括本视图内的其他区域和对比视图中的其他区域,对比学习流程如图7所示。判别器对比损失函数的详细设计如下:

$$l(\mathbf{z}_i, \mathbf{z}_i') = \frac{e^{\text{sim}(\mathbf{z}_i, \mathbf{z}_i')/\tau}}{e^{\text{sim}(\mathbf{z}_i, \mathbf{z}_i')/\tau} + \sum_{j=1}^N \mathbf{1}_{[j \neq i]} e^{\text{sim}(\mathbf{z}_i, \mathbf{z}_j)/\tau} + \sum_{k=1}^N \mathbf{1}_{[k \neq i]} e^{\text{sim}(\mathbf{z}_i, \mathbf{z}_k')/\tau}} \quad (9)$$

式(9)定义了一对正样本对区域  $(\mathbf{z}_i, \mathbf{z}_i')$  之间的对比损失,  $\text{sim}(\cdot, \cdot)$  代表相似函数,  $\mathbf{1} \in \{0, 1\}$  是指示函数,不相等时系数取1。因此,对全局流量特征编码图和各模态的总融合流量特征编码图的图对比学习阶段的对比目标为最大化

所有正区域对上的平均值,总对比损失函数为:

$$\mathcal{L}_{\text{con}} = \frac{1}{2N} \sum_{i=1}^N (l(\mathbf{z}_i, \mathbf{z}_i') + l(\mathbf{z}_i', \mathbf{z}_i)) \quad (10)$$

其中,  $\mathbf{z}_i$  表示第  $i$  个区域的总流量特征编码,  $\mathbf{z}_i'$  表示第  $i$  个区域各交通模式流量的融合特征,  $N$  是不规则分区总个数。




图7 对比判别过程

Fig. 7 Process of comparative discrimination

### 3.3.4 损失函数

在对多种交通模式异构图编码的过程中,不同模式间通常会学习到类似信息,但是这种多余的表征信息往往不必要。因此,这里引入互信息最小化损失来减少各出行交通流量的编码特征冗余度,使得各模态获得关键且互异的流量特征表示。对于出租车和共享单车两种出行方式,基于异构图编码特征表达互信息最小化损失定义为:

$$\mathcal{L}_{\text{mi}} = H(\mathbf{Z}_T^B) + H(\mathbf{Z}_T^C) - H(\mathbf{Z}_T^B, \mathbf{Z}_T^C) \quad (11)$$

其中,  $H(\cdot)$  代表边缘熵,  $H(\cdot, \cdot)$  是联合熵,  $\mathbf{Z}_T^B$  和  $\mathbf{Z}_T^C$  是出租车和共享单车对应的流量异构编码特征输出。度量两种流量特征之间的互信息等价于计算两种流量特征各自的数据分布(即均值以及标准差)之间的相似性。具体地,对于不同出行方式交通模态对应的交通流量异构编码(如出租车、自行车的异构图流量特征输出),分别计算它们的均值以及方差作为互信息。

流量预测阶段的损失函数用于衡量模型的预测能力,这里交通流量预测的目标是通过训练模型使预测流量和真实流量之间的均方误差(Mean-Square Error, MSE)最小,表达式如下:

$$\mathcal{L}(\mathbf{Y}, \hat{\mathbf{Y}}) = \frac{1}{Q} \sum_{i=1}^Q (y_i - \hat{y}_i)^2 \quad (12)$$

其中,  $y_i$  代表流量真实值,  $\hat{y}_i$  代表流量预测值,  $Q$  是预测总数。对于多模态的交通流量共同预测,总的回归预测损失为:

$$\mathcal{L}_{\text{reg}} = \sum_{\text{mode } i \in M} \mathcal{L}(\mathbf{Y}_{\text{mode } i}, \hat{\mathbf{Y}}_{\text{mode } i}) + \mathcal{L}(\mathbf{Y}_A, \hat{\mathbf{Y}}_A) \quad (13)$$

其中,  $M$  是交通模式种类数,  $\mathbf{Y}_{\text{mode } i}$  和  $\hat{\mathbf{Y}}_{\text{mode } i}$  代表第  $i$  类出行流量真实值和预测值,  $\mathbf{Y}_A$  和  $\hat{\mathbf{Y}}_A$  代表总流量真实值和预测值。

最终,基于图对比学习的多模态交通流量预测总损失函数由联合图对比损失式(9)、互信息最小化损失式(11)和回归预测损失式(13)得到:

$$\mathcal{L}_{\text{all}} = \mathcal{L}_{\text{reg}} + \alpha \mathcal{L}_{\text{con}} + \beta \mathcal{L}_{\text{mi}} \quad (14)$$

其中,  $\alpha$  和  $\beta$  是损失平衡参数,用于权衡回归预测损失、图对比损失和互信息最小化损失所占权重的比例。

## 4 实验

### 4.1 数据集

大多数城市区域级交通流量预测公开数据集都是按照

规则网格进行区域划分统计,例如北京出租车流量(TaxiBJ)按照 $32 \times 32$ 的区域进行划分。而实际城市路网和行政边界范围却是不规则的,根据这种规则方式构建异构关系以及采集统计交通流量会忽略不规则边界,因而具有不合理性。而且,一个地区针对不同交通流的统计方式也存在差异,比如以站点为单位统计某地自行车流量,却按照网格分区统计出租车流量,导致缺少对同一地区多种出行方式按照相同不规则分区统计方式的公开多模态数据集。基于以上原因,本文自行选择处理所需异构关系的不规则分区信息和功能兴趣点数据集,同时对美国纽约市曼哈顿区和芝加哥市的原始出行数据进行统计以构建多模态交通流量数据集。

#### 4.1.1 数据来源

1) NYC Open Data: 纽约市政府提供的开放数据平台,旨在促进透明、参与和创新。该平台为公众和研究者提供了丰富的数据集,涵盖了城市的各个方面,包括城市规划、交通、教育、环境、公共健康、住房、公共安全等。

2) NYC Citi Bike: 纽约市由花旗银行 Citi Bank 赞助的一个自行车共享项目“花旗单车”(Citi Bike)。它为纽约的居民和游客提供一种便捷的、可持续的交通方式选择。基于分布广泛的自行车站点,用户可以通过手机应用程序租借 Citi Bike 自行车,在城市中进行短途出行。

3) Chicago Data Portal: 芝加哥市一个综合性的城市数据管理平台,建设目的在于促进城市治理的效率和透明度。该平台集成了各种信息和数据资源,包括城市基础设施、交通系统、人口统计数据等,以支持政府决策制定和城市规划。

4) Chicago Divvy Bike: 芝加哥城市自行车共享计划,旨在为芝加哥市居民和游客提供方便、可持续的城市交通解决方案。该计划通过建立广泛的自行车站点和使用手机应用程序,为用户提供简便的租借服务,以满足其短途出行需求。

5) OpenStreetMap: 一个由全球志愿者共同创建的开放地图项目,它提供免费、可编辑和可自由使用的地理数据,包括道路、建筑物和地理特征。其通过众包的方式收集数据,使得用户可以编辑和更新地图内容,从而不断改进和完善地理信息,广泛用于导航、地理分析和社区参与等各种应用领域。

#### 4.1.2 异构关系数据集

由于本文考虑的异构关系包括地理位置和城市功能场景两种,因此需要相应的数据集来度量位置关系和城市功能,涉及的数据集包括城市不规则分区和城市功能兴趣点。下面依次介绍两类数据集的详细信息以及对数据集的处理。

##### 1) 分区和兴趣点数据集

(1) 分区信息: 纽约市分区信息基于 NYC Open Data 上的出租车分区数据集<sup>1)</sup>,其中曼哈顿区包含了 69 个区域。芝加哥市按照 City of Chicago 上社区划分数据集<sup>2)</sup>被划分成了 77 个区域。图 8 展示了两地车流量统计的分区边界。




图 8 纽约市曼哈顿区和芝加哥市不规则分区

Fig. 8 Irregular zoning of the borough of Manhattan in New York City and Chicago

(2) 城市功能兴趣点: 纽约市的兴趣点数据<sup>3)</sup>可以从 NYC open data 获取,在该数据集中兴趣点被划分成了住宅、教育设施、文化设施、娱乐设施、社会服务、交通设施、商业、政府设施(非公共安全)、宗教机构、卫生服务、公共安全、水和其他共 13 个类别。芝加哥市的兴趣点数据<sup>4)</sup>来源于 OpenStreetMap Overpass API,兴趣点是按 OSM 标签的便利设施进行分类的,包括公共服务、健康、休闲、餐饮、住宿、购物、金融、旅游、宗教、交通和其他共 11 类兴趣点。

##### 2) 数据处理

对于异构关系中的地理位置,不规则分区信息数据集中存在 geometry 属性,利用 shapely 和 geopandas 库,使用 geometry.Geometry.centroid 获取各分区质心坐标,通过 great\_circle 函数计算区域间质心距离。对于异构关系中的城市功能,纽约市城市兴趣点数据集中存在列信息用于分类,而在 OpenStreetMap 的兴趣点数据集中缺少类似信息,但其具有对应的分类编码信息,根据编码前缀将城市功能点进行预处理,再根据功能点坐标将其划分到相应区域,用  $n$  维向量表示每个分区的城市功能信息, $n$  代表功能点种类数,最后计算城市功能相似度。

#### 4.1.3 交通流量数据集

由于并未有人提出多模态流量预测方法,因此大部分公开数据集都是针对某个地方的单种出行方式的,不适用于本文。我们只能根据原始出行数据,按照 4.1.2 节中的不规则分区信息进行分区统计采集,且同时采集出流量和入流量,形成多模态交通流量数据集。本小节介绍两地选择的原始出行数据集、数据集的统计过程以及最终形成的多模态交通流量数据集。

##### 1) 原始出行数据集

(1) NYC Taxi<sup>5)</sup>: 来自纽约城市开放数据平台 NYC Open Data,出租车数据包括纽约市常见的两种出租车——黄色出租车和绿色出租车。出租车轨迹记录数据记录的是纽约出租车的通行信息,包括起止点的区域编号、起停时间、乘客数、费用等。

<sup>1)</sup> <https://data.cityofnewyork.us/Transportation/NYC-Taxi-Zones/d3c5-ddgc>

<sup>2)</sup> <https://data.cityofchicago.org/Facilities-Geographic-Boundaries/Boundaries-Community-Areas-current-/cauq-8yn6>

<sup>3)</sup> <https://data.cityofnewyork.us/City-Government/Points-Of-Interest/rxuy-2muj>

<sup>4)</sup> [https://wiki.openstreetmap.org/wiki/Overpass\\_API](https://wiki.openstreetmap.org/wiki/Overpass_API)

<sup>5)</sup> <https://www.nyc.gov/site/tlc/about/tlc-trip-record-data.page>

(2) NYC Bike<sup>1)</sup>:来自纽约城市单车系统 Citi Bike 的用户租赁自行车行驶轨迹数据。轨迹记录数据主要由自行车 ID、租赁起止的位置坐标及时间、起止站点 ID、行程持续时间等部分组成。

(3) CHI Taxi<sup>2)</sup>:来自芝加哥市城市数据管理平台 City of Chicago,包括芝加哥市所有类型出租车数据。出租车轨迹记录数据包括订单编号、起止点的社区、起止时间、费用、距离等内容。

(4) CHI Bike<sup>3)</sup>:来自芝加哥市共享单车计划 Divvy 的用户租赁轨迹数据。记录的轨迹记录数据是自行车 ID、租赁起止的位置坐标、起止站点 ID、起止时间等。

## 2) 多模态流量数据集构建

在统计前,出租车和自行车原始出行数据集都需要筛查空值行以及重复行。除此之外,自行车轨迹数据的起始和到达是以站点坐标形式记录的,因此需要获取停放站点信息,将对应的站点通过坐标划分到对应的不规则分区再进行统计。但自行车站点的性质,导致站点信息变化较大,因此必须统一站点名和站点坐标。例如,站点“Racine Ave \& Fullerton Ave”在某段时间内会更名为“Racine Ave \& Fullerton Ave (Temp)”。出行数据清洗之后,先后完成站点坐标和区域对齐、时间片划分以及按不规则区域和时间片统计,形成的多模态交通流量数据集详细信息如表 1 所列。

表 1 多模态交通流量数据集详细信息

Table 1 Multi-modal traffic flow datasets details

数据集	种类	区域数	时间间隔	时间范围	轨迹总数
NYC Manhattan Multi-modal Traffic Flow Dataset	NYC Taxi NYC Bike NYC Overall	69	30 min	2022-06-01— 2022-09-30	1.1665×10 <sup>7</sup> 9.7650×10 <sup>6</sup> 2.1430×10 <sup>7</sup>
Chicago City Multi-modal Traffic Flow Dataset	CHI Taxi CHI Bike CHI Overall	77	1 h	2022-11-01— 2023-02-28	1.722×10 <sup>6</sup> 6.410×10 <sup>5</sup> 2.818×10 <sup>6</sup>

(1) NYC Manhattan Multi-modal Traffic Flow Dataset: 纽约市曼哈顿区多模态交通流量数据集,统计了纽约市曼哈顿区 69 个交通区域从 2022 年 6 月 1 日到 2022 年 9 月 30 日

这 4 个月出租车、共享单车和总流量的交通信息。

(2) Chicago City Multi-modal Traffic Flow Dataset: 芝加哥市多模态交通流量数据集,统计了芝加哥市的 77 个社区从 2022 年 11 月 1 日到 2023 年 2 月 28 日这 4 个月出租车、共享单车和总流量的交通信息。

## 4.2 实验设置

Python 语言版本为 3.6.9,使用 Pytorch1.9.0 框架在 NVIDIA A30 TENSOR CORE GPU 上进行训练实现。采用 Adam 作为优化器,初始学习率设置为 0.001。对于所有数据集,使用 Min-Max 方法归一化。输入、输出维度均为 2,时间步长取 3,编码特征维度为 64,时间维度上的卷积核大小设置为 3,批处理大小设置为 32,训练集、验证集、测试集的划分比例为 6:2:2。根据经验将损失函数的权重参数  $\alpha$  和  $\beta$  设置为 1。除了以上参数设置外,其余均采用描述相关方法的文献中默认的实验设置。评估指标为两种常见的交通预测指标,即平均绝对误差 (Mean Absolute Error, MAE) 和均方根误差 (Root Mean Square Error, RMSE)。

$$MAE = \frac{1}{Q} \sum_{i=1}^Q |y_i - \hat{y}_i|$$

$$RMSE = \frac{1}{Q} \sum_{i=1}^Q (y_i - \hat{y}_i)^2$$
(15)

## 4.3 策略有效性实验

为了验证多模态同步预测策略的有效性,在这里选取 3 种具有代表性的使用图学习的单模态交通流量模型进行策略使用前后的对比实验。这 3 种模型分别是基于注意力的时空图卷积网络 ASTGCN<sup>[13]</sup>、时空注意力多图卷积网络 STA-MGCN<sup>[14]</sup> 和时空多图卷积网络 ST-MGCN<sup>[15]</sup>。

对于每一种模型,在统计的纽约市曼哈顿区和芝加哥市的多模态数据集上分别进行出租车、共享单车和总流量单种交通流量类别的预测,然后将它们分别加上本文提出的基于构建异构图的多模态图对比 (CoF-MGCL) 的方式进行多出行模式和总流量的同步预测,比较加入前后的预测性能。

纽约市曼哈顿区和芝加哥市多模态入流量和出流量的实验结果分别如表 2 和表 3 所列。

表 2 纽约市曼哈顿区多模态交通流量预测性能前后比较

Table 2 Comparison of multimodal traffic flow forecasting performance in Manhattan, New York city before-and-after combining multimodal prediction strategy

模型	NYC Taxi				NYC Bike				NYC Overall			
	MAE		RMSE		MAE		RMSE		MAE		RMSE	
	In	Out	In	Out	In	Out	In	Out	In	Out	In	Out
ASTGCN	6.305	6.911	9.831	10.968	6.514	6.934	10.311	10.888	9.557	10.106	14.696	15.077
ASTGCN+Ours	<b>6.124</b>	<b>6.703</b>	<b>9.657</b>	<b>10.903</b>	<b>6.198</b>	<b>6.481</b>	<b>9.907</b>	<b>10.364</b>	<b>9.177</b>	<b>9.809</b>	<b>14.133</b>	<b>14.562</b>
Improvements	+2.87%	+3.01%	+1.77%	+0.59%	+4.85%	+6.53%	+3.92%	+4.81%	+3.98%	+2.94%	+3.83%	+3.42%
STA-MGCN	5.789	6.356	9.284	10.453	5.999	6.272	9.623	10.064	8.865	9.371	13.865	<b>14.551</b>
STA-MGCN+Ours	<b>5.703</b>	<b>6.288</b>	<b>9.031</b>	<b>10.192</b>	<b>5.963</b>	<b>6.230</b>	<b>9.451</b>	<b>9.914</b>	<b>8.744</b>	<b>9.324</b>	<b>13.612</b>	14.684
Improvements	+1.49%	+1.07%	+2.73%	+2.50%	+0.60%	+0.67%	+1.79%	+1.49%	+1.36%	+0.50%	+1.82%	-0.91%
ST-MGCN	5.133	5.190	8.282	8.700	<b>5.275</b>	5.501	8.544	8.918	8.048	8.289	12.489	13.041
ST-MGCN+Ours	<b>5.104</b>	<b>5.102</b>	<b>8.139</b>	<b>8.560</b>	5.284	<b>5.411</b>	<b>8.469</b>	<b>8.835</b>	<b>7.946</b>	<b>8.184</b>	<b>12.187</b>	<b>12.809</b>
Improvements	+0.57%	+1.70%	+1.73%	+1.61%	-0.17%	+1.64%	+0.88%	+0.93%	+1.28%	+1.27%	+2.42%	+1.78%

<sup>1)</sup> <https://ride.citibikenyc.com/system-data>

<sup>2)</sup> <https://data.cityofchicago.org/>

<sup>3)</sup> <https://divvybikes.com/system-data>

表3 芝加哥市多模态交通流量预测性能前后比较

Table 3 Comparison of multi-modal traffic flow forecasting performance in Chicago before-and-after combining multimodal prediction strategy

模型	CHI Taxi				CHI Bike				CHI Overall			
	MAE		RMSE		MAE		RMSE		MAE		RMSE	
	In	Out	In	Out	In	Out	In	Out	In	Out	In	Out
ASTGCN	2.655	3.262	6.047	8.051	3.130	3.273	6.305	6.677	3.190	3.795	7.557	9.484
ASTGCN+Ours	<b>2.603</b>	<b>3.136</b>	<b>5.769</b>	<b>8.016</b>	<b>3.020</b>	<b>3.086</b>	<b>6.062</b>	<b>6.585</b>	<b>3.172</b>	<b>3.620</b>	<b>7.474</b>	<b>9.359</b>
Improvements	+1.96%	+3.86%	+4.60%	+0.43%	+3.51%	+5.71%	+3.85%	+1.38%	+0.56%	+4.61%	+1.10%	+1.32%
STA-MGCN	2.594	3.050	5.729	7.785	2.861	3.043	5.529	6.029	2.921	3.434	6.440	8.416
STA-MGCN+Ours	<b>2.562</b>	<b>2.985</b>	<b>5.526</b>	<b>7.500</b>	<b>2.773</b>	<b>2.970</b>	<b>5.334</b>	<b>5.770</b>	<b>2.908</b>	<b>3.409</b>	<b>6.312</b>	<b>8.364</b>
Improvements	+1.23%	+2.13%	+3.54%	+3.66%	+3.08%	+2.40%	+3.53%	+4.30%	+0.45%	+0.73%	+1.99%	+0.62%
ST-MGCN	2.272	2.484	5.458	6.758	1.277	1.352	3.900	4.161	2.668	2.935	6.794	8.198
ST-MGCN+Ours	<b>2.193</b>	<b>2.364</b>	<b>5.198</b>	<b>6.468</b>	<b>1.209</b>	<b>1.188</b>	<b>3.695</b>	<b>3.900</b>	<b>2.623</b>	<b>2.898</b>	<b>6.673</b>	<b>7.938</b>
Improvements	+3.48%	+4.83%	+4.76%	+4.29%	+5.33%	+12.1%	+5.26%	+6.27%	+1.69%	+1.26%	+1.78%	+3.17%

可以看出,在纽约市曼哈顿区的大多数数据集上,在结合多模态预测策略之后,每个模型的预测性能都有0.50%~6.53%的提升,仅在共享单车入流量的MAE和总的出流量的RMSE两个指标上有些许下降。而在芝加哥市的多模态数据集上,使用策略后的预测性能均有所上升,甚至在自行车流量数据集的出流量的MAE上提升高达12.1%,表明使用所提方法的确能让交通流量预测的准确性得到相应的提升,从而证明了基于图对比的多模态交通流量协同预测方法的有效性。

#### 4.4 模型对比实验

为了进一步体现所提方法的优越性,将在策略有效性实验中提升效果最好的模型ST-MGCN结合所提方法CoF-MGCL作为对比模型ST-MGCL,并选取多种具有公开代码的单模态交通流量预测模型在收集多模态交通流量数据集上进行性能比较。对比的基准方法包括:

LSVR<sup>[5]</sup>:线性支持向量机方法,用于传统时序预测任务。

FC-LSTM<sup>[16]</sup>:全连接的长短期记忆神经网络,能够有效建模序列依赖的网络结构。

STGCN<sup>[11]</sup>:时空图卷积网络,使用空间维度的ChebNet和时间维度的二维卷积网络对交通数据时空相关性进行建模。

STSGCN<sup>[17]</sup>:时空同步图卷积网络,提出的时空同步机制能有效捕捉复杂的局部时空相关性,且设计了多个不同

时间段的模块以捕获时空数据的异质性。

GMAN<sup>[18]</sup>:图的多注意力网络,同时使用时间注意力、空间注意力以及转移注意力3种注意力用于交通流预测。

MTGNN<sup>[19]</sup>:通过图学习模块融合外部知识和变量之间的单向关系,mix-hop传播层用于空间模块,在时间模块利用dilated inception捕获时序依赖。

Bi-STAT<sup>[20]</sup>:一种双向时空自适应变换器,不仅能根据当前流量预测未来流量,而且能根据当前流量预测过去流量,从而提升流量预测的准确性。

DGCRN<sup>[21]</sup>:每个时间步从空间节点属性中提取动态特征生成动态图,将动态图与预定义的静态图集成用于交通流量预测,并提出了一种循环预测方法来提高预测效率。

在纽约市曼哈顿区和芝加哥市的多模态数据集上的实验结果分别如表4和表5所列。从表中可以看到,ST-MGCL在大多数数据集上都有着不错的表现,仅在纽约市不同出行方式数据集上的3个指标稍低于MTGNN,1个指标稍低于Bi-STAT,其余的预测效果均处于领先的位置。由于忽略了城市交通流量数据变化中的空间相关信息,LSVR和FC-LSTM的表现效果较差。对异构图进行编码得到了丰富的邻域信息,使得ST-MGCL的预测性能优于仅考虑距离关系的STGCN和STSGCN模型。同时,尽管ST-MGCL不像GMAN使用注意力机制动态捕捉时空特征,但其通过图对比学习可以有效利用多模态信息的交互,预测效果可能优于GMAN模型。

表4 纽约市曼哈顿区不同交通流量预测方法的预测性能比较(NYC)

Table 4 Comparison of forecasting performance of different traffic flow forecasting methods in Manhattan, New York city(NYC)

Datasets	Metric	Type	LSVR	FC-LSTM	STGCN	STSGCN	GMAN	MTGNN	Bi-STAT	DGCRN	ST-MGCL
NYC Taxi	MAE	In	6.125	6.128	5.557	5.437	5.369	5.274	5.462	5.387	<b>5.104</b>
		Out	6.482	6.479	5.907	5.834	5.820	5.668	5.886	5.739	<b>5.102</b>
	RMSE	In	9.031	8.966	8.991	8.475	8.460	8.158	8.453	8.331	<b>8.139</b>
		Out	9.891	9.852	9.699	9.268	9.362	9.060	9.427	9.133	<b>8.560</b>
NYC Bike	MAE	In	6.724	6.674	5.813	5.746	5.592	5.511	5.456	5.489	<b>5.284</b>
		Out	6.921	6.856	5.794	5.903	5.605	5.589	5.651	5.721	<b>5.411</b>
	RMSE	In	10.290	10.107	9.256	9.106	8.910	8.487	8.521	8.658	<b>8.469</b>
		Out	10.454	10.250	9.262	9.233	8.784	<b>8.673</b>	8.799	8.942	8.835
NYC Overall	MAE	In	9.667	9.665	8.813	8.324	7.953	7.947	<b>7.929</b>	7.958	7.946
		Out	9.948	9.943	8.828	8.617	8.319	8.277	8.433	8.382	<b>8.184</b>
	RMSE	In	14.275	14.155	13.407	12.769	12.195	<b>11.918</b>	11.948	12.050	12.108
		Out	14.711	14.622	13.799	13.174	12.894	<b>12.458</b>	12.940	12.912	12.809

表 5 芝加哥市不同交通流量预测方法的预测性能比较(CHI)

Table 5 Comparison of forecasting performance of different traffic flow forecasting methods in Chicago(CHI)

Datasets	Metric	Type	LSVR	FC-LSTM	STGCN	STSGCN	GMAN	MTGNN	Bi-STAT	DGCRN	ST-MGCL
CHI	MAE	In	3.602	3.507	2.704	2.819	2.680	2.595	2.670	2.562	<b>2.193</b>
		Out	4.054	3.895	2.834	3.499	3.154	2.951	2.917	2.872	<b>2.364</b>
Taxi	RMSE	In	9.318	8.414	8.868	6.778	6.373	5.937	6.253	5.966	<b>5.198</b>
		Out	10.405	9.908	9.571	9.920	8.593	7.722	7.335	7.533	<b>6.468</b>
CHI	MAE	In	3.921	3.478	1.482	3.475	3.151	2.947	2.803	2.911	<b>1.209</b>
		Out	3.835	3.467	1.464	3.548	3.097	2.921	2.779	2.865	<b>1.188</b>
Bike	RMSE	In	8.134	6.943	5.522	7.229	6.769	6.159	5.711	6.258	<b>3.695</b>
		Out	7.799	6.780	5.233	7.563	6.559	6.191	5.632	6.314	<b>3.900</b>
CHI	MAE	In	4.434	4.241	3.510	3.548	3.338	3.008	3.182	3.098	<b>2.623</b>
		Out	4.859	4.661	3.442	4.180	3.611	3.496	3.558	3.499	<b>2.898</b>
Overall	RMSE	In	12.166	10.190	8.236	7.563	8.301	6.945	7.405	7.457	<b>6.673</b>
		Out	12.871	11.695	11.032	11.564	9.522	8.965	8.596	9.195	<b>7.938</b>

值得一提的是,MTGNN,Bi-STAT 和 DGCRN 的性能表现优于其他单模态预测模型,这是因为这 3 种模型都充分考虑了多种信息。其中 MTGNN 建模了多变量时间序列数据中成对变量之间的潜在空间依赖,Bi-STAT 同时利用过去和未来的交通流量序列优化了预测精度,DGCRN 通过生成方式捕获了动态的空间相关性。但是从实验结果中可以看到,本文方法在纽约和芝加哥数据集上的性能表现几乎超过了 MTGNN,Bi-STAT 和 DGCRN 模型,表明了多模态交通流量交互的重要性。

#### 4.5 消融实验

为了探究异构图编码模块中通过构建不同空间关系编码和图对比的方式挖掘不同出行方式的交互关系和模态间

互信息最小化来减少冗余信息对预测效果的影响,在芝加哥市多模态交通流量数据集上进行消融实验,将 ST-MGCL 移除部分,产生一些变体(w/o)D,(w/o)P,(w/o)Mi 和(w/o)Gcl 来进行预测效果对比。其中,(w/o)D 和(w/o)P 分别去除了地理位置关系和城市功能关系,仅使用单关系图进行图编码;(w/o)Gcl 模型将损失系数  $\alpha$  置为零,不使用图对比损失;(w/o)Mi 将互信息最小化的损失系数  $\beta$  设置为零。消融实验结果如图 9 所示。从图中可以看到,图对比对预测效果的影响最大,证明了多模态交通流量信息交互的重要性。除此以外,仅使用地理位置或是城市功能的单关系进行图编码也会使模型预测效果变差,利用互信息将模态间的冗余消除对预测的影响虽然较小,但也有一定的作用。

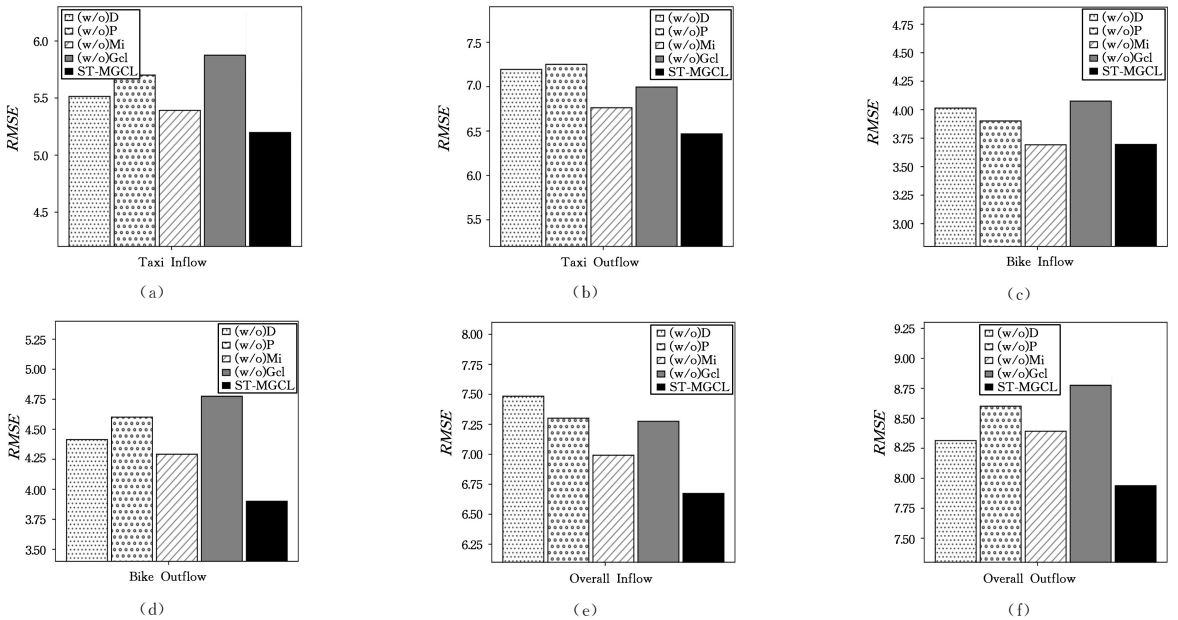


图 9 芝加哥市多模态交通流量数据集上的消融结果

Fig. 9 Ablation results on multimodal traffic flow dataset in Chicago

#### 4.6 案例研究

本小节选择部分区域和整体区域流量的预测结果进行可视化,直观地观察预测效果。将纽约市曼哈顿区的 69 号区域进行不同出行方式预测结果的可视化,分别得到了预测值和真实值的曲线,其中红色代表预测值,蓝色代表真实值,如图 10 所示。从图中可以看到,城市中不同出行方式的交通流量数据均具有周期性,且预测的结果与

真实值的周期基本一致,模型可以很好地预测真实的交通流量数据变化。

然后选取某个工作日两个地方的总车流量早、中、晚 3 个时间段的预测值进行可视化,纽约市曼哈顿区选择 2022 年 8 月 10 日的总车流量,芝加哥市选取 2023 年 2 月 1 日的总车流量。从图 11 中可以看到,真实情况与预测情况几乎一致,在城市核心功能区的流量明显高于城市边缘区,同时,午间的车流

量明显低于早晚高峰,呈现的情况符合实际生活中由交通系统

设备完善性设置与否以及工作出勤情况而产生的出行规律。

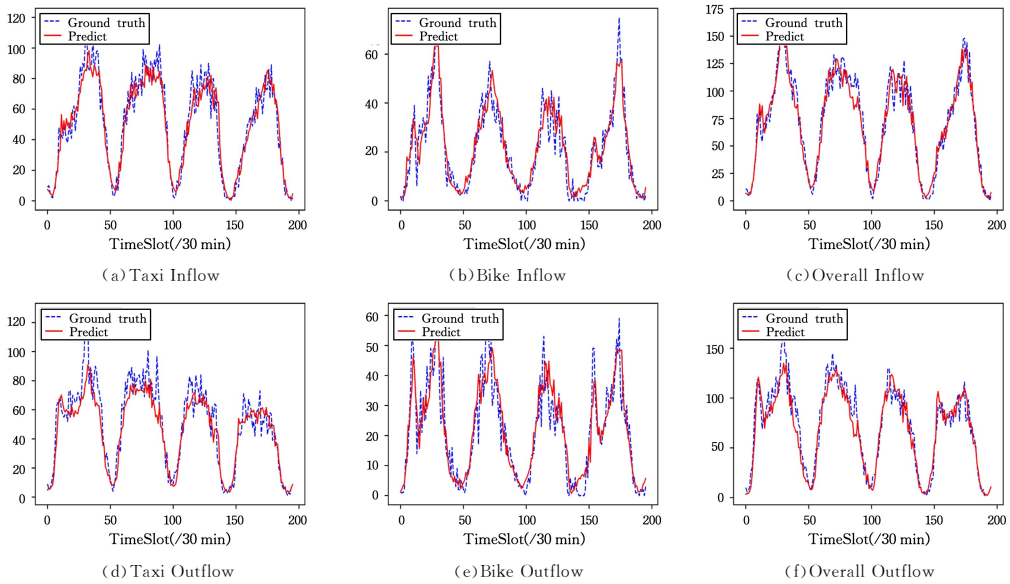


图 10 纽约市曼哈顿区 69 号区域多模态交通流量预测结果(电子版为彩图)

Fig. 10 Multimodal traffic flow prediction results of area 69 in Manhattan, New York city

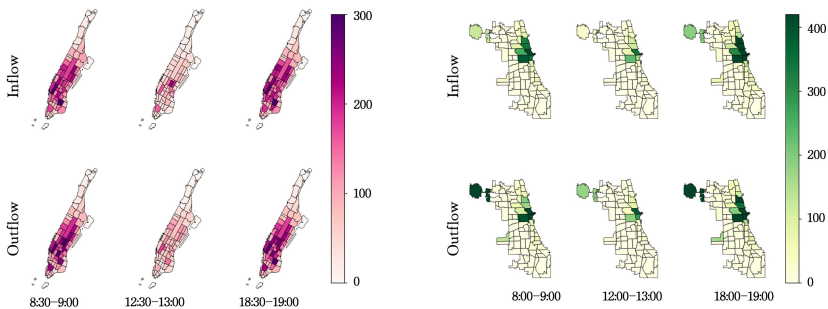


图 11 纽约市曼哈顿区和芝加哥市某日总流量变化

Fig. 11 Overall traffic flow of Manhattan in New York city and Chicago on a certain day

**结束语** 本文提出了一种新的基于图对比学习的多模态交通流量预测协同方法,通过图对比学习对多模态交通流量数据进行协同预测,以有效地捕获不同出行模式之间的依赖关系。在自行构建的真实世界不同地区的多模态出行方式数据集上进行实验,并与多种单模态交通流量模型进行对比,验证了本文提出的策略具有提升预测性能的优势。事实上,该策略具有很好的迁移性,能嵌入到多种使用图神经网络的交通流量预测模型中。未来,将优化本文方法的结构,进一步提升多模态交通流量预测的效率。

## 参考文献

[1] FU R, ZHANG Z, LI L. Using LSTM and GRU neural network methods for traffic flow prediction[C]//2016 31st Youth Academic Annual Conference of Chinese Association of Automation. 2016:324-328.

[2] ZHANG J, ZHENG Y, QI D. Deep spatio-temporal residual networks for citywide crowd flows prediction[C]//Proceedings of the AAAI Conference on Artificial Intelligence. 2017:1655-1661.

[3] LIANG Y, OUYANG K, SUN J, et al. Fine-grained urban flow prediction[C]//Proceedings of the Web Conference 2021. 2021:

1833-1845.

[4] 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.

[5] WU C H, HO J M, LEE D T. Travel-time prediction with support vector regression [J]. IEEE transactions on Intelligent Transportation Systems, 2004, 5(4):276-281.

[6] VAN LINT J W C, VAN HINSBERGEN C. Short-term traffic and travel time prediction models[J]. Artificial Intelligence Applications to Critical Transportation Issues, 2012, 22(1):22-41.

[7] ZHAO W, GAO Y, JI T, et al. Deep temporal convolutional networks for short-term traffic flow forecasting[J]. IEEE Access, 2019, 7:114496-114507.

[8] ZHANG C, PATRAS P. Long-term mobile traffic forecasting using deep spatio-temporal neural networks[C]//Proceedings of the Eighteenth ACM International Symposium on Mobile Ad Hoc Networking and Computing. 2018:231-240.

[9] YAO H, TANG X, WEI H, et al. Revisiting spatial-temporal similarity: A deep learning framework for traffic prediction [C]//Proceedings of the AAAI Conference on Artificial Intelligence. 2019:5668-5675.

[10] WU Z, PAN S, LONG G, et al. Graph wavenet for deep spatial-

temporal graph modeling[J]. arXiv:1906.00121,2019.

- [11] YU B, YIN H, ZHU Z. Spatio-temporal graph convolutional networks: A deep learning framework for traffic forecasting[C]// Proceedings of the International Joint Conference on Artificial Intelligence. 2018:3634-3640.
- [12] GUO K, HU Y, SUN Y, et al. Hierarchical graph convolution network for traffic forecasting[C]// Proceedings of the AAAI Conference on Artificial Intelligence. 2021,35(1):151-159.
- [13] 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.
- [14] XING D, ZHAO C, WANG G. A Spatial-Temporal Attention Multi-Graph Convolution Network for Ride-Hailing Demand Prediction Based on Periodicity with Offset[J]. arXiv: 2203.12505,2022.
- [15] 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. 2019:3656-3663.
- [16] SUTSKEVER I, VINYALS O, LE Q V. Sequence to sequence learning with neural networks[C]// Proceedings of the Advances in Neural Information Processing Systems. 2014.
- [17] 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.
- [18] ZHENG C, FAN X, WANG C, et al. Gman: A graph multi-attention network for traffic prediction[C]// Proceedings of the

AAAI Conference on Artificial Intelligence. 2020:1234-1241.

- [19] WU Z, PAN S, LONG G, et al. Connecting the dots: Multivariate time series forecasting with graph neural networks[C]// Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. 2020:753-763.
- [20] CHEN C, LIU Y, CHEN L, et al. Bidirectional spatial-temporal adaptive transformer for Urban traffic flow forecasting[J/OL]. IEEE Transactions on Neural Networks and Learning Systems. 2022:1-13. <https://ieeexplore.ieee.org/document/9810964>.
- [21] LI F, FENG J, YAN H, et al. Dynamic graph convolutional recurrent network for traffic prediction: Benchmark and solution [J]. ACM Transactions on Knowledge Discovery from Data, 2023,17(1):1-21.



**XIAO Yang**, born in 2001, postgraduate. Her main research interests include artificial intelligence and spatio-temporal data mining.



**LIAO Qing**, born in 1988, Ph.D, professor. Her research interests include artificial intelligence and data mining.

(责任编辑:李亚辉)