

## 跨城市人类移动行为预测研究综述

张雨松, 胥帅, 严兴宇, 关东海, 许建秋

### 引用本文

张雨松, 胥帅, 严兴宇, 关东海, 许建秋. [跨城市人类移动行为预测研究综述](#)[J]. 计算机科学, 2025, 52(1): 102-119.

ZHANG Yulong, XU Shuai, YAN Xingyu, GUAN Donghai, XU Jianqiu. [Survey on Cross-city Human Mobility Prediction](#) [J]. Computer Science, 2025, 52(1): 102-119.

---

## 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SE注意力多源域对抗网络的射频指纹识别](#)

RF Fingerprint Recognition Based on SE Attention Multi-source Domain Adversarial Network  
计算机科学, 2025, 52(1): 412-419. <https://doi.org/10.11896/jsjcx.231100076>

#### [计算机视觉领域对抗样本检测综述](#)

Adversarial Sample Detection in Computer Vision:A Survey  
计算机科学, 2025, 52(1): 345-361. <https://doi.org/10.11896/jsjcx.240300080>

#### [基于最大影响力集合的主动学习方法](#)

Active Learning Based on Maximum Influence Set  
计算机科学, 2025, 52(1): 289-297. <https://doi.org/10.11896/jsjcx.231100075>

#### [视觉富文档理解预训练综述](#)

Review of Pre-training Methods for Visually-rich Document Understanding  
计算机科学, 2025, 52(1): 259-276. <https://doi.org/10.11896/jsjcx.240300028>

#### [基于细粒度代码表示和特征融合的即时软件缺陷预测方法](#)

Just-In-Time Software Defect Prediction Approach Based on Fine-grained Code Representation and Feature Fusion  
计算机科学, 2025, 52(1): 242-249. <https://doi.org/10.11896/jsjcx.240200046>

# 跨城市人类移动行为预测研究综述

张雨松<sup>1</sup> 胥帅<sup>1,2</sup> 严兴宇<sup>1</sup> 关东海<sup>1</sup> 许建秋<sup>1</sup>

1 南京航空航天大学计算机科学与技术学院 南京 211106

2 计算机软件新技术国家重点实验室(南京大学) 南京 210023

(sz2216133@nuaa.edu.cn)

**摘要** 城市化进程积累了大量记录人类移动行为的时空数据,为研究人类移动行为建模及预测提供了良好的数据基础。在智慧城市建设背景下,跨城市人类移动预测是实现城市协同管理与治理的必然要求,时常面临数据匮乏以及数据分布不平衡等问题,传统机器学习方法难以取得理想的性能。因此,将人类移动相关知识从数据丰富的源城市迁移到数据稀疏乃至稀缺的目标城市至关重要。首先概述了现有跨城市人类移动行为预测研究所使用的数据集和评价指标,随后循序渐进地讨论人类个体和群体层面的跨城市移动预测问题并分类综述各自适用的研究方法。针对人类个体跨城市移动预测,主要分析协同过滤、矩阵分解、统计学习以及深度学习这4类模型方法的应用。针对人类群体跨城市移动预测,则聚焦知识迁移和元学习这两种面向少样本机器学习方法的应用。最后,展望了跨城市人类移动行为预测领域亟需解决的重要问题。

**关键词**: 跨城市; 人类移动行为; 时空数据; 迁移学习; 深度学习

**中图分类号** TP181

## Survey on Cross-city Human Mobility Prediction

ZHANG Yusong<sup>1</sup>, XU Shuai<sup>1,2</sup>, YAN Xingyu<sup>1</sup>, GUAN Donghai<sup>1</sup> and XU Jianqiu<sup>1</sup>

1 College of Computer Science and Technology, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China

2 State Key Laboratory for Novel Software Technology(Nanjing University), Nanjing 210023, China

**Abstract** The advancement of urbanization has accumulated massive spatio-temporal data that records human mobility, providing a favorable data foundation for human mobility modeling and prediction. In the context of smart city construction, cross-city human mobility prediction is an inevitable requirement for achieving urban collaborative management and governance. At this time, there are often problems such as data scarcity and imbalanced data distribution. Traditional machine learning methods are difficult to achieve ideal performance. Therefore, it is crucial to transfer knowledge related to human mobility from the data-rich source cities to the data-scarce target cities. This paper firstly provides an overview of the datasets and commonly used evaluation metrics used in existing studies, followed by a gradual discussion of the cross-city mobility prediction problem at the human individual-level and group-level respectively, and then categorizes the applicable research methods. For the individual-level human mobility prediction, the application of four types of models, i. e., collaborative filtering, matrix factorization, statistical learning, and deep learning, are analyzed. For group-level human mobility prediction, two types of machine learning methods for few samples, i. e., knowledge transfer and meta learning, are specifically analyzed. In the end, important issues that urgently need to be addressed in the field of cross-city human mobility prediction are prospected.

**Keywords** Cross-city, Human mobility, Spatio-Temporal data, Transfer learning, Deep learning

## 1 引言

人类和资源在时间和空间的交汇点汇聚,形成了城市这一当代文明的标志。城市的崛起为大规模社会协作和基础设施的可持续利用提供了便利条件,从而显著地促进了社会

经济效益的提升。然而,近年来,城市面临着急剧增长的人口挑战,这引发了一系列与人类移动行为紧密相关的复杂问题。人类的流动性正在变得越来越复杂,不仅受到个体决策的影响<sup>[1]</sup>,还受到众多因素的驱动,如病毒性疾病的传播<sup>[2-4]</sup>、自然灾害<sup>[5-7]</sup>、气候变化<sup>[8-9]</sup>等。在这一背景下,研究和理解人类的

到稿日期:2024-01-02 返修日期:2024-07-01

基金项目:国家自然科学基金(62302213,61972198);江苏省自然科学基金(BK20210280);中央高校基本科研业务费(NS2022089)

This work was supported by the National Natural Science Foundation of China (62302213, 61972198), Natural Science Foundation of Jiangsu Province, China (BK20210280) and Fundamental Research Funds for the Central Universities (NS2022089).

通信作者:胥帅(xushuai7@nuaa.edu.cn)

移动行为成为了一项至关重要的课题。

随着普适计算技术的发展,城市已经变成了巨大的信息网络,各种智能终端、物联网设备以及社交媒体平台不断地产生着海量的时空数据<sup>[10]</sup>。移动智能终端、车辆以及船只的GPS设备为研究人类移动行为提供了前所未有的数据来源,部分城市更是积累了丰富的移动相关的时空数据,这些数据反映了人类的行为、偏好和移动模式,为深入了解城市中的人类活动提供了坚实的基础。因此,研究人类移动行为不仅在学术界引起了广泛的关注,而且在交通管理<sup>[11-12]</sup>、公共卫生<sup>[13]</sup>等领域也具有巨大的实际价值。

因此,研究人类的移动行为成为一个重要课题,不少工作从个体和群体两个方面研究人类移动行为的规律并进行预测。简单来说,个体移动行为预测问题<sup>[14-19]</sup>就是在给定时空范围内,通过对个体的丰富历史移动数据进行建模,预测其未来的移动轨迹、位置或其他相关行为。而群体移动行为预测研究<sup>[20-26]</sup>旨在根据大量的时空数据,准确预测该地区或路段在未来一段时间内的流量情况。这两类研究在城市发展的移动行为的微观和宏观层面上都具有深远的学术和实际意义,这些模型对社会交互机制以及移动记忆机制进行建模,为联系宏观层面的城市发展和微观层面的个体移动行为架设了坚实的理论桥梁。这些模型依赖于城市中积累的丰富的时空数据,数据的充足性使得模型能够学习到更为复杂和细致的时空关联,从而更好地适应城市的特定环境。然而,当我们尝试将研究成果在不同城市之间进行应用时,可能会面临一个显著而普遍的问题——目标城市数据的稀疏性。一旦将这些模型迁移到目标城市,就暴露了目标城市数据稀缺的困境。目标城市的信息相对匮乏,不足以提供模型在新环境下有效预测所需的全面上下文。因此,这些研究尽管对理解城市中的人类移动行为有着巨大的现实意义,但大多集中于单一城市的数据分析与预测,而跨城市移动行为的预测则是全新的挑战。

同时,目标城市可能受限于资源、技术或隐私等因素,数据量相对较少,即存在数据稀疏性问题。单一城市的丰富数据支撑下的预测成果并不能保证在数据稀疏的其他城市中同样有效。数据不对称现象严重限制了模型的普适性和准确性,也增加了在目标城市开展有效预测的难度。同时,考虑到城市之间存在结构和文化等差异,传统的基于深度学习等方法的模型无法在人类跨城市移动行为预测这一课题上发挥出良好的性能,这不仅增加了模型的复杂性,还要求模型具有更高的泛化能力,以适应不同城市之间的差异。因此,将数据丰富的源城市上的知识迁移到数据匮乏的目标城市上,并解决人类移动行为预测问题,是当前的研究热点,也是城市发展的新方向。

近年来,跨城市人类移动行为预测也得到了社会各界的较多关注,并且在数据流量预测<sup>[27]</sup>、连锁品牌店选址<sup>[28-30]</sup>、广告牌选址<sup>[31]</sup>、环境质量预测<sup>[32]</sup>等跨城市应用中初见成效。跨城市的具体定义,可以从个体和群体两方面来说。其中,个体跨城市移动行为预测是指预测源城市中的用户在造访目标城市可能会访问的位置,其在物理上确实来到了其他城市;

针对人类群体跨城市移动行为预测,主要是利用源城市丰富的轨迹数据辅助预测目标城市的人类群体流量,本质上并没有物理意义上的空间转移。

目前,跨城市人类移动行为预测模型面临的挑战主要来源于以下几个方面。

1)数据异质性和稀疏性:不同城市的时空数据通常具有不同的结构和语义,因此数据的异质性使得跨城市数据整合和特征表示变得复杂,而目标城市的数据稀疏性可能导致模型训练的不稳定性和低准确性。

2)城市特征差异化:跨城市研究需要考虑城市之间的地理、文化、气候、经济等多种差异,这些差异会影响用户行为和人群流向分布。因此,如何在模型中有效地建模弥合城市差异是一项挑战。

3)知识迁移和领域自适应:从一个城市向另一个城市迁移知识和模型需要解决领域自适应问题,因为不同城市的数据分布和特性可能差异显著。如何有效地迁移模型以适应目标城市的特征,是一个重要问题。

近年来,在跨城市人类移动行为预测的相关研究中,一些研究主要采取了传统的推荐算法<sup>[33-38]</sup>。例如,在个体跨城市移动行为预测研究中,文献<sup>[33]</sup>中最早采用了协同过滤的方法,通过用户的社交关系、地理位置的远近以及用户本身的偏好构建模型。但由于各个城市间原本就存在着巨大的特征差异,因此原有模型难以拥有良好的性能。而基于统计学习<sup>[39-45]</sup>和深度学习(Deep Learning, DL)模型<sup>[46-51]</sup>的方法能够有效提取出城市特有特征以及城市公共特征,进而将用户在源城市的偏好传递到目标城市辅助进行预测工作。随着迁移学习<sup>[52-54]</sup>的逐渐兴起,越来越多的研究使用迁移学习模型转移用户的偏好等知识。此外,迁移学习还常被用来弥合因城市相关特征而导致的城市之间的差异。但随着问题定义的扩展,预测问题不再局限于单一模式的源城市和目标城市之间,而是如何将多个源城市的知识转移到一个目标城市上,学习人群移动知识的共性,因此研究者便将元学习框架<sup>[55-56]</sup>纳入模型,以便有效缓解冷启动问题,并帮助模型收敛到更好的状态。在人群跨城市行为预测问题中也存在类似的问题扩展,由单一的源城市对应一个目标城市转变为多个源城市对应一个目标城市,因而研究中模型的选取也从迁移学习模型逐步演化为元学习框架,使模型拥有更良好的性能。

本文根据已有文献对跨城市人类移动行为预测相关任务进行分类,着重于按照模型解决的问题对研究进行划分。具体而言,跨城市人类移动行为预测涵盖了个体跨城市移动行为预测和群体跨城市移动行为预测这两个方面。个体跨城市移动行为预测主要关注人类个体在家乡城市之外访问特定位置的预测,用户自行实现了从源城市到目标城市的物理移动。而群体跨城市移动行为预测则侧重于在数据稀缺的城市环境中预测群体移动行为,因此需要利用源城市丰富的时空数据中所蕴含的人类群体移动知识来辅助解决该问题。需要注意的是,人类群体本身并未实际实现从源城市到目标城市的物理迁移。针对每个问题,我们系统性地探讨了相关研究挑战和问题定义,并详细阐述了文献中应用于解决这些问题的关键方法、数据集和评价指标。具体内容概览如图1所示。

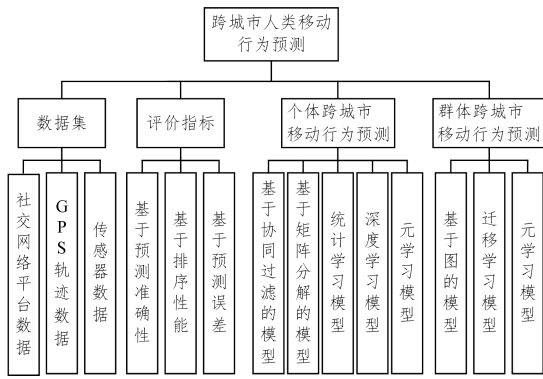


图1 综述内容概要

Fig. 1 Overview of the survey

本文第2章介绍跨城市人类移动行为预测的背景知识,并简要讨论模型所使用的机器学习和深度学习模块;第3章讨论了各种数据集的特性;第4章介绍了普遍用于跨城市人类移动行为预测相关研究中的评价指标;第5章和第6章分别介绍跨城市人类移动行为中的个体跨城市移动行为和群体跨城市移动行为的现有研究;第7章对亟需解决的重要问题进行总结与展望。

## 2 研究背景与方法

### 2.1 相关定义

#### 2.1.1 个体跨城市移动行为预测

根据本文的分类方法,个体跨城市移动行为预测部分主要关注基于位置的社交网络(Location-Based Social Network, LBSN)提供的用户  $u$  的签到记录。每条记录应该包含用户标识符、POI 标识符和类别、位置以及时间戳。用户在城市中访问某个地点时,会在一些 LBSN 平台上进行签到,并留下相应的记录,这些平台包括 Foursquare, Yelp 和 Twitter 等。在研究中,我们将重点探讨用户在家乡城市之外的城市中访问特定场所的行为预测问题和与之相关的解决方法。

**定义 1(签到记录)** 设  $u$  为用户,一条签到记录是一个元组  $r^u = (u, v, c, l, t)$ ,其中  $u, v, c, l, t$  分别表示用户、POI、POI 类别、位置以及时间。在实际中,  $l$  通常采用经纬度的形式。

**问题定义:**对于个体跨城市移动行为预测,首先给定一个目标用户  $u$  和该用户在源城市的签到记录  $D_u$ ,对于用户从未到过的目标城市,个体跨城市移动行为预测的任务是找到目标城市中符合用户兴趣的前  $k$  个 POI。

#### 2.1.2 群体跨城市移动行为预测

人类群体跨城市移动行为预测则侧重于城市时空数据的分析,这些时空数据包含出租车轨迹、自行车轨迹、公交地铁刷卡数据等多模态信息。城市时空数据是由城市中 GPS、移动设备和遥感等所产生的高度相关的数据。传统人群移动行为预测本质上是一个典型的时空预测任务,旨在根据历史时空数据(例如自行车和出租车出行记录)预测全市范围内未来的人群流动情况。而人类群体跨城市移动行为预测则是探讨如何通过源城市丰富的时空数据学习人类的群体移动知识,并将其应用于数据稀疏的目标城市。与个体研究不同的是,

人类群体本身并没有完成在物理意义上的迁移。

**定义 2(时空序列)** 将城市的历史交通数据划分为间隔长度相同的  $T$  个时间片,那么该城市的时空序列表示为  $\{X^1, X^2, \dots, X^T\}$ ,其中  $X^T$  是时间间隔  $T$  的时空信息。

**定义 3(区域)** 根据城市中不同的粒度和语义,对位置有许多定义。许多研究根据经纬度将城市划分为  $M \times N$  的网格图,其中一个网格表示城市的一个区域。

**问题定义:**给定一组具有丰富时空数据的源城市  $c_s$ ,令  $c_t$  为数据不足或稀疏的目标城市。我们的目标是设计一个模型,以自适应地将源城市学习到的人群移动知识转移到目标城市,以便目标城市  $c_t$  的稀疏历史序列  $\{X_{t-k+1}^{c_t}, X_{t-k+2}^{c_t}, \dots, X_t^{c_t}\}$  和源城市的丰富数据  $\{X_{t-k+1}^{c_s}, X_{t-k+2}^{c_s}, \dots, X_t^{c_s}\}$  为目标城市  $c_t$  提供  $X_{t+1}^{c_t}$  的预测。

### 2.2 常用机器学习方法与深度学习学习方法

本节对跨城市相关研究中常用的机器学习方法和经典深度学习学习方法进行简要的概述。

1)协同过滤和矩阵分解。协同过滤和矩阵分解是推荐系统中常用的两种技术,它们用于预测用户对未知项目的偏好。协同过滤主要分为基于用户的协同过滤和基于项目的协同过滤两种,它们分别使用用户和项目之间的相似性来预测用户对项目的偏好。在跨城市移动行为预测中,矩阵分解则是将用户-位置评分矩阵分解成两个低秩矩阵来进行推荐,通过学习这两个矩阵,模型能够捕捉用户和位置之间的潜在特征,从而提高个体跨城市行为预测的准确性。

2)概率生成模型。概率生成模型(Probabilistic Generative Model)是一类用于表示和推断不确定性的统计模型,用于对数据的分布进行建模和学习。它们可以学习数据中的模式和规律,从而生成与原始数据相似的新样本。这些模型考虑到用户签到中的不确定性,并使用概率描述可能的数据分布。JIM<sup>[41]</sup>和 TRM<sup>[45]</sup>等模型在跨城市位置预测问题中通过学习用户签到数据中的统计规律,捕获数据的分布和关系,以便能够生成具有相似统计特征的签到数据。潜在狄利克雷分配(Latent Dirichlet Allocation, LDA)属于概率生成模型的一种,用于分析文本数据和发现文档集中的主题结构。LDA 的目标是根据观察到的文档,推断每个文档中的主题分布以及每个主题的单词分布,从而发现数据中的潜在主题结构,这使得 LDA 常用于文本挖掘、主题分析、文档分类和推荐系统等任务。在人类个体跨城市移动行为预测的研究中,概率生成模型通常会对用户的兴趣以及其余相关因素做出一些假设,但如果假设与实际数据分布不相符,可能导致预测结果失真。相比于深度学习模型,概率生成模型的泛化能力往往比较差,难以处理大规模高维数据,同时特征表示能力有限,难以学习复杂的非线性特征。

3)注意力机制。注意力机制(Attention Mechanisms)在模拟人类感知和认知过程中发挥了关键作用,可以让深度学习模型选择性地关注输入数据中最重要的部分,并将其他部分数据视为背景信息,从而提高模型的性能和效率。在跨城市人类移动行为中,注意力机制被广泛地用于跨城市人类移动行为预测中,分别用来捕获用户的个人偏好和交通流量的历史模式。例如, CityTrans<sup>[46]</sup>通过不同的注意力机制分别

提取用户的长期偏好和短期偏好,以此构成旅行者的兴趣特征,进而对用户的跨城市行为进行预测。

4) CNN, LSTM, ConvLSTM 和图神经网络。卷积神经网络(Convolutional Neural Networks, CNN)通过卷积层和池化层提取图像中的特征,被广泛用于捕获数据中的局部空间相关性。而长短期记忆网络(Long-Short-Term Memory Networks, LSTM)擅长学习视频、时空数据等序列数据中的时间模式,常结合门控循环单元(Gated Recurrent Units, GRU)来捕获序列数据中的长期依赖性,从而解决传统 RNN 中的梯度消失问题。为了进一步处理时空数据,将 CNN 与 LSTM 结合形成 ConvLSTM,用于处理既有空间特性又有时间序列特性的数据。ConvLSTM 使用 LSTM 的记忆单元,但在每个时间步上,其输入和隐藏状态都通过卷积操作来处理,这使得它能够捕获时空数据中的长期依赖关系和局部特征,因而常用于各种时空预测任务中。在人群跨城市移动行为预测中,ConvLSTM 学习时空图像的时间序列表示,以编码时空依赖性,捕捉时空数据的特征。而图神经网络(Graph Neural Networks, GNN)在处理非欧空间数据时表现出良好的性能,在跨城市移动行为预测中,适用于表示社交网络、交通道路网络等复杂关系,捕捉时空图中的全局时空相关性。图卷积网络(Graph Convolutional Networks, GCN)将卷积运算推广到图数据,通过学习一个函数映射  $f(\cdot)$  聚合节点  $v_i$  的特征  $x_i$  和它的邻居特征  $x_j (j \in N(v_i))$  来生成节点  $v_i$  的新表示,在研究中常用于对空间数据建模。Xin 等<sup>[48]</sup> 在 TRAINOR 模型中利用图神经网络聚合用户在家乡城市的签到记录,以便提取用户偏好;同时通过 GCN 对地理信息进行建模,以便对用户的跨城市移动行为进行合理预测。

5) 迁移学习和元学习。迁移学习(Transfer Learning)是一种机器学习方法,其核心思想在于将从源任务中学习的

知识和特征迁移到另一个目标任务中,以提高目标任务的性能。元学习(Meta Learning)是一种学习如何学习的方法,它的目标是使模型能够快速适应新任务。元学习通过在训练中模拟多个不同的源任务,使模型能够泛化到新的目标任务上。迁移学习和元学习都注重模型的泛化性能,但它们的重点略有不同。迁移学习侧重于将人类移动知识迁移到目标城市上,从而更好地理解个体行为模式的变化和群体行为规律。CCTP<sup>[27]</sup> 等模型利用迁移学习将基础模型中学习到的源城市中人群移动的共性知识迁移到目标城市中进行预测。元学习则侧重于训练模型,帮助个体跨城市移动行为预测模型快速调整以适应目标城市环境和行为模式的变化,实现模型的个性化优化,同时帮助群体跨城市移动行为预测模型高效适应目标城市的群体行为规律。类似地,MetaST<sup>[32]</sup> 等模型也先在多个源城市上进行广泛的训练,学习人类移动知识,最后在目标城市上进行相应的预测。总体上,迁移学习关注源城市和目标城市之间存在相关性的情况,元学习适合应对不断变化和快速适应新城市的情形。这两种方法都有助于解决跨城市问题中的样本数据稀缺、领域自适应和快速适应等问题,因此在跨城市人类移动行为预测中得到了广泛的应用。

### 3 数据集

在过去的十年里,我们目睹了大规模数字数据集的涌现,这些数据集不断地揭示了人类的运动模式。在研究跨城市人类移动行为规律时,这些数据集起到了至关重要的作用。数据集中通常包含了多个城市或地区的丰富信息,涵盖了多城市人类移动的时空轨迹和行为模式。本章将讨论各种移动数据集的特性,并介绍一些常用于相关研究中的训练和测试模型的公共数据集,如表 1 所列。

表 1 数据集介绍

Table 1 Introduction of datasets

类型	数据集	评价
社交平台数据	Foursquare	Foursquare 提供了丰富的用户签到数据,可以对个人的地点偏好和移动模式进行分析,尤其适合研究城市热点区域和用户行为模式,有助于跨城市移动行为预测
	Gowalla	Gowalla 平台留下的历史数据常用来分析过往的移动模式和社交网络结构。因为数据是历史性的,可能不太适用于当前的预测
	Brightkite	类似于 Gowalla,其历史数据可用于研究早期的移动模式。相对于更多现代的数据,它的适用性和相关性可能较低
	Yelp	Yelp 的评论和评分数据常用于分析商业点评,而且其位置信息也可用于评估某地点的受欢迎程度,同时辅助估计城市各区域的人群活跃度
	Twitter	Twitter 数据集的大范围用户基础使得其非常适合预测用户的移动行为,为个体跨城市移动行为预测提供大量的可用数据
GPS 轨迹数据	Instagram	Instagram 数据更偏向于视觉内容,可通过分析地理标签和活动数据来研究特定区域的受欢迎程度或旅游模式
	Taxi(NYC, DC, CHI, Porto, Bos, BJ)	出租车 GPS 轨迹数据是研究城市交通和人类移动行为的宝贵资源,有助于理解城市间的交通流和人口迁移模式
	Bike(NYC, DC, CHI)	自行车共享服务的 GPS 数据可以提供关于城市中非机动车模式的洞见
传感器数据	DiDi	DiDi 的网约车服务产生的数据集包含丰富的移动轨迹和需求模式,适合研究城市间和城市内的移动行为和交通流量。其 GAIA 计划中提供的 6 个城市的数据集也提供了丰富的人群移动行为知识
	PEMS	PEMS 数据集提供了加州高速公路上的车辆流量和其他指标,适合交通流量建模和交通预测
	METR-LA	METR-LA 是洛杉矶区域内的交通传感器数据集,其适用于研究道路区域内的交通模式和车辆拥堵情况
	Nav-BJ, Nav-SH, Nav-HZ	Nav 数据集主要包含了北京、上海和杭州 3 个城市主要道路上的平均车速。数据集中的特征矩阵展示了响应时间所有道路的速度,为群体移动模式的预测提供了有力的数据支持

### 3.1 社交网络平台数据

社交媒体上的用户帖子,无论是照片、文本,还是视频,往往伴随着地理位置和时间信息,这些信息通常以地理标记的形式存在。这些时空数据可以被用来还原用户在社交媒体上的发展轨迹,同时获取用户的长期偏好。一些常见的社交媒体平台,如 Twitter,不仅提供了帖子的精确地理位置标签,即纬度和经度,还提供了预定义的地理位置选项,如城市、区域或餐厅。在其他平台上,如 Four-Square 和 Gowalla,用户可以选择预定义的场馆地点,这些场馆地点通常与社会、文化和基础设施相关联,如城市、商店或博物馆。这些场馆地点关联了物理位置信息(纬度和经度)和文本信息,包括对该地点的描述或与该地点相关的活动。这种信息可以根据不同的层次分类,提供有关活动的不同细节,如美食、西餐厅或中餐厅。这种地理位置和时间数据在研究人类移动行为时具有重要作用,其提供了深入了解用户活动和兴趣的机会。用户的签到记录即地理标记一般包含了用户的标识符、位置标识符(类别或位置作为字符串)、时间、经纬度以及相关文本(推文、图片等),但是,许多数据集中虽然包含了许多的位置信息,但只有少部分的位置存在用户的签到记录,且不同用户的签到频率存在很大的差距。总体而言,这些数据集中的数据可能是结构化的、半结构化的或者非结构化的,因此,它实际上是异构的,数据具有空间分布不平衡、时间间隔不均匀、层次结构不显著和稀疏性等特征。

常见的社交网络平台数据集,如 Gowalla 和 Brightkite,都可以在其官方网站上免费下载获得。在已经不再使用的平台 Brightkite 中,用户可以登录 POI,以查看目前谁在附近以及之前谁去了该 POI。该数据集包含了 2008 年 4 月到 2010 年 10 月的共计近 450 万次签到记录,同时还包含用户的社交朋友信息,约有 6 万个节点和 22 万条边。Gowalla 是一个基于位置的社交网络平台,用户通过其官方网站在相关场所进行签到,签到程序描述了用户标识符、位置标识符、时间戳以及经纬度;另外,数据集中还包含该用户的社交朋友信息,共约 20 万个节点和 100 万条边。该数据集包含了 2009 年 2 月到 2010 年 10 月这段时间中超过 600 万次的签到。

Foursquare<sup>[57]</sup>作为目前最受欢迎且最具代表性的地理社交网络平台,包含了纽约、洛杉矶、芝加哥等多个城市的用户签到数据。Yelp<sup>[58]</sup>作为来源于地理社交网站自行发布的数据集,其网站上有专门针对个别场所的页面,比如餐馆或酒吧,其用户社区主要活跃在大城市地区。这两个公共数据集都能够对用户的偏好和行为模式进行有效分析。

Twitter 提供了几个开放的数据集,其中的位置通常被表示为平台建议的语义点(如纽约帝国大厦),或用户输入(如 Home),或经纬度对。同时, Twitter 支持 Foursquare 和 Gowalla 等第三方位置共享服务,这些服务的用户可以选择在 Twitter 上共享他们的登录信息。带有地理标记的推文可以直接使用 Twitter APIs 进行检索。Yin 等<sup>[44]</sup>提供了一个 Twitter 数据集,描述了从 2010 年 9 月到 2011 年 1 月的 114508 个用户数据。

Instagram 数据集中公开账户的帖子和标签地点可以

用于分析流行趋势和地理行为模式,进而准确预测个体的跨城市移动行为。

### 3.2 GPS 轨迹数据

GPS 数据是通过全球定位系统(Global Positioning System, GPS)接收器收集的人类时空移动路径信息。这些数据记录了移动对象的经度、纬度以及时间戳等时空数据,通常以地理位置坐标序列的形式存储。GPS 接收器存在于许多日常生活工具中,如手机、车辆、船舶和一些可穿戴设备中。在手机上,一些需要用户位置的应用程序(如谷歌地图)会在使用时激活 GPS 接收器。在车辆上, GPS 设备一般在车辆启动时自动打开,将车辆位置以每几秒钟的频率发送到服务器。GPS 接收器的精度从几厘米到几米不等,这取决于设备的质量和系统产生的误差<sup>[59]</sup>。常见的 GPS 数据是一组元组( $u, t, lat, lon$ ),其中  $u$  表示用户,  $t$  表示当前时间戳,  $lat$  和  $lon$  分别表示该位置的纬度和经度。为了减少错误并提取有意义的语义, GPS 数据需要几个预处理任务,对于没有明确定义语义位置的时空点的密集序列,通过特定的预处理技术来推断其语义<sup>[60-62]</sup>。

Moreira 等<sup>[63]</sup>提供了在葡萄牙波尔图的出租车旅行数据,其中的点包含纬度、经度和指示行程何时开始的时间戳。数据大约每 15 秒收集一次。该数据集为每次旅行提供了一些辅助信息,如旅行的类型(例如,从中央发送,向操作员要求,向司机请求),出租车离开的位置,以及乘客的电话号码的标识符。纽约市出租车和豪华轿车委员会收集了从 2009 年开始在该市运营的黄色和绿色出租车的数据集。该数据集提供了有关接送日期/时间和地点、旅行距离、分项票价、费率类型、付款类型和司机报告的乘客数量的信息。芝加哥、波士顿和华盛顿特区等城市在官方网站都提供了相关的出租车数据集。

纽约市的共享单车站点被记录在 Lyft 的花旗自行车提供的数据集 NYCBIke<sup>[64]</sup>中,其中每一条记录都详细记录了行程的起始和结束站点,同时提供了这些站点的坐标信息。类似的其他城市的公开数据集,也都能在相关网站上下载,如华盛顿<sup>[65]</sup>和芝加哥<sup>[66]</sup>。

DiDi 的 GAIA 计划<sup>[67]</sup>提供了数个城市的 GPS 轨迹数据集,包括成都、西安和深圳等 6 个城市,其中包含了城市中的基于滴滴的出租车轨迹数据计算的城市交通指数数据和平均行驶速度等字段。

当然,随着网络的快速发展,越来越多的数据包含了用户敏感信息,部分数据集在发布时采用隐私保护机制,确保数据的安全使用<sup>[68]</sup>。

### 3.3 传感器数据

各个城市的交通路网中往往会布置大量的传感器,例如磁吸式传感器、微波传感器和摄像头等。这些传感器实时监控相应路段的交通流量、速度和占有率等关键指标,并将数据传输到交通管理中心进行分析和使用。数据集中的数据都以结构化的形式进行存储和管理,通常以表格或数据库的形式呈现。每个数据点包含了时间戳、位置信息以及具体的交通参数数值。

PEMS 是基于传感器网络收集的交通流量数据集,包含了数百个传感器在高速公路上提供的实时和历史数据。这些

数据以每 5 min 为间隔提供,包括交通流量、速度、占有率等信息。该数据集可以在官方网站下载获得。

METR-LA 是另一个包含交通流量速度的数据集,它在洛杉矶地区收集,采用了传感器、摄像头和其他传感器设备,提供了详细的交通数据,包括交通流量、速度以及车辆轨迹等。

Nav-BJ, Nav-SH 和 Nav-HZ 分别收集了 2019 年 1 月 1 日至 7 月 1 日中国北京、上海和杭州主要道路上的平均车速。举例来说,Nav-BJ 数据集中包含两组可用数据:邻接矩阵和特征矩阵。邻接矩阵表示 1 362 条道路之间的连接情况;  $52128 \times 1362$  特征矩阵包含 8990 个时间步,其中行数据表示相应时间所有道路的速度。

## 4 评价指标

本章回顾在相关的跨城市人类移动行为预测文献中采用

的主流评价指标。在实验过程中,数据集通常按照时间戳分为训练集和测试集,其中训练集用于学习模型参数,而测试集则用于评估模型的性能。为了评估模型性能,通常采用信息检索领域常用的评价指标。根据不同的评价视角,将现有的评价指标大致分为 3 类,即基于预测准确性的指标、基于排序性能的指标和基于预测误差的指标。

### 4.1 基于预测准确性的指标

当将用户位置预测问题作为信息检索任务时,可以使用基于预测准确性的评价指标,如 Precision, Recall, Acc@N, MAP@N 和 HitRatio 等。各指标的计算和注释见表 2。综合来看,Acc@N 和 HitRatio 主要侧重于排名前 N 个结果的准确性,Precision 和 Recall 则同时关注模型预测结果的正确覆盖率,而 MAP@N 则考虑了预测结果中排序的准确性和完整性。根据具体的任务需求和重点,可以选择合适的评价指标来评估跨城市人类移动行为预测模型的性能。

表 2 基于预测准确性的评价指标

Table 2 Accuracy-based evaluation metrics for human mobility prediction

评价指标	计算方法	描述
Precision	$Precision = \frac{TP}{TP + FP}$	TP 为真正例数量,FP 是假正例数量。Precision 表示分类器预测为正样本的样本中实际为正样本的比例。Precision 的值越大,表示预测准确率越高。在个体跨城市移动行为预测中,Precision 可以评估模型对于用户兴趣的准确性,即预测的前 k 个 POI 中有多少与用户实际兴趣相匹配
Recall	$Recall = \frac{TP}{TP + FN}$	FN 是假负例数量。Recall 表示正样本被分类器识别出来的比例。Recall 的值越大,表示预测准确率越高。在研究中,Recall 用于评估模型对用户兴趣的覆盖程度,即模型是否能够找到所有用户可能感兴趣的位置
Acc@N	$Acc@N = \frac{TP + TN}{TP + TN + FP + FN}$	TN 表示真负例数量。Acc@N 表示前 N 个预测结果中正确预测的比例。对于一个测试样本,首先按照模型预测概率从高到低排序,然后计算前 N 个预测结果的准确率。Acc@N 的值越大,表示前 N 个预测结果准确率越高。Acc@N 则衡量在模型推荐的前 N 个位置中,预测结果与用户实际兴趣的匹配程度,可以更直观地评估模型在前 N 个预测结果中的准确性
MAP@N	$MAP@N = \frac{\sum_{i=1}^N AP_i}{ L }$	MAP@N 表示前 N 个预测结果的平均准确率。对于一个测试样本,首先按照模型预测概率从高到低排序,然后计算前 N 个预测结果的准确率,并求出它们的平均值。MAP@N 的值越大,表示前 N 个预测结果的平均准确率越高。在个体跨城市移动行为预测中,MAP@N 可以帮助评估模型的整体预测质量,考虑到了不同位置的推荐结果
HitRatio	$HitRatio = \frac{1}{S} \sum_{i=1}^S hit(i)$	S 表示样本数目,在人类个体跨城市移动行为中可以理解为用户的数量。hit(i) 表示第 i 个用户是否包含在模型预测的列表中。若预测中,则其值为 1; 否则为 0。在个体跨城市移动行为预测中,HitRatio 可以反映模型推荐结果命中用户兴趣的比例

### 4.2 基于排序性能的指标

一些个体跨城市移动行为预测相关研究对用户在每个候选位置的签到概率进行排列,以产生最终结果,因此经常使用基于排序性能的评价指标来衡量模型位置预测的性能。基于排名的主要指标包括 Normalize Discounted Cumulative Gain

(NDCG)和 Mean Reciprocal Rank(MRR)。同时,4.1 节中的 MAP 也可以视为基于排序性能的评价指标。每个评价指标的计算和备注可见表 3。NDCG 主要关注预测结果的排序质量和相关性程度,而 MRR 则注重预测结果中第一个正确项目的位置。

表 3 基于排序性能的评价指标

Table 3 Ranking-based evaluation metrics for human mobility prediction

评价指标	计算方法	描述
NDCG@K	$NDCG@K = \frac{DCG}{iDCG}$ $DCG@K = \sum_{i=1}^k \frac{2^{rel(i)} - 1}{\log_2(i+1)}$	NDCG 是在 DCG 的基础上进行计算的,iDCG 为 DCG 中的最大值,k 表示列表中基本真实项的排名,rel(i) 表示在位置 i 处的结果的分级相关性。NDCG 值越大,表示模型预测排名越准确。在跨城市人类移动行为预测中,NDCG 可以帮助评估模型对于用户兴趣的排序质量,即预测结果的相关性程度和排名顺序的准确性
MRR	$MRR = \frac{1}{ T } \sum_{i=1}^{ T } \frac{1}{rank(i)}$	MRR 是用于衡量排名模型性能的指标,它主要关注实际结果在预测结果中的位置。MRR 值越大,表示模型预测排名越准确。在跨城市人类移动行为预测中,MRR 强调了推荐结果中第一个正确项目出现的位置,即命中速度

### 4.3 基于预测误差的指标

基于预测误差的评价指标用于比较不同预测模型的性能,并帮助选择最佳模型或进行模型改进。它们提供了对模型在预测过程中的误差量化的度量,使我们能够更好地理解模型的准确性和预测误差。常见的评价指标有 Root Mean Square Error (RMSE), Mean Absolute Error (MAE), Mean

Absolute Percentage Error (MAPE)。这些指标的计算和注释见表 4。

在人类群体跨城市移动行为预测中, RMSE 强调预测结果中大误差的影响;与 RMSE 不同, MAE 对误差的大小并不敏感,更注重预测误差的绝对值大小;而 MAPE 更重视相对误差的影响。

表 4 基于预测误差的评价指标

Table 4 Error-based evaluation metrics for human mobility prediction

评价指标	计算方法	描述
RMSE	$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$	RMSE 计算的是预测值与真实值之间差异的平方和的均值的平方根。其中, $n$ 是样本数量, $y_i$ 是真实值, $\hat{y}_i$ 是预测值。RMSE 的值越小, 表示模型预测误差越小。在人类群体跨城市移动行为预测任务中, RMSE 可以量化预测误差的平均量级, 对大误差更为敏感
MAE	$MAE = \frac{1}{n} \sum_{i=1}^n  y_i - \hat{y}_i $	MAE 计算的是预测值与真实值之间差异的绝对值的平均值。MAE 的值越小, 表示模型的预测误差越小。在人类群体跨城市移动行为预测任务中, MAE 可以提供对平均绝对误差的评估, 能够更好地表示模型的平均预测准确度
MAPE	$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left  \frac{y_i - \hat{y}_i}{y_i} \right $	MAPE 计算的是预测值与真实值之间百分比误差的平均值。MAPE 的值表示平均相对误差的百分比。较低的 MAPE 值, 表示模型的预测相对误差较小。在研究中, MAPE 用于评估群体跨城市移动行为预测模型对于不同规模变化的预测效果

## 5 个体跨城市移动行为预测

不同城市之间, 由于发展情况不同, 因此收集到的数据在质量和数量上存在巨大差异。同时, 对个人隐私的关注和各种数据收集政策的加强, 导致高质量数据的总量不断减少。更为重要的是, 不同地区对隐私的政策存在差异, 导致流动性数据出现了显著偏差。在一些城市规模较小、人口数量有限的冷启动城市中, 依赖于充足训练数据的预测模型无法直接展现出良好性能。城市的特征由公共特征和特有特征组成, 其中公共特征包括 POI 类别和用户组的表示。通过学习有效的公共特征表示, 可以使源城市的知识应用于目标城市, 从而解决跨城市移动行为预测中数据不足的问题。这涉及将不同城市的特征进行映射, 以增强它们在相似性方面的可比性。人类个体跨城市移动行为预测是一个复杂的问题, 需要综合考虑可用数据、城市之间的相似性、用户行为模式等因素。

对用户进行跨城市移动行为预测与很多应用都存在相关性, 不仅可以提升游客和新居民的城市体验, 还在城市管理方面发挥着重要作用。通过指导人流、交通和资源分配, 个体跨城市移动行为预测系统有助于提高城市的效率和可持续性, 减少交通拥堵, 提高空气质量, 以及优化资源利用。这种系统有望成为城市规划者的强大工具, 可用于改进城市的整体运行, 从而使城市更具吸引力, 吸引新居民和游客, 刺激经济增长。因此, 跨城市用户移动行为预测系统对于城市管理者来说, 不仅提供了一种更智能、更可持续化的城市管理方式, 还有助于提高城市的吸引力和竞争力。

此外, 预测用户在新城市的 POI 访问活动也具有很大的挑战性。不同城市的 POI 数据通常以不同的格式、结构和语义存储, 这导致了数据的异质性, 使得跨城市数据整合和特征表示变得更加困难。同时, 用户在目标城市中的签到记录非常稀疏, 因此缺乏足够的信息来进行准确的预测。解决这一问题通常需要从用户在源城市的签到数据中提取知识并进行迁移。如图 2 所示, 不同城市间的特征差异是另一个关键

问题。城市特征差异通常涵盖城市间的文化、地理、经济等多个方面, 这些差异显著影响用户的行为, 使得用户的兴趣可能发生漂移<sup>[69]</sup>, 从而增加了位置预测的复杂性。例如, 在文化差异方面, 不同城市拥有独特的文化和习俗, 这可能直接影响用户的短期兴趣和偏好。在现代化城市, 如上海和深圳, 用户可能更倾向于购物和娱乐; 而在历史悠久的城市, 如南京和西安, 用户可能更关注历史遗迹和景点。用户的真实兴趣通常在城市间的公共特征上进行转移, 而这与城市的特有特征无关。用户的签到活动会受到时空习惯以及类别偏好等因素的影响。因此, 更好地理解 and 考虑城市间的特征差异对于提高预测模型的性能至关重要。相关跨城市用户移动行为预测方法、评估方法及数据集如表 5 所列。特别地, 也有研究者不局限于具体的位置预测模式, 利用常数有界算法等方法实现新城市中的区域预测, 即预测外地用户可能感兴趣的区域<sup>[69]</sup>。同时, 也有研究者不局限于 POI 的位置推荐模式, 利用常数有界算法等方法实现新城市中的区域推荐, 即向外地用户推荐其可能感兴趣的区域<sup>[70]</sup>。

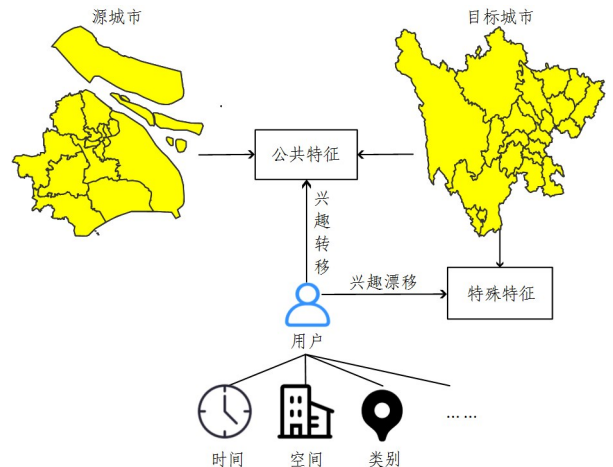


图 2 个体跨城市移动预测示意图

Fig. 2 Overview of individual-level cross-city human mobility prediction

表5 人类个体跨城市移动行为预测模型列表  
Table 5 Individual-level cross-city human mobility prediction models

文献	模型	方法	评估方法	数据集	年份
[33]	UPS-CF	协同过滤	Precision	Foursquare Gowalla	2013
[34]	PR-UIDT	矩阵分解	HitRatio NDCG@k	Tencent Yelp	2019
[35]	TAP-F	张量分解 HITS 算法	RMSE MAE	Foursquare	2017
[36]	CRTCF	协同过滤 潜在狄利克雷分配	Recall	Gowalla	2013
[37]	BPTFSLR	概率张量分解 贝叶斯正则化	Precision Recall MAP@N	Foursquare	2014
[38]	CRCF	协同过滤	MRR Recall	Yelp Foursquare	2016
[39]	CTLM	主题模型 迁移学习	F1 MAP NDCG@k	Foursquare Twitter	2019
[40]	LSARS	概率生成模型 潜在狄利克雷分配	Acc@N Precision	Yelp Foursquare	2017
[41]	JIM	概率生成模型	Acc@N	Foursquare Twitter	2015
[42]	Geo-SAGE	稀疏加性生成模型	Recall	Foursquare Twitter	2015
[43]	JFT	潜在因素模型 潜在狄利克雷分配	Precision NDCG@k	—	2017
[44]	ST-LDA	概率生成模型	Acc@N	Yelp Foursquare	2016
[45]	TRM	概率生成模型	Acc@N	Foursquare Twitter	2016
[46]	CityTrans	迁移学习 注意力机制	Acc@N NDCG@k	Yelp	2023
[47]	ST-TransRec	深度神经网络 迁移学习 基于密度的重采样	Recall Precision@k NDCG@k MAP@N	—	2020
[48]	TRAINOR	图神经网络 神经主题模型 注意力机制	Recall MAP@N	—	2021
[49]	ACCAC	自动编码器 生成对抗网络	Recall NDCG@k	Yelp Foursquare	2022
[50]	HOPE	长短期记忆网络 自适应注意力网络	Acc@N	Yelp Foursquare	2021
[51]	UPTDNet	循环神经网络	MRR Recall	Gowalla Foursquare	2023
[71]	SH-CDL	概率矩阵分解 受限玻尔兹曼机 深度信念网络	Acc@N MAE	Yelp Foursquare	2017
[72]	CAPTOR	条件随机场 记忆网络	HitRatio Precision NDCG@k	Foursquare —	2022
[73]	METAODE	元学习 神经常微分方程	HitRatio NDCG@K	Foursquare	2021
[74]	CHAML	元学习 课程学习 难分样本挖掘	HitRatio NDCG@K	Baidu	2021
[75]	AXOLOTL	元学习 图注意力网络	Precision NDCG@K	Gowalla Foursquare	2022

如今,个体跨城市移动行为预测主要面临着3个挑战。

1)数据稀疏性:由于目标城市缺乏用户的签到记录,预测模型必须依赖源城市的数据来理解用户的行为。然而,源城市的数据可能无法充分捕捉到用户的全部偏好和行为模式,导致在目标城市的推荐准确性下降。2)冷启动问题:对于在目标城市没有任何签到记录的新用户,预测他们在该城市的兴趣点变得尤其困难。3)用户兴趣漂移:用户的兴趣可能随着时间和环境的变化而发生变化,这表示过去的签到记录不一定能完全准确地反映用户当前的兴趣。因此,如何有效地捕捉用户兴趣漂移并进行准确的预测是一个挑战。

## 5.1 基于协同过滤的模型

协同过滤是一类常用于推荐系统的算法,其基本思想是通过分析用户与项目(兴趣点)之间的历史交互行为,发现用户之间的相似性或项目(兴趣点)之间的相似性,从而实现针对用户的个性化推荐。在协同过滤算法中,相似性的计算通常使用余弦相似性或皮尔逊相关系数等方法。一旦获得相似性矩阵,就可以通过加权平均或其他方法为目标用户推荐项目(兴趣点)。但经典的协同过滤算法无法向用户推荐新区域中的POI,因此需要对原有的算法进行扩展以使其适应新的问题场景。之前的人类个体跨城市移动行为预测工作中提出

了基于协同过滤的方法,分别利用用户和城市间兴趣点之间的相似性个性化地为目标用户推荐访问地点。特别是 Ference 等<sup>[33]</sup>将用户相似性以及社交关系引入协同过滤框架中,并结合地理邻近度排除距离过远的位置。通过这种方式,实现了目标用户偏好和社交连接的建模,捕捉用户间的隐性连接和朋友间的相似的行为模型,进而为外地用户提供位置推荐。但如果用户和其社交圈还未访问过某些区域,就很难基于社交关系进行新的位置预测。不同于此,Zheng 等<sup>[36]</sup>在协同过滤框架中融合了潜在狄利克雷分配,以挖掘不同地区中相似的访问模式和 POI,并将这些主题分布作为特征计算用户和兴趣点之间的相似度,以预测目标用户未来是否会访问 POI。但在区域之间的访问模式差异性较大的情况下,LDA 难以准确捕捉移动行为模式。另外,LDA 模型可能会引入额外的计算复杂度,对于大规模数据集而言可能会产生性能瓶颈。Zhang 等<sup>[38]</sup>将用户偏好细分为长期偏好和短期偏好,即用户对 POI 内容的偏好以及用户对 POI 本身的偏好,前者与 POI 位置无关,而后者受用户位置和 POI 位置间的距离限制,这样可以使模型更灵活地适应用户的不同兴趣。在此基础上,通过内容推荐器和位置推荐器的独立建模分别获取用户对 POI 内容和距离的评分,将两者组合获取最终预测结果。

近年来,基于协同过滤的模型在人类个体跨城市移动行为预测问题中很少再被使用,其虽然能够通过计算城市间用户和兴趣点之间的相似性在一定程度上迁移用户的偏好等特征,实现用户的外地推荐,但当面对用户在新城市上缺乏足够的历史数据即处理冷启动问题时,其推荐效果往往较差。另外,协同过滤在考虑城市之间差异性时表现不佳,因为它主要依赖用户或兴趣点之间的相似性,而不是城市的特定特征,难以对城市的特有特征进行合理的考量。最后,大多数协同过滤算法都属于静态模型,模型中的假设关系在不同时间是固定的。然而,用户的访问行为往往会随着时间的推移而表现出复杂的时间模式和周期性性质,例如工作日和周末用户往往会展现出不同的生活模式。

## 5.2 基于矩阵分解的模型

矩阵分解是人类个体跨城市移动行为预测领域中的一项流行技术。在本预测问题中,不同城市的用户位置签到矩阵都被分解为两个低秩矩阵,这两个矩阵分别表示用户和 POI 的潜在向量,然后由两个合适的向量做内积来拟合用户对新城市中候选位置的偏好。已有工作提出了基于矩阵分解的方法,利用用户的反馈来模拟他们的偏好,从而有效预测他们在新城市中的访问位置。Ding 等<sup>[34]</sup>根据旅行者中兴趣漂移和转移共存的现象提出了一种可扩展的矩阵分解框架,其中用户向量被划分为独立于城市的部分和另一个独立的非城市部分,而 POI 则被表示为本地人和旅行者两个独立向量,如图 3 所示。通过这种方式对用户兴趣的转移和漂移现象进行了表示,模拟了旅行者在新城市中的签到行为,通过低秩矩阵分解有效缓解了模型过拟合并提升泛化能力。但即使分解为低秩矩阵,矩阵分解方法在处理目标城市中稀疏的数据时效果也可能下降。Yin 等<sup>[71]</sup>也利用概率矩阵分解模拟用户对每个签到记录的概率生成过程,以挖掘本地用户和游客的偏好。




图 3 矩阵分解模型示例图

Fig. 3 Example diagram of matrix factorization model

与矩阵分解相比,张量分解作为一种推广到高维数据的方法,在个体跨城市移动行为预测中具有更强的表达能力。张量分解可有效处理用户、POI 和城市等多个维度的交互信息,从而更全面地捕捉用户行为的多样性。Zhao 等<sup>[37]</sup>通过贝叶斯概率张量分解模型挖掘不同地理区域的人们的社会维度,即用户访问行为、社交关系和场所相似性,同时挖掘每个城市中的本地兴趣社区,再通过跨区域社区匹配,在城市所在的城市以外的城市预测其访问地点。然而,当其中一维度数据缺失或稀疏时,预测准确性可能会受到影响。类似地,Ying 等<sup>[35]</sup>设计了一个上下文感知的张量分解模型,将用户的历史位置数据映射到三维张量,分别代表用户、POI 类别和时段。其中,张量的每个条目存储特定用户在特定时间段生成的特定 POI 类别的签到数量,进而捕获时间感知的用户偏好。最终,结合基于 HITS 的模型推断用户的 POI 评级,以进行合理预测。

张量分解在模型的表达能力上具有更多优势,能够处理多维度数据,但同时也带来了更高的计算复杂度和对数据的依赖性。而矩阵分解在处理稀疏数据和新城市问题时的表现尽管并不如张量分解灵活,但在计算资源有限的情况下可能更实用。然而,对于新城市或者缺乏历史数据的城市,两者仍然面临着冷启动问题。换言之,它们在冷启动场景中并不灵活。另外,矩阵分解模型仍然难以对城市之间的异质性进行建模,进而难以有效捕捉城市之间的特定差异,因为城市之间的差异不仅仅表现在用户和兴趣点的特征上。

## 5.3 统计学习模型

统计学习模型通常将个体跨城市移动行为预测问题抽象为分类问题,这类问题基于现有的机器学习方法(如概率生成模型、判别式模型、自动编码器等模型方法)可以很好地解决。这些模型利用统计学原理建模用户行为,以更好地理解用户在不同城市中对兴趣点的访问模式,具有较强的可解释性。Wang 等<sup>[42]</sup>提出利用地理稀疏加性生成模型提取潜在主题来表征用户的兴趣。模型根据单个用户访问的空间项目及其相关内容来推断用户对一组主题的兴趣分布,最终提取用户内在兴趣、游客偏好和公众偏好这 3 个因素来模拟用户访问 POI 的决策过程。模型的优势在于能够发掘用户兴趣背后的

潜在主题,为 POI 预测提供了一种可解释的机制,但并不足以捕捉用户兴趣随时间变化而动态变化的过程,缺少用户动态的环境适应。Yin 等<sup>[41]</sup>通过概率生成模型,联合建模时间影响、地理社会影响、内容语义以及口碑效应,模拟用户选择访问的 POI 决策的联合影响。进一步,Yin 等<sup>[44]</sup>又建立时空 LDA 模型对用户个人偏好和公共人群偏好建模,以缓解数据稀疏性,并学习跨城市用户的兴趣漂移现象。这些模型可解释性都较强,但训练复杂度较高,需要更多的计算资源。Li 等<sup>[39]</sup>通过建立主题迁移模型,区分了所有城市共享的共同主题和每个城市的具体主题,并通过共同主题的媒介将用户的真实兴趣从源城市转移到目标城市,解决用户和 POI 不匹配的问题;此外,引入了每个城市区域的空间影响力,以满足用户对目标城市的可达性需求。同样地,Wang 等<sup>[40]</sup>提出潜在概率生成模型 LSARS 来适应用户兴趣驱动和人群情绪,从而模拟用户在外地场景中签到的决策过程。它可以从空间项目和用户评论的内容中学习位置感知和情感感知的个人兴趣。另外,Lin 等<sup>[43]</sup>使用产品级随机化方法将潜在因素模型 LFM 和 LDA 进行桥接,将文本评论和数字评分联系起来以提供个性化的跨城市预测。但是,LFM 和 LDA 的结合会导致模型参数和结构更加复杂。Qin 等<sup>[49]</sup>通过去噪自动编码器学习用类别层次知识增强的预训练 POI 嵌入,并引入生成对抗网络结合双自动编码器来探索用户的家乡偏好和外地偏好之间的非线性映射函数。Xin 等<sup>[72]</sup>利用条件随机场 CRF 对 POI 之间的空间仿射关系进行建模,使得空间相关 POI 嵌入可以在 POI 之间合并空间信息并保留 POI 的固有属性。

图 4 展示了在个体跨城市移动行为预测中,概率生成模型的图表示结构。虽然统计学习模型的实现相对简单,但这类模型往往需要大量的重叠用户数据进行学习,在缺乏足够信息的情况下,模型可能难以准确地预测用户兴趣。最重要的是,这类统计学习模型通常会从用户签到数据或社交网络中选择一组人工确定的特征。这种特征工程在过程中通常不仅需要领域专家的繁琐工作和额外的知识,而且模型的泛化能力往往也较差。




图 4 概率生成模型示例图

Fig. 4 Example diagram of probability generation model

#### 5.4 深度学习模型

在个体跨城市移动行为预测中,深度学习模型近年来得到广泛关注和应用。深度学习模型通过多层神经网络学习用户和兴趣点之间的复杂非线性关系,能够更好地捕捉数据中的高阶特征,提高预测的准确性。

Xu 等<sup>[46]</sup>则利用自注意力机制分别描述用户的长期和

短期偏好,并将其融合成旅行者表征,最后结合 POI 的属性和信息进行旅行者在周边城市的访问预测。Li 等<sup>[47]</sup>利用深度神经网络对用户和 POI 的复杂交互进行建模,通过预测其上下文来学习 POI 的文本嵌入,进而结合迁移学习技术将用户的长期兴趣转移到目标城市,利用基于密度的重采样技术平衡城市间的 POI 分布,为用户预测其在新城市可能会访问的 POI。在数据稀疏的城市,模型存在一定的过拟合风险。不同于此,Xin 等<sup>[48]</sup>采用 G-GNN 模型和注意力网络对用户家乡签到数据进行编码和聚合,获得用户家乡偏好,利用神经主题模型 NTM 发现通用的旅行意图,并通过另一个注意力网络整合发现的意图和用户的家乡偏好来总结用户特定的意图;然后,利用矩阵分解学习用户和 POI 的潜在表示,获得用户外地偏好,同时利用 GeoConv 捕获 POI 的地理信息;最后,偏好转移模块接收用户家乡偏好嵌入并内置 MLP 映射从家乡到外地的非线性关系。Sun 等<sup>[50]</sup>采用网络结构来捕获区域内的人群偏好和 POI 转变,以实现对用户兴趣漂移的建模,同时采用具有时间门控的 LSTM 来捕获短期偏好,并利用非对称 SVD 导出用户长期偏好;最后,利用自适应注意力机制,以合理的方式平衡长期和短期偏好,从而缓解数据稀疏性,实现精确的跨城市移动行为预测。Yang 等<sup>[51]</sup>则基于双循环神经网络来模拟游客当前城市的偏好转移以及不同用户角色之间的漂移,以此学习用户短期偏好;对于长期偏好,采用映射函数和用户相似度计算来实现偏好从游客家乡的转移以及个体用户之间的漂移。通过双循环网络模拟偏好转移,自然地整合漂移与偏好转变,保持用户行为的连续性。但依赖于有序序列数据,其对于非时序化或动静混合数据可能表现不佳。

这些深度学习模型的优势在于能够进行更复杂的非线性建模,自动学习高阶特征,以及通过潜在表示学习更好地捕捉城市、用户和兴趣点之间的抽象关系,提升了预测的准确程度。然而,深度学习模型也并非没有挑战:它们对大量数据的需求较高,这在新城市数据匮乏的情况下可能导致过拟合;同时,复杂的模型结构和训练过程更需要大量的计算资源。

#### 5.5 元学习模型

跨城市预测方法通常要求两个城市之间存在大量重叠用户,但当两个城市之间仅有少量或者不存在重叠用户,且目标城市和源城市中的共享数据有限时,该如何对数据稀缺的目标城市中的用户进行移动行为预测?基于迁移学习的方法可能无法完全克服预训练的影响,导致城市间信息传递不准确,无法捕捉目标城市的用户偏好等特征。与此不同,元学习范式作为机器学习算法,在小样本学习等问题中取得了显著成功。因此,元学习范式在人类个体跨城市移动行为预测中得到了广泛应用。

引入元学习模型的研究成果,为应对预测系统中的冷启动和数据稀缺性等问题提供了一种有效的解决途径。通过在多个源城市的数据上进行训练,元学习模型从中学习人类签到行为中的相似性和差异性的知识,并将这一知识迁移到数据稀缺的目标城市,以提高推荐性能。在实际应用场景中,元学习模型通过参数共享的机制降低了对大量目标城市数据的依赖,减轻了计算负担,同时提高了模型的计算效率。Tan

等<sup>[73]</sup>将神经微分方程融入到元学习范式中,在桥接转换城市不变信息和利用 GRU-ODE-Bayes 建模时空影响后,采用元学习机制来优化模型中的参数,即通过在多个源城市上的元训练实现对目标城市上模型参数的微调,但是,常微分方程的数学性质可能增加模型理解和实现的难度。Chen 等<sup>[74]</sup>将课程学习和难样本挖掘纳入元学习范式,考虑城市级和用户级层面的硬度,按由易到难的训练顺序提高模型的泛化能力和学习效率。其中,如何定义和挑选“难样本”至关重要。Gupta 等<sup>[75]</sup>使用位置推荐和社交预测学习地元学习过程,联合最小化特定城市的社交、位置预测损失来学习模型参数,有助于捕获不同城市用户行为的普遍特征。但是,该方法依赖于高质量的社交和位置数据。

元学习范式能够很好地解决人类个体跨城市移动行为预测中的数据稀疏和冷启动问题,但其性能可能受到城市选择的影响。不合适的源城市集合可能导致模型学到的经验难以有效泛化到目标城市。元学习模型的训练和推断过程可能相对复杂,尤其是在处理大规模数据时,需要大量计算资源和时间。

## 6 群体跨城市移动行为预测

城市中的群体移动行为预测在交通规划、风险评估等城市管理实践中具有重要作用。一些数据驱动的研究<sup>[76-77]</sup>旨在挖掘不同城市内部的多源异质数据,通过深度学习模型发现城市人群分布的时空特征,从而预测城市不同区域的人群流量。然而,这些研究往往依赖于所研究城市的大规模时空数据,而对于那些数据匮乏的新城市,这些预测模型并不能发挥出良好的性能。

尽管各城市均拥有可观测的时空数据,但不同城市之间的发展水平存在差异,且部分城市数据收集成本较高,因此在数据规模和多样性上存在不均衡现象。对于数据相对匮乏的目标城市,需要借助其他城市丰富的时空数据来预测目标城市内部人类群体的移动趋势。

准确预测人类群体跨城市移动行为对城市规划和旅游业发展等具有重要意义。首先,精准地预测人类群体移动轨迹能够为城市规划和交通建设提供有力指导。通过深入了解

不同城市之间的人类移动需求和流动分布,可以有效规划城市交通网络,进行道路扩建,并科学合理地布局交通设施,最大程度地提升交通效率,减轻交通拥堵,从而改善城市出行环境。其次,这对人民的日常生活产生了深远影响。同时,该研究也有助于为居民提供更为精准、可靠的出行信息,协助他们合理规划出行时间和方式,减少通勤时间和压力,提高出行的便利性和舒适度,进而提升生活质量。此外,群体跨城市移动行为预测对于城市交通管理的重要性不可忽视。通过对道路和各站点的实时监测,以及精准预测人类群体跨城市移动行为,交通管理部门可以灵活调度各类交通资源,优化交通信号控制,提高交通运输的安全性、稳定性和运输效率。这有助于降低交通事故风险,缓解交通拥堵,提升交通系统的应急响应能力,为公众出行提供更加安全畅通和可靠的服务。总体而言,人类群体跨城市移动行为预测研究对推动城市可持续发展,提升人民生活质量,以及优化交通管理水平,具有深远的现实意义,可为城市交通运输系统的发展和居民出行提供有益指导。

目前,群体跨城市移动行为预测的研究主要面临着 3 个挑战。1) 数据异质性和稀疏性:不同城市的时空数据通常具有不同的结构、格式和语义,因此,数据异质性使得跨城市数据整合和特征表示变得复杂。同时,目标时空数据通常是稀疏的,即在某些时间和地点缺乏数据,这可能导致模型训练的不稳定性和低准确性。2) 城市特征差异化:在进行跨城市研究时,必须充分认识到不同城市间在地理位置、文化习俗、气候条件、经济发展水平等方面的差异。这些因素共同作用,塑造了居民的出行习惯和人口分布的特征。如何在模型中巧妙地融入并准确表征这些城市之间的差异成了一项巨大的挑战,尤其是在缺少大规模、已标准化的城际比较数据的背景下更为明显。3) 知识迁移和领域自适应:从一个城市向另一个城市迁移知识和模型需要解决领域自适应问题,因为不同城市的时空数据分布和特性可能差异显著。如何有效地迁移模型以适应目标城市的特征是一个重要问题,尤其是对于没有足够数据的目标城市而言。常见的人群跨城市移动行为预测研究的流程图如图 5 所示。

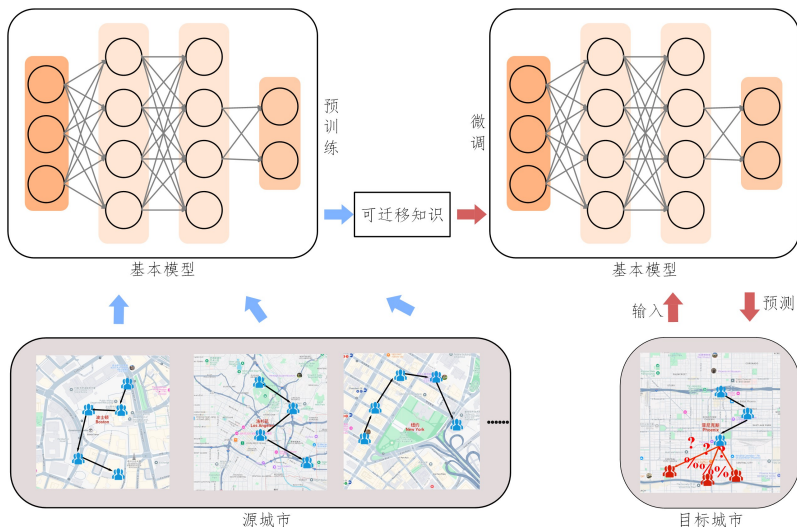


图 5 人类群体跨城市移动行为预测概览

Fig. 5 Overview of group-level cross-city mobility prediction

相关人群跨城市移动行为预测模型、评估方法及数据集 如表 6 所列。

表 6 人类群体跨城市行为预测模型列表  
Table 6 Group-level cross-city human mobility prediction models

文献	模型	方法	评估方法	数据集	年份
[27]	CCTP	迁移学习 生成对抗网络	MAE RMSE MAPE	—	2022
[32]	MetaST	元学习 LSTM 卷积神经网络	RMSE	Taxi(NYC,DC,CHI,Porto,BOS) Bike(NYC,DC,CHI)	2019
[78]	DastNet	对抗学习 迁移学习	MAE RMSE MAPE	PEMS04 PEMS07 PEMS08	2022
[79]	TEEPEE	迁移学习 图神经网络	MAE RMSE MAPE	Nav-BJ Nav-SH	2021
[80]	ST-GFSL	元学习 图神经网络	RMSE MAE	DiDi METR-LA PEMS-BAY	2022
[81]	DAGN	迁移学习 图神经网络	MAE RMSE MAPE	PEMS03 PEMS04 PEMS08 等	2023
[82]	Ada-STGCN	迁移学习 图卷积神经网络	MAE RMSE MAPE	PEMS03 PEMS04 PEMS08	2023
[83]	ADA	迁移学习 边缘计算 图卷积神经网络	RMSE MAE	PEMS04	2021
[84]	CCMHC	迁移学习	RMSE MAPE	—	2022
[85]	RegionTrans	迁移学习 ConvLSTM	RMSE	Bike(NYC,DC,CHI)	2019
[86]	TL-DCRNN	迁移学习 扩散卷积神经网络 DCRNN	MAE RMSE MAPE	—	2021
[87]	CrossTReS	迁移学习 特征网络 加权网络	RMSE MAE	Taxi(NYC,DC,CHI) Bike(NYC,DC,CHI)	2022
[88]	MGAT	元学习 迁移学习 注意力机制	RMSE	Taxi(NYC,DC,CHI,Porto,BOS) Bike(NYC,DC,CHI)	2022
[89]	STAN	迁移学习 注意力机制	RMSE MAE	Taxi(NYC,BJ) Bike(NYC,CHI) Chengdu	2022
[91]	TrafficTL	迁移学习 图神经网络	MAE RMSE MAPE	Nav-BJ Nav-SH Nav-HZ	2023
[92]	ST-DAAN	迁移学习 注意力机制 ConvLSTM	MAE	Taxi(NYC,BJ) Bike(NYC,CHI)	2022
[93]	NodeTrans	迁移学习 图神经网络	MAE RMSE MAPE	DiDi PEMSD4 PEMSD8 PEMS-BAY METR-LA 等	2022
[94]	DATGCN	迁移学习 图卷积神经网络	MAE RMSE MAPE	PEMS04 PEMS08	2021
[95]	MTN	多任务学习	RMSE MAE	DiDi	2021
[96]	ARG-STNet	元学习 ConvLSTM	MAE RMSE MAPE	Taxi(NYC,DC,Porto) Bike(NYC,DC,CHI)	2021
[97]	MetaTP	元学习 插值网络 时空记忆网络	RMSE MAE	—	2021

## 6.1 基于图的模型

在人群跨城市移动行为预测中,基于图的模型通常利用城市道路网络的拓扑结构来构建图的结构,自然捕捉城市内部和不同城市之间的空间关系。这样的模型将城市划分为

节点,将道路连接表示为图的边,形成一个时空图。常见的图神经网络(GNN)和时空图卷积网络(ST-GCN)等模型被广泛用于处理这类数据。Tang 等<sup>[78]</sup>提出了一种可转移框架,将图表示学习和对抗域适应融合,以学习不同城市间的通用

特征,然后通过 GRU 网络对时空流量数据进行建模,捕获时间相关性。但如果源城市和目标城市之间差异过大,对抗域适应可能不足以捕捉所有相关特征。Huang 等<sup>[79]</sup>首先采用图聚类方法将交通网络划分为多个子图,并将子图与 GCN 结合来训练基于数据丰富的源域的模型,然后将训练好的模型应用于数据稀缺的目标领域。模型高效地对地理数据进行了细分,充分利用了源城市地大量的时空数据获取人群的移动知识。Lu 等<sup>[80]</sup>将时空图模型与元学习结合,实现小样本学习,通过时空图中更加复杂和动态的节点特征学习城市中的人群移动知识。特别地,Ouyang 等<sup>[81]</sup>开发了跨城市图结构学习模块,以捕获跨城市的节点对相关性,从而实现城市间时空信息的动态聚合,为跨城市泛化提供强力支持。此外,他们提出了图重建损失,以强制学习图和先验图之间的结构一致性,协助城市间的知识转移。但需要注意的是,图重建的一致性要求可能会限制模型在捕捉城市间结构性差异方面的能力。

时空图卷积网络在处理时空数据时展现出卓越的性能,在人群跨城市移动行为预测中,每个节点代表城市的一个交叉口或道路段,而边则表示它们之间的连接关系。时空图卷积网络能够有效捕捉城市道路网络中的时空动态特征,从而提高流量预测的准确性。Yao 等<sup>[82]</sup>运用时空图卷积网络从源城市和目标城市的道路网络中提取时空依赖性,并结合对抗域适应方法,以学习具有判别性和可转移性的特征。Chen 等<sup>[83]</sup>采用具备边缘计算的时空图卷积网络来提取交通流的时空相关性,并将其作为特征提取模块参与预训练过程。

基于图的模型在一定程度上具有跨城市泛化的能力。通过学习城市间的共享特征和相似性,模型可以更好地适应不同城市的人群移动行为预测任务,减轻数据稀疏性的问题。然而,在跨城市移动行为预测任务中,基于图的模型对城市间的异构性较为敏感,需要一定的领域知识或特征的预处理方法来适应这种异构性。

## 6.2 迁移学习模型

在人群跨城市移动行为预测领域,迁移学习模型作为一项强有力的工具,为解决目标城市数据稀缺的人群行为预测问题提供了崭新的思考方式。这一类模型不仅能够充分利用源城市丰富的数据,而且可以通过迁移学习的机制将源城市积累的知识传递至目标城市,从而提升预测性能。面对目标城市数据有限的情况,迁移学习模型通过有效地利用源城市的信息,弥补了目标城市数据稀缺性带来的不足,为人群行为预测提供了一种创新而可行的解决途径。这种知识迁移的机制不仅使模型在目标城市上更具泛化能力,还有助于提高预测准确性,为城市规划、交通管理等提供了有益的支持。

迁移学习模型能够显著提升模型的泛化能力。通过在源城市大规模数据集上进行预训练,模型能够学到更丰富、更一般的时空特征,从而更好地适应目标城市的人群移动行为预测任务。这种泛化能力的提高对于数据稀缺的目标城市尤为关键,因为在这种情况下,传统模型可能难以从有限的数据中学到有效的模式。Chen 等<sup>[84]</sup>提出一种跨城市跨模式的迁移学习方法,首先探索区域功能和道路网络的相似性,以过滤掉可转移性较低的区域。但要注意,这个过程可能会忽视一些

有价值的信息。然后,利用交通流的时间相关性,以动态方式匹配与目标区域高度相关的源区域,进而实现人群跨城市行为预测。Wang 等<sup>[85]</sup>研究了一种用于数据稀缺时空交通预测的迁移学习方法。首先学习了一个匹配函数来计算域相似性;然后堆叠 ConvLSTM 和 Conv2D 层来提取时空依赖性;最后提出了一种优化算法,利用匹配函数来迁移学到的知识。Mallick 等<sup>[86]</sup>将应用于高速公路预测的扩散卷积循环神经网络 DCRNN 扩展至迁移学习方法中。TL-DCRNN 边缘化位置特定信息,并学习跨多个子图的时空模式。因此,模型权重的训练方式使其可以对相似但不可见的图进行泛化,这种能力可用于对不可见的高速公路网络进行预测。但某些特定的数据分布或特征会对模型产生难以预估的影响,导致迁移效果不一。Huang 等<sup>[79]</sup>提出了一种使用图神经网络进行交通预测的迁移学习方法,在图结构上将从源城市学习到的空间信息传递到目标城市,同时需要保证源城市和目标城市之间的图结构拥有较高的一致性。Jin 等<sup>[87]</sup>提出了一种基于微调的跨城市迁移学习框架,该框架自适应地重新加权源区域以协助目标区域的微调,因而往往需要较为精确的先验知识来确保加权的有效性。

这些方法虽然能够有效迁移知识,却忽略了不同城市之间的数据分布差异以及城市特征差异,因而直接在差异巨大的城市之间迁移人群移动知识,可能会导致负迁移的情况。Mo 等<sup>[88]</sup>设计了一个由空间注意力和多头注意力机制组成的自适应迁移模块,从多个源城市训练的多粒度特征中自动选择最合适的特征迁移到目标城市,减小城市间的数据分布差异。若无法准确衡量和匹配城市之间的差异,可能会导致人群移动知识的负迁移,进而导致模型性能下降。Fang 等<sup>[89]</sup>采用对抗的方式捕获时空数据中可转移的空间特征,并利用注意力机制捕获细粒度迁移学习的关键时间特征,提升知识迁移效果。Tang 等<sup>[78]</sup>将对抗域适应技术应用于基于图的网络上,通过空间编码器将原始节点特征映射到节点嵌入,域分类器学习域嵌入,并与时间预测器中的流量数据融合,以进行跨城市的流量预测。类似地,Ouyang 等<sup>[81]</sup>也利用域对抗技术减轻城市间空间和时间维度的分布差异,进而通过注意力机制从全局节点嵌入中自适应地提取可转移的知识,从而全面利用全局信息在目标城市上进行预测。Yao 等<sup>[82]</sup>采用对抗域适应技术学习判别性和源城市时空数据中的可转移特征。具体来说,域分类器旨在区分源域和目标域的数据表示,时空数据表示学习网络充当生成器,通过学习域不变表示来欺骗域分类器。Li 等<sup>[90]</sup>提出了一种基于特征的域适应框架,通过经验模态分解(Empirical Mode Decomposition, EMD)提取交通数据特征。然后,通过最小化最大平均差异(Maximum Mean Discrepancy, MMD)损失来减少源域和目标域之间的分布差异,以促进知识转移。Huang 等<sup>[91]</sup>利用周期性的传输范式减少源城市和目标城市的数据分布之间的差异引起的负传输,同时采取图重建技术纠正目标城市数据的缺陷。Wang 等<sup>[92]</sup>将源城市和目标城市的时空数据映射到同一个嵌入空间内,实现初始的域对齐。接着,为了进一步减小两个域之间的分布差异,采用了域适应策略;特别是在几个指定的域特定层上,通过加入域差异惩罚项来强制两个域的平均嵌入

在分布上更为接近。此外,鉴于城市时空数据通常涉及复杂的空间相关性,还引入了一种全局注意力机制,该机制能够使模型更有效地捕捉到扩展的空间依赖性,从而提高模型处理时空数据的能力。Yin等<sup>[93]</sup>通过聚类分析提取源城市的普遍时空模式,并将这些模式映射至目标城市,以增强目标城市流量预测的准确性和鲁棒性。其适用于目标域数据稀缺的场景,能有效利用源城市的丰富数据来优化目标城市的预测模型。Zhao等<sup>[94]</sup>提出一种新颖的基于领域对抗的图神经网络,其核心在于应用了领域适应技术,使得网络能够将在数据丰富的源道路网络中学习到的知识迁移并应用于数据稀缺的目标道路网络。此外,模型内嵌了一个域鉴别器,其目的是在域转移过程中促使网络产生无关于特定域的通用特征,这有助于降低目标网络中数据不足或数据丢失情况的影响。但要注意对抗训练可能不稳定,需要细致的调参来保证模型的域适应能力和通用特征生成。Zhang等<sup>[95]</sup>注重通过多任务学习架构来挖掘和利用不同城市间的空间依赖性和时间规律性。多任务学习的应用使得网络可以在完成多城市交通流预测的同时共享及协同学习各城市间的相关信息,以此提升单个城市流量预测的性能。

迁移学习利用源城市的数据进行预训练,模型可以更充分地利用已有信息,从而在目标城市数据较为有限的情况下也能够取得较好的预测效果。这对于解决数据不足的问题具有重要的实际意义。然而,当迁移学习应用于跨城市预测任务时,现有部分研究建立在静态知识迁移的基础上,忽略了城市间交通数据模式随时间动态变化的事实。同时,模型还需要考虑不同城市之间的数据分布差异,无法直接将源城市上学习到的知识迁移到目标城市中,避免造成负迁移现象。最后,部分研究<sup>[83-85]</sup>将从源城市学到的知识应用到目标城市时,通常使用替换或简单组合即相加或串联的方式,完全忽略了所转移的知识与目标城市自身所包含的特征之间的关系,可能会导致更重要的特征信息被遗漏。

### 6.3 元学习模型

不同于迁移学习模型,元学习模型的本质在于学习如何学习,其目标是通过在不同任务之间学习的方式,使得模型能够更迅速、有效地适应新任务。在人群跨城市移动行为预测问题中,元学习模型展现出更为卓越的时空动态适应性,能够更全面地捕捉城市人群流量变化的复杂性和非线性。这种先进的学习框架使得模型在面对新的任务时,能够更加灵活地调整自身参数,从而提高在目标城市的预测性能。元学习模型的时空动态适应性赋予了它更强大的能力,有助于更准确地反映人群行为的多样性和变化趋势,为跨城市移动行为预测领域提供了一种新颖的学习范式。Tian等<sup>[96]</sup>设计了一种具有注意力机制的一阶元学习方法 Reptile, 通过从源域学习初始参数,并提出一种生成机制,将长期时空特征从源域转移到稀缺数据的目标域。与旨在学习通用初始化以适应任何新任务的元学习算法不同,该模型通过考虑多个源城市和目标城市之间的不同分布相似性,在特定目标城市上取得了更出色的性能。同时,模型需要平衡足够快的学习速率来适应新的任务,且需要保证算法的高度适应性,在面对城市间数据极差差异时依然有效。Lu等<sup>[80]</sup>设计了一个时空元知识学习器,

以提取时空域的节点级元知识,通过参数共享机制实现知识的迁移。同样地,Yao等<sup>[32]</sup>设计了一种元学习范式,首先对来自多个源城市的时空特征进行编码,然后对它们进行聚类,以生成更稳定的共同模式,以此作为元知识迁移到目标城市。Zhong等<sup>[97]</sup>构建了一个名为 MetaTP 的元学习框架,除了基础流量预测网络之外,模型的核心在于元知识的传递,这需要足够的源数据来构建有效的元知识。通过快速适应元知识传递过程,实现了从数据丰富的源区域到数据稀少的目标区域的知识迁移,从而在目标区域上获得更好的泛化。此元学习框架的实施,进一步得益于两个记忆网络,它们能够捕捉跨区域的空间和时间维度的全局信息模式,强化了元学习在时间序列预测中的应用效果。

为了获得良好的初始化,并同时从多个源城市提取目标城市的有用信息,目前的研究主要倾向于通过元学习模型传递知识。该方法的核心思想在于从多个任务中找到一组初始参数,以便在面对任何新任务时都能够实现良好的泛化。尽管先前的研究<sup>[79]</sup>提出将多个源城市编码的时空特征聚类作为更稳定的元知识进行迁移,但它未能实现基于源城市数据量的自动学习和自适应地增加元知识聚类的数量。这一不足导致在一定程度上忽略了各个城市之间的数据分布差异,从而影响了模型的性能。

## 7 总结与展望

本调查提出了关于人类跨城市移动行为的视角,分别从个体和群体两个层面展开讨论,即人类个体跨城市移动行为预测和人类群体跨城市移动行为预测两个层面。对于每个任务,我们强调了需要应对的相关挑战。最后,描述了每个任务的相关解决方案。从描述中,我们可以了解到跨城市人类移动行为预测相关任务近年来开始大量使用深度学习方法。迁移学习和元学习框架也逐渐开始在跨城市领域中的应用,并展现出巨大的潜力。在迁移学习方面,研究人员利用源城市的数据来帮助提升目标城市的预测性能,以应对不同城市之间数据分布的差异性。这种方法不仅可以减少数据标记的成本,还能提高模型的泛化能力和稳定性。而元学习框架则通过在训练过程中模拟快速适应不同城市环境的能力,使得模型能够更好地适应新的城市数据并实现个性化预测。未来,我们需要进一步关注如何优化迁移学习和元学习算法,以更好地应对跨城市场景中的相关任务,并探索如何结合两种方法来实现更精准的城市间数据预测和分析。这些方法的应用将为跨城市领域带来更加精细化和有效的研究手段,值得未来重点关注。

文中对跨城市人类移动性研究的概述显示,现有的解决方案存在一些局限,许多相关问题需要在未来加以解决。目前的研究需要应对以下挑战。

1) 数据异质性和一致性。不同城市之间的时空数据在结构和语义上存在显著差异,这涉及了数据的格式、数据字段的定义以及不同数据来源之间的差异。为应对这一挑战,需要采取数据整合与转换的技术手段,以将多样化的城市数据统一标准化为一个一致的格式。这要求设计和应用数据对齐、融合和清洗算法,同时考虑跨城市数据集成和一致性维护的

技术策略,从而确保数据的可比性和有效性,为进一步的比较和分析提供可靠的基础。

2)城市特征差异化。城市之间的差异涵盖地理位置、气候、文化和经济等方面。这些差异会对人群移动行为产生影响。因此,研究者需要深入研究如何在模型中考虑这些城市特征。例如,可引入城市特定的特征变量来充分表征不同城市的独特性,或者利用城市特定的权重来调整优化模型,使其更好地适应不同城市的数据特点。运用数据挖掘和深度学习方法,结合特征工程和模型调优等方法,以提高模型的准确性和泛化能力,从而更好地预测和分析跨城市移动行为。

3)时空数据分布不均衡。城市内的时空数据分布通常是不均匀的,某些地区或时间段可能有丰富的数据,而其他地区或时间段可能非常稀疏。为解决这一问题,需要处理数据不平衡性,以确保模型在所有地区和时间段都具有稳定的性能。例如,采用样本加权或集成学习方法平衡数据分布,以及结合异常检测和插值技术填充数据缺失。通过这些技术手段,可以提高模型的鲁棒性和泛化能力,更好地应对城市内时空数据分布的不均衡情况。

4)隐私和伦理问题。大规模的位置数据可能涉及用户隐私问题。为解决这一问题,需要研究如何采取隐私保护措施,例如数据匿名化、数据脱敏和访问控制,以确保数据的安全使用。

5)可解释性和可解释机器学习。在城市决策方面,模型的可解释性非常重要。为此,需要研究如何开发可解释的机器学习模型,以帮助城市决策者理解模型的预测结果并做出明智的决策。可以借助可视化技术展示模型推理过程和决策路径,促进决策者对模型的信任和理解。通过这些技术手段,可以提高模型的透明度和可解释性,为城市决策提供支持和指导。

6)知识迁移和领域自适应。将知识从一个城市迁移到另一个城市需要解决领域自适应问题,这意味着需要在不同城市之间转移模型和特征知识,同时适应不同的数据分布和城市特性。研究者需要研究有效的迁移学习方法,以实现模型的可迁移性。这包括开发领域自适应算法,如深度特征对齐、实例重用等,以适应不同城市的数据分布和特性。另外,可以利用迁移学习中的特权学习、多任务学习等技术,提升模型的泛化能力和可迁移性。通过这些技术手段,可以有效应对城市之间知识迁移的挑战,实现模型在不同城市间的可迁移性和性能提升。

7)跨城市应用和决策支持。研究需要更加关注如何将模型的输出集成到城市规划和管理中。这包括如何开发决策支持系统,将模型的结果转化为可操作的政策和措施,以解决城市的实际问题,如交通拥堵、紧急响应和城市可持续性。具体来说,可以制定决策支持系统架构,集成模型输出到系统中,采用可视化技术呈现结果,实现决策过程的透明化和追溯性。此外,结合智能优化算法和模拟仿真技术,优化决策方案,并通过实验验证模型在解决实际问题中的有效性。通过这些技术手段,可以更好地支持城市规划和管理,推动城市可持续发展 and 优化决策流程。

**结束语** 在城市和互联网飞速发展的今天,越来越多的

人类移动数据集涌现,以供研究者发掘人群移动行为的规律。本文从人类个体跨城市移动行为预测和人类群体跨城市移动行为预测两个方面分别对现有研究进行分类,阐述了各类研究方向的定义以及所面临的挑战,并依据所使用的技术方法、数据集和评价指标进行总结分析。

研究者们使用了多种机器学习方法对跨城市人类移动行为进行预测。传统的协同过滤、矩阵分解以及深度学习方法能够缓解跨城市问题中存在的稀疏性和冷启动等问题;迁移学习和元学习的快速发展,不仅极大地缓解了数据稀疏等问题,也能为城市特征差异化、时空数据分布不均衡和知识迁移等问题提供有效的解决途径。未来的跨城市人类移动行为预测不仅需要解决这些研究中的实际问题,同时也需要注重模型的可解释性,并在隐私和伦理问题之间达到更好的平衡。

## 参考文献

- [1] GUADAGNO L. Human mobility in a socioenvironmental context: Complex effects on environmental risk [M] // Identifying Emerging Issues in Disaster Risk Reduction, Migration, Climate Change and Sustainable Development: Shaping Debates and Policies. Berlin: Springer, 2017: 13-31.
- [2] RUKTANONCHAI N W, FLOYD J R, LAI S, et al. Assessing the impact of coordinated COVID-19 exit strategies across Europe [J]. *Science*, 2020, 369(6510): 1465-1470.
- [3] KRAEMER M, YANG C, GUTIERREZ B, et al. The effect of human mobility and control measures on the COVID-19 epidemic in China [J]. *Science*, 2020, 368(6490): 493-497.
- [4] LAI S, FARNHAM A, RUKTANONCHAI N W, et al. Measuring mobility, disease connectivity and individual risk: a review of using mobile phone data and mHealth for travel medicine [J]. *Journal of Travel Medicine*, 2019, 26(3): taz019.
- [5] JIANG R, SONG X, FAN Z, et al. Deepurban-momentum: An online deep-learning system for short-term urban mobility prediction [C] // Proceedings of the AAAI Conference on Artificial Intelligence. AAAI, 2018: 784-791.
- [6] SONG X, ZHANG Q, SEKIMOTO Y, et al. Prediction and simulation of human mobility following natural disasters [J]. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 2016, 8(2): 1-23.
- [7] WANG Y, TAYLOR J E. Coupling sentiment and human mobility in natural disasters: a Twitter-based study of the 2014 South Napa Earthquake [J]. *Natural Hazards*, 2018, 92: 907-925.
- [8] SIMINI F, BARLACCHI G, LUCA M, et al. Deep Gravity: Enhancing mobility flows generation with deep neural networks and geographic information [J]. arXiv: 2012. 00489, 2020.
- [9] ZHANG J J, WANG Y B, LONG M S, et al. Predictive Recurrent Networks for Seasonal Spatiotemporal Data with Applications to Urban Computing [J]. *Chinese Journal of Computers*, 2020, 43(2): 286-302.
- [10] VELENTZAS P, CORRAL A, VASSILAKO-POULOS M. Big spatial and spatio-temporal data analytics systems [J]. *Transactions on Large-Scale Data and Knowledge-Centered Systems XLVII: Special Issue on Digital Ecosystems and Social Networks*, 2021, 47: 155-180.

- [11] CHEN J, XIAO Z, WANG D, et al. Stay of Interest: A dynamic spatiotemporal stay behavior perception method for private car users[C]//Proceedings of the IEEE 21st International Conference on High Performance Computing and Communications. IEEE, 2019: 1526-1532.
- [12] KHAIDEM L, LUCA M, YANG F, et al. Optimizing transportation dynamics at a city-scale using a reinforcement learning framework [J]. IEEE Access, 2020, 8: 171528-1541.
- [13] OLIVER N, LEPRI B, STERLY H, et al. Mobile phone data for informing public health actions across the COVID-19 pandemic life cycle [J]. Science Advances, 2020, 6(23): eabc0764.
- [14] ZHAO P, LUO A, LIU Y, et al. Where to go next: A spatio-temporal gated network for next poi recommendation [J]. IEEE Transactions on Knowledge and Data Engineering, 2020, 34(5): 2512-2524.
- [15] QIAN T, LIU B, NGUYEN Q V, et al. Spatiotemporal representation learning for translation-based POI recommendation [J]. ACM Transactions on Information Systems (TOIS), 2019, 37(2): 1-24.
- [16] HUANG L, MA Y, WANG S, et al. An attention-based spatio-temporal lstm network for next poi recommendation [J]. IEEE Transactions on Services Computing, 2019, 14(6): 1585-1597.
- [17] 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, 2014, 16(2): 865-873.
- [18] WU Y, LI K, ZHAO G, et al. Personalized long-and short-term preference learning for next POI recommendation [J]. IEEE Transactions on Knowledge and Data Engineering, 2020, 34(4): 1944-1957.
- [19] SHI M H, SHEN D R, KOU Y, et al. Next Point-of-interest Recommendation Approach with Global and Local Feature Fusion [J]. Ruan Jian Xue Bao/Journal of Software, 2023, 34(2): 786-801.
- [20] ZHAO W Z, YUAN G, ZHANG Y M, et al. Multi-view Fused Spatial-temporal Dynamic Graph Convolutional Network for Urban Traffic Flow Prediction [J]. Ruan Jian Xue Bao/Journal of Software(in Chinese), 2024, 35(4): 2204-2225.
- [21] 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 (YAC). IEEE, 2016: 324-328.
- [22] WU Y, TAN H, QIN L, et al. A hybrid deep learning based traffic flow prediction method and its understanding [J]. Transportation Research Part C: Emerging Technologies, 2018, 90: 166-180.
- [23] FENG N, GUO S N, SONG C, et al. Multi-component spatial-temporal graph convolution networks for traffic flow forecasting [J]. Ruan Jian Xue Bao/Journal of Software, 2019, 30(3): 759-769.
- [24] YANG B, SUN S, LI J, et al. Traffic flow prediction using LSTM with feature enhancement [J]. Neurocomputing, 2019, 332: 320-327.
- [25] KIM Y J, HONG J S. Urban traffic flow prediction system using a multifactor pattern recognition model [J]. IEEE Transactions on Intelligent Transportation Systems, 2015, 16(5): 2744-2755.
- [26] MA X D, ZHAO F, REN P K. Visual Analysis of Resident Behavior Characteristics Based on Spatio-Temporal Data[J]. Computer Engineering, 2023, 49(2): 105-111.
- [27] WU Q, HE K, CHEN X. Deep transfer learning across cities for mobile traffic prediction [J]. IEEE/ACM Transactions on Networking, 2021, 30(3): 1255-1267.
- [28] GUO B, LI J, ZHENG V W, et al. Citytransfer: Transferring inter-and intra-city knowledge for chain store site recommendation based on multi-source urban data[C]//Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies. ACM, 2018: 1-23.
- [29] LIU Y, GUO B, ZHANG D, et al. Knowledge transfer with weighted adversarial network for cold-start store site recommendation [J]. ACM Transactions on Knowledge Discovery from Data(TKDD), 2021, 15(3): 1-27.
- [30] LI J, GUO B, WANG Z, et al. Where to place the next outlet? harnessing cross-space urban data for multi-scale chain store recommendation[C]//Proceedings of the 2016 ACM International Joint Conference on Pervasive and Ubiquitous Computing: Adjunct. ACM, 2016: 149-152.
- [31] QIU D, WANG Y, ZHAO Y, et al. CityCross: Transferring Attention-based Knowledge for Location-based Advertising Recommendation[C]//2022 23rd IEEE International Conference on Mobile Data Management(MDM). IEEE, 2022: 254-261.
- [32] YAO H, LIU Y, WEI Y, et al. Learning from multiple cities: A meta-learning approach for spatial-temporal prediction [C]//The World Wide Web Conference. ACM, 2019: 2181-2191.
- [33] FERENC G, YE M, LEE W C. Location recommendation for out-of-town users in location-based social networks[C]//Proceedings of the 22nd ACM International Conference on Information & Knowledge Management. ACM, 2013: 721-726.
- [34] DING J, YU G, LI Y, et al. Learning from hometown and current city: Cross-city POI recommendation via interest drift and transfer learning[C]//Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies. ACM, 2019: 1-28.
- [35] YING Y, CHEN L, CHEN G. A temporal-aware POI recommendation system using context-aware tensor decomposition and weighted HITS [J]. Neurocomputing, 2017, 242: 195-205.
- [36] ZHENG N, JIN X, LI L. Cross-region collaborative filtering for new point-of-interest recommendation [C]//Proceedings of the 22nd International Conference on World Wide Web. ACM, 2013: 45-46.
- [37] ZHAO Y L, NIE L, WANG X, et al. Personalized recommendations of locally interesting venues to tourists via cross-region community matching [J]. ACM Transactions on Intelligent Systems and Technology(TIST), 2014, 5(3): 1-26.
- [38] ZHANG C, WANG K. POI recommendation through cross-region collaborative filtering [J]. Knowledge and Information Systems, 2016, 46: 369-387.
- [39] LI D, GONG Z, ZHANG D. A common topic transfer learning model for crossing city POI recommendations [J]. IEEE Transactions on Cybernetics, 2018, 49(12): 4282-4295.
- [40] WANG H, FU Y, WANG Q, et al. A location-sentiment-aware recommender system for both home-town and out-of-town users

- [C]//Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. ACM, 2017: 1135-1143.
- [41] YIN H, ZHOU X, SHAO Y, et al. Joint modeling of user check-in behaviors for point-of-interest recommendation [C]// Proceedings of the 24th ACM International on Conference on Information and Knowledge Management. ACM, 2015: 1631-1640.
- [42] WANG W, YIN H, CHEN L, et al. Geo-SAGE: A geographical sparse additive generative model for spatial item recommendation [C]//Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. ACM, 2015: 1255-1264.
- [43] XIAO L, MIN Z, YONG F Z. Joint factorizational topic models for cross-city recommendation [C]//Web and Big Data: First International Joint Conference. Springer, 2017: 591-609.
- [44] YIN H, ZHOU X, CUI B, et al. Adapting to user interest drift for poi recommendation [J]. IEEE Transactions on Knowledge and Data Engineering, 2016, 28(10): 2566-2581.
- [45] YIN H, CUI B, ZHOU X, et al. Joint modeling of user check-in behaviors for real-time point-of-interest recommendation [J]. ACM Transactions on Information Systems (TOIS), 2016, 35(2): 1-44.
- [46] XU S, XU J Q, LI B H, et al. Predicting Where You Visit in a Surrounding City: A Mobility Knowledge Transfer Framework Based on Cross-City Travelers [C]//Database Systems for Advanced Applications. Springer, 2023: 334-350.
- [47] LI D, GONG Z. A deep neural network for crossing-city poi recommendations [J]. IEEE Transactions on Knowledge and Data Engineering, 2020, 34(8): 3536-3548.
- [48] XIN H, LU X, XU T, et al. Out-of-town recommendation with travel intention modeling [C]//Proceedings of the AAAI Conference on Artificial Intelligence. AAAI, 2021: 4529-4536.
- [49] QIN L, LIAN D. Adversarial Cycle-Consistent Autoencoder for Category-Aware Out-of-Town Recommendation [C]//International Conference on Knowledge Science, Engineering and Management. Springer International Publishing, 2022: 501-515.
- [50] SUN H, XU J, ZHOU R, et al. HOPE: a hybrid deep neural model for out-of-town next POI recommendation [J]. World Wide Web, 2021, 24(5): 1749-1768.
- [51] YANG T, GAO Y, HUANG Z, et al. UPTDNet: A User Preference Transfer and Drift Network for Cross-City Next POI Recommendation [J]. International Journal of Intelligent Systems, 2023, 2023: 1-17.
- [52] PAN S J, YANG Q. A survey on transfer learning [J]. IEEE Transactions on Knowledge and Data Engineering, 2009, 22(10): 1345-1359.
- [53] ZHUANG F, QI Z, DUAN K, et al. A comprehensive survey on transfer learning [C]//Proceedings of the IEEE. IEEE, 2020: 43-76.
- [54] ZHUANG F Z, LUO P, HE Q, et al. Survey on Transfer Learning Research [J]. Ruan Jian Xue Bao/Journal of Software, 2015, 26(1): 26-39.
- [55] FINN C, ABBEEL P, LEVINE S. Model-agnostic meta-learning for fast adaptation of deep networks [C]//International Conference on Machine Learning. PMLR, 2017: 1126-1135.
- [56] HOSPEDALES T, ANTONIOU A, MICAEL-LI P, et al. Meta-learning in neural networks: A survey [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2021, 44(9): 5149-5169.
- [57] FENG J, LI Y, ZHANG C, et al. Deepmove: Predicting human mobility with attentional recurrent networks [C]//Proceedings of the 2018 World Wide Web Conference. ACM, 2018: 1459-1468.
- [58] LUCA M. Reviews, reputation, and revenue: The case of Yelp.com [M]//Com (March 15, 2016). Harvard Business School NOM Unit Working Paper, 2016: 12-16.
- [59] CARLSON J. Mapping large, urban environments with GPS-aided slam [D]. Carnegie Mellon University, 2010.
- [60] FENG Z, ZHU Y. A survey on trajectory data mining: Techniques and applications [J]. IEEE Access, 2016, 4: 2056-2067.
- [61] ZHENG Y. Trajectory data mining: an over-view [J]. ACM Transactions on Intelligent Systems and Technology (TIST), 2015, 6(3): 1-41.
- [62] ZHENG Y, CAPRA L, WOLFSON O, et al. Urban computing: concepts, methodologies, and applications [J]. ACM Transactions on Intelligent Systems and Technology (TIST), 2014, 5(3): 1-55.
- [63] MOREIRA-MATIAS L, GAMA J, FERREIRA M, et al. Predicting taxi-passenger demand using streaming data [J]. IEEE Transactions on Intelligent Transportation Systems, 2013, 14(3): 1393-1402.
- [64] AN R, ZAHNOW R, POJANI D, et al. Weather and cycling in New York: The case of Citibike [J]. Journal of Transport Geography, 2019, 77: 97-112.
- [65] SCHMIEDESKAMP P, ZHAO W. Estimating daily bicycle counts in Seattle, Washington, from seasonal and weather factors [J]. Transportation research record, 2016, 2593(1): 94-102.
- [66] ZHOU X. Understanding spatiotemporal patterns of biking behavior by analyzing massive bike sharing data in Chicago [J]. PloSone, 2015, 10(10): e0137922.
- [67] Data retrieved from Didi Chu Xing [EB/OL]. (2017-11-09) [2023-12-08]. <https://gaia.didichuxing.com>.
- [68] TIAN F, WU Z Q, LU L F, et al. A Sample Based Personalized Differential Privacy Mechanism for Trajectory Data Publication [J]. Chinese Journal of Computers, 2021, 44(4): 709-723.
- [69] XIE R, CHEN Y, XIE Q, et al. We know your preferences in new cities: Mining and modeling the behavior of travelers [J]. IEEE Communications Magazine, 2018, 56(11): 28-35.
- [70] PHAM TA, LI X, CONG G. A general model for out-of-town region recommendation [C]//Proceedings of the 26th International Conference on World Wide Web. ACM, 2017: 401-410.
- [71] YIN H, WANG W, WANG H, et al. Spatial-aware hierarchical collaborative deep learning for POI recommendation [J]. IEEE Transactions on Knowledge and Data Engineering, 2017, 29(11): 2537-2551.
- [72] XIN H, LU X, ZHU N, et al. CAPTOR: A Crowd-Aware Pre-Travel Recommender System for Out-of-Town Users [C]//Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval. ACM, 2022: 1174-1184.
- [73] TAN H, YAO D, HUANG T, et al. Meta-learning enhanced

- neural ODE for citywide next POI recommendation [C]// 2021 22nd IEEE International Conference on Mobile Data Management(MDM). IEEE,2021:89-98.
- [74] CHEN Y, WANG X, FAN M, et al. Curriculum meta-learning for next POI recommendation [C]// Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining. ACM,2021:2692-2702.
- [75] GUPTA V, BEDATHUR S. Doing more with less: overcoming data scarcity for poi recommendation via cross-region transfer [J]. ACM Transactions on Intelligent Systems and Technology (TIST), 2022, 13(3): 1-24.
- [76] SHAO E, WANG H, FENG J, et al. DeepFlowGen: Intention-aware fine grained crowd flow generation via deep neural networks [J]. IEEE Transactions on Knowledge and Data Engineering, 2021, 34(12): 5693-5707.
- [77] LIU J, LI T, JI S, et al. Urban flow pattern mining based on multi-source heterogeneous data fusion and knowledge graph embedding [J]. IEEE Transactions on Knowledge and Data Engineering, 2021, 35(2): 2133-2146.
- [78] TANG Y, QU A, CHOW A H, et al. Domain adversarial spatial-temporal network: a transferable framework for short-term traffic forecasting across cities [C]// Proceedings of the 31st ACM International Conference on Information & Knowledge Management. ACM, 2022: 1905-1915.
- [79] HUANG Y, SONG X, ZHANG S, et al. Transfer learning in traffic prediction with graph neural networks [C]// 2021 IEEE International Intelligent Transportation Systems Conference (ITSC). IEEE, 2021: 3732-3737.
- [80] LU B, GAN X, ZHANG W, et al. Spatio-Temporal Graph Few-Shot Learning with Cross-City Knowledge Transfer [C]// Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. ACM, 2022: 1162-1172.
- [81] OUYANG X, YANG Y, ZHANG Y, et al. Domain adversarial graph neural network with cross-city graph structure learning for traffic prediction [J]. Knowledge-Based Systems, 2023, 278: 110885-110903.
- [82] YAO Z, XIA S, LI Y, et al. Transfer Learning With Spatial-Temporal Graph Convolutional Network for Traffic Prediction [J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24(8): 8592-8605.
- [83] CHEN G, XU X, ZHENG H, et al. Traffic Forecasting with Adversarial Domain Adaptation in Edge-Computing Systems [C]// 2021 7th International Conference on Computer and Communications (ICCC). IEEE, 2021: 1366-1370.
- [84] CHEN Y, GU J, ZHUANG F, et al. Exploiting Hierarchical Correlations for Cross-City Cross-Mode Traffic Flow Prediction [C]// 2022 IEEE International Conference on Data Mining (ICDM). IEEE, 2022: 891-896.
- [85] WANG L, GENG X, MA X, et al. Cross-city transfer learning for deep spatio-temporal prediction [EB/OL]. (2018-05-19) [2023-12-08]. <https://doi.org/10.48550/arXiv.1802.00386>.
- [86] MALLICK T, BALAPRAKASH P, RASK E, et al. Transfer learning with graph neural networks for short-term highway traffic forecasting [C]// 2020 25th International Conference on Pattern Recognition (ICPR). IEEE, 2021: 10367-10374.
- [87] JIN Y, CHEN K, YANG Q. Selective cross-city transfer learning for traffic prediction via source city region re-weighting [C]// Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. ACM, 2022: 731-741.
- [88] MO J, GONG Z. Cross-City Multi-Granular Adaptive Transfer Learning for Traffic Flow Prediction [J]. IEEE Transactions on Knowledge and Data Engineering, 2022, 35(11): 11246-11258.
- [89] FANG Z, WU D, PAN L. When transfer learning meets cross-city urban flow prediction: spatio-temporal adaptation matters [C]// IJCAI. 2022: 2030-2036.
- [90] LI J, ZHANG K, SHEN L, et al. A domain adaptation framework for short-term traffic prediction [C]// 2021 IEEE International Intelligent Transportation Systems Conference (ITSC). IEEE, 2021: 3564-3569.
- [91] HUANG Y, SONG X, ZHU Y, et al. Traffic Prediction With Transfer Learning: A Mutual Information-Based Approach [J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24(8): 8236-8252.
- [92] WANG S, MIAO H, LI J, et al. Spatio-temporal knowledge transfer for urban crowd flow prediction via deep attentive adaptation networks [J]. IEEE Transactions on Intelligent Transportation Systems, 2021, 23(5): 4695-4705.
- [93] YIN X, LI F, SHEN Y, et al. Nodetrans: A graph transfer learning approach for traffic prediction [EB/OL]. (2022-07-04) [2023-12-08]. <https://doi.org/10.48550/arXiv.2207.01301>.
- [94] ZHAO H, YANG H, WANG Y, et al. Domain-adversarial-based temporal graph convolutional network for traffic flow prediction problem [C]// 2021 IEEE International Intelligent Transportation Systems Conference (ITSC). IEEE, 2021: 1365-1370.
- [95] ZHANG Y, YANG Y, ZHOU W, et al. Multi-city traffic flow forecasting via multi-task learning [J]. Applied Intelligence, 2021, 51: 6895-6913.
- [96] TIAN C, ZHU X, HU Z, et al. A transfer approach with attention reptile method and long-term generation mechanism for few-shot traffic prediction [J]. Neurocomputing, 2021, 452: 15-27.
- [97] ZHONG W, SUO Q, GUPTA A, et al. MetaTP: Traffic prediction with unevenly-distributed road sensing data via fast adaptation [C]// Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies. ACM, 2021: 1-28.



**ZHANG Yusong**, born in 2000, post-graduate. His main research interests include geo-social networks and so on.



**XU Shuai**, born in 1991, Ph.D, associate professor, master supervisor, is a member of CCF (No. D4709M). His main research interests include temporal-spatial data mining and smart city.