

# 意图感知的社交网络用户城外移动行为预测

胥 帅<sup>1,2)</sup> 李博涵<sup>1)</sup> 许建秋<sup>1)</sup> 曹玖新<sup>3)</sup> 傅晓明<sup>4)</sup>

<sup>1)</sup>(南京航空航天大学计算机科学与技术学院 南京 211106)

<sup>2)</sup>(计算机软件新技术国家重点实验室(南京大学) 南京 210023)

<sup>3)</sup>(东南大学网络空间安全学院 南京 211189)

<sup>4)</sup>(哥廷根大学计算机科学研究所 哥廷根 37077 德国)

**摘 要** 基于社交网络用户生成的时空数据预测用户在城外的移动行为已成为城市协同管理的迫切需求. 用户城外出行相对于城内移动而言属于“长尾”事件, 导致用户在城外生成的签到数据极度稀疏, 现有研究难以利用有限的跨城市签到数据建模用户城外出行偏好, 进而准确预测用户在城外的移动行为. 为此, 本文提出一种意图感知的社交网络用户城外移动偏好建模框架 TIEMPO. 首先, 为缓解数据稀疏性问题, 通过随机游走从构建的城外地点网络中采样移动轨迹, 利用无监督聚类发现特定数目的用户城外出行意图; 其次, 引入记忆网络从相似用户在城外的移动轨迹中进一步提炼出行意图; 然后, 基于迁移学习思想, 将用户城内签到与城外出行意图进行交互建模, 从而强化用户城外移动偏好表示; 最后, 融合用户城外移动偏好表示与地点隐含表示对用户访问城外地点的概率进行量化. 本文基于多个跨城市签到数据集进行广泛的实验分析, 结果表明 TIEMPO 能有效预测社交网络用户在城外的移动行为, 预测准确性指标  $Acc@10$  相比基线模型体现出  $12\% \sim 15\%$  的明显优势, 排序可靠性指标  $NDCG@10$  相比基线模型则超出  $3\% \sim 5\%$ , 即使在冷启动预测场景下 TIEMPO 依然表现最优.

**关键词** 移动行为预测; 跨城市; 意图感知; 偏好建模; 知识迁移; 社交网络

中图法分类号 TP391

DOI号 10.11897/SP.J.1016.2024.02579

## Intention-Aware Out-of-Town Mobility Prediction for Social Network Users

XU Shuai<sup>1,2)</sup> LI Bo-Han<sup>1)</sup> XU Jian-Qiu<sup>1)</sup> CAO Jiu-Xin<sup>3)</sup> FU Xiao-Ming<sup>4)</sup>

<sup>1)</sup>(College of Computer Science and Technology, Nanjing University of Aeronautics and Astronautics, Nanjing 211106)

<sup>2)</sup>(State Key Laboratory for Novel Software Technology (Nanjing University), Nanjing 210023)

<sup>3)</sup>(School of Cyber Science and Engineering, Southeast University, Nanjing 211189)

<sup>4)</sup>(Institute of Computer Science, University of Göttingen, Göttingen 37077, Germany)

**Abstract** Predicting social network users' out-of-town mobility based on their generated spatio-temporal data has become an impending demand for urban collaborative management. User out-of-town mobility is indeed a “long tail” event compared with user mobility inside a city, resulting in extremely sparse check-in data generated by users in the out-of-town area. It is difficult for existing studies to utilize the limited cross-city check-in data to model users' out-of-town mobility preference, and afterwards accurately predict users' mobility outside the city. Toward these issues, in this article, a novel intention-aware framework called TIEMPO (short for intention-aware Mobility Preference modeling) for modeling user out-of-town mobility preference is proposed and implemented. Firstly, in order to alleviate the data sparsity problem, abundant

收稿日期:2024-03-18;在线发布日期:2024-09-10. 本课题得到国家自然科学基金青年项目(62302213)、国家自然科学基金联合基金项目(U23A20296)、江苏省自然科学基金(BK20210280)、中央高校基本科研业务费(NS2022089)项目资助. 胥 帅(通信作者), 博士, 副教授, 中国计算机学会(CCF)会员, 主要研究领域为社会计算、智慧城市. E-mail: xushuai7@nuaa.edu.cn. 李博涵, 博士, 副教授, 中国计算机学会(CCF)高级会员, 主要研究领域为知识图谱、数据挖掘. 许建秋, 博士, 教授, 中国计算机学会(CCF)高级会员, 主要研究领域为时空数据库. 曹玖新, 博士, 教授, 中国计算机学会(CCF)高级会员, 主要研究领域为复杂网络、社会计算. 傅晓明, 博士, 教授, 中国计算机学会(CCF)会员, 主要研究领域为计算机网络、云计算、大数据、在线社交网络等.

trajectories are sampled from the constructed out-of-town location network via random walk, based on which a specific number of user intentions for out-of-town mobility can be discovered through unsupervised clustering. Secondly, the memory network is introduced to refine user intentions from similar users' out-of-town trajectories. Thirdly, following the idea of transfer learning, user check-ins inside a city and user intentions outside a city are interactively modeled to enhance user's out-of-town mobility preference representation. Finally, the probability of a user visiting an out-of-town location is quantified by integrating the user's out-of-town mobility preference representation and the location hidden representation. Extensive experiments based on multiple cross-city check-in datasets are conducted, and empirical results indicate that the proposed TIEMPO framework can effectively predict users' out-of-town mobility in terms of the visited locations, where the prediction accuracy metric  $Acc@10$  shows a significant advantage of 12%–15% and the ranking reliability metric  $NDCG@10$  achieves 3%–5% advantage compared with the baseline models. Even in cold-start prediction scenarios, TIEMPO framework still has the best performance.

**Keywords** mobility prediction; cross-city; intention-aware; preference modeling; knowledge transfer; social network

## 1 引 言

近年来,基于位置的社交网络(Location-Based Social Networks, LBSN)已成为人们获取信息与服务的主要方式,其产生的海量位置轨迹包含定位、文本、图片、评分等多维异质信息,记录了人们在物理世界的移动过程,反映了人们的生活与出行习惯,蕴含了极为丰富的语义与时空信息<sup>[1]</sup>. 基于源自社交网络的用户位置轨迹,城市尺度下的人类个体移动预测得到了学术界与产业界的广泛研究,其主要关注拥有丰富轨迹数据的特定城市,分析用户在出行过程中产生的签到数据,挖掘多维异质信息背后隐藏的各式各样的兴趣偏好和移动模式,进而推测用户在城市内部的出行需求及访问地点<sup>[2-3]</sup>.

随着城际交通系统的发展,跨城市出行愈发便利,如果将行政区(县)视为小型城市,那么人们由城市主城区至城外区域的移动可视作跨城市移动行为. 通过分析社交网络用户的签到行为,文献<sup>[4]</sup>发现若将距离用户签到中心 10 公里至 30 公里区域定义为城外(Out-of-town),则用户在城外的签到次数之和占全体签到的比重超过 30%. 类似地,有研究<sup>[5-6]</sup>指出,受交通条件和出行意愿限制,城市中人类个体的移动范围在空间距离上呈现“长尾”分布特点,虽然城内签到占据绝大多数,但城外签到并非稀缺事件,现有研究低估了人类个体城外移动的可预

测性. 在智慧城市建设背景下,准确预测社交网络用户的城外移动行为是实现都市圈联动管理的必然要求,不仅能为个性化位置服务提供驱动力<sup>[7-8]</sup>,对于评估疫情在城市间的传播风险还同样具有重要作用<sup>[9]</sup>. 因此,基于社交网络用户位置轨迹研究用户城外移动行为预测方法是极为必要的.

图 1 绘制了以凤凰城(Phoenix)为中心城市<sup>①</sup>的 Yelp 用户当地的签到分布热力图. 统计发现,约 74% 的用户在远离市区 24 公里的 Mesa 市存在至少 1 次跨城市签到行为,而存在 5 次以上跨城市签到的用户占比却不足 14%. 这表明用户访问城外区域的出行需求十分普遍. 然而该类移动行为属于

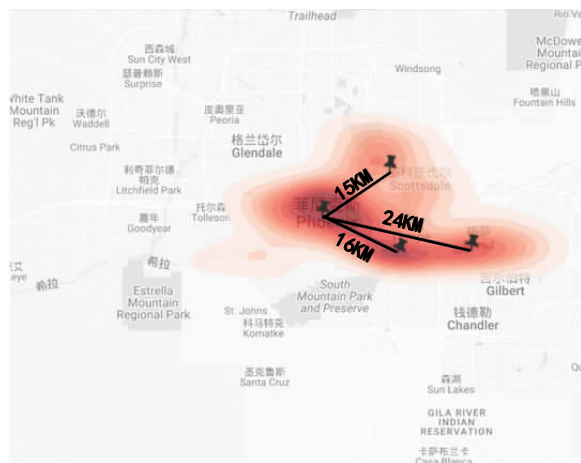


图 1 凤凰城 Yelp 用户的签到分布热力图

① 本文将用户产生签到记录最多的城市视作用户的中心城市.

“长尾”事件,导致用户在城外生成的签到数据相比城内而言极度稀疏.此外,出于隐私保护需要,部分中心城市用户虽然访问了城外地点,但并未在 Yelp 等移动应用中签到,这进一步加剧了用户城外签到数据的稀疏性<sup>[10]</sup>.

现有研究主要关注数据稠密的特定城市,相关用户移动偏好建模方法(比如 TransPredict<sup>[11]</sup>)对于数据极度稀疏的城外区域并不适用.由于观测到的少量城外签到数据均由中心城市用户产生,并且从城外区域获取当地用户的轨迹数据代价高昂,因此难以利用现有方法实现中心城市用户在城外的移动行为预测.另一方面,研究表明人类个体的移动行为具有周期性、从众性和主题性等特点<sup>[12]</sup>,因此用户在城外的移动行为由长期稳定的城内移动模式、相似用户的城外签到行为以及城外区域的地点属性三者共同驱动,这使得用户在城外的短期移动行为与城内长期的移动模式并非完全一致.虽然部分研究<sup>[13-14]</sup>使用统一框架刻画用户在城市内外签到数据的生成,但是难以描述用户在城市内外出行偏好的交互与融合过程.

针对上述不足,本文提出一种意图感知的社交网络用户城外移动偏好建模框架 TIEMPO.为缓解数据稀疏性,以采样生成的城外移动轨迹为媒介,提炼相似用户的城外出行意图,通过城内移动行为与城外出行意图交互建模,使得用户城外移动偏好兼具城内偏好的长期稳定性与城外出行的短期偏移性.本文的主要贡献体现在3个方面:

(1) 研究新颖的社交网络用户城外移动行为预测问题.在该问题中,所有签到数据均由中心城市用户产生,且城外生成的签到数据相比城内而言极度稀疏.本文旨在基于中心城市用户的跨城市签到数据预测用户在城外的访问地点;

(2) 提出一种意图感知的社交网络用户城外移动偏好建模框架,利用记忆网络与多种注意力机制刻画用户城内移动偏好、城外出行意图的交互与融合过程,通过推断用户出行意图提升其城外移动行为的可预测性;

(3) 基于多个跨城市签到数据集开展大量实验分析,在不同实验场景下验证了所提框架的有效性及其相较于已有方法的优越性.

## 2 相关工作

基于位置的社交网络具有本地化、社会化和移

动性等信息服务特征,以其为研究对象的城外兴趣点推荐(Out-of-town POI Recommendation)是跨城市用户移动行为预测研究的主流. Ference 等人<sup>[15]</sup>最早研究了城外兴趣点推荐问题,他们提取用户历史签到记录中的兴趣点类别、社交关系、地理距离等统计特征,在城外寻找相似的兴趣点将其作为候选集,最后观察用户是否访问这些地点来评价推荐的准确性.随后, Wang 等人<sup>[16]</sup>提出一系列方法解决城外兴趣点推荐问题.他们以隐含狄利克雷分布(Latent Dirichlet Allocation, LDA)为工具,利用概率图模型融合用户对时间、区域、地点类别的偏好,刻画用户在城市内外签到数据的生成过程.考虑到用户的签到行为存在从众性,他们又引入社交变量,通过其他用户在城外的签到行为引导当前签到的生成过程,进而描述用户在城外的兴趣偏移. Wang 等人<sup>[17]</sup>从分布式环境的多智能体角度出发,提出一种基于遗憾最小化的动态建模方法模拟城市人群的移动行为. Pham 等人<sup>[18]</sup>进一步研究了城外区域推荐问题,基于用户签到地点的地理分布,利用几何交集法为目标用户推荐城外的矩形网格区域,使得推荐区域内包含用户感兴趣的地点.

深度学习及迁移学习领域的研究进展为跨城市用户移动行为预测带来了新思路. Sun 等人<sup>[19]</sup>利用深层神经网络建模目标用户在本地、城外的签到序列以及其余用户在城外的签到序列,通过注意力机制发现目标用户与其余用户的相似偏好,进而预测目标用户在城外的访问地点. Li 等人<sup>[20]</sup>和 Ding 等人<sup>[21]</sup>考虑多种维度的地点属性,通过匹配不同城市的兴趣点实现用户移动偏好在城市间的自适应迁移. Xin 等人<sup>[22]</sup>首先借助图神经网络建模用户的本地签到序列以获取用户的本地移动偏好,随后引入神经主题模型刻画目标用户在城外签到数据的生成过程. Zhu 等人<sup>[23]</sup>基于多维异质信息融合,结合图卷积网络和循环神经网络依次捕捉用户所在区域的空间特征和不同区域间的时序关联,进而预测用户下一步访问的城市区域. Xu 等人<sup>[24]</sup>尝试从用户及好友在中心城市以外区域的签到记录中挖掘其城外移动模式,虽然在一定程度上缓解了数据稀疏问题,但是难以刻画用户在城外的兴趣偏移.

可以发现,不管是基于概率图模型的方法还是基于深度学习的方法,相关研究一般直接利用城外的签到数据挖掘用户的签到主题.然而,就本文研究的社交网络用户城外移动行为预测问题而言,由于用户在城外生成的签到数据与城内相比极度稀疏,

并且跨城市出行存在兴趣偏移现象,现有研究难以利用有限的城外签到数据准确建模用户的出行意图.除此以外,相关工作针对城外地点间的签到次序、流行度及空间分布等特征缺乏有效的刻画手段,难以体现用户跨城市出行时的地点选择倾向.

### 3 问题定义与数据描述

#### 3.1 问题定义

表 1 总结了本文使用的主要符号及其释义.

表 1 符号及释义

符号	释义
$\mathcal{U}$	中心城市 $S$ 的社交网络用户集合
$\mathcal{V}^S, \mathcal{V}^T$	中心城市 $S$ 和城外区域 $T$ 的地点集合
$\mathcal{D}^S, \mathcal{D}^T$	中心城市 $S$ 和城外区域 $T$ 的签到集合
$\mathbf{R}^S, \mathbf{R}^T$	中心城市 $S$ 和城外区域 $T$ 的签到矩阵
$\mathcal{C}^{u,S}, \mathcal{C}^{u,T}$	用户 $u$ 在中心城市 $S$ 和城外区域 $T$ 的签到集合
$c_i^{u,S}, c_j^{u,T}$	用户 $u$ 在中心城市 $S$ 和城外区域 $T$ 的单个签到
$u^f$	相似用户的城外轨迹表示
$u^{int}$	相似用户的城外出行意图表示
$u^l, u^o$	用户在城内的长期偏好和在城外的短期偏好表示
$u^*, v^*$	用户城外移动偏好表示和城外地点隐含表示
$\mathbf{K}, \mathbf{w}, \mathbf{M}$	键值记忆网络的键矩阵、值向量和记忆缓存矩阵
$\{\mathbf{W}\}, \{\mathbf{b}\}$	权重矩阵集合和偏置向量集合
$\hat{s}_{u,v}$	用户 $u$ 针对地点 $v$ 的访问概率

给定中心城市  $S$  和城外区域  $T$ ,其地点集合分别记作  $\mathcal{V}^S$  和  $\mathcal{V}^T$ . 来自中心城市  $S$  的社交网络用户集合用  $\mathcal{U}$  表示,其在城市  $S$  和城市  $T$  生成的签到数据集合分别记作  $\mathcal{D}^S$  和  $\mathcal{D}^T$ . 假设  $|\mathcal{U}| = M$ ,  $|\mathcal{V}^S| = N_1$ ,  $|\mathcal{V}^T| = N_2$ , 则用户在中心城市  $S$  和城外区域  $T$  的签到矩阵可分别表示为  $\mathbf{R}^S = \{r_{u,v}\}_{M \times N_1}$  和  $\mathbf{R}^T = \{r_{u,v}\}_{M \times N_2}$ , 其中矩阵元素  $r_{u,v}$  为非负实数,数值为用户在该地点的签到频率.

用户  $u$  在中心城市  $S$  的签到集合记为  $\mathcal{C}^{u,S} = \{c_i^{u,S} | u \in \mathcal{U}, 1 \leq i \leq n_u\}$ , 其中  $n_u$  表示签到个数,每个元素  $c_i^{u,S} = (u, v_i, t_i, r_i)$  的物理含义为用户  $u$  于时间  $t_i$  在地点  $v_i$  进行了一次签到,并产生数值化评分  $r_i$ . 同理,用户  $u$  在城外区域  $T$  的签到记录可用  $\mathcal{C}^{u,T}$  表示.

对于中心城市  $S$  和城外区域  $T$  的任意地点,其地理经纬度、地点类别均已知.此外,地点的总访问次数亦可由数据集统计获得.

不失一般性,基于上述信息给出社交网络用户城外移动行为预测问题的形式化定义:

**问题定义 1.** 给定用户集合  $\mathcal{U}$ 、地点集合  $\mathcal{V}^S$  和  $\mathcal{V}^T$ 、签到集合  $\mathcal{D}^S$  和  $\mathcal{D}^T$ . 针对来自中心城市的目标用户  $u^o \in \mathcal{U}$ , 以 Top- $K$  列表形式预测用户  $u^o$  在城外

区域  $T$  的访问地点,使得用户的真实访问地点  $v^o \in \mathcal{V}^T$  尽可能位于预测列表顶部.

图 2 直观展示了上述问题的示意图. 该问题与现有的城外兴趣点推荐问题存在区别,在本问题中,所有签到数据均由来自中心城市  $S$  的用户产生,城外区域  $T$  当地用户的签到数据不可观测. 此外,根据是否存在跨城市签到行为可将中心城市  $S$  的用户分为跨城市用户和非跨城市用户,其中非跨城市用户(比如用户  $a$ )可用于评价模型针对“冷启动”场景<sup>[25]</sup>的预测性能.

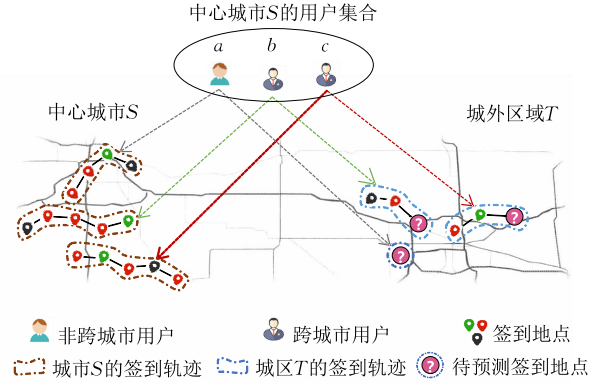


图 2 用户城外移动行为预测问题示意图

#### 3.2 数据描述

作为生活化移动社交平台的探路者和典范, Yelp 凭借成功的商业模式和开放的运营姿态得到了研究人员的青睐. 自 2013 年以来, Yelp 不定期举办数据挖掘竞赛,并在官网中发布大规模、多模态用户签到数据供研究者使用. 本文使用的数据收集自 Yelp 竞赛网站<sup>①</sup>, 原始数据包含北美百余座城市的用户签到记录. 为定量分析用户城外移动行为的可预测性,选取具有代表性的三个城市对,形成三个跨城市签到数据集,分别是 Las Vegas-Henderson(记作 LV-HD)、Phoenix-Mesa(记作 PH-MS)、Boston-Cambridge(记作 BS-CA), 其中 Henderson、Mesa、Cambridge 依次为 Las Vegas、Phoenix、Boston 的近邻卫星城市,每个城市对的地理距离(城市中心坐标的直线距离)均在 30 公里左右.

数据集的签到记录包含“用户 ID”、“地点 ID”、“地点经纬度”、“地点类别”、“时间戳”、“签到评分”等字段. 对于每个数据集,均进行预处理以确保每个用户在城市  $S$  和城市  $T$  均有签到记录,且在城市  $S$  的签到次数多于在城市  $T$  的签到次数. 同时,确保每个用户的签到个数不低于 10 个,每个地点的被签

① <https://www.yelp.com/dataset>, 获取时间为 2019 年 12 月.

到次数不低于 10 次。预处理后的数据集统计信息如表 2 所示。需要指出,在每个数据集中,若用户在城市  $T$  仅存在 1 次签到记录,则该用户被视作非跨城

市用户(比如图 2 中用户  $a$ ),此签到记录被视作真实标签(Ground-truth),用于评估冷启动场景的预测性能(参见第 5 节实验分析)。

表 2 数据集统计信息

	用户总数	跨城市用户数	城市S签到数	城市T签到数	城市S地点数	城市T地点数	城市S签到密度/%	城市T签到密度/%
LV-HD	5239	4675	221370	27743	4205	1254	1.00	0.47
PH-MS	4196	3397	168574	20966	4682	1596	0.86	0.38
BS-CA	3075	2493	142376	15352	3056	942	1.51	0.65

## 4 意图感知的用户城外移动偏好建模

为解决上述用户城外移动行为预测问题,提出一种意图感知的用户城外移动偏好建模框架(Intention-aware Mobility Preference Modeling, TIEMPO),其结构如图 3 所示。TIEMPO 框架可分为离线计算和在线建模两个部分。其中,离线计算部分一方面基于图表示学习获得城外地点隐含表示(模块①),另一方面

面构建带权有向地点网络进行轨迹采样,在此基础上利用无监督聚类发现用户在城外的出行意图(模块②)。在线建模部分则包括签到嵌入表示(模块③)、意图感知强化(模块④)、移动知识迁移(模块⑤)、访问偏好计算(模块⑥)四个子模块。在两个部分之间,城外轨迹无监督聚类的结果能够为意图感知强化模块提供初始化,而城外地点隐含表示则与用户城外移动偏好相结合,用于量化用户针对城外地点的访问概率。下文将详细介绍 TIEMPO 框架的主要模块。

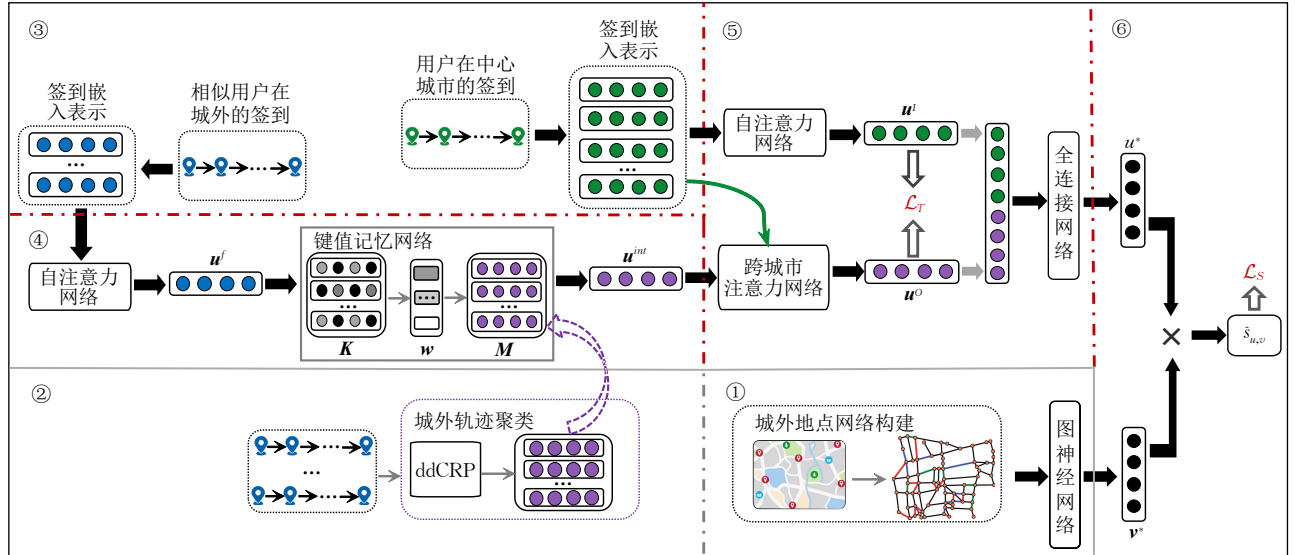


图 3 TIEMPO 框架结构图

### 4.1 距离敏感的城外地点隐含表示

研究表明,用户在城外的移动行为呈现地理聚簇现象,即用户倾向于访问流行度更高、分布更密集的地点,该现象对于以观光为出行目的的跨城市移动而言尤为明显<sup>[26]</sup>。因此,需要一种能够兼顾流行度和地理影响力的城外地点隐含表示学习方法。在模块①中,融合地理距离、地点流行度、地点类别等特征构建带权无向图,图中节点表示城外地点,而节点之间连边权重则根据地理距离计算获得。在此基础上,利用图神经网络学习地点嵌入表示<sup>[27]</sup>。

首先,针对城外地点  $v_j^T$ ,将地点 ID、地点类别、

总访问次数三种离散变量进行 one-hot 编码并拼接,利用神经网络嵌入层将拼接后的向量映射至  $d$  维向量空间,即  $v_j^T \in \mathbb{R}^d$ 。此时,可获得城外地点集合的初始嵌入矩阵  $\mathbf{V}^T \in \mathbb{R}^{N_2 \times d}$ 。

其次,构造带权无向图  $\mathcal{G} = (\mathcal{V}^T, \mathcal{E}, \mathcal{W})$ ,其中  $\mathcal{E}$  表示连边集合,  $\mathcal{W}$  表示连边权重集合。对于任意地点对  $\langle v_p^T, v_q^T \rangle$ ,根据地点之间的地理距离计算二者连边的权重:

$$e_{p,q} = \exp(-\text{dist}(v_p^T, v_q^T)) \quad (1)$$

其中,  $\text{dist}(\cdot, \cdot)$  表示两个地点之间的半正弦距离(Haversine Distance)。此时,城外地点连边权重的

邻接矩阵可表示为  $\mathbf{E}^T \in \mathbb{R}^{N_2 \times N_2}$ . 为减轻后续计算量, 设定阈值  $\delta$ , 将邻接矩阵  $\mathbf{E}^T$  中小于  $\delta$  的元素均置为 0, 即认为两个地点之间无连边.

然后, 利用图神经网络学习带权无向图  $\mathcal{G}$  的节点嵌入表示:

$$\mathbf{V}^{T*} = \text{Relu}(\mathbf{E}^T \cdot \mathbf{V}^T \cdot \mathbf{W}_1 + \mathbf{b}_1) \quad (2)$$

其中,  $\mathbf{W}_1 \in \mathbb{R}^{d \times d}$  和  $\mathbf{b}_1 \in \mathbb{R}^d$  依次为待学习的神经网络权重矩阵和偏置向量, 而  $\mathbf{V}^{T*}$  则表示更新后的城外地点隐含表示矩阵. 一般而言, 图神经网络的层数越多, 学习到的地点隐含表示越能反映带权无向图的结构信息、地理影响力和流行度特征. 然而, 预实验结果表明两层网络相比于单层网络的性能提升极其有限, 但是运算时间却明显增加, 故在后续实验环节仅采用单层图神经网络.

在此基础上, 对于任意城外地点  $v^T$ , 可从矩阵  $\mathbf{V}^{T*}$  获得其隐含表示  $v^{T*} \in \mathbb{R}^d$ .

## 4.2 基于 ddCRP 的城外出行意图发现

在模块②中, 为缓解数据稀疏性, 构造带权有向地点网络, 利用随机游走从网络中采样足量城外轨迹. 以此为基础, 采用距离依赖的中餐馆过程 (distance dependent Chinese Restaurant Process, ddCRP)<sup>[28]</sup> 对采样获得的轨迹进行无监督聚类.

首先, 以文献[29]所提方法构造带权有向地点网络, 网络中的节点表示城外地点, 而有向边的权重则表示从当前地点转移到目标节点的概率. 该构造方法使得通过随机游走可以将属于同一类别、地理距离较近、同时又经常被连续访问的地点以较大的概率采样至同一序列, 因此能够有效模拟现实世界用户在城外的移动轨迹. 需要指出, 由于带权有向网络的构造过程充分考虑了已有签到的空间分布与时序特征, 因此基于该网络的采样实质上完成了对原有城外轨迹的补充, 可有效缓解用户城外签到数据的稀疏性.

其次, 不同于已有研究通过事先指定数目的方式发现用户城外出行意图<sup>[22,30]</sup>, 本文针对采样获得的城外轨迹进行无监督聚类, 采用 ddCRP 从轨迹中自适应地发现特定数目的出行意图. CRP 作为 Dirichlet 过程的一种经典构造, 适用于解决无序可交换数据的无监督聚类. CRP 对餐桌本身进行建模, 同一餐桌上的顾客 (数据) 具有相同的类别. 然而, 用户移动轨迹本质上是一种时序数据, 不符合无序可交换性质, 因此 CRP 不适用移动轨迹聚类. 相比之下, ddCRP 对数据之间的连接性进行建模, 即对具有先后次序的签到地点邻接关系进行追溯, 每个顾客不直接选择一张桌子, 而是根据时序关系和空间距离

选择一个顾客并坐到旁边, 重复此过程可完成有序到达顾客在多个餐桌上的分配, 每个餐桌上的顾客共享一个类别. 图 4 展示了基于 ddCRP 的城外出行意图发现示意图, 其中图 4(a) 为采样获得的多条城外移动轨迹, 图 4(b) 为对应的意图发现结果, 其中每一张桌子代表一个主题, 即一个出行意图.

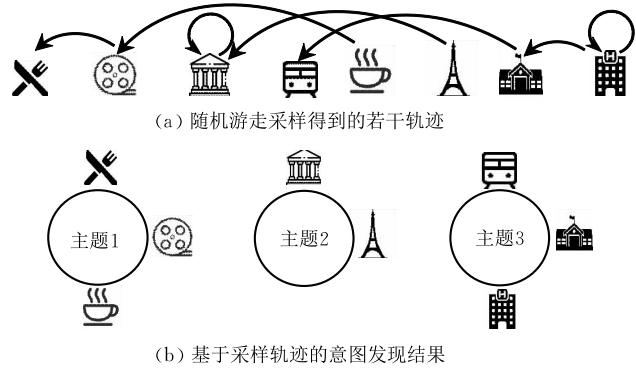


图 4 基于 ddCRP 的出行意图发现示意图

## 4.3 基于自注意力的用户移动偏好表示

在图 3 的模块③中, 对于拥有跨城市签到记录的用户  $u$ , 首先利用其在中心城市的签到记录学习用户  $u$  在城内长期稳定的移动偏好. 为了克服城外移动轨迹的稀疏性, 需寻找与用户  $u$  具有相似城内偏好的用户, 通过采样相似用户在城外的签到记录刻画用户  $u$  的短期兴趣偏移. 图 5 直观展示了寻找相似用户并采样其城外签到记录的过程. 为确保可操作性, 对于用户  $u$ , 首先依据相似度对相似用户进行排序, 然后从最相似用户的城外移动轨迹中采样签到记录, 直到采样的签到数量为  $m$ .

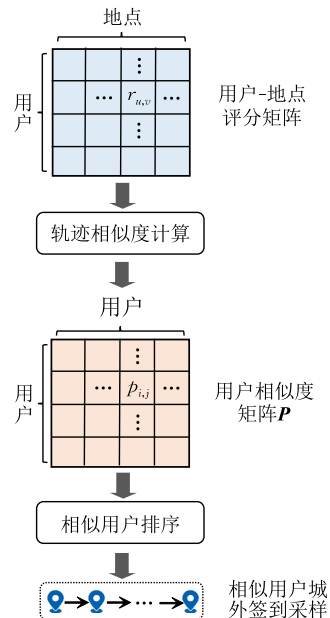


图 5 相似用户城外签到采样过程示意图

对于用户  $u$  在中心城市  $S$  的单个签到  $c_i^{u,S} \in \mathcal{C}^{u,S}$ , 将该签到的地点 ID、地点类别、离散化的时间窗口进行 one-hot 编码并拼接, 利用神经网络嵌入层将拼接后的向量映射至  $d$  维向量空间, 即  $\tilde{c}_i^{u,S} \in \mathbb{R}^d$ . 据此, 可获得用户  $u$  在中心城市  $S$  的签到嵌入表示矩阵  $\mathbf{C}^{u,S} \in \mathbb{R}^{n_u \times d}$ , 其中  $n_u$  表示用户  $u$  在中心城市  $S$  的签到数量.

在模块④中, 为学习用户  $u$  在中心城市  $S$  的移动偏好, 利用图 6 所示的自注意力机制对签到嵌入表示矩阵  $\mathbf{C}^{u,S}$  进行聚合, 以  $d$  维向量的形式表示用户  $u$  的城内偏好  $\mathbf{u}^l$ . 首先, 通过如下方式计算注意力权重矩阵  $\mathbf{A} \in \mathbb{R}^{n_u \times n_u}$ :

$$\begin{aligned} \mathbf{Q} &= \mathbf{W}^Q \cdot \mathbf{C}^{u,S} \\ \mathbf{K} &= \mathbf{W}^K \cdot \mathbf{C}^{u,S} \\ \mathbf{A} &= \text{softmax}(\mathbf{K} \cdot \mathbf{Q}^T) \end{aligned} \quad (3)$$

其中, 矩阵元素  $a_{i,j} \in \mathbf{A}$  表示签到记录  $c_i^{u,S}$  与  $c_j^{u,S}$  之间的注意力权重,  $\mathbf{W}^Q, \mathbf{W}^K \in \mathbb{R}^{d \times d}$  为待学习的神经网络权重矩阵. 在此基础上, 依照下述方式对签到嵌入表示矩阵  $\mathbf{C}^{u,S}$  进行更新:

$$\begin{aligned} \mathbf{V} &= \mathbf{W}^V \cdot \mathbf{C}^{u,S} \\ \tilde{\mathbf{C}}^{u,S} &= \mathbf{A} \cdot \mathbf{V} \end{aligned} \quad (4)$$

其中,  $\tilde{\mathbf{C}}^{u,S} \in \mathbb{R}^{n_u \times d}$ ,  $\mathbf{W}^V \in \mathbb{R}^{d \times d}$  为待学习的神经网络权重矩阵.




图 6 自注意力机制结构

然后, 对矩阵  $\tilde{\mathbf{C}}^{u,S}$  进行如下操作以获得用户  $u$  的城内偏好表示  $\mathbf{u}^l$ :

$$\mathbf{u}^l = \text{Relu}(\mathbf{W}_2 \cdot (\tilde{\mathbf{c}}_1^{u,S} \parallel \tilde{\mathbf{c}}_2^{u,S} \parallel \dots \parallel \tilde{\mathbf{c}}_{n_1}^{u,S}) + \mathbf{b}_2) \quad (5)$$

其中,  $\mathbf{u}^l \in \mathbb{R}^d$ ,  $\mathbf{W}_2$  和  $\mathbf{b}_2$  依次为待学习的神经网络权重矩阵和偏置向量, 符号  $\parallel$  表示向量拼接操作.

同理, 对于采样得到的相似用户城外签到记录集合, 通过上述步骤可获得相似用户的城外偏好表示  $\mathbf{u}^f$ .

#### 4.4 基于记忆网络的用户城外出行意图感知

在 TIEMPO 框架的模块④中, 为预判用户的城外出行意图, 提升用户城外移动行为的可预测性, 引入键值记忆网络 (Key-value Memory Network)<sup>[31]</sup> 对上述发现的用户城外出行意图进行提炼. 键值记忆网络的核心组件是键矩阵、值向量和记忆缓存矩阵, 其中记忆缓存允许网络将无监督聚类发现的主题作为先验知识, 将知识存储在结构化记忆单元中, 并使用键来寻址相关的记忆单元, 再对所有记忆单元依据键值进行融合, 最终汇聚得到用户的城外出行意图.

ddCRP 发现的特定数目的主题能够为键值记忆网络提供初始化. 假设发现的主题数为  $h$ , 那么记忆网络包含  $h$  个键、 $h$  个键值和  $h$  个记忆单元, 此时键矩阵、值向量、记忆缓存矩阵可依次表示为  $\mathbf{K} \in \mathbb{R}^{h \times d}$ ,  $\mathbf{w} \in \mathbb{R}^h$ ,  $\mathbf{M} \in \mathbb{R}^{h \times d}$ , 且每一个记忆单元  $m_i \in \mathbb{R}^d$  被初始化为该主题下所有地点隐含表示的均值.

依据如下公式计算相似用户城外偏好表示  $\mathbf{u}^f$  与各个键向量  $\mathbf{k}_i \in \mathbb{R}^d$  之间的归一化相关度  $\omega_i$ :

$$\omega_i = \text{softmax}(\mathbf{u}^{fT} \cdot \mathbf{k}_i) = \frac{\exp(\mathbf{u}^{fT} \cdot \mathbf{k}_i)}{\sum_j \exp(\mathbf{u}^{fT} \cdot \mathbf{k}_j)} \quad (6)$$

其中,  $j=1, 2, \dots, h$ , 表示  $h$  个出行意图.

在此基础上, 以线性方式对所有记忆单元进行聚合, 从而获得代表用户城外出行意图的向量表示  $\mathbf{u}^{int}$ :

$$\mathbf{u}^{int} = \sum_{i=1}^h \omega_i m_i \quad (7)$$

#### 4.5 移动知识跨城市迁移

在 TIEMPO 框架的模块⑤中, 基于用户城外出行意图  $\mathbf{u}^{int}$ , 设计一种跨城市注意力机制将用户  $u$  在中心城市  $S$  的签到嵌入表示矩阵  $\mathbf{C}^{u,S}$  与  $\mathbf{u}^{int}$  交互, 获得兼具城内移动模式与城外兴趣偏移的用户城外偏好表示. 图 7 展示了跨城市注意力机制的结构.




图 7 跨城市注意力机制结构

针对签到嵌入表示矩阵  $\mathbf{C}^{u,S}$  中的任意向量  $\mathbf{c}_j^{u,S} \in \mathbb{R}^d$ , 依据如下公式计算  $\mathbf{c}_j^{u,S}$  与  $\mathbf{u}^{int}$  之间的注意力权重  $\beta_j$ :

$$\beta_j = \text{softmax}(\mathbf{c}_j^{u,S} \cdot \mathbf{W}_3 \cdot \mathbf{u}^{int}) \quad (8)$$

其中,  $\mathbf{W}_3 \in \mathbb{R}^{d \times d}$  为待学习的神经网络权重矩阵. 在此基础上, 以线性方式对矩阵  $\mathbf{C}^{u,S}$  中的全体签到嵌入表示进行聚合, 获得用户城外偏好表示  $\mathbf{u}^O$ :

$$\mathbf{u}^O = \sum_{j=1}^{n_u} \beta_j \mathbf{c}_j^{u,S} \quad (9)$$

基于用户  $u$  在城内的长期偏好  $\mathbf{u}^I$  和在城外的短期偏好  $\mathbf{u}^O$ , 将其拼接并采用全连接神经网络层映射为最终的用户城外移动偏好  $\mathbf{u}^*$ :

$$\mathbf{u}^* = \text{Relu}(\mathbf{W}_4 \cdot (\mathbf{u}^I \parallel \mathbf{u}^O) + \mathbf{b}_4) \quad (10)$$

其中,  $\mathbf{W}_4 \in \mathbb{R}^{d \times 2d}$  和  $\mathbf{b}_4 \in \mathbb{R}^d$  依次为待学习的神经网络权重矩阵和偏置向量.

从图 3 可以看到, 在移动知识迁移模块, 为了使学习到的城外偏好表示  $\mathbf{u}^O$  具有中心城市的移动模式与签到风格, 引入迁移损失  $\mathcal{L}_T$  以约束  $\mathbf{u}^I$  与  $\mathbf{u}^O$  之间的距离. 在预实验中, 分别尝试了 KL 散度、欧式距离、余弦相似度三种方式计算迁移损失  $\mathcal{L}_T$ , 结果表明基于余弦相似度的迁移损失能取得更好的预测性能, 因此以余弦相似度作为  $\mathcal{L}_T$  的计算方式:

$$\mathcal{L}_T = - \frac{\mathbf{u}^I \cdot \mathbf{u}^O}{\|\mathbf{u}^I\| \times \|\mathbf{u}^O\|} \quad (11)$$

#### 4.6 访问概率计算与模型优化

在 TIEMPO 框架的模块⑥中, 基于学习到的用户城外移动偏好表示  $\mathbf{u}^*$  和城外地点隐含表示  $\mathbf{v}^*$  (在不引起歧义的情况下, 忽略城外地点上标以增强可读性), 依据矩阵分解思想, 以点积形式刻画二者的交互过程, 量化用户  $u$  访问城外地点的  $v$  的概率:

$$\hat{s}_{u,v} = \mathbf{u}^* \cdot \mathbf{v}^{*T} \quad (12)$$

其中,  $\mathbf{v}^{*T}$  表示向量  $\mathbf{v}^*$  的转置.

为了显式刻画已有的城外签到记录中用户与地点的交互, 受贝叶斯个性化排序 (Bayesian Personalized Ranking, BPR) [32] 启发, 引入预测损失  $\mathcal{L}_S$ , 计算方式如下:

$$\mathcal{L}_S = - \sum_{u \in \mathcal{U}} \sum_{\langle v^+, v^- \rangle \in \mathcal{R}_u} \ln \sigma(\hat{s}_{u,v^+} - \hat{s}_{u,v^-}) + \epsilon \|\Theta\|^2 \quad (13)$$

其中,  $\mathcal{R}_u$  表示用户  $u$  对应的训练样本集合,  $v^+$  表示正样本对应的地点, 即用户在城外签到的地点,  $v^-$  表示负样本对应的地点, 即随机采样的真实访问地点以外的地点,  $\sigma(\cdot)$  表示 sigmoid 函数, 其作用是将输入值映射到  $[0, 1]$  区间,  $\Theta$  代表神经网络层待学习的参数集合 (包括权重矩阵集合  $\{\mathbf{W}\}$  和偏置向量集

合  $\{\mathbf{b}\}$ ),  $\epsilon$  表示损失函数的正则化项系数.

由于采用 BPR 作为损失函数的计算形式, 需要为每个正样本采样至少一个负样本. 为确保可操作性, 统一为每个正样本采样 10 个负样本. 在采样过程中, 每次循环 (Epoch) 均重新进行负样本采样. 在该采样方式下, 虽然负样本的规模是正样本的 10 倍, 但每个负样本给出的“负信号”较为微弱, 保证了模型训练的有效性和高效率.

针对上述迁移损失  $\mathcal{L}_T$  和预测损失  $\mathcal{L}_S$ , 通过线性加权的方式对两种损失进行融合, 获得 TIEMPO 框架的总体损失函数:

$$\mathcal{L} = \lambda_1 \mathcal{L}_T + \lambda_2 \mathcal{L}_S \quad (14)$$

其中,  $\lambda_1$  和  $\lambda_2$  分别为迁移损失项和预测损失项的权重系数.

训练过程需要对总体损失函数  $\mathcal{L}$  进行最小化, 由于 TIEMPO 框架的在线建模部分实质上是一种前馈神经网络, 权重矩阵等参数均可导, 因此可采用 Adam 优化器 [33] 完成梯度下降的自主步长学习.

#### 4.7 基于 TIEMPO 框架的用户城外移动行为预测

针对来自中心城市  $S$  的目标用户  $u^o \in \mathcal{U}$ , 可基于训练完成的 TIEMPO 框架预测用户  $u^o$  在城外区域  $T$  的访问地点. 具体而言, 对于城外区域  $T$  的候选地点  $v^o \in \mathcal{V}^T$ , 计算目标用户  $u^o$  在此地点的访问概率  $\hat{s}_{u^o, v^o}$ . 随后, 将候选地点按访问概率降序排序, 选取 Top- $K$  个地点形成有序列表作为最终的预测结果. 预测过程如算法 1 所示.

**算法 1.** 社交网络用户城外访问地点预测算法.

输入:  $u^o, \mathcal{D}^S, \mathcal{D}^T, \mathcal{V}^T, \Theta, \mathbf{P}, m, K$

输出: 有序列表  $L$

1. 依据相似度矩阵  $\mathbf{P}$  寻找用户  $u^o$  的相似用户
2. 从相似用户的城外签到记录中采样  $m$  条签到记录
3. 根据式 (10) 计算用户的城外移动偏好表示  $\mathbf{u}^{*o}$
4. FOR candidate POI  $v^o \in \mathcal{V}^T$  DO
  - 计算地点的隐含表示  $\mathbf{v}^{*o}$
  - 计算用户针对城外地点的访问概率  $\hat{s}_{u^o, v^o}$
5. END FOR
6. 根据访问概率对候选地点集合降序排序
7. 从  $\mathcal{V}^T$  中选择 Top- $K$  预测地点形成有序列表  $L$
8. 返回列表  $L$

算法 1 的总体时间复杂度为  $\mathcal{O}(M+n) + \mathcal{O}(N \cdot n \cdot m) + \mathcal{O}(N \log(N))$ . 其中,  $M$  表示数据集中的用户数目、 $N$  表示城外区域  $T$  的候选地点数目、 $n$  表示用户移动轨迹平均长度、 $m$  表示从相似用户城外轨迹采样到的签到数目. 不难发现,  $\mathcal{O}(M+n)$  表示寻找相似用户并进行轨迹采样的时间复杂度,



$\mathcal{O}(N \cdot n \cdot m)$ 表示计算用户城外访问概率的时间复杂度,而 $\mathcal{O}(N \log(N))$ 则表示对城外候选地点进行排序的时间复杂度.

## 5 实验评估

实验代码通过 Python 3.7 编写, TIEMPO 框架通过 PyTorch 1.3.1 搭建. 基于 2.2 节介绍的三个跨城市用户签到数据集, 本文开展了大量实验分析, 旨在回答如下五个研究问题:

(1) 离线计算部分, ddCRP 能够发现哪些城外出行意图?

(2) 与现有用户移动行为预测方法相比, TIEMPO 框架的表现如何?

(3) 针对“冷启动”预测场景, TIEMPO 框架的表现如何?

(4) 在线建模部分, 键值记忆网络对于刻画用户城外出行意图的实际作用如何?

(5) TIEMPO 框架的不同组件在消融实验下表现如何?

### 5.1 实验设定

#### 5.1.1 数据划分与评价指标

针对数据集中存在跨城市签到行为的用户, 取其在中心城市的全部签到数据和在城外区域的前 80% 签到数据用于训练, 取其在城外区域的后 20% 签到记录用作测试. 需要指出, 根据 3.2 节数据描述可知, 在城外区域仅存在 1 次签到记录的用户被视作非跨城市用户, 该次签到用于评价不同模型在冷启动场景下的预测性能.

对于目标用户  $u^o$ , 针对其测试集中的任意签到记录, 基于算法 1 获得该签到记录对应的 Top-K 地点预测列表  $L$ . 为评价预测效果, 分别选取  $Acc@K$  和  $NDCG@K$  作为评价指标, 其中前者判断 Top-K 列表中是否存在真实访问地点, 是算法预测准确度的体现, 而后者衡量真实访问地点在列表中的次序, 是算法排序可靠性的体现<sup>[24]</sup>. 上述两个评价指标取值范围均为  $[0, 1]$ , 且取值越大表明预测效果越理想.

#### 5.1.2 实验参数设定

TIEMPO 框架的离线计算部分, 地点连边权重阈值  $\delta$  设为  $1e^{-3}$ . 对于在线建模部分, 神经网络层的权重矩阵集合  $\{W\}$  和偏置向量集合  $\{b\}$  按照均匀分布  $U(-0.01, 0.01)$  进行初始化; 批量大小 (Batch Size) 设置为 128; Adam 优化器的初始学习率设置为 0.001; 损失函数  $\mathcal{L}_s$  的正则化项系数  $\epsilon$  设置为  $1e^{-5}$ ; 用户偏

好与地点的向量表示维度  $d$  固定为 128; 为了避免过拟合, 在全连接神经网络层设置随机失活神经元比例 (Dropout Rate) 为 0.5.

统计发现, 不同数据集中用户在城外的平均签到数目不足 10 个, 且用户城内移动轨迹的长度约为用户城外移动轨迹长度的 10 倍, 因此将采样相似用户城外签到的数量  $m$  设置为 100. 对于总体损失函数  $\mathcal{L}$  中迁移损失项  $\mathcal{L}_T$  和预测损失项  $\mathcal{L}_s$  的权重系数  $\lambda_1$  和  $\lambda_2$ , 经过在  $[0.1, 0.9]$  区间进行网格搜索 (步长均为 0.1), 发现当二者比例接近一致时, 预测准确性最高. 图 8 展示了在 BS-CA 数据集上进行网格搜索时  $Acc@10$  指标的变化情况. 可以发现, 总体上当  $\lambda_1$  和  $\lambda_2$  取值一致时,  $Acc@10$  指标能够达到峰值, 因此不妨在后续实验中设置  $\lambda_1 = \lambda_2 = 1$ .




图 8  $Acc@10$  指标下 BS-CA 数据集的网格搜索结果

### 5.2 对比方法

首先, 考虑到针对用户在城市范围内的移动预测研究较为普遍, 因此选取如下两种典型的用户轨迹预测模型 (非跨城市移动行为预测方法) 作为基准对比方法:

(1) L2V<sup>[34]</sup>. 该模型基于图嵌入思想学习用户、地点、时间窗口等异构节点在同一语义空间中的向量表示, 通过计算特定时间窗口下用户与地点的向量相似度确定目标用户最有可能的访问位置.

(2) PMove<sup>[35]</sup>. 该模型通过多种注意力机制挖掘用户历史轨迹的多层级周期性特征, 从历史轨迹中匹配与近期轨迹最相似的片段, 进而确定用户下一步最有可能的访问位置.

需要指出, 为保证上述非跨城市移动行为预测方法具有可操作性, 在实验过程中需要将中心城市与近邻目标城市视作同一城市, 从而将跨城市用户

移动预测问题转换为同一城市尺度下用户访问位置预测问题。

然后,选取如下六种具有代表性的用户城外移动行为预测模型与 TIEMPO 框架进行对比:

(1) CCTP<sup>[36]</sup>. 该模型考虑不同城市不同类型地点的分布特征,从而将用户在中心城市对于不同地点的访问偏好直接迁移到目标城市中。

(2) UIDT<sup>[21]</sup>. 该模型通过两个矩阵分别建模中心城市用户和目标城市用户在各自城市的移动偏好,通过“重叠用户”将两个矩阵联立,从而发现用户跨城市移动时的兴趣偏移。

(3) CHAML<sup>[25]</sup>. 该模型不依赖跨城市用户,利用元学习实现用户移动偏好跨城市迁移,非常适用于解决“冷启动”场景下的推荐与预测问题。

(4) TRAINOR<sup>[22]</sup>. 该模型针对跨城市用户在城外的签到记录,利用神经主题模型挖掘指定数目的主题,并进一步描述用户在城外签到记录的生成过程。

(5) TransRec<sup>[20]</sup>. 该模型基于最大均值差异思想实现不同城市之间的兴趣点匹配,以此为媒介将不同城市中用户与地点之间的交互联合建模,从而实现用户移动偏好的自适应迁移。

(6) CityTrans<sup>[24]</sup>. 该模型在不针对用户城外轨迹进行意图挖掘的情况下,利用跨城市注意力机制对用户城内移动偏好与相似用户城外移动偏好进行直接交互,实现由城内至城外的用户兴趣偏好自适应迁移。

在上述对比方法中, CityTrans<sup>[24]</sup> 针对用户跨城市移动行为具有最高的预测准确性,而 CHAML<sup>[25]</sup> 则针对冷启动场景表现最佳,二者可被视作现有研究中解决用户城外移动行为预测问题的先进模型(State-Of-The-Art, SOTA)。

## 5.3 实验结果

### 5.3.1 用户城外出行意图发现

针对 LV-HD、PH-MS、BS-CA 三个数据集的城外区域 HD、MS、CA, 首先利用第 4.2 节所述方法构造带权有向地点网络, 随后通过随机游走进行城外轨迹采样. 在此基础上, 采用 ddCRP 对轨迹进行无监督聚类. 对于 LV-HD、PH-MS、BS-CA 三个数据集, 初步获得的类别数目依次为 12、11、8. 然而, 由于 ddCRP 缺乏语义鉴别能力<sup>[37]</sup>, 仅能实现数据的局部聚类, 初步得到的聚类结果存在语义“重叠”现象. 比如, BS-CA 数据集的聚类结果中存在两个类别的地点均与餐饮主题紧密相关, 因此有必要进行相似类别合并从而区分不同类别的边界. 由于

城外出行意图发现以离线计算形式进行, 因此可通过人工鉴别的方式进行相似类别合并.

类别合并后, LV-HD、PH-MS、BS-CA 三个数据集各自得到 10 个、10 个和 5 个主题. 据此, 将三个数据集对应的意图数量  $h$  分别设定为 10、10、5. 为直观展示 ddCRP 发现的意图及其含义, 以 BS-CA 数据集为例, 给出编号从 0 到 4 的 5 个出行意图以及相应的 Top 3 地点类别(如表 3 所示). 不难发现, 编号为 0 的意图与餐饮相关, 编号为 1 的意图与艺术会展相关, 编号为 2 的意图与差旅相关, 编号为 3 的意图与房产经纪相关, 而编号为 4 的意图则与医疗保健相关.

表 3 BS-CA 数据集用户城外出行意图

意图编号	Top 3 地点类别
#0	Restaurants/Food/Coffee & Tea
#1	Arts & Entertainment/Museums/Libraries
#2	Hotels & Travel/Transportation/Buses
#3	Professional Services/Real Estate/Home Services
#4	Health & Medical/Pediatricians/Medical Centers

### 5.3.2 针对跨城市用户的预测效果分析

基于 LV-HD、PH-MS、BS-CA 三个数据集, 分别采用  $Acc@K$  ( $K$  依次取 1、5、10) 和  $NDCG@K$  ( $K$  依次取 5、10) 评估不同模型的预测准确度和排序可靠性. 表 4 汇总了不同模型的性能指标, 其中每一行的加粗数值代表相应指标下的最优值, 标“\*”的数值表示相对于次优数值的增长具有统计学显著性(双侧 Fisher 检验  $p$ -value  $\leq 0.05$ ). 针对表 4 的实验结果, 有以下发现:

首先, 与 L2V 和 PMove 两种非跨城市移动行为预测方法相比, TIEMPO 框架的预测准确性具有非常明显的优势. 通过实证分析发现, L2V 等方法更适用于预测用户在日常活动范围内(比如住址所在区域、工作所在区域等)的访问地点, 对于远离上述区域的用户移动行为则预测性能较差. 与以上方法相比, TIEMPO 框架针对用户跨城市移动这一“长尾”事件进行适配, 在意图感知的基础上通过城内移动行为与城外出行意图交互建模能更加准确地预测用户在城外的访问地点.

其次, 与 CityTrans、TransRec 等若干用户城外移动行为预测模型相比, TIEMPO 框架在多种评价指标下同样表现最优. 以  $Acc@10$  指标为例, TIEMPO 框架与基线模型相比体现出明显优势. 具体而言, 在 LV-HD 数据集上, TIEMPO 相比 CityTrans、TransRec、TRAINOR 分别具有 3.43%、9.27%、14.83% 的性能提升; 在 PH-MS 数据集上, TIEMPO 相比

CityTrans、TransRec、TRAINOR 分别具有 3.36%、6.96%、14.95% 的性能提升; 在 BS-CA 数据集上, TIEMPO 与 CityTrans、TransRec、TRAINOR 相比, 分别表现出 3.35%、7.78%、12.15% 的性能优势, 在  $NDCG@10$  指标下也可观察到 TIEMPO 框架相较于基线模型的性能提升. 上述观察表明, TIEMPO 框架能有效预测跨城市用户在城外区域

的移动行为, 并且在预测准确度、排序可靠性两方面相比基线模型具有领先优势. 此外, 随着列表长度  $K$  增加, 虽然预测准确度和排序可靠性指标均有所提升, 但 TIEMPO 框架相比其余方法的优势却在缩小, 这意味着针对用户城外移动行为的预测准确性存在上界<sup>[38]</sup>, 而本文提出的基于出行意图增强的预测方法能够逼近该上界.

表 4 多种评价指标下不同模型的性能对比

数据集	评价指标	L2V <sup>[34]</sup>	PMove <sup>[35]</sup>	CCTP <sup>[36]</sup>	UIDT <sup>[21]</sup>	CHAML <sup>[25]</sup>	TRAINOR <sup>[22]</sup>	TransRec <sup>[20]</sup>	CityTrans <sup>[24]</sup>	TIEMPO
LV-HD	Acc@1	0.131	0.118	0.126	0.142	0.165	0.194	0.211	0.224	<b>0.232*</b>
	Acc@5	0.140	0.123	0.134	0.152	0.181	0.208	0.224	0.236	<b>0.247*</b>
	Acc@10	0.155	0.140	0.148	0.166	0.194	0.236	0.248	0.262	<b>0.271*</b>
	NDCG@5	0.202	0.185	0.188	0.234	0.362	0.381	0.386	0.397	<b>0.408*</b>
	NDCG@10	0.248	0.204	0.206	0.268	0.379	0.402	0.412	0.406	<b>0.418*</b>
PH-MS	Acc@1	0.118	0.102	0.107	0.134	0.156	0.188	0.202	0.210	<b>0.215*</b>
	Acc@5	0.122	0.106	0.112	0.146	0.173	0.198	0.214	0.221	<b>0.228*</b>
	Acc@10	0.138	0.120	0.127	0.169	0.208	0.214	0.230	0.238	<b>0.246*</b>
	NDCG@5	0.185	0.169	0.173	0.224	0.346	0.365	0.371	0.375	<b>0.386*</b>
	NDCG@10	0.240	0.187	0.190	0.252	0.354	0.369	0.377	0.379	<b>0.391*</b>
BS-CA	Acc@1	0.146	0.126	0.131	0.158	0.179	0.212	0.225	0.238	<b>0.247*</b>
	Acc@5	0.155	0.137	0.142	0.171	0.193	0.228	0.237	0.246	<b>0.256*</b>
	Acc@10	0.175	0.159	0.160	0.182	0.209	0.247	0.257	0.268	<b>0.277*</b>
	NDCG@5	0.211	0.188	0.194	0.245	0.371	0.389	0.397	0.399	<b>0.411*</b>
	NDCG@10	0.238	0.214	0.215	0.273	0.385	0.408	0.417	0.415	<b>0.428*</b>

需要指出, TIEMPO 和 CityTrans 均对用户城内长期移动偏好与相似用户城外短期兴趣偏移进行交互建模, 并基于迁移学习思想刻画用户移动知识的自适应迁移, 这使得用户在城外的移动偏好兼具中心城市移动模式与城外区域签到风格. 与 TRAINOR 等仅考虑用户自身城外签到数据的模型相比, TIEMPO 和 CityTrans 能更好地缓解数据稀疏问题. 与 TransRec、UIDT 等基于不同城市用户-地点交互行为联合建模进行知识迁移的模型相比, TIEMPO 和 CityTrans 显式融合了用户在城内的长期移动偏好与城外的短期兴趣偏移, 因此对用户城外移动偏好的刻画更加合理. 与 CityTrans 模型相比, TIEMPO 框架进一步对用户在外出行意图进行挖掘, 利用记忆网络提炼相似用户在城外的签到主题, 因此能更准确地预判用户在城外的访问地点类别, 从而提升预测准确性. 经过对数据集进行统计分析, 同时结合 Google Map 等可视化地图工具对不同城市兴趣点的空间分布进行观察, 我们发现近邻城市(比如 Phoenix 和 Mesa)在功能区域和空间布局上存在互补性, 而相距较远的城市(比如 Phoenix 和 Las Vegas)在功能区域和空间布局上则存在明显的同质性. 正是由于近邻城市用户出行需求的互补性, 导致用户由中心城市到城外区域的移动意图更加容

易预判(实质上等价于缩小了候选地点集合规模), 使得 TIEMPO 框架通过城内移动行为与城外出行意图交互建模能更加准确地预测用户在城外的访问地点. 因此, 与已有方法相比, 本文提出的 TIEMPO 框架适用于由中心城市到城外区域的跨近邻城市用户移动行为预测. 而 UIDT、TRAINOR、TransRec 等模型针对城市无关的人类移动模式共性和目标城市独有的地点特性进行研究, 更加适用于相距较远城市之间的用户跨城市移动行为预测.

为了进一步研究跨城市用户签到数据的作用, 图 9 绘制了  $Acc@10$  指标下各个数据集使用不同比




图 9 使用不同比例训练数据对预测结果的影响

例城外签到数据用于训练 TIEMPO 的效果. 可以发现, 随着用于训练 TIEMPO 框架的城外签到数据比例提升, 各个数据集的  $Acc@10$  指标均呈现明显的上升趋势, 且在数据可用比例为 100% 时,  $Acc@10$  指标达到最大值. 上述观察表明, 城外可用签到数据越多, 针对用户城外移动偏好刻画就越精确, 进而带来更理想的预测表现.

### 5.3.3 针对冷启动场景的预测效果分析

为评价不同模型在冷启动场景下的预测性能, 对于 LV-HD、PH-MS、BS-CA 三个数据集中的非跨城市用户, 将用户在城外唯一签到记录对应的地点作为真实标签, 利用不同模型分别生成预测列表, 通过观察真实标签是否存在列表中以及在列表中的次序计算  $Acc@10$  和  $NDCG@10$  值. 图 10 展示了两种指标下不同模型的预测结果.

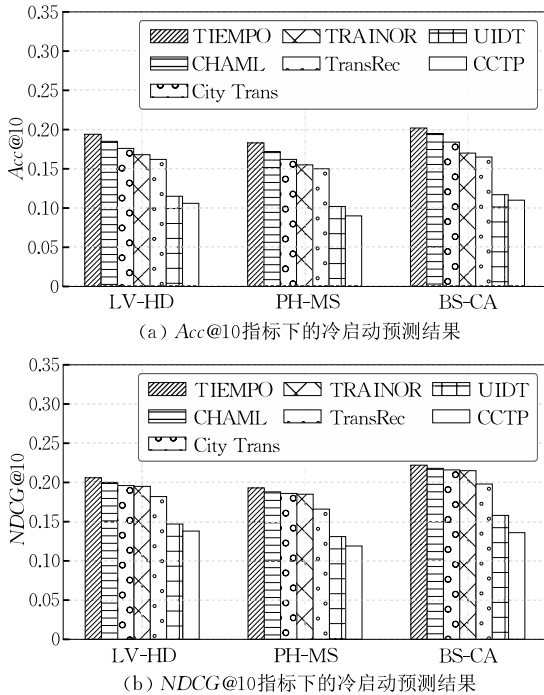



图 10 不同数据集下的冷启动预测结果

从图 10 可以发现, TIEMPO 框架在不同指标、不同数据集上一致表现最优, 即使与冷启动预测的先进模型 CHAML 相比, TIEMPO 依旧体现出较为明显的优势. 究其原因主要包括两个方面: 其一, CHAML 是一种针对完全冷启动场景的元学习预测框架, 即使存在大量跨城市用户, 但其完全忽略了中心城市用户的跨城市签到行为, 这导致该模型虽然能实现不同城市之间用户移动知识的相互迁移, 但是难以显式地刻画中心城市用户在城外区域的移动偏好. 其二, CHAML 并未针对用户的城外出行意图进行提炼, 在城外签到数据极度稀疏的背景下,


该模型难以准确捕获用户对于不同地点的访问偏好. 相比之下, TIEMPO 不仅充分利用中心城市用户在城外的移动轨迹, 还通过无监督聚类 and 相似用户意图提炼预判用户的城外签到主题, 即使在冷启动场景下, 也能更准确地预测目标用户在城外的访问地点.

### 5.3.4 记忆网络性能分析

TIEMPO 框架在线建模部分的核心组件是键值记忆网络. 为了评估记忆网络在出行意图建模中的作用, 需要测试 TIEMPO 框架在不同数目出行意图下的性能表现. 图 11 展示了记忆网络的意图数量  $h$  取值为  $\{5, 10, 15, 20, 25, 30\}$  时, TIEMPO 在不同指标下的预测性能. 为公平起见, 进行本实验时忽略离线计算部分基于 ddCRP 的城外轨迹无监督聚类结果. 无论  $h$  取何值, 记忆缓存矩阵  $\mathbf{M}$  的每一个记忆单元  $m_i$  均进行随机初始化.



(a) 不同意图数量对  $Acc@10$  指标的影响



(b) 不同意图数量对  $NDCG@10$  指标的影响

图 11 意图数量对于预测结果的影响

从图 11 可以看出, 总体上意图数量  $h$  的取值对于最终预测结果的影响并不显著, 当 LV-HD、PH-MS、BS-CA 三个数据集的意图数量  $h$  取值为 10、10、5 时, 预测性能可达到峰值, 这与离线计算部分针对

ddCRP 聚类结果合并后的意图数目一致. 此外, 通过对图 11(a)和图 11(b)中的数值进行分析, 可以发现预测结果的峰值低于表 4 的相应指标值, 这表明记忆缓存矩阵初始化对于建模用户城外出行意图具有增强作用.

为了直观展示记忆网络中键值的作用, 本文开展以下实证研究. 选取 BS-CA 数据集中某用户  $u$  访问卫星城市 Cambridge 哈佛艺术博物馆(Harvard Art Museums)这一跨城市签到为案例, 首先基于算法 1 对用户  $u$  的城外访问地点进行预测, 并抽取记忆网络中的值向量  $w$ . 然后, 结合表 3 所示 BS-CA 数据集的用户城外出行意图, 将记忆网络值向量  $w$  每一维度权重进行可视化展示(图 12). 可以发现, 编号为 1 的意图对应的权重最大, 而该意图与艺术会展活动紧密相关(参见表 3), 很大程度上体现了用户  $u$  此次城外签到的主题.




图 12 实证研究中记忆单元权重在不同意图上的分布

上述分析表明, TIEMPO 框架引入的记忆网络能有效预判用户在城外的出行意图, 进一步提升用户城外移动行为的可预测性.

### 5.3.5 消融实验

在上述分析的基础上, 进一步开展消融实验以定量评价 TIEMPO 框架中不同组件的作用. 具体而言, 逐步移除关键特征, 获得若干 TIEMPO 框架的变种, 并分别测试不同变种的实际表现. 图 13 展示了  $Acc@10$  指标下不同 TIEMPO 变种的性能, 其中, TIEMPO-Tran 表示移除总体损失函数的迁移损失项, TIEMPO-M 表示移除在线建模部分的记忆网络, TIEMPO-G 表示移除学习城外地点隐含表示的




图 13 消融实验结果

地理距离特征, TIEMPO-T 表示移除相似用户在城外区域  $T$  的偏好建模过程, 而 TIEMPO-S 表示移除用户在中心城市  $S$  的偏好建模过程.

在图 13 中, 对于不同的 TIEMPO 变种而言,  $Acc@10$  值越低, 说明被移除的相应特征越重要, 反之亦然. 因此, 可以推断在 TIEMPO 框架中, 针对用户在中心城市  $S$  的偏好建模最为重要, 即用户在中心城市长期稳定的移动模式相比其他特征对于预测结果的贡献最大, 而迁移损失项  $\mathcal{L}_T$  对于预测结果的贡献相对最弱. 此外, 移除相似用户城外偏好建模使得 TIEMPO-T 的预测性能相比其余变种下降明显, 这间接印证了相似用户的跨城市签到以及城外出行意图建模的重要性.

## 6 结 论

本文针对社交网络用户城外移动预测问题, 提出一种意图感知的用户城外移动偏好建模框架 TIEMPO. 离线计算部分, 针对采样获得的城外轨迹进行无监督聚类, 用于初始化记忆网络以建模用户城外出行意图; 在线建模部分, 通过多种注意力机制刻画用户城内移动偏好、城外出行意图的融合过程, 最后量化用户针对城外地点的访问概率. 实验结果从多个角度验证了所提框架的有效性.

未来的工作包括三个方面. 第一, 考虑利用评论、评分、图片等多模态用户生成数据建模用户城外移动偏好; 第二, 将用户城外移动预测场景进一步延伸至具有普遍性的跨城市人类移动预测, 特别是针对跨城市用户数近似为零的极端数据稀疏场景, 利用元学习探索人类移动偏好迁移的可行性; 第三, 进一步考虑数据处理效率和框架的可扩展性, 优化模型在实际应用中的实时预测响应时间.

## 参 考 文 献

- [1] Zhao Lin-Lin, Wu An-Biao, Yuan Ye, et al. Graph representation learning on location-based social networks. Chinese Journal of Computers, 2022, 45(4): 838-857(in Chinese) (赵琳琳, 吴安彪, 袁野等. 位置社交网络上的图表示学习. 计算机学报, 2022, 45(4): 838-857)
- [2] Xu Shuai, Fu Xiao-Ming, Pi De-Chang, et al. Inferring individual human mobility from sparse check-in data: A temporal-context-aware approach. IEEE Transactions on Computational Social Systems, 2024, 11(1): 600-611
- [3] Niu Hong-Ting, Sun Ying, Zhu Heng-Shu, et al. Exploring the tidal effect of urban business district with large-scale human mobility data. Frontiers of Computer Science, 2023, 17(3): 173319

- [4] Alessandretti L, Aslak U, Lehmann S. The scales of human mobility. *Nature*, 2020, 587(7834): 402-407
- [5] Zhang Chao, Zhao Kai, Chen Meng. Beyond the limits of predictability in human mobility prediction: Context-transition predictability. *IEEE Transactions on Knowledge and Data Engineering*, 2023, 35(5): 4514-4526
- [6] Ding Dai-Zong, Zhang Mi, Pan Xu-Dong, et al. Modeling personalized out-of-town distances in location recommendation // *Proceedings of the 2020 IEEE International Conference on Data Mining*. Sorrento, Italy, 2020: 112-121
- [7] Zhang Xiao, Ye Zi-Ming, Lu Jian-Feng, et al. Fine-grained preference-aware personalized federated POI recommendation with data sparsity // *Proceedings of the 46th International ACM SIGIR Conference on Research and Development in Information Retrieval*. Taipei, China, 2023: 413-422
- [8] Liu Xiao-Jian, Zhu Yi, Wu Xin-Dong. Joint user profiling with hierarchical attention networks. *Frontiers of Computer Science*, 2023, 17(3): 173608
- [9] Xiong Chen-Feng, Hu Song-Hua, Yang Mo-Feng, et al. Mobile device data reveal: The dynamics in a positive relationship between human mobility and COVID-19 infections. *Proceedings of the National Academy of Sciences*, 2020, 117(44): 27087-27089
- [10] Gupta V, Bedathur S. Doing more with less: Overcoming data scarcity for POI recommendation via cross-region transfer. *ACM Transactions on Intelligent Systems and Technology*, 2022, 13(3): 1-24
- [11] Zhang Jing-Lei, Shi Hai-Long, Cui Li. Location prediction model based on transportation mode and semantic trajectory. *Journal of Computer Research and Development*, 2019, 56(7): 1357-1369 (in Chinese)  
(章静蕾, 石海龙, 崔莉. 基于出行方式及语义轨迹的位置预测模型. *计算机研究与发展*, 2019, 56(7): 1357-1369)
- [12] Massimiliano L, Gianni B, Bruno L, et al. A survey on deep learning for human mobility. *ACM Computing Surveys (CSUR)*, 2021, 55(1): 1-44
- [13] Yin Hong-Zhi, Zhou Xiao-Fang, Cui Bin, et al. Adapting to user interest drift for POI recommendation. *IEEE Transactions on Knowledge and Data Engineering*, 2016, 28(10): 2566-2581
- [14] Wang Hao, Fu Yan-Mei, Wang Qin-Yong, et al. A location-sentiment-aware recommender system for both home-town and out-of-town users // *Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. Halifax, Canada, 2017: 1135-1143
- [15] Ferenc G, Ye Mao, Lee W-C. Location recommendation for out-of-town users in location-based social networks // *Proceedings of the 22nd ACM International Conference on Information and Knowledge Management*. San Francisco, USA, 2013: 721-726
- [16] Wang Wei-Qing, Yin Hong-Zhi, Chen Ling, et al. Geo-SAGE: A geographical sparse additive generative model for spatial item recommendation // *Proceedings of the 21st ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. Sydney, Australia, 2015: 1255-1264
- [17] Wang Zhen, Mu Chun-Jiang, Hu Shu-Ye, et al. Modelling the dynamics of regret minimization in large agent populations: A master equation approach // *Proceedings of the 31st International Joint Conference on Artificial Intelligence*. Vienna, Austria, 2022: 534-540
- [18] Pham T, Li Xu-Tao, Cong Gao. A general model for out-of-town region recommendation // *Proceedings of the 26th International Conference on World Wide Web*. Perth, Australia, 2017: 401-410
- [19] Sun Hui-Min, Xu Jia-Jie, Zhou Rui, et al. HOPE: A hybrid deep neural model for out-of-town next POI recommendation. *World Wide Web*, 2021, 24(5): 1749-1768
- [20] Li Di-Chao, Gong Zhi-Guo. A deep neural network for crossing-city POI recommendations. *IEEE Transactions on Knowledge and Data Engineering*, 2020, 34(8): 3536-3548
- [21] Ding Jing-Tao, Yu Guang-Hui, Li Yong, et al. Learning from hometown and current city: Cross-city POI recommendation via interest drift and transfer learning. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 2019, 3(4): 1-28
- [22] Xin Hao-Ran, Lu Xin-Jiang, Xu Tong, et al. Out-of-town recommendation with travel intention modeling // *Proceedings of the 35th AAAI Conference on Artificial Intelligence*. New York, USA, 2021: 4529-4536
- [23] Zhu Neng-Jun, Cao Jian, Lu Xin-Jiang, et al. Predicting a person's next activity region with a dynamic region-relation-aware graph neural network. *ACM Transactions on Knowledge Discovery from Data*, 2022, 16(6): 1-23
- [24] Xu Shuai, Xu Jian-Qiu, Li Bo-Han, et al. Predicting where you visit in a surrounding city: A mobility knowledge transfer framework based on cross-city travelers // *Proceedings of the 28th International Conference on Database Systems for Advanced Applications*. Tianjin, China, 2023: 334-350
- [25] Chen Yu-Dong, Wang Xin, Fan Miao, et al. Curriculum meta-learning for next POI recommendation // *Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*. Singapore, 2021: 2692-2702
- [26] Xin Hao-Ran, Lu Xin-Jiang, Zhu Neng-Jun, et al. CAPTOR: A crowd-aware pre-travel recommender system for out-of-town users // *Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval*. Madrid, Spain, 2022: 1174-1184
- [27] Zhou Wei, Huang Hong, Shi Rui-Ze, et al. Temporal heterogeneous information network embedding via semantic evolution. *IEEE Transactions on Knowledge and Data Engineering*, 2023, 35(12): 13031-13042
- [28] Blei D M, Frazier P I. Distance dependent Chinese restaurant processes. *Journal of Machine Learning Research*, 2011, 12(8): 2461-2488
- [29] Xu Shuai, Cao Jiu-Xin, Li Shan-Cang, et al. Venue2Vec: An efficient embedding model for fine-grained user location prediction in Geo-Social networks. *IEEE Systems Journal*, 2020, 14(2): 1740-1751

- [30] Li Di-Chao, Gong Zhi-Guo, Zhang De-Fu. A common topic transfer learning model for crossing city POI recommendations. *IEEE Transactions on Cybernetics*, 2019, 49(12): 4282-4295
- [31] Zhou Xiao, Mascolo C, Zhao Zhong-Xiang. Topic-enhanced memory networks for personalized point-of-interest recommendation//*Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. Anchorage, USA, 2019; 3018-3028
- [32] Rendle S, Freudenthaler C, Gantner Z, et al. BPR: Bayesian personalized ranking from implicit feedback. *arXiv preprint arXiv:1205.2618*, 2012
- [33] Kingma D P, Ba J. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*, 2014
- [34] Yang Ding-Qi, Qu Bing-Qing, Yang Jie, et al. Revisiting user mobility and social relationships in LBSNs: A hypergraph embedding approach//*Proceedings of the Web Conference 2019*. San Francisco, USA, 2019; 2147-2157
- [35] Sun Hao, Yang Chang-Jie, Deng Li-Wei, et al. Periodic-Move: Shift-aware human mobility recovery with graph neural network//*Proceedings of the 30th ACM International Conference on Information & Knowledge Management*. Gold Coast, Australia, 2021; 1734-1743
- [36] Xie Rong, Chen Yang, Xie Qin-Ge, et al. We know your preferences in new cities: Mining and modeling the behavior of travelers. *IEEE Communications Magazine*, 2018, 56(11): 28-35
- [37] Orbanz P, Roy D M. Bayesian models of graphs, arrays and other exchangeable random structures. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2014, 37(2): 437-461
- [38] Feng Jie, Rong Can, Sun Fu-Ning, et al. PMF: A privacy-preserving human mobility prediction framework via federated learning. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 2020, 4(1): 1-21



**XU Shuai**, Ph. D. , associate professor. His main research interests include social computing and smart cities.

**LI Bo-Han**, Ph. D. , associate professor. His main research interests include temporal-spatial data mining and

knowledge graph.

**XU Jian-Qiu**, Ph. D. , professor. His main research interests focus on temporal-spatial databases.

**CAO Jiu-Xin**, Ph. D. , professor. His main research interests include complex network and data security.

**FU Xiao-Ming**, Ph. D. , professor, IEEE Fellow, ACM Distinguished Scientist, and member of Academia Europaea. His main research interests include computer network, cloud computing, big data, and online social networks.

## Background

The problem studied in this paper is human mobility modeling and prediction in the field of computational social science. Human mobility prediction has practical significance for serving major national needs such as smart city construction. Existing studies are mainly based on the rich temporal-spatial data accumulated in specific cities to solve the problem of human mobility prediction within a city. However, the extremely sparse human trajectories across cities and the lack of temporal-spatial data in most cities make it difficult for related works to cope with cross-city human mobility prediction.

In this paper, we consider an intriguing problem, that is predicting a social network user's visit location in the out-of-town area, where users rarely leave trajectories due to the long-tail nature of out-of-town mobility and the need for personal privacy preserving. For this problem, the extreme data sparsity issue and out-of-town user preference modeling urgently need to be solved. To overcome the above challenges, user mobility preference in down-town areas and interest drift in out-of-town areas are simultaneously incorporated for

cross-city mobility prediction, where an intention-aware user mobility preference modeling framework called TIEMPO is conceived and implemented. By inducing user travel intentions in advance, TIEMPO is expected to enhance the predictability of users' out-of-town mobility. Compared with existing approaches, the proposed framework achieves more accuracy under various prediction scenarios. In practical terms, for any kind of user trajectories generated by location-based services (not limited to geo-social networks), the proposed TIEMPO framework can be applicable for predicting user visit locations outside the city as long as similar users' trajectories can be properly collected.

The research presented in this paper is supported in part by the National Natural Science Foundation of China under Grant No. 62302213 and No. U23A20296, the Natural Science Foundation of Jiangsu Province under Grant No. BK20210280, and the Fundamental Research Funds for the Central Universities under Grant No. NS2022089.