

基于地理时空关联和社会影响的兴趣点推荐

金红, 陈礼珂, 游兰, 吕顺营, 周开成, 肖奎

引用本文

金红, 陈礼珂, 游兰, 吕顺营, 周开成, 肖奎. [基于地理时空关联和社会影响的兴趣点推荐](#)[J]. 计算机科学, 2025, 52(5): 128-138.

JIN Hong, CHEN Like, YOU Lan, LYU Shunying, ZHOU Kaicheng, XIAO Kui. [Point-of-interest Recommendation Based on Geospatial-Temporal Correlations and Social Influence](#) [J]. Computer Science, 2025, 52(5): 128-138.

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)

[开源软件开发者价值评估体系及其实证研究](#)

Value Assessment System Oriented for Open-source Software Developers and Its Empirical Research
计算机科学, 2024, 51(12): 87-99. <https://doi.org/10.11896/jsjcx.240100169>

[面向兴趣点推荐系统的自然噪声过滤算法](#)

Natural Noise Filtering Algorithm for Point-of-Interest Recommender Systems
计算机科学, 2023, 50(11): 132-142. <https://doi.org/10.11896/jsjcx.230400045>

[基于人群移动模式先验的兴趣点推荐](#)

Human Mobility Pattern Prior Knowledge Based POI Recommendation
计算机科学, 2023, 50(9): 139-144. <https://doi.org/10.11896/jsjcx.220900114>

[基于多目特征交叉的服务推荐算法](#)

Service Recommendation Algorithm Based on Multi-features Crossing
计算机科学, 2023, 50(6A): 210800242-7. <https://doi.org/10.11896/jsjcx.210800242>

[基于Apriori算法填充数据及改进相似度的推荐算法](#)

Recommendation Algorithm Based on Apriori Algorithm and Improved Similarity
计算机科学, 2022, 49(11A): 211000005-5. <https://doi.org/10.11896/jsjcx.211000005>

基于地理时空关联和社会影响的兴趣点推荐

金红^{1,3} 陈礼珂¹ 游兰^{1,3} 吕顺营^{2,4} 周开成¹ 肖奎^{1,4}

1 湖北大学计算机学院 武汉 430062

2 湖北大学网络空间安全学院 武汉 430062

3 大数据智能分析与行业应用湖北省重点实验室(湖北大学) 武汉 430062

4 智能感知系统与安全教育部重点实验室(湖北大学) 武汉 430062

(anya_1024@163.com)

摘要 随着基于位置的社交网络的流行,个性化兴趣点推荐已经成为一项重要任务。然而现有研究在对上下文信息建模及融合时对其内在联系考虑不充分,其中地理与时间两种上下文之间往往是相互影响的;此外,在建模用户社会关系时主要通过度量不同用户签到的POI子集之间的直接相似性来表达用户社交行为的相似性程度,未能更好地缓解数据稀疏对不同用户签到POI子集相似性度量的影响。因此,合理地重构了上下文信息模型并有效地融合建模到用户偏好中,提出了一种基于地理时空关联和社会影响的兴趣点推荐方法。该方法根据不同时间状态下用户的主要地理活动中心呈现空间聚集现象,使用带有时间约束的方法评估POI间的地理相关性,以建模POI地理信息对用户签到的影响。进一步地,在对用户社会关系建模时假设具有更多共同签到的POI或签到POI的类别有着更大重合度的用户社交行为的相似性更高,结合POI类别信息来提高社会关系建模的有效性和作用。最后,将提出的地理时空关联模型和用户社会关系模型融合到加权矩阵分解中,进行用户的个性化POI推荐。对比实验结果表明,所提方法具有更好的POI推荐性能,说明了提出的模型在上下文建模和克服数据稀疏性方面更具优势。

关键词: 基于位置的社交网络;兴趣点推荐;数据稀疏;地理时空关联;社会影响

中图分类号 TP391

Point-of-interest Recommendation Based on Geospatial-Temporal Correlations and Social Influence

JIN Hong^{1,3}, CHEN Like¹, YOU Lan^{1,3}, LYU Shunying^{2,4}, ZHOU Kaicheng¹ and XIAO Kui^{1,4}

1 School of Computer Science, Hubei University, Wuhan 430062, China

2 School of Cyber Science and Technology, Hubei University, Wuhan 430062, China

3 Hubei Key Laboratory of Big Data Intelligent Analysis and Application(Hubei University), Wuhan 430062, China

4 Key Laboratory of Intelligent Sensing System and Security(Hubei University), Ministry of Education, Wuhan 430062, China

Abstract With the popularity of location-based social networks, personalized POI recommendation has become an important task. However, existing research inadequately considers the intrinsic relationships when modeling and integrating contextual information. Among these, geographical and temporal contexts often interact with and influence each other. Moreover, when modeling user social relationships, current approaches primarily measure the direct similarity between POI subsets visited by different users to express the similarity of their social behaviors. These approaches fails to effectively alleviate the impact of data sparsity on measuring the similarity of POI subsets visited by different users. Therefore, by reasonably reconstructing the contextual information model and effectively integrating it into user preference model, a POI recommendation method based on geospatial-temporal correlations and social influence is proposed. This method leverages the spatial aggregation phenomenon of users' primary geographic activity centers under different temporal states. It employs a time-constrained approach to assess the geographical correlations between POIs, thereby modeling the impact of POI geographical information on user check-ins. Furthermore, when modeling user social relationships, it is assumed that users with more shared check-ins at POIs or greater overlap in the categories of POIs they visit exhibit higher similarity in their social behaviors. By incorporating POI category information, the effectiveness and utility of social relationship modeling are enhanced. Finally, the proposed geospatial-temporal correlation model and user social re-

到稿日期:2024-02-26 返修日期:2024-07-29

基金项目:国家自然科学基金(62377009);湖北省重点研发计划(2022BAA044);湖北省教育厅科学研究计划(Q20211010)

This work was supported by the National Natural Science Foundation of China(62377009), Key R & D Program of Hubei Province(2022BAA044) and Scientific Research Project of Education Department of Hubei Province(Q20211010).

通信作者:吕顺营(823356045@qq.com)

relationship model are integrated into a weighted matrix factorization framework to perform personalized POI recommendations for users. Extensive experiments demonstrate that the proposed method achieves superior POI recommendation performance, highlighting the advantages of the proposed models in contextual modeling and overcoming data sparsity.

Keywords Location-based social network, Point-of-interest recommendation, Data sparse, Geospatial-temporal correlations, Social influence

1 引言

近年来,随着移动设备的普及以及无线通信技术的进步, Gowalla, Foursquare, Yelp 等基于位置的社交网络(Location-Based Social Network, LBSN)发展迅速。这些平台吸引了数百万用户进行使用和共享信息,用户可以通过移动设备实时签到的形式发布他们的物理位置并与朋友分享访问兴趣点(Point-of-Interest, POI)的经验,如餐厅、购物广场等。图1给出了LBSNs的基本结构,用户往往会在访问某个兴趣点后对其进行签到和评分,这些签到和评分对于了解用户偏好和行为至关重要。除用户签到信息外,还可以从LBSN中获取大量上下文信息,如用户社交信息、POI地理信息、POI类别信息和POI签到时间等,合理利用这些上下文信息极大地提高了POI推荐的准确性。POI推荐不仅可以帮助用户探索有吸引力和有趣的地方,为用户做出正确决策以便节省时间,引导用户体验实时场景,还可以帮助商家发现更多潜在用户群体,刺激用户消费欲望并提升企业盈利能力。




图1 基于位置的社交网络结构

Fig. 1 Location-based social network structure

目前针对个性化POI推荐已涌现出许多不同方法,其中基于协同过滤的方法^[1]是推荐中应用最广泛的技术。它们基于用户倾向于访问相似POI的特性,给用户推荐其感兴趣但未访问过的POI。但这种方法需要大量的用户签到数据,然而,现实生活中POI不计其数且遍及世界各地,用户往往只对其中极少数POI进行访问并签到。这就导致用户签到数据高度稀疏,因此缓解POI签到数据的稀疏性对个性化POI推荐准确性的影响是一个关键问题。不同于传统的商品推荐,个性化POI推荐具有以地理信息为代表的复杂上下文信息。这些信息均会对用户产生不同程度的影响,但如何有效建模用户自身偏好和这些上下文信息也是一项挑战。

已有研究工作^[1]证明了地理信息在用户个性化POI推荐中的有效性和重要性,但大部分研究在对不同上下文建模并融合的过程中对它们之间的内在联系考虑得不够充分。

例如,在不同时间状态下用户签到POI的地理分布呈现空间聚集现象,说明不同上下文信息之间并不是相互独立的。此外,用户的行为通常会受到朋友的影响,现有研究主要专注于如何将社会关系信息融合建模到POI推荐框架中^[2],较少对社会关系信息本身进行更深入的研究。在建模用户的社会关系信息时,大多数研究主要考虑相互关注的用户之间的直接朋友关系,而忽视了在相同POI签到和相同类别POI签到的用户之间的行为相似关系。相比直接朋友关系,具有相似POI签到行为的用户之间的影响是对社会关系信息建模的有效补充。例如,好朋友之间可能具有不一样的兴趣偏好,一人爱吃辣而另一人喜好甜食,那么在选择餐厅时就会做出不同的决策。而经常访问同一个POI或者访问同类型POI的用户在签到行为上极其相似,在建模社会关系影响时应给予考虑。虽然已有研究表明了朋友关系对用户POI决策的影响,但仍需要进一步挖掘非朋友用户之间的社会(行为)关系在POI个性化推荐中所扮演的角色。

综上所述,本文在融合上下文关系时,主要考虑了地理因素与时间因素之间的内在联系以更准确地刻画上下文对POI推荐的影响;同时,对社会关系建模做了更深层次的探索,在用户签到行为相似性度量方面通过引入POI类别信息缓解了数据稀疏对社会关系建模的负面影响;提出了一个基于地理时空关联和社会影响的POI推荐模型,从用户社会关系信息、地理信息,以及用户自身偏好这3个方面建模用户签到行为。首先,通过基于用户的协同过滤方法得到社会信息对用户签到行为的影响程度。在计算用户之间的相似度时,考虑两种类型的朋友关系:友谊关系和行为关系。并且,在建模行为关系时,假设那些具有更多共同签到的POI或签到POI的类别有着更大重合度的用户的相似性更高。其次,在建模地理信息对用户签到行为的影响时,考虑到签到POI在不同时间状态下存在的空间聚集现象,利用带时间约束的方式衡量不同地理位置的相似性。最后,为了更好地拟合用户签到行为,本文将提出的社会关系和地理时空建模以一致的方式融合到一个通用的加权矩阵分解模型中,合理融合用户自身偏好和上下文信息,提高了POI推荐的准确率。

本文的主要贡献如下:

1)在建模社会关系信息影响时,通过友谊关系和行为关系这两种类型的朋友关系来更准确地刻画用户之间的社会相似性。为了缓解数据稀疏对社会关系建模的影响,在计算行为关系时结合POI类别信息进行合理假设,认为那些具有更多共同签到的POI或签到POI的类别有着更大重合度的用户相似性更高。

2)在建模地理信息影响时,根据在不同时间状态下POI分布呈现的空间聚集现象,结合时间因素来更准确地刻画地理

位置之间的相似性;并提出了一个通用的融合用户自身偏好和上下文信息的加权矩阵分解模型,该模型具有良好的扩展性。

3)在两个真实的 LBSN 数据集上进行了充分的实验,实验结果表明本文方法能够很好地应对数据稀疏问题,与当前主流的推荐算法相比具有更高的准确性。

本文第 2 章介绍了现有 POI 推荐的研究现状;第 3 章建模用户上下文信息,包括用户社会关系信息、地理信息等,并将其与用户自身偏好融合;第 4 章通过实验验证了本文模型的性能;最后总结全文并展望未来。

2 相关工作

近年来,个性化 POI 推荐颇为流行,现有研究主要将用户签到数据与多种上下文信息结合起来提高推荐性能,如地理信息、用户社会关系信息、POI 类别信息、时间信息等。

2.1 基于地理信息的 POI 推荐

不同于传统推荐系统,POI 的位置与用户签到行为密切相关^[3]。因此,如何有效利用地理位置信息是 POI 推荐的一项重要任务。Zhang 等^[2]提出了一个基于任意两个 POI 之间距离分布的核密度估计的个性化融合框架。Lian 等^[4]提出了 GeoMF,采用加权矩阵分解来整合空间聚类现象,将地点划分为网格,分别利用用户活动区域向量和 POI 影响区域向量来增强用户和 POI 的隐藏特征,实验结果表明模型是有效的,但不能捕捉到用户活动的周期性特征。Liu 等^[5]设计了地理概率因素分析框架,该框架关注多个因素,包括用户-POI 签到次数、选择 POI 的地理影响和用户移动性等,通过该模型可以很好地模拟用户移动行为,但在模型中时间因素没有得到充分利用。Li 等^[6]通过研究地理和时间特征对用户的影响来计算用户上下文感知相似性,为用户生成动态的 POI 推荐列表。

2.2 基于社会关系信息的 POI 推荐

在 LBSNs 中,许多学者考虑社交关系以提高 POI 推荐性能,因为社交朋友比陌生人更可能有相似的兴趣偏好^[7]。Guo 等^[8]在推荐时用社会网络来填补偏好数据的空白,通过合并用户可信邻居的评级,为用户创建一个新的评级档案,缓解了冷启动问题。Li 等^[9]定义了一个两步走框架:首先,根据用户朋友的偏好来确定用户感兴趣但未访问的 POI;其次,对用户之间的社交关系进行分类,分为互相关注的用户关系、访问相同 POI 的用户关系,以及地理位置较近的用户关系,并用矩阵分解模型来学习用户及其朋友的偏好数据,提高了 POI 推荐准确率。Ding 等^[10]提出了一种深度学习网络来学习签到数据中的用户共同访问以及地理和 POI 分类信息对用户签到的联合影响,以此来缓解 POI 推荐中的数据稀疏问题。

2.3 基于类别等信息的 POI 推荐

除上述上下文信息外,部分研究考虑将其他上下文信息应用于 POI 推荐中。POI 类别信息能有效衡量用户对相应 POI 类别的偏好。Zhang 等^[11]在建模地理相关性和社会相关性的基础上,考虑用户对 POI 类别的偏好,联合类别相关性来计算用户与未访问 POI 的相关性得分。Ren 等^[12]提出了一种基于上下文感知概率矩阵分解模型的有效 POI 推荐方法,

同时将地理信息、社交信息、类别信息及文本信息纳入模型中。Ma 等^[13]为了捕捉用户分类偏好,设计了一种基于类别分层结构的方法,并将其与地理和社交偏好相结合进行推荐。此外,时间信息也是 POI 推荐的一个重要因素,现有研究针对用户偏好随时间变化的规律,建模了时间信息对个性化 POI 推荐的影响。Yuan 等^[14]结合了时间和空间两个方面,设计了一个基于 CF 的模型来整合时间循环模式,使用余弦相似度来识别具有相似兴趣的用户。Zhao 等^[15]设计了一种时间索引方案来捕捉连续 POI 推荐的特定时间特征,以显示三片式时间间隔连续签到的效果。Zhang 等^[16]提出了一个概率框架,不仅考虑到一天的时间段,还考虑了工作日和周末,但不能区分用户个性化兴趣。Luo 等^[17]提出了基于位置推荐的时空注意力网络模型 STAN,设计了两个注意力层来提取连续和非连续 POI 之间的相对时空信息。

3 融合地理时空关联与社会影响的 POI 推荐方法

3.1 问题描述

本研究的目标是给用户推荐一系列符合其喜好但未曾访问的 POI 供用户选择。根据用户对 POI 的历史签到数据以及各种上下文信息,融合建模社会关系信息、地理时空信息以及个人偏好对用户 POI 决策的影响,从而向目标用户推荐 top-N 的 POI。本文用到的基本符号如表 1 所列。

表 1 基本符号描述

Table 1 Description of basic symbols

符号	描述
U	用户集合 $U = \{u_1, u_2, u_3, \dots, u_m\}$
L	POI 集合 $L = \{l_1, l_2, l_3, \dots, l_n\}$
T	POI 类别集合 $T = \{t_1, t_2, t_3, \dots, t_j\}$
K	隐藏特征矩阵维度
$R_{m \times n} = [r_{u,l}]$	用户对 POI 的签到次数矩阵
$C_{m \times n} = [c_{u,l}]$	签到矩阵 R 的二值化矩阵
$S_{m \times n} = [s_{u,l}]$	用户对 POI 在社交媒体上的偏好程度矩阵
$G_{m \times n} = [g_{u,l}]$	用户对 POI 在地理位置上的偏好程度矩阵
P	用户隐藏特征矩阵
Q	POI 隐藏特征矩阵
p_u	P 中用户 u 对应的隐藏特征向量
q_l	Q 中 POI l 对应的隐藏特征向量

3.2 用户社会关系信息建模

一般来说,在现实世界中,朋友之间在兴趣爱好方面具有更高的相似性^[18]。例如,朋友之间可能会相约去餐厅打卡、一起购物等。公开数据表明,用户访问的新地点中有 30% 以上是朋友或者朋友的朋友访问过的。因此,社会关系信息有着将用户联系起来的重要作用,可以影响用户签到行为。除了用户之间的友谊关系外,我们也考虑到用户签到行为的相似性。例如,两个用户经常访问同一个或者同类型的 POI,说明他们之间具有相似的兴趣爱好。这表明用户决定访问新地点时,社会关系信息会影响用户的选择。因此,利用用户的历史签到数据来挖掘用户之间的社会关系相似性,在一定程度上可以提高 POI 推荐的准确率。尽管研究结果指出社会关系信息对用户签到行为的影响是有限的,但它不应该被忽视。

因此,在社会关系信息方面,本文定义两种类型的关系:友谊关系和行为关系。友谊关系指在 LBSN 中相互关注的用户;而行为关系则指具有大量相似签到行为的用户,他们

一般具有相似的兴趣爱好,但不一定是直接的朋友关系。




图2 用户社交关系

Fig. 2 User social relationships

我们使用用户之间的友谊关系和行为关系来获得用户社会关系信息对用户决策行为的影响。本文从两个方面考虑用户之间的相似度。一方面,考虑用户社交网络上的相似度,如果两个用户相互关注,我们用实线连接他们,即为用户之间的友谊关系;另一方面,考虑用户签到行为上的相似度,用虚线连接具有相似兴趣爱好但不是直接朋友关系的用户,即为用户之间的行为关系,如图2所示。两个用户之间也可能同时存在友谊关系和行为关系。对于每个用户 u , 考虑他访问的 POI, 根据用户 u 访问过的 POI 及其访问频率, 将用户 u 对 POI 的签到行为以及签到次数表示为向量 \mathbf{pr}_u :

$$\mathbf{pr}_u = (f_{u,l_1}, f_{u,l_2}, \dots, f_{u,l_n}) \quad (1)$$

在这个向量中,如果 $f_{u,l_i} = 0$, 表示用户 u 未访问过 POI l_i , 否则 f_{u,l_i} 为用户 u 对 POI l_i 的签到次数, 我们对其进行归一化。

其次,根据用户访问 POI 的类别,将用户 u 对 POI 类别的签到向量表示为向量 \mathbf{cb}_u :

$$\mathbf{cb}_u = (f_{u,t_1}, f_{u,t_2}, \dots, f_{u,t_j}) \quad (2)$$

其中, f_{u,t_i} 表示用户 u 对 POI 类别 t_i 的访问次数, 并同上式一样进行归一化。

接下来,根据所有用户对 POI 的历史签到数据来计算用户之间的相似性。从两个角度出发,首先,若用户之间经常访问同一个 POI, 则认为他们的兴趣偏好更为相似。其次,考虑到用户往往分布在不同的区域,而不同区域内的两个用户在一个 POI 签到的概率是很小的,即使这两个用户兴趣偏好是相似的。因此我们认为,访问相同 POI 类别的用户也具有一定的相似性。基于上述两种情况,计算用户之间签到行为的相似性,如式(3)所示:

$$\text{sim}(u, u') = \cos(\mathbf{pr}_u, \mathbf{pr}_{u'}) + \eta \cos(\mathbf{cb}_u, \mathbf{cb}_{u'}) \quad (3)$$

以往的研究中计算两个用户的相似度方法^[19]有 Jaccard 相似度和 cosine 相似度等,本文使用余弦相似度衡量两个用户之间的相似性。其中 \mathbf{pr}_u 向量和 \mathbf{cb}_u 向量分别表示用户 u 访问 POI 的次数和用户 u 访问属于某种类型的 POI 次数, η 用来衡量签到相同 POI 和签到相同类型 POI 对相似关系的影响程度。

余弦值越接近 1, 两个向量越相似; 其值越接近 0, 就越不相似。对于同时存在友谊关系和行为关系的情况, 我们对其进行融合, 最终的用户相似度为:

$$A_{u,u'} = \begin{cases} (1-\beta) \cdot \frac{1}{|F_u|}, & \text{if } u' \in F_u \cap u' \notin SF_u \\ (1-\beta) \cdot \frac{1}{|F_u|} + \frac{\beta}{S_u} \cdot \text{sim}(u, u'), & \text{if } u' \in F_u \cap SF_u \\ \frac{\beta}{S_u} \cdot \text{sim}(u, u'), & \text{if } u' \in SF_u \cap u' \notin F_u \end{cases} \quad (4)$$

其中, $A_{u,u'}$ 表示用户 u 和用户 u' 之间的相似度; F_u 表示与用户 u 互相关注的朋友集合, SF_u 表示与用户 u 访问过相同 POI 或相同类型 POI 的朋友集合, $S_u = \sum_{u' \in SF_u} \text{sim}(u, u')$; β 是权重因子, 用来权衡友谊关系和行为关系对用户相似度的影响程度。经过上述计算, 得到两个用户之间融合后的社会关系相似度 $A_{u,u'}$ 。

本文使用基于用户的协同过滤方法来获得社会关系信息对用户签到的影响, 计算式如下:

$$s_{u,l} = \frac{\sum_{u' \in U} A_{u,u'} \cdot c_{u',l}}{\sum_{u' \in U} A_{u,u'}} \quad (5)$$

其中, $s_{u,l}$ 表示用户 u 在社会关系信息影响下对 POI l 签到的概率; $c_{u',l} = 1$ 表示用户 u' 访问过 POI l , $c_{u',l} = 0$ 表示用户 u' 未访问过 POI l ; $A_{u,u'}$ 表示用户 u 和用户 u' 之间的相似度。

3.3 地理信息建模

用户签到行为可以反映出用户频繁活动的地理范围以及偏好。在 LBSN 上, 用户签到行为往往存在空间聚类现象, 即用户访问位置倾向于聚集在一起, 也就是说用户倾向于访问他们之前访问过的 POI 附近的地点^[20]。通过对空间聚类现象进行建模, 对于用户未访问过的 POI, 可以区分是用户自身对其不感兴趣还是用户不知其存在但可能吸引用户的位置。尤其是用户经常访问的 POI 附近未访问的 POI, 更有可能是用户本身不感兴趣的。因为如果用户经常访问某个 POI, 但从未访问过周围的 POI, 那么用户将来访问这些 POI 的可能性很小。

以往研究在对用户签到行为进行建模时, 往往没有考虑到地理信息和时间信息之间的联合作用。但用户通常会在特定时间做出相同特定行为, 例如用户在用餐时间更倾向于去餐厅而不是花店, 即用户会在相同或相近的时间访问相似的 POI。考虑到用户签到受时间变化的影响, 本文将其划分为工作时间和休息时间: 我们将一天 24 小时分为工作时间(早上 8:00 至下午 18:00) 和休息时间(下午 18:00 至次日早上 8:00)。例如, 用户在工作时间可能会选择每天去同一家餐厅用餐, 但在休息时间该用户会访问更多样化的 POI。因此, 本文考虑地理和时间之间的相互影响有助于更好地对用户签到行为进行建模。

受以上启发, 本文将两种特征现象共同应用于地理信息建模, 用 $g_{u,l}$ 来表示用户 u 对未访问过的 POI l 在给定活动中心 C_u 的访问概率。

$$g_{u,l} = P(u, l | C_u) = \frac{|C_u|}{\sum_{c_u \in C_u} \text{dist}(l, c_u)} \cdot \frac{f_{c_u}}{\sum_{i \in C_u} f_i} \quad (6)$$

其中, l 表示 POI 的经纬度; C_u 表示用户 u 的活动中心集合; $c_u \in C_u$, f_{c_u} 表示活动中心 c_u 内的签到次数; $\sum_{i \in C_u} f_i$ 则表示用户所有活动中心的总签到次数; $\text{dist}(l, c_u)$ 为 POI l 和活动中心 c_u 之间的距离, 这里本文利用 POI 的经纬度信息, 通过球面半正矢公式计算两者之间的距离。

本文根据帕累托原则^[21]来寻找用户活动中心。首先, 对于每个用户 u , 我们用 L_u 表示用户 u 签到的 POI 集合, 并根据用户签到频率对其排序。接下来选择用户签到频率最大的 POI, 将与所有访问过的其他 POI (距离所选 POI 不到 d km) 合并到一个区域中, 如果该区域的总签到次数与用户总签到

次数之比大于阈值 θ , 则将这些签到到位置设置为一个区域并建立一个活动中心。重复此过程, 直到所有用户的签到 POI 都被覆盖。确定活动中心的过程如算法 1 所示。

算法 1 多中心发现算法

输入: 用户-POI 签到矩阵 \mathbf{R} , POI 坐标

输出: 用户中心集合

1. 对于每个用户 u , 根据签到频率对用户签到的 POI 进行排序 $|L_u|$
2. $\forall l_i \in L_u, l_i, \text{center} = -1$
3. $\text{Center_list} = \emptyset; \text{center_no} = 0$
4. FOR i from 1: $|L_u|$ DO
5. IF $l_i, \text{center} = -1$ THEN
6. $\text{center_no}++; \text{Center} = \emptyset; \text{Center.total_freq} = 0$
7. $\text{Center.add}(l_i); \text{Center.total_freq} += l_i, \text{freq}$
8. FOR $j = i+1: |L_u|$ DO
9. IF $l_j, \text{center} = -1$ and $\text{dist}(l_i, l_j) \leq d$ THEN
10. $l_j, \text{center} = \text{center_no}; \text{Center.add}(l_j);$
11. $\text{Center.total_freq} += l_j, \text{freq}$
12. END IF
13. END FOR
14. IF $\text{Center.total_freq} \geq |u_i| \cdot \text{total_freq} * \theta$ THEN
15. $\text{Center_list.add}(\text{Center})$
16. END IF
17. END IF
18. END FOR
19. RETURN Center_list for user u

本文定义了两种时间状态, 即工作时间和休息时间。最终用户 u 对未访问 POI l 的偏好为:

$$g_{u,l} = P(u, l | C_u) = \lambda \times P(u, l | C_u; WT) + (1 - \lambda) \times P(u, l | C_u; LT) \quad (7)$$

其中, WT 和 LT 分别表示工作时间和休息时间, λ 则表示工作时间和休息时间对用户签到行为的影响程度。

3.4 基于加权矩阵分解的用户偏好建模

基于用户-POI 签到矩阵, POI 推荐的一种建模方法是对低秩矩阵分解^[22], 即将用户和 POI 分别映射到维度为 $K \ll \min(M, N)$ 的潜在空间中, 以便将用户对 POI 的偏好建模为该潜在空间中它们之间的内积。为了减小泛化误差, 通常会将正则化项添加到目标函数中, 即:

$$J = \sum_{u=1}^{|U|} \sum_{l=1}^{|L|} (c_{u,l} - \mathbf{p}_u^\top \mathbf{q}_l)^2 + \lambda_p \sum_{u=1}^{|U|} \|\mathbf{p}_u\|^2 + \lambda_q \sum_{l=1}^{|L|} \|\mathbf{q}_l\|^2 \quad (8)$$

其中, $\mathbf{p}_u \in \mathbf{P}$ 是用户 u 的 K 维潜在向量, $\mathbf{q}_l \in \mathbf{Q}$ 是 POI l 的 K 维潜在向量, $\mathbf{p}_u^\top \mathbf{q}_l$ 表示用户自身偏好, λ_p 和 λ_q 是正则化系数。

在 POI 推荐中, 我们只观察到积极的例子, 即用户访问了 POI, 而用户对 POI 的访问反映了该用户对此地点的偏好, 对该地点的访问频率决定了对该地点的偏好程度。特别是, 较高的访问频率表示用户对该位置的偏好程度越大。本文采用 Hu 等^[23]提出的 WMF 模型, 为用户签到矩阵中的零项和非零项按访问次数分配一个非零权重:

$$\omega_{u,l} = \begin{cases} \alpha \cdot r_{u,l} + 1, & \text{if } r_{u,l} > 0 \\ 1, & \text{otherwise} \end{cases} \quad (9)$$

其中, $\omega_{u,l}$ 是随着签到次数 $r_{u,l}$ 增加而增加的用户偏好权重, α 是调整参数。目标函数如下:

$$J = \sum_{u=1}^{|U|} \sum_{l=1}^{|L|} \omega_{u,l} (c_{u,l} - \mathbf{p}_u^\top \mathbf{q}_l)^2 + \lambda_p \sum_{u=1}^{|U|} \|\mathbf{p}_u\|^2 + \lambda_q \sum_{l=1}^{|L|} \|\mathbf{q}_l\|^2 \quad (10)$$

其中, $\omega_{u,l}$ 可由式(9)得到, 后面两项为正则化项。

3.5 融合上下文信息模型(USGT)

本文建模了用户社会关系信息和地理信息对用户偏好的影响, 得到了用户在社会关系和地理时空影响下对 POI 签到的概率, 分别为 $s_{u,l}$ 和 $g_{u,l}$ 。其中, $s_{u,l}$ 是根据用户之间的友谊关系和用户签到行为的相似性关系求得, 而 $g_{u,l}$ 是通过研究用户签到行为特征捕获用户的主要活动中心, 并计算未签到 POI 与活动中心的相关性获得。此外, 在建模地理影响时, 我们还考虑了不同时间段对用户偏好的影响。以往研究采用简单的线性组合^[19]来建模不同上下文信息对用户签到行为的影响, 本文使用乘法法则融合上下文信息, 表达式如下:

$$sg_{u,l} = s_{u,l} \cdot g_{u,l} \quad (11)$$

本文将用户自身偏好和上下文信息结合在一起, 给出融合上下文信息的目标函数:

$$J = \sum_{u=1}^{|U|} \sum_{l=1}^{|L|} \omega_{u,l} (c_{u,l} - (\mathbf{p}_u^\top \mathbf{q}_l + sg_{u,l}))^2 + \lambda_p \sum_{u=1}^{|U|} \|\mathbf{p}_u\|^2 + \lambda_q \sum_{l=1}^{|L|} \|\mathbf{q}_l\|^2 \quad (12)$$

考虑到当 $c_{u,l} = 0$ 时, 为了拟合 $\mathbf{p}_u^\top \mathbf{q}_l + sg_{u,l} = c_{u,l} = 0$, 则 $\mathbf{p}_u^\top \mathbf{q}_l < 0$, 这显然是不合理的。因为用户未访问过的 POI 并不代表用户对其不感兴趣, 也有可能是用户并不知道它的存在。因此对用户未访问过的 POI, 只用用户自身兴趣来拟合用户签到行为, 最终的目标函数如下:

$$J = \sum_{(u,l) \in R} \omega_{u,l} (c_{u,l} - (\mathbf{p}_u^\top \mathbf{q}_l + sg_{u,l}))^2 + \sum_{(u,l) \in R} (\mathbf{p}_u^\top \mathbf{q}_l)^2 + \lambda_p \sum_{u=1}^{|U|} \|\mathbf{p}_u\|^2 + \lambda_q \sum_{l=1}^{|L|} \|\mathbf{q}_l\|^2 \quad (13)$$

其中, 上下文信息对用户的影响 $sg_{u,l}$ 由式(11)给出, 用户偏好权重由式(9)得到, 后面两项为正则化项。

3.6 算法优化

在模型优化方面, 本文使用与文献[24]中类似的优化方法, 即元素级的最小交替二乘(eALS)算法来对用户潜在矩阵 \mathbf{P} 和 POI 潜在矩阵 \mathbf{Q} 中的单个元素进行更新。相比 ALS 算法, 本文使用的优化方法可以避免对缺失数据加权带来的大量重复计算, 以加快学习速度。首先, 对用户潜在矩阵的一个元素 p_{uf} 进行更新, 求导得:

$$p_{uf} = \frac{\sum_{l \in R_u} \omega_{u,l} q_{lf} (c_{u,l} - sg_{u,l} - (\mathbf{p}_u^\top \mathbf{q}_l)^f) - \sum_{l \in R_u} q_{lf} (\mathbf{p}_u^\top \mathbf{q}_l)^f}{\sum_{l \in R_u} \omega_{u,l} q_{lf}^2 + \sum_{l \in R_u} q_{lf}^2 + \lambda_p} \quad (14)$$

其中:

$$(\mathbf{p}_u^\top \mathbf{q}_l)^f = \mathbf{p}_u^\top \mathbf{q}_l - p_{uf} q_{lf} \quad (15)$$

可以看出, 式子的关键在于缺失项计算, 即用户未访问过的 POI。首先处理 $\sum_{l \in R_u} q_{lf} (\mathbf{p}_u^\top \mathbf{q}_l)^f$:

$$\begin{aligned} \sum_{l \in R_u} q_{lf} (\mathbf{p}_u^\top \mathbf{q}_l)^f &= \sum_{l=1}^N q_{lf} \sum_{k \neq f} p_{uk} q_{lk} - \sum_{l \in R_u} q_{lf} (\mathbf{p}_u^\top \mathbf{q}_l)^f \\ &= \sum_{k \neq f} p_{uk} \sum_{l=1}^N q_{lf} q_{lk} - \sum_{l \in R_u} q_{lf} (\mathbf{p}_u^\top \mathbf{q}_l)^f \end{aligned} \quad (16)$$

可以发现, $\sum_{l=1}^N q_{lf} q_{lk}$ 与用户 u 无关, 因此可以通过提前计算来提升速度。令 $\mathbf{X}^q = \sum_{l=1}^N \mathbf{q}_l \mathbf{q}_l^\top$, 式(16)可以写为:

$$\sum_{l \in R_u} q_{lf} (\mathbf{p}_u^T \mathbf{q}_l)^f = \sum_{k \neq f} p_{uk} x_{fk}^q - \sum_{l \in R_u} q_{lf} (\mathbf{p}_u^T \mathbf{q}_l)^f \quad (17)$$

同样地,处理另一个缺失项:

$$\sum_{l \in R_u} q_{lf}^2 = \sum_{l=1}^N q_{lf}^2 - \sum_{l \in R_u} q_{lf}^2 = x_{ff}^q - \sum_{l \in R_u} q_{lf}^2 \quad (18)$$

因此,式(18)可以改写为:

$$p_{uf} = \frac{\sum_{l \in R_u} q_{lf} (\omega_{u,l} (c_{u,l} - s g_{u,l}) - (\omega_{u,l} - 1) (\mathbf{p}_u^T \mathbf{q}_l)^f) - \sum_{k \neq f} p_{uk} x_{fk}^q}{\sum_{l \in R_u} (\omega_{u,l} - 1) q_{lf}^2 + x_{ff}^q + \lambda_p} \quad (19)$$

同理,应用上述更新规则得到 q_{lf} :

$$q_{lf} = \frac{\sum_{u \in R_l} p_{uf} (\omega_{u,l} (c_{u,l} - s g_{u,l}) - (\omega_{u,l} - 1) (\mathbf{p}_u^T \mathbf{q}_l)^f) - \sum_{k \neq f} p_{uk} x_{fk}^p}{\sum_{u \in R_l} (\omega_{u,l} - 1) p_{uf}^2 + x_{ff}^p + \lambda_q} \quad (20)$$

优化过的模型 USGT 在时间复杂度上有了明显改善。可知缓存项的时间复杂度为 $O(|N|K^2)$, 更新用户矩阵 \mathbf{P} 和 POI 矩阵 \mathbf{Q} 的时间复杂度分别为 $O(|U|K^2 + |\mathbf{R}|K)$ 和 $O(|L|K^2 + |\mathbf{R}|K)$ 。因此,本文模型 USGT 的时间复杂度为 $O((|U| + |L|)K^2 + |\mathbf{R}|K)$ 。可以看出,本文模型的时间复杂度与 eALS 在同一个量级上,相比使用 WMF 的时间复杂度 $O((|U| + |L|)K^2 + |\mathbf{R}|K^2)$ 优化了 K 倍。

4 实验

本章首先介绍实验所用的数据集、实验参数设置以及评估指标,然后描述用于对比实验的基线方法和实验结果及分析。

4.1 数据集

本文实验使用由文献[25]提供的来自 Yelp 和 Gowalla 的两个公开可用的真实世界 LBSN 签到数据集。我们对数据集进行了预处理,过滤掉签到记录少于 15 次和被签到次数小于 10 次的 POI,最终数据集概要信息如表 2 所列。除此之外,数据集中还包含 POI 的经纬度信息和类别信息等,其中只有 Yelp 数据集包含 POI 类别信息。在实验中,将每个数据集分为 3 个部分,即选取 70% 作为训练集,10% 作为验证集,20% 作为测试集。

表 2 数据集统计信息

Table 2 Statistics of datasets

数据集	用户数量	POI 数量	签到数量	社交关系数量	稠密度/%
Gowalla	5 628	31 803	620 683	46 001	0.34
Yelp	7 135	16 621	301 753	46 778	0.25

4.2 实验设置

本文提出的模型需要设置的参数有可调参数 α 、社会关系权重因子 β 、时间影响因子 λ 、POI 类别影响因子 η 、活动中心距离参数 d 以及正则化参数 λ_p 和 λ_q 。本文通过实验调整,得出最佳参数设置如下:Gowalla 数据集上, $\alpha=0.5, \beta=0.7, \lambda=0.5, d=15, \lambda_p=\lambda_q=0.01$, 由于在 Gowalla 数据集上缺少 POI 类别信息,因此设置 $\eta=0$;Yelp 数据集上, $\alpha=0.6, \beta=0.8, \lambda=0.5, \eta=0.4, d=15, \lambda_p=\lambda_q=0.01$ 。实验迭代次数为 20 轮,其他对比基线模型尽可能保证与其原文设置一致。

本文采用的评估指标为常见的准确率 $Precision@N$ 、召回率 $Recall@N$ 以及搜索评价指标 $nDCG@N$ 。其计算式如下:

$$Precision@N = \frac{tp_u}{tp_u + fp_u} \quad (21)$$

$$Recall@N = \frac{tp_u}{tp_u + tn_u} \quad (22)$$

其中, tp_u 是用户访问的推荐 POI 数量, fp_u 是用户未访问的推荐 POI 数量, tn_u 是用户访问但不在 top- N 推荐的数量。

$nDCG@N$ 是对推荐模型排名质量的衡量指标,定义为:

$$nDCG@N = \frac{DCG@N}{IDCG@N} \quad (23)$$

其中,折损累计增益 $DCG@N = \sum_{l=1}^N \frac{2^{rel_l} - 1}{\log_2(l+1)}$, rel_l 表示 l 在此位置上的相关度, $IDCG@N$ 是最理想的结果序列, $nDCG@N$ 赋予排序靠前的推荐结果更高的权重。

实验对比方法如下:

GeoSoca^[11]:利用用户和 POI 之间的地理、社交和类别 3 种上下文信息,首先使用具有自适应带宽的核密度估计方法来建模地理信息,然后通过幂律分布来计算用户与朋友之间的社交相关性,并融合 POI 类别信息获得 POI 的受欢迎程度。

iGSLR^[22]:使用核密度估计(KDE)对地理信息建模,并根据与用户居住地的距离计算其相似性。将用户偏好、社交信息和地理信息整合到统一的推荐框架中。

L-WMF^[26]:利用距离较近的 POI 往往被相似的用户访问这一特征,从位置角度利用地理特征建模地理关系模型,并将其作为正则化项融合进加权矩阵分解。

LGLMF^[27]:从用户和地点两个角度建立地理模型,同时考虑了用户的主要活动区域和区域内 POI 的相关性,并将提出的地理模型融合到逻辑矩阵分解中。

CPAM^[28]:设计基于 Skip-Gram 的 POI 嵌入模型来捕捉 POI 的上下文信息,从用户签到序列中学习 POI 的向量表示,并将其与逻辑矩阵分解结合进行用户个性化推荐。

PPR^[29]:通过对异构图中的用户-POI 关系、序列模式、地理影响和社交关系进行联合建模来学习用户和 POI 表征,提出了一种时空表征学习的神经网络模型。

USGT-NoTC:本文提出的模型只考虑用户社会信息和用户自身偏好。

USGT-NoSocial:本文提出的模型只考虑地理信息和用户自身偏好。

USGT:本文提出的模型综合考虑了用户社会信息、地理信息和用户自身偏好。

4.3 实验结果

本文首先对比两个数据集在推荐列表长度 $N=10$ 时,隐藏特征矩阵维度取不同值 $K=\{5, 10, 20, 40\}$ 的推荐结果,如表 3、表 4 所列。可知,在 Gowalla 和 Yelp 两个数据集上,本文提出的模型在 3 个评估指标上比其他基线算法有更好的表现(加粗数据为性能最优值)。可以看出,本文模型和其他基线方法在 Gowalla 数据集上的性能明显优于 Yelp 数据集,这可能是由于 Yelp 数据集的用户活动范围较大,对地理信息建模产生了一定的影响。

表 3 在 Gowalla 数据集上不同方法 top-10 对比

Table 3 Comparison of top-10 different methods on Gowalla dataset

Dataset	K	Metrics	GeoSoca	iGSLR	L-WMF	LGLMF	CPAM	PPR	USGT-NoTC	USGT-NoSocial	USGT
Gowalla	5	<i>precision@10</i>	0.0236	0.0297	0.0271	0.0356	0.0419	0.0461	0.0268	0.0322	0.0375
		<i>recall@10</i>	0.0275	0.0285	0.0258	0.0347	0.0410	0.0452	0.0252	0.0304	0.0363
		<i>nDCG@10</i>	0.0296	0.0302	0.0307	0.0377	0.0426	0.0478	0.0279	0.0355	0.0416
	10	<i>precision@10</i>	0.0236	0.0297	0.0285	0.0364	0.0428	0.0461	0.0343	0.0405	0.0439
		<i>recall@10</i>	0.0275	0.0285	0.0296	0.0366	0.0422	0.0452	0.0325	0.0387	0.0428
		<i>nDCG@10</i>	0.0296	0.0302	0.0345	0.0385	0.0430	0.0478	0.0354	0.0443	0.0479
	20	<i>precision@10</i>	0.0236	0.0297	0.0323	0.0370	0.0438	0.0461	0.0401	0.0432	0.0506
		<i>recall@10</i>	0.0275	0.0285	0.0332	0.0369	0.0430	0.0452	0.0406	0.0442	0.0498
		<i>nDCG@10</i>	0.0296	0.0302	0.0358	0.0393	0.0444	0.0478	0.0421	0.0467	0.0528
	40	<i>precision@10</i>	0.0236	0.0297	0.0328	0.0380	0.0454	0.0461	0.0392	0.0424	0.0469
		<i>recall@10</i>	0.0275	0.0285	0.0355	0.0372	0.0446	0.0452	0.0385	0.0414	0.0461
		<i>nDCG@10</i>	0.0296	0.0302	0.0367	0.0409	0.0464	0.0478	0.0408	0.0457	0.0507

表 4 在 Yelp 数据集上不同方法 top-10 对比

Table 4 Comparison of top-10 different methods on Yelp dataset

Dataset	K	Metrics	GeoSoca	iGSLR	L-WMF	LGLMF	CPAM	PPR	USGT-NoTC	USGT-NoSocial	USGT
Yelp	5	<i>precision@10</i>	0.0116	0.0184	0.0143	0.0172	0.0220	0.0266	0.0215	0.0242	0.0253
		<i>recall@10</i>	0.0111	0.0266	0.0215	0.0245	0.0335	0.0387	0.0306	0.0363	0.0367
		<i>nDCG@10</i>	0.0124	0.0196	0.0155	0.0175	0.0239	0.0284	0.0219	0.0263	0.0271
	10	<i>precision@10</i>	0.0116	0.0184	0.0157	0.0174	0.0229	0.0266	0.0221	0.0262	0.0278
		<i>recall@10</i>	0.0111	0.0266	0.0230	0.0252	0.0342	0.0387	0.0320	0.0385	0.0414
		<i>nDCG@10</i>	0.0124	0.0196	0.0159	0.0186	0.0248	0.0284	0.0223	0.0282	0.0297
	20	<i>precision@10</i>	0.0116	0.0184	0.0168	0.0181	0.0238	0.0266	0.0250	0.0273	0.0309
		<i>recall@10</i>	0.0111	0.0266	0.0249	0.0264	0.0354	0.0387	0.0379	0.0408	0.0467
		<i>nDCG@10</i>	0.0124	0.0196	0.0173	0.0188	0.0260	0.0284	0.0255	0.0293	0.0323
	40	<i>precision@10</i>	0.0116	0.0184	0.0192	0.0202	0.0255	0.0266	0.0242	0.0267	0.0296
		<i>recall@10</i>	0.0111	0.0266	0.0276	0.0288	0.0366	0.0387	0.0360	0.0396	0.0457
		<i>nDCG@10</i>	0.0124	0.0196	0.0202	0.0213	0.0269	0.0284	0.0251	0.0287	0.0318

另外,基线方法中 GeoSoca 模型性能表现相对较差,L-WMF 和 LGLMF 的性能优于 GeoSoCa(类别信息、地理信息和社会关系信息等)和 iGSLR(地理信息和社会关系信息),原因可能是矩阵分解方法更好地利用了用户历史签到数据的隐式反馈信息。而基于词嵌入模型学习用户上下文信息的 CPAM 和基于 LSTM 模型学习用户签到序列特征的 PPR 模型是对比方法中表现最优的。

本文提出的模型中,融合社会关系信息 USGT-NoTC 和融合地理时空信息的 USGT-NoSocial 整体上优于 LGLMF,且 USGT-NoSocial 性能优于 USGT-NoTC,进一步说明地理时空信息比社会关系信息在 POI 推荐中的影响更大,而同时融合了这几种上下文信息的 USGT 与基线方法相比性能显著提升。

结果表明,在两个数据集上,融合利用地理、时间和社会关系信息的 USGT 具有良好的 POI 推荐性能,有效缓解了 POI 签到数据的稀疏性对 POI 推荐准确性的影响。另外,在 Gowalla 和 Yelp 数据集上随着维度 K 的增加,本文模型性能也逐渐提高。当 K 达到 20 时,3 个指标均达到最优,与 PPR 推荐性能相比 Gowalla 数据集平均提高 10%,Yelp 数据集平均提高 16%。 K 继续增大时推荐性能开始下降,因此在接下来的实验中将隐藏特征矩阵维度设置为 20。

接下来,设置 $K=20$,然后在不同 POI 推荐长度列表 $N=\{5,10,15,20\}$ 下,对本文模型进行性能评估测试,评估结果如表 5、表 6 所列。可以清楚地看到,随着 POI 推荐列表

长度的增加,各个模型的推荐性能指标 precision 和 nDCG 都在降低。这是因为随着推荐数量的增多,用户可以选择的 POI 也增加,那些在推荐列表中排名较低的 POI 被签到的概率就会相应降低。而算法的召回率随着 POI 推荐长度的增加而提高,这意味着随着推荐数量增加,用户更容易选择感兴趣的 POI。当 $N=20$ 时,每种算法的召回率都达到最优。整体来看,结合了更多上下文信息的本文模型在评估指标上明显超过了其他基线方法,表明本文模型在融合地理信息、时间信息和社会关系信息方面更具有优势。

此外,根据表 5 和表 6 的计算结果,我们对本文模型 USGT 以及 USGT-NoSocial 和 USGT-NoTC 的性能进行了对比分析。其中,USGT-NoSocial 没有融合用户社会关系这一信息,只考虑了用户自身偏好、地理和时间信息;而 USGT-NoTC 没有考虑地理时空信息,只基于用户自身偏好和社会关系。如表 5、表 6 所列,在两个数据集上,USGT 在每个评估指标上都优于 USGT-NoSocial 和 USGT-NoTC,这表明融合社会关系和地理信息均能提高 POI 推荐模型的性能。另一方面,USGT-NoSocial 性能始终优于 USGT-NoTC,这表明在 POI 推荐中,地理位置信息对模型性能的提升较为明显。

为了研究 USGT 和其他基线方法在处理稀疏数据时的表现,我们从已有用户签到数据中通过随机抽取的方式选取原始数据集中不同比例的数据构成新的签到数据集。显然,新构建的签到数据集较原始数据集而言稀疏性进一步加剧。在接下来的实验过程中,使用它们来评估本文算法在处理稀

疏数据时的性能。对于每个用户,我们只考虑在训练集内随机访问一定比例的兴趣点(40%~80%),表7、表8列出了

USGT 和其他基线方法基于稀疏程度更高的签到数据集的推荐性能。

表5 在 Gowalla 数据集上不同方法 top-N 对比

Table 5 Comparison of top-N different methods on Gowalla dataset

Dataset	Metrics	GeoSoca	iGSLR	L-WMF	LGLMF	CPAM	PPR	USGT-NoTC	USGT-NoSocial	USGT
Gowalla	<i>precision@5</i>	0.0316	0.0331	0.0353	0.0452	0.0514	0.0528	0.0445	0.0509	0.0553
	<i>recall@5</i>	0.0142	0.0201	0.0210	0.0225	0.0270	0.0272	0.0229	0.0266	0.0283
	<i>nDCG@5</i>	0.0328	0.0357	0.0408	0.0461	0.0521	0.0529	0.0453	0.0524	0.0569
	<i>precision@10</i>	0.0236	0.0297	0.0328	0.0380	0.0454	0.0461	0.0401	0.0432	0.0506
	<i>recall@10</i>	0.0275	0.0285	0.0355	0.0372	0.0446	0.0452	0.0406	0.0442	0.0498
	<i>nDCG@10</i>	0.0296	0.0302	0.0367	0.0409	0.0464	0.0478	0.0421	0.0467	0.0528
	<i>precision@15</i>	0.0244	0.0268	0.0291	0.0341	0.0402	0.0416	0.0378	0.0394	0.0438
	<i>recall@15</i>	0.0305	0.0369	0.0428	0.0492	0.0609	0.0612	0.0561	0.0594	0.0648
	<i>nDCG@15</i>	0.0272	0.0295	0.0347	0.0378	0.0434	0.0458	0.0403	0.0435	0.0481
	<i>precision@20</i>	0.0221	0.0242	0.0282	0.0309	0.0362	0.0379	0.0358	0.0364	0.0404
	<i>recall@20</i>	0.0368	0.0438	0.0510	0.0585	0.0723	0.0730	0.0693	0.0720	0.0780
	<i>nDCG@20</i>	0.0253	0.0262	0.0303	0.0352	0.0407	0.0426	0.0386	0.0410	0.0452

表6 在 Yelp 数据集上不同方法 top-N 对比

Table 6 Comparison of top-N different methods on Yelp dataset

Dataset	Metrics	GeoSoca	iGSLR	L-WMF	LGLMF	CPAM	PPR	USGT-NoTC	USGT-NoSocial	USGT
Yelp	<i>precision@5</i>	0.0133	0.0189	0.0201	0.0218	0.0273	0.0287	0.0262	0.0321	0.0344
	<i>recall@5</i>	0.0063	0.0135	0.0149	0.0155	0.0203	0.0219	0.0197	0.0246	0.0271
	<i>nDCG@5</i>	0.0138	0.0211	0.0213	0.0227	0.0292	0.0309	0.0264	0.0329	0.0346
	<i>precision@10</i>	0.0116	0.0184	0.0192	0.0202	0.0255	0.0266	0.0250	0.0273	0.0309
	<i>recall@10</i>	0.0111	0.0266	0.0276	0.0288	0.0366	0.0387	0.0379	0.0408	0.0467
	<i>nDCG@10</i>	0.0124	0.0196	0.0202	0.0213	0.0269	0.0284	0.0255	0.0293	0.0323
	<i>precision@15</i>	0.0105	0.0173	0.0181	0.0193	0.0229	0.0236	0.0237	0.0249	0.0283
	<i>recall@15</i>	0.0150	0.0366	0.0387	0.0418	0.0501	0.0532	0.0533	0.0554	0.0628
	<i>nDCG@15</i>	0.0116	0.0191	0.0196	0.0205	0.0258	0.0271	0.0246	0.0273	0.0303
	<i>precision@20</i>	0.0099	0.0159	0.0175	0.0179	0.0212	0.0224	0.0229	0.0233	0.0262
	<i>recall@20</i>	0.0187	0.0457	0.0504	0.0519	0.0620	0.0632	0.0677	0.0684	0.0779
	<i>nDCG@20</i>	0.0110	0.0180	0.0189	0.0194	0.0232	0.0250	0.0239	0.0259	0.0282

表7 在 Gowalla 数据集上不同稀疏程度数据集 top-10 性能对比

Table 7 Comparison of top-10 datasets with different sparsity levels on Gowalla dataset

Dataset	Sampling scale	Metrics	GeoSoca	iGSLR	L-WMF	LGLMF	CPAM	PPR	USGT-NoTC	USGT-NoSocial	USGT
Gowalla	40%	<i>precision@10</i>	0.0195	0.0208	0.0234	0.0276	0.0288	0.0330	0.0299	0.0321	0.0359
		<i>recall@10</i>	0.0168	0.0180	0.0231	0.0271	0.0280	0.0321	0.0296	0.0320	0.0368
		<i>nDCG@10</i>	0.0204	0.0214	0.0251	0.0301	0.0316	0.0352	0.0308	0.0347	0.0385
	60%	<i>precision@10</i>	0.0208	0.0242	0.0262	0.0298	0.0322	0.0388	0.0333	0.0371	0.0405
		<i>recall@10</i>	0.0180	0.0222	0.0273	0.0308	0.0340	0.0376	0.0326	0.0367	0.0413
		<i>nDCG@10</i>	0.0220	0.0254	0.0288	0.0318	0.0366	0.0406	0.0339	0.0398	0.0438
	80%	<i>precision@10</i>	0.0217	0.0272	0.0287	0.0318	0.0378	0.0409	0.0365	0.0395	0.0438
		<i>recall@10</i>	0.0210	0.0255	0.0309	0.0313	0.0382	0.0402	0.0362	0.0396	0.0436
		<i>nDCG@10</i>	0.0263	0.0295	0.0317	0.0339	0.0401	0.0438	0.0383	0.0425	0.0478

表8 在 Yelp 数据集上不同稀疏程度数据集 top-10 性能对比

Table 8 Comparison of top-10 datasets with different sparsity levels on Yelp dataset

Dataset	Sampling scale	Metrics	GeoSoca	iGSLR	L-WMF	LGLMF	CPAM	PPR	USGT-NoTC	USGT-NoSocial	USGT
Gowalla	40%	<i>precision@10</i>	0.0077	0.0107	0.0111	0.0128	0.0138	0.0190	0.0188	0.0192	0.0229
		<i>recall@10</i>	0.0065	0.0177	0.0188	0.0201	0.0222	0.0284	0.0275	0.0296	0.0342
		<i>nDCG@10</i>	0.0074	0.0111	0.0120	0.0130	0.0148	0.0183	0.0182	0.0198	0.0235
	60%	<i>precision@10</i>	0.0086	0.0122	0.0127	0.0146	0.0162	0.0209	0.0201	0.0213	0.0251
		<i>recall@10</i>	0.0081	0.0192	0.0214	0.0223	0.0258	0.0315	0.0306	0.0325	0.0393
		<i>nDCG@10</i>	0.0089	0.0131	0.0144	0.0151	0.0186	0.0212	0.0204	0.0225	0.0268
	80%	<i>precision@10</i>	0.0098	0.0143	0.0155	0.0169	0.0202	0.0239	0.0226	0.0242	0.0257
		<i>recall@10</i>	0.0093	0.0225	0.0241	0.0249	0.0315	0.0354	0.0337	0.0365	0.0403
		<i>nDCG@10</i>	0.0105	0.0161	0.0178	0.0181	0.0210	0.0244	0.0230	0.0256	0.0273

可以看出,随着用户签到数据的减少,本文模型 USGT 及其他基线方法在表3和表4的基础上推荐性能逐渐下降,

但本文模型在两个数据集上的性能表现始终较优。具体来看,之前表现较好的 CPAM 模型性能下降较为明显,原因可能是随着数据越来越稀疏,其用户 POI 序列的平均长度变短导致推荐性能下降,而融合更多上下文信息的本文模型和 PPR 模型在处理稀疏数据时拥有更好的性能。这表明,在处理稀疏数据时,模型性能的提高更依赖于上下文信息的建模。

4.4 参数实验

为了衡量社会关系信息建模中友谊关系和行为关系对用户相似度的影响程度,我们考察模型参数 β 对模型性能的影响。图 3 和图 4 分别给出了不同 β 值对本文模型性能 precision@10 和 recall@10 的影响。本文使用 β 值在范围 $[0, 1]$ 内以 0.1 为间隔来训练模型,并保持其他参数固定。图中显示,随着 β 值的增大,POI 的推荐性能逐渐上升,当达到阈值时性能逐渐降低。在 Gowalla 数据集上, $\beta=0.7$ 时模型性能达到最优;在 Yelp 数据集上, $\beta=0.8$ 时模型性能达到最优。这些结果表明,用户在选择新地点时,与其经常访问相似 POI 的用户对模型性能影响更大,但友谊关系和行为关系都不应该被忽略,这两者对 POI 推荐都很重要。





图 3 β 值对准确率的影响

Fig. 3 Effect of β on precision@10





图 4 β 值对召回率的影响

Fig. 4 Effect of β on recall@10

接下来衡量用户活动中心区域选择范围的大小对地理建模的影响程度,图 5 和图 6 分别给出了参数 d 值对模型性能 precision@10 和 recall@10 的影响。可以看出,随着 d 值增大,在 Gowalla 和 Yelp 两个数据集上模型性能也逐步上升,在 $d=15$ 时达到最优值,随后性能开始下降。这说明将距离较远的 POI 加入到用户活动中心,不仅不会给用户提供更多 POI 选择,反而会因为增大了活动距离而导致推荐性能下降。结果表明,用户更倾向于访问距离活动区域较近的 POI。





图 5 d 值对准确率的影响

Fig. 5 Effect of d on precision@10



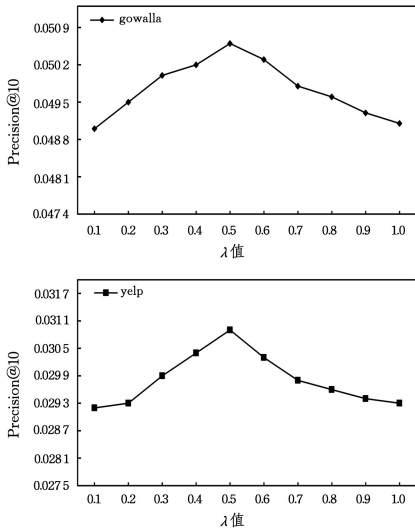
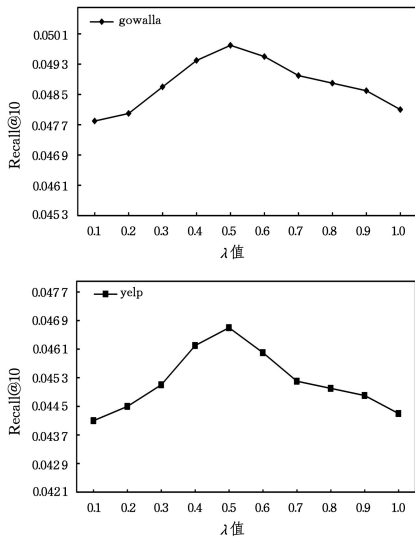


图 6 d 值对召回率的影响

Fig. 6 Effect of d on recall@10

另外,为了验证在对地理信息进行建模时,关联时间因素与地理因素的合理性与作用,图 7 和图 8 分别给出了参数 λ 值对模型性能的影响。可以看出, λ 设置为 0(只有休息时间)或者 1(只有工作时间)时性能表现相对较差,而在 $\lambda=0.5$ 时达到最优值。这表明用户签到行为的活动中心受时间因素的影响,用户选择 POI 时会呈现出随时间变化的一些规律性,进一步说明了考虑地理和时间信息的相互影响有助于更好地对用户签到行为建模。

图7 λ 值对准确率的影响Fig. 7 Effect of λ on precision@10图8 λ 值对召回率的影响Fig. 8 Effect of λ on recall@10

结束语 本文提出了一种基于地理时空关联和社会关系影响的兴趣点推荐模型 USGT,该模型综合考虑用户签到行为特征,在用户自身偏好的基础上融合了不同上下文信息,并根据用户是否访问过 POI 采用了不同的融合策略,有效提高了 POI 推荐性能。USGT 提取用户社会关系时,分别考虑了用户之间的友谊关系和行为关系来挖掘用户之间的社会关系相似性,同时结合 POI 类别信息度量用户签到行为相似性,一方面缓解了数据稀疏性对社会关系相似性建模的影响,另一方面也更符合客观实际,例如对异地用户进行签到行为相似性度量采用 POI 类别更具普适应。其次,在建模地理信息对用户签到行为的影响时,考虑时间因素对用户签到偏好的影响。观察到用户签到 POI 在不同时间状态下呈现出空间聚类现象,本文通过引入地理活动中心的概念,融入时间信息以提高地理信息建模的有效性。然后,将社会关系信息和地理时空信息与用户自身偏好融合到统一的加权矩阵分解模型中来生成 POI 推荐列表。最后,在两个 LBSN 数据集上的

实验表明,本文模型 USGT 在 3 个评价指标上明显优于对比 POI 推荐模型,能够有效缓解 POI 签到数据的稀疏性影响,明显地提升了模型推荐性能,并具有一定的可扩展性。

在未来的工作中,我们将在用户个性化 POI 推荐中考虑更多的上下文信息,如用户评论文本等,以提高 POI 推荐性能。此外,为了更准确地预测用户签到行为,可以针对时间信息做更细粒度的划分,进一步挖掘地理时空联合作用对用户签到行为的影响。

参考文献

- [1] YE M, YIN P, LEE W C, et al. Exploiting geographical Influence for collaborative point-of-interest recommendation [C] // Proceedings of the 34th International ACM SIGIR Conference on Research and Development in Information Retrieval. 2011: 325-334.
- [2] ZHANG J D, CHOW C Y. iGSLR: Personalized geo-social location recommendation: a kernel density estimation approach [C] // Proceedings of the 21st ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems. 2013: 334-343.
- [3] LUO Y, LIU Q, LIU Z. STAN: Spatio-Temporal attention network for next location recommendation [C] // Proceedings of the Web Conference 2021. 2021: 2177-2185.
- [4] LIAN D, ZHAO C, XIE X, et al. GeoMF: joint geographical modeling and matrix factorization for point-of-interest recommendation [C] // Proceedings of the 20th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. 2014: 831-840.
- [5] LIU B, FU Y, YAO Z, et al. Learning geographical preferences for point-of-interest recommendation [C] // Proceedings of the 19th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. 2013: 1043-1051.
- [6] LI M, ZHENG W, XIAO Y, et al. Exploring temporal and spatial features for next POI recommendation in LBSNs [J]. IEEE Access, 2021, 9: 35997-36007.
- [7] RAHMANI H A, ALIANNEJADI M, BARATCH M, et al. A systematic analysis on the impact of contextual information on point-of-interest recommendation [J]. ACM Transactions on Information Systems (TOIS), 2022, 40(4): 1-35.
- [8] GUO G, ZHANG J, THALMANN D. Merging trust in collaborative filtering to alleviate data sparsity and cold start [J]. Knowledge-Based Systems, 2014, 57: 57-68.
- [9] LI H, GE Y, HONG R, et al. Point-of-interest recommendations: Learning potential check-ins from friends [C] // Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. 2016: 975-984.
- [10] DING R, CHEN Z. RecNet: A deep neural network for personalized POI recommendation in location-based social networks [J]. International Journal of Geographical Information Science, 2018, 32(8): 1631-1648.
- [11] ZHANG J D, CHOW C Y. Geosoca: Exploiting geographical, social and categorical correlations for point-of-interest recommendations [C] // Proceedings of the 38th International ACM SIGIR

- Conference on Research and Development in Information Retrieval, 2015:443-452.
- [12] REN X, SONG M, HAIHONG E, et al. Context-aware probabilistic matrix factorization modeling for point-of-interest recommendation[J]. *Neurocomputing*, 2017, 241: 38-55.
- [13] MA Y, MAO J, BA Z, et al. Location recommendation by combining geographical, categorical, and social preferences with location popularity[J]. *Information Processing & Management*, 2020, 57(4):102251.
- [14] YUAN Q, CONG G, MA Z, et al. Time-aware point-of-interest recommendation[C] // Proceedings of the 36th International ACM SIGIR Conference on Research and Development in Information Retrieval. 2013:363-372.
- [15] ZHAO S, ZHAO T, YANG H, et al. S^{TEL}-LAR: Spatial-temporal latent ranking for successive point-of-interest recommendation [C]//Proceedings of the AAAI Conference on Artificial Intelligence. 2016.
- [16] ZHANG J D, CHOW C Y. TICRec: A probabilistic framework to utilize temporal influence correlations for time-aware location recommendations[J]. *IEEE Transactions on Services Computing*, 2015, 9(4):633-646.
- [17] LUO Y, LIU Q, LIU Z. Stan: Spatio-temporal attention network for next location recommendation[C]//Proceedings of the Web Conference 2021. 2021:2177-2185.
- [18] SEYEDHOSEINZADEH K, RAHMANI H A, AFSHARCHI M, et al. Leveraging social influence based on users activity centers for point-of-interest recommendation[J]. *Information Processing & Management*, 2022, 59(2):102858.
- [19] PENG H W, JIN Y Y, LV X Q, et al. Context-aware POI recommendation based on matrix factorization[J]. *Chinese Journal of Computers*, 2019, 42(8):1797-1811.
- [20] HE Y, WANG Z R, ZHOU X, et al. Point of interest recommendation algorithm integrating social geographical information based on weighted matrix factorization[J]. *Journal of Jilin University(Engineering and Technology Edition)*, 2023, 53(9):2632-2639.
- [21] HAFNER A W. Pareto's principle: The 80-20 rule [J]. Retrieved December, 2001, 26:2001.
- [22] KOREN Y, BELL R, VOLINSKY C. Matrix factorization techniques for recommender systems[J]. *Computer*, 2009, 42(8):30-37.
- [23] HU Y, KOREN Y, VOLINSKY C. Collaborative filtering for implicit feedback datasets[C]//2008 Eighth IEEE International Conference on Data Mining. IEEE, 2008:263-272.
- [24] HE X, ZHANG H, KAN M Y, et al. Fast matrix factorization for online recommendation with implicit feedback[C]//Proceedings of the 39th International ACM SIGIR Conference on Research and Development in Information Retrieval. 2016: 549-558.
- [25] LIU Y, PHAM T A N, CONG G, et al. An experimental evaluation of point-of-interest recommendation in location-based social networks[J]. *Proceedings of the VLDB Endowment*, 2017, 10(10):1010-1021.
- [26] GUO L, WEN Y, LIU F. Location perspective-based neighborhood-aware POI recommendation in location-based social networks[J]. *Soft Computing*, 2019, 23(22):11935-11945.
- [27] RAHMANI H A, ALIAANNEJADI M, AHMADIAN S, et al. LGLMF: local geographical based logistic matrix factorization model for POI recommendation [C] // Information Retrieval Technology: 15th Asia Information Retrieval Societies Conference(AIRS 2019). Hong Kong, China, Springer, 2020:66-78.
- [28] YU D, WANYAN W, WANG D. Leveraging contextual influence and user preferences for point-of-interest recommendation [J]. *Multimedia Tools and Applications*, 2021, 80(1):1487-1501.
- [29] DAI S, YU Y, FAN H, et al. Personalized poi recommendation: spatio-temporal representation learning with social tie[C]//Database Systems for Advanced Applications: 26th International Conference(DASFAA 2021). Taipei, Taiwan, Part I 26. Springer International Publishing, 2021:558-574.



JIN Hong, born in 1984, Ph.D, lecturer. Her main research interests include graph computing, artificial intelligence, deep learning and complex network.



LYU Shunying, born in 1965, M. S. His main research interests include computer application technology, software engineering and spatio-temporal big data.

(责任编辑:何杨)