基于用户活动轨迹和个性化区域划分的兴趣点推荐

安敬民 李冠宇 蒋 伟 孙云浩
(大连海事大学信息科学技术学院 辽宁 大连 116026)

摘 要 随着基于位置的社交网络(Location-Based Social Networks,LBSNs)与兴趣点(Point of Interest,POI)推荐的有效组合,近年来已涌现出大量的相关研究,这些方法主要可分为将地理、社会、类别、文本以及时间等上下文信息进行建模并融合,进而克服数据稀疏问题并提升兴趣点推荐的性能.但已有的兴趣点推荐方法认为不同上下文间相互独立,在对不同上下文建模并融合的过程中忽略了其内在联系,导致上下文信息未得到充分利用.另外,在将上下文模型融合到用户自身偏好模型时,未考虑上下文信息对用户历史签到记录的不同影响.为应对上述挑战,本文合理地重构了上下文信息模型并有效地融合到用户偏好模型中,且提出了一种基于用户活动轨迹和个性化区域划分的兴趣点推荐方法.该方法根据用户的活动轨迹刻画出其日常活动区域,并探索了不同用户间的地理距离分布以及活动轨迹的相似度以建模社会关系对用户签到的影响.进一步地,结合用户活动轨迹区域内的 POI 的地理信息,使用带有自适应带宽的核密度估计方法评估 POI 间的地理相关性,以建模 POI 地理信息对用户签到的影响.最后,将用户社会关系模型和 POI 地理信息模型与用户自身偏好模型融合,使用改进的加权矩阵分解技术求解用户的个性化 POI 推荐.本文分别采用经典的和当前流行的相关研究作为基准,在 Gowalla 和 Foursquare 数据集上进行对比,实验结果表明本文方法具有更好的 POI 推荐效果,说明了本文提出的模型在融合策略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;上下文信息;数据稀疏;用户活动轨迹;加权矩阵分解
中图法分类号 TP311 **DOI 号** 10.11897/SP.J.1016.2022.01176

A Point-of-Interest Recommendation Method Based on Activity Tracks and Personalized-Area Partitions of Users

AN Jing-Min LI Guan-Yu JIANG Wei SUN Yun-Hao
(*School of Information Science and Technology, Dalian Maritime University, Dalian, Liaoning* 116026)

Abstract At present, in the context of social Internet of Things, Point of Interest (POI) recommendation has become a hot issue and is widely applied to the service recommendation of location-based social networks (LBSNs). With the effective fusion of LBSNs and POI recommendation, a lot of relevant researches have emerged. These methods are mainly regarded as modeling and fusing context information such as geographical information, social information, POI categories, text information, and check-in temporal information, so as to overcome the problems of data sparsity and cold start and improve the performance of POI recommendation. However, for modeling and fusing context information, existing POI recommendation methods assume that different context information is independent between each other, and they ignore the internal relationships between context information, resulting in failing to take full advantage of context information. Moreover, when they fuse context models into user preference model, the different influences of context information on user preference are ignored (the influences of context information on the POIs that

收稿日期:2020-09-21;在线发布日期:2021-05-11.本课题得到国家自然科学基金(61976032)资助.**安敬民**,博士研究生,主要研究方向为推荐系统、泛在计算、知识工程.E-mail:jingminan1018@163.com.**李冠宇**(通信作者),博士,教授,博士生导师,中国计算机学会(CCF)高级会员,主要研究领域为物联网、知识工程.E-mail:liguanyu@dlmu.edu.cn.**蒋 伟**,博士研究生,主要研究方向为算法优化、知识工程.**孙云浩**,博士研究生,主要研究方向为语义网、知识工程.

users have visited and the POIs that users have not visited). To address the above challenges, the paper innovatively models the multiple context information reasonably, fused into the user preference model effectively and proposes a method of POI recommendation based on the activity tracks and personalized-area partitions of users. The proposed method depicts the daily activity areas of users according to their activity tracks and explores the geographical distance distributions between different users and the semantic similarities of activity tracks to model the influence of the social relationships on user check-in preference (UGS). Furthermore, combined with the geographical information of POI in the user activity track area, we adopt the kernel density estimation method with adaptive bandwidth to evaluate the geographical correlations between POIs to model the influence of POI geographical information on user check-in preference (PG). Then we improve weighted matrix factorization (WMF) as our fused model, reflected in two points. (1) Considering the influence of POI categories when modeling user preferences, we integrate the POI category information into user-POI rating matrix to alleviate data sparsity; (2) Considering the different influences of context information on the checked-in POIs and non-checked-in POIs, we develop a two-step fusion strategy, which fuses context information with the checked-in POIs rather than the non-checked-in POIs. Finally, the user social relationship model, the POI geographical information model, and the user preference model are fused together using the improved weighted matrix factorization, namely UGS_PG-WMF, to solve the personalized POI recommendation. We select the classic and current popular related works as the baselines to implement experiments from several aspects, including the potential vector dimension K, the POI recommended quantity top-k, the cold-start problem, the parameter influence, and the influence of sparse data on the widely used Gowalla and Foursquare datasets. To the end, the experimental results show that the proposed model has better performance compared with the state-of-the-art models, and the performance is improved by 10%—13%, proving the advantages of our proposed model in overcoming the problems of data sparsity and cold start.

Keywords　location-based social network; point-of-interest recommendation; context information; data sparse; activity tracks of users; weighted matrix factorization

1　引　言

随着移动设备和无线网络在近几年的快速发展与普及，人们在日常生活中获得了越来越多的便利，这其中以人们可以随时分享自己的位置和兴趣点(Point-of-Interest，POI)最为普遍，也使得基于位置的社交网络(Location-Based Social Networks，LBSNs)受到了广大用户和专家学者的关注，例如国内的大众点评平台，国外的 Gawalla 和 Foursquare 网站等最为典型. 当前常见的 LBSNs 的基本结构框架如图 1 所示，用户将自己签到过的位置通过点评的方式分享到网络平台上，其他用户通过 LBSNs 查找符合自己偏好的 POI(电影院、餐厅和景点等). 其中，我们不难发现，在整个签到和社交过程中，除了用户的签到数据，同时产生了丰富的上下文信息，比如可直接获取的用户社交信息、POI 的地理信息、类别信息、文本信息和签到时间信息等，以及隐含在交互信息中的某些社会行为关系. 能够对这些上下文信息进行合理地挖掘和使用，将会促进基于 LBSNs 的 POI 个性化推荐进一步发展.

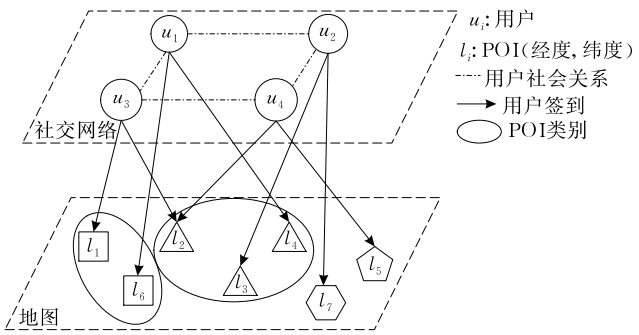

图 1　基于位置的社交网络模型

个性化 POI 推荐服务旨在综合用户偏好和其他的上下文信息,向用户推荐其未曾访问过的 POI[1].对用户本身而言,这无疑为其日常出行等活动提供了方便,而对于第三方商家来说,也可以获取更多用户潜在的 POI,并向相应的用户群体推送广告,以达到准确定位客户需求的目的.

截至目前,关于 LBSNs 的 POI 推荐的研究层出不穷,但为了实现更加高效的个性化 POI 推荐,仍然主要存在两个问题需进一步解决.其一,现实世界中现有的位置 POI 的数量是巨大的,且遍布各地,但相比较而言,每个用户实际访问且签到过的 POI 数量确是极少的,这造成了可利用的签到数据矩阵的高稀疏性,也为以数据分析为基础的个性化 POI 推荐带来了挑战;其二,实现个性化 POI 推荐,需要结合用户在社会交互过程中产生的上下文信息.由于上下文信息是多样化的,若只考虑部分上下文信息(地理或社会信息)会对推荐的准确性产生较大的影响,而全面地考虑多种上下文信息来拟合用户决策过程,如何有效合理地融合信息建模也成为了一个难题.

首先,根据地理学第一定律[2]可知,相邻事物的相似度大于远离事物,所以地理距离是用户考虑是否访问一个 POI 的重要因素.地理因素主要包括"用户-用户"距离、"用户-POI"距离和"POI-POI"距离三种,前者是用户间的社会地理距离,主要指不同用户所在生活区域距离,而两后者分别是用户与 POI 间的地理距离和用户未访问过的 POI 与签到过的 POI 间距离.其次,由于用户签到行为大多发生在其自身的日常生活区域附近[3-5],所以我们认为,在用户的社会关系上,那些现实中与该用户社会地理距离较近且行为习惯相近者(如朋友、邻居或者其他人)对用户的偏好决策影响更大.因此,为解决签到数据稀疏问题和提高个性化 POI 推荐准确性,将上述提及的地理、社会、POI 类别、文本以及时间等上下文信息与用户自身偏好有效地融合是现阶段的研究重点.而在现有的一些研究工作[6-13]中主要存在以下问题:(1)未能同时充分考虑上述影响因素;(2)在综合不同上下文对用户偏好决策时,假设上下文间是相互独立的,而忽略了其可能的内在联系;(3)在上下文与用户自身偏好融合过程中,忽略了上下文对零项与非零项的不同影响.如文献[6-8,10,13]缺少对 POI 文本内容或时间信息的考虑,文献[6,11-12]忽略了上下文间可能存在的内在联系,文献[7-13]中的融合策略未考虑上下文对用户-POI 签到矩阵中的零项与非零项的不同影响.

针对上述分析,本文提出了一种基于用户的活动轨迹和个性化区域划分的 POI 推荐方法,该方法的主要工作和贡献点如下:(1)联合"用户-用户"、"用户-POI"和"POI-POI"地理距离关系、用户签到时间以及文本内容信息,提出了全新的社会-地理模型的建模方法;(2)向用户-POI 签到矩阵中融入 POI 类别信息的影响来建模用户自身偏好,并提出了一种具有两步融合策略的加权矩阵分解技术(Weighted Matrix Factorization,WMF);(3)本文在两个真实的 LBSNs 数据集(Gowalla 和 Foursquare)上进行了多角度多评估指标的实验,结果证实该方法相比现有的方法具有更好的性能,也同时说明本文在融合多种上下文信息建模和克服数据稀疏性方面更具优势.

本文第 2 节对现有的基于 LBSNs 的 POI 推荐方法进行概述;第 3 节给出基于用户活动轨迹和个性化区域划分的上下文信息建模;第 4 节是上下文信息与用户偏好的融合模型;第 5 节详细介绍本文的实验设计与结果分析;第 6 节是工作总结.

2 相关工作

为了更好地实现在 LBSNs 中的 POI 个性化推荐服务,当前大多研究工作均采用将上下文信息与用户签到数据相结合的方式来进行 POI 推荐,主要涉及的上下文信息包括地理位置信息、社会信息和 POI 类别信息,并同时也有少量研究工作针对时间信息和文本信息做了相关研究.

2.1 基于地理信息的 POI 推荐

不同于其他的个性化推荐服务(比如图书、电影和音乐等项目的推荐),基于 LBSNs 的个性化 POI 推荐更强调是用户对 POI 的实际签到或访问的交互动作,所以 POI 的地理关系对用户签到行为的决策起到了不可忽视的作用.在早期的一些工作[14-16]当中,作者仅根据用户间的地理关系以计算用户间相似关系的权重或者将位置 POI 视为普通的推荐项目,利用基于项目的协同过滤方法实现推荐,而未考虑 POI 具体位置间距离的影响.而后,部分学者利用真实数据分析用户所签到过的 POI 间的距离是具有一定规律特征的,因此使用分布函数进一步拟合位置间距离的分布.如 Ye 等人[17]利用被同一用户访问过的 POI 在空间上具有聚类的特点,提出 POI 位置间的幂律分布;Cheng 等人[1]发现用户签到呈现一种多中心现象,并提出了一种多中心高斯

《计算机学报》

分布模型；而 Zhang 等人[18]通过研究提出，基于位置的用户签到行为是个性化的，不具有一般性，故提出一种基于核密度估计的个性化地理位置建模方法，且针对核密度估计中的带宽进行了优化并给出了一种 POI 地理关系的近似评估方法，以及设计了一种上下文信息的联合方法求解用户偏好的 POI[19]；在此基础上，Lian 等人[20]和 Li 等人[21]将地理信息融入到矩阵分解当中，分别提出 GeoMF 模型和 Rank-GeoMF 模型，主要是针对签到的数据和未签到的数据做了不同的处理（如分配不同权重或排序）；而 Liu 等人[22]则对 POI 级别进行划分，从单个 POI 和区域 POI 两个角度分析地理位置信息对用户偏好的影响；近期，Yang 等人[23]利用神经网络（Neural）较强的感知和表达能力，将半监督学习建模的上下文信息（地理位置信息和社会关系信息）与协同过滤方法获得的用户偏好信息有效结合来进行 POI 推荐.

在当前现有的工作中已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，但大多研究只在其基础上考虑了部分上下文信息（如社会信息），且以简单的线性组合或矩阵分解方式进行融合.

2.2　基于社会信息的 POI 推荐

在 LBSNs 中，用户不是独立存在的，且用户间具有社会关系（如朋友关系），该关系对用户个性化 POI 推荐有着积极的影响. 早期的一些研究工作[17,24-25]采用基于用户的协同过滤方法，根据用户对相同 POI 的签到数据，利用 Consine 相似度、Pearson 相关度或 Jaccard 系数等计算用户间的相似度. 而后，在一些研究[1,17,25-27]中，认为朋友间具有更多的相似签到行为，并且他们的兴趣更为相似，所以为了更好地将社会信息融合到 POI 推荐过程中，使用基于朋友的协同过滤方法[25]和随机游走算法[28-30]量化社会关系对用户偏好的影响（即朋友向用户推荐其未访问过的 POI 对用户偏好决策的影响），并结合矩阵分解实现 POI 推荐. 而 Zhang 等人[6]认为用户和朋友间的社会签到关系服从幂律分布，并采用幂律分布函数构建社会关系评估模型. 除此之外，仍有少量的研究考虑了地理位置对社会关系的影响；如 Gao 等人[3]采取地理位置与社会关系相结合的方式，提出地理距离与朋友关系的四种组合，并以线性组合的方式实现用户对未访问过的 POI 的预测；而 Li 等人[7]则从三个角度来分析和建模社会关系，分别是社会联系的朋友关系、对相同 POI 进行签到的朋友关系和生活区域较近的朋友关系三个方面，并将三类朋友关系融合到一个具有两种损失函数的矩阵分解模型当中，以提高 POI 推荐准确率和解决冷启动问题. 近期，Gao 等人[31]就信任社会信息对 POI 推荐的影响展开了研究，将信任关系分为显性的信任朋友关系和隐性的信任朋友关系，并基于 SVD++ 模型将两类信任关系融合建模，并联合地理信息构建基于矩阵分解技术的分解模型.

上述研究工作在 POI 推荐方面均取得了明显的效果，但仍存在以下不足：(1) 在计算朋友签到行为相似度时，只考虑朋友间对同一位置的签到，而忽略了不同位置 POI 的语义关系. 如 u_1 和 u_2 是朋友关系，u_1 签到过某水上公园 l_1，u_2 签到过某湿地公园 l_2，l_1 和 l_2 属于同一语义范畴，具有一定的语义相似性；(2) 大多研究工作只将社会关系视为朋友关系，而在文献[1,10,18]中已指出，朋友间的 POI 分享或共同签到的 POI 重叠率不足 10%，说明朋友关系对用户 POI 决策的影响是有限的，仍要进一步挖掘非朋友用户间的社会（行为）关系在 POI 个性化推荐中的作用.

2.3　基于类别等信息的 POI 推荐

除了地理信息和社会信息在用户个性化 POI 推荐中被广泛使用，部分研究工作也对其他上下文信息在 POI 推荐中的应用进行了研究. POI 类别信息能够隐式地表明用户在签到 POI 上的相关性，因此 Liu 等人[8]在地理或社会信息的基础上，利用用户签到数据构建 POI 类别的相关矩阵，并直接融合到矩阵分解中以求解用户对 POI 的偏好；而在文献[6,8]中，则是将社会信息与 POI 类别信息进行乘法组合，以从多方面考虑朋友间的相似度；Li 等人[7]则是考虑了类别信息对用户自身偏好的影响. 同时仍有部分工作[32-36]分别针对文本信息和时间信息在 POI 推荐中的作用进行了研究. 近期，Zhang 等人[9]注意到 POI 的文本内容中隐含着多个不同特征，这对致力于缺失项预测的矩阵分解模型具有较高的价值，他们从用户签到矩阵中抽取出用户-标签矩阵以进一步分析用户与 POI 间的潜在关系，并最终联合社会及地理影响与用户偏好融合. 而 Gao 等人[37]首次基于神经网络提出了一个时间感知的 POI 推荐网络模型，利用神经网络学习签到行为记录中的用户、POI 及时间的交叉特征和组合特征进行 POI 推荐. 以及 Xing 等人[10]采用卷积神经网络（Convolutional Neural Network，CNN）深度挖掘文本内容的三种信息，即 POI 属性、用户兴趣和用户情感，同时与由高斯分布获得的 POI 地理关系融入

《计算机学报》

矩阵分解模型中；而 Hao 等人[11]侧重于用户-POI 签到事件的实时跟踪及表示的研究，利用 CNN 抽取并表示出访问过的 POI 文本内容中关键字、位置和时间的多模式嵌入，并设计了一种实时事件嵌入的矩阵分解模型. Xiong 等人[12]则是就现有研究未能考虑 POI 文本信息的多源性，提出了基于 LBSNs 和 MBSNs(基于微博的社会网络，Microblog-Based Social Networks)的文本主题抽取方法，并结合时间信息建模文本内容对用户签到的影响，同时融合用户的社会关系及 POI 地理相关性构建预测 POI 的联合分布模型. 最近，Li 等人[13]提出了 POI 间的竞争关系分析方法，利用基于图神经网络(Graph Neural Network，GNN)的深度学习框架将地理信息、文本内容信息和用户行为偏好有效融合以挖掘 POI 间的竞争关系，且认为更强的竞争关系即更强的 POI 相关性，并实现 POI 推荐.

上述相关研究工作已从多角度建模上下文信息来拟合用户偏好，包括地理、社会、类别、文本和时间方面，但主要仍存在以下问题：(1)将时间分割成离散片段，而时间本质上是连续的；(2)在上下文的建模和融合过程中认为上下文间是相互独立的，而忽略了其内在联系；(3)由于用户签到矩阵是稀疏的，零项的处理方法的选用对最后的推荐结果有较大影响，这些方法大多直接将上下文信息与用户偏好信息直接拟合，未考虑上下文信息与用户偏好信息中的零项和非零项间的实际关系.

综上所述，现有的基于 LBSNs 的 POI 个性化推荐的方法中，在上下文信息多样性的使用和融合方面仍有不足，针对这一问题，本文提出了一种基于用户活动轨迹和个性化区域划分的 POI 推荐方法，从地理信息、社会信息、POI 类别信息、文本信息和签到时间信息方面重构社会-地理模型及用户偏好模型，并采用改进的 WMF 将多模型融合以解决现有工作中的问题.

3 基于用户活动轨迹和个性化区域划分的上下文信息建模

3.1 问题描述

本文旨在研究与用户日常生活区域较近或同一城市等且用户未访问过的 POI 的推荐问题. 如图 2 所示，根据用户日常的 POI 签到行为轨迹(数据)，可以刻画出用户个性化活动区域及行为模式 *Niche*，通过对不同 *Niche* 中的签到行为和 POI 信息(如位置、类别和文本等)的分析，获取对应的用户社会关系与 POI 地理关系.

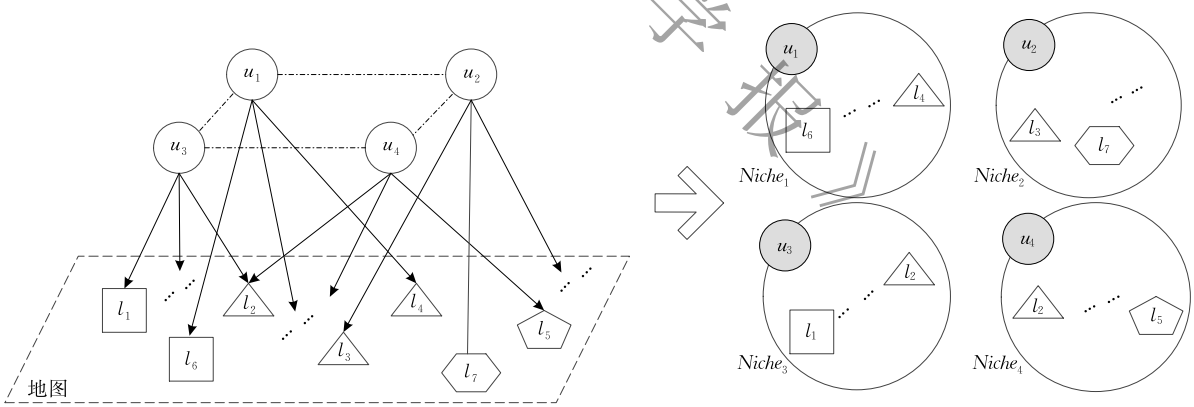

图 2 用户的 POI 签到行为模式

定义 1. 兴趣点 l_i. 令 $l_i=(l_i.loc, l_i.doc)$，其中，$l_i.loc$ 表示兴趣点的地理位置(经纬度)，$l_i.loc=(\varphi_i,\lambda_i)$；$l_i.doc$ 则是对兴趣点的描述的文本信息(如名称、分类、设施、特点等).

定义 2. 用户个性化区域下的签到行为 *Behavior* 和行为模式 *Niche*. 令 u_i 对 l_j 的签到行为 $B_{ij}=(u_i, l_j, t)$，这里 t 表示任意签到时间；u_i 的签到行为模式 $Niche_i=\{B_{i1}, B_{i2}, \cdots, B_{ij}, B_{in}\}$. 主要符号描述如表 1 所示.

表 1 文章主要符号描述

符号	描述
U, L, Ca	用户集，POI 集，POI 类别集
$\boldsymbol{R}_{\lvert U\rvert\times\lvert L\rvert}$	用户签到矩阵
$[\boldsymbol{sc}_{i,j}]$	用户 u_i 与 u_j 间的社会关系矩阵
$[\boldsymbol{C}_{i,j}]$	对应 $\boldsymbol{R}_{\lvert U\rvert\times\lvert L\rvert}$ 的 0、1 矩阵
$[\boldsymbol{gc}_{i,j}]$	用户 u_i 对 POI l_j 的偏好程度矩阵
$[\boldsymbol{sg}_{i,j}]$	用户 u_i 受上下文信息影响对 POI l_j 的偏好程度矩阵
$[\boldsymbol{I}_{i,j}]$	用户 u_i 对 POI l_j 的自身偏好程度矩阵
$[\boldsymbol{w}_{i,j}]$	用户 u_i 对 POI l_j 偏好的权重矩阵
K	潜在特征向量的维度
$\boldsymbol{P}$	K 维用户潜在特征矩阵，$\boldsymbol{p}_i\in\boldsymbol{P}$
$\boldsymbol{Q}$	K 维 POI 潜在特征矩阵，$\boldsymbol{q}_j\in\boldsymbol{Q}$
$\boldsymbol{V}$	K 维 POI 类别潜在特征矩阵，$\boldsymbol{v}_{Ca_j}\in\boldsymbol{V}$

3.2　解决方案及建模

通过从传统的 LBSNs 模型中刻画出个性化区域与行为模式 *Niche*，本文从以下几个方面分析与使用影响用户签到行为的上下文信息，如图 3 所示.

(1) 利用用户签到数据，构建基于用户签到轨迹的个性化区域及签到行为模式(定义 2)和建模 POI 相关的上下文信息(定义 1).

(2) 建模社会-地理关系模型. 关于用户的社会关系，考虑不同用户的社会地理距离分布，即 *Niche* 间地理相关性，过滤掉那些与 $Niche_i$ 距离较远或不在同一区域者；其次，联合用户签到过的 POI 的文本内容信息和签到时间计算 POI 的相关性，并采用 EMD 距离[38]度量用户 u_i 和 u_k 的个性化区域内行为模式($Niche_i$ 和 $Niche_k$)间的相似度. 这里，我们最终综合用户间地理和行为相关性，得到社会关系对用户的偏好影响. 而 POI 的地理关系，则根据(1)所获得 $Niche_i$，建模 $Niche_i$ 中 POI 的地理距离分布，通过判断用户 u_i 未访问过的 l_k($l_k \in Niche_k$)与 $Niche_i$ 中 POI 的地理相关性，得到 POI 地理信息对用户的偏好影响. 并使用乘法法则将社会关系和地理关系融合.

(3) 构建用户自身偏好模型及融合模型. 采用 WMF 建模用户自身偏好，并将 POI 类别信息融入建模过程中，使得原本极度稀疏的用户-POI 签到矩阵得到进一步缓解. 最后将上述量化的社会-地理关系针对用户自身偏好中的不同情况(用户-POI 矩阵中的零项与非零项)，有效融合到矩阵分解模型中，从而计算生成对用户 u_i 的 top-k 推荐列表.

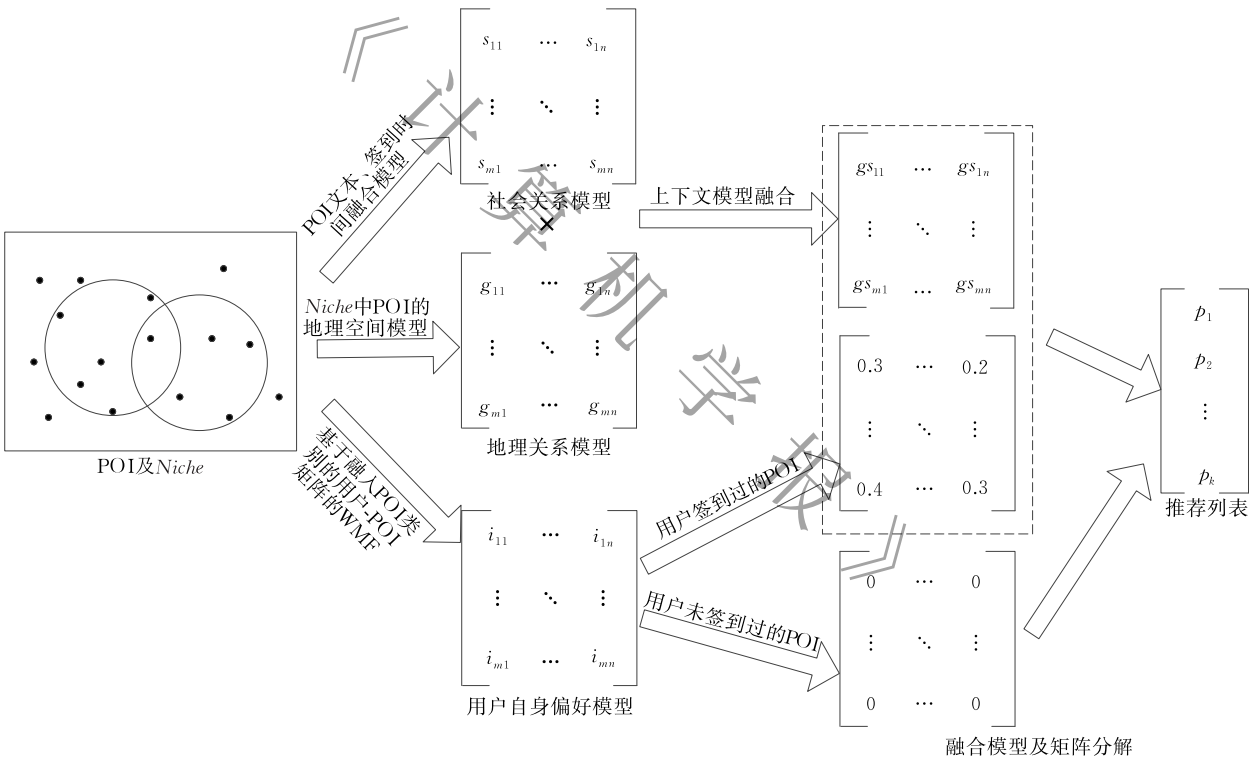

图 3　解决方案框架图

3.3　用户的社会关系建模

的确，在 POI 推荐过程中，朋友关系会对用户的偏好决策有影响，但这影响是有限的，其原因主要有两点：一是用户与朋友往往不在同一区域或地区，用户的日常签到行为大多均发生在用户生活区域附近，所以兴趣相似的二者在相同 POI 签到概率很低；其二是用户的行为习惯或偏好是受多种客观因素影响的，朋友间的行为重合度或相似度并不高，这也被已有的研究[1,18,27]所证实. 因此，在社会信息的使用方面，仅仅考虑朋友关系是不合理的. 在 LBSNs 中，社交关系是复杂的，除了朋友关系外，不同用户间隐含的社会关系同样具有应用价值，如用户间的社会签到行为的相似性：用户 u_i 和 u_k 经常签到相同或相近的 POI，说明二者具有相似的偏好和习惯，所以将 u_k 签到过而 u_i 未访问过的 POI 推荐给 u_i 是更具有实际应用意义的. 不同用户的日常(签到)行为习惯相似度与对相同 POI 签到的概率呈正相关，所以挖掘 LBSNs 中的用户行为相似度作为社会关系是更加合理的.

用户更倾向于签到距离自己较近的 POI，且用

户日常的签到行为大多发生在其活动轨迹和区域附近.如果用户 u_i 和 u_k 的活动轨迹或区域间的距离过大(超过 50 km,这是已有研究[39-40]证实的用户可达距离半径,驾车 1～1.5 h 距离),则说明 u_k 签到过的 POI 距离 u_i 相对较远,因此即使在 u_i 和 u_k 具有相似的偏好或习惯的情况下,基于 u_k 的协同推荐并不是最好的选择.进一步地,考虑到不同用户间签到行为的相似度计算复杂度时,由于在相同区域且行为更相似的用户相互影响更突出,故过滤掉那些距离较大(相关性较弱)的用户,以此降低签到行为的相似度计算复杂度,并同时保证了用户社会关系在 POI 推荐中的作用.本文在后续的实验中讨论并证明了这一点.本文以 $Niche$ 的中心作为用户的地理位置,并采用无参估计的 Triangular 核函数拟合用户在地理位置上的相关性.因为其相比较于其他核函数方法,具有更好的过滤性.具体如以下公式 $K_D(u_i,u_k)$ 所示:

$$K_D(u_i,u_k)\propto\left(1-\frac{d(u_i,u_k)}{b}\right)I_b \tag{1}$$

这里,$K_D(u_i,u_k)$ 表示 u_i 与 u_k 间的地理相关分数;$d(u_i,u_k)$ 表示 u_i 和 u_k 所在 $Niche$ 间的距离;I_b 是指示函数(如果 $d(u_i,u_k)\leq b$,则 $I_b=1$;如果 $d(u_i,u_k)>b$,则 $I_b=0$);b 是核函数宽度.所以,当 $d(u_i,u_k)$ 大于 b 时,$K_D(u_i,u_k)=0$;否则,$d(u_i,u_k)$ 越小,$K_D(u_i,u_k)$ 越大,u_i 与 u_k 的相关性越大.本文基于经纬度信息计算 $d(u_i,u_k)$,具体如以下半正矢公式所示:

$$d(u_i,u_k)=2r\cdot\arcsin\left[\sin^2\left(\frac{\bar{\varphi}_k-\bar{\varphi}_i}{2}\right)+\cos(\bar{\varphi}_i)\cos(\bar{\varphi}_k)\sin^2\left(\frac{\bar{\lambda}_k-\bar{\lambda}_i}{2}\right)\right]^{\frac{1}{2}} \tag{2}$$

其中,r 表示地球半径距离;$(\bar{\varphi}_i,\bar{\lambda}_i)$ 与 $(\bar{\varphi}_k,\bar{\lambda}_k)$ 分别是 u_i 和 u_k 日常签到 POI 的中心位置,即 $Niche_i$ 和 $Niche_k$ 地理坐标.具体地,使用如下公式求取:

$$\bar{\varphi}_i=\frac{\sum\limits_{\varphi_j\in Niche_i}\varphi_j}{n} \tag{3}$$

$$\bar{\lambda}_i=\frac{\sum\limits_{\lambda_j\in Niche_i}\lambda_j}{n} \tag{4}$$

在用户相似度方面,已有研究[17-18,24-25]采用余弦相似度或 Jaccard 相似度等计算方法,利用用户签到数据集,计算不同用户对相同 POI 签到的概率,进而得到用户间的相似度.但这些方法在考虑用户相似度时,认为用户对 POI 的签到行为相似度非 0 即 1,显然这是不合理的,因为在很多情况下,用户间并没有对相同 POI 进行签到,但其行为仍有相似性.例如,u_i 签到了某水上公园,u_k 签到了某湿地公园,虽然二者不是相同的 POI,但是不能以完全相同或完全不同来度量,两个 POI 属于相同类别并具有相似的语义特征,所以其相似度应该介于 0 和 1 之间.

本文使用连续词袋(Continuous Bag of Words,CBOW)模型[41]将用户签到数据生成词向量,并使用 EMD 距离度量公式计算词向量间的语义相似度,即用户的签到行为模式相似度.令用户 u_i 和 u_k 间的相似度 $S_{i,k}$ 是在其对应的 $Niche_i$ 和 $Niche_k$ 间的语义距离 $D(u_i,u_k)$ 上实现的,具体如以下公式所示:

$$S_{i,k}\propto(1-D(u_i,u_k)) \tag{5}$$

$D(u_i,u_k)$ 是由 EMD 距离计算用户签到行为模式对应的单词多重集所得,如式(6)所示.令用户 u_i 和 u_k 的行为模式单词多重集分别为 $W_i=\{(w_{p1},c_{p1},T_{p1}),(w_{p2},c_{p2},T_{p2}),\cdots,(w_{pm},c_{pm},T_{pm})\}$ 和 $W_k=\{(w_{q1},c_{q1},T_{q1}),(w_{q2},c_{q2},T_{q2}),\cdots,(w_{qn},c_{qn},T_{qn})\}$,其中 w_i 表示 u_i 签到行为 B_{ij} 中的 $l_j.doc$,c_i 是 B_{ij} 的归一化频次,T_i 是签到的时间集,f_{ik} 是 w_{pi} 到 w_{qk} 的转化量,且 d_{ik} 表示 w_{pi} 与 w_{qk} 间的距离.

$$D(u_i,u_k)=\min_{f_{ik}}\frac{\sum\limits_{i=1}^{m}\sum\limits_{k=1}^{n}f_{ik}d_{ik}}{\sum\limits_{i=1}^{m}\sum\limits_{k=1}^{n}f_{ik}} \tag{6}$$

$$\text{s.t.}\quad f_{ij}\geq 0;$$

$$\sum_{j=1}^{n}f_{ij}\leq c_{pi},\ 1\leq i\leq m;$$

$$\sum_{i=1}^{m}f_{ij}\leq c_{qj},\ 1\leq j\leq n;$$

$$\sum_{i=1}^{m}\sum_{j=1}^{n}f_{ij}=\min\left(\sum_{i=1}^{m}c_{pi},\sum_{j=1}^{n}c_{qj}\right);$$

这里,d_{ik} 是由两部分组成,即语义感知距离和时间感知距离.语义上,是低维向量 $\boldsymbol{v}(w_{pi})$ 与 $\boldsymbol{v}(w_{qk})$ 间的距离 d_{ik}^{s},如式(7):

$$d_{ik}^{s}=\left\|\boldsymbol{v}(w_{pi})-\boldsymbol{v}(w_{qk})\right\|_2 \tag{7}$$

而对于 w_{pi} 和 w_{qk} 的签到时间距离感知,是我们出于对文本 $l_j.doc$ 信息不完整和无意义情况的考虑.在 LBSNs 的用户签到数据(如 Gowalla 和 Foursquare 等)中,平均有 30% 的 POI 的文本信息描述是不完整的或者无意义的,所以只考虑文本信息的语义相关性以判断用户行为的相似性在技术上

《计算机学报》

仍有不足.我们发现,用户已签到过的 POI 的文本内容与签到时间 $t(t\in T)$具有相关性,即用户通常在相似或相同时间签到那些具有相似或相同功能(内容)的 POI,可以通过构建一种行为模式内容与签到时间的同现模型,以弥补文本语义相似度计算的不足.为有效地将文本语义关系与时间效应融合,我们采用连续时间值,并将一天的时间范围正则化在[0,1].这与现有相关方法[11,35-37]不同,主要是因为这些方法大多采用离散时间片段,违背了时间客观上是连续的以及回避了时间间隔设置的合理性问题.我们使用 Beta 分布[42] Ψ 来刻画基于签到时间的 POI 内容的相关性,如式(8):

$$P(w_{qj}\mid\psi,t,w_{pi},W_i,W_j)\propto \left(\sum_{W_i}n_{pi}+\sum_{W_j}n_{qj}-1\right)\frac{n_{qj}-1}{\sum_{W_i}(n_{pi}-1)}\cdot \frac{(1-t_{pi})^{\psi_{w_{pi},1}-1}\cdot t_{pi}^{\psi_{w_{pi},2}-1}}{\mathrm{Beta}(\psi_{w_{pi},1},\psi_{w_{pi},2})} \tag{8}$$

其中,基于Gibbs 采样,抽取出时间指数 $t\sim\mathrm{Beta}(\Psi_{w,1},\Psi_{w,2})$,$n_i$ 是 W_i 中单词 w_i 的数量,t_i 是用户 u_i 签到内容为 w_i 的时间戳.且 $\Psi_{w,1}$,$\Psi_{w,2}$ 的更新如下:

$$\psi_{w,1}=t_w\left(\frac{t_w(1-t_w)}{s_w^2}-1\right) \tag{9}$$

$$\psi_{w,2}=(1-t_w)\left(\frac{t_w(1-t_w)}{s_w^2}-1\right) \tag{10}$$

这里,t_w 和 s_w 分别表示单词 w 的时间戳的采样平均值和标准差.则签到时间感知距离 d_{ik}^t 可表示为

$$d_{ik}^t\propto 1-P(w_{qk}\mid\psi,t,w_{pi},W_i,W_k) \tag{11}$$

POI 的文本内容语义和签到时间的同现模型:融合文本内容信息和签到时间信息可采取乘法或加法法则,但由于二者的先验知识不足和难以确定的加权权重,直接做乘法或加法是不合理的.我们采用一种将内容语义和时间等同处理的方法,如式(12)～(15):

归一化 d_{ik}^s 和 d_{ik}^t:

$$\hat{d}_{ik}^s=\frac{d_{ik}^s}{\max\limits_{w_k\in W_k}d_{ik}^s} \tag{12}$$

$$\hat{d}_{ik}^t=\frac{d_{ik}^t}{\max\limits_{w_k\in W_k}d_{ik}^t} \tag{13}$$

$\hat{d}_{ik}^s$ 和 $\hat{d}_{ik}^t$ 间的均值和标准差:

$$\mu_{ik}=\frac{\hat{d}_{ik}^s+\hat{d}_{ik}^t}{2} \tag{14}$$

$$\sigma_{ik}=\frac{\sqrt{(\hat{d}_{ik}^s-d_{ik}^\mu)^2+(\hat{d}_{ik}^t-d_{ik}^\mu)^2}}{2} \tag{15}$$

根据式(14)和(15)可知,均值 μ_{ik} 分别与 d_{ik}^s 和 d_{ik}^t 的差值决定了标准差 σ_{ik} 的值,且差值越小,则 σ_{ik} 越小,$\hat{d}_{ik}^s$ 和 $\hat{d}_{ik}^t$ 的融合置信度越大,因此我们利用 μ_{ik} 与 σ_{ik} 的差值构建 w_{pi} 与 w_{qk} 间的最终距离:

$$d_{ik}=1-(\mu_{ik}-\sigma_{ik}) \tag{16}$$

不同于现有研究,本文在用户社会行为相似度的基础上进一步融合了用户间的地理关系,并作为最终的用户相似度 $R_{i,k}$:

$$R_{i,k}=K_D(u_i,u_k)\cdot S_{i,k} \tag{17}$$

结合 $R_{i,k}$,本文使用一种基于用户协同过滤的方法来刻画与 u_i 近邻且行为相似的用户对 u_i 签到 POI 的影响:

$$\boldsymbol{sc}_{i,j}=\frac{\sum\limits_{u_k}R_{i,k}\cdot C_{k,j}}{\sum\limits_{u_k}R_{i,k}} \tag{18}$$

$\boldsymbol{sc}_{i,j}$ 是用户 u_i 在 u_k 影响下签到 POI l_j 的概率;u_k 是与 u_i 近邻且行为相似的用户,由式(1)获得;$C_{k,j}=1$ 表示 u_k 签到过 POI l_j,$C_{k,j}=0$ 表示 u_k 未访问过 POI l_j.

3.4　POI 的地理信息建模

现有研究已证明,POI 地理位置的近邻性会显著增加用户签到率,所以近年来专注于 POI 位置关系的研究大量涌现,其中主要以幂律分布[17]、多中心高斯模型[1]和核密度估计[18]等最为典型.基于幂律分布和多中心高斯模型的位置对用户偏好影响分析方法均是一种通用模型,而根据本文提出的针对不同 u_i 的 $Niche_i$,应使用一种能够考虑到个体用户签到习惯的个性化地理位置信息建模方法,所以本文采用一种基于自适应宽带(Adaptive Bandwidth)的核密度估计进行 POI 位置间相关性的分析,如式(10)所示.不同于使用固定带宽的核密度估计方法[10],带有自适应带宽的核密度估计能更准确地描述出不同 $Niche$ 中的 POI 空间分布以及刻画出不同用户的签到空间偏好,因为自适应带宽是从 $Niche$ 中的签到数据学习获得.

令用户 u_i 签到过的 POI 集 $L_i=\{l_1,l_2,\cdots,l_p,\cdots,l_n\}$,$L_i\subseteq Niche_i$,且以 $r_{i,p}$ 表示 u_i 对 l_p 的签到频率,由于 $r_{i,p}$ 能够客观反映 l_p 对 u_i 的重要程度.本文以 $\boldsymbol{gc}_{i,j}$ 表示用户 u_i 对未访问过的 POI l_j 的地理偏好程度:

《计算机学报》

$$\boldsymbol{gc}_{i,j}=P(l_j|L_i)=\frac{1}{N}\sum_{p=1}^{n}(r_{i,p}\cdot K_{Hh_i}(l_j-l_p)) \tag{19}$$

$$N=\sum_{p=1}^{n}r_{i,p} \tag{20}$$

式(19)中,$K_{Hh_i}(l_j-l_p)$是基于全局带宽 $H=(H_1,H_2)$和自适应带宽 h_i的核函数:

$$K_{Hh_i}(l_j-l_p)=\frac{1}{2\pi H_1H_2h_i^2}\exp\left(-\frac{(x_j-x_p)^2}{2H_1^2h_i^2}-\frac{(y_j-y_p)^2}{2H_2^2h_i^2}\right) \tag{21}$$

这里,(x_p,y_p)与(x_j,y_j)分别是 u_i签到过的 POI 和未访问过的 POI 对应的地理经纬度坐标;两个全局带宽 H_1和 H_2是根据 $Niche_i$中不同 POI l_p,$l_q\in L_i$的经度(纬度)的标准差计算而得:

$$H_1=1.06n^{-\frac{1}{5}}\sqrt{\frac{1}{N}\left(\sum_{p=1}^{n}r_{i,p}x_p-\frac{1}{N}\sum_{q=1}^{n}r_{i,q}x_q\right)^2} \tag{22}$$

$$H_2=1.06n^{-\frac{1}{5}}\sqrt{\frac{1}{N}\left(\sum_{p=1}^{n}r_{i,p}y_p-\frac{1}{N}\sum_{q=1}^{n}r_{i,q}y_q\right)^2} \tag{23}$$

针对每一个 $Niche_i$的本地自适应带宽 h_i,本文使用其固定带宽求得,如式(24)、(25)和式(26):

$$P'(l_p|L_i)=\frac{1}{N}\sum_{q=1}^{n}(r_{i,q}\cdot K_H(l_p-l_q)) \tag{24}$$

$$K_H(l_p-l_q)=\frac{1}{2\pi H_1H_2}\exp\left(-\frac{(x_p-x_q)^2}{2H_1^2}-\frac{(y_p-y_q)^2}{2H_2^2}\right) \tag{25}$$

$$h_i=(P'(l_p|L_i)\cdot Z^{-1})^{-\gamma} \tag{26}$$

其中,γ是可调的敏感参数 $\gamma\in[0,1]$,h_i对 $P'(l_p|L_i)$的敏感度与 γ呈正相关,且 Z是 $P'(l_p|L_i)$的几何均值:

$$Z=\sqrt[n]{\prod_{p=1}^{n}P'(l_p|L_i)} \tag{27}$$

Z的目的是强制约束 h_i的几何平均值为 1,$i=1,2,\cdots,n$.

3.5 融合模型:UGS_PG-WMF

本文进一步地分析了上下文对用户签到 POI 的偏好影响,重构了用户的社会关系及 POI 的地理位置信息模型,并得到用户签到 POI 的用户地理社会影响相关分数 $\boldsymbol{sc}_{i,j}$和 POI 地理位置相关分数 $\boldsymbol{gc}_{i,j}$.融合上下文信息通常有两种方式,即加法法则和乘法法则,由于文中的 $\boldsymbol{sc}_{i,j}$主要是根据 $Niche_i$中用户签到过的 POI 的名称等标签信息和签到时间的相似度计算获得,而 $\boldsymbol{gc}_{i,j}$则是利用 POI 的经纬度分布关系算得.具体地,前者是在不同 POI 的文本描述信息及被签到的时间方面的考虑,反映了不同用户签到 POI 的轨迹和对 POI 内容的个性化偏好,并在寻求偏好相似性的基础上利用用户协同过滤方法求出社会关系对用户签到偏好的影响,而后者则是根据用户签到过的 POI 的空间分布特征反映了不同用户的活动区域的个性化偏好,并在探究用户未访问过的 POI 与个性化活动区域的地理相关性的基础上求得 POI 地理关系对用户签到偏好的影响.所以,二者是从不同的研究角度出发,挖掘不同的 POI 的上下文信息对用户偏好的影响,本质上是不同的,进行简单的加法线性组合显然是不合理的.相比于加法法则,本文选择乘法法则进行上下文信息融合,因为 $\boldsymbol{gc}_{i,j}$是在已确定的 $\boldsymbol{sc}_{i,j}$的基础上获得的,故后者可以认为是前者的权重,具体上下文融合 $\boldsymbol{sg}_{i,j}$如式(28)所示:

$$\boldsymbol{sg}_{i,j}=\boldsymbol{sc}_{i,j}\cdot\boldsymbol{gc}_{i,j} \tag{28}$$

上下文信息对用户的偏好决策的影响是不可否认的,但用户自身的偏好在用户签到行为决策方面具有更大的作用.一般地,基于矩阵分解构建用户自身偏好模型是常用方法,令 $\boldsymbol{p}_i$是 u_i的 K 维特征潜在向量,$\boldsymbol{p}_i\in\boldsymbol{P}$,$\boldsymbol{q}_j$是 POI l_j的 K 维特征潜在向量,$\boldsymbol{q}_j\in\boldsymbol{Q}$,则用户自身偏好 $\boldsymbol{I}_{i,j}=\boldsymbol{p}_i^{\mathrm{T}}\boldsymbol{q}_j$.据此,一些方法[1,8,43]使用高斯分布构建概率模型,而也存在一些方法[7,20-21]使用 Hu 等人[44]提出的 WMF 模型,两种模型结构不同主要在于零项与非零项的权重分配上,前者将非零项均赋值权重为 1,而零项权重为 0,后者则是根据用户实际签到次数为所有项分配一个非零权重,如式(29)所示:

$$\boldsymbol{w}_{i,j}=\begin{cases}1, & (u_i,l_j)\notin\boldsymbol{R}_{|U|\times|L|}\\ 1+\alpha\cdot r_{i,j}, & (u_i,l_j)\in\boldsymbol{R}_{|U|\times|L|}\end{cases} \tag{29}$$

其中,$\boldsymbol{w}_{i,j}$是用户偏好权重,α是一个可调参数且$\alpha>0$,$\boldsymbol{w}_{i,j}$随着 $r_{i,j}$的增大而增加.考虑到实际生活中缺失项对用户仍有一定的影响,本文采用 WMF 模型并进行改进,结合上下文信息因素 $sg_{i,j}$,给出如下目标函数:

$$\min_{U,L}G=\sum_{i=1}^{|U|}\sum_{j=1}^{|L|}\boldsymbol{w}_{i,j}(\boldsymbol{C}_{i,j}-(\boldsymbol{I}_{i,j}+sg_{i,j}))^2+\lambda_p\sum_{i=1}^{|U|}\|\boldsymbol{p}_i\|^2+\lambda_q\sum_{j=1}^{|L|}\|\boldsymbol{q}_j\|^2 \tag{30}$$

这里,λ_p和 λ_q表示正则化系数.利用式(30)可以建模并求解用户对 POI 的偏好,当前大多数工作[1,14,20-21,26,43-45]均属于此类模型,只有少数工作考虑了 POI 类别对用户偏好的影响,如文献[7].比如某用户 u_i经常签到某一湿地公园 l_j,说明 u_i对湿地

公园这一类 $Ca_j(l_j \in Ca_j)$ 较为感兴趣，所以有效地融合 POI 的类别信息可以进一步建模用户自身偏好以及减缓数据稀疏问题. 文献[7]中为所有类别设置了一个固定偏小的权重，以表示类别在用户自身偏好的影响，而本文在充分考虑了用户对不同类别 POI 的签到频率的不同，对其进行改进如下：

$$\boldsymbol{I}_{i,j}=\boldsymbol{p}_i^{\mathrm{T}}\left(\boldsymbol{q}_j+\left(\sum_{l_j\in Ca_j} r_{i,j}\right)\cdot \boldsymbol{v}_{Ca_j}\right) \tag{31}$$

其中，$\sum_{l_j\in Ca_j} r_{i,j}$ 表示用户 u_i 签到 l_j 的频率总和，l_j 属于类别 Ca_j，$\boldsymbol{v}_{Ca_j}$ 表示类别 Ca_j 的 K 维潜在向量，$\boldsymbol{v}_{Ca_j}\in \boldsymbol{V}$. 根据融合了 POI 类别的用户自身偏好模型，我们进一步改进了目标函数如下：

$$\begin{aligned}\min_{U,L} G=&\sum_{i=1}^{|U|}\sum_{j=1}^{|L|}\boldsymbol{w}_{i,j}(\boldsymbol{C}_{i,j}-(\boldsymbol{I}_{i,j}+sg_{i,j}))^2+\\&\lambda_p\sum_{i=1}^{|U|}\|\boldsymbol{p}_i\|^2+\lambda_q\sum_{j=1}^{|L|}\|\boldsymbol{q}_j\|^2+\lambda_v\sum_{j=1}^{|Ca|}\|\boldsymbol{v}_{Ca_j}\|^2\end{aligned} \tag{32}$$

在式(32)中，本文增加了一个关于 POI 类别的正则化项 $\lambda_v\sum_{j=1}^{|Ca|}\|\boldsymbol{v}_{Ca_j}\|^2$，$\lambda_v$ 是对应的正则化系数.

通过对式(32)的分析，我们发现当 u_i 签到过或访问过 POI l_j 时，$\boldsymbol{C}_{i,j}=1$，这时用户自身偏好与上下文影响因素之和拟合 $\boldsymbol{C}_{i,j}=1$. 如果 $sg_{i,j}$ 偏小，可能是实际地理距离较远等原因造成的，则此时 $\boldsymbol{I}_{i,j}$ 会相对偏大以实现拟合，因为 u_i 可能对 l_j 十分感兴趣；反之，若 u_i 对 l_j 兴趣较弱，$\boldsymbol{I}_{i,j}$ 偏小，此时 $sg_{i,j}$ 应该偏大，因为有可能是地理距离较近使得 u_i 签到 POI l_j. 所以，在用户偏好决策过程中，上下文信息是不可忽视的. 然而，当 $\boldsymbol{C}_{i,j}=0$ 时，即 u_i 未访问过 POI l_j 的情况下，为了拟合 $\boldsymbol{I}_{i,j}+sg_{i,j}=\boldsymbol{C}_{i,j}=0$，那么 $\boldsymbol{I}_{i,j}<0$，因为上下文信息影响因素 $sg_{i,j}>0$，这显然是不合理的. u_i 未访问过 POI l_j 并不能直接说明其对 l_j 是完全不感兴趣的，当然也不能证明其感兴趣，所以，我们认为，在 $\boldsymbol{C}_{i,j}=0$ 情况下，只使用 $\boldsymbol{I}_{i,j}$ 来拟合用户实际签到行为，而忽略 $sg_{i,j}$ 的影响更符合客观性. 最终，我们给出如下优化后的目标函数：

$$\begin{aligned}\min_{U,L} G=&\sum_{i=1}^{|U|}\sum_{j=1}^{|L|}\sum_{(u_i,l_j)\in\boldsymbol{R}}\boldsymbol{w}_{i,j}(\boldsymbol{C}_{i,j}-(\boldsymbol{I}_{i,j}+sg_{i,j}))^2+\\&\sum_{i=1}^{|U|}\sum_{j=1}^{|L|}\sum_{(u_i,l_j)\notin\boldsymbol{R}}\boldsymbol{I}_{i,j}^2+\lambda_p\sum_{i=1}^{|U|}\|\boldsymbol{p}_i\|^2+\\&\lambda_q\sum_{j=1}^{|L|}\|\boldsymbol{q}_j\|^2+\lambda_v\sum_{j=1}^{|Ca|}\|\boldsymbol{v}_{Ca_j}\|^2\end{aligned} \tag{33}$$

接着，为了求解 G 的局部最优，将对矩阵 $\boldsymbol{P}$、$\boldsymbol{Q}$ 及 $\boldsymbol{V}$ 进行更新. 考虑到数据稀疏性，用户的签到矩阵 $\boldsymbol{R}_{|U|\times|L|}$ 更多的是缺失项(零项)，所以更新的主要任务是对缺失项的处理，即式(33)中的 $\sum_{(u_i,l_j)\notin\boldsymbol{R}}$ 部分，而此部分不包含上下文信息，可以线下预处理以降低时间代价的消耗. 本文采取与文献[45]类似的做法，利用元素级的最小交替二乘(eALS)算法对 K 维潜在矩阵 $\boldsymbol{P}$、$\boldsymbol{Q}$ 及 $\boldsymbol{V}$ 中的元素逐次更新，相比于向量级的 ALS 算法，本文使用的方法能够避免矩阵求逆所带来的大量时间消耗. 令 x_{if}、y_{jf} 和 z_{Ca_jf} 分别是矩阵 $\boldsymbol{P}$、$\boldsymbol{Q}$ 和 $\boldsymbol{V}$ 的一个元素，具体步骤如下：

对式(24)求偏导，使得 $\frac{\partial G}{\partial x_{if}}=0$，$\frac{\partial G}{\partial y_{jf}}=0$ 和 $\frac{\partial G}{\partial z_{Ca_jf}}=0$，则：

$$x_{if}\leftarrow\frac{\sum_{l_j\in\boldsymbol{R}}\boldsymbol{w}_{i,j}h_{jf}(\boldsymbol{C}_{i,j}-sg_{i,j}-I_{i,j}^p)-\sum_{l_j\notin\boldsymbol{R}}h_{jf}\cdot I_{i,j}^p}{\sum_{l_j\in\boldsymbol{R}}\boldsymbol{w}_{i,j}h_{jf}^2-\sum_{l_j\notin\boldsymbol{R}}h_{jf}^2+\lambda_p} \tag{34}$$

$$y_{jf}\leftarrow\frac{\sum_{l_j\in\boldsymbol{R}}\boldsymbol{w}_{i,j}x_{if}(\boldsymbol{C}_{i,j}-sg_{i,j}-I_{i,j}^q)-\sum_{l_j\notin\boldsymbol{R}}x_{if}\cdot\left(I_{i,j}^q+\left(\sum_{l_j\in Ca_j}r_{i,j}\right)\cdot\boldsymbol{v}_{Ca_j}\right)}{\sum_{l_j\in\boldsymbol{R}}\boldsymbol{w}_{i,j}x_{if}^2-\sum_{l_j\notin\boldsymbol{R}}x_{if}^2+\lambda_q} \tag{35}$$

$$z_{Ca_jf}\leftarrow\frac{\sum_{l_j\in Ca_j}\left(\sum_{l_j\in\boldsymbol{R}}\boldsymbol{w}_{i,j}\left(\sum_{l_j\in Ca_j}r_{i,j}\right)x_{if}(\boldsymbol{C}_{i,j}-sg_{i,j}-I_{i,j}^v)-\sum_{l_j\notin\boldsymbol{R}}x_{if}\cdot\left(\sum_{l_j\in Ca_j}r_{i,j}\right)\left(I_{i,j}^v+\left(\sum_{l_j\in Ca_j}r_{i,j}\right)\cdot\boldsymbol{v}_{Ca_j}\right)\right)}{\sum_{l_j\in Ca_j}\left(\sum_{l_j\in\boldsymbol{R}}\boldsymbol{w}_{i,j}\left(\sum_{l_j\in Ca_j}r_{i,j}\right)^2x_{if}^2-\sum_{l_j\notin\boldsymbol{R}}\left(\sum_{l_j\in Ca_j}r_{i,j}\right)^2x_{if}^2+\lambda_v\right)} \tag{36}$$

上式中：

$$h_{jf}=y_{jf}+\left(\sum_{l_j\in Ca_j}r_{i,j}\right)v_{Ca_jf} \tag{37}$$

$$I_{i,j}^p=\boldsymbol{I}_{i,j}-x_{if}\cdot h_{jf} \tag{38}$$

$$I_{i,j}^q=\boldsymbol{I}_{i,j}-x_{if}\cdot y_{jf} \tag{39}$$

$$I_{i,j}^v=\boldsymbol{I}_{i,j}-\left(\sum_{l_j\in Ca_j}r_{i,j}\right)x_{if}v_{Ca_jf} \tag{40}$$

3.6　时间复杂度分析

以式(34)为例，由于式中主要的时间消耗来自于缺失项 $\sum_{l_j\notin\boldsymbol{R}}h_{jf}\cdot I_{i,j}^p$ 和 $\sum_{l_j\notin\boldsymbol{R}}h_{jf}^2$，所以本文在计算过程中，先对缺失项预处理. 由 $\sum_{l_j\notin\boldsymbol{R}}h_{jf}\cdot I_{i,j}^p=\sum_{k\neq f}x_{ik}\sum_{j=1}^{|L|}h_{jf}h_{jk}-\sum_{l_j\in R}h_{jf}\cdot I_{i,j}^p$ 可知，$\sum_{j=1}^{|L|}h_{jf}h_{jk}$ 与用户无关，所以在更新 x_{if} 时，可进行线下处理($\sum_{l_j\notin\boldsymbol{R}}h_{jf}^2$ 同理)，则除去线下处理部分，更新矩阵 $\boldsymbol{P}$ 的时间代价为 $O(|U|K^2+$

计算机学报

$|\boldsymbol{R}|K$).

类似地,式(35)和(36)在更新矩阵 $\boldsymbol{Q}$ 和 Ca 时,时间复杂度均为 $O(|L|K^2+|\boldsymbol{R}|K)$.综上,本文提出的融合模型 UGS_PG-WMF 的时间复杂度为 $O((|U|+|L|)K^2+|\boldsymbol{R}|K)$,与 eALS 模型的时间复杂度在相同的数量级上.向量级的 ALS 算法在更新一个潜在向量时,将不可避免地消耗矩阵求逆时间 $O(K^3)$,为此,对于更新矩阵 $\boldsymbol{P}$、$\boldsymbol{Q}$ 和 Ca,使用 ALS 算法的时间复杂度为 $O((|U|+|L|)K^3+|\boldsymbol{R}|K^2)$.所以,本文所提方法优于 ALS 算法 K 倍.

4 实验验证与结果分析

本节将重点介绍本文所使用的数据集、实验设置(参数、评价指标及对比方法)和最终的多角度实验结果及分析.

4.1 数据集

本文采用了 LBSNs 中两个经典的数据集 Gowalla 和 Foursquare 中的部分数据,且实验前,我们对数据集进行了过滤的预处理,目的是剔除异常数据,如过滤掉签到记录低于 10 条或签到不同 POI 的数量低于 5 个的用户,同时排出那些很少被用户签到的 POI(被签到次数少于 10 次).最终获得如表 2 所示的数据集,除了表中给出的数据信息,两个数据集中还有重要的上下文信息,包括 POI 的标签和经纬度等.实验过程中,我们对每个数据集随机选取 80%进行训练模型,剩余的 20%作为测试集来验证本文方法的性能(向用户推荐其未访问过的 POI 的 *precision* 和 *recall*),并使用被挑选出的异常数据测试模型处理冷启动问题的能力.

表 2 数据集的统计信息

数据集	用户数量	POI 数量	类别数量	用户签到数量	稠密度/%
Gowalla	4159	24919	121	301191	0.291
Foursquare	3475	21657	58	289467	0.385

4.2 实验设置

模型 USG_PG-WMF 中需要设定的参数有 b,γ 和 α 以及正则化系数 λ_p,λ_q 和 λ_v(自适应带宽 h 可通过式(26)自学习获得),本文通过多次实验调整,最终在两个数据集上分别选取不同的参数:Gowalla 上,核函数宽度 $b=45$ km,敏感参数 $\gamma=0.5$,可调参数 $\alpha=0.45$,正则系数 $\lambda_p=\lambda_q=0.01$,$\lambda_v=200$;Foursquare 上,核函数宽度 $b=30$ km,敏感参数 $\gamma=0.5$,可调参数 $\alpha=0.55$,正则系数 $\lambda_p=\lambda_q=0.01$,$\lambda_v=100$.且模型迭代设置为 20 轮.而对于与本文对比的方法(baselines)中参数设置,我们尽可能保证 12 种方法与在其原文中最优状态下的参数一致.具体的对比方法如下:

User-based CF. 利用不同用户签到习惯的相似性,向用户推荐其未访问过的 POI[46].

Item-based CF. 将 POI 直接看作一般的项目,忽略其本身的地理特征,根据 POI 的用户评价间相似度,向用户进行服务推荐[47].

这里,我们将 User-based CF 和 Item-based CF 方法的邻居设定为 100.

GeoMF. 考虑了 POI 的地理信息对用户签到的影响,并将地理因素融入到 WMF 中,求解用户访问某个 POI 的概率[20].

GeoSoCa. 采用核密度估计评估用户的个性化 POI 签到分布;使用幂律分布分别建模基于朋友的社会关系和基于 POI 类别加权的流行度对签到的影响,最后采用线性组合方法将上下文融合,并实现 POI 推荐[6].

CoRe. 考虑到用户的实际签到行为是个性化的,提出利用带有优化带宽的核密度估计计算 POI 的地理信息对用户签到的影响,并结合用户的社会关系,设计了一种上下文融合策略,以实现 POI 推荐[11].

ASMF. 针对用户的社会关系,分别定义了三类朋友关系,并将其组合融合于 WMF 中进行 POI 个性化推荐[7].

TSG-MF. 将表征 POI 文本内容的多标签、用户的社会关系以及 POI 的地理相关性融合到矩阵分解模型中进行 POI 推荐[9].

Realtime-MF. 跟踪用户-POI 签到事件,基于 CNN 挖掘事件中上下文特征,并构建文本、位置和时间的多模式嵌入,采用矩阵分解技术融合上下文模型求解 POI 推荐列表[11].

MTAS. 采用联合分布建模多源的 POI 文本信息、签到时间、地理关系以及社会关系对用户签到的影响[12].

DeepR. 采用 GNN 深度学习框架分别实现 POI

地理空间竞争关系的学习以及 POI 的服务或功能方面的竞争关系学习，并将两种关系融合进行 POI 推荐[13]. 该方法也是目前 LBSNs 中 POI 推荐的最新研究进展之一

UGS_PG-WMF. 本文提出的模型，根据用户活动轨迹和个性化区域划分，重构了用户社会关系模型和 POI 地理信息关系模型，并将其融合到加权矩阵分解技术进行 POI 推荐.

为了验证本文模型的可扩展性，进一步分为 USG-WMF 和 PG-WMF：

USG-WMF. 本文提出的模型，相比于 UGS_PG-WMF，只考虑了用户社会关系和用户自身偏好.

PG-WMF. 本文提出的模型，相比于 UGS_PG-WMF，只考虑了 POI 间的地理关系和用户自身偏好.

关于评价指标，本文采用准确率（*precision@k*）和召回率（*recall@k*）两个指标进行模型性能的评测，具体计算公式如下：

$$precision@k=\frac{1}{|U|}\sum_{i=1}^{|U|}\frac{|S_i(k)\cap T_i|}{k} \tag{41}$$

$$recall@k=\frac{1}{|U|}\sum_{i=1}^{|U|}\frac{|S_i(k)\cap T_i|}{|T_i|} \tag{42}$$

其中的 $S_i(k)$ 表示模型向用户推荐的其未访问过的 top-k POI 集合列表（不包括训练集中 POI），T_i 表示测试集中用户签到过的 POI.

4.3　实验结果

本文首先进行 $k=5$，不同维度 $K=\{5,10,20,40\}$ 在两种数据集上的对比实验，如表 3 所示. 由表 3 可知，因为 GeoSoCa 和 CoRe 在简单协同过滤方法的基础上，更多地考虑了上下文信息（社会关系和地理信息等）的作用，所以其性能均优于 User-based CF 和 Item-based CF，且当 $K<10$ 时，GeoSoCa 和 CoRe 较基于 MF 的方法也具有一定的优势. 而当 $K\geq10$ 时，现有的基于 MF 改进的方法，如 ASMF、TSG-MF 以及 Realtime-MF，相比直接进行乘法组合或线性融合的 GeoSoCa 和 CoRe 模型更具优势. 而且采用联合分布融合不同上下文信息的 MTAS 和基于 GNN 学习 POI 不同特征的 DeepR 是现有方法中性能最优的. 在本文提出的三个模型中，USG-WMF 与 PG-WMF 总体上是接近的且 USG-WMF 稍具优势，这与之前的工作[1,18,27,43]有所不同（这些工作中都证实在用户偏好决策方面地理信息的作用大于社会信息），说明本文对社会关系建模改进的有效性，而且 USG-WMF 和 PG-WMF 也分别较 ASMF 和 GeoMF 具有更好的性能表现；同时综合了 USG-WMF 和 PG-WMF 两方面优势的 UGS_PG-WMF 的个性化 POI 推荐效果相比于其他方法有了显著的提升，其中，相比于 MTAS 与 DeepR 平均提高了 10%～13%. 这一结果也说明了 UGS_PG-WMF 能更好地利用用户签到数据和上下文信息，在上下文信息的建模并融合到 WMF 这一过程中，不仅能够有效地降低数据的稀疏性，而且融合方法是合理且有效的. 而且我们发现，随着 K 的增大，UGS_PG-WMF 的性能逐渐提高，在 $K=20$ 时，*precision* 和 *recall* 达到最大，所以在接下来的实验中，将潜在的特征矩阵的维度 K 设定为 20，进行关于推荐不同 POI 数量（top-k）、冷启动（given-n）问题和参数影响的实验验证.

表 3　13 种方法的推荐（top-5）性能对比

DataSet	K	Metrics	User-based CF	Item-based CF	Geo MF	Geo SoCa	CoRe	ASMF	TSG-MF	Realtime-MF	MTAS	DeepR	USG-WMF	PG-WMF	UGS_PG-WMF
Gowalla	5	*precision*@5	0.0463	0.0435	0.0510	0.0612	0.0603	0.0512	0.0529	0.0533	0.0633	**0.0637**	0.0527	0.0524	0.0539
		recall@5	0.0326	0.0318	0.0307	0.0368	0.0366	0.0341	0.0360	0.0364	**0.0429**	0.0422	0.0358	0.0343	0.0332
	10	*precision*@5	0.0463	0.0435	0.0553	0.0612	0.0603	0.0574	0.0604	0.0611	0.0633	**0.0637**	0.0605	0.0591	0.0635
		recall@5	0.0326	0.0318	0.0347	0.0368	0.0366	0.0359	0.0385	0.0396	**0.0429**	0.0422	0.0383	0.0386	0.0411
	20	*precision*@5	0.0463	0.0435	0.0586	0.0612	0.0603	0.0617	0.0621	0.0629	0.0633	0.0637	0.0634	0.0616	**0.0708**
		recall@5	0.0326	0.0318	0.0348	0.0368	0.0366	0.0362	0.0414	0.0428	0.0429	0.0422	0.0437	0.0394	**0.0463**
	40	*precision*@5	0.0463	0.0435	0.0598	0.0612	0.0603	0.0613	0.0619	0.0622	0.0633	0.0637	0.0621	0.0602	**0.0702**
		recall@5	0.0326	0.0318	0.0359	0.0368	0.0366	0.0371	0.0397	0.0401	0.0429	0.0422	0.0386	0.0369	**0.0443**
Foursquare	5	*precision*@5	0.0431	0.0526	0.0519	0.0616	0.0608	0.0553	0.0534	0.0536	0.0651	**0.0655**	0.0562	0.0557	0.0576
		recall@5	0.0321	0.0335	0.0323	0.0370	0.0367	0.0361	0.0358	0.0365	**0.0425**	0.0429	0.0369	0.0363	0.0375
	10	*precision*@5	0.0431	0.0526	0.0573	0.0616	0.0608	0.0597	0.0607	0.0615	0.0651	0.0655	0.0619	0.0611	**0.0662**
		recall@5	0.0321	0.0335	0.0345	0.0370	0.0367	0.0374	0.0390	0.0398	0.0425	0.0429	0.0399	0.0389	**0.0430**
	20	*precision*@5	0.0431	0.0526	0.0614	0.0616	0.0608	0.0621	0.0626	0.0632	0.0651	0.0655	0.0662	0.0641	**0.0741**
		recall@5	0.0321	0.0335	0.0358	0.0370	0.0367	0.0371	0.0423	0.0427	0.0435	0.0429	0.0450	0.0393	**0.0492**
	40	*precision*@5	0.0431	0.0526	0.0601	0.0616	0.0608	0.0607	0.0618	0.0623	0.0651	0.0655	0.0630	0.0619	**0.0718**
		recall@5	0.0321	0.0335	0.0356	0.0370	0.0367	0.0364	0.0405	0.0412	0.0425	0.0429	0.0396	0.0389	**0.0459**

其次，进行 $K=20$，不同的 POI 推荐数量 $k=\{5,10,20,40\}$ 在两种数据集上的性能测试，结果如表 4 所示. 直观地看，随着 k 值的增大，各方法均呈现出 *precision* 降低，而 *recall* 上升的趋势. 这是因为 k 增大，向用户最终推荐的 POI 数量增多，这其中用户可能偏好的 POI 增多，但同时部分 POI 被签到的概率就有所降低. 具体地分析发现，结合上下文进行 POI 推荐的方法完全优于简单的协同过滤方法 User-based CF 与 Item-based CF，且融入了部分上下文信息的 GeoMF、GeoSoCa、CoRe、ASMF 以及 PG-WMF 和 USG-WMF 整体上逊色于考虑了更多上下文信息的 TSG-MF、Realtime-MF、MTAS 以及 DeepR 和 USG_PG-WMF，而 USG-WMF 是利用部分上下文信息推荐 POI 方法中性能表现最优的，USG_PG-WMF 是在 13 种推荐方法中最具优势的. 原因在于 GeoMF 使用的是标准的核函数（带有固定的带宽）建模地理信息对用户的偏好，而本文的 PG-WMF 则根据用户具体签到过的 POI 位置集合（*Niche*）采用自适应带宽的核密度估计方法进行建模，能更准确地刻画用户签到的偏好；USG-WMF 相比于 ASMF 不仅考虑了近邻朋友对用户签到的影响，同时根据不同用户间的地理位置关系，结合用户行为相似度建模用户社会关系对签到的影响，改善了社会关系对用户签到方面的作用，且采用了一种新的基于 WMF 的上下文与用户偏好融合策略，相比于 GeoMF 和 ASMF 中的简单的 MF 融合方法及 GeoSoCa 和 CoRe 中的线性组合方法更有效. UGS_PG-WMF 是综合了 PG-WMF 和 USG-WMF 的优势，同时将社会关系、POI 地理信息、POI 类别信息、文本内容信息以及时间信息有效地融合.

表 4 13 种方法的推荐（top-k）性能对比

DataSet	Metrics	User-based CF	Item-based CF	Geo MF	Geo SoCa	CoRe	ASMF	TSG-MF	Realtime-MF	MTAS	DeepR	USG-WMF	PG-WMF	UGS_PG-WMF
Gowalla	*precision*@5	0.0463	0.0435	0.0586	0.0612	0.0603	0.0617	0.0621	0.0629	0.0633	0.0637	0.0634	0.0616	**0.0708**
	recall@5	0.0326	0.0318	0.0348	0.0368	0.0366	0.0362	0.0414	0.0428	0.0429	0.0422	0.0437	0.0394	**0.0463**
	precision@10	0.0421	0.0396	0.0510	0.0529	0.0521	0.0536	0.0548	0.0557	0.0561	0.0565	0.0563	0.0528	**0.0616**
	recall@10	0.0383	0.0382	0.0415	0.0422	0.0414	0.0423	0.0466	0.0474	0.0485	0.0478	0.0504	0.0453	**0.0543**
	precision@20	0.0375	0.0364	0.0454	0.0473	0.0470	0.0475	0.0487	0.0498	0.0507	0.0505	0.0503	0.0475	**0.0539**
	recall@20	0.0452	0.0440	0.0488	0.0496	0.0492	0.0500	0.0543	0.0567	0.0576	0.0574	0.0589	0.0520	**0.0608**
	precision@40	0.0353	0.0343	0.0422	0.0443	0.0441	0.0446	0.0456	0.0466	0.0475	0.0472	0.0480	0.0445	**0.0508**
	recall@40	0.0488	0.0469	0.0509	0.0517	0.0512	0.0528	0.0569	0.0583	0.0597	0.0588	0.0604	0.0533	**0.0622**
Foursquare	*precision*@5	0.0431	0.0526	0.0614	0.0616	0.0608	0.0621	0.0626	0.0632	0.0651	0.0655	0.0662	0.0641	**0.0741**
	recall@5	0.0321	0.0335	0.0358	0.0370	0.0367	0.0371	0.0423	0.0427	0.0435	0.0429	0.0450	0.0393	**0.0492**
	precision@10	0.0378	0.0455	0.0541	0.0555	0.0550	0.0552	0.0559	0.0564	0.0586	0.0594	0.0591	0.0566	**0.0683**
	recall@10	0.0366	0.0377	0.0415	0.0424	0.0421	0.0427	0.0458	0.0472	0.0481	0.0477	0.0489	0.0451	**0.0567**
	precision@20	0.0334	0.0398	0.0479	0.0488	0.0485	0.0492	0.0505	0.0510	0.0522	0.0516	0.0529	0.0503	**0.0614**
	recall@20	0.0425	0.0434	0.0482	0.0498	0.0493	0.0501	0.0546	0.0553	0.0560	0.0553	0.0569	0.0512	**0.0663**
	precision@40	0.0310	0.0362	0.0447	0.0457	0.0453	0.0461	0.0483	0.0491	0.0503	0.0500	0.0505	0.0467	**0.0572**
	recall@40	0.0435	0.0443	0.0498	0.0521	0.0517	0.0524	0.0559	0.0567	0.0576	0.0575	0.0580	0.0535	**0.0695**

接着，我们进一步验证本文所提出模型的冷启动（given-n）处理能力. 实验数据采用在数据预处理过程中过滤掉的部分，即一个用户签到 POI 的数量为 3，5，10（推荐 top-5），具体结果如表 5 所示. 不难发现，上下文信息在推荐过程中发挥了重要作用，简单的协同过滤方法应对冷启动问题的能力是较差的，融合了多种不同上下文信息的推荐方法在冷启动问题上的性能表现优于只融合了部分上下文信息的推荐方法. 本文提出的模型在 POI 推荐的冷启动处理能力上更具优势，更具体地，随着 n 的增加，*precision* 和 *recall* 均有上升的趋势，这是因为数据量增加，模型可以更好地学习用户的偏好；USG-WMF 是利用用户生活区域内与该用户行为相似的所有用户作为社会关系，相比于 ASMF 等考虑了部分上下文信息的方法，能更加充分合理地利用上下文，更准确地刻画用户的社会关系影响，且在此基础上进一步融合 POI 地理信息（PG-WMF）的 UGS_PG-WMF 获得了在 13 种方法中最好的推荐结果，即使对于签到数量很少的用户，其也能充分发挥由多种不同的上下文信息建模的用户社会关系和 POI 地理信息的作用，进行 POI 推荐.

同时，为了研究 UGS_PG-WMF 模型中不同因素所起到的作用，我们分别在 $K=20$，top-k 推荐和冷启动问题方面进行了实验. 这里涉及的因素有社会、地理以及用户自身偏好，分别对应模型如下：

表 5　12 种方法的冷启动(given-n)处理能力对比

DataSet	n	Metrics	User-based CF	Item-based CF	Geo MF	Geo SoCa	CoRe	ASMF	TSG-MF	Realtime-MF	MTAS	DeepR	USG-WMF	PG-WMF	UGS_PG-WMF
Gowalla	3	*precision*@5	0.0095	0.0091	0.0152	0.0164	0.0158	0.0166	0.0199	0.0187	0.0205	0.0185	0.0203	0.0154	**0.0215**
		recall@5	0.0086	0.0074	0.0137	0.0146	0.0141	0.0145	0.0157	0.0153	0.0173	0.0155	0.0156	0.0140	**0.0191**
	5	*precision*@5	0.0098	0.0099	0.0161	0.0175	0.0168	0.0179	0.0207	0.0201	0.0212	0.0203	0.0211	0.0165	**0.0245**
		recall@5	0.0087	0.0086	0.0139	0.0159	0.0155	0.0162	0.0182	0.0175	0.0186	0.0180	0.0184	0.0144	**0.0212**
	10	*precision*@5	0.0106	0.0109	0.0175	0.0188	0.0184	0.0192	0.0214	0.0223	0.0236	0.0222	0.0224	0.0177	**0.0286**
		recall@5	0.0095	0.0098	0.0143	0.0174	0.0169	0.0176	0.0194	0.0201	0.0215	0.0202	0.0199	0.0146	**0.0237**
Foursquare	3	*precision*@5	0.0107	0.0112	0.0158	0.0171	0.0166	0.0174	0.0204	0.0191	0.0217	0.0200	0.0209	0.0159	**0.0223**
		recall@5	0.0101	0.0103	0.0139	0.0145	0.0142	0.0149	0.0165	0.0157	0.0177	0.0165	0.0164	0.0142	**0.0198**
	5	*precision*@5	0.0114	0.0118	0.0178	0.0186	0.0179	0.0189	0.0212	0.0206	0.0226	0.0212	0.0215	0.0182	**0.0260**
		recall@5	0.0103	0.0109	0.0146	0.0155	0.0149	0.0156	0.0189	0.0182	0.0208	0.0186	0.0193	0.0147	**0.0217**
	10	*precision*@5	0.0121	0.0122	0.0193	0.0204	0.0196	0.0207	0.0215	0.0229	0.0264	0.0225	0.0228	0.0196	**0.0297**
		recall@5	0.0108	0.0111	0.0169	0.0182	0.0173	0.0185	0.0206	0.0221	0.0237	0.0207	0.0205	0.0175	**0.0241**

SoWMF：

$$\min_{U,L} G=\sum_{u_i,l_j} \boldsymbol{w}_{i,j}(\boldsymbol{C}_{i,j}-(\boldsymbol{p}_i^{\mathrm{T}}\boldsymbol{q}_j+\boldsymbol{sc}_{i,j}))^2+\lambda_p\sum_{i=1}^{|U|}\|\boldsymbol{p}_i\|^2+\lambda_q\sum_{j=1}^{|L|}\|\boldsymbol{q}_j\|^2 \tag{43}$$

GeoWMF：

$$\min_{U,L} G=\sum_{u_i,l_j} \boldsymbol{w}_{i,j}(\boldsymbol{C}_{i,j}-(\boldsymbol{p}_i^{\mathrm{T}}\boldsymbol{q}_j+\boldsymbol{gc}_{i,j}))^2+\lambda_p\sum_{i=1}^{|U|}\|\boldsymbol{p}_i\|^2+\lambda_q\sum_{j=1}^{|L|}\|\boldsymbol{q}_j\|^2 \tag{44}$$

CaWMF：

$$\min_{U,L} G=\sum_{u_i,l_j} \boldsymbol{w}_{i,j}(\boldsymbol{C}_{i,j}-\boldsymbol{I}_{i,j})^2+\lambda_p\sum_{i=1}^{|U|}\|\boldsymbol{p}_i\|^2+\lambda_q\sum_{j=1}^{|L|}\|\boldsymbol{q}_j\|^2+\lambda_v\sum_{j=1}^{|Ca|}\|\boldsymbol{v}_{Ca_j}\|^2 \tag{45}$$

具体结果如图 4、图 5、图 6 和图 7 所示. 从结果中可以发现，UGS_PG-WMF 始终优于只考虑单因素的模型，且社会、地理和用户自身偏好分别对 UGS_PG-WMF 的性能起到了不同程度的作用. 另外，相同因素在两种不同的实验评估中具有不同的影响程度. 在 top-k 推荐的实验中，影响程度：用户自身偏好＞社会关系＞地理关系. 在冷启动问题的实验中，影响程度：社会关系＞地理关系＞用户自身

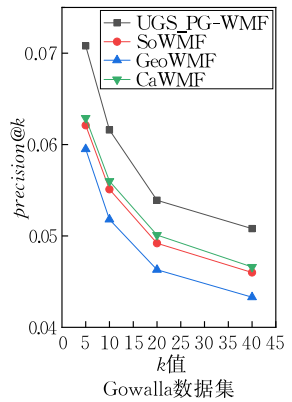

图 4　不同因素对 top-k 推荐准确率的影响

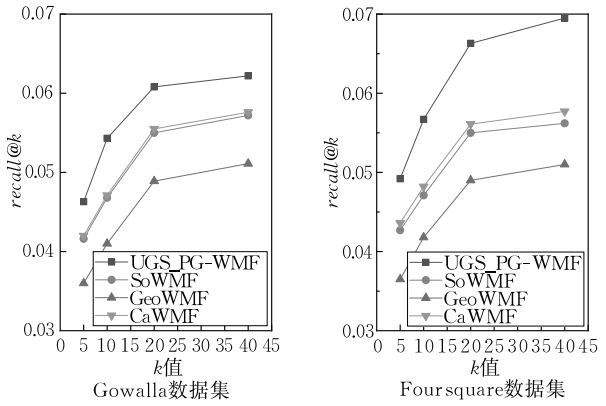

图 5　不同因素对 top-k 推荐召回率的影响

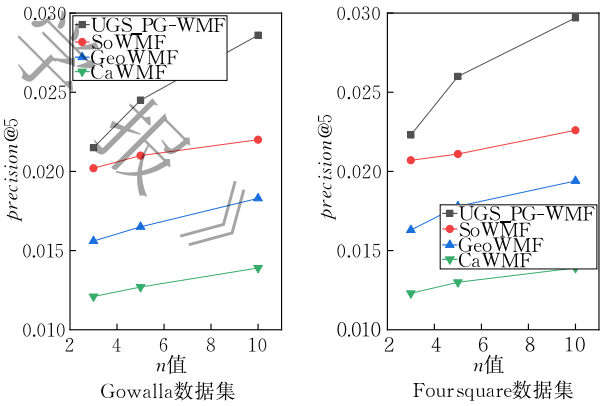

图 6　不同因素对冷启动问题(given-n)准确率的影响

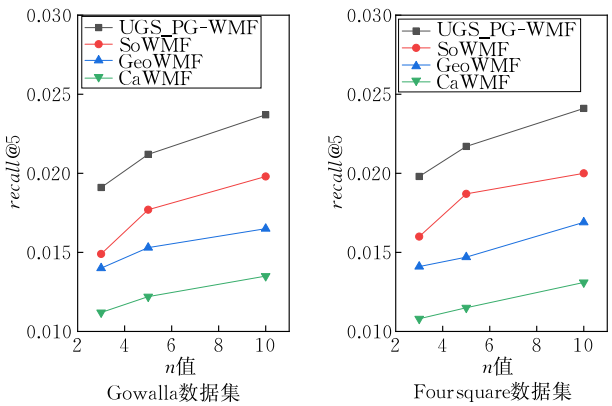

图 7　不同因素对冷启动问题(given-n)召回率的影响

偏好.本文社会关系模型始终优于地理关系模型,再次说明了本文对社会关系改进的有效性.

进一步地,本文探究参数对 UGS_PG-WMF 模型的性能影响,模型中涉及的参数包括核函数宽度 b,敏感参数 γ 以及权重 α.图 8 和图 9 所示的是 b 对 UGS_PG-WMF 性能的影响,随着 b 的增大,在 Gowalla 和 Foursquare 数据集上模型性能均逐步提高,但分别在 $b=45$ 和 $b=30$ 时,模型性能的增长率开始大幅度降低,说明过大的 b 值对模型性能的提升作用并不明显,这是因为 b 值决定参与计算的用户数据量,用户的邻居用户数量随着 b 值增大而增加,但此时距离该用户活动区域(*Niche*)较远的用户数量也在增加,他们在社会关系对用户签到偏好方面的影响并不大,反而因为计算量的增加,造成了模型推荐 POI 的过程中的消耗代价的增加.图 10 和图 11 表明了 γ 对 UGS_PG-WMF 的性能的影响,$\gamma=0$ 时,自适应带宽的核密度估计方法退化为固定带宽的核密度估计方法,当 γ 的取值在[0,0.4)区间内,模型的推荐效果并不好,是因为 POI 地理相关性(式(10))对用户签到数据的敏感程度较低,不同用户的本地带宽与具体的数据关联性不大;而 γ 的取值在(0.5,1.0]区间内时,随着 γ 增大,推荐效果反而降低,是由于式(10)对用户签到数据高度敏感造而过拟合造成的;最终当 γ 的取值在[0.4,0.5]区间内,模型推荐效果较理想.图 12 和图 13 显示了权重参数 α 对 UGS_PG-WMF 的性能影响,明显地,在数据集 Gowalla 和 Foursquare 上,α 分别在 0.45 和 0.55 附近能够取得较好的推荐效果,而过大或过小的 α 会使得模型性能下降,原因在于文中的 WMF 不同于一般的 MF 的重要原因是为每一个零

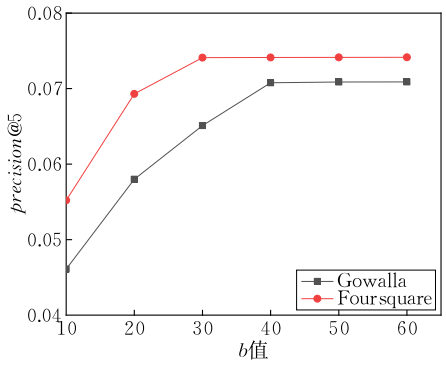

图 8 b 值对 UGS_PG-WMF 的准确率的影响

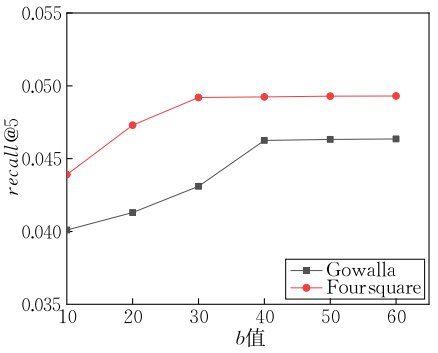

图 9 b 值对 UGS_PG-WMF 的召回率的影响

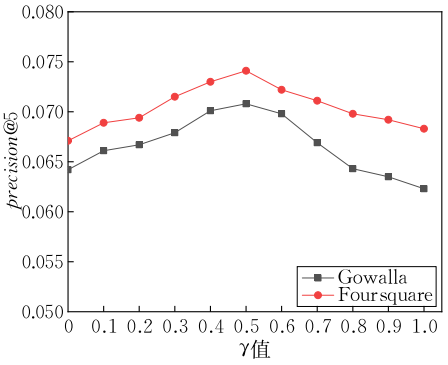

图 10 γ 值对 UGS_PG-WMF 的准确率的影响

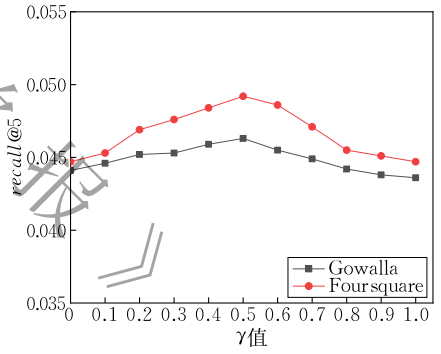

图 11 γ 值对 UGS_PG-WMF 的召回率的影响

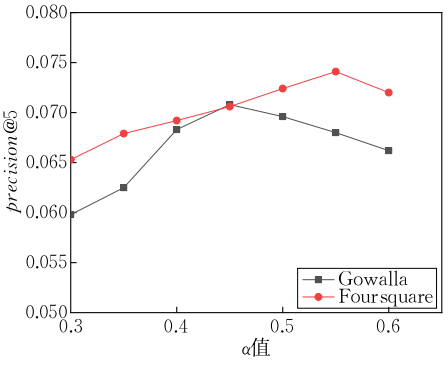

图 12 α 值对 UGS_PG-WMF 的准确率的影响

《计算机学报》

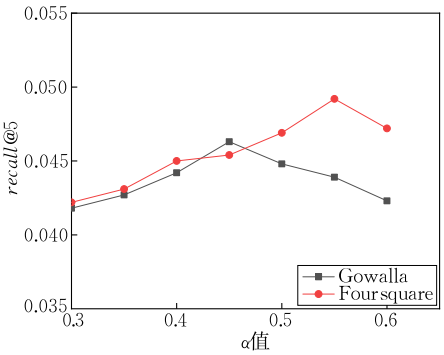

图 13　α 值对 UGS_PG-WMF 的召回率的影响

项分配一个非零权重，而非零项的权重根据 α 动态计算获得，如果 α 过小，则零项与非零项区别不大，影响非零项在计算过程中的作用，而如果 α 过大，则影响零项数据的作用.

上述实验证实了本文提出的模型的性能的优势，这主要归功于本文对于用户的社会关系、POI 的地理信息、POI 类别信息、文本信息、时间信息以及用户自身偏好的建模和融合的优势，但由于签到数据的稀疏性，致使 *precision* 和 *recall* 均不高. 最后，本文对模型在克服数据稀疏性方面进行了实验，我们设置 $k=5$，分别利用 20%、40%及 60%的数据作为训练集，在原有的数据基础上进一步调整了数据的稀疏性强度，结果如表 6 所示. 从表 6 中的数据可知，当数据稀疏性提高时，模型的推荐性能较表 3 中的结果有了明显的下降，这是可用的用户签到数据减少，用户的自身偏好建模效果不佳所导致的. 整体上，简单协同过滤方法 User-based CF 与 Item-based CF＜应用部分上下文信息建模的方法＜采用了更多上下文信息建模的推荐方法. 所以，当数据具有较高的稀疏性时，模型的性能优劣更多依赖于上下文信息的建模. 进一步地，当 20%数据作为训练集时，13 种推荐方法的性能表现均处于最差水平，且在应用部分上下文信息建模的方法中，USG-WMF 的推荐结果是最优的，较 ASMF 和 GeoSoCa 分别提高了 19%和 23%，而在采用了更多上下文信息建模的推荐方法中，UGS_PG- WMF 表现最佳，较 MTAS 和 DeePR 分别提高了 18%和 25%. 当采用 40%的数据训练时，结果是 USG-WMF 的性能较 ASMF 和 GeoSoCa 提高了 13%和 16%，UGS_PG-WMF 比 MTAS 和 DeepR 分别提高了 15%和 18%. 当训练数据达到 60%时，USG-WMF 比 ASMF 和 GeoSoCa 提高了 12%和 14%，UGS_PG-WMF 比 MTAS 和 DeepR 分别提高了 12%和 14%. 随着训练数据集的比例增大，USG-WMF 和 UGS_PG-WMF 的优势相对减小，说明了本文所提出的模型分别在 POI 地理信息、用户社会关系、POI 类别信息、文本内容以及时间信息的建模和融合上更具优势，能够更好地解决数据稀疏问题.

表 6　13 种方法在不同比例(%)数据集作为训练集情况下的推荐(top-5)性能对比

DataSet	%	Metrics	User-based CF	Item-based CF	Geo-MF	Geo SoCa	CoRe	ASMF	TSG-MF	Realtime-MF	MTAS	DeepR	USG-WMF	PG-WMF	UGS_PG-WMF
Gowalla	20%	*precision*@5	0.0102	0.0110	0.0142	0.0235	0.0226	0.0246	0.0275	0.0289	0.0303	0.0295	0.0301	0.0208	**0.0369**
		recall@5	0.0089	0.0095	0.0127	0.0198	0.0181	0.0220	0.0228	0.0251	0.0260	0.0256	0.0262	0.0174	**0.0307**
	40%	*precision*@5	0.0201	0.0206	0.0345	0.0363	0.0359	0.0376	0.0407	0.0415	0.0422	0.0416	0.0420	0.0362	**0.0499**
		recall@5	0.0172	0.0183	0.0289	0.0300	0.0295	0.0306	0.0326	0.0338	0.0354	0.0339	0.0341	0.0296	**0.0398**
	60%	*precision*@5	0.0339	0.0334	0.0518	0.0551	0.0545	0.0562	0.0573	0.0581	0.0595	0.0581	0.0587	0.0547	**0.0684**
		recall@5	0.0294	0.0291	0.0311	0.0325	0.0321	0.0330	0.0371	0.0390	0.0396	0.0390	0.0394	0.0330	**0.0438**
Foursquare	20%	*precision*@5	0.0113	0.0121	0.0158	0.0263	0.0249	0.0277	0.0287	0.0305	0.0315	0.0301	0.0308	0.0232	**0.0381**
		recall@5	0.0095	0.0106	0.0135	0.0212	0.0208	0.0231	0.0240	0.0262	0.0279	0.0263	0.0270	0.0186	**0.0320**
	40%	*precision*@5	0.0223	0.0227	0.0362	0.0378	0.0370	0.0389	0.0413	0.0422	0.0436	0.0429	0.0433	0.0400	**0.0526**
		recall@5	0.0194	0.0199	0.0296	0.0310	0.0302	0.0315	0.0337	0.0345	0.0369	0.0363	0.0366	0.0302	**0.0415**
	60%	*precision*@5	0.0343	0.0347	0.0522	0.0564	0.0557	0.0575	0.0587	0.0595	0.0616	0.0609	0.0615	0.0559	**0.0696**
		recall@5	0.0310	0.0315	0.0327	0.0343	0.0339	0.0352	0.0385	0.0403	0.0410	0.0405	0.0408	0.0346	**0.0460**

5　结束语

针对 LBSNs 中 POI 推荐过程中的用户偏好和上下文融合问题以及数据稀疏问题，本文提出了一种 UGS_PG-WMF 模型. 该模型改进了 WMF，在用户自身偏好建模时，融入了用户对 POI 类别的偏好，并针对用户签到过的 POI 与未签到过的 POI 采取了不同的上下文融合方法，且获得了优异的性能表现. UGS_PG-WMF 重构了用户的社会关系，增强了社会关系在用户偏好决策中的作用，并利用自适应带宽的核密度估计评估了用户活动轨迹中的 POI 个性化分布关系，并融合到改进的 WMF 中进行 POI 推荐，结果表明，该模型能有效克服签到数据的稀疏性和冷启动问题.

《计算机学报》

致 谢 审稿专家和编辑给出了宝贵意见,在此表示感谢!

参 考 文 献

[1] Cheng C, Yang H, King I, et al. Fused matrix factorization with geographical and social influence in location-based social networks//Proceedings of the 26th AAAI Conference on Artificial Intelligence. Toronto, Canada, 2012: 17-23

[2] Tobler W R. A computer movie simulating urban growth in the Detroit region. Economic Geography, 1970, 46(Sup1): 234-240

[3] Gao H, Tang J, Liu H. gSCorr: Modeling geo-social correlations for new check-ins on location-based social networks//Proceedings of the 21st ACM International Conference on Information and Knowledge Management. Maui, USA, 2012: 1582-1586

[4] Ye M, Yin P, Lee W C. Location recommendation for location-based social networks//Proceedings of the 18th SIGSPATIAL International Symposium on Advances in Geographic Information Systems. California, USA, 2010: 458-461

[5] Ying J J C, Lu E H C, Kuo W N, et al. Urban point-of-interest recommendation by mining user check-in behaviors//Proceedings of the 18th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. Beijing, China, 2012: 63-70

[6] Zhang J D, Chow C Y. GeoSoCa: Exploiting geographical, social and categorical correlations for point-of-interest recommendations//Proceedings of the 38th International ACM SIGIR Conference on Research and Development in Information Retrieval. Santiago, Chile, 2015: 443-452

[7] Li H, Ge Y, Zhu H. Point-of-interest recommendations: Learning potential check-ins from friends//Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Francisco, USA, 2016: 975-984

[8] Liu X, Liu Y, Aberer K, et al. Personalized point-of-interest recommendation by mining users' preference transition//Proceedings of the 22nd ACM International Conference on Information & Knowledge Management. San Francisco, USA, 2013: 733-738

[9] Zhang Z Y, Liu Y, Zhang Z J, et al. Fused matrix factorization with multi-tag, social and geographical influences for POI recommendation. World Wide Web, 2019, 22(3): 1135-1150

[10] Xing S N, Liu F A, Wang Q Q, et al. Content-aware point-of-interest recommendation based on convolutional neural network. Applied Intelligence, 2019, 49(3): 858-871

[11] Hao P Y, Cheang W H, Chiang J H. Real-time event embedding for POI recommendation. Neurocomputing, 2019, 349: 1-11

[12] Xiong X, Qiao S J, Li Y Y, et al. A point-of-interest suggestion algorithm in multi-source geo-social networks. Engineering Applications of Artificial Intelligence, 2020, 88: 1-11

[13] Li S L, Zhou J B, Xu T, et al. Competitive analysis for points of interest//Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. CA, USA, 2020: 1265-1274

[14] Zheng V W, Cao B, Zheng Y, et al. Collaborative filtering meets mobile recommendation: A user-centered approach//Proceedings of the 24th AAAI Conference on Artificial Intelligence. Atlanta, USA, 2010: 236-241

[15] Zheng Y, Zhang L, Ma Z, et al. Recommending friends and locations based on individual location history. ACM Transactions on the Web, 2011, 5(1): 5:1-5:44

[16] Zheng V W, Zheng Y, Xie X, et al. Towards mobile intelligence: Learning from GPS history data for collaborative recommendation. Artificial Intelligence, 2012, 184-185: 17-37

[17] Ye M, Yin P, Lee W C, et al. Exploiting geographical influence for collaborative point-of-interest recommendation//Proceedings of the 34th International ACMSIGIR Conference on Research and Development in Information Retrieval. Beijing, China, 2011: 325-334

[18] Zhang J D, Chow C Y. IGSLR: Personalized geo-social location recommendation: A kernel density estimation approach//Proceedings of the 21st ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems. Orlando, USA, 2013: 334-343

[19] Zhang J, Chow C. CoRe: Exploiting the personalized influence of two-dimensional geographic coordinates for location recommendations. Information Sciences, 2015, 293: 163-181

[20] Lian D, Zhao C, Xie X, et al. GeoMF: Joint geographical modeling and matrix factorization for point-of-interest recommendation//Proceedings of the 20th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York, USA, 2014: 831-840

[21] Li X, Cong G, Li X L, et al. Rank-GeoFM: A ranking based geographical factorization method for point of interest recommendation//Proceedings of the 38th International ACMSIGIR Conference on Research and Development in Information Retrieval. Shanghai, China, 2015: 433-442

[22] Liu Y, Wei W, Sun A, et al. Exploiting geographical neighborhood characteristics for location recommendation//Proceedings of the 23rd ACM International Conference on Information and Knowledge Management. Shanghai, China, 2014: 739-748

[23] Yang C, Bai L, Zhang C, et al. Bridging collaborative filtering and semi-supervised learning: A neural approach for POI recommendation//Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. Halifax, Canada, 2017: 1245-1254

[24] Gao Rong, Li Jing, Du Bo, et al. A synthetic recommendation model for point-of-interest on location-based social networks: Exploiting contextual information and review.

《计算机学报》

Journal of Computer Research and Development, 2016, 53(4): 752-763(in Chinese)
(高榕，李晶，杜博等. 一种融合情景和评论信息的位置社交网络兴趣点推荐模型. 计算机研究与发展，2016，53(4)：752-763)

[25] Ma H, King I, Lyu M R. Learning to recommend with social trust ensemble//Proceedings of the 32nd International ACMSIGIR Conference on Research and Development in Information Retrieval. Boston, USA, 2009: 203-210

[26] Ma H, Yang H, Lyu M R, et al. SoRec: Social recommendation using probabilistic matrix factorization//Proceedings of the 17th ACM Conference on Information and Knowledge Management. California, USA, 2008: 931-940

[27] Peng Hong-Wei, Jin Yuan-Yuan, Lv Xiao-Qiang, et al. Context-aware POI recommendation based on matrix factorization. Chinese Journal of Computers, 2019, 42(8): 1797-1811(in Chinese)
(彭宏伟，靳远远，吕晓强等. 一种基于矩阵分解的上下文感知 POI 推荐算法. 计算机学报，2019，42(8)：1797-1811)

[28] Noulas A, Scellato S, Lathia N, et al. A random walk around the city: New venue recommendation in location-based social networks//Proceedings of the 2012 International Conference on Privacy, Security, Risk and Trust (PASSAT), and 2012 International Conference on Social Computing (SocialCom). Amsterdam, The Netherlands, 2012: 144-153

[29] Tong H, Faloutsos C, Pan J Y. Fast random walk with restart and its applications//Proceedings of the 6th International Conference on Data Mining. Washington, USA, 2006: 613-622

[30] Ying J J C, Kuo W N, Tseng V S, et al. Mining user check-in behavior with a random walk for urban point of interest recommendations. ACM Transactions on Intelligent Systems and Technology, 2014, 5(3): 40:1-40:26

[31] Gao R, Li J, Li X F, et al. A personalized point-of-interest recommendation model via fusion of geo-social information. Neurocomputing, 2018, 273: 159-170

[32] Bao J, Yu Z, Mokbel M F. Location-based and preference-aware recommendation using sparse geo-social networking data//Proceedings of the 20th International Conference on Advances in Geographic Information Systems. New York, USA, 2012: 199-208

[33] Yin H, Sun Y, Cui B, et al. LCARS: A location-content-aware recommender system//Proceedings of the 19th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. Chicago, USA, 2013: 221-229

[34] Li Y, Nie J, Zhang Y, et al. Contextual recommendation based on text mining//Proceedings of the 23rd International Conference on Computational Linguistics: Posters. Beijing, China, 2010: 692-700

[35] Gao H, Tang J, Hu X, et al. Exploring temporal effects for location recommendation on location-based social networks//Proceedings of the 7th ACM Conference on Recommender Systems. Hong Kong, China, 2013: 93-100

[36] Yuan Q, Cong G, Ma Z, et al. Time-aware point-of-interest recommendation//Proceedings of the 36th International ACM SIGIR Conference on Research and Development in Information Retrieval. Dublin, Ireland, 2013: 363-372

[37] Gao L, Li Y H, Zhu Z L, et al. ST-RNet: A time-aware point-of-interest recommendation method based on neural network//Proceedings of the 2019 International Joint Conference on Neural Networks. Budapest, Hungary, 2019: 1-8

[38] Rubener Y, Tomasi C, Guibas L J. The earth mover's distance as metric for image retrieval. International Journal of Computer Vision, 2000, 40(2): 99-121

[39] Ference G, Ye M, 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. Burlingame, USA, 2013: 721-726

[40] Cho E, Myers S A, Leskovec J. Friendship and mobility: User movement in location based social networks//Proceedings of the 17th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Diego, USA, 2011: 1082-1090

[41] Mikolov T, Sutskever I, Chen K. Distributed representations of words and phrases and their compositionality//Proceedings of the 27th International Joint Conference on Neural Information Processing System(NIPS). Nevada, USA, 2013: 3111-3119

[42] Wang X R, McCallum A. Topics overt time: A non-Markov continuous time model of topical trends//Proceedings of the 12th ACMSIGKDD International Conference on Knowledge Discovery and Data Mining. Ljubljana, Slovenia, 2006: 424-433

[43] Ren Xing-Yi, Song Mei-Na, Song Jun-De. Context-aware point-of-interest recommendation in location-based social networks. Chinese Journal of Computers, 2017, 40(4): 824-841(in Chinese)
(任星怡，宋美娜，宋俊德. 基于位置社交网络的上下文感知的兴趣点推荐. 计算机学报，2017，40(4)：824-841)

[44] Hu Y, Koren Y, Volinsky C. Collaborative filtering for implicit feedback datasets//Proceedings of the 8th IEEE International Conference on Data Mining. Pisa, Italy, 2008: 263-272

[45] He X, Zhang H, Kan M Y, et al. Fast matrix factorization for online recommendation with implicit feedback//Proceedings of the 39th International ACM SIGIR Conference on Research and Development in Information Retrieval. Pisa, Italy, 2016: 549-558

[46] Herlocker J L, Konstan J A, Borchers A, et al. An algorithmic framework for performing collaborative filtering//Proceedings of the 22nd International ACM SIGIR Conference on Research and Development in Information Retrieval. Berkeley, USA, 1999: 230-237

[47] Sarwar B, Kapypis G, Konstan J, et al. Item-based collaborative filtering recommendation algorithms//Proceedings of the 10th International Conference on World Wide Web. Hong Kong, China, 2001: 285-295

《计算机学报》

AN Jing-Min, Ph. D. candidate. His major research interests include recommender system, ubiquitous computing, and knowledge engineering.

LI Guan-Yu, Ph. D., professor, Ph. D. supervisor. His major research interests include Internet of Things and knowledge engineering.

JIANG Wei, Ph. D. candidate. His major research interests include algorithm optimization and knowledge engineering.

SUN Yun-Hao, Ph. D. candidate. His major research interests include semantic web and knowledge engineering.

Background

With the maturity of mobile devices and wireless network technology, people are more used to sharing their real-time locations and point of interests (POIs) on social networks, which makes location-based social networks (LBSNs) has become a hot issue at present. The LBSN is an open platform, and people can find some POIs they may be interested in and also share some their own interests. The process includes user preferences and a lot of context information (social relationship, POI geographical information and POI category information, text information, and temporal information, etc). We are able to exploit the information to achieve user personalized POI recommendations.

Many researches have emerged for user personalized POI recommendations. However, these methods have not achieved the desired results influenced by high data sparsity. The reason is that user check-in data is limited, leading to the recommendation model can not better learn user preferences. Accordingly, how to model context information efficiently and reasonably and fuse these context models is the key to solve the problem. Therefore, this paper proposes a POI recommendation method based on the activity tracks and personalized-area partitions of users, whose main contribution points are as follows. (1) Modeling user's check-in preference according to user's historical records, social relationships, and POI geographical location information. (2) To simulate user preferences, we introduce POI category information into user-POI matrix to model user preferences and rewrite weighted matrix factorization (WMF) framework. (3) For modeling context information, considering the limitations of existing methods on employing friendships, we restructure the user social relationship model leveraging geographical, text, and temporal information. Through the distance distribution and similarity between users' personalized activity areas, we calculate the social relationships and further use the kernel density estimation with adaptive bandwidth to evaluate the geographical correlations between POIs in personalized activity areas. (4) To fuse context information and user preferences, we develop a two-step fusion strategy for POIs that users have visited and not visited. Experimental results show that our proposed model has the excellent performance.

The work in this paper is supported by the National Natural Science Foundation of China under grant No. 61976032.

《计算机学报》