

位置社交网络中基于评论文本的兴趣点推荐

王啸岩 袁景凌 秦 凤

(武汉理工大学计算机科学与技术学院 武汉 430070)

摘 要 随着位置社交网络(Location-Based Social Networks, LBSN)的快速发展,兴趣点(Point-Of-Interest, POI)推荐对于用户和商家愈发重要。目前基于社交网络的兴趣点推荐算法主要利用用户的历史签到数据和社交网络数据来提升推荐质量,但忽略了利用兴趣点的评论文本数据;并且 LBSN 中的数据经常会存在部分信息缺失的情况,对兴趣点推荐算法而言如何保证鲁棒性是一个巨大的挑战。为此,提出了一种新的用户兴趣点推荐模型,称其为 SoGeoCom 模型。该模型融合了用户社交网络数据、地理位置数据以及兴趣点的评论文本数据这 3 个因素来进行兴趣点推荐。基于来自 Yelp 的真实数据集的实验结果表明,与其他主流的兴趣点推荐算法相比,SoGeoCom 模型能够提高准确率和召回率,并且具有良好的鲁棒性,获得了更好的推荐效果。

关键词 用户兴趣点推荐,社交网络,评论文本,地理信息

中图分类号 TP311 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2017.12.044

Point-of-interest Recommendation Based on Comment Text in Location Social Network

WANG Xiao-yan YUAN Jing-ling QIN Feng

(College of Computer Science and Technology, Wuhan University of Technology, Wuhan 430070, China)

Abstract With the rapid development of the location-based social networks(LBSN), the point-of-interest(POI) recommendation is becoming more and more important to users and businesses. At present, the recommendation algorithm based on social network mainly uses the user's historical data and social network data to improve the quality of recommendation, but ignores the POI's comment text data. And the data in LBSN often have some missing information, how to guarantee robustness is a huge challenge for the point-of-interest recommendation algorithms. To this end, this paper proposed a new model of point-of-interest recommendation, called SoGeoCom model. The model combines the user's social network data, geographic location data and the POI's comment text data to carry on the POI recommendation. Experimental results based on real data set from Yelp show that, compared with other mainstream POI recommendation models, the SoGeoCom model can improve the precision and recall rate, have good robustness, and get a better recommendation effect.

Keywords User point-of-interest recommendation, Social networks, Comment text, Geographical information

1 引言

近年来,web2.0 技术得到了迅速发展,社交网络也随之繁荣,如微信、Facebook、Twitter 等应用已经在全球流行。据最近调查可知,社交网站的访问量已经占据了互联网总访问量的 25%,并且全球互联网用户中有近 2/3 的用户在使用社交网络服务^[1]。同时随着智能手机的发展,支持 GPS 功能并且能够提供位置服务 APP 的手机开始普及,在这种情况下,基于位置的社交网络(Location-Based Social Networks, LBSN)^[2-3]也随之蓬勃发展。

在 LBSN 中,用户可以访问现实世界中的地理位置,并通过 LBSN 提供的签到功能发布所在地理位置的评论、图片等信息,进而与其他用户交流和分享。用户在 LBSN 中的联系

不仅包含多个用户在同一地点签到,同时还包含了他们拥有相同的兴趣爱好、参与相同的活动等^[4]。因此,用户兴趣点推荐已经成为了一个很热门的研究方向。目前,大多数的兴趣点推荐算法都是根据用户在兴趣点的签到历史记录信息以及社交关系、时间、地点等情景信息来挖掘用户对兴趣点的偏好程度,但 LBSN 中的数据信息往往存在数据稀疏,甚至部分信息缺失的情况,如某些用户并没有添加好友,因此仅仅使用稀疏的签到历史记录数据以及情景数据来进行推荐会使最终的推荐结果有较大的偏差。

实际上,还可以通过分析用户对兴趣点的评论文本来研究用户的偏好,比如用户对某家电影院的评论文本为:“这是一家历史悠久的电影院,建筑物古香古色,环境优雅,还有免费 wifi”。从该条评论可以看出,此用户对这家电影院的态度

到稿日期:2016-11-30 返修日期:2017-01-15 本文受国家自然科学基金(61303029),科技部国家科技支撑计划基金项目(2012BAH89F01)资助。

王啸岩(1991-),男,硕士生,CCF 学生会会员,主要研究方向为推荐系统;袁景凌(1975-),女,博士,教授,博士生导师,主要研究方向为绿色计算、机器学习、数据挖掘;秦 凤(1993-),女,硕士生,主要研究方向为数据挖掘。

是正向的,并且对此电影院的偏好程度较高。本文综合考虑社交网络、地理位置与评论文本等多源异构信息,提出了 SoGeoCom 用户兴趣点推荐模型。

总体来说,本文对兴趣点推荐的贡献如下:

1) 本文综合考虑用户偏好、社交影响和地理影响,提出了 SoGeoCom 兴趣点推荐模型,并利用此融合模型集成多种因素来进行推荐。

2) 由于本文提出的兴趣点推荐模型融合了多源异构数据,因此在处理冷启动问题时有很好的效果;并且因为模型的模块化,在 LBSN 中的数据存在部分信息缺失的条件下也能获得较好的推荐结果,即模型具有良好的鲁棒性。

3) 本文在真实的位置社交网络数据集上进行实验,实验结果表明:与其他主流推荐算法相比,提出的 SoGeoCom 模型在准确率和召回率等指标上有明显的提升。

2 相关工作

兴趣点推荐是推荐系统领域中的一个重要任务,而相关的最新研究工作大多是围绕地理因素、社交关系、评论文本信息展开的。

1) 基于社交网络关系的兴趣点推荐。位置社交网络是社交网络的一个子集,由于社交网络发展迅速,使数据获取较容易,因此很多学者均把社交网络关系融入模型来提高推荐系统的质量。Zhang 等人^[5]将用户间的相似性无缝嵌入到基于用户的协同过滤技术中。Mao 等人^[6]利用用户社交网络中好友的协同评分以及通过距离衡量好友之间的相似性来进行兴趣点推荐。Jamali 等人^[7]提出了 SocialMF 模型,并且将信任传播机制融入其中,认为用户与好友、粉丝之间具有信任关系,进而通过矩阵分解的方式来恢复用户好友的矩阵。Caverlee 等人^[8]基于在线社交网络提出了 SocialTrust 信任模型,该模型通过信任关系和反馈信息生成推荐列表,推荐精度比较高。

2) 基于地理位置数据的兴趣点推荐。地理信息是位置社交网络对社交网络进行扩展的关键之处,Ahmed 等人^[9]通过提取用户在社交网络中发表的评论信息中所包含的地理数据来对地理位置进行层次结构的建模。

3) 基于评论文本的兴趣点推荐。用户对兴趣点的评论文本中蕴含着该用户的偏好,可以通过对评论文本进行挖掘来发现用户的兴趣。高明等人^[10]基于 LDA 主题模型来推断微博的主题分布和用户的兴趣取向,提出了一种微博系统上用户感兴趣的微博的实时推荐算法。

4) 基于地理位置数据以及社交关系的兴趣点推荐。目前大多数的兴趣点推荐算法都在研究如何利用这两种信息来进行高效的兴趣点推荐。Cheng 等人^[11]通过建立多中心高斯模型,把社交数据和地理数据融合到一个扩展的矩阵分解模型中。Zhao 等人^[12]利用移动用户位置敏感的特点来挖掘用户评分与兴趣点地理位置距离之间的相关性。Ference 等人^[13]改进了基于用户的协同过滤算法,融入了用户位置信息和社交网络信息,为移动端用户提供推荐服务。

以上兴趣点推荐算法基本都能生成令用户较为满意的推荐列表。但基于社交网络关系、地理位置信息、评论文本的兴趣点推荐算法都侧重于单一的数据信息,因此模型在冷启动问题以及鲁棒性上的表现不尽如人意。融合地理位置数据以

及社交关系数据的兴趣点推荐算法表现较优,但并没有涉及到用户评论文本,因此对于用户的偏好挖掘并不深入。而本文提出的 SoGeoCom 模型对上述各种信息进行了联合分析,同时考虑了用户的社交关系、签到的地理位置信息以及评论文本信息,相比现有的推荐模型,能更真实地反映现实场景。

3 SoGeoCom 模型

本文在考虑用户社交关系数据与兴趣点签到历史数据的基础上还考虑了评论文本信息,提出了一种新的兴趣点推荐模型——SoGeoCom(Social, Geographical and Comment)模型。

兴趣点推荐系统的目标是为用户推荐其感兴趣的地点,一个用户对某地点越感兴趣则访问该兴趣点的概率就会越大,因此如果能够计算出用户对地点的访问概率,并选择访问概率最大的 TopN 地点推荐给用户,即达成了兴趣点推荐系统的目标。在 SoGeoCom 模型中,决定用户访问兴趣点的因素有两方面:兴趣和距离。在兴趣方面,可以通过对用户的评论文本进行挖掘得到;在距离方面,其可分为心理距离和物理距离,心理距离是指用户在心理上对某一兴趣点的感兴趣程度,物理距离是指用户和兴趣点之间在地理上的距离。

图 1 给出了 SoGeoCom 模型基于多源信息的建模图。




图 1 SoGeoCom 模型基于多源信息的建模图

3.1 用户社交网络关系建模

社交网络关系是指用户间存在的好友关联关系。在社交网络中,根据人的群体趋同性,用户与自己好友的兴趣爱好一般较为相似。本文利用社交网络的这种特性在计算心理层面上用户与兴趣点之间的距离。

当计算用户 i 对兴趣点 j 的访问概率时,使用基于用户的协同过滤模型来预测用户对该兴趣点的评分,设计的公式如下:

$$p_p(i, j) = \frac{1}{r_{\max}} \left(\frac{\sum_{i' \in F_i} (r_{i'j} - \bar{r}_i) \text{sim}(i, i')}{\sum_{i' \in F_i} \text{sim}(i, i')} + \bar{r}_i \right) \quad (1)$$

其中, F_i 是用户 i 的所有好友构成的邻域集合; $r_{\max}$ 是最大评分值,其作用是对评分进行归一化; $\text{sim}(i, i')$ 指用户 i 和用户 i' 之间的相似度,实验中使用 cosine 来计算该相似度。

3.2 地理位置信息建模

根据地理学第一定律,结合实际场景,可以推测出用户往往存在以下两种行为:1) 倾向于前往距离自己住所以及办公地点比较近的兴趣点;2) 倾向于前往距离过去已访问过的兴趣点较近的其他兴趣点。

同一个用户的任意两个兴趣点之间的距离可用 power law 分布^[14]表示如下:

$$y = a \times x^b \quad (2)$$

其中, a 和 b 是 power law 幂率分布的参数,可以使用最小二乘法学习。 x 表示两个兴趣点间的距离,而 y 表示用户在兴

趣点签到的概率。

设 L 为一个兴趣点集合, 对于一个用户 u_i , $Pg[L_i]$ 表示该用户 i 访问 L 中所有兴趣点的概率, 并且该概率与地点之间的距离有关:

$$Pg[L_i] = \prod_{l_m, l_n \in L_i \wedge m \neq n} Pg[d(l_m, l_n)] \quad (3)$$

其中, $Pg[d(l_m, l_n)] = a * d(l_m, l_n)^b$ 是幂率分布, 并且 $d(l_m, l_n)$ 表示两个兴趣点 l_m 和 l_n 之间的距离。

因此, 根据用户 u_i 在兴趣点的历史签到记录 L_i , 对于任意一个候选兴趣点 l_j , 可以得到该用户 u_i 访问 l_j 的概率公式为:

$$Pg[l_j | L_i] = \prod_{l_y \in L_i} Pg[d(l_j, l_y)] \quad (4)$$

其中, $Pg[l_j | L_i]$ 代表对兴趣点 l_j 签到的同时对兴趣点集合 L_i 中所有兴趣点都签到的概率。

3.3 评论文本信息建模

隐狄利克雷分布 (Latent Dirichlet Allocation, LDA) 可以从文本中抽取主题以及表征主题词。在对兴趣点的评论文本进行建模时, 因为绝大多数的评论文本都比较短, 导致用户的兴趣比较稀疏, 所以本文把一个用户对所有兴趣点的评论文本聚集起来作为一个文档, 形成一个聚合的 LDA 模型, 并从此文档中挖掘用户的兴趣。

每一个用户对应了一个聚合文档 d , 主题 z 服从多维正态分布 θ , 且主题由一些词语 w 构成, 词语分布记作 ϕ , α 和 β 是超参。

通过 Aggregated LDA 过程能够得到每个用户的兴趣主题分布 θ_i 和每个主题 z 对应的词语集合, 由此可以得到兴趣点表现在用户感兴趣的主题上的分布 π_j 。

假设用户兴趣主题个数为 s (即主题维度为 s), 通过使用似然函数和吉布斯采样, 可以推导出主题词语的分布 ϕ 和用户的兴趣分布 θ :

$$\phi_w = \frac{n_i^{(w)} + \beta}{\sum_{v=1}^V n_i^{(v)} + V\beta} \quad (5)$$

$$\theta_z = \frac{n_i^{(z)} + \alpha}{\sum_{s=1}^K n_i^{(s)} + K\alpha} \quad (6)$$

其中, $n_i^{(w)}$ 表示主题包含的词语 w 的个数, $n_i^{(z)}$ 表示用户 i 的聚合文档中包含的主题个数, v 和 k 表示词语表长度和主题的个数。

兴趣点在对应兴趣上表现的分布为:

$$\pi_j = \frac{n_j^{(s)} + \alpha}{\sum_{i=1}^K n_j^{(i)} + K\alpha} \quad (7)$$

其中, $n_j^{(s)}$ 表示兴趣点 j 的所有点评文本构成的聚合文档中某个主题所包含词语的个数。

由此可以定义用户 i 对兴趣点 j 的兴趣概率为:

$$a(i, j) = \theta_i^T \pi_j \quad (8)$$

3.4 SoGeoCom 模型

本文在 3.1—3.3 节中分别对基于评论文本的用户对兴趣点的兴趣、基于社交网络关系的用户与兴趣点之间的心理距离以及基于地理位置数据的用户与兴趣点之间的物理距离进行了讨论。通过集合多源异构信息, 本文提出了一个联合模型 SoGeoCom 来进行评级预测。

SoGeoCom 模型认为用户对兴趣点的访问概率由用户对兴趣点的兴趣、用户与兴趣点之间的心理距离和物理距离这 3 个因素决定。兴趣越大, 访问概率越高; 距离越近, 访问概

率也相应越高。前文已将用户对兴趣点的兴趣、用户与兴趣点之间的心理距离以及用户与兴趣点之间的物理距离都转换成了概率的表示形式, 因此定义用户对兴趣点的最终访问概率如下:

$$p(i, j) = a(i, j)((1-\gamma)p_g(i, j) + \gamma p_p(i, j)) \quad (9)$$

其中, $a(i, j)$ 表示用户 i 对兴趣点 j 感兴趣的概率大小, 即用户对兴趣点的兴趣。 $p_g(i, j)$ 表示地理距离的影响概率。而 $p_p(i, j)$ 表示基于社交关系的心理距离的影响概率。 γ 用于调节用户与兴趣点之间的地理距离以及心理距离在概率计算中的比重大小。当 γ 等于 1 时, 只有心理距离起作用, 此时不需要对地理距离进行建模; 当 γ 等于 0 时, 只有地理距离起作用, 此时不需要对心理距离进行建模。由此可见, 该模型在遇到一些信息不可获得的情况下, 仍能够在一定程度内保持模型推荐的稳定性, 即具有良好的鲁棒性。

4 实验

4.1 实验数据集

本文实验使用的是 Yelp 数据集。Yelp 是美国最大的点评网站, 在该网站与其移动端的应用中, 用户可以在兴趣点签到, 为兴趣点评分并撰写评论文本, 还可以添加好友。

表 1 对 Yelp 数据集中用户、兴趣点、评论文本的数量以及矩阵密度进行了统计, 表 2—表 4 分别展示了 Yelp 数据集中社交关系数据、地理信息数据、评分与评论文本数据的具体格式信息。

表 1 Yelp 数据集统计

Event	Yelp
Users	43873
POIs	111537
Reviews	229907
User-POIs Matrix Density	$7.82 * 10^{-5}$
User-reviews Matrix Density	$4.334 * 10^{-3}$

表 2 社交关系数据格式

property	Yelp
User id	L0OrG-U45IWF6EZtm2dv8A
Friends	HZ3ltZ23xZHqjUjRIdPi7Q

表 3 地理信息数据格式

property	Yelp
Business id	vcNAWtLmIdR7D2nwwJ7nCA
Full Address	4840E Indian School Rd Ste 101
Latitude	33.499313
Longitude	-111.983758

表 4 评分与评论文本数据格式

property	Yelp
User id	jmt4JEcdtCO8_QGV5wFb3A
Business id	AryNioF9fx8RYGiIE7fSA
Review	Amazing food, every time, I've never left hungry or dissatisfied.
Stars	5

4.2 评价指标

本文使用准确率 Precision (P) 和召回率 Recall (R) 这两个广泛使用的评测指标来验证推荐的性能。

$$\text{准确率 } Precision@K = \frac{|S_{visited} \cap S_{K, rec}|}{K} \quad (10)$$

$$\text{召回率 } Recall@K = \frac{|S_{visited} \cap S_{K, rec}|}{S_{visited}} \quad (11)$$

其中, $S_{visited}$ 表示测试数据集中用户访问过的兴趣点集合。 $S_{K,rec}$ 表示前 K 个被推荐的兴趣点集合。*Precision* 和 *Recall* 是测试数据集上所有用户的平均值。

4.3 推荐模型对比

为了验证 SoGeoCom 模型的性能,选取了 3 个经典的模型进行对比。

PMF: 概率矩阵分解模型^[15], 该模型目前在推荐系统中应用得非常广泛, 主要以评分矩阵为输入, 并将其分解成用户-特征矩阵和兴趣点-特征矩阵, 同时通过梯度下降等学习方法学习出两个矩阵并最终预测原评分矩阵的缺失值。

NMF: 非负矩阵分解模型^[16], 该模型在概率矩阵分解的基础上假设用户特征矩阵和兴趣点特征矩阵中的元素是非负的, 比较符合特定场景的要求。

CoRe: 该模型基于鲁棒性规则融合了用户社交关系和地理因素, 其中地理因素是基于核密度估计进行建模^[17]。

按照 8:2 的比例随机将数据分为训练数据集和测试数据集。在 SoGeoCom 模型中, 设置 LDA 的参数 $K=40$, $\alpha=50/K$, $\beta=0.3$, 在调节心理距离和物理距离的影响比例时, 使用交叉验证设置 γ 为 0.35。

4 个模型在 *Precision* 指标和 *Recall* 指标上的效果对比图分别如图 2 和图 3 所示。




图 2 4 个模型在 *Precision* 指标上的效果对比图




图 3 4 个模型在 *Recall* 指标上的效果对比图

由图 2 和图 3 可知, PMF 和 NMF 模型在指标上的表现不佳, 这是因为它们仅采用了评分作为模型的输入, 所以对于解决数据稀疏性以及冷启动问题没有优势。CoRe 模型整合了用户社交关系和兴趣点地理因素, 并没有考虑相关类别信息和评论信息, 但其采用一个具有鲁棒性的规则而不是简单的线性加权来对用户的社交关系和地理因素进行融合, 同时对地理因素也进行基于核密度估计的建模, 因此它的推荐精度较好。由于 SoGeoCom 模型同样使用一个具有鲁棒性的规则融合了地理位置因素、社交关系以及评论文本数据, 能更加细致地描述用户兴趣, 同时解决数据稀疏性以及冷启动问题, 因此与其他 3 个对比算法相比, SoGeoCom 模型在准确率和召回率上均有更优的表现。随着推荐兴趣点个数 k 的增加, 4 个模型的准确率不断下降, 召回率不断上升, 这是由 *Precision* 和 *Recall* 的计算公式决定的。

4.4 模型鲁棒性讨论

LBSN 中的数据经常存在部分信息缺失的情况, 此时模


型在 *Precision* 和 *Recall* 上的表现就体现了模型的鲁棒性, 我们选择了 3 种 SoGeoCom 模型存在部分信息缺失的情况, 列举如下:

SoGeoCom-GeoCom: 在 SoGeoCom 模型中去除了地理位置信息和点评文本信息。

SoGeoCom-Com: 在 SoGeoCom 模型中去除了点评文本信息。


SoGeoCom-So: 在 SoGeoCom 模型中去除了社交网络信息。

SoGeoCom 在 *Precision* 和 *Recall* 上的鲁棒性对比图如图 4 和图 5 所示。



注: * 代表 SoGeoCom

图 4 SoGeoCom 在 *Precision* 上的鲁棒性对比图



注: * 代表 SoGeoCom

图 5 SoGeoCom 在 *Recall* 上的鲁棒性对比图

由图 4 和图 5 可知, 几种去除了部分信息的简化模型在指标 *Precision* 和 *Recall* 上的表现都不如 SoGeoCom 模型, 这是因为当 LBSN 存在部分信息缺失时不能较好地刻画用户的兴趣。同时还可以发现, 去除了部分信息的模型与 SoGeoCom 模型相比, *Precision* 和 *Recall* 的数值并没有大幅降低, 仍保持了不错的推荐性能, 说明 SoGeoCom 模型具有良好的鲁棒性。

SoGeoCom-So 模型的 *Precision* 和 *Recall* 数值与原始模型 SoGeoCom 很接近, 但其他两个简化模型指标的数值则有较大程度的降低, 这说明了用户的评论文本数据 (comment) 在模型中的贡献比较大, 而社交关系数据 (social) 的贡献比较小。

结束语 本文主要提出了一种全新的兴趣点推荐模型 SoGeoCom, 该模型融合了社交网络数据、地理位置数据以及兴趣点的评论文本数据这 3 个因素来进行用户兴趣点推荐。具体来说, 该模型认为决定用户访问兴趣点的因素有两个方面: 兴趣和距离。在兴趣方面, 可以通过对用户的评论文本进行挖掘得到; 在距离方面, 其可分为心理距离和物理距离, 心理距离可由社交网络关系建模得到, 物理距离可由地理位置信息建模得到。基于来自 Yelp 的真实数据集的实验结果证明, 本文提出的推荐算法是有效的。近年来深度神经网络已经被用于各种情景信息和文本内容的研究, 因此未来将深度学习融入兴趣点推荐模型是一个很有价值的研究方向。

(下转第 278 页)

- of Continuous Image Sequence With Image and Seam Selections [J]. IEEE Sensors Journal, 2015, 15(10): 5910-5918.
- [2] KUPER B, NETANYAHU N S, SHIMSHONI I. An Efficient SIFT Based Mode Seeking Algorithm for Sub-Pixel Registration of Remotely Sensed Images [J]. IEEE Geoscience & Remote Sensing Letters, 2015, 12(2): 379-383.
- [3] ZHANG D, YU C G. Image Mosaic Technology Based on Feature Point Match [J]. Computer Systems & Applications, 2016, 25(3): 107-112. (in Chinese)
张东, 余朝刚. 基于特征点的图像拼接方法 [J]. 计算机系统应用, 2016, 25(3): 107-112.
- [4] BROWN M, LOWE D G. Automatic Panoramic Image Stitching using Invariant Features [J]. International Journal of Computer Vision, 2007, 74(1): 59-73.
- [5] PAUL S, PATI U C. Remote Sensing Optical Image Registration Using Modified Uniform Robust SIFT [J]. IEEE Geoscience & Remote Sensing Letters, 2016, 13(9): 1300-1304.
- [6] CHIA W C, YEONG L S, CH'NG S I, et al. The effect of rain-fall on feature points extraction and image stitching [C] // 2014 International Conference on Information Science, Electronics and Electrical Engineering (ISEEE). IEEE, 2014: 1382-1386.
- [7] SHEN J, ZHAO Y, YAN S, et al. Exposure fusion using boosting Laplacian pyramid [J]. IEEE Transactions on Cybernetics, 2014, 44(9): 1579-1590.
- [8] QU Z, QIAO G Y, LIN S P. A Fast Image Stitching Algorithm Eliminates Seam line and Ghosting [J]. Computer Science, 2015, 42(3): 280-283. (in Chinese)
瞿中, 乔高元, 林嗣鹏. 一种消除图像拼接缝和鬼影的快速拼接算法 [J]. 计算机科学, 2015, 42(3): 280-283.
- [9] WAINE M, ROSSA C, SLOBODA R, et al. 3D shape visualization of curved needles in tissue from 2D ultrasound images using RANSAC [C] // IEEE International Conference on Robotics and Automation. IEEE, 2015: 4723-4728.
- [10] WANG T J, CHENG L Z. Image mosaic via improved Levenberg-Marquardt algorithm [J]. Journal of Computer Application, 2009, 29(10): 2693-2694. (in Chinese)
王腾蛟, 成礼智. 基于 Levenberg-Marquardt 改进算法的图像拼接 [J]. 计算机应用, 2009, 29(10): 2693-2694.
- [11] MO C K, CHEN S X, HAO W U, et al. A Robust Estimation Based 3D Passive Locating Algorithm [J]. Electronics Optics & Control, 2015, 22(2): 22-26.

(上接第 248 页)

参 考 文 献

- [1] BENEVENUTO F, RODRIGUES T, CHA M, et al. Characterizing user behavior in online social networks [C] // Proceedings of the 9th ACM SIGCOMM Conference on Internet Measurement Conference. ACM, 2009: 49-62.
- [2] SCELLATO S, NOULAS A, MASCOLO C. Exploiting place features in link prediction on location-based social networks [C] // ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. ACM, 2011: 1046-1054.
- [3] BAO J, ZHENG Y, WILKIE D, et al. Recommendations in location-based social networks: a survey [J]. GeoInformatica, 2015, 19(3): 525-565.
- [4] FERENC G, YE M, LEE W C. Location recommendation for out-of-town users in location-based social networks [C] // ACM International Conference on Conference on Information & Knowledge Management. 2013: 721-726.
- [5] ZHANG J D, CHOW C Y. CoRe: Exploiting the personalized influence of two-dimensional geographic coordinates for location recommendations [J]. Information Sciences, 2015, 293: 163-181.
- [6] YE M, YIN P, LEE W C. Location recommendation for location-based social networks [C] // Proceedings of the 18th SIGSPATIAL International Conference on Advances in Geographic Information Systems. ACM, 2010: 458-461.
- [7] JAMALI M, ESTER M. A matrix factorization technique with trust propagation for recommendation in social networks [C] // ACM Conference on Recommender Systems, Recsys 2010. Barcelona, Spain, 2010: 1055-1066.
- [8] CAVERLEE J, LIU L, WEBB S. The social trust framework for trusted social information management: architecture and algorithms [J]. Information Sciences An International Journal, 2010, 180(1): 95-112.
- [9] GHIOCA D. Hierarchical geographical modeling of user locations from social media posts [C] // International Conference on World Wide Web. 2013: 25-36.
- [10] GAO M, JIN C Q, QIAN W N, et al. Real-time and personalized recommendation on microblogging systems [J]. Chinese Journal of Computers, 2014, 37(4): 963-975. (in Chinese)
高明, 金澈清, 钱卫宁, 等. 面向微博系统的实时个性化推荐 [J]. 计算机学报, 2014, 37(4): 963-975.
- [11] CHENG C, YANG H, KING I, et al. Fused matrix factorization with geographical and social influence in location-based social networks [C] // Proc of the 26th AAAI Conf on Artificial Intelligence (AAAI'12). Menlo Park, CA: AAAI, 2012: 211-216.
- [12] ZHAO G, QIAN X, KANG C. Service Rating Prediction by Exploring Social Mobile Users' Geographic Locations [J]. IEEE Transactions on Big Data, 2017(99): 67-78.
- [13] FERENC G, YE M, LEE W C. Location recommendation for out-of-town users in location-based social networks [C] // Proceedings of the 22nd ACM International Conference on Information & Knowledge Management. ACM, 2013: 721-726.
- [14] DEL PRETE L, CAPRA L. differRS: A Mobile Recommender Service [C] // Eleventh International Conference on Mobile Data Management, MDM 2010. Kansas City, Missouri, USA, 2010: 21-26.
- [15] MNH A, SALAKHUTDINOV R. Probabilistic matrix factorization [C] // International Conference on Machine Learning. 2012: 880-887.
- [16] LEE D D, SEUNG H S. Learning the parts of objects by non-negative matrix factorization [J]. Nature, 1999, 401 (6755): 788-791.
- [17] YE M, YIN P, LEE W C, et al. Exploiting geographical influence for collaborative point-of-interest recommendation [C] // International ACM SIGIR Conference on Research and Development in Information Retrieval. ACM, 2011: 325-334.