



文章编号:1001-9081(2019)05-1261-08

DOI:10.11772/j.issn.1001-9081.2018102084

融合社交网络和图像内容的兴趣点推荐

邵长城*, 陈平华

(广东工业大学 计算机学院, 广州 510006)

(*通信作者电子邮箱 chengjuzhen@126.com)

摘要: 基于位置的社交网络(LBSN)蓬勃发展,带来了大量的兴趣点(POI)数据,加速了兴趣点推荐的研究。针对用户-兴趣点矩阵极端稀疏造成的推荐精度低和兴趣点特征缺失问题,通过融合兴趣点的标签、地理、社交、评分以及图像等信息,提出了一种融合社交网络和图像内容的兴趣点推荐方法(SVPOI)。首先分析兴趣点数据集,针对地理信息,利用幂律概率分布构造距离因子;针对标签信息,利用检索词频率构造标签因子;融合已有的历史评分数据,构造新的用户-兴趣点评分矩阵。其次利用VGG16深度卷积神经网络模型(DCNN)识别兴趣点图像内容,构造兴趣点图像内容矩阵。然后根据兴趣点数据的社交网络信息,构造用户社交矩阵。最后,利用概率矩阵分解(PMF)模型,融合用户-兴趣点评分矩阵、图像内容矩阵、用户社交矩阵,构成SVPOI兴趣点推荐模型,生成兴趣点推荐列表。大量的真实数据集上的实验结果表明,与PMF、SoRec、TrustMF、TrustSVD推荐算法相比,SVPOI推荐的准确度均有较大提升,其平均绝对误差(MAE)和均方根误差(RMSE)两项指标比最优的TrustMF算法分别降低了5.5%和7.82%,表明SVPOI具有更好的推荐效果。

关键词: 兴趣点推荐; 基于位置的社交网络; 图像内容; 深度卷积神经网络; 概率矩阵分解模型

中图分类号:TP18 文献标志码:A

Point-of-interest recommendation integrating social networks and image contents

SHAO Changcheng*, CHEN Pinghua

(School of Computers, Guangdong University of Technology, Guangzhou Guangdong 51000, China)

Abstract: The rapid growth of Location-Based Social Networks (LBSN) provides a vast amount of Point-of-Interest (POI) data, which facilitates the research of POI recommendation. To solve the low recommendation accuracy caused by the extreme sparseness of user-POI matrix and the lack of POI features, by integrating information such as tags, geography, socialization, score, and image information of POI, a POI recommendation method integrating social networks and image contents called SVPOI was proposed. Firstly, with the analysis of POI dataset, a distance factor was constructed based on power law distribution and a tag factor was constructed based on term frequency, and the existing historical score data was merged to construct a new user-POI matrix. Secondly, VGG16 Deep Convolutional Neural Network (DCNN) was used to process the images of POI to construct the POI image content matrix. Thirdly, the user social matrix was constructed according to the social network information of POI data. Finally, with the use of Probabilistic Matrix Factorization (PMF) model, the POI recommendation list was obtained with the integration of user-POI matrix, image content matrix and user social matrix. On real-world datasets, the accuracy of SVPOI is improved significantly compared to PMF, SoRec (Social Recommendation using probabilistic matrix factorization), TrustMF (Social Collaborative Filtering by Trust) and TrustSVD (Social Collaborative Filtering by Trust with SVD) while Mean Absolute Error (MAE) and Root-Mean-Square Error (RMSE) of SVPOI are decreased by 5.5% and 7.82% respectively compared to those of TrustMF which was the best of the comparison methods. The experimental results demonstrate the recommendation effectiveness of the proposed method.

Key words: point-of-interest recommendation; Location-Based Social Network (LBSN); image content; Deep Convolutional Neural Network (DCNN); Probabilistic Matrix Factorization (PMF) model

0 引言

随着移动互联网和基于位置的社交网络(Location-Based Social Network, LBSN)技术的发展,Yelp、Foursquare、Facebook Places等应用积累了大量的用户。用户通过对他们感兴趣的兴趣点(Point-of-Interest, POI)(例如商场、餐厅、艺术展览、酒

店等)进行在线评论和评分、上传图片、与朋友分享体验等方式留下了大量的兴趣点数据。与一般商品推荐一样,兴趣点推荐是推荐系统的一个重要研究课题,也是推荐系统研究的一个热点,但是,与一般商品推荐不同,兴趣点推荐具有更丰富的特征维度,蕴含了人类更多的主观意识和决策过程,体现了人类作为群居动物的独特属性。

收稿日期:2018-10-15;修回日期:2018-11-21;录用日期:2018-12-03。

基金项目:国家自然科学基金资助项目(61572144);广东省科技计划项目(2016B030306002, 2015B010110001, 2017B030307002)。

作者简介:邵长城(1992—),男,山东枣庄人,硕士研究生,CCF会员,主要研究方向:机器学习、大数据、推荐系统; 陈平华(1967—),男,湖南攸县人,教授,硕士,主要研究方向:机器学习、大数据、推荐系统。



从传统推荐系统角度来看,兴趣点可以看作是一个具有抽象意义的商品,其推荐过程可以使用经典的推荐算法,例如概率矩阵分解(Probabilistic Matrix Factorization, PMF)^[1]、SoRec(Social Recommendation using probabilistic matrix factorization)^[2]、TrustMF(Social Collaborative Filtering by Trust)^[3]、TrustSVD(Social Collaborative Filtering by Trust with SVD)^[4]等。其中,PMF利用用户对POI的历史评分数据;SoRec利用用户社交关系和兴趣点的历史评分数据;TrustMF、TrustSVD利用用户信任关系和POI的历史评分数据。

与传统商品推荐相比,兴趣点推荐有一定的特殊性,它不仅具有更加复杂的生活应用场景,同时由于涉及地理位置信息,兴趣点数据有其独特的数据特质,因此,简单地将传统商品推荐算法直接应用于兴趣点推荐可能带来兴趣点特征缺失问题。此外,由于用户访问的兴趣点通常局限于某一特定区域,因此,兴趣点推荐还将面临数据稀疏的问题。

兴趣点具有地理位置属性以及标签属性,兴趣点的诞生通常伴随着大量的图片信息,兴趣点用户拥有大量的社交网络信息。为解决兴趣点推荐过程中因为特征缺失和数据稀疏而导致的推荐准确率不高的问题,本文在应用地理信息和分类信息的基础上,运用深度学习技术抽取图片特征信息,丰富兴趣点特征,同时融合用户社交网络信息,形成了融合用户兴趣点评分矩阵、图像内容矩阵和用户社交矩阵的兴趣点推荐模型,并取得了预期的效果。

本文的研究工作主要贡献如下:

1)提出了一个基于概率矩阵分解的兴趣点推荐模型,称为SVPOI(Social and Visual content Point-of-Interest recommendation),融合兴趣点评分分数、地理、标签、社交信息与图像信息,并构建了融合评分信息矩阵、社交关系矩阵和图像内容矩阵的概率矩阵分解模型。

2)提出了一种新的用户评分信息构造方法,对用户评分信息进行了重新定义,根据地理位置信息和标签信息,构造了距离因子和标签因子,并结合用户评分分数,计算出新的用户评分信息矩阵。

3)利用兴趣点推荐中用户的社交网络信息,构造社交关系矩阵,并与新的用户评分信息矩阵进行有效融合。

4)利用深度卷积神经网络抽取图像特征信息,形成图像特征矩阵作为兴趣点的特征,并与新的用户评分信息矩阵和社交关系矩阵进行有效融合。

5)在一个真实的LBSN的大规模数据集上进行了实验,评估SVPOI性能,实验结果表明SVPOI优于其他推荐算法。

1 相关工作

1.1 兴趣点推荐

在个性化推荐系统中,其主要目标是根据用户对物品产生的历史信息,例如兴趣偏好、行为习惯、用户个人信息、物品信息等,来模拟用户决策过程,从而实现对用户的精准推荐。而兴趣点推荐系统也是一种个性化推荐系统,只不过是向用户推荐其感兴趣的兴趣点,兴趣点推荐被认为是推荐领域中的一个重要任务,也称为位置推荐^[5]。

随着个性化推荐的不断发展,诸多推荐模型不断涌现,协同过滤推荐算法成为工业界与学术界关注的焦点。其中,基于矩阵分解的协同过滤算法^[6](简称为矩阵分解推荐方法)在Netflix Prize比赛上脱颖而出,引起越来越多的科研工作者关注。该方法仅仅利用评分信息,将用户对物品的评分信息用矩阵的形式进行表示;然后将评分矩阵分解为低维的用户特征矩阵和物品特征矩阵,利用用户与物品的向量内积来表示用户对物品的喜爱程度,进而构建出基于矩阵分解的推荐方法。然而,由于评分矩阵的高稀疏和不均匀分布等特点,导致仅仅利用评分信息进行推荐带来的推荐性能低、冷启动等问题^[7]。

针对上述问题,研究人员通过引入社交信息^[8]在一定程度上取得了较好的推荐效果。Ma等^[2]首次引入社交信息,提出了在原有概率矩阵分解模型的基础上,增加用户社交关系矩阵,并将其分解为用户特征矩阵和社交特征矩阵;Yang等^[3]通过引入社交关系中的信任关系,首次构建了用户的信任模型与被信任模型,并对社交关系进行新的建模,在原有矩阵分解模型的基础上提出了社交推荐模型TrustMF;Guo等^[4]在改进版矩阵奇异值分解算法模型(Singular Value Decomposition enhancement, SVD++)^[9]的基础上,通过引入社交信息,提出基于信任模型的矩阵分解推荐方法,也获得了不错的推荐效果;文献[10]对基于矩阵分解的社交推荐模型进行了综述,讲述了融合社交信息的矩阵分解推荐方法的演变历程以及具体融合社交信息的方法。

可见基于矩阵分解的推荐模型可以灵活扩展,成为研究人员构造个性化推荐模型的重要模型,所以,对于兴趣点的推荐,依然可以沿用这一基础模型进行不断扩展。兴趣点不同于物品推荐,因为兴趣点不仅仅是地理上的点,更具有很多抽象的意义。用户对于兴趣点的选择,受到距离因素、社交因素、兴趣点自身特征因素等的影响,所以,兴趣点推荐任务比物品推荐更加复杂,需要更加丰富的特征维度来描述兴趣点特征。

兴趣点推荐也被称为地理位置推荐,在推荐系统中受到越来越多的关注。最近,关于POI推荐的许多研究通常从数据的4个方面进行着手,即地理影响分析、社会相关性分析、时间匹配分析以及文本内容分析^[11]。Lian等^[12]提出一种结合地理影响的加权矩阵分解方法;Ye等^[13]在LBSN中引入了POI推荐,并研究了POI推荐的地理影响和社会影响;Li等^[14]通过融合地理位置和社交信息,将用户好友分为社交好友以及地理位置好友,在进行POI推荐时,达到了对用户签到数据进行扩展的效果;Yuan等^[15]将时间周期信息和地理信息纳入时间感知进行POI推荐;Cheng等^[16]用矩阵分解方法介绍了在LBSN中连续个性化POI推荐的任务;Liu等^[17]用聚合的线性判别分析(Linear Discriminant Analysis, LDA)模型研究了POI相关标签的效果。因为用户的签到行为具有高稀疏性,为兴趣点推荐带来很大的挑战,所以越来越多的研究结合地理影响、时间效应、社会相关性、内容信息和流行度影响等因素提高兴趣点推荐的性能。另外,最新的兴趣点推荐开始应用多媒体数据^[18]:Jiang等^[19]利用旅游指南和社区提供的照片以及与这些照片相关的异构元数据(如标签、地理



位置和日期),提出一种个性化旅行序列兴趣点推荐;Wang 等^[20]通过单纯挖掘用户图谱信息和地点图片信息,提出了在概率矩阵分解模型基础上增加视觉内容兴趣点推荐模型,优化兴趣点推荐结果,该模型利用卷积神经网络(Convolutional Neural Network, CNN)对图片内容进行高维度抽取,并将该图片矩阵分别融合到用户隐含矩阵和兴趣点隐含矩阵,在 Instagram 数据集上进行实验,取得不错的实验结果。文中仅仅利用了评分和图像信息,并没有利用社交网络、物理地点等辅助信息,最后也提出了可以利用其他辅助信息的想法。本文重点在结合社交网络信息和图像信息,提出新的推荐模型。

1.2 图像内容挖掘

大家都听说过“眼见为实”这句话,这也暗含着图像对于用户决策的重要性,对于 LBSN 中的兴趣点推荐也是如此,好的图片总能吸引更多的用户,所以,在推荐系统中,图片也应该是数据挖掘的对象。最近,许多基于图像内容挖掘的推荐系统方法不断提出:McAuley 等^[21]提出了利用已有衣物穿搭图片进行衣服搭配的推荐方法;Wang 等^[22]根据图像内容进行情感的挖掘;Li 等^[23]利用 bag-of-words 图像内容模型来判断图片中的兴趣点。这些利用 POI 图片信息进行推荐的研究工作,充分说明了图片与 POI 有强关联关系,图片包含着 POI 的一些特征信息,影响着用户的决策过程。

2 社交网络和图像内容融合的兴趣点推荐

2.1 问题定义

本节定义数据结构,阐述研究的问题与展示算法模型框图。从 LBSN 的丰富信息中提取数据信息,包括 POI 上的用户历史评分数据,包括 POI 的地理信息、POI 上的标签信息、用户之间的社会关系、POI 上的图片信息。为了便于说明,表 1 列出本文的关键符号。

表 1 本文中的关键符号

Tab. 1 Key notations used in the proposed paper

符号	含义
$R_{ U \times V }$	用户-兴趣点偏好信息矩阵
$C_{ U \times U }$	用户好友社交关系矩阵
$G_{ V \times P }$	兴趣点-图像特征矩阵
S_U	LBSN 上用户集合
S_V	LBSN 上 POI 集合
S_P	POI 图片集合
R_{ij}^{score}	用户实际评分分数
Γ_1	距离因素
Γ_2	标签因素
$(l_j^{\text{lati}}, l_j^{\text{longi}})$	表示兴趣点 j 的经纬度坐标
$(l_i^{\text{lati}}, l_i^{\text{longi}})$	表示用户 i 的经纬度坐标
d_{ij}	用户 i 与兴趣点 j 之间的距离
$\text{CNN}(p_{je})$	兴趣点 j 对应的每张图片 p_{je}
$\text{CNN}(p_{jl})$	经过 CNN 处理后的图像特征向量
T_{v_j}	兴趣点 j 对应的抽象图像特征向量
T_{u_i}	兴趣点 j 对应的标签集合
T_u	用户 i 去过的所有兴趣点的标签多重集

为了便于说明, $S_U = \{u_1, u_2, \dots, u_m\}$ 为用户集合, m 表示用户数量; $S_V = \{v_1, v_2, \dots, v_n\}$ 为 POI 集合, n 表示 POI 数量; $S_Z = \{u_1, u_2, \dots, u_m\}$ 为用户对应好友集合, m 表示其数量;

$S_P = \{p_1, p_2, \dots, p_\omega\}$ 为兴趣点对应图片。

定义 1 偏好信息矩阵。给定一个 LBSN 上的 POI 的用户历史签到数据,构建一个兴趣点偏好信息矩阵 $R_{|U| \times |V|}$,矩阵中的每个元素 r_{ij} 代表用户 $u_i \in S_U$ 在位置 $v_j \in S_V$ 上的偏好信息, S_U 和 S_V 分别是 LBSN 上的用户和 POI 的集合。

在本文的算法模型中,将用户评分分数记为 R_{ij}^{score} ,而真正的用户-兴趣点偏好信息计算如式(1)所示:

$$R_{ij} = \Gamma_1 * \Gamma_2 * R_{ij}^{\text{score}} \quad (1)$$

其中: 定义距离因素为 Γ_1 , 标签因素为 Γ_2 。

定义 2 社交关系矩阵。给定一个 LBSN 上的用户之间的社交关系,构建一个社交关系矩阵 $C_{|U| \times |U|}$,如果两个不同的用户 $u_i, u_k \in S_U$ 之间存在社会关系,则 $c_{ik} = 1$; 否则 $c_{ik} = 0$ 。但是在社交网络中,仅仅依靠好友关系来定义社交关系包含太多噪声,以及忽略了社交网络中的图结构信息^[1],类似于文献[24]提出的 Web 链接邻接图,在基于信任关系的社交网络中, c_{ik} 的值表现该用户在信任关系网络中的权重,例如,当用户 u_i 关注很多好友时,其 c_{ik} 值会相应下降,当用户 u_i 被很多用户关注时,其 c_{ik} 值会相应上升。所以,在本文算法模型中,用 c'_{ik} 来代替 c_{ik} ,重新构建社交关系矩阵 $C_{|U| \times |U|}$,计算如式(2)所示:

$$c'_{ik} = \sqrt{\frac{d^-(u_k)}{d^+(u_i) + d^-(u_k)}} \times c_{ik} \quad (2)$$

其中: $d^+(u_i)$ 表示节点 u_i 的出度, $d^-(u_k)$ 表示节点 u_k 的入度。

定义 3 距离因素。每一个兴趣点 $v_j \in S_V$ 是与一对地理经纬度坐标 $(l_j^{\text{lati}}, l_j^{\text{longi}})$ 相关的;一个用户 $u_i \in S_U$ 是与一对地理经纬度坐标 $(l_i^{\text{lati}}, l_i^{\text{longi}})$ 相关的。因为用户和 POI 之间的距离服从幂律分布(power law distribution)^[25],所以本文计算出用户与各 POI 之间的概率,构造出距离因素,如式(3)所示:

$$\Gamma_1 = a * d^b \quad (3)$$

其中: a, b 是参数, d 是 $u_i \in S_U$ 与 $v_j \in S_V$ 之间的距离,根据对应的坐标计算出距离。

定义 4 标签因素。每一个 POI $v_j \in S_V$ 对应多个标签,用集合 T_{v_j} 表示兴趣点 $v_j \in S_V$ 的标签集合;同时用户 $u_i \in S_U$ 所访问的每个 POI $v_j \in S_V$ 均有对应标签值,进而用其访问的 POI 标签来表示用户的喜好标签,所以用集合 T_{u_i} 表示用户 $u_i \in S_U$ 的标签多重集。那么,本文根据用户访问的 POI 标签来计算标签因素,定义 $\text{card}(T_{u_i})$ 表示用户所有喜好标签个数总和,定义 $\text{card}(T_{v_j} \cap T_{u_i})$ 表示兴趣点 v_j 的标签在集合 T_{u_i} 的个数。利用检索词频率(term frequency)构造出标签因素,如式(4)所示:

$$\Gamma_2 = \frac{\text{card}(T_{v_j} \cap T_{u_i})}{\text{card}(T_{u_i})} \quad (4)$$

定义 5 图像特征向量。给定一张图片 p ,利用 CNN 构建一个图像特征向量 $\text{CNN}(p)$;对于每个兴趣点 j 对应的图片 e , $\text{CNN}(p_{je})$ 表示对图片 p_{je} 抽取为图像特征向量。因为每个兴趣点对应多张图片,所以本文对兴趣点 $v_j \in S_V$ 的所有图像特征矩阵 $\text{CNN}(p_{je})$ 求平均值,构造图像特征矩阵向量 $\text{CNN}(p_j)$,表示每个 POI 对应的图像特征,如式(5)所示:

$$\text{CNN}(p_j) = \overline{\sum \text{CNN}(p_{je})} \quad (5)$$

定义 6 图像特征矩阵。给定一个 POI,本文根据定义 5 可



以得到其对应的图像特征向量 $\text{CNN}(p_j)$, 对于所有兴趣点 $v_j \in S_V$, 可以得到一个矩阵 $G_{|V| \times |P|}$, 表示所有 POI 的图像特征。

问题 兴趣点推荐。给定用户的历史评分信息、用户社交信息、兴趣点的地理位置标签等信息、兴趣点的图片, 构建用户-兴趣点偏好矩阵 $R_{|U| \times |V|}$, 构建用户社交矩阵 $C_{|U| \times |U|}$, 构建图像特征矩阵 $G_{|V| \times |P|}$, 输入到 SVPOI 模型, 生成兴趣点推荐列表。推荐框架如图 1 所示。

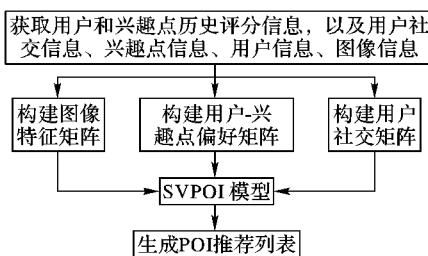


图 1 POI recommendation framework of SVPOI model

2.2 模型框架及推理

2.2.1 基本兴趣点推荐模型

在本文算法中, 利用概率矩阵分解(PMF)模型作为基模型进行扩展, PMF 模型是目前最受欢迎的协同过滤算法^[26]之一, 而且已经被广泛地改造成适用于兴趣点推荐^[20]。PMF 模型将真实观测量看作用户偏好值, 如式(6)所示:

$$R_{ij} = R_{ij}^{\text{score}} \quad (6)$$

假定用户偏好 R_{ij} 与预测评分 $U_i^T V_j$ 的差值符合均值为 0、方差为 σ_R^2 的高斯分布, 如式(7)所示:

$$p(R | U, V, \sigma_R) = \prod_{i=1}^m \prod_{j=1}^n [N(R_{ij} | g(U_i^T V_j), \sigma_R^2)]^{R_{ij}} \quad (7)$$

其中: $N(x | \mu, \sigma^2)$ 表示均值为 μ 、方差为 σ^2 的高斯分布, $g(x) = 1/(1 + e^{-x})$ 为 logistic 函数。同时, 假定用户和物品的特征矩阵 U, V 满足均值为 0, 方差分别为 σ_U^2 和 σ_V^2 的高斯分布, 同时假定用户特征矩阵 U 中各用户特征向量满足独立同分布, 物品特征矩阵 V 中各物品的特征向量也满足独立同

分布, 则有:

$$p(U | \sigma_U^2) = \prod_{i=1}^m N(U_i | 0, \sigma_U^2 I) \quad (8)$$

$$p(V | \sigma_V^2) = \prod_{j=1}^n N(V_j | 0, \sigma_V^2 I) \quad (9)$$

根据贝叶斯推理, 特征矩阵 U, V 的后验分布计算如式(10)所示:

$$\begin{aligned} p(U, V | R, \sigma_R^2, \sigma_U^2, \sigma_V^2) &\propto \\ p(R | U, V, \sigma_R^2) p(U | \sigma_U^2) p(V | \sigma_V^2) &= \\ \prod_{i=1}^m \prod_{j=1}^n N[(R_{ij} | g(U_i^T V_j), \sigma_R^2)]^{R_{ij}} \times \\ \prod_{i=1}^m N(U_i | 0, \sigma_U^2 I) \times \prod_{j=1}^n N(V_j | 0, \sigma_V^2 I) \end{aligned} \quad (10)$$

2.2.2 抽取图像内容

为了在 POI 推荐中建模图像内容, 需要从图像中提取有用的特征。在图像分类和识别中, 深度卷积神经网络(Deep Convolutional Neural Network, DCNN)是一种抽取高维度图像特征的方法, 因此, 本文算法利用 DCNN 来进行图像特征的抽取。由于 VGG16 模型拥有非常不错的图像识别效果^[27], 本文选择 VGG16 模型作为图像特征抽取模型, 如图 2 所示。VGG16 包含 13 个 convolution 层, 5 个 max pooling 层, 3 个 fully connected 层和 1 个 softmax 层。VGG16 输入是一个大小为 $224 \times 224 \times 3$ 的图片, 224×224 是图片的尺寸, 3 是图片的 RGB 通道数量。所以, 本文首先裁剪图片大小为 224×224 , 作为 VGG16 的输入。图中的每个方块表示图像特征维度, 例如, 在 convolution 层的最左边的图像特征维度为 $224 \times 224 \times 64$, 不同大小的方块表示不同的维度。最后的一层是 softmax 层, 用作图片分类。具体 VGG16 的介绍, 可以参看文献^[27]。本文算法模型去掉 VGG16 最后一层, 直接得到一个 1000 维度的向量, 用 $\text{CNN}(p_k)$ 来表示; 同时, 利用已经训练好参数的 VGG16 模型来直接抽取图像特征, 当得到 $\text{CNN}(p_k)$ 时, 可以结合这些特征进行 POI 推荐。

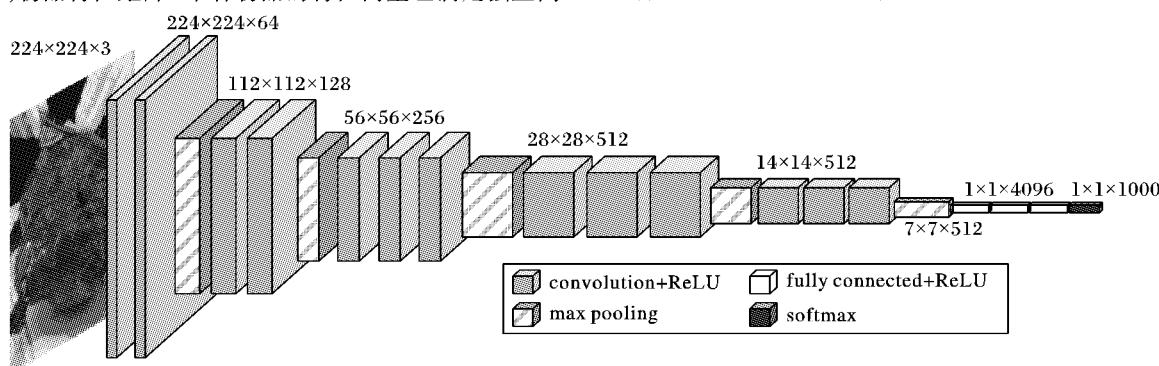


图 2 VGG16 模型架构
Fig. 2 Architecture of VGG16 model

首先, 依据定义 5 计算得到 $\text{CNN}(p_j)$, 类比式(7), 假定兴趣点图像特征 $\text{CNN}(p_j)$ 与预测兴趣点图像特征矩阵 $V_j^T P_i$ 的差值符合均值为 0、方差为 σ_G^2 的高斯分布, 即:

$$p(G | V, P, \sigma_G^2) = \prod_{j=1}^n \prod_{i=1}^w [N(G_{ji} | g(V_j^T P_i), \sigma_G^2)]^{G_{ji}} \quad (11)$$

对于物品特征矩阵 V 见式(9), 图片特征矩阵 P 如式(12)所示:

$$p(P | \sigma_P^2) = \prod_{i=1}^w N(P_i | 0, \sigma_P^2 I) \quad (12)$$

根据贝叶斯推理, 特征矩阵 V, P 的后验分布计算如式(13)所示:



$$\begin{aligned}
p(\mathbf{V}, \mathbf{P} | \mathbf{G}, \sigma_G^2, \sigma_V^2, \sigma_P^2) &\propto \\
p(\mathbf{G} | \mathbf{V}, \mathbf{P}, \sigma_G^2) p(\mathbf{V} | \sigma_V^2) p(\mathbf{P} | \sigma_P^2) &= \\
\prod_{j=1}^n \prod_{l=1}^w N[(\mathbf{G}_{jl} + g(\mathbf{V}_j^\top \mathbf{P}_l), \sigma_G^2)]^{I_{jl}^G} \times \\
\prod_{j=1}^n N(\mathbf{V}_j | 0, \sigma_V^2 \mathbf{I}) \times \prod_{l=1}^w N(\mathbf{P}_l | 0, \sigma_P^2 \mathbf{I}) & \quad (13)
\end{aligned}$$

2.2.3 社交关系矩阵

由定义2已给出,本文假定社交关系矩阵 \mathbf{C}_{ik} 与用户好友特征矩阵 $\mathbf{U}_i^\top \mathbf{Z}_k$ 的差值符合均值为0、方差为 σ_c^2 的高斯分布,即式(14)所示:

$$p(\mathbf{C} | \mathbf{U}, \mathbf{Z}, \sigma_c^2) = \prod_{i=1}^m \prod_{k=1}^m [N(\mathbf{C}_{ik} + g(\mathbf{U}_i^\top \mathbf{Z}_k), \sigma_c^2)]^{I_{ik}^C} \quad (14)$$

对于用户特征矩阵 \mathbf{U} 见计算式(8),好友特征矩阵 \mathbf{C} 如计算式(15)所示:

$$p(\mathbf{Z} | \sigma_z^2) = \prod_{k=1}^m N(\mathbf{Z}_k | 0, \sigma_z^2 \mathbf{I}) \quad (15)$$

根据贝叶斯推理,特征矩阵 \mathbf{U}, \mathbf{Z} 的后验分布计算如式(16)所示:

$$\begin{aligned}
p(\mathbf{U}, \mathbf{Z} | \mathbf{C}, \sigma_c^2, \sigma_u^2, \sigma_z^2) &\propto \\
p(\mathbf{C} | \mathbf{U}, \mathbf{Z}, \sigma_c^2) p(\mathbf{U} | \sigma_u^2) p(\mathbf{Z} | \sigma_z^2) &= \\
\prod_{i=1}^m \prod_{k=1}^m N[(\mathbf{C}_{ik} + g(\mathbf{U}_i^\top \mathbf{Z}_k), \sigma_c^2)]^{I_{ik}^C} \times \\
\prod_{i=1}^m N(\mathbf{U}_i | 0, \sigma_u^2 \mathbf{I}) \times \prod_{k=1}^m N(\mathbf{Z}_k | 0, \sigma_z^2 \mathbf{I}) & \quad (16)
\end{aligned}$$

2.2.4 SVPOI 模型

为模仿用户在决策过程中的兴趣点偏好行为,本文算法提出了一个基于概率矩阵分解的兴趣点推荐模型,并融合融合兴趣点评分分数、地理、标签、社交信息与图像信息。SVPOI 模型如图3所示,其中: $l = 1, 2, \dots, w$; $j = 1, 2, \dots, n$; $i = 1, 2, \dots, m$; $k = 1, 2, \dots, m$, 并且 $\sigma_u, \sigma_v, \sigma_z, \sigma_p, \sigma_R, \sigma_c$ 、 σ_G 分别表示高斯分布的先验。

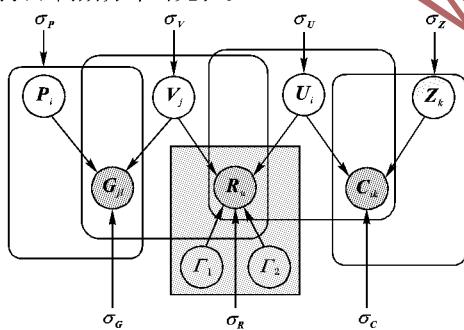


图3 SVPOI 模型框架

Fig. 3 Framework of SVPOI model

阴影圈表示输入数据,阴影框部分表示对原始输入数据进行距离因素和标签因素的限定。结合图3中的模型框架,以及式(10)、式(13)、式(16),可以得到后验概率计算如式(17)所示:

$$\begin{aligned}
p(\mathbf{U}, \mathbf{V}, \mathbf{Z}, \mathbf{P} | \mathbf{C}, \mathbf{G}, \mathbf{R}, \sigma_c^2, \sigma_R^2, \sigma_u^2, \sigma_v^2, \sigma_z^2, \sigma_p^2) &\propto \\
p(\mathbf{C} | \mathbf{U}, \mathbf{Z}, \sigma_c^2) p(\mathbf{G} | \mathbf{V}, \mathbf{P}, \sigma_G^2) p(\mathbf{R} | \mathbf{U}, \mathbf{V}, \sigma_R^2) & \\
p(\mathbf{U} | \sigma_u^2) p(\mathbf{V} | \sigma_v^2) p(\mathbf{Z} | \sigma_z^2) p(\mathbf{P} | \sigma_p^2) & \quad (17)
\end{aligned}$$

本文算法的 SVPOI 模型框架如式(18)所示:

$$\max_{\mathbf{U}, \mathbf{V}, \mathbf{Z}, \mathbf{P}} \ln p(\mathbf{U}, \mathbf{V}, \mathbf{Z}, \mathbf{P} | \mathbf{C}, \mathbf{G}, \mathbf{R}, \sigma_c^2, \sigma_R^2, \sigma_u^2, \sigma_v^2, \sigma_z^2, \sigma_p^2)$$

$$(18)$$

最大化后验概率,取对数可以得到式(19):

$$\begin{aligned}
l_{\text{svpoi}} &= \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^n I_{ij}^R (\mathbf{R}_{ij} - g(\mathbf{U}_i^\top \mathbf{V}_j))^2 + \\
&\frac{\lambda_c}{2} \sum_{i=1}^m \sum_{k=1}^m I_{ik}^C (\mathbf{C}_{ik} - g(\mathbf{U}_i^\top \mathbf{Z}_k))^2 + \\
&\frac{\lambda_G}{2} \sum_{j=1}^n \sum_{l=1}^w I_{jl}^G (\mathbf{G}_{jl} - g(\mathbf{V}_j^\top \mathbf{P}_l))^2 + \\
&\frac{\lambda_U}{2} \|\mathbf{U}\|_F^2 + \frac{\lambda_V}{2} \|\mathbf{V}\|_F^2 + \frac{\lambda_Z}{2} \|\mathbf{Z}\|_F^2 + \frac{\lambda_P}{2} \|\mathbf{P}\|_F^2
\end{aligned} \quad (19)$$

$$\text{其中: } \lambda_c = \frac{\sigma_R^2}{\sigma_c^2}, \lambda_U = \frac{\sigma_R^2}{\sigma_u^2}, \lambda_V = \frac{\sigma_R^2}{\sigma_v^2}, \lambda_Z = \frac{\sigma_R^2}{\sigma_z^2}, \lambda_P = \frac{\sigma_R^2}{\sigma_p^2}.$$

2.2.5 更新规则及算法过程

本文利用梯度下降来求解更新 $\mathbf{U}, \mathbf{V}, \mathbf{Z}, \mathbf{P}$, 如式(20)所示:

$$\left\{
\begin{aligned}
\frac{\partial l_{\text{svpoi}}}{\partial \mathbf{U}_i} &= \sum_{j=1}^n I_{ij}^R g'(\mathbf{U}_i^\top \mathbf{V}_j) (\mathbf{R}_{ij} - g(\mathbf{U}_i^\top \mathbf{V}_j)) \mathbf{V}_j + \\
&\lambda_c \sum_{k=1}^m I_{ik}^C g'(\mathbf{U}_i^\top \mathbf{Z}_k) (\mathbf{C}_{ik} - g(\mathbf{U}_i^\top \mathbf{Z}_k)) \mathbf{Z}_k + \lambda_U \mathbf{U}_i \\
\frac{\partial l_{\text{svpoi}}}{\partial \mathbf{V}_j} &= \sum_{i=1}^m I_{ij}^R g'(\mathbf{U}_i^\top \mathbf{V}_j) (\mathbf{R}_{ij} - g(\mathbf{U}_i^\top \mathbf{V}_j)) \mathbf{U}_i + \\
&\lambda_G \sum_{l=1}^w I_{jl}^G g'(\mathbf{V}_j^\top \mathbf{P}_l) (\mathbf{G}_{jl} - g(\mathbf{V}_j^\top \mathbf{P}_l)) \mathbf{P}_l + \lambda_V \mathbf{V}_j \\
\frac{\partial l_{\text{svpoi}}}{\partial \mathbf{Z}_k} &= \lambda_c \sum_{i=1}^m I_{ik}^C g'(\mathbf{U}_i^\top \mathbf{Z}_k) (\mathbf{C}_{ik} - g(\mathbf{U}_i^\top \mathbf{Z}_k)) \mathbf{U}_i + \lambda_Z \mathbf{Z}_k \\
\frac{\partial l_{\text{svpoi}}}{\partial \mathbf{P}_l} &= \lambda_G \sum_{j=1}^n I_{jl}^G g'(\mathbf{V}_j^\top \mathbf{P}_l) (\mathbf{G}_{jl} - g(\mathbf{V}_j^\top \mathbf{P}_l)) \mathbf{V}_j + \lambda_P \mathbf{P}_l
\end{aligned} \right. \quad (20)$$

其中: $g(x) = 1/(1 + e^{-x})$ 为 logistic 函数, $g'(x)$ 为 logistic 函数的导数。

算法1 SVPOI 模型的框架。

输入 $\mathbf{R}_{|\mathbf{U}| \times |\mathbf{V}|}, \mathbf{C}_{|\mathbf{U}| \times |\mathbf{U}|}, \mathbf{G}_{|\mathbf{V}| \times |\mathbf{P}|}$;
输出 每个用户的 top- k POI。

- 1) 初始化 $\mathbf{U}, \mathbf{V}, \mathbf{Z}, \mathbf{P}$
- 2) repeat
- 3) update \mathbf{U} as $\mathbf{U} \leftarrow \mathbf{U} + \eta \frac{\partial l}{\partial \mathbf{U}}$
- 4) update \mathbf{V} as $\mathbf{V} \leftarrow \mathbf{V} + \eta \frac{\partial l}{\partial \mathbf{V}}$
- 5) update \mathbf{Z} as $\mathbf{Z} \leftarrow \mathbf{Z} + \eta \frac{\partial l}{\partial \mathbf{Z}}$
- 6) update \mathbf{P} as $\mathbf{P} \leftarrow \mathbf{P} + \eta \frac{\partial l}{\partial \mathbf{P}}$
- 7) until 收敛
- 8) 返回 $\mathbf{U}^\top \mathbf{V}$ 计算的 top- k POI

3 实验

3.1 实验设置

3.1.1 数据集描述

Yelp 公开数据集来源于一个大规模的基于位置以及社交网络的点评网站。它允许用户对不同的签到点进行评分,上传图片,以及关注好友等。本文使用 Yelp 公开数据集 (<https://www.yelp.com/dataset>),如图4的地图所示,显示了在本文的实验中,签到时间跨度从 2004 年 10 月到 2017 年 7



月,所有美国和欧洲用户的签到记录以及某一个特定用户签到记录的热力图。

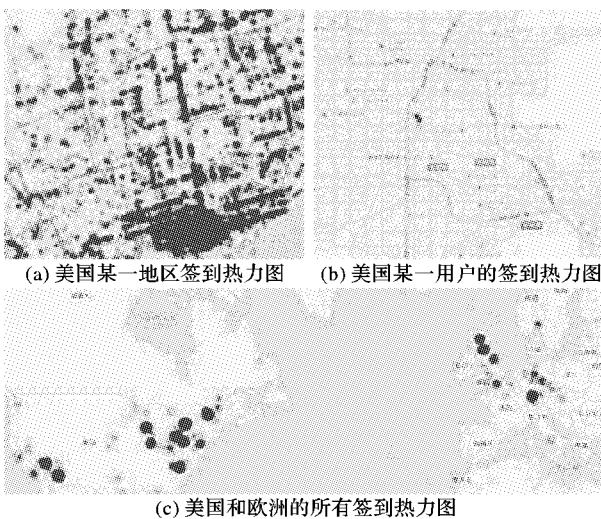


图4 Yelp数据集的签到地域热力图

Fig.4 Regional thermodynamic diagrams of sign-in records in Yelp dataset

对于每个用户,该数据集包含了用户的社交关系网络,签到POI的信息,包括签到的ID、地理位置信息(即经纬度坐标)、兴趣点的标签与分类信息、用户上传的关于兴趣点的图片等。为了过滤和清洗数据,本文过滤掉少于20次的签到用户,并筛选出每个POI至少被用户访问20次。此外,本文还

限制了每个用户应至少访问10个不同的POI。本文的实验中数据集信息如表2所示,本文方法是一个灵活、通用的算法,同样适用于Twitter、微博、豆瓣等数据集来进行实验评估。

3.1.2 评估方法

本文算法将用户签到行为的数据划分为训练集和测试集。随机选择20%的数据作为测试集,其余用户生成的签到数据作为训练集。在对比实验中,采用平均绝对误差(Mean Absolute Error, MAE)、均方根误差(Root-Mean-Square Error, RMSE)两项指标来衡量推荐准确度,即MAE、RMSE值越小,推荐越准确。

MAE 定义如式(21)所示:

$$MAE = \left[\sum_{i,j} |R_{i,j} - \hat{R}_{i,j}| \right] / N \quad (21)$$

RMSE 定义如式(22)所示:

$$RMSE = \sqrt{\left[\sum_{i,j} (R_{i,j} - \hat{R}_{i,j})^2 \right] / N} \quad (22)$$

3.2 实验结果

3.2.1 实验对比

在本节中,本文算法通过SVPOI算法模型与其他先进的推荐算法进行对比实验,对比的算法有:PMF、SoRec、TrustMF、TrustSVD。

图5表示特征维度分别为5、10,在训练集占比分别为20%、50%、80%、99%的情况下MAE和RMSE值。

表2 数据集统计
Tab. 2 Dataset statistics

数据集	用户数量	评分数量	社会关系数量	POI的数量	图片数量	分类数量	时间跨度
Yelp	416478	3056146	5819453	74932	180621	1240	2004-10—2017-07
Yelp小数据集	1000	5310	158	2244	69875	1240	2005-07—2017-07

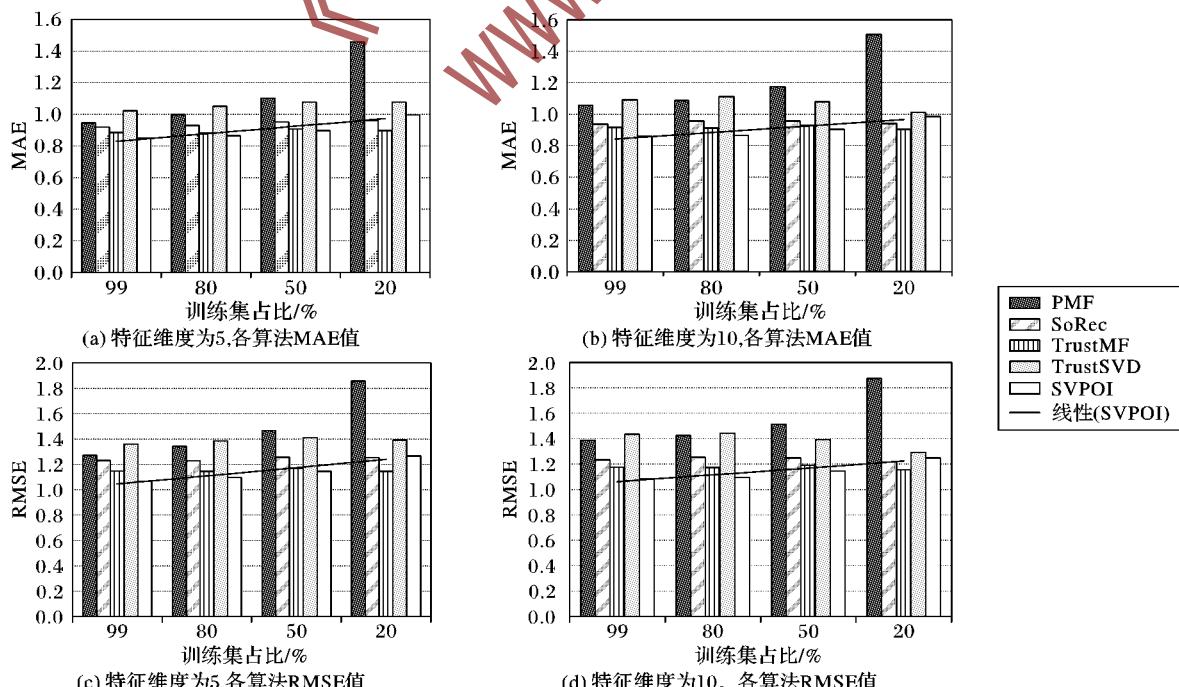


图5 大数据量下5种算法的MAE、RMSE比较

Fig. 5 MAE & RMSE comparison of five approaches under large dataset

从图5(a)、5(b)中可以看出,在特征维度分别为5、10

时,在80%的训练数据集的情况下,SVPOI的MAE值(MAE



$\text{@} 5 = 0.864$, $\text{MAE@10} = 0.866$)相对于其他四种算法中最优的 TrustMF ($\text{MAE@5} = 0.883$, $\text{MAE@10} = 0.909$) 分别提升 2.15%, 4.73% 的精度;从图 5(c), 5(d) 中可看出, 在特征维度分别取 5, 10, 在占比 80% 的训练集的情况下, SVPOI 的 RMSE 值 ($\text{RMSE@5} = 1.096$, $\text{RMSE@10} = 1.094$) 相对于其他算法中最优的 TrustMF ($\text{RMSE@5} = 1.144$, $\text{RMSE@10} = 1.174$) 分别提升 4.20%, 6.81% 的精度。同时, 从图中线性 (SVPOI) 折线还可以看到, 随着训练数据集的占比增大, 其准确率也会上升;整体来看, SVPOI 具有较高的推荐准确率, 比其他四种算法都好。

表 3 显示了在小量数据集上, 特征维度为 10, 80% 训练数据集下的 MAE 和 RMSE 的取值情况。从表中可以看出, 小数据量下, SVPOI 算法仍然具有最低的 MAE 值和 RMSE 值 ($\text{MAE@10} = 0.187$, $\text{RMSE@10} = 0.497$), 相比 TrustSVD ($\text{MAE@10} = 0.943$, $\text{RMSE@10} = 1.189$) 精度分别有 80.16% 和 58.2% 的提升。

表 3 小数据量下, 特征维度为 10 时各算法评测指标

Tab. 3 Metric comparison of different algorithms with feature dimension of 10 under small dataset

评测指标	PMF	SoRec	TrustMF	TrustSVD	SVPOI
MAE@10	2.525	1.358	0.971	0.943	0.187
RMSE@10	2.827	1.614	1.297	1.189	0.497

3.2.2 模型参数

所有算法模型的主要参数取值如表 4 所示。不同的参数会对算法的推荐效果产生影响, 本文进行了大量的实验, 尝试并选择了一些参数进行实验效果对比。

表 4 各算法模型主要参数取值

Tab. 4 Primary parameters of different algorithms

算法	λ_u	λ_v	λ_z	λ_p	λ_c	a	b
SVPOI	0.001	0.001	0.0005	0.0005	10	10	-1
PMF	0.010	0.010	—	—	—	—	—
SoRec	0.001	0.001	0.0100	—	10	—	—
TrustMF	0.001	0.001	1.0000	—	—	—	—
TrustSVD	0.010	0.010	0.0100	—	—	—	—

如表 5 所示, 记录了定义 3 中距离因素的两个参数中, 当 $b = -1$ 时, a 取不同值时的 MAE 和 RMSE 的变化。实验测试结果表明, 在 SVPOI 中, 当 $b = -1$, a 取值为 10 时, 会得到比较好的推荐效果。

表 5 式(3)中 a 取值对 SVPOI 的 MAE 和 RMSE 值的影响

Tab. 5 Impact of parameter a in formula(3) on MAE & RMSE values of SVPOI

指标	a 取值			
	1000	100	10	1
MAE@10	3.779	0.332	0.185	0.201
RMSE@10	9.800	0.824	0.491	0.549

在图像特征抽取过程中, 本文算法利用了 VGG16 深度卷积神经网络模型。VGG16 是一种卷积神经网络模型, 用于“大规模图像识别的深度卷积网络”^[27], 该模型在 ImageNet

(<http://www.image-net.org/>) 中达到 92.7% 的 top-5 测试精度, ImageNet 是属于 1000 个类的 1400 万个图像的数据集。本文算法利用 ImageNet 来训练 VGG16 模型的参数, 已达到良好的分类效果。

4 结语

本文提出了一个社交网络和图像内容融合的兴趣点推荐模型——SVPOI, 基于位置的社交网络中用户的签到行为, 有效地结合了用户评分信息、地理位置信息、标签分类信息、用户社交关系信息和兴趣点图像信息, 有效地解决了数据稀疏以及兴趣点特征缺失的问题。为了证明 SVPOI 模型的适用性, 本文在真实的大规模数据集上进行了大量的实验, 在推荐精度方面对 SVPOI 进行了评估, 结果表明 SVPOI 的推荐精度与其他推荐算法相比有明显提升。未来将进一步挖掘图像内容, 融合其他推荐模型作进一步的尝试, 从而提高兴趣点推荐的性能。

参考文献 (References)

- [1] SALAKHUTDINOV R, MNIH A. Probabilistic matrix factorization [C] // Proceedings of the 20th International Conference on Neural Information Processing Systems. New York: ACM, 2008: 1257 – 1264.
- [2] MA H, YANG H, LYU M R, et al. SoRec: social recommendation using probabilistic matrix factorization [C] // Proceedings of the 17th ACM Conference on Information and Knowledge Management. New York: ACM, 2008: 931 – 940.
- [3] YANG B, LEI Y, LIU J, et al. Social collaborative filtering by trust [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(8): 1633 – 1647.
- [4] GUO G, ZHANG J, YORKE-SMITH N. TrustSVD: Collaborative filtering with both the explicit and implicit influence of user trust and of item ratings [C] // Proceedings of the 29th AAAI Conference on Artificial Intelligence. Menlo Park, CA: AAAI Press, 2015: 123 – 125.
- [5] BAO J, ZHENG Y, WILKIE D, et al. Recommendations in location-based social networks: a survey [J]. GeoInformatica, 2015, 19(3): 525 – 565.
- [6] KOREN Y, BELL R, VOLINSKY C. Matrix factorization techniques for recommender systems [J]. Computer, 2009, 42(8): 30 – 37.
- [7] SHI Y, LARSON M, HANJALIC A. Collaborative filtering beyond the user-item matrix: a survey of the state of the art and future challenges [J]. ACM Computing Surveys, 2014, 47(1): Article No. 3.
- [8] MARSDEN P V, FRIEDKIN N E. Network studies of social influence [J]. Sociological Methods & Research, 1993, 22(1): 127 – 151.
- [9] KOREN Y. Factorization meets the neighborhood: a multifaceted collaborative filtering model [C] // Proceedings of the 14th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2008: 426 – 434.
- [10] 刘华锋, 景丽萍, 于剑. 融合社交信息的矩阵分解推荐方法研究综述 [J]. 软件学报, 2018, 29(2): 340 – 362. (LIU H F, JING L



- P, YU J. Survey of matrix factorization based recommendation methods by integrating social information[J]. Journal of Software, 2018, 29(2): 340 – 362.)
- [11] GAO H, LIU H. Mining human mobility in location-based social networks[J]. Synthesis Lectures on Data Mining and Knowledge Discovery, 2015, 7(2): 1 – 115.
- [12] 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. New York: ACM, 2014: 831 – 840.
- [13] YE M, YIN P, LEE W C. Location recommendation for location-based social networks[C]// Proceedings of the 18th SICSPATIAL International Conference on Advances in Geographic Information Systems. New York: ACM, 2010: 458 – 461.
- [14] 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. New York: ACM, 2016: 975 – 984.
- [15] 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. New York: ACM, 2013: 363 – 372.
- [16] CHENG C, YANG H, LYU M R, et al. Where you like to go next: successive point-of-interest recommendation[C]// Proceedings of the 23rd International Joint Conference on Artificial Intelligence. Menlo Park, CA: AAAI Press, 2013: 2605 – 2611.
- [17] LIU B, XIONG H. Point-of-interest recommendation in location based social networks with topic and location awareness[EB/OL]. [2018-06-20], https://binbenliu.github.io/papers/poi_sdml3.pdf.
- [18] 任星怡, 宋美娜, 宋俊德. 基于用户签到行为的兴趣点推荐[J]. 计算机学报, 2017, 40(1): 28 – 51. (REN X Y, SONG M N, SONG J D. Point-of-interest recommendation based on the user check-in behavior[J]. Chinese Journal of Computers, 2017, 40(1): 28 – 51.)
- [19] JIANG S, QIAN X, MEI T, et al. Personalized travel sequence recommendation on multi-source big social media[J]. IEEE Transactions on Big Data, 2016, 2(1): 43 – 56.
- [20] WANG S, WANG Y, TANG J, et al. What your images reveal: Exploiting visual contents for point-of-interest recommendation [C]// Proceedings of the 26th International Conference on World Wide Web. Geneva: International World Wide Web Conferences Steering Committee, 2017: 391 – 400.
- [21] McAULEY J, TARGETT C, SHI Q, et al. Image-based recommendations on styles and substitutes[C]// Proceedings of the 38th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2015: 43 – 52.
- [22] WANG Y, WANG S, TANG J, et al. Unsupervised sentiment analysis for social media images[EB/OL]. [2018-06-20]. <https://ijcai.org/Proceedings/15/Papers/336.pdf>.
- [23] LI X, PHAM T A N, CONG G, et al. Where you instagram?: Associating your instagram photos with points of interest[C]// Proceedings of the 24th ACM International Conference on Information and Knowledge Management. New York: ACM, 2015: 1231 – 1240.
- [24] ZHOU D, HOFMANN T, SCHLKOPF B. Semi-supervised learning on directed graphs[EB/OL]. [2018-06-20]. <http://papers.nips.cc/paper/2718-semi-supervised-learning-on-directed-graphs.pdf>.
- [25] LI H, HONG R, ZHU S, et al. Point-of-interest recommender systems: a separate-space perspective[C]// Proceedings of the 2015 IEEE International Conference on Data Mining. Piscataway, NJ: IEEE, 2015: 231 – 240.
- [26] WANG S, TANG J, WANG Y, et al. Exploring implicit hierarchical structures for recommender systems[C]// Proceedings of the 24th International Conference on Artificial Intelligence. Menlo Park, CA: AAAI Press, 2015: 1813 – 1819.
- [27] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J/OL]. arXiv Preprint, 2014, 2014: arXiv:1409.1556 (2014-09-04) [2015-04-10]. <https://arxiv.org/abs/1409.1556>.

This work is partially supported by the National Natural Science Foundation of China (61572144), the Science and Technology Planning Project of Guangdong Province (2016B030306002, 2015B010110001, 2017B030307002).

SHAO Changcheng, born in 1992, M. S. candidate. His research interests include machine learning, big data, recommendation system.

CHEN Pinghua, born in 1967, M. S., professor. His research interests include machine learning, big data, recommendation system.