

doi:10.11835/j.issn.1000-582X.2020.234

# 结合地点类别和社交网络的兴趣点推荐

唐浩然, 曾 骏, 李 烽, 文俊浩

(重庆大学 大数据与软件学院, 重庆 400044)

**摘要:**随着互联网和全球定位技术的高速发展,基于位置的社交网络(location-based social network)不断涌现,鼓励用户通过签到的形式发布个人动态并实时分享地理位置。海量的签到数据为挖掘用户偏好提供了机会,有利于提供基于位置的服务,如兴趣点(point of interest)推荐。兴趣点推荐旨在通过分析用户历史出行记录来得到用户的位置偏好,从而在未来为用户推荐新的地点,同时也能帮助广告商精准地投放用户感兴趣的广告。地点类别往往能够精准地提炼出位置的上下文语义,而现有的兴趣点研究大多都直接去计算用户对地点的偏好,没有有效地结合类别信息。通过对社交网站 Yelp 的公开数据集进行分析,发现相比访问共同的地点,朋友之间更容易访问相同的类别。因此,考虑朋友间地点类别偏好关系比直接考虑用户间项目偏好的关系更为合适。文中提出一种结合地点类别和社交网络的兴趣点推荐算法 CSRS,先从用户历史签到记录获取用户地点类别偏好,然后考虑朋友间的类别偏好差异性。在 Yelp 数据集上的实验结果表明,与其他算法相比,文中提出的算法在准确率和召回率指标上都取得了更好的结果。

**关键词:**基于位置的社交网络;兴趣点推荐;用户偏好;矩阵分解;地点类别

**中图分类号:**TP391

**文献标志码:**A

**文章编号:**1000-582X(2020)07-042-09

## Point of interest recommendation based on location category and social network

TANG Haoran, ZENG Jun, LI Feng, WEN Junhao

(School of Big Data & Software Engineering, Chongqing University, Chongqing 400044, P. R. China)

**Abstract:** With the rapid development of internet and global positioning technology, location-based social network (LBSN) is emerging in large numbers which encourages users to share their personal feelings and locations in real time by check-ins. Volumes of check-in data afford an opportunity for mining user preference, which promotes location-based services such as point of interest (POI) recommendation. POI recommendation can not only help users identify favorite locations, but also help POI owner acquire more target customers. A location's category is the accurate abstraction of the context semantics of location. Most of present research only directly considers user preference on a specific location and ignore consideration of location's category. In Yelp, we find the ratio of common visited location is lower than that of common visited location category, which means that considering user preference on location

**收稿日期:**2019-12-16

**基金项目:**国家自然科学基金资助项目(61502062, 61672117)。

Supported by National Natural Science Foundation of China (61502062, 61672117).

**作者简介:**唐浩然(1995—),男,硕士研究生,主要从事推荐系统、服务计算研究。

**通讯作者:**曾骏,男,副教授,主要从事移动大数据分析、移动用户轨迹挖掘等研究,(E-mail)zengjun@cqu.edu.cn。

category is more reasonable than that on specified locations. In light of the above, we present a novel POI recommendation method based on location category and social network named CSRS which infers users' preference on category from their check-ins history, and at the same time take the differences of category preferences among friends into consideration. The experimental results on Yelp demonstrate CSRS achieves superior precision and recall compared to other recommendation techniques.

**Keywords:** location-based social network; point of interest recommendation; user preference; matrix factorization; location category

随着互联网的高速发展以及全球定位技术的不断加强,移动终端设备逐渐成为人们日常生活中必不可少的事物,这极大地加速了基于位置的社交网站的崛起(LBSN, location-based social network),如 Twitter、Yelp、Foursquare 等。根据 Foursquare 官网的统计信息,每月使用 Foursquare 的用户超过 5 000 万,月位置签到数量超过 120 亿条,数字相当惊人,并且最高的时候能够在一天之内产生 900 万条签到记录,这充分说明基于位置的社交网络已经得到广泛的推广和使用<sup>[1-3]</sup>。

这些 LBSN 鼓励用户实时地向朋友分享自己的出行经历以及目前所处的位置,而这些具有一定语义的位置统称为兴趣点(POI, point-of-interest)(如中餐厅和电影院)。这种实时分享位置的移动服务可以让用户的朋友充分参与进来,增进朋友间的感情也丰富了如今的社交网络氛围<sup>[4]</sup>。通常情况下,一条典型的签到记录除了包含用户发布的文本信息外,还包括签到时间、签到地点的位置信息如经纬度坐标<sup>[5]</sup>。通过收集 LBSN 上的用户签到记录,可以对用户的个人偏好进行挖掘,从而向用户提供一系列符合其偏好和需求的位置服务,如兴趣点推荐(POI recommendation)。目前,各式各样的社交网站已经产生了大量的用户签到数据,值得去研究其中蕴藏的用户出行模式。这些含有语义和坐标的签到数据既可以帮助用户在新的区域中发现有趣的地方,也能够帮助第三方或商家吸引客流,因此具有很高的研究价值<sup>[6-14]</sup>。

上下文是兴趣点推荐中一个非常重要的研究内容。在真实的应用场景中,人们选择访问某个地点的决定受到诸多因素的制约,如天气、路况、场馆开放时间等。传统的推荐系统是依靠用户-项目二元关系来进行基于内容的推荐或协同推荐,适用于商品、电影等,但无法有效地处理兴趣点推荐特有的上下文如地理距离。因此,兴趣点推荐旨在通过分析和处理用户历史出行记录,结合多种上下文,考虑地理等有着直接决定作用的因素,来为用户推荐其满意的未知地点<sup>[5-6, 15-22]</sup>。

LBSN 通常会根据地点功能对地点定义类别,而一个地点可能对应多个类别<sup>[21-23]</sup>。类别可以反映用户对于地点的潜在偏好,如果用户的签到主要集中在某些类别上,那么可以着重处理这些类别来完成精准的推荐。LBSN 中包含大量的用户和地点,而一般情况下一个用户只访过少数地点,甚至有的用户只在两三个地点上有过签到行为,如果构建用户地点二维矩阵,那么该矩阵会显得非常的稀疏,以该矩阵直接进行推荐显得不太合适。因此,笔者将类别信息充分融入兴趣点推荐中,以此来提高推荐的精度。首先根据用户的历史签到记录,构建用户地点类别的签到矩阵,使用矩阵分解技术分别得到用户特征矩阵和地点类别特征矩阵,然后根据一个地点所属的类别去计算该地点的特征向量,再对社交网络中用户对地点类别的偏好差异性进行建模,最后由用户特征向量和地点特征向量做内积运算得到用户对目标地点的分值,将这些分值从高到低排序,取前  $K$  个地点为用户生成推荐列表。

文中第 2 章回顾了相关研究工作;第 3 章详细阐述了结合地点类别信息和社交网络的兴趣点推荐算法;第 4 章是算法的实验结果并对其原因进行解析;最后总结全文。为了方便起见,文中所说的位置和地点均代表兴趣点。

## 1 相关工作

传统的推荐系统是将地点看成简单的项目,然后运用协同过滤之类的方法进行推荐,这种忽略用户移动性以及上下文的处理方式往往使得推荐结果不尽人意。因此,目前许多研究关注于影响用户行为的多种因素,主要可以分为四大类。

### 1.1 基于地理位置的兴趣点推荐

用户通过实时的签到与地点进行交互,不同签到地点之间的距离往往反映用户签到在地理上的行为模式,通常可以采取幂率分布、高斯分布等来对不同地点间的距离进行刻画。Ye 等<sup>[5]</sup>对 Foursquare 和 Whrrl 的公开数据集进行处理后,发现用户在某个地点签到的概率与这个地点到当前位置的距离呈现幂率分布。Cheng 等<sup>[16]</sup>认为用户的签到往往是围绕某些区域中心的,因此提出了多中心高斯模型。相反地,Zhang 等<sup>[21]</sup>认为不同的用户对于地理因素具有不同的行为模式,不能统一使用幂率分布或高斯分布来模拟,而使用核密度模型则可以实现用户的个性化。

### 1.2 基于时间因素的兴趣点推荐

用户的签到通常呈现出一定的时间规律性,如满足周期性或连续性。Yuan 等<sup>[6]</sup>将一天分为 24 h,构建时间-用户-地点三维矩阵并利用时间之间的相似度去填充该三维矩阵,继而改进传统的协同过滤中存在的不足。Gao 等<sup>[10]</sup>同样将一天分为 24 h,为每个时间段分别构建用户-地点矩阵,然后进行矩阵分解求得不同时间段下的偏好。Cheng 等<sup>[7]</sup>和 Feng 等<sup>[8]</sup>认为短时间内的签到具有较强的关联性,可以利用马尔科夫链去模拟序列变化来推荐序列下一个地点。

### 1.3 基于社交网络的兴趣点推荐

随着近几年社交网络的崛起,越来越多的研究开始重视社交关系。Ye 等<sup>[15]</sup>早期就提出了在协同过滤中运用社交关系,因为朋友之间可能会去相同的地点。后来 Cheng<sup>[16]</sup>等提出朋友间很大程度上不会签到同一地点,也通过实验表明了无法有效地利用社交关系中的相同地点去提升推荐结果的精度。因此直接从朋友处获得地点推荐也就存在不合理<sup>[15]</sup>。在传统的推荐系统中推荐目标大多是电影、商品之类的比较单一、简单的线上项目,不具备实时移动的物理性质。

### 1.4 基于地点类别的兴趣点推荐

目前,很少有研究会考虑位置的所属类别,而恰恰类别会在某些真实场景下发挥重要作用。Bao 等<sup>[24]</sup>采用 HITS 算法为不同城市下的每个地点类别创建“本地专家”,当用户访问一个新城市时,通过对用户偏好进行建模并匹配相应的“本地专家”来寻找合适的推荐地点。Liu 等<sup>[23]</sup>计算出用户的位置偏好后基于 k-means 算法对用户进行聚类,接着对用户类别矩阵使用矩阵分解技术从而得到下一个可能访问的类别,同时结合以幂率分布表示的地理模型共同产生最终推荐结果。Zhao 等<sup>[25]</sup>将用户划分为不同群组并以地点类别签到向量去表示每个用户,接着根据不同群组之间在地理区域上的相似性采用协同过滤方法来完成推荐。Hu 等<sup>[26]</sup>认为用户对一个地点的评分与其近邻地点类别无关,因此应该过滤掉近邻类别的影响来完成目标地点的推荐。

上述相关工作均没有考虑社会化关系在推荐中的作用。因此,文章从该角度出发,对用户的地点类别偏好进行建模,同时结合社交关系来挖掘用户感兴趣的地点。

## 2 结合地点类别和社交网络的兴趣点推荐算法

### 2.1 问题定义

定义 1: 基于位置的社交网络。随着互联网和全球定位技术的高速发展,社交网络已经不再局限于传统的定点模式,而是在可移动终端的基础上实时地进行交互,不断将用户的地点数据实时地进行刷新,因此,这种以位置为主要载体的社交网络被称为基于位置的社交网络<sup>[5, 15-16, 18-22]</sup>。

定义 2: 签到。用户在一个地点上的签到记录通常用  $\langle u, l, t \rangle$  三元组来表示,其意思是某个用户  $u$  在  $t$  这个时间点访问了某个位置  $l$ 。用户的签到在很大程度上反映了用户对于某地点的行为模式。

定义 3: 兴趣点。兴趣点是根据地点的语义和功能而概括出的精炼表达,如餐厅、电影院、博物馆。兴趣点的相关信息通常包括名称、类别、经纬度等。文中所提及的地点都视为兴趣点。

定义 4: 兴趣点推荐<sup>[26-28]</sup>。在 LBSN 中,根据用户的历史签到记录,结合多种因素,为用户推荐符合其偏好的兴趣点,帮助人们发现新事物。兴趣点推荐可以分为普通兴趣点推荐和连续兴趣点推荐<sup>[7-8, 13-14, 29-30]</sup>,文中主要研究前者,即普通兴趣点的推荐。

文中使用  $U = \{u_1, u_2, u_3, \dots, u_{|U|}\}$  和  $L = \{l_1, l_2, l_3, \dots, l_{|L|}\}$  分别表示用户的集合和兴趣点的集合,

其中 $|U|$ 和 $|L|$ 分别代表各自的总数量。给定 $U$ 和 $L$ 构成的用户历史签到记录、社会化关系 $S$ 、地点类别 $C$ ,为某个用户 $i$ 推荐兴趣点的任务即可表示为

$$U \times L \times S \times C \rightarrow E_i, \quad (1)$$

式中, $E_i$ 是面向用户 $i$ 的推荐列表,以向量形式展示。计算出所有目标地点的分值后进行排序,将前 $K$ 个分值较高的兴趣点作为结果推荐给用户。

## 2.2 地点类别影响分析

LBSN 通常会预先定义地点的类别信息<sup>[23]</sup>,例如 Foursquare 中的地点类别是一个三级的分层框架,如图 1 所示。用户类别矩阵显然在稀疏性方面优于用户地点矩阵,而且类别很大程度上可以反映用户对于某种功能或语义的地点的喜好。根据历史签到数据计算出类别偏好差异,然后结合这些类别信息为用户推荐兴趣点,继而提升推荐的准确性。

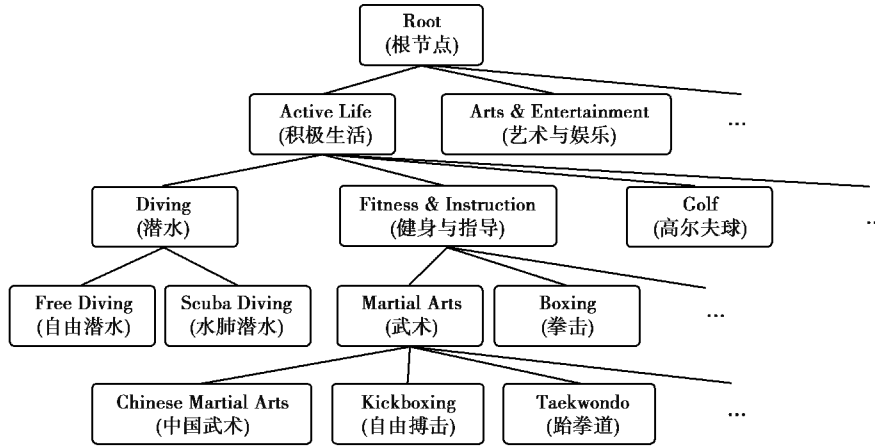


图 1 地点类别层次结构图

Fig. 1 Category hierarchy of locations

相比传统的推荐系统,文中提出的算法不是直接使用用户地点关系来进行推荐,因为这种方式会在矩阵的强稀疏性下导致推荐结果不佳。文中算法首先从原始数据集中提取出用户类别矩阵 $R$ ,采用 01 的形式,如果用户 $i$ 曾经访问过某个类别 $j$ ,那么 $R_{ij}$ 的值为 1,如果没有访问过则为 0, $R \in |U| \times |C_a|$ , $|C_a|$ 代表的是类别的总数量。矩阵分解技术被很多推荐系统算法所使用和推广,在此启发下,笔者也使用矩阵分解来对类别矩阵进行剖析,继而得到了用户的特征矩阵 $P \in f \times |U|$ 和类别的特征矩阵 $Q \in f \times |C_a|$ , $f$ 表示特征维度,可以根据经验来进行选取。分解过程中的损失为

$$\Gamma = \frac{1}{2} \sum_{i=1}^{|U|} \sum_{j=1}^{|C_a|} I_{ij} (R_{ij} - P_i^T Q_j)^2 + \frac{\lambda_1}{2} \|P_i\|_F^2 + \frac{\lambda_2}{2} \|Q_j\|_F^2, \quad (2)$$

式中, $I$ 是指示函数,它的作用是用来制约那些用户没有访问过的位置,使他们的权重为 0,而那些正例(即用户真正访问过的位置)则为 1。 $P_i$ 和 $Q_j$ 分别是由式(1)初始化的关于用户 $i$ 和类别 $j$ 的特征向量。正则化损失对于矩阵分解而言,可以有效地防止过拟合, $\lambda_1$ 和 $\lambda_2$ 是正则化项的权重, $\|\cdot\|_F$ 表示 Frobenius 范数。最后,通过经典的梯度下降算法不断地去迭代和更新用户和类别的特征向量。

通常情况下,一个位置不止有一个类别,因此它对应了多个类别的特征向量,对这些类别向量进行集成即可得到该地点的特征向量。首先,将地点和类别进行映射,得到地点和类别的表示矩阵 $M \in |L| \times |C_a|$ ,同样采用 01 的形式,如果一个地点属于某个类别,那么在矩阵中的对应元素即为 1。为 0 的时候恰好相反,代表地点与这个类别无关。接着,根据地点类别矩阵可得到地点的特征矩阵 $H$ 为

$$H = QM^T. \quad (3)$$

通过式(4)可以计算用户 $u$ 对未知地点 $l$ 的分值 Score,其中, $P_u$ 是根据公式(2)更新得到的用户 $u$ 的特征向量, $H_l$ 是由公式(3)得到的地点 $l$ 的特征向量。最后对所有分数进行排序,即可为用户推荐 Top-K 个兴趣点。

$$\text{Score}_{ul} = \mathbf{P}_u^T \mathbf{H}_l. \quad (4)$$

### 2.3 社会正则化研究

目前大多数有关兴趣点推荐的研究都是直接根据相似度来考虑朋友之间的社交关系。而文中已经阐明了朋友之间对于相同地点的偏好其实存在较大的差异<sup>[16]</sup>。因此,传统的推荐系统依靠朋友间的相似性或者直接从朋友处获取地点就变得非常不合适<sup>[5, 15, 31]</sup>。

地点类别是对地点功能和语义的提炼,能够反映用户的个人倾向。Yelp 数据集充分表明了用户间共同签到类别的比例远远超过共同签到地点。因此,从该角度出发,提出使用社会正则化对这种差异性建模<sup>[31]</sup>:

$$\frac{\lambda_3}{2} \sum_{i=1}^{|U|} \sum_{o \in F^+(i)} \text{Sim}(i, o) \|\mathbf{P}_i - \mathbf{P}_o\|_F^2, \quad (5)$$

式中: $\lambda_3$  是权衡社会正则化作用的权重参数; $F^+(i)$  为用户  $i$  在社交网络中主动关注的朋友列表; $\text{Sim}(i, o)$  计算用户  $i$  和用户  $o$  在位置类别上的偏好相似性。相似度的计算方式有很多种,较为传统的是余弦相似度,而文中采用的是杰卡德系数,为

$$\text{Sim}(i, o) = \frac{|C_i \cap C_o|}{|C_i \cup C_o|}. \quad (6)$$

式中, $C_i$  是用户  $i$  访问过的全体类别,式(4)主要反映的是 2 个用户在位置类别上的匹配程度。在目前的推荐系统研究进展中,社会正则化已经得到了很多研究者的认可和使用,它缓解了协同过滤的数据稀疏难题,对推荐的质量有一定的保障。

### 2.4 结合地点类别和社交网络的兴趣点推荐算法

基于 2.2 节和 2.3 节阐述的内容,提出了一种将地点类别和社交网络进行结合的兴趣点推荐算法 CSRS (category and social network based recommendation system),在图 2 中展示了其整体的框架。一方面用户类别矩阵相对于用户地点矩阵能够缓解稀疏性;另一方面,利用社会正则化对社交关系中类别偏好差异进行约束可以使得该算法更贴近现实。式(2)是梯度下降更新参数的损失,式(5)是引入社会化关系的损失,CSRS 算法的总损失(最终的目标函数)如式(7)所示,其中所有的参数在之前的小节中已经进行了阐述。

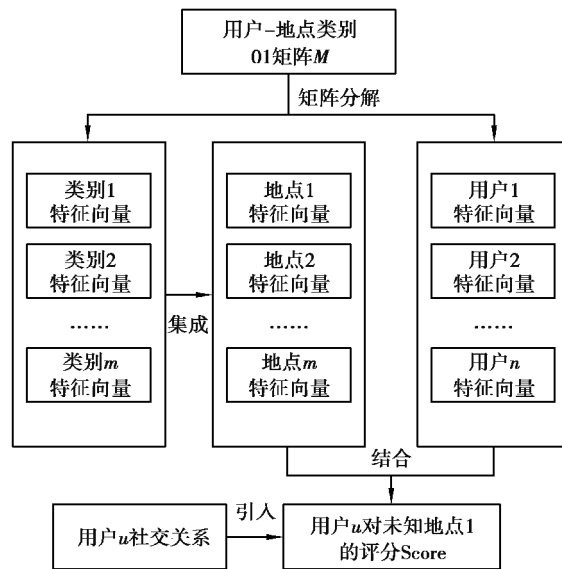


图 2 CSRS 算法流程图

Fig. 2 Flow chart of CSRS

同样对目标函数采用随机梯度下降法求解  $\mathbf{P}$  和  $\mathbf{Q}$ , 式(8)和式(9)为求导公式。其中, $F^-(i)$  为主动关注用户  $i$  的朋友集合。求得  $\mathbf{P}$  和  $\mathbf{Q}$  之后就可以结合式(3)和式(4)来计算用户  $u$  对未知地点  $l$  的最终分值,最后对所有地点的分值按从高到低进行排序,选取 Top-K 个兴趣点作为推荐结果。

$$\Gamma = \frac{1}{2} \sum_{i=1}^{|U|} \sum_{j=1}^{|C_a|} I_{ij} (\mathbf{R}_{ij} - \mathbf{P}_i^T \mathbf{Q}_j)^2 + \frac{\lambda_1}{2} \|\mathbf{P}_i\|_F^2 +$$

$$\frac{\lambda_2}{2} \|\mathbf{Q}_j\|_F^2 + \frac{\lambda_3}{2} \sum_{i=1}^{|U|} \sum_{o \in F^+(i)} \text{Sim}(i, o) \|\mathbf{P}_i - \mathbf{P}_o\|_F^2, \quad (7)$$

$$\frac{\partial \Gamma}{\partial \mathbf{P}_i} = \sum_{j=1}^{|C_a|} \mathbf{I}_{ij} (\mathbf{P}_i^T \mathbf{Q}_j - \mathbf{R}_{ij}) \mathbf{Q}_j + \lambda_1 \mathbf{P}_i + \lambda_3 \sum_{o \in F^+(i)} \text{Sim}(i, o) (\mathbf{P}_i - \mathbf{P}_o) + \lambda_3 \sum_{g \in F^-(i)} \text{Sim}(i, g) (\mathbf{P}_i - \mathbf{P}_g), \quad (8)$$

$$\frac{\partial \Gamma}{\partial \mathbf{Q}_j} = \sum_{i=1}^{|U|} \mathbf{I}_{ij} (\mathbf{P}_i^T \mathbf{Q}_j - \mathbf{R}_{ij}) \mathbf{P}_i + \lambda_1 \mathbf{Q}_j. \quad (9)$$

### 3 实验及结果

#### 3.1 数据集

Yelp 是一个面向大众、主流热门的在线社交应用。用户在 Yelp 应用里可以进行地点的签到并发表评论。Yelp 已经发布了很多开源数据集供研究者使用,因此,笔者选择 Yelp 的数据集来进行实验。该数据集包含用户的社交关系、签到评分、地点经纬度、签到时间等。由于原数据过于庞大,为了验证文中提出算法的有效性,在预处理数据时,首先选择社交关系最为广泛的用户,以该用户为起点,在整个数据集上进行深度遍历,就得到了研究所需要的用户集合,这些用户的签到记录即作为我们实验所使用的签到数据。最终的数据集包括 7 933 个用户,18 995 个地点,624 个类别。用于训练集的签到数量是 517 516,而用于测试集的签到数量是 171 396。

#### 3.2 评价指标

在推荐系统中,常用的评价指标有准确率( $P_{\text{Pre@K}}$ )和召回率( $R_{\text{Rec@K}}$ ),它们也是机器学习领域中最常见的指标。准确率是指为用户产生的推荐列表中,被正确推荐的地点所占的比例。而召回率是指在用户的测试集中,被正确推荐的地点所占的比例。这 2 种指标具体的计算公式为

$$P_{\text{Pre@K}} = \frac{1}{|U_{\text{test}}|} \sum_{u \in U_{\text{test}}} \frac{|L_u^{\text{rec}} \cap L_u^{\text{test}}|}{K}, \quad (10)$$

$$R_{\text{Rec@K}} = \frac{1}{|U_{\text{test}}|} \sum_{u \in U_{\text{test}}} \frac{|L_u^{\text{rec}} \cap L_u^{\text{test}}|}{|L_u^{\text{test}}|}, \quad (11)$$

式中, $U_{\text{test}}$  代表测试集用户集合。 $L_{\text{urec}}$  是算法为用户产生的推荐列表,而  $L_{\text{utest}}$  是用户  $u$  在测试集中的地点集合(即需要预测的真实地点)。实验中  $K$  值参照多数算法取 10、20、50。

#### 3.3 实验结果对比分析

文中所提出的算法充分结合了地点类别和社交关系,旨在改进传统经典的推荐模型,因此,研究选取的对比算法有下列几种:

1) UserCF 算法:热门且经典的基于用户的协同过滤算法,根据用户地点矩阵来计算用户之间的相似性从而完成对目标用户的推荐。

2) UC 算法:基于地点类别的推荐算法,没有考虑社会化关系,其核心公式可以根据文中关于地点类别分数的求解过程中得到。

3) Basic MF 算法:基于矩阵分解技术的推荐算法,通过分解原始的用户地点矩阵来对其进行填充以寻找潜在的未知地点。

文中提出的算法是以层层递进的方式结合类别与社交关系以求得用户的偏好,最后基于协同过滤进行推荐,所以不存在需要调整的参数。相似用户的个数根据绝大多数论文的经验而设置,由于目前基础的协同过滤已经相当成熟,因此该数值不是文中考察的重点。

图 3 与图 4 展示了准确率和召回率的实验结果,当推荐列表的长度分别为 10、20、50 时,文中提出的 CSRS 算法在 2 种评价指标下都优于其他的推荐算法,这充分说明考虑地点类别和社交关系有利于提升推荐效果。值得一提的是,UC 算法代表了 CSRS 算法的中间过程,即在地点类别影响下的推荐结果。但相比 Basic MF 算法和 UserCF 算法,其准确率和召回率仍具有明显优势,这也体现了地点类别的重要性。

然而,UC 算法没有结合社交关系,当推荐个数为 10 时,文中提出的结合类别与社交关系的 CSRS 算法

远超过 UC 算法。但随着推荐个数的增加,这种差距逐渐缩小,这表明社交关系的提升作用有限。无论是在准确率还是召回率方面,UserCF 的效果都是最差的,笔者分析这可能是由于数据稀疏造成的。直接构建用户地点矩阵会使得该矩阵相当稀疏,因此在计算用户相似度时存在明显缺陷,导致最终的推荐效果不佳。

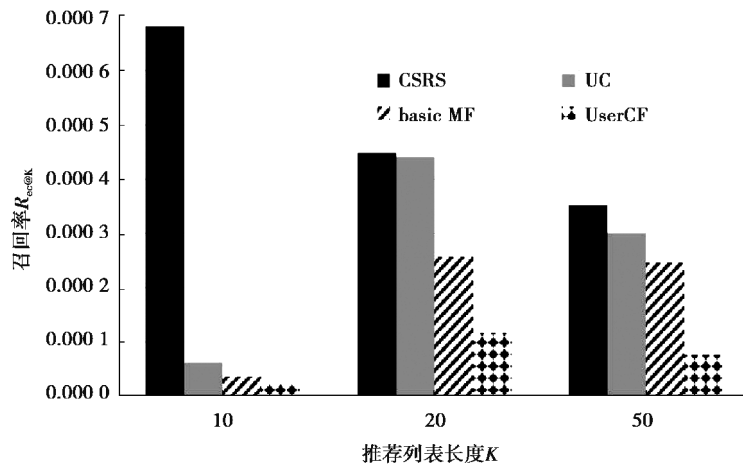


图 3 准确率对比

Fig. 3 Comparison of precision

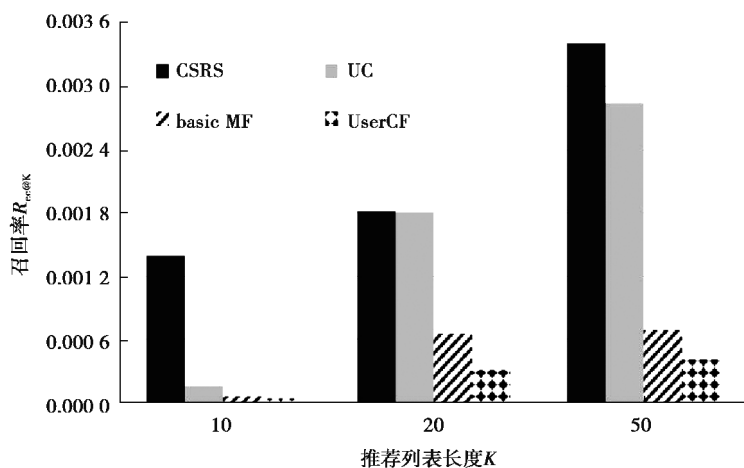


图 4 召回率对比

Fig. 4 Comparison of recall

## 4 结 论

兴趣点推荐是推荐系统中极为重要的一个子领域。文章首先总结了已有的关于兴趣点推荐的研究工作,然后提出了一种基于地点类别和社交关系的推荐算法 CSRS。地点类别与地点本身相比,不仅更能反映用户的倾向,而且在构建矩阵时也能有效地缓解稀疏性。同时,Yelp 数据集表明朋友之间访问相同类别的比例远高于访问相同地点。因此,CSRS 算法适合运用于兴趣点推荐的研究中。最后与目前主流经典的推荐算法进行了对比,其实验结果充分证明了 CSRS 算法的优势和有效性。

文中提出的推荐算法主要研究了地点类别和社交关系。在以后的工作中,笔者会将其他一些因素如流行度、时间规律等加入到算法中,以进一步提升推荐效果。

### 参考文献:

[1] 曹玖新,董羿,杨鹏伟,等. LBSN 中基于元路径的兴趣点推荐[J]. 计算机学报, 2016, 39(4): 675-684.

CAO Jiuxin, DONG Yi, YANG Pengwei, et al. POI recommendation based on meta-path in LBSN[J]. Chinese Journal of

- Computers, 2016, 39(4): 675-684.(in Chinese)
- [2] 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[J]. 计算机学报, 2017, 40(4): 824-841.  
REN Xingyi, SONG Meina, SONG Junde. Context-Aware point-of-interest recommendation in location-based social network[J]. Chinese Journal of Computers, 2017, 40(4): 824-841.(in Chinese)
- [3] 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 Xingyi, SONG Meina, SONG Junde. Point-of-interest recommendation based on the user check-in behavior[J]. Chinese Journal of Computers, 2017, 40(1): 28-51.(in Chinese)
- [4] 刘树栋, 孟祥武. 基于位置的社会化网络推荐系统[J]. 计算机学报, 2015, 38(2):322-336.  
LIU Shudong, MENG Xiangwu. Recommender system in location-based social networks [J]. Chinese Journal of Computers, 2015, 38(2): 322-336.(in Chinese)
- [5] Ye M, Yin P F, Lee W C, et al. Exploiting geographical influence for collaborative point-of-interest recommendation[C]// Proceedings of the 34th international ACM SIGIR conference on Research and development in Information Retrieval. Beijing, China, 2011: 325-334.
- [6] Yuan Q, Cong G, Ma Z Y, et al. Time-aware point-of-interest recommendation[C]//Proceedings of the 36th international ACM SIGIR conference on Research and development in information retrieval. Dublin, Ireland, 2013: 363-372.
- [7] Cheng C, Yang H, Lyu M R, et al. Where you like to go next: successive point-of-interest recommendation[C]// Proceedings of the Twenty-Third international joint conference on Artificial Intelligence. Beijing, China, 2013: 2605-2611.
- [8] Feng S S, Li X T, Zeng Y F, et al. Personalized ranking metric embedding for next new POI recommendation[C]// Proceedings of the 24th International Conference on Artificial Intelligence. Buenos Aires, Argentina, 2015:2069-2075.
- [9] Zhang J D, Chow C Y, Li Y H. LORE: exploiting sequential influence for location recommendations[C]// Proceedings of the 22nd ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems. Dallas, Texas, 2014:103-112.
- [10] Gao H J, Tang J L, Hu X, et al. Exploring temporal effects for location recommendation on location-based social networks[C]//Proceedings of the 7th ACM conference on Recommender systems. Hong Kong, China, 2013:93-100.
- [11] Griesner J B, Abdessalem T, Naacke T. POI recommendation: towards fused matrix factorization with geographical and temporal influences[C]// Proceedings of the 9th ACM Conference on Recommender Systems. Vienna, Austria, 2015: 301-304.
- [12] Liu Y C, Liu C R, Liu B, et al. Unified point-of-interest recommendation with temporal interval assessment[C]// Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Francisco, USA, 2016:1015-1024.
- [13] Zhao S L, Zhao T, Yang H Q, et al. STELLAR: spatial-temporal latent ranking for successive point-of-interest recommendation[C]//Proceedings of the 30th Conference on Artificial Intelligence. Phoenix, USA, 2016:1015-1024.
- [14] Zhang W, Wang J Y. Location and time aware social collaborative retrieval for new successive point-of-interest recommendation [C] // Proceedings of the 24th ACM International on Conference on Information and Knowledge Management. Melbourne, Australia, 2015: 1221-1230.
- [15] Ye M, Yin P F, Lee W C. Location recommendation for location-based social networks[C]// Proceedings of the 18th SIGSPATIAL International Conference on Advances in Geographic Information Systems. San Jose, USA, 2010: 458-461.
- [16] Cheng C, Yang H Q, King I, et al. Fused matrix factorization with geographical and social influence in location-based social networks[C]//Proceedings of the 26th Conference on Artificial Intelligence. Toronto, Canada, 2012: 17-23.
- [17] Hu B, Ester M. Spatial topic modeling in online social media for location recommendation. Proceedings of the 7th ACM conference on recommender systems. Hong Kong, China, 2013:25-32.
- [18] Gao H J, Tang J L, Hu X, et al. Content-aware point of interest recommendation on location-based social networks[C]// Proceedings of the 29th AAAI Conference on Artificial Intelligence. Astin, USA, 2015: 1721-1727.
- [19] Zhang F Z, Yuan N J, Zheng K, et al. Exploiting dining preference for restaurant recommendation[C]// Proceedings of the 25th International Conference on World Wide Web. Montréal, Canada, 2016:725-735.
- [20] Yin H Z, Wang W Q, Wang H, et al. Spatial-aware hierarchical collaborative deep learning for POI recommendation[J]. IEEE Transactions on Knowledge & Data Engineering, 2017, 29(11):2537-2551.
- [21] Zhang J D, Chow C Y. GeoSoCa: Exploiting geographical, social and categorical correlations for point-of-interest



- recommendations[C]// Proceedings of the 38th International ACM SIGIR Conference on Research and Development in Information Retrieval. Santiago, Chile, 2015: 443-452.
- [22] Lian D F, 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, USA, 2014:831-840.
- [23] Liu X, Liu Y, Aberer K, et al. Personalized point-of-interest recommendation by mining users' preference transition[C]// Proceedings of the 22nd ACM international conference on Information & Knowledge Management (CIKM '13). San Francisco, USA, 2013: 733-738.
- [24] Bao J, Zheng Y, Mokbel M F. Location-based and preference-aware recommendation using sparse geo-social networking data[C]// Proceedings of the 20th International Conference on Advances in Geographic Information Systems. Redondo Beach, USA, 2012: 199-208.
- [25] Zhao Y L, Nie L, Wang X, et al. Personalized recommendations of locally interesting venues to tourists via cross-region community matching[J]. *Acm Transactions on Intelligent Systems & Technology*, 2014, 5(3):1-26.
- [26] Hu L K, Sun A X, Liu Y. Your neighbors affect your ratings: on geographical neighborhood influence to rating prediction [C]// Proceedings of the 37th international ACM SIGIR conference on Research & development in information retrieval. Queensland, Australia, 2014: 345-354.
- [27] Liu B, Fu Y J, Yao Z J, et al. Learning geographical preferences for point-of-interest recommendation[C]// Proceedings of the 19th ACM SIGKDD international conference on Knowledge discovery and data mining, Chicago, USA, 2013: 1043-1051.
- [28] Yuan Q, Cong G, Sun A X. Graph-based point-of-interest recommendation with geographical and temporal influences[C]// Proceedings of the 23rd ACM International Conference on Conference on Information and Knowledge Management. Shanghai, China, 2014: 659-668.
- [29] He J, Li X, Liao L J, Song D D, et al. Inferring a personalized next point-of-interest recommendation model with latent behavior patterns[C]// Proceedings of the Thirtieth AAAI Conference on Artificial Intelligence. Phoenix, USA, 2016: 137-143.
- [30] He J, Li X, Liao L J. Category-aware next point-of-interest recommendation via listwise bayesian personalized ranking[C]// Proceedings of the Twenty-Sixth International Joint Conference on Artificial Intelligence. Melbourne, Australia, 2017: 1837-1843.
- [31] Ma H, Zhou D Y, Liu C, et al. Recommender systems with social regularization[C]// Proceedings of the fourth ACM international conference on Web search and data mining. Hong Kong, China, 2011:287-296.

(编辑 詹燕平)