

## 混合时空和流行度特征的兴趣点推荐算法

吴 燕, 章 韵, 陈双双

(南京邮电大学 计算机学院, 南京 210003)

**摘 要:** 兴趣点推荐有助于用户发现所需位置, 但现有推荐算法的精确率较低。为此, 提出一种融合时空与流行度特征的个性化兴趣点推荐算法。在基于用户的协同过滤算法中融入时间特征, 将基于时间因素的兴趣点流行度估算与空间特征相结合, 分别给出相应的估算方法并进行线性组合, 从而得到基于联合框架的兴趣点推荐算法。实验结果表明, 相比 U、UTF、U + SB 算法, 该推荐算法能够有效提升推荐精确率和召回率。

**关键词:** 兴趣点推荐; 协同过滤; 时间特征; 空间特征; 流行度

**中文引用格式:** 吴 燕, 章 韵, 陈双双. 混合时空和流行度特征的兴趣点推荐算法[J]. 计算机工程, 2018, 44(9): 59-63, 69.

**英文引用格式:** WU Yan, ZHANG Yun, CHEN Shuangshuang. Point of interest recommendation algorithm fusing with spatiotemporal and popularity features[J]. Computer Engineering, 2018, 44(9): 59-63, 69.

## Point of Interest Recommendation Algorithm Fusing with Spatiotemporal and Popularity Features

WU Yan, ZHANG Yun, CHEN Shuangshuang

(School of Computer Science, Nanjing University of Posts and Telecommunications, Nanjing 210003, China)

**[Abstract]** Point of Interest (POI) recommendation helps users to find the desired location, but the recommendation accuracy of existing recommendation algorithms is low. To solve this problem, a POI recommendation algorithm fusing with spatiotemporal and popularity features is proposed. The time characteristics are integrated into the user based collaborative filtering algorithm, and the estimation of the POI popularity based on time factors is integrated into the spatial characteristics, the corresponding estimation methods are given respectively for the two methods, and a joint framework based POI recommendation algorithm is obtained. Experimental results show that, compared with U, UTF and U + SB algorithm, the proposed recommendation algorithm can effectively improve the recommendation accuracy and recall rate.

**[Key words]** Point of Interest (POI) recommendation; collaborative filtering; time characteristics; spatial characteristics; popularity

**DOI:** 10.19678/j.issn.1000-3428.0047866

### 0 概述

近年来, 基于位置的社交网络(Location Based Social Networks, LBSN)<sup>[1-2]</sup> 得到迅猛发展, 其为兴趣点推荐服务提供了用户信息、社会关系、地理坐标、签到时间、评论信息等多维度信息<sup>[3]</sup>。在 LBSN 中, 用户通过签到来发布自己的当前位置信息, 并分享他们对当前兴趣点(Point of Interest, POI), 如旅游景点、博物馆、图书馆、餐厅等的评论信息和体验感觉。这些基于位置的社交网站容纳了海量的用户签到信息, 可以利用这些信息向用户推荐感兴趣且未去过的地方。兴趣点推荐<sup>[4-6]</sup> 对于用户和商家都具有非

常重要的作用, 其一方面可以减轻用户信息过载问题, 满足用户个性化需求, 另一方面可以帮助商家向潜在用户推送广告, 增加商家的知名度, 以此提高商业效益。

目前, 兴趣点推荐算法主要结合用户信息、社交关系、位置坐标、签到时间、评论信息等进行推荐。其中, 有效利用时空因素可以进一步提高兴趣点推荐的性能, 给用户带来更好的推荐体验。利用时空因素时需要考虑以下 2 个方面:

1) 时序影响力。基于社交网络用户行为的时间信息是指用户访问兴趣点的时间记录。通过分析签到数据挖掘出用户行为的时序特征, 从而改善推荐

效果。例如,人们通常在工作日和周末访问不同的地方,随着时间的变化,用户的偏好也会发生变化。介于该因素,文献[7-8]将用户签到时间进行分段,并且对较近的时间段赋予较高的权重。文献[9]把用户-兴趣点评分矩阵切分成不同时间下的子矩阵,然后把这些子矩阵通过矩阵分解成对应时间段的位置特征矩阵和用户偏好矩阵,最后对不同时间段的用户偏好矩阵进行集成,以得到用户对于某个兴趣点的综合偏好。

2)地理位置的影响力。文献[10]研究表明,与离得远的事物相比,离得近的事物之间相似度更高。在日常生活中,人们访问一个兴趣点后,通常喜欢访问该兴趣点附近的地理位置,即与离得远的兴趣点相比,相邻位置的兴趣点相似度更高。基于地理位置的兴趣点推荐分为2种:一种仅考虑目标用户的当前空间坐标,过滤掉离目标用户较远的兴趣点<sup>[11-13]</sup>;另一种应用主题模型或地理潜在特征来获取POI的潜在特征<sup>[14-15]</sup>。

在实际中,很难从用户签到数据中得到有效信息和过于稀疏的用户签到数据。为此,本文提出一种融合时空和流行度特征的兴趣点推荐算法,目的在于提高推荐精确率和召回率。首先在基于用户的协同过滤算法中融入时间特征得到相应估算方法;然后将基于时间因素的兴趣点流行度估算融入到空间特征中同样得出相应估算方法;最后线性组合这2个方法,给出一种混合时空与流行度特征的个性化兴趣点推荐算法。

## 1 数据集特征分析

### 1.1 时间特征

实时地向目标用户推荐兴趣点具有很大的实际价值。基于位置社交网络的签到数据的时间特征主要分为差异性特征与连续性特征。时间的差异性是指在不同的时间点,目标用户会签到不同的位置。例如,用户在中午时分,倾向于去食堂、饭馆;晚上倾向于去电影院、酒吧等娱乐场所;工作日通常会在住家和公司附近商圈签到。受此启发,本文提出的兴趣点推荐算法考虑时间特征,把1d时间按照小时等分为24个时间点,即 $T = \{0, 1, \dots, 23\}$ ,时间点 $t \in T$ 为整数,如16(hh):01(mm):00(ss)表示 $t = 16$ 。时间的连续性是指目标用户往往在距离较近的时间点所访问的兴趣点很类似。例如,用户在中午11点~13点的时间区间内一般吃饭休息;上午9点~11点和下午3点~5点一般在公司附近签到。本文研究来自社交网站Foursquare的数据集,发现用户在不同的时间点有相似的签到行为。

图1所示为Foursquare数据集的6点、9点和

15点分别与一天中24个时间点的相似曲线。从图1可以看出,距离较近的时间点间用户的签到行为很相似。早上6点和早上5点间用户签到的相似度高要高于早上6点和早上4点间用户签到的相似度。但是,尽管早上6点和早上9点时间很相近,6点前的时间区间(0点~5点)用户签到行为相似度要高于6点后的时间区间(9点~23点),而这种行为在9点的折线图上表现得则相反。观察15点的折线图可以发现,9点~14点间的相似度曲线很平稳,11点~12点间有大幅度上升,这很符合实际中工作和午餐时间点的用户行为。综上,用户的行为在目标时间点 $t$ 可能与一天中的某些时间点很相似。




图1 用户给定时间点与任意时间点之间的相似度

### 1.2 兴趣点流行度特征

兴趣点流行度是指用户对兴趣点的欢迎程度,一般通过基于位置社交网站上用户访问该兴趣点的次数进行评估。研究表明,越容易被推荐的兴趣点,其受欢迎程度越高,即其被签到的次数越多。除此之外,兴趣点流行度还受时间因素的影响,一天中不同时间点兴趣点的流行度也不一样。例如,食堂、餐馆一般在中午或晚上的人流量较大,银行、企业等办公场所一般在工作日时间人流量较大。为验证这一点,本文选取社交网站Foursquare数据集中最受欢迎的2个兴趣点A和B,用折线图绘制在不同时间点签到该兴趣点的可能性,如图2所示。其中,在 $t$ 时间点签到兴趣点 $l$ 的可能性,是由所有用户在 $t$ 时间点签到到兴趣点 $l$ 的次数与所有用户在24个时间点签到到兴趣点 $l$ 的次数的比值计算所得。




图2 一天中不同时间的兴趣点流行度分布

## 2 兴趣点推荐算法

### 2.1 融合用户协同过滤和时间特征的兴趣点推荐

#### 2.1.1 数据预处理

统计目标用户  $u$  访问过的地点集合  $L_u$ , 遍历地点集合  $L_u$ , 找到访问过相同兴趣点的用户  $v$ 。计算目标用户  $u$  和用户  $v$  共同访问的兴趣点的数量  $N_{u,v}$ , 若  $N_{u,v}$  大于阈值  $O$ , 则用户  $v$  是与目标用户  $u$  相似的用户, 否则过滤掉  $v$ 。如此反复, 最后得到与目标用户  $u$  相似的用户集合  $SUser$ 。

#### 2.1.2 任意2个时间点的相似性

对于  $\forall u \in U$ , 用户  $u$  的时间点  $t$  与  $\forall t_1$  之间相似度的计算如式(1)。这2个时间点的相似性即为全部用户在这2个时间点相似度的平均值, 如式(2)所示。

$$sim_{t,t_1}^u = \frac{\sum c_{u,t,l} c_{u,t_1,l}}{\sqrt{\sum c_{u,t,l}^2} \sqrt{\sum c_{u,t_1,l}^2}} \quad (1)$$

$$sim_{t,t_1} = \frac{\sum sim_{t,t_1}^u}{N_{user}} \quad (2)$$

其中,  $N_{user}$  为数据集中用户数量,  $c_{u,t,l}$  为目标用户  $u$  在时间点  $t$  对兴趣点  $l$  的签到值, 值为1表示已经签到, 值为0表示尚未签到。

#### 2.1.3 运用平滑技术时的用户相似性

将时间划分为以小时为单位的多个时间点, 则用户的偏好矩阵维度变成用户-时间-兴趣点3层, 势必会使用户的签到数据更稀疏, 这导致有时不能很好地比较用户之间的相似性。例如, 假设用户  $u$  在  $t_1$  和  $t_2$  时间点分别访问了兴趣点  $l_1$  和  $l_2$ , 而用户  $v$  在  $t_1$  和  $t_2$  时间点分别访问了兴趣点  $l_2$  和  $l_1$ , 如果不考虑时间, 通过式(3)计算出用户  $u$  和用户  $v$  的相似性为1, 而加入时间因素后, 通过式(4)计算出用户  $u$  和用户  $v$  的相似性为0。

$$sim_{u,v} = \frac{\sum_l c_{u,l} c_{v,l}}{\sqrt{\sum_l c_{u,l}^2} \sqrt{\sum_l c_{v,l}^2}} \quad (3)$$

$$sim_{u,v}^t = \frac{\sum_l c_{u,t,l} c_{v,t,l}}{\sqrt{\sum_l c_{u,t,l}^2} \sqrt{\sum_l c_{v,t,l}^2}} \quad (4)$$

根据第1.1节的时间特征分析可知, 用户签到行为在某一时间点和在某些其他时间点上很相似。由此, 本文提出一种基于不同时间点用户签到相似性的时间平滑技术, 以解决由数据稀疏所带来的问题。根据式(5), 可以计算出  $c_{u,t,l}$  的新值  $\hat{c}_{u,t,l}$ , 可实现平滑目的。根据式(6), 可以计算出2个用户的相似性。

$$\hat{c}_{u,t,l} = \frac{\sum_{t_1=1}^T sim_{t,t_1} c_{u,t_1,l}}{\sum_{t_1=1}^T sim_{t,t_1}} \quad (5)$$

$$sim_{u,v}^t = \frac{\sum_{l \in L} \hat{c}_{u,t,l} \hat{c}_{v,t,l}}{\sqrt{\sum_{l \in L} \hat{c}_{u,t,l}^2} \sqrt{\sum_{l \in L} \hat{c}_{v,t,l}^2}} \quad (6)$$

#### 2.1.4 基于平滑技术时间感知的用户协同过滤

运用平滑技术时, 目标用户  $u$  在时间点  $t$  访问兴趣点  $l$  的可能性如式(7)所示。

$$c_{u,t,l}^t = \sum_{v \in SUser} \frac{sim_{u,v}^t \sum_{t_1=1}^T \hat{c}_{v,t_1,l} sim_{t,t_1}}{\sum_{v \in SUser} sim_{u,v}^t} \quad (7)$$

### 2.2 融合流行度与空间特征的兴趣点推荐

#### 2.2.1 最近邻候选兴趣点

文献[14,16]研究表明, 用户倾向于访问他们曾经去过的地方附近。某地点与当前位置距离越近, 兴趣度越高, 反之, 随着距离增加, 用户的兴趣度将会下降。受到该现象启发, 本文提出最近邻候选兴趣点选取评估方法, 以此提高推荐精确率。

令目标用户  $u$  访问过的地点集合为  $L_u = \{l_1, l_2, \dots, l_n\} \in L, l_i \in L$  且  $l_i \notin L_u$ 。则目标用户访问候选兴趣点  $l_i$  的条件概率如式(8)所示。

$$p(l_i | L_u) = \frac{1}{\min_{l_j \in L_u} geodist(l_i, l_j)} \quad (8)$$

其中, 兴趣点  $l_i, l_j$  的距离  $geodist(l_i, l_j)$  采用地球球面距离公式计算。假设  $l_i$  的坐标是  $\langle lat_i, lng_i \rangle$ ,  $l_j$  的坐标是  $\langle lat_j, lng_j \rangle$ ,  $R$  是地球的近似半径,  $geodist(l_i, l_j)$  计算如式(9)所示。

$$geodist(l_i, l_j) = R \cdot \cos^{-1}(\sin(lat_i) \cdot \sin(lat_j) + \cos(lat_i) \cdot \cos(lat_j) \cdot \cos(lng_i - lng_j)) \quad (9)$$

#### 2.2.2 基于时间因素的兴趣点流行度

研究表明, 每个兴趣点在一天中的不同时间点, 用户的签到概率(即兴趣点的流行度)不同。同时, 不同的兴趣点在不同的时间点, 用户的签到概率也不同。利用候选兴趣点在某个时间点的签到数量和该候选兴趣点长期的签到数量, 本文提出基于时间因素的兴趣点流行度评估方法, 定义如下:

令  $C_l$  为在兴趣点  $l$  签到的实际用户数量,  $C_{l,t}$  为在时间点  $t$  兴趣点  $l$  被签到的实际用户数量。则兴趣点  $l$  在时间点  $t$  被签到的可能性如式(10)所示。

$$p_t(l) = \lambda \frac{|C_{l,t}|}{\sum_{l' \in L} |C_{l',t}|} + (1 - \lambda) \frac{|C_l|}{\sum_{l' \in L} |C_{l'}|} \quad (10)$$

其中,  $\lambda$  为平衡候选兴趣点在某个时间被签到概率和该候选兴趣点长期被签到概率的权重因子, 取值为  $[0, 1]$ 。

在最近邻候选兴趣点估计的基础上,融合基于时间因素的兴趣点流行度估计,得到最终目标用户  $u$  在时间点  $t$  访问兴趣点  $l$  的概率,如式(11)所示。

$$c_{u,t,l}^s = p(l|L_u) p_t(l) \quad (11)$$

### 2.3 LRBTSP 算法

由于时间、空间以及流行度的利用在一定程度上能改善推荐性能,本文构建一种线性联合框架,以融合上述 2 个算法后得到算法 LRBTSP (Location Recommendation Based on Temporal, Spatial and POI Popularity)。由于上述 2 种算法的结果使用了不同的方法进行评,因此在融合前必须采用 Min - Max 标准化方法对这 2 种算法的结果进行线性变换,如式(12)、式(13)所示。

$$\tilde{c}_{u,t,l}^t = \frac{c_{u,t,l}^t - \min_l'(c_{u,t,l'}^t)}{\max_l'(c_{u,t,l'}^t) - \min_l'(c_{u,t,l'}^t)} \quad (12)$$

$$\tilde{c}_{u,t,l}^s = \frac{c_{u,t,l}^s - \min_l'(c_{u,t,l'}^s)}{\max_l'(c_{u,t,l'}^s) - \min_l'(c_{u,t,l'}^s)} \quad (13)$$

其中,  $\min_l'(\cdot)$  和  $\max_l'(\cdot)$  分别为目标用户  $u$  在时间点  $t$  签到兴趣点  $l$  的最小可能性和最大可能性。

本文对标准化后的算法结果进行线性加权,得出推荐得分如式(14)。

$$c_{u,t,l}^{ts} = K\tilde{c}_{u,t,l}^t + (1-K)\tilde{c}_{u,t,l}^s \quad (14)$$

其中,  $K$  是平衡基于时间和空间特征的 2 种算法权重的参数,取值为  $[0,1]$ 。

LRBTSP 算法伪代码如下:

输入 用户签到数据集  $C$ , 目标用户  $u$ , 历史签到位置集合  $L_u$ , 时间点  $t$

输出 位置推荐列表  $L_n$

1. 预处理数据,得到与目标用户  $u$  相似的用户集合  $SUser$
2. for each  $t_1 \in T$  do
3. 用式(1)计算  $\text{sim}_{u,t_1}^u$
4. end for
5. for each  $l \in L$  且  $l \notin L_u$  do
6. for each  $v \in SUser$  do
7. for each  $t \in T$  do
8. for each  $l' \in L$  do
9. 用式(5)计算  $\hat{c}_{u,t,l}$
10. end for
11. end for
12. 用式(6)计算  $\text{sim}_{u,v}^t$
13. for each  $t_1 \in T$  do
14. 计算  $c_{v,t_1,l}, \text{sim}_{t_1,t}$
15. end for
16. 用式(7)计算  $c_{u,t,l}^t$
17. end for
18. for each  $l' \in L_u$  do
19. 用式(9)计算  $\text{geodist}(l, l')$
20. end for

21. 用式(8)计算  $p(l|L_u)$

22. 用式(10)计算  $p_t(l_u)$

23. 用式(11)计算  $c_{u,t,l}^s$

24. 用式(14)计算  $c_{u,t,l}^{ts}$ , 得到线性加权后的推荐得分

25. end for

26. return 推荐列表  $L_n$

## 3 实验结果与分析

### 3.1 实验设置

本文实验具体设置如下:

1) 数据集。本实验使用 Foursquare 数据集,该数据集主要包括用户的签到记录(即用户 ID、兴趣点 ID、地理坐标、时间)。其中,对真实时间进行处理,将一天按小时等分为 24 个时间点,如将真实时间 09:01:00 记为 9。本实验数据集包括 194 108 条签到记录、2 321 个用户和 5 596 个兴趣点。本文实验从数据集中随机选取 70% 的数据作为训练集,其余数据作为测试集。

2) 度量标准。为评估 TOP- $N$  兴趣点推荐性能,本文将准确率和召回率作为实验度量标准。其中,精确率表示前  $N$  个被推荐的兴趣点中含有测试签到兴趣点的数量占  $N$  的比值,召回率表示前  $N$  个被推荐的兴趣点中用户已经签到过的兴趣点数量占用户实际签到过的所有兴趣点数量的比值。

3) 对比算法。本次实验将本文算法与其他算法进行对比,以此来验证本文算法的性能。对比算法为基于用户的协同过滤算法 U、融合时间函数和用户偏好的兴趣点推荐算法 UTF<sup>[17]</sup>、结合空间特征的基于用户的协同过滤算法 U + SB<sup>[18]</sup>。

### 3.2 算法性能分析

#### 3.2.1 参数 $O$ 取值的影响

算法运行时需删除与目标用户共同访问的兴趣点数量低于  $O$  个的用户。图 3、图 4 所示是不同的  $O$  值对算法推荐性能的影响。从图 3、图 4 可以看出,过滤掉和目标用户共同签到位置数量小于 4 的用户时,LRBTSP 算法的精确率和召回率最高。除此之外,数据预处理可以为测试集中的目标用户减少大约 75% 的相似用户。通过数据预处理,能减小计算开销并提高推荐算法的性能。




图 3 不同  $O$  值对推荐精确率的影响




图 4 不同 O 值对推荐召回率的影响

3.2.2 参数 λ、K 取值的影响

参数 λ 是平衡候选兴趣点在某个时间点的被签到概率和该候选兴趣点长期被签到概率的权重因子。实验通过从 0 到 1 每增加 0.1 来获得参数 λ,分别估算不同的 λ 值下,LRBTSP 算法的推荐精确率和召回率,发现 λ = 0.5 时,LRBTSP 算法精确率最佳。

参数 K 是平衡基于时间和空间特征的 2 种算法权重的因子。在参数 λ = 0.5 的情况下,实验通过从 0 到 1 每增加 0.1 来获得参数 K,LRBTSP 算法在 Foursquare 数据集下的精确率和召回率如图 5、图 6 所示。从图 5、图 6 可以看出,K 值为 0.5 时,LRBTSP 算法的精确率和召回率达到最佳。




图 5 不同 K 值对推荐精确率的影响




图 6 不同 K 值对推荐召回率的影响

3.2.3 性能对比

实验采用 Foursquare 数据集分别对 4 个兴趣点推荐算法(U、UTF、U + SB、LRBTSP)进行精确率和召回率的对比分析。实验中令 LRBTSP 算法的参数 K = 0.5,实验结果如图 7、图 8 所示。从图 7、图 8 可以看出,UTF、U + SB、LRBTSP 这 3 种算法在精确率和召回率上优于算法 U,说明挖掘时空因素可以提高推荐的精确率;LRBTSP 兴趣点推荐算法在精确率和召回率上优于算法 UTF、U + SB,说明该算法在提高推荐精确率上有明显优势。




图 7 4 种算法精确率对比




图 8 4 种算法召回率对比

4 结束语

在基于位置的社交网络中,用户历史签到数据的获取推动了推荐服务的发展。本文通过深入分析签到数据的特点,提出一种融合时空和流行度特征的兴趣点推荐算法 LRBTSP。实验结果表明,相比 U、UTF、U + SB 算法,该算法具有较高的推荐性能。下一步将深入挖掘 LBSN 中用户对兴趣点的评论信息的特征,使推荐结果更加精确。

参考文献

- [ 1 ] 孟祥武,胡 勋,王立才,等. 移动推荐系统及其应用[J]. 软件学报,2013,24(1):91-108.
- [ 2 ] 丁兆云,贾 焰,周 斌. 微博数据挖掘研究综述[J]. 计算机研究与发展,2014,51(4):691-706.
- [ 3 ] GAO H J,TANG J L,HU X, et al. Modeling temporal effects of human mobile behavior on location-based social networks [ C ]//Proceedings of the 22nd ACM International Conference on Information and Knowledge Management. New York, USA: ACM Press, 2013: 1673-1678.
- [ 4 ] BAO J,ZHENG Y,WILKIE D, et al. Recommendations in location-based social networks:a survey[J]. Geoinformatica, 2015,19(3):525-565.
- [ 5 ] ZHANG D C,LI M,WANG C D. Point of interest recommendation with social and geographical influence[C]//Proceedings of 2016 IEEE International Conference on Big Data. Washington D. C.,USA:IEEE Press,2016:1070-1075.
- [ 6 ] YU F,LI Z J,JIANG S X, et al. Point-of-interest recommendation for location promotion in location-based social networks [ C ]//Proceedings of the 18th IEEE International Conference on Mobile Data Management. Washington D. C., USA:IEEE Press,2017:344-347.
- [ 7 ] KOREN Y. Collaborative filtering with temporal dynamics[J]. Communications of the ACM,2010,53(4):89-97.

(下转第 69 页)

## 参考文献

- [1] LEE J, SHIN S, JANG D, et al. Music recommendation system based on usage history and automatic genre classification [C]//Proceedings of IEEE International Conference on Consumer Electronics. Washington D. C., USA: IEEE Press, 2015: 134-135.
- [2] NANOPOULOS A, RAFAILIDIS D, SYMEONIDIS P, et al. MusicBox: personalized music recommendation based on cubic analysis of social tags [J]. IEEE Transactions on Audio Speech & Language Processing, 2010, 18(2): 407-412.
- [3] CHEN C M, TSAI M F, LIU J Y, et al. Using emotional context from article for contextual music recommendation [C]//Proceedings of ACM International Conference on Multimedia. New York, USA: ACM Press, 2013: 649-652.
- [4] STECK H. Item popularity and recommendation accuracy [C]//Proceedings of ACM Conference on Recommender Systems. Chicago, USA: ACM Press, 2011: 125-132.
- [5] 张邦佐, 桂欣, 何涛, 等. 一种融合异构信息网络和评分矩阵的推荐新算法[J]. 计算机研究与发展, 2014(S2): 69-75.
- [6] 郭兰杰, 梁吉业, 赵兴旺. 融合社交网络信息的协同过滤推荐算法[J]. 模式识别与人工智能, 2016, 29(3): 281-288.
- [7] GUO M J, SUN J G, MENG X F. A neighborhood-based matrix factorization technique for recommendation [J]. Annals of Data Science, 2015, 2(3): 1-16.
- [8] KOREN Y. Factorization meets the neighborhood: a multifaceted collaborative filtering model [C]//Proceedings of ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York, USA: ACM Press, 2008: 426-434.
- [9] 朱寒婷, 尹敏, 贺樑. 基于首播前搜索数据的电视剧流行度预测[J]. 计算机工程, 2017, 43(7): 1-8.
- [10] VALLET D, BERKOVSKY S, ARDON S, et al. Characterizing and predicting viral-and-popular video content [C]//Proceedings of ACM International on Conference on Information & Knowledge Management. New York, USA: ACM Press, 2015: 1591-1600.
- [11] XIA C, JIANG X, LIU S, et al. Dynamic item-based recommendation algorithm with time decay [C]//Proceedings of International Conference on Natural Computation. Yantai, China: [s. n.], 2010: 242-247.
- [12] SARWAR B, KARYPIS G, KONSTAN J, et al. Item-based collaborative filtering recommendation algorithms [C]//Proceedings of International Conference on World Wide Web. New York, USA: ACM Press, 2001: 285-295.
- [13] 李洪奇, 杨中国, 朱丽萍, 等. 基于数据集特征的KNN最优K值预测方法[J]. 计算机应用与软件, 2016, 33(6): 54-58.
- [14] ZACHARIAH D, SUNDIN M, JANSSON M, et al. Alternating least-squares for low-rank matrix reconstruction [J]. IEEE Signal Processing Letters, 2012, 19(4): 231-234.
- [15] 朱丽中, 徐秀娟, 刘宇. 基于项目和信任的协同过滤推荐算法[J]. 计算机工程, 2013, 39(1): 58-62.
- [16] PEDUZZI P, CONCATO J, KEMPER E, et al. A simulation study of the number of events per variable in logistic regression analysis [J]. Journal of Clinical Epidemiology, 1996, 49(12): 1373-1379.
- [8] GAO H, TANG J, HU X, et al. Mobile location prediction in spatio-temporal context [C]//Proceedings of Workshop on Nokia Mobile Data Challenge. Berlin, Germany: Springer, 2012: 41-44.
- [9] 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. New York, USA: ACM Press, 2013: 93-100.
- [10] TOBLER W R. A computer movie simulating urban growth in the Detroit region [J]. Economic Geography, 1970, 46(S): 234-240.
- [11] HU B, ESTER M. Spatial topic modeling in online social media for location recommendation [C]//Proceedings of the 7th ACM Conference on Recommender Systems. New York, USA: ACM Press, 2013: 25-32.
- [12] 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 and Development in Information Retrieval. New York, USA: ACM Press, 2014: 345-354.
- [13] ZHAO G S, QIAN S M, KANG C. Service rating prediction by exploring social mobile users' geographical locations [J]. IEEE Transactions on Big Data, 2017, 3(1): 67-78.
- [14] WANG H, TERROVITIS M, MAMOULIS N. Location recommendation in location-based social networks using user check-in data [C]//Proceedings of the 21st ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems. New York, USA: ACM Press, 2013: 374-383.
- [15] FERENC G, YE M, LEE W. Location recommendation for out-of-town users in location-based social networks [C]//Proceedings of the 22nd ACM International Conference on Information and Knowledge Management. New York, USA: ACM Press, 2013: 721-726.
- [16] YUAN Z W, LI H G. Location recommendation algorithm based on temporal and geographical similarity in location-based social networks [C]//Proceedings of the 12th World Congress on Intelligent Control and Automation. Washington D. C., USA: IEEE Press, 2016: 1697-1702.
- [17] DING Y, LI X. Time weight collaborative filtering [C]//Proceedings of the 14th ACM International Conference on Information and Knowledge Management. New York, USA: ACM Press, 2005: 485-492.
- [18] YE M, YIN P F, WANG-CHIEN L, et al. Exploiting geographical influence for collaborative point-of-interest recommendation [C]//Proceedings of ACM International SIGIR Conference on Research and Development in Information Retrieval. New York, USA: ACM Press, 2011: 325-334.

编辑 索书志

(上接第63页)

编辑 吴云芳