

## 多因素融合的个性化位置推荐算法

代仕芳<sup>1</sup>, 李 燕<sup>1</sup>, 海 凇<sup>2</sup>

(1. 南京财经大学 信息工程学院, 南京 210046; 2. 南京邮电大学 电子与光学工程学院, 南京 210023)

**摘 要:** 位置推荐中影响推荐结果的主要因素有地理位置、个人爱好、社会关系以及时间周期, 为有效融合 4 个影响因素并进行个性化位置推荐, 针对每个因素构建对应的选择概率模型, 并分析各因素对用户选择的影响力, 在此基础上, 提出一种启发式推荐算法。实验结果表明, 与传统的基于位置的推荐算法相比, 该算法性能更好, 推荐的结果更能被用户所接受。

**关键词:** 基于位置的社会网络; 推荐算法; 社会关系; 签到集; 多因素

**中文引用格式:** 代仕芳, 李 燕, 海 凇. 多因素融合的个性化位置推荐算法[J]. 计算机工程, 2018, 44(6): 300-304, 311.

**英文引用格式:** DAI Shifang, LI Yan, HAI Lin. Personalized location recommendation algorithm mixing multi-factors[J]. Computer Engineering, 2018, 44(6): 300-304, 311.

## Personalized Location Recommendation Algorithm Mixing Multi-factors

DAI Shifang<sup>1</sup>, LI Yan<sup>1</sup>, HAI Lin<sup>2</sup>

(1. College of Information and Engineering, Nanjing University of Finance and Economics, Nanjing 210046, China;

2. College of Electronic and Optical Engineering, Nanjing University of Posts and Telecommunications, Nanjing 210023, China)

**【Abstract】** The main factors that influence the recommendation results in location recommendation system include location, personal interest, social relationship and time cycle. In order to effectively integrate 4 factors to personalized location recommendation, the corresponding selection probability model is constructed for each factor. The influence of 4 factors on user selection is analyzed. Finally, the heuristic recommendation algorithm is proposed by combining 4 factors. Experimental results show that, compared with the traditional location-based recommendation algorithm, the proposed algorithm has better performance and the recommended results are more acceptable to users.

**【Key words】** Location-Based Social Network(LBSN); recommendation algorithm; social relationship; check-in set; multi-factors

**DOI:** 10.19678/j.issn.1000-3428.0046410

### 0 概述

随着智能移动终端的广泛应用与发展, 在基于位置的社会网络<sup>[1-2]</sup> (Location-Based Social Network, LBSN) 中, 用户可以很方便地以“签到”的形式来分享其地理位置、签到时间和社会关系。国外常用的 LBSN 有 Foursquare、Gowalla、Whrrl 等, 国内常用的 LBSN 有大众点评、美团、微信等。通过对 LBSN 中收集到的大量“签到”信息进行分析, 用个性化推荐算法向不同的用户推荐其可能感兴趣的地点 (Points of Interest, POI), 如餐馆、商场、健身中心等, 是目前大数据应用的研究热点之一。

在 LBSN 平台中, 个人 POI 的选择受到多种因素的影响, 如用户当前所处的位置、社会关系等。为此, 本文综合地理位置、个人爱好、社会关系及时间周期因素, 并分析各因素对用户选择的影响, 然后提出一

种综合考虑以上 4 个因素的个性化线性融合推荐算法, 用以在不同的时间和地点向不同用户进行个性化推荐。

### 1 相关工作

在 LBSN 中, 人们可以分享他们曾到过的地方以及对这些地方的评分与评价。事实上, 大多数用户会登录签到, 但是不愿意按部就班地给出具体的分数测评, 同样也很少发表评论和留言, 因此, 近年来有关位置推荐的研究相对集中于对签到信息的分析和研究。其中, 大部分的推荐算法, 只侧重于地理位置、个人爱好、社会关系及时间周期这 4 个因素中的某一个, 且未明确构建个人爱好、社会关系及时间周期的选择概率模型, 更未提出有效融合 4 个影响因素的推荐算法。

**基金项目:** 江苏省自然科学基金(BK20161023); 江苏省高校自然科学基金(16KJB520015); 南京财经大学校级预研项目(YYJ201417)。

**作者简介:** 代仕芳(1984—), 女, 讲师、博士, 主研方向为光纤-无线接入网络、无源光网络; 李 燕、海 凇, 讲师、博士。

**收稿日期:** 2017-03-20 **修回日期:** 2017-06-15 **E-mail:** shifangdai@njue.edu.cn

1.1 地理位置因素

在 LBSN 中,用户的地理位置信息是影响其做出选择的重要因素<sup>[3-6]</sup>,例如,为节省时间,人们总喜欢去离自己较近的餐馆就餐。图 1 所示为对 Gowalla 平台上某用户从 2009 年 2 月—2010 年 10 月间的访问地点的分析结果。其中,用户访问距

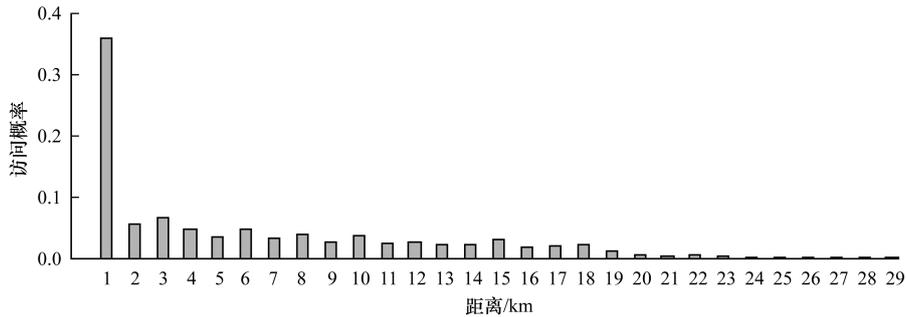


图 1 某用户对 POI 的访问概率与距离间的关系

1.2 个人爱好因素

在 LBSN 中,用户的个人爱好是影响用户选择的又一重要因素。早期有关个人爱好的研究工作<sup>[7-10]</sup>,大都集中于通过分析用户的评分、评论或留言的内容来分析用户爱好,事实上,大多数用户会登录签到,但是很少发表评论或留言,也没有耐心给出评分,基于这一事实,文献[7-8]中的推荐算法考虑将用户爱好与用户评分进行融合。此后,有研究者认为可以通过用户的历史访问记录来确定该用户的爱好,例如,若某用户喜欢看电影,则其常在影院签到,而喜欢购物的用户则常在商场出现。文献[11-12]通过分析历史签到集来确定用户习惯和爱好,为用户提供个性化推荐。

图 2 所示为对 Gowalla 平台上某用户从 2009 年 2 月—2010 年 10 月间对不同地点的访问次数的分析结果。从图 2 中可以看出, ID 为 71276、480523 及 974711 的地点是该用户访问最多的 3 个地点,访问次数分别为 11、10 和 5,其他地点的访问次数均较少,可见用户只会对自己喜欢的地点进行频繁访问。因此,可以通过分析签到集来获知用户的个人爱好。

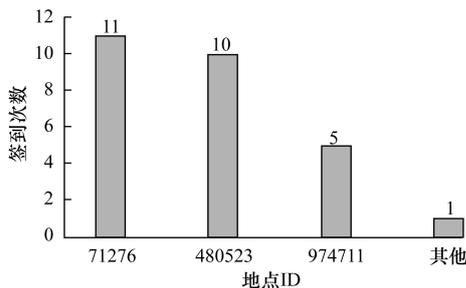


图 2 某用户对不同地点的访问次数

1.3 社会关系因素

在 LBSN 中,用户的选择可能还会受到社会关系的影响。例如,人们往往更容易接受来自朋友而非陌生人的推荐。图 3 所示为一个简单的 LBSN 网

络示意图,该网络中的用户间构成了一张社会关系网,而用户与各地点间又形成了签到关系,用户间的社会关系会影响用户与地点间的签到关系。从图 3 中可以看出,用户 2 访问过的餐厅,作为他朋友的用户 3 也极有可能去访问。文献[13]考虑有着相似位置历史信息的用户间可能有着相同的兴趣和行为,这些相似的用户间可以进行好友推荐。

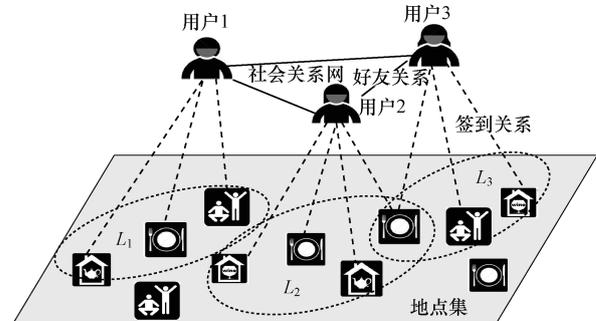


图 3 用户社会关系对签到关系的影响

1.4 时间周期因素

用户的活动往往存在时间性与周期性,如工作日的中午人们一般在公司附近的餐厅就餐,而周末更愿意在家<sup>[14-16]</sup>。因此,时间周期因素在推荐系统中越来越受关注。文献[14-15]将 1 d 划分为若干独立的时间片,用户在这些时间片上的签到信息互不影响、相互独立。然而,实际中的时间是连续的而非一个个相互独立、互不相关的时间片,用户最近的签到信息对其下一步活动有着很大影响,如用户一般不会再次光顾 1 h 前刚去过的餐厅。文献[16]构建基于时间连续性的时间差异计算模型。

2 各因素建模

本文设计一种综合考虑上述 4 个因素的个性化推荐算法。首先为每个因素建立对应的数学模型,以计算用户  $u$  选择地点  $l_j$  的概率。

## 2.1 LBSN 网络建模

LBSN 是由不同性质的节点共同构成的异构网络,用四元组  $G(U, L, E, T)$  来表示,其中,  $U = \{u_1, u_2, \dots, u_n\}$  表示用户集,  $L = \{l_1, l_2, \dots, l_m\}$  表示地点集,  $E$  表示关系集,  $T$  表示签到时间集,是一个连续的时间区间。关系集  $E$  可以划分成 2 个子部分:用户与用户间的好友关系集  $R$ ,用户与地点间的签到关系集  $S$ ,即  $E = R \cup S$ ,其中,好友关系集  $R = \{(u, v) | u, v \in U, u \neq v\}$ ,  $(u, v)$  仅表示  $v$  是  $u$  的好友,不代表  $u$  同时也是  $v$  的好友,其为单向关系,签到关系集  $S = \{(u, l, t) | u \in U, l \in L, t \in T\}$ 。

## 2.2 地理位置因素模型

地理位置因素对 POI 选择的影响主要由被选择地点  $l_j$  与用户  $u$  当前所在地点  $l_i$  之间的距离所决定,如图 2 所示,距离越远,访问概率越低。本文中地点集中  $l_i$  和  $l_j$  用经纬度表示,因此,它们之间的距离  $d(l_i, l_j)$  的计算如下:

$$d(l_i, l_j) = R \times \arccos(\sin(lat_i \times C) \times \sin(lat_j \times C) + \cos(lat_i \times C) \times \cos(lat_j \times C) \times \cos(lon_i - lon_j \times C)) \quad (1)$$

其中,  $(lon_i, lat_i)$  表示地点  $l_i$  的经纬度,  $(lon_j, lat_j)$  表示地点  $l_j$  的经纬度,  $C = \pi/180$ ,  $R = 6\ 378.137$  km。  $d(l_i, l_j)$  计算结果单位为 km。

本文沿用文献[5-6]中的 Power Law 分布模型,如式(2)所示,该模型认为仅考虑物理位置因素时用户在当前位置  $l_i$  选择访问地点  $l_j$  的可能性  $P(l_j | l_i)$ ,与用户当前位置  $l_i$  和位置  $l_j$  的距离  $d(l_i, l_j)$  间呈 Power Law 分布:

$$P(l_j | l_i) = c \times d(l_i, l_j)^\theta \quad (2)$$

其中,参数  $c$  和  $\theta$  是常数,可以通过训练集训练获得。

## 2.3 个人爱好因素模型

在签到集中签到次数较多的地点能够反映出用户的需求或兴趣,基于这一点,构建个人爱好因素模型,该模型基于用户  $u$  在时刻  $t$  之前的个人历史访问地点集  $L_{ut}$ ,计算该用户选择地点  $l_j$  的可能性,用  $P(l_j | L_{ut})$  表示,其计算如式(3)所示。

$$P(l_j | L_{ut}) = \sum_{l_s \in L_{ut}} (F_s \times SIM_{sj}) \quad (3)$$

其中,  $F_s = \frac{N_s}{N}$ ,  $SIM_{sj} = \frac{|U_s \cap U_j|}{|U_s \cup U_j|}$ ,  $F_s$  表示用户  $u_i$  在历史过程中访问地点  $l_s$  的频率,  $N_s$  表示在以前的历史记录中用户  $u_i$  访问地点  $l_s$  的总签到次数,  $N$  表示用户  $u_i$  在之前的历史中总签到次数,  $SIM_{sj}$  表示地点  $l_s$  与地点  $l_j$  之间的相似度,  $U_s$  和  $U_j$  分别表示在过去的历史中,访问过地点  $l_s$  与地点  $l_j$  的各自的用户集合。本文认为既访问过地点  $l_s$  也访问过地点  $l_j$  的用户数  $|U_s \cap U_j|$ ,和访问过地点  $l_s$  或访问过地点  $l_j$  的用户数  $|U_s \cup U_j|$  之间的比值越大,表示地点  $l_s$  与地点  $l_j$  的相似度越高。  $SIM_{sj}$  根据基于物品的协同过滤方法计算而来。

## 2.4 社会关系因素模型

好友关系是影响用户选择兴趣地点的一个重要因素,好友去过的地点用户极有可能也会去。定义  $P(l_j | R_u)$  表示基于好友关系集  $R_u$  时用户  $u$  选择地点  $l_j$  的概率。该概率公式可简化为:

$$P(l_j | R_u) = \frac{\sum_{k \in R_u} S_k}{|R_u|} \quad (4)$$

其中,  $k$  表示用户好友集中的任意一个好友,且

$$S_k = \begin{cases} 1, & \text{用户 } k \text{ 访问过地点 } l_j \\ 0, & \text{用户 } k \text{ 没有访问过地点 } l_j \end{cases}$$

## 2.5 时间周期因素模型

定义  $P(l_j | t)$  表示在时刻  $t$  用户  $u$  选择地点  $l_j$  的概率。在  $t$  时刻之前所有在地点  $l_j$  签到的时间集为  $T$ ,对其中的任意一个签到时间  $t_p$ ,沿用文献[16]中的时间差异模型来计算  $t_p$  与  $t$  之间的时间差异  $t \odot t_p$ ,具体计算如式(5)所示,该差异模型采用 1 d(24 h) 为一个时间周期,时间差异越大,则用户  $u$  在时刻  $t$  选择地点  $l_j$  的概率越小。基于该时间差异模型,  $P(l_j | t)$  概率计算如式(6)所示。

$$t \odot t_p = \begin{cases} |t - t_p|, & |t - t_p| \leq 12 \\ 24 - |t - t_p|, & |t - t_p| > 12 \end{cases} \quad (5)$$

$$P(l_j | t) = \frac{1}{|T|} \sum_{t_p \in T} \frac{1}{\lfloor t \odot t_p \rfloor + 1} \quad (6)$$

其中,  $\lfloor t \odot t_p \rfloor$  表示对时间差异的计算结果下取整。

## 3 多因素融合的位置推荐算法

上述 4 种概率模型都能各自工作,但各有侧重,单一使用某一模型,不能全面地体现用户的个性化需求。因此,本节针对 LBSN 中的位置推荐问题,基于该 4 种模型,提出一种个性化位置推荐算法 PRAFF (Personalized Recommendation Algorithm with mixing Four Factors)。

### 3.1 多因素融合位置推荐模型

为有效设计 PRAFF 算法,本文用图 4 说明各因素对用户选择的影响。该图是在 Gowalla 平台 2010 年 7 月的签到集上,随机选择 100 000 条签到信息,分别对 4 个因素进行单一因素推荐测试的结果。本文采用 TOP-K 的推荐方式,即从所有的推荐结果中选择排名靠前的前  $K$  个地点推荐给用户,图 4 中横坐标即为  $K$  值的变化,纵坐标表示在 4 个不同的因素下,分别为这 100 000 个用户提供推荐结果后,接受该推荐结果的用户数。从图 4 中可以看出,基于位置因素的推荐结果被用户接受的可能性远远高于其他 3 种因素,因此,位置因素是影响用户选择的首要因素,其他依次为个人爱好因素、社会关系因素和时间周期因素。

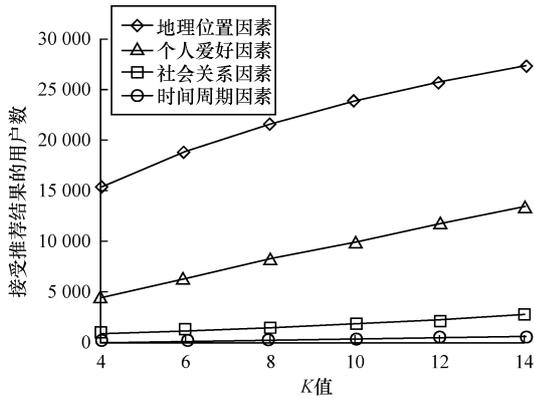


图 4 4 个因素对用户选择的影响对比

基于图 4 的分析结果,本文 PRAFF 算法融合各因素时的顺序为位置因素、个人爱好因素、社会关系因素、时间因素,算法流程如图 5 所示。此处之所以没有采用各因素按比例设置权重的方式来设计推荐算法,是因为根据分析,社会因素和时间因素权重太小,无法对最终结果产生影响。

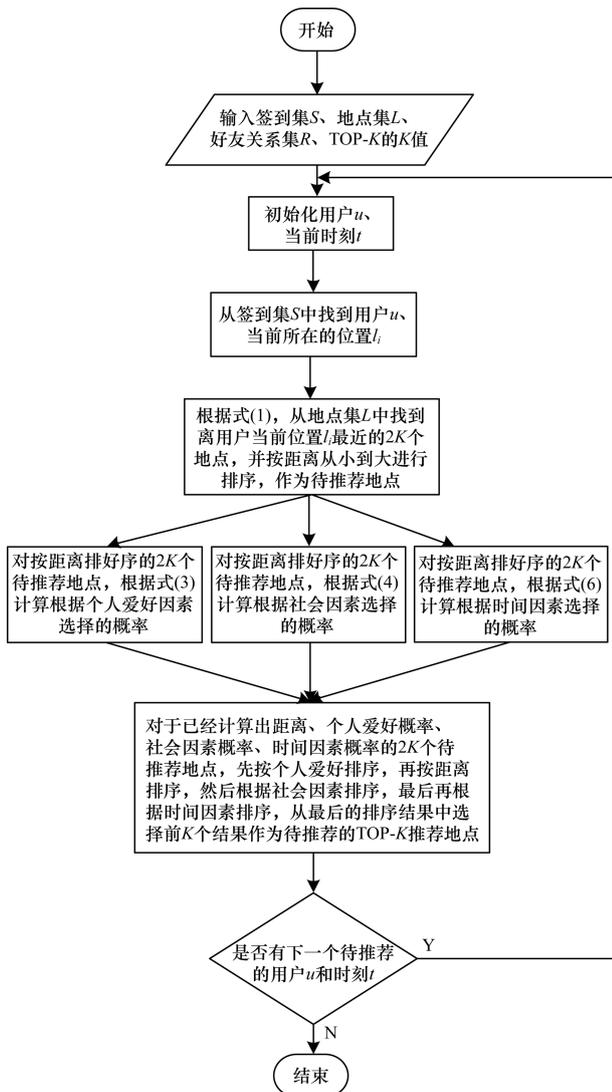


图 5 PRAFF 算法流程

### 3.2 启发式推荐算法 PRAFF

本文启发式推荐算法 PRAFF 的目的是在特定时刻  $t$ , 基于签到集  $S$ 、地点集  $L$  和好友关系集  $R$ , 为用户  $u$  进行个性化位置推荐, 其中采用 TOP-K 的推荐结果。

PRAFF 算法伪代码如下:

输入 签到集  $S$ 、地点集  $L$ 、好友关系集  $R$ 、指定用户  $u$ 、当前时刻  $t$ 、TOP-K 中的  $K$  值

输出 在特定时刻  $t$ , 为用户  $u$  产生一个含有  $K$  个地点的 TOP-K 推荐列表, 该列表中的地点按选择可能性从高到低排列。

1) 从签到集  $S$  中选择离当前时刻  $t$  最近的用户  $u$  的签到记录, 该签到地点即为用户  $u$  当前所在位置  $l_i$ 。

2) 从地点集  $L$  中, 根据式(1)选择离用户  $u$  当前位置  $l_i$  最近的  $2K$  个地点, 将这些地点按距离从小到大进行排序, 作为待推荐地点列表  $list$ 。

3) 针对用户  $u$  的地点推荐列表  $list$  中的任意一个地点  $l_j$ , 利用式(3)、式(4)、式(6)分别给出用户根据个人爱好、社会关系和时间因素选择位置  $l_j$  的概率。

4) 将已经统计了距离(位置因素)、个人爱好、访问好友数(社会因素)、时间差异(时间因素)的  $2K$  个待选地点, 先按个人爱好从大到小排序, 再按距离从小到大排序(因为在选择待选地点时已经按距离排序进行了选择), 然后再根据访问的朋友数从大到小排序, 最后按时间差异从小到大排序, 从最后的排序结果中选择前  $K$  个地点作为 TOP-K 推荐位置列表。

### 4 实验结果与分析

本文实验采用斯坦福大学在社交平台 Gowalla 上收集的数据, 该数据集记录了 2010 年 7 月份的所有签到数据, 其中总签到次数为 707 685, 涉及用户 41 031 个, 签到的地点数为 339 862, 好友关系为 124 805 对。

在 TOP-K 推荐系统中, 一般用召回率 ( $Recall$ ) 来衡量推荐算法给出的推荐地点是否全面, 召回率主要衡量用户选择地点的可能性, 因此, 本文通过测试召回率、精确率和 F 值指标来综合判断 PRAFF 算法的性能。召回率 ( $Recall$ )、精确率 ( $Precision$ ) 和 F 值的计算如式(7)~式(9)所示。

$$Recall = \frac{\sum_{u \in U} |R(u) \cap S(u)|}{\sum_{u \in U} |S(u)|} \quad (7)$$

$$Precision = \frac{\sum_{u \in U} |R(u) \cap S(u)|}{\sum_{u \in U} |R(u)|} \quad (8)$$

$$F = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (9)$$

其中,  $R(u)$  表示为用户  $u$  提供的推荐地点集,  $S(u)$  表示用户  $u$  实际访问的地点集。

此外, 为验证 PRAFF 算法性能, 本文对比分析了文献[5]中的 USG 算法, 该算法采用线性混合模型, 有效融合了个人爱好因素、社会关系因素和位置因素。USG 算法的定义如下:

$$S_{i,j} = (1 - \alpha - \beta) S_{i,j}^u + \alpha S_{i,j}^s + \beta S_{i,j}^l \quad (10)$$

其中,  $S_{i,j}$  表示用户  $i$  选择地点  $l_j$  的概率,  $S_{i,j}^u$ 、 $S_{i,j}^s$  和  $S_{i,j}^l$  分别表示用户  $i$  单独基于个人爱好因素、社会关系因素、位置因素选择地点  $l_j$  的概率,  $\alpha$ 、 $\beta$  是调和系数, 满足  $0 \leq \alpha + \beta \leq 1$ 。文献[5]经过多次实验, 获知当  $\alpha = 0.1$ 、 $\beta = 0.2$  时算法性能最优, 为简单起见, 本文直接沿用该参数设置进行实验。

本次实验在 Gowalla 数据集上选择 100 000 条签到信息进行测试, 运用 4 种方法对这 100 000 个用户在不同  $K$  值下进行 TOP- $K$  位置推荐, 并计算其召回率、精确率和 F 值, 结果如图 6 ~ 图 8 所示, 图中的 P 曲线和 L 曲线分别代表只考虑个人爱好因素(基于本文个人爱好概率模型获得的 TOP- $K$  推荐结果)和位置因素(选择距离最近的 TOP- $K$  推荐结果)对用户选择的影响结果。

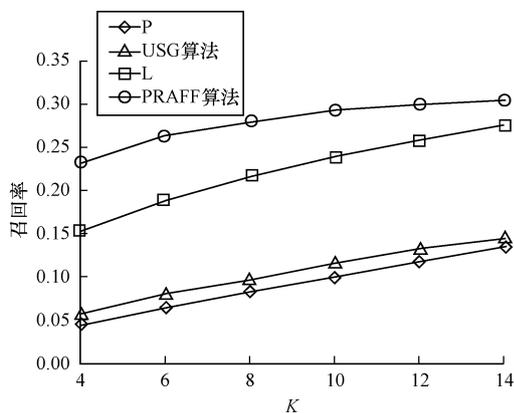


图 6 不同  $K$  值下 4 种方法的召回率

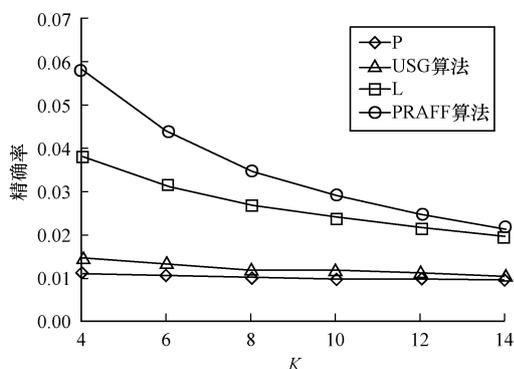


图 7 不同  $K$  值下 4 种方法的精确率

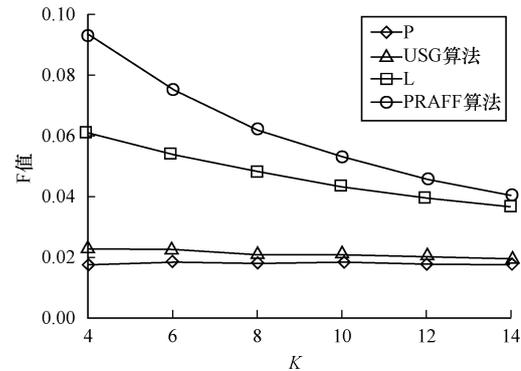


图 8 不同  $K$  值下 4 种方法的 F 值

从图 6 ~ 图 8 的结果中可以看出, 本文 PRAFF 算法在召回率、精确率和 F 值方面, 性能均优于仅基于单一因素的推荐算法以及 USG 算法。

## 5 结束语

本文针对影响用户选择的常见 4 个因素: 位置因素, 个人爱好因素, 社会关系因素及时间因素, 分别建立对应的选择概率模型, 以此计算在该因素影响下用户选择特定地点的概率。这些模型可以单独实现位置推荐, 也可以根据本文提出的启发式算法进行有效融合, 从而为用户提供更个性化的推荐。实验结果表明, 相对基于单一因素的推荐算法, 本文推荐算法得到的推荐结果更容易被人们所接受和选择。下一步考虑将评论信息融入到推荐算法中, 分析用户评论和位置评论信息, 以提升位置推荐的准确性。

## 参考文献

- [1] BAO J, ZHENG Y, WILKIE D, et al. Recommendations in location-based social networks: a survey [J]. Geoinformatica, 2015, 19(3): 525-565.
- [2] HU B, ESTER M. Social topic modeling for point-of-interest recommendation in location-based social networks[C]//Proceedings of 2014 IEEE International Conference on Data Mining. Washington D. C., USA: IEEE Press, 2014: 12-16.
- [3] ZHENG V W, ZHENG Y, XIE X, et al. Collaborative location and activity recommendations with GPS history data[C]//Proceedings of International Conference on World Wide Web. New York, USA: ACM Press, 2010: 1029-1038.
- [4] PARK M H, HONG J H, CHO S B. Location-based recommendation system using bayesian user's preference model in mobile devices[C]//Proceedings of International Conference on Ubiquitous Intelligence and Computing. Berlin, Germany: Springer, 2007: 1130-1139.
- [5] YE M, YIN P, 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. New York, USA: ACM Press, 2011: 325-334.

(下转第 310 页)

#### 4 结束语

维吾尔语事件共指关系识别对维吾尔语自然语言领域研究的发展有重要的意义,将其结合深度学习机制能更好地挖掘文本中深层语义信息的优势。为此,本文探索了深度学习方法在维吾尔语事件共指识别的应用,并通过实验证明了其有效性。后期将利用训练词向量进行事件表示来减少特征工程的使用,避免人工干预,进一步提升识别性能。

#### 参考文献

- [1] 马彬. 事件关系识别关键技术研究[D]. 苏州: 苏州大学, 2014.
- [2] 赵妍妍, 秦兵, 车万中, 等. 中文事件抽取技术研究[J]. 中文信息学报, 2008, 22(1): 3-8.
- [3] LIU Mengyi, LIU Xin, LI Yan, et al. Exploiting feature hierarchies with convolutional neural networks for cultural event recognition[C]//Proceedings of IEEE International Conference on Computer Vision Workshop. Washington D. C., USA: IEEE Computer Society, 2015: 274-279.
- [4] NGUYEN T H, CHO K, GRISHMAN R. Joint event extraction via recurrent neural networks [C]//Proceedings of Conference of the North American Chapter of the Association for Computational Linguistics; Human Language Technologies. Washington D. C., USA: 2016: 300-309.
- [5] 仲兆满, 刘宗田, 周文, 等. 事件关系表示模型[J]. 中文信息学报, 2009, 23(6): 56-60.
- [6] 杨雪蓉, 洪宇, 马彬, 等. 基于核心词和实体推理的事件关系识别方法[J]. 中文信息学报, 2014, 28(2): 100-108.
- [7] 丁 硃, 周 枫, 庙介璞, 等. 基于跨事件理论的新闻事件时序关系识别方法[J]. 计算机工程, 2017, 43(6): 189-194.
- [8] 余 凯, 贾 磊, 陈雨强, 等. 深度学习的昨天、今天和明天[J]. 计算机研究与发展, 2013, 50(9): 1799-1804.
- [9] 刘红光, 马双刚, 刘桂锋. 基于降噪自动编码器的中文新闻文本分类方法研究[J]. 现代图书情报技术, 2016, 32(6): 12-19.
- [10] 吴嘉伟, 关 毅, 吕新波. 基于深度学习的电子病历中实体关系抽取[J]. 智能计算机与应用, 2014, 4(3): 35-38.
- [11] 付剑锋. 面向事件的知识处理研究[D]. 上海: 上海大学, 2010.
- [12] MIKOLOV T, SUTSKEVER I, CHEN K, et al. Distributed representations of words and phrases and their compositionality [J]. Advances in Neural Information Processing Systems, 2013, 26: 3111-3119.
- [13] LIAN Peng, SHI Wenzhong, ZHANG Xiaokang. Remote sensing image classification based on stacked denoising autoencoder[J]. Remote Sensing, 2017, 10(1): 16.
- [14] BUDIMAN A, FANANY M I, BASARUDDIN C. Stacked denoising autoencoder for feature representation learning in pose-based action recognition [C]//Proceedings of the 3rd IEEE Global Conference on Consumer Electronics. Washington D. C., USA: IEEE Press, 2014: 684-688.
- [15] LU Chen, WANG Zhenya, QIN Weili, et al. Fault diagnosis of rotary machinery components using a stacked denoising autoencoder-based health state identification [J]. Signal Processing, 2017, 130(C): 377-388.
- [6] YE M, YIN P, LEE W C. Location recommendation for location-based social networks [C]//Proceedings of the 18th International Conference on Advances in Geographic Information Systems. New York, USA: ACM Press, 2010: 458-461.
- [7] 巫 可, 战荫伟, 李 鹰. 融合用户属性的隐语义模型推荐算法[J]. 计算机工程, 2016, 42(12): 171-175.
- [8] 何 顺, 王淑娟, 雷建云. 基于加权多融合偏好与结构相似度的协同过滤算法[J]. 计算机工程, 2016, 42(10): 64-68.
- [9] 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. New York, USA: ACM Press, 2013: 1043-1051.
- [10] YANG D, ZHANG D, YU Z, et al. A sentiment-enhanced personalized location recommendation system [C]//Proceedings of the 24th ACM Conference on Hypertext and Social Media. New York, USA: ACM Press, 2013: 119-128.
- [11] 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. New York, USA: ACM Press, 2012: 199-208.
- [12] JANARTHANAN M, GANDHI M. Location based preference aware recommendation using sparse geo-social networking data [J]. European Journal of Applied Sciences, 2016, 8(3): 181-185.
- [13] LI Q, ZHENG Y, XIE X, et al. Mining user similarity based on location history [C]//Proceedings of International Conference on Advances in Geographic Information Systems. New York, USA: ACM Press, 2008: 34-38.
- [14] GAO H, TANG J, HU X, et al. Exploring temporal effects for location recommendation on location-based social networks [C]//Proceeding of the 7th ACM Conference on Recommender Systems. New York, USA: ACM Press, 2013: 93-100.
- [15] YUAN Q, CONG G, MA Z, et al. Time-aware point-of-interest recommendation [C]//Proceeding of ACM SIGIR International Conference on Research and Development in Information Retrieval. New York, USA: ACM Press, 2013: 363-372.
- [16] ZHANG J D, CHOW C Y. TICRec: a probabilistic framework to utilize temporal influence correlations for time-aware location recommendations [J]. IEEE Transactions on Services Computing, 2016, 9(4): 633-646.

编辑 刘冰

编辑 吴云芳