

上下文感知的移动社交网络推荐算法研究*

张志军^{1,2,3} 刘 弘^{1,2}

¹(山东师范大学 信息科学与工程学院 济南 250014)

²(山东省分布式计算机软件新技术重点实验室 济南 250014)

³(山东建筑大学 计算机科学与技术学院 济南 250101)

摘 要 尽管人类活动模式表现出较大的自由度,但也表现出受制于地理和社会限制的结构化模式. 针对移动通信网络领域中个性化服务推荐问题,结合社会化网络分析方法,提出一种融合多种上下文信息的社交网络推荐算法. 该算法在利用用户的地理位置和时间信息的基础上,深入挖掘潜在的用户社会关系,辅助用户寻找与其偏好相似的用户,然后结合移动用户的社会关系进行相应的推荐,有效解决推荐的准确性问题. 这些发现有助于LBSN类系统设计和开发人员更好地了解用户,获知用户的需求,最终完善自己的设计,为用户提供更好的应用服务. 在真实数据集上的实验结果验证该算法的可行性和有效性,并且与现有推荐算法相比,具有更高的预测准确度.

关键词 移动通信网, 移动社会化网络, 用户上下文, 社会化推荐, 偏好预测

中图法分类号 TP 391

DOI 10.16451/j.cnki.issn1003-6059.201505003

Research on Context-Awareness Mobile SNS Recommendation Algorithm

ZHANG Zhi-Jun^{1,2,3}, LIU Hong^{1,2}

¹(School of Information Science and Engineering, Shandong Normal University, Jinan 250014)

²(Shandong Provincial Key Laboratory for Distributed Computer Software Novel Technology, Jinan, 250014)

³(School of Computer Science and Technology, Shandong Jianzhu University, Jinan 250101)

ABSTRACT

Although patterns of human activity show a large degree of freedom, they exhibit structural patterns subjected by geographic and social constraints. Aiming at various problems of personalized recommendation in mobile networks, a social network recommendation algorithm is proposed with a variety of context-aware information and combined with a series of social network analysis methods. Based on geographical location and temporal information, potential social relations among users are mined deeply to find the most similar set of users for the target user, then recommendations are carried out incorporating with social relations of the mobile users to effectively solve the problem of recommendation precision. The above study can not only help LBSN designers and developers to better understand their users and grasp their want, but also help to refine the design of their system to provide users with more appropriate applications and services. The experimental results on the real-world dataset verify the

* 国家自然科学基金项目(No. 61272094, 61472232)、山东省科技发展计划项目(No. 2014GGX101011)、山东省自然科学基金项目(No. ZR2010QL01)、山东省高等学校科技计划项目(No. J12LN31, J13LN11)、济南市高校院所自主创新计划项目(No. 201401214, 201303001)资助

收稿日期:2014-09-18;修回日期:2015-01-11

作者简介 张志军,男,1973年生,副教授,博士研究生,主要研究方向为个性化推荐、人工智能. E-mail: zzhj@163.com. 刘弘(通讯作者),女,1955年生,教授,博士生导师,主要研究方向为分布式人工智能、软件工程及计算机辅助设计的交叉研究. E-mail: lhdscn@jn-public.sd.cninfo.net.

feasibility and effectiveness of the proposed algorithm, and it has higher prediction accuracy compared with existing recommendation algorithms.

Key Words Mobile Communication, Mobile Social Network, Context-Awareness, Social Recommendation, Preference Prediction

1 引言

随着“三网融合”和物联网技术的飞速发展,信息过载问题愈加严重,为用户带来很大的信息负担,推荐系统被认为是解决此类问题的有效方法^[1]. 移动社交网络推荐系统是传统推荐方法在移动互联网社交领域的延伸与扩展. 与互联网用户相比,移动用户面临着更加复杂多变的移动网络环境,只有准确提取用户所处环境及偏好,才能生成有效的推荐结果. 移动推荐系统对实时性要求较高,它根据上下文环境的不同进行不同项目或商品的推荐. 但现有的推荐系统通常只注重上下文信息,而忽略用户之间的社会关系,以至于推荐结果不够准确. 随着社交网络服务(Social Networking Service, SNS)的出现^[2],推荐系统可根据用户本人的偏好以及社会关系中好友的评价信息向用户推荐服务^[3],在现实生活中,朋友或认识的人的推荐可提高商品购买的几率. 因此移动社交网络推荐系统的研究还有待进一步完善和提高. 现在线社交网络服务已成为互联网上发展最快的应用^[4],社交网站的访问量已经占互联网总访问量的 25%^[5]. 最近,出现许多基于位置的社交网络(Location Based Social Network, LBSN),它是位置与社交网络的结合,如 Foursquare, Facebook, Gowalla, Brightkite 等,用户通过在网站登记可分享他们的位置信息.

孟祥武等^[6]对最近几年移动推荐系统的研究进展进行综述,指出如何利用移动上下文信息进一步提高推荐的精度和用户满意度. 王玉祥等^[7]将上下文相似度引入到服务选择的过程中,并且和信任度相结合,提出一种三维协作过滤服务选择模型. 郭磊等^[8]提出一种信任关系强度敏感的社会化推荐算法,其所推导出的信任关系强度能提高已有推荐算法的精度. Zheng 等^[9]使用朴素贝叶斯分类器(Naive Bayes Classifier)对当前时间上下文分类,计算项目属于不同类别的概率,但移动用户兴趣随着时间的推移可能发生的变化没有被考虑. Gao 等^[10]提出一种基于用户时间和空间上下文的位置预测算法,不仅考虑空间的历史轨迹,并且考虑时间

的周期模式,结合平滑技术,得到较好的推荐精度. Gong 等^[11]提出一种在社交网络环境下通过用户朋友所处位置预测用户下一个可能到达的位置,但没有考虑用户本身的位置历史信息. 也有一些研究人员通过分析用户的时间周期序列研究用户的偏好,Thanh 和 Phuong^[12]提出一种基于手机驻留时间的高斯混合模型,以学习用户描述文件和预测用户位置.

上述算法有的借助于用户的位置因素,有的考虑用户的时间因素,还有的使用用户之间的社会关系,但没有把这些因素综合起来考虑. 本文提出一种融合多源信息的社交网络移动推荐算法,在公开数据集上的仿真实验表明,该算法的推荐精度优于目前流行的推荐方法.

2 基于上下文的移动推荐模型和算法

2.1 数据模型

Adomavicius 和 Tuzhilin^[13]提出上下文感知推荐系统(Context-Aware Recommender Systems)的概念,融入上下文信息的推荐系统将有利于提高推荐算法的精确度^[14]. 常见的上下文类型包括位置、时间、周围人员、天气状况等. 目前的推荐系统主要采用“用户-项目”二维评分效用模型,它没有考虑用户的上下文信息,即

$$u : Users \times Items \rightarrow R.$$

然而很多情况下,推荐系统想要准确进行推荐必须依靠其他的上下文信息,如时间、地点、陪伴人员等. 此时,二维评分效用模型扩展为包含多种上下文信息的多维评分效用模型,即

$$u : D_1 \times \dots \times D_n \rightarrow R.$$

通常用户可直接使用二维评分效用模型进行预测和推荐,但当移动用户偏好受上下文影响时,需要转变为包含上下文的多维度评分矩阵^[15].

定义 1 移动社交网络 $N = \langle U, R \rangle$. 其中, $U = \{u_1, u_2, \dots, u_n\}$, 表示用户的集合, n 为用户的数目,

R 为关系的集合,可分为弱关系和强关系两种.弱关系是指用户之间以相同的兴趣爱好聚合在一起的关系;强关系是用户之间通过现实生活的联系聚合在一起的关系.

定义 2 上下文感知推荐系统^[16]

$$\forall (d_{j_1}, d_{j_2}, \dots, d_{j_l}) \in D_{j_1} \times D_{j_2} \times \dots \times D_{j_l},$$

$$(d_{i_1}, d_{i_2}, \dots, d_{i_k}) = \arg \max_{\substack{(d'_{i_1}, d'_{i_2}, \dots, d'_{i_k}) \in D_{i_1} \times D_{i_2} \times \dots \times D_{i_k}, \\ (d'_{j_1}, d'_{j_2}, \dots, d'_{j_l}) = (d_{j_1}, d_{j_2}, \dots, d_{j_l})}} u(d'_1, d'_2, \dots, d'_n),$$

其中,待预测偏好的目标维度空间为 $(D_{j_1}, D_{j_2}, \dots, D_{j_l})$, $l < n$,推荐结果维度空间为 $(D_{i_1}, D_{i_2}, \dots, D_{i_k})$, $k < n$,并且满足 $(D_{j_1}, D_{j_2}, \dots, D_{j_l}) \cap (D_{i_1}, D_{i_2}, \dots, D_{i_k}) = \emptyset$.效用函数 $u(\cdot)$ 用于计算用户在多维度上下文条件下对项目的偏好.

定义 3 Check in 一般称为签到,用户通过 Check in 服务,可以很容易把当前的位置信息发布到社交网站,朋友可以看到他的位置.它一般具有下列属性^[17]:check in 本质上是社会的;它和特定的地点有关系;通常带有一些情感因素.

2.2 多维上下文移动社交网络推荐模型

文献[10]通过分析用户的时间和空间上下文信息为用户进行位置的推荐,提出整合时-日信息的分层皮特曼-尤尔模型(Hierarchical Pitman-Yor Prior Hour-Day Model, HPHD).移动数据集中包含用户过去一段时间的访问地理位置轨迹和相应的时间戳信息,把它们作为训练集,可计算给定未来某个时间访问某个地点的概率. HPHD 模型如下所示:

$$p(v_i = l | t_i = t, v_{i-1} = l_k)$$

$$= \frac{p(v_i = l, t_i = t | v_{i-1} = l_k)}{p(t_i = t)}$$

$$\propto p(v_i = l, t_i = t | v_{i-1} = l_k)$$

$$= p(t_i = t | v_i = l, v_{i-1} = l_k) p(v_i = l | v_{i-1} = l_k)$$

$$= p(t_i = t | v_i = l) p(v_i = l | v_{i-1} = l_k)$$

$$= p(h_i = h | v_i = l) p(d_i = d | v_i = l) p(v_i = l | v_{i-1} = l_k)$$

$$= N_l(h | \mu_h, \sigma_h^2) N_l(d | \mu_d, \sigma_d^2) p(v_i = l | v_{i-1} = l_k).$$

文献[18]借助于用户的地点检入历史信息和社会关系信息,对用户进行位置推荐.基于社会历史信息的推荐模型(Social Historical Model, SHM)如下所示:

$$P_{SH}^i(c_{n+1} = l) = \eta P_H^i(c_{n+1} = l) + (1 - \eta) P_S^i(c_{n+1} = l).$$

其中, $P_{SH}^i(c_{n+1} = l)$ 表示预测用户 u_i 在地点 l 签到的概率; $P_H^i(c_{n+1} = l)$ 表示依据用户 u_i 的历史信息,计算所得在地点 l 签到的概率; $P_S^i(c_{n+1} = l)$ 表示依据用户 u_i 的社会信息,计算所得在地点 l 签到的概率; $\eta \in [0, 1]$,表示用户历史信息所占的权重比例.

移动用户的移动信息需求同时受多种上下文因素的影响,如时间、位置、周围人员等.各种因素对推荐结果的影响程度也不一样,需要选择有重要影响的上下文,避免增加不必要的计算复杂度.在 HPHD 模型和 SHM 模型的基础上,通过引入移动用户之间的社会关系,融合时间、地点等上下文因素对用户的位置进行预测,以提高推荐算法的精度.本文提出的多维上下文感知移动社交网络推荐模型(Context-Awareness Mobile SNS Recommendation, CMSR)如下所示:

$$P_{CMSR}^i(c_{n+1} = l) = \alpha P_{HPHD}^i(c_{n+1} = l, t_i = t) + (1 - \alpha) P_S^i(c_{n+1} = l), \quad (1)$$

其中,

$$P_{HPHD}^i(c_{n+1} = l, t_i = t) = N_l(h | \mu_h, \sigma_h^2) N_l(d | \mu_d, \sigma_d^2) p(c_{n+1} = l | c_n = l_k),$$

$$P_S^i(c_{n+1} = l) = \sum_{u_j \in N(u_i)} sim(u_i, u_j) P_{HPY}^{i,j}(c_{n+1} = l),$$

其中, $N(u_i)$ 是用户 u_i 的朋友的集合; $P_{HPY}^{i,j}(c_{n+1} = l)$ 表示用户 u_i 到达位置 l 的概率,它是通过学习用户 u_j 的地点检入历史信息训练得到; $sim(u_i, u_j)$ 表示用户 u_i 和 u_j 之间的余弦相似度.

2.3 CMSR 模型算法设计

在 CMSR 模型中包含多个参数,如何调整这些参数的取值十分重要,既要使运行结果收敛到最大取值,又要防止过度拟合.参数 α 确定如下:为确定位置时间信息和社会历史信息对用户行为的影响,参数 α 的初值为 0,然后每次增加 0.01,直到 α 的取值为 1.通过实验确定参数 α 的最佳取值,算法过程描述如下.

算法 CMSR 算法

输入 用户 u 当前的位置 l 、下次签到的时间 t 、当前上下文 C

输出 用户 u 在当前上下文 C 下,偏好最大的位置列表 L

step 1 依据用户 u 的偏好数据,构造移动用户-上下文偏好矩阵.

step 2 利用相似性公式计算上下文之间的相似度,构造相似上下文集合 $N(c)$.

step 3 利用最大似然估计方法和 EM 算法,对参数 α 的取值进行确定.

step 4 利用式(1)计算用户的位置偏好,并将偏好最大的 TOP-N 个位置信息推荐给目标用户 u .

其中,当前上下文 C 的表达形式如下: $C = \{t, l, s, h\}$, t 表示当前的时间; l 表示当前的地理位置; s 表示社会信息; h 表示历史信息.

3 实验与结果分析

3.1 数据集简介

本文选择 Foursquare、Gowalla 和 BrightKite 这 3 个基于用户地理位置信息(LBSN) 的社交网站的用户签到信息作为数据集。

Foursquare 网站提供用户定位的社交网络服务,鼓励手机用户同他人分享自己当前所在地理位置。Gowalla 是一个移动互联网应用,它提供基于地理位置的服务,让用户知道他们朋友的地点,从而可分享他们喜欢的地方,发现身边的新世界。BrightKite 允许用户在任何地点签到 LBSN 应用,它的一个特色是允许用户选择使用电脑进行签到。Brightkite 是 LBSN 应用的先行者,但当基于位置的社交网络变得普及时,Brightkite 的应用落后于它的竞争对手 Foursquare 和 Gowalla。

在实验中,选择至少有 10 个以上位置检入信息的用户作为研究对象,从以上 3 个数据集中抽取从 2013 年 2 月到 2014 年 1 月的部分数据作为实验数据集,数据集统计信息如表 1 所示。

表 1 数据集统计信息

Table 1 Statistics information of datasets

数据集	Foursquare	Gowalla	BrightKite
用户数目	20308	10997	6233
签到数目	2452359	1327685	121539
平均签到数目	109	128	78
链接数目	158349	124976	35672

3.2 评价指标

本文采用位置预测精度作为实验的评价指标,如下所示:

$$accuracy(T_i) = \frac{|\{u | u \in U, P_{T_i}(u) = l_{T_i}(u)\}|}{|U|},$$

其中, U 表示用户的集合; $l_{T_i}(u)$ 表示用户 u 在时间 T_i 时刻到地点 l 实际进行的签到。

3.3 用户签到行为分析

根据收集到的 LBSN 用户签到及相关行为的特点,提出以下 3 个研究内容:

- 1) 用户的签到行为是否受社会关系的影响;
- 2) 用户签到地理位置有什么特点;
- 3) 用户签到时间有什么规律。

通过多个实验说明用户的签到行为受地理位置、社会关系和时间因素的共同影响,在此基础上把

本文推荐模型 CMSR 应用到基于地理位置的社交网站上,与当前流行的算法进行比较,实验结果表明所提出的方法推荐精确度更高。

实验 1 社会关系对用户的签到行为的影响。

分别比较用户在朋友之间和陌生人之间共同的签到次数,在 Foursquare 数据集上的统计分析结果如表 2 所示,朋友之间的共同签到次数大概是陌生人的 3 倍。由此可见,社会关系对用户的签到行为会产生较大的影响。

表 2 用户签到次数的区别

Table 2 Differences in the frequency of users' check-in

关系	共同的签到次数
朋友之间	12.135
陌生人之间	4.178

实验 2 地理位置对用户的签到行为的影响。

通过实验分析用户签到的地点和用户之间社会关系的特征。在这里把用户的签到次数作为用户朋友和用户所住位置距离的函数,在 Foursquare、Brightkite 和 Gowalla 数据集上的统计结果如图 1 所示。从图中可看出,在这 3 个数据集上,分布函数极其相似,它们都呈现出幂律函数的分布特征,当距离小于 100km 时,分布衰减较快;当距离超过 100km 时,分布衰减较慢。




图 1 签到概率与用户和朋友距离的关系

Fig. 1 Relationships between check-in probability and user-friends distance

随机选择 2 个用户,通过实验观察用户的签到次数和随机用户之间位置距离的函数呈现形式。在 Foursquare、Brightkite 和 Gowalla 这 3 个数据集上的实验结果如图 2 所示。从图中可看出,用户的签到概率和随机用户之间的距离并没有呈现出完全衰减的形态,当距离超过 1 000km 时,签到概率有小幅度的增加,这源于不均匀的人口密度。




图2 签到概率与随机用户之间距离的关系

Fig. 2 Relationships between check-in probability and distance of random users

下面将分析随着用户离家旅行距离的增加,他们拜见朋友的概率如何发生变化,在以上3个数据集上的实验结果如图3所示.从图中可看出,当用户的旅行距离超过100km时,他们去拜访朋友的概率增加30%,由此可看出,人们喜欢去有好友的地方做远距离旅行,但近距离活动不受社会关系的影响.此外,还发现好友关系对移动性的影响远大于移动性对新的好友关系建立的影响.




图3 用户拜访朋友的概率与距离的关系

Fig. 3 Relationships between probability of visiting friends and distance

如果2个用户的运动轨迹相似,他们成为朋友的概率如何变化.首先定义运动轨迹的相似性,用户的运动轨迹可看成是一个向量,向量中第*i*个节点的取值表示用户在位置*i*签到的次数,运动轨迹的相似性可借助于余弦相似度计算,即

$$\text{sim}(u_i, u_j) = \frac{f_i \cdot f_j}{|f_i|_2 \cdot |f_j|_2}$$

把用户之间成为朋友的概率看作是运动轨迹相似性的函数,实验结果如图4所示.由此可以看出,用户的运动轨迹越相似,成为朋友的概率越大.




图4 成为朋友的概率与运动轨迹的关系

Fig. 4 Relationship between probability of making friends and trajectory

实验3 时间因素对用户签到行为的影响.

上面分析社交网络信息对人类活动的影响,下面的研究转向非社会化因素,即时间因素对用户运动的影响.首先探讨用户签到的时间分布规律,从Gowalla数据集中提取签到地点不为空的签到时间列,分析一天中从0点到12点的签到时间分布规律,以小时为单位,分析结果如图5所示.从图中可看出,从0点到4点用户的签到频率较低,这是因为此时用户一般都在睡觉休息,5点到8点、12点到14点以及17点到21点签到概率较高,21点之后签到概率明显下降.




图5 LBSN用户一天签到时间分布

Fig. 5 Distribution of LBSN users' check-in time in a day

进一步分析一周中的签到时间分布规律,将日期转化为以7天为单位的时间,然后利用Excel中的频度分析公式Frequency计算周一到周日的签到时间分布,如图6所示,从图中可看出,周末的签到频率低于平时工作日,原因是周末休息,不用像平时上班那么有规律,周五的签到频率最高,这是因为周五是工作日的最后一天,下班后可外出活动或者购物.另外还发现,从周一到周五,每天都有3个峰值,

分别是 8 点、12 点和 18 点,这 3 个时间点恰好是人们活动的高峰期。




图 6 LBSN 用户一周签到时间分布

Fig. 6 Distribution of LBSN users' check-in time in a week

3.4 推荐精度对比

为了对提出的 CMSR 模型的性能进行评价,选择基于位置的预测模型 (Location Model, LOCM) 以及基于位置 and 时间的预测模型 (Location Time Model, LOCTIM) 作为基准模型进行评价。




图 7 预测模型性能比较

Fig. 7 Comparison of prediction performance

LOCM 模型仅根据用户当前所处的地理位置进行推荐, LOCTIM 模型根据用户当前所处的位置和时间信息进行推荐, CMSR 模型在用户地理位置和时间信息的基础上加入用户社会关系的有关信息。从 Foursquare 数据集上抽取部分数据进行实验,结果如图 7 所示。由图可知,训练集分别占整个数据集的 10% 到 90%, 在这 9 个时间点上,本文模型 CMSR 的预测精度都要高于模型 LOCM 和模型 LOCTIM, 并可看出增加用户当前所处的时间、地点以及社会关系等上下文信息能够明显提高算法的推荐精度。另外,模型 LOCTIM 的推荐精度高于模型 LOCM, 这说明单纯依靠用户当前所处的位置信息进行地点的推荐并不准确,时间因素对用户的兴趣也会产生较大的影响。由此可看出,在上下文感知的移动社交网

络中,增加用户的上下文信息能够产生使用户更加满意的推荐结果。

4 结束语

本文面向移动社交网络提出一种基于上下文感知的移动社交网络推荐算法,通过对移动社交网络中用户之间潜在的社会关系进行挖掘,将用户的社会信息融入推荐算法,结合时间、地点等上下文因素对用户可能感兴趣的位置进行预测。在真实数据集上的实验结果验证了算法的可行性和有效性。该推荐算法提高了预测准确度。另外,用户的上下文信息还包括用户的社会信任关系,多数用户更相信朋友之间的推荐信息,如何把用户之间的信任关系融入上下文信息也是未来的研究方向。

参 考 文 献

- [1] Zhang Z J, Liu H. Application and Research of Improved Probability Matrix Factorization Techniques in Collaborative Filtering. *International Journal of Control and Automation*, 2014, 7(8): 79-92
- [2] Gu H S, Xie X, Lv Q, *et al.* Etree: Effective and Efficient Event Modeling for Real-Time Online Social Media Networks // *Proc of the IEEE/WIC/ACM International Conferences on Web Intelligence and Intelligent Agent Technology*. Lyon, France, 2011, 1: 300-307
- [3] Gu H S, Gartrell M, Zhang L, *et al.* AnchorMF: Towards Effective Event Context Identification // *Proc of the 22nd ACM International Conference on Information and Knowledge Management*. San Francisco, USA, 2013: 629-638
- [4] Gu H S, Hang H J, Lv Q, *et al.* Fusing Text and Friendships for Location Inference in Online Social Networks // *Proc of the IEEE/WIC/ACM International Conferences on Web Intelligence and Intelligent Agent Technology*. Macau, China, 2012, 1: 158-165
- [5] Benevenuto F, Rodrigues T, Cha M, *et al.* Characterizing User Behavior in Online Social Networks // *Proc of the 9th ACM SIGCOMM Conference on Internet Measurement*. Chicago, USA, 2009: 49-62
- [6] Meng X W, Hu X, Wang L C, *et al.* Mobile Recommender Systems and Their Applications. *Journal of Software*, 2013, 24(1): 91-108 (in Chinese)
(孟祥武, 胡 勋, 王立才, 等. 移动推荐系统及其应用研究. *软件学报*, 2013, 24(1): 91-108)
- [7] Wang Y X, Qiao X Q, Li X F, *et al.* Research on Context-Awareness Mobile SNS Service Selection Mechanism. *Chinese Journal of Computers*, 2010, 33(11): 2126-2135 (in Chinese)
(王玉祥, 乔秀全, 李晓峰, 等. 上下文感知的移动社交网络服务选择机制研究. *计算机学报*, 2010, 33(11): 2126-2135)
- [8] Guo L, Ma J, Chen Z M. Trust Strength Aware Social Recommendation Method. *Journal of Computer Research and Development*,

- 2013, 50(9): 1805–1813 (in Chinese)
(郭磊, 马军, 陈竹敏. 一种信任关系强度敏感的社会化推荐算法. 计算机研究与发展, 2013, 50(9): 1805–1813)
- [9] Zheng V W, Cao B, Zheng Y, *et al.* Collaborative Filtering Meets Mobile Recommendation: A User-Centered Approach // Proc of the 24th AAAI Conference on Artificial Intelligence. Atlanta, USA, 2010: 236–241
- [10] Gao H J, Tang J L, Liu H. Mobile Location Prediction in Spatio-Temporal Context // Proc of the Mobile Data Challenge by Nokia Workshop in conjunction with International Conference on Pervasive Computing. Newcastle, UK, 2012: 32–39
- [11] Gong Y, Li Y, Jin D P, *et al.* A Location Prediction Scheme Based on Social Correlation // Proc of the 73rd IEEE Vehicular Technology Conference. Yokohama, Japan, 2011: 1–5
- [12] Thanh N, Phuong T M. A Gaussian Mixture Model for Mobile Location Prediction // Proc of the IEEE International Conference on Research, Innovation and Vision for the Future. Hanoi, Vietnam, 2007: 152–157
- [13] Adomavicius G, Tuzhilin A. Context-Aware Recommender Systems // Ricci F, Rokach L, Shapira B, *et al.*, eds. Recommender Systems Handbook. New York, USA: Springer US, 2008: 217–253
- [14] Adomavicius G, Sankaranarayanan R, Sen S, *et al.* Incorporating Contextual Information in Recommender Systems Using a Multidimensional Approach. ACM Transactions on Information Systems, 2005, 23(1): 103–145
- [15] Meng X W, Shi Y C, Wang L C, *et al.* Review on Learning Mobile User Preferences for Mobile Network Services. Journal on Communications, 2013, 34(2): 147–155 (in Chinese)
(孟祥武, 史艳翠, 王立才, 等. 用户对移动网络服务偏好学习技术综述. 通信学报, 2013, 34(2): 147–155)
- [16] Wang L C, Meng X W, Zhang Y J. Context-Aware Recommender Systems. Journal of Software, 2012, 23(1): 1–20 (in Chinese)
(王立才, 孟祥武, 张玉洁. 上下文感知推荐系统. 软件学报, 2012, 23(1): 1–20)
- [17] Cheng Z Y, Caverlee J, Lee K, *et al.* Exploring Millions of Footprints in Location Sharing Services // Proc of the 5th International Conference on Weblogs and Social Media. Barcelona, Spain, 2011: 81–88
- [18] Gao H J, Tang J L, Liu H. Exploring Social-Historical Ties on Location-Based Social Networks // Proc of the 6th International AAAI Conference on Weblogs and Social Media. Dublin, Ireland, 2012: 114–121