

# 基于协同过滤的美食推荐算法\*

熊聪聪, 邓滢, 史艳翠, 陶鑫, 陈亚瑞

(天津科技大学 计算机科学与信息工程学院, 天津 300222)

**摘要:** 为了解决传统的基于用户的协同过滤算法中的数据稀疏性问题, 提高推荐的准确率, 对推荐算法进行了改进并将改进后的算法应用在美食推荐领域。利用均值中心化方法对实验数据进行处理, 减少因个人评分习惯差异造成的推荐误差。通过使用改进的空值填补法降低评分矩阵的稀疏性, 在计算相似度时引入了遗忘函数和用户间的信任度, 进一步提高了推荐系统的准确性。实验表明, 提出的改进算法比传统算法有更高的准确率, 并得出了在推荐过程中考虑用户和项目外的其他因素以及针对不同的数据信息采用不同的算法, 都有利于提高推荐准确率的重要结论。

**关键词:** 推荐系统; 美食推荐; 协同过滤; 遗忘函数; 信任

**中图分类号:** TP301.6 **文献标志码:** A **文章编号:** 1001-3695(2017)07-1985-04

doi:10.3969/j.issn.1001-3695.2017.07.014

## Food recommendation algorithm based on collaborative filtering

Xiong Congcong, Deng Ying, Shi Yancui, Tao Xin, Chen Yarui

(College of Computer Science & Information Engineering, Tianjin University of Science & Technology, Tianjin 300222, China)

**Abstract:** In view of the problem of data sparseness in the traditional user-based collaborative filtering algorithm, improved the recommended accuracy, this paper put forward an improved algorithm and used this algorithm to the field of food recommendation. Firstly, in order to reduce the recommended error caused by different personal rating habits, this paper used the mean centralized method to dispose the score data. Secondly, with the improved null values fill method to reduce the sparse of the rank matrix. Finally, when calculating the similarity between users, this paper considered the factors of the forgotten function and trust relationship between users, in order to improve the accuracy of recommendation system. The experiment shows that the proposed algorithm can get higher accuracy than the traditional algorithm, and it is concluded that in the process of recommended, consider about other factors expect users and items as well as use different algorithms for different data information are beneficial to improve the accuracy of recommendation.

**Key words:** recommendation system; food recommendation; collaborative filtering; forgotten function; trust

随着计算机技术和互联网技术的快速发展,信息的传播方式越来越丰富,传播速度也在不断增快,这些都导致信息过载问题愈发严重。近些年,推荐系统作为一种重要的信息过滤技术和手段,吸引了大量的学者开展研究。目前,推荐系统已经被广泛应用在各种大型多媒体和电子商务网站上,如亚马逊、谷歌新闻和淘宝等。推荐系统主要包括基于内容的推荐、协同过滤推荐和混合过滤三种算法<sup>[1]</sup>。其中协同过滤推荐算法出现最早、应用最广泛,主要通过分析相似用户评分过的物品预测目标用户可能感兴趣的物品<sup>[2]</sup>。

美食,作为日常生活中必不可少的一部分,其种类和样式随着经济的发展在不断地增加和丰富,但同时也导致了用户在选择美食时需要花费更多的时间和精力。现有的美食推荐虽然能在一定程度上缓解上述问题,但在实际推荐过程中由于从网上直接获取的信息比较稀疏,并且用户和餐厅都有很多不同于其他领域的特征信息<sup>[3]</sup>,所以直接将传统的协同过滤算法应用在美食的推荐上,会导致推荐的准确率降低。

针对上述问题,本文在传统协同过滤算法研究的基础上,根据美食推荐中涉及的用户和餐厅特征信息,通过对数据的预

处理及相似度计算方法的改进,提出了一种基于协同过滤的美食推荐算法。

### 1 相关工作

协同过滤算法主要根据用户或项目的相似性情况产生推荐结果。其算法主要分为基于用户(user-based)和基于项目(item-based)的协同过滤推荐算法两类。基于用户的协同过滤算法根据相似用户的喜好产生对目标用户的推荐<sup>[4]</sup>。基于项目的协同过滤推荐算法则根据用户对相似项目的评分数据预测目标项目的评分。并且,协同过滤推荐系统存在数据稀疏性、冷启动等问题。本文结合基于用户和基于项目的两种协同过滤算法,并针对数据稀疏性问题对算法进行改进,最终将改进的算法应用在美食推荐领域。

随着餐饮企业的快速发展,如何通过网络及时准确地为用户提供合适的餐厅已经成为目前研究的重点。文献[5]将用户的实时地理位置作为一个参数引入到推荐系统中,并提出了一种基于位置服务的个性化美食搜索算法。文献[6]在推荐

收稿日期: 2016-05-05; 修回日期: 2016-06-14 基金项目: 国家自然科学基金资助项目(61272509, 61402331, 61402332)

作者简介: 熊聪聪(1961-),女,四川成都人,教授,博士,主要研究方向为计算机网络与嵌入式、并行计算(2692908037@qq.com); 邓滢(1989-),女,助教,硕士,主要研究方向为智能信息处理、推荐系统; 史艳翠(1982-),女(通信作者),讲师,博士,主要研究方向为推荐系统、用户需求获取; 陶鑫(1992-),男,硕士研究生,主要研究方向为智能信息处理; 陈亚瑞(1982-),女,副教授,博士,主要研究方向为机器学习。

过程中加入时间、同伴和天气等情境信息,并使用机器学习实现美食推荐。文献[7]通过挖掘移动网络中存在的直接及潜在关系,提出了一种基于移动用户社会化关系挖掘的协同过滤算法。这些研究都考虑了用户和餐厅的特征信息,但没有对这些信息进行预处理,也没有考虑用户兴趣的时效性和用户间信任关系对推荐的影响。文献[8]提出了一种基于餐厅特征信息进行建模的改进方法,虽然依据餐厅特有的时间周期特性,提出了时效衰退模型,但同样没有考虑用户间的信任关系。

针对上述问题,本文提出了一种基于协同过滤的美食推荐算法。在综合考虑用户和餐厅特征信息的基础上,通过对评分数据的预处理以及对用户相似度计算方法的改进,来提高推荐系统的准确度。

## 2 算法描述

### 2.1 数据建模

#### 2.1.1 用户模型表示

本文用用户—项目评分矩阵表示法对实验数据进行建模,在暂时忽略用户和餐厅的其他基本特征的前提下,将推荐系统表示为二维的用户—餐厅评分矩阵( $U \times D$ )。其中  $u_i \in U$  为用户集合,  $d_k \in D$  为餐厅集合,矩阵中的元素  $r_{ik} \in (U \times D)$  代表某一用户对给定餐厅的评分。该表示方法较适用于协同过滤推荐算法,但在推荐过程中却存在数据稀疏性问题<sup>[9]</sup>。本文利用改进的空值填补法和基于信任度的相似度计算方法对协同过滤推荐算法进行改进,从而降低评分矩阵的稀疏性。

#### 2.1.2 改进的空值填补法

在现实生活中,餐厅的数量是庞大的,而用户去过或是在评分网站上给出的显性评分的数量却是有限的。另外,当用户间没有共同评分的项目时,将无法计算用户间的相似度。现有的解决矩阵稀疏性的方法有很多,其中最常用的是空值填补法<sup>[10]</sup>,该方法主要采用有效的方法设定一个缺省值,并用这个值对评分矩阵中用户未评分项进行填补,从而提高了评分矩阵的数据密度,降低了矩阵稀疏性。

借鉴已有研究<sup>[11-13]</sup>,本文将用户对餐厅的评分及该餐厅的相关特征融合到美食推荐系统中,主要包括餐厅的口味、人均消费水平、地址,并假设特征相同的餐厅会得到相似评分的前提下,对空值填补法进行改进以获得新的缺省值。设评分矩阵( $U \times D$ )中缺少用户  $u_i \in U$  对餐厅  $d_k \in D$  的评分  $r_{ik}$ ,  $s$ 、 $p$ 、 $z$  分别代表口味、人均消费水平和地址,而  $Q_s$ 、 $Q_p$ 、 $Q_z$  分别代表它们的权重,并且  $Q_s + Q_p + Q_z = 1$ 。由于美食网站上附有餐厅的口味、人均消费水平、地址等标签信息,所以本文根据用户去过的餐厅的标签信息,找出评分矩阵中与餐厅  $s_k$  口味相同的餐厅有  $w$  个,其评分为  $(s_1, \dots, s_w)$ ; 与人均消费水平相同的餐厅有  $m$  个,其评分为  $(p_1, \dots, p_m)$ ; 与地址相同的有  $g$  个,其评分为  $(z_1, \dots, z_g)$ 。改进的空值填补法的公式如下:

$$r_{ik} = \frac{Q_s \sum_{l=1}^w s_l}{w} + \frac{Q_p \sum_{l=1}^m p_l}{m} + \frac{Q_z \sum_{l=1}^g z_l}{g} \quad (1)$$

#### 2.1.3 评分标准化

每个用户都有自己的评分习惯,当不同的用户给出评分时,即使他们对某一项目的认可度相同,给出的评分也未必一致。例如有些用户不情愿给他们喜欢的物品评高分或给他们不喜欢的物品评低分。但在协同过滤推荐过程中,需要利用其

他用户给出的评分预测目标用户的喜好。如果将不同用户的评分直接使用,可能会导致推荐系统的准确性降低。因为两个不相似的用户可能有相同的评分习惯,对某些项目给出相似的评分;而两个相似的用户可能会对某些项目给出差距很大的评分。因此,需要在寻找邻居用户之前,通过通用的标准化机制将个人评分标准转换为通用的整体评分标准,即对所有评分进行标准化处理。本文使用均值中心化(average standardized)方法<sup>[1]</sup>进行评分标准化,该方法的思想是通过与平均分的比较来决定一个评分为正或者为负。在推荐系统中,设  $r_{ik}$  为用户  $u_i$  对项目  $d_k$  的原始评分,可以通过减去他评价的所有物品的平均分  $\bar{r}_{u_i}$ ,转换为均值中心化评分  $\delta_{ik}$ ,公式如下:

$$\delta_{ik} = r_{ik} - \bar{r}_{u_i} \quad (2)$$

### 2.2 用户相似度计算

#### 2.2.1 引入时间效用的用户相似度计算

用户兴趣随时间的推移可能发生变化,而人们在给别人推荐某项目时,总会优先推荐近期去过的餐厅等。在推荐系统中,用户的评分代表某一刻用户对项目感兴趣的程度,时间的推移会导致用户兴趣的衰减,即用户评分效用的衰减。心理学家艾宾浩斯最早针对遗忘现象研究得出遗忘函数  $J(t)$ <sup>[14]</sup>,其形式如下:

$$J(t) = \frac{ae^b}{(t+t_0)^c} \quad a > 0, c > 0, b > 0, t_0 > 0 \quad (3)$$

其中:  $e$  为自然对数的底;  $a$ 、 $b$ 、 $c$ 、 $t_0$ 、 $t$  为变量,  $t$  为评分时间距离现在时间的的时间差,单位为  $d$ 。因用户的兴趣漂移符合人类的自然遗忘规律,所以式(3)中的  $a$ 、 $b$ 、 $c$  和  $t_0$  的值采用文献[14]中通过实验得到的数值:  $a = 20$ ,  $b = 0.42$ ,  $c = 0.0225$ ,  $t_0 = 0.00255$ 。

传统的用户相似度计算方法主要有余弦相似度、修正的余弦相似度、皮尔森相关系数<sup>[15]</sup>。本文在传统的皮尔森相关系数基础上,通过引入遗忘函数调整评分的时间效用。改进的皮尔森相关系数的计算式如下:

$$\text{sim}'(u_i, u_j) = \frac{\sum_{d_k \in D_{ij}} (\delta_{ik} J(t_{ik}) - \bar{\delta}_{u_i}) (\delta_{jk} J(t_{jk}) - \bar{\delta}_{u_j})}{\sqrt{\sum_{d_k \in D_{ij}} J(t_{ik}) (\delta_{ik} J(t_{ik}) - \bar{\delta}_{u_i})^2 + \sum_{d_k \in D_{ij}} J(t_{jk}) (\delta_{jk} J(t_{jk}) - \bar{\delta}_{u_j})^2}} \quad (4)$$

其中:  $u_i$  为目标用户,  $u_j \in I$  为与目标用户有共同评分的用户集合; 餐厅  $d_k \in D_{ij}$  ( $D_{ij}$  表示用户  $u_i$  和  $u_j$  共同评过分的餐厅集合);  $J(t_{ik})$  和  $J(t_{jk})$  表示用户  $u_i$  和  $u_j$  对餐厅  $d_k$  的评分  $r_{ik}$  和  $r_{jk}$  的遗忘函数;  $\bar{\delta}_{u_i}$ 、 $\bar{\delta}_{u_j}$  表示用户  $u_i$  和  $u_j$  的平均评分。

#### 2.2.2 用户间信任度的计算

现实生活中,用户在需要作出选择时,往往会优先参考有经验的人或者权威人士给出的意见。线上推荐系统中,目标用户与大多数其他用户通常都不认识。但在某些情况下,根据用户给出的信息或用户之间的交互行为,可以推断出一个陌生用户是否值得信任,以及值得信任的程度。这里提到的信任是指在某种特定的情境或具体时间下,对用户基于另一用户的能力和和行为相信其程度的度量。

**定义1** 信任度。用户  $u_i$  对用户  $u_j$  的信任程度的量化称为  $u_i$  对  $u_j$  的信任度<sup>[16]</sup>,用符号  $T(u_i, u_j)$  表示。

信任的表示方法主要有两种:概率方法,以0或者1代表用户的信任度,即一个用户要么可信,要么不可信;渐进方法,是指当行为产生一定程度的正向作用的时候估计信任度,即提

提供的信息一定程度上对或错,并不是完全对或者错,信任可以用不同的值表示不同的程度,如文献[17]用四个值表示信任程度:非常信任、信任、不信任、非常不信任。

本文通过融合以上两种方法计算用户信任度。根据数据集特点,从两个方面计算用户信任度,并对结果进行加权平均得到最终的用户信任度。一方面是根据用户的社交信息计算用户的信任度,用符号  $t(u_i, u_j)$  表示,其中  $u_i, u_j \in U$ 。假设用户  $u_i$  是用户  $u_j$  的粉丝,并且用户  $u_j$  不是用户  $u_i$  的粉丝。那么当  $u_i$  为目标用户的时候,  $u_i$  对  $u_j$  的信任度  $t(u_i, u_j)$  为 1; 但当  $u_j$  为目标用户的时候,  $u_j$  对  $u_i$  的信任度  $t(u_i, u_j)$  为 0, 即信任度具有不对称性。

另一方面根据用户 ( $u_j \in U$ ) 在社会网络中的影响力确定其自身的信任度,用符号  $t'(u_j)$  表示。本文主要选取用户的五个基本特征:粉丝数  $f$ 、点评数  $d$ 、鲜花数  $h$ 、贡献值  $g$ 、社区等级  $m$ , 并通过计算得到用户自身的信任度  $t'(u_j)$ , 公式如下:

$$t'(u_j) = \frac{f_{u_j}}{N} + \frac{d_{u_j}}{\sum_{i=1}^N d_{u_i}} + \frac{h_{u_j}}{\sum_{i=1}^N h_{u_i}} + \frac{g_{u_j}}{\sum_{i=1}^N g_{u_i}} + \frac{m_{u_j}}{M} \quad (5)$$

其中:  $f_{u_j}$ 、 $d_{u_j}$ 、 $h_{u_j}$ 、 $g_{u_j}$ 、 $m_{u_j}$  分别表示用户  $u_j \in U$  的粉丝数、点评数、鲜花数、贡献值;  $N = |U|$  表示用户总的数量;  $M$  表示用户最高的社区等级。

通过式(5)计算得到的用户信任度  $t'(u_j)$  的取值范围较广,不满足实验要求,还需要进行离差标准化处理,即进行线性变换,使用户信任度能在  $[0, 1]$  区间内取值,得到有界的用户信任度  $t''(u_j)$  公式如下:

$$t''(u_j) = \frac{t'(u_j) - \min}{\max - \min} \quad (6)$$

其中:  $\max$  为式(5)中计算出的所有用户的信任度中的最大值,  $\min$  为其最小值。

最后,对两个信任度进行加权平均得到用户最终的信任度  $T(u_i, u_j)$ , 公式如下:

$$T(u_i, u_j) = \frac{t(u_i, u_j) + t''(u_j)}{2} \quad (7)$$

综上,在计算用户相似度的时候,综合考虑评分随时间衰减以及用户间的信任关系对用户间相似度的影响,对相似度的计算公式进行改进,具体公式如下:

$$\text{sim}(u_i, u_j) = \frac{\text{sim}'(u_i, u_j) + T(u_i, u_j)}{2} \quad (8)$$

### 2.3 用户偏好预测

用户偏好的预测主要分为两个步骤:a)用 top- $N$  方法搜寻邻居用户,即利用式(8)得出的用户相似度对用户进行排序,选出排名靠前的  $n$  个用户作为目标用户的邻居用户;b)根据邻居用户的评分对目标用户的评分进行预测。

根据得到的用户间的相似度以及其他用户的实际评分,采用加权平均的方法对目标用户的评分进行预测,并根据预测评分排序产生推荐列表。设目标用户  $u_i \in U$ , 最终得到的邻居用户集合为  $U'$ ,  $n = |U'|$  表示邻居数量,邻居用户  $u_j \in U'$  ( $j = 1 \sim n$ ) 对餐厅  $d_k \in D$  的均值化评分为  $\delta_{jk}$ , 目标用户  $u_i$  对餐厅  $d_k$  的预测评分为  $r'_{ik}$ , 公式如下:

$$r'_{ik} = \frac{\sum_{j=1}^n \delta_{jk} \times \text{sim}(u_i, u_j)}{n} + \bar{r}_{ik} \quad (9)$$

## 3 实验

本文实验环境为:2 GB 内存,2 GHz 双核 CPU, Windows 7

操作系统, Eclipse 3.6 集成环境, MySQL 5.5 数据库。实验通过留一法验证改进推荐算法的有效性。

### 3.1 实验数据

本文所用数据集是通过爬虫软件采集的大众点评网站上真实的用户及餐厅信息。首先,选择一组用户作为种子节点,然后利用雪球采样策略采集其他用户信息的方式来获取实验数据集。采集内容主要包括 100 名用户的背景信息(用户 ID、粉丝数、贡献值、鲜花数、社区等级、口味标签、人均消费水平)、社交信息(关注信息、粉丝信息)及行为信息(点评过的餐厅名、点评分数、点评时间)和相关的 2 000 家餐厅的基本信息(餐厅 ID、位置信息、口味标签、人均消费)。

### 3.2 评价标准

准确度是目前推荐系统中最常用的度量标准,通过计算预测的用户评分与实际用户评分之间的偏差度量预测的准确性,平均绝对误差(MAE)越小,推荐系统的准确度越高。MAE 值公式如下:

$$\text{MAE} = \sqrt{\frac{1}{|T|} \sum_{(i,j) \in T} |r'_{ij} - r_{ij}|} \quad (10)$$

其中:  $r'_{ij}$  为测试集  $T$  上预测得到的评分。

### 3.3 实验

#### 3.3.1 实验前准备工作

a) 对式(1)中三个相关特征的权重赋值后进行多次对比实验,选取当实验效果最好时的权重值。具体权重值设置如表 1 所示。

表 1 相关公式中的特征权重值设置

公式	特征的权重分配		
空值填补法	平均	地址	
计算公式	口味	消费	
式(1)	$Q_s = 0.5$	$Q_p = 0.3$	$Q_z = 0.2$

b) 对实验数据进行统一处理和建模。先对用户及餐厅的评分数据进行评分矩阵建模,然后采用空值填补法(式(1))降低矩阵稀疏性,并对矩阵中的评分数据进行均值中心化处理(式(2))。

#### 3.3.2 实验描述及结果分析

本文使用传统的基于用户的协同过滤推荐算法作为基准算法进行对比实验<sup>[18]</sup>。

a) 用户相似度阈值  $\gamma$  的影响。将  $\gamma$  设置为不同的数值,设定近似邻居数目  $n = 25$ , 计算传统的基于用户的协同过滤算法与本文提出的协同过滤算法的 MAE 值,实验结果如图 1 所示。

从图 1 可知,在规定固定邻居数的前提下,用户相似度阈值  $\gamma$  的取值变化对两种算法都会产生影响。当  $\gamma < 70\%$  时,因相似度阈值过低导致得到的邻居用户数据不够准确,并使得推荐准确率较低,所以两种算法的 MAE 值会随着  $\gamma$  的增加而逐渐减小,并在  $\gamma = 70\%$  时,达到最低;当  $\gamma > 70\%$  时,两种算法的 MAE 值都逐渐升高,因为相似度阈值过高会造成与目标用户相似的用户数量较少,增加了一些偏差度较大的数据对最终推荐结果的影响,从而导致推荐的准确率降低。但无论  $\gamma$  的取值为多少,改进后的算法都要比传统算法的 MAE 值低。

b) 近似邻居数目  $n$  的影响。将  $n$  设置为不同的数值,并取用户相似度阈值  $\gamma = 70\%$ , 计算两种算法的 MAE 值,实验结果

如图 2 所示。

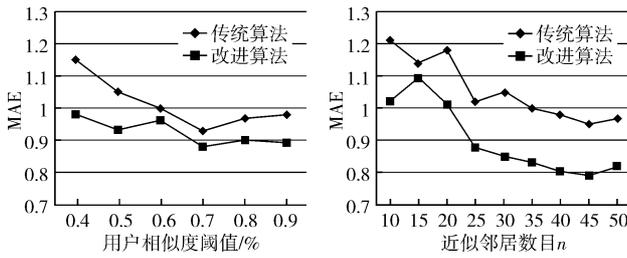


图 1 两种算法的 MAE 对比图 图 2 两种算法的 MAE 对比图

从图 2 可知,在相似度阈值固定的前提下,近似邻居数目  $n$  的变化对两种算法都产生了影响。当  $n = 25$  时,两种算法的 MAE 值变化幅度最大;当  $n = 45$  时,两种算法的 MAE 值最小。这一现象主要是因为当最近邻数较少时,目标用户的偏好预测受噪声用户评分的影响较大,准确率较低;而当近似邻居数到达一定的数量后,准确率逐渐提高,并在  $n = 45$  时达到最高。但当  $n > 45$  时,由于近似邻居数较多,用户偏好趋于平均值,失去了协同过滤的意义,准确率会小幅度降低。但是无论  $n$  的取值为多少,改进后的算法都要比传统算法的 MAE 值低。

通过两组对比实验的结果可以看出,两种算法的 MAE 值随变量  $n$  和  $y$  的变化趋势相似,并且当  $n = 45$ 、 $y = 70\%$  时,两种算法的准确度都达到了最高。主要因为改进的算法中在计算用户间相似度时考虑了用户评分的时间效用衰减和用户之间的信任关系两个因素,并且在实验前对数据进行了空置填补和标准化处理,这些改进都有利于提高推荐系统的准确度。而传统的推荐算法未考虑用户的评分习惯差异和评分效用随时间的衰减、用户之间的信任关系等因素对用户评分预测的影响,这些因素导致推荐结果的准确率较低。

#### 4 结束语

本文利用大众点评网上真实的用户和餐厅数据对传统的基于用户的协同过滤推荐算法进行改进,提出了一种改进的基于协同过滤的美食推荐算法。为降低实验数据的稀疏性和用户习惯差异导致的不准确性,实验前先对评分矩阵进行空置填补和评分标准化处理。实验过程中,利用时间遗忘函数和信任度对皮尔森相关系数进行改进,并通过实验对比验证了本文提出的算法有较高的准确率。

本文的局限在于:只是简单地考虑了用户间的信任对推荐的影响,没有深入研究信任的传播和聚合等特性对算法的影响,下一步准备系统的对用户间的关系进行深入研究。

#### 参考文献:

[1] Ricci F, Rokach L, Shapira B, et al. Recommender systems handbook [M]. Berlin: Springer, 2011: 1-833.

[2] 王玉斌, 孟祥武, 胡勋. 一种基于信息老化的协同过滤推荐算法[J]. 电子与信息学报, 2013, 35(10): 2391-2396.

[3] Stefanidis K, Pitoura E, Vassiliadis P. Adding context to preferences [C]//Proc of the 23rd International Conference on Data Engineering. [S.l.]: IEEE Press, 2007: 846-855.

[4] 王立才, 孟祥武, 张玉洁. 上下文感知推荐系统[J]. 软件学报, 2012, 23(1): 1-20.

[5] 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[J]. 通信学报, 2013, 34(2): 147-155.

[6] 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.

[7] 陈婷婷. 融合上下文和项目属性的美食商店信息推荐算法研究与实现[D]. 北京: 北京邮电大学, 2014.

[8] Weng Sungshun, Lin Binshan, Chen Wentien, et al. Using contextual information and multidimensional approach for recommendation [J]. IEEE Personal Communications, 2009, 36(1): 1268-1279.

[9] 孙光福, 吴乐, 刘洪, 等. 基于时序行为的协同过滤推荐算法[J]. 软件学报, 2013, 24(11): 2721-2733.

[10] 许斐. 基于时间因子的动态推荐算法研究[D]. 湖北: 中南民族大学, 2013.

[11] Ge Mouzhi, Elahi M, Massimo D, et al. Using tags and latent factors in a food recommender system [J]. International Conference on Digital Health, 2015, 13(2): 105-112.

[12] Jin Suk, Jue Hee, Sung Yong. Food recommendation system using big data based on scoring taste adjectives [J]. International Journal of u-and e-Service Science and Technology, 2016, 9(1): 39-52.

[13] Elahi M, Ge Mouzhi, Ricci F, et al. Interactive food recommendation for groups [C]//Proc of the 8th ACM Conference on Recommender Systems. 2014: 6-10.

[14] 孙光辉. 基于时间效应和用户兴趣变化的改进推荐算法研究[D]. 北京: 北京邮电大学, 2014.

[15] 王晨旭, 管晓红, 秦涛, 等. 微博消息传播中意见领袖影响力建模研究[J]. 软件学报, 2015, 26(6): 1473-1485.

[16] 甘早斌, 曾灿, 马尧, 等. 基于信任网络的 C2C 电子商务信任算法[J]. 软件学报, 2015, 26(8): 1946-1959.

[17] Kim M, Sang P. Group affinity based social trust model for an intelligent movie recommender system [J]. Multimedia Tools & Applications, 2013, 64(2): 505-516.

[18] 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[J]. 计算机学报, 2010, 33(11): 2127-2135.

(上接第 1985 页)

[8] Zhang Wenqiang, Gen M. Process planning and scheduling in distributed manufacturing system using multiobjective genetic algorithm [J]. IEEJ Trans on Electrical and Electronic Engineering, 2010, 5(1): 62-72.

[9] 鞠海华. 基于 NSGA-II 算法的作业车间调度研究[D]. 济南: 山东大学, 2008.

[10] 李新宇. 工艺规划与车间调度集成问题的求解方法研究[D]. 武汉: 华中科技大学, 2009.

[11] 吴正佳, 罗月胜, 周玉琼, 等. 一种求解典型 JSP 的改进离散粒子群优化算法[J]. 计算机应用研究, 2013, 30(8): 2405-2409.

[12] 张国辉, 张凌杰, 吴立辉, 等. 精英进化策略求解柔性作业车间调

度问题[J]. 计算机应用研究, 2016, 33(12): 3579-3581.

[13] 文笑雨. 多目标集成式工艺规划与车间调度问题的求解方法研究[D]. 武汉: 华中科技大学, 2014.

[14] Fang H L, Ross P, Come D. A promising genetic algorithm approach to Job-Shop scheduling, rescheduling, and open-shop scheduling problems [M]. San Mateo, California: Morgan Kaufmann Publishers, 1993: 375-382.

[15] 郭秀萍. 多目标进化算法及其在制造系统中的应用研究[D]. 上海: 上海交通大学, 2007.

[16] 郑金华. 多目标进化算法及其应用 [M]. 北京: 科学出版社, 2007: 33-70.