

## 时间加权的混合推荐算法

邹凌君<sup>1</sup> 陈 峻<sup>2,3</sup> 李 娟<sup>4</sup>

(金陵科技学院信息化建设与管理中心 南京 211169)<sup>1</sup> (扬州大学信息学院计算机系 扬州 225009)<sup>2</sup>  
(南京大学软件新技术国家重点实验室 南京 210093)<sup>3</sup> (金陵科技学院计算机工程学院 南京 211169)<sup>4</sup>

**摘 要** 提出了一种基于时间加权的混合推荐方法。该方法分为离线和在线两个阶段,离线阶段根据目标用户对物品的评价等信息得到与目标用户有相似兴趣的邻居,并构建物品描述模型;在线阶段根据目标用户和邻居用户的评价行为构建用户描述模型。由于用户兴趣会随外部因素而产生概念漂移,因此在算法中引入衰减系数以提高推荐质量。在滑动窗口模型下,每隔一定时间间隔,更新用户模型和相似群组,产生个性化的推荐。实验结果表明,该算法能实时反映用户兴趣,提高推荐系统的准确率,有较高的用户满意度。

**关键词** 个性化推荐,时间权重,混合推荐,Logistic 函数

中图分类号 TP301 文献标识码 A

### Time-weighted Hybrid Recommender Algorithm

ZOU Ling-jun<sup>1</sup> CHEN Ling<sup>2,3</sup> LI Juan<sup>4</sup>

(Information Technology and Management Center, Jinling Institute of Technology, Nanjing 211169, China)<sup>1</sup>

(Department of Computer Science, Yangzhou University, Yangzhou 225009, China)<sup>2</sup>

(State Key Laboratory of Novel Software Technology, Nanjing University, Nanjing 210093, China)<sup>3</sup>

(College of Computer Engineering, Jinling Institute of Technology, Nanjing 211169, China)<sup>4</sup>

**Abstract** This paper proposed a novel Time-weighted Hybrid Recommender algorithm. The algorithm was divided into an online component and an offline component. The offline component derives the similar group of the target recommendation user according to the information such as evaluation information and constructed object profile model while the online component constructed user profile model according to both target user and the neighbors' behavior. Because user preferences are drifting over time, the method uses attenuation coefficient in user profile model to improve the recommendation quality. The method uses sliding windows which is divided into several equal segments to produce personalized recommendation in each segment and update user profile model as well as the neighbors in a certain interval. The experimental results show that the algorithm can reflect user preferences over time, and has better effectiveness and achieves a more satisfactory effort.

**Keywords** Personalized recommendation, Time-weighted, Hybrid recommendation, Logistic function

## 1 引言

互联网的快速发展,为人们提供了海量的信息。然而,如何在浩瀚如海的信息中识别出感兴趣的、有价值的信息是一件困难的事情。因此,推荐系统应运而生。推荐系统能根据用户的个性化特征或历史交易记录,挖掘用户的潜在兴趣,主动向用户推荐其可能感兴趣的资源。通过提供有针对性的服务,能提高用户的忠诚度,带来更好的用户体验。

推荐技术已经在电子商务、Web 检索、数字图书馆等各个领域广泛应用。诸多网站都有不同形式的推荐系统,如 Amazon、eBay、YouTube 和 Google 等。其中,Amazon 研究电子商务的推荐系统长达十多年时间,使用推荐系统为其提高了 35% 的商品销售额<sup>[1]</sup>。

目前推荐算法主要可以分为:协同过滤算法<sup>[2-6]</sup>、基于内容的推荐算法<sup>[7,8]</sup>以及混合推荐算法<sup>[9-12]</sup>。混合推荐方法是将协同过滤算法和基于内容的推荐算法结合起来,以提高推荐准确率。文献<sup>[12]</sup>提出了一种新的混合推荐算法 RS\_IGB,该算法基于单个用户和相似用户群的行为构建了一种新的用户模型以更好地反映用户兴趣,但没有考虑到时序属性对推荐结果的影响。

近年来,有学者在推荐模型中加入时序信息,以更好地学习数据的变化,提高推荐准确率<sup>[13-17]</sup>。由于用户兴趣会随外部因素而产生概念漂移,为了解决此问题,文献<sup>[14]</sup>提出了 TimeSVD 算法,在用户的特征向量中加入了时间信息;孙光福等人<sup>[16]</sup>通过时序信息来构建用户之间的结构关系,进行相似度计算,然后将其集成到概率矩阵分解算法中;郑志高<sup>[17]</sup>

本文受国家自然科学基金项目(61379066),江苏省高校自然科学基金项目(15KJD520008),江苏省现代教育技术研究课题(2014-R-32521)资助。  
邹凌君(1984—),女,硕士生,讲师,主要研究方向为数据挖掘、人工智能等,E-mail:njzoulingjun@163.com;陈 峻(1951—),男,教授,博士生导师,主要研究方向为数据挖掘、体系结构、并行计算;李 娟(1980—),女,硕士,讲师,主要研究方向为数据挖掘、信息管理。

提出的时间加权不确定近邻协同过滤算法,充分考虑了时间效应的影响,对评分数据进行时间加权,保证了数据对于时间的有效性,从而解决了概念漂移的问题。

本文在已有的研究工作的基础上,提出一种基于时序信息的混合协同推荐算法(Time Weighted Recommendation System Using Individual And Group Behavior, TW\_RS\_IGB)。在考虑用户个人和邻居群组的兴趣和行为的基础上,引入时间权重,根据用户当前的兴趣实时地给出推荐结果。

## 2 问题描述和相关概念

本文提出的推荐算法将推荐过程分为两个阶段:离线阶段和在线阶段。离线阶段构建物品描述模型并根据用户的年龄、职业等特征和历史评分信息等分析出用户的兴趣,找到目标用户初始的邻居群组。在线阶段,在 RS\_IGB 的框架基础上,使用衰减系数,在滑动窗口模型下,每隔一定的时间间隔对用户模型和邻居群组同时进行更新,以提高推荐的准确度。

### 2.1 离线阶段

根据用户对物品的评价等信息,使用常用的 Pearson 相关性方法计算用户的初始邻居集,并建立初始的物品模型。

定义 1 物品特征模型<sup>[12]</sup>

$$CC_m = (c_m^{ij}, i=1, \dots, I, j=1, \dots, K_i), m=1, \dots, M \quad (1)$$

其中,  $I$  是物品的特征总数,  $K_i$  是第  $i$  个物品特征含有的特征值数,  $M$  为物品集总数。在该模型中,若物品组  $m$  有第  $i$  个特征的第  $j$  个特征值,则  $c_m^{ij}$  为 1, 否则为 0。

例如,设物品为图书,以表 1 中的图书分类信息为例,分类 1 和分类 2 分别为图书所对应的课程特征和特征值。课程特征分别是文学( $i=1$ ), ..., 工业技术( $i=7$ )。在文学中,特征值分别为文学理论( $j=1$ ), ..., 欧洲文学( $j=4$ )。则同时包含中国文学和计算机技术的课程特征模型定义为:

$$CC_m = (c_m^{11}, c_m^{12}, c_m^{13}, \dots, c_m^{64}, c_m^{71}, c_m^{72}, \dots, c_m^{74}) \\ = (0, 0, 1, \dots, 0, 0, 1, 0, 0)$$

表 1 图书分类

分类 1	分类 2
文学	文学理论, 世界文学, 中国文学, 欧洲文学
艺术	艺术理论, 绘画, 书法, 雕塑
历史	世界史, 中国史, 亚洲史, 非洲史
地理科学	天文学, 测绘学, 地球物理学
生物科学	细胞学, 遗传学, 生理学, 生物化学, 植物学
农业科学	农学, 农作物, 园艺, 林业
工业技术	电子技术, 计算机技术, 建筑科学, 水利工程

### 2.2 在线阶段

在线阶段根据用户的行为建立用户模型,并随时间的递进不断更新模型和邻居群组,以实时反映用户的兴趣。

用户模型由单个用户的信息和邻居用户的信息构成,分别由如下的步骤来计算。

步骤 1 计算单个用户  $A$  的绝对兴趣信息  $IA_A^{ij}$  和相对兴趣信息  $IR_A^{ij}$

用户  $A$  对第  $i$  个物品特征的第  $j$  个特征值(以下称为特征值  $ij$ )的绝对兴趣定义为:

$$IA_A^{ij} = \lambda_1 \frac{c_A^{ij}}{C_A} + \lambda_2 \frac{b_A^{ij}}{B_A} + \lambda_3 \frac{s_A^{ij}}{S_A} \quad (2)$$

$C_A$  表示用户  $A$  点击的物品总数,  $c_A^{ij}$  表示  $C_A$  中有特征值  $ij$  的物品的数量。  $B_A$  表示用户  $A$  放入预选篮的物品总数。

$b_A^{ij}$  表示  $B_A$  中含有特征值  $ij$  的物品的数量。  $S_A$  表示用户  $A$  事先选择的感兴趣物品特征值总数,是用户在离线阶段选择的个人的兴趣范围。若用户感兴趣的特征值中包含了特征值  $ij$ ,则  $s_A^{ij}$  值为 1, 否则为 0。参数  $\lambda_k$  是权重因子,用以调节各部分的权重。其中  $\lambda_1 + \lambda_2 + \lambda_3 = 1$ 。

用户  $A$  对特征值  $ij$  的相对兴趣度计算如下:

$$IR_A^{ij} = \frac{IA_A^{ij}}{\frac{1}{|T|} \sum_{t \in T} IA_t^{ij}} \quad (3)$$

其中,  $T$  是用户集,  $|T|$  是用户数。

步骤 2 计算相似群组的绝对兴趣和相对兴趣

相似群组是与用户  $A$  有相似特征的用户群组,称为  $G_A$ 。群组  $G_A$  对物品的特征值  $ij$  的绝对兴趣计算如下:

$$GA_{G_A}^{ij} = \lambda_1 \frac{c_{G_A}^{ij}}{C_{G_A}} + \lambda_2 \frac{b_{G_A}^{ij}}{B_{G_A}} + \lambda_3 \frac{s_{G_A}^{ij}}{S_{G_A}} \quad (4)$$

其中,  $C_{G_A}$  表示群组  $G_A$  的点击的物品总数;  $c_{G_A}^{ij}$  表示  $C_{G_A}$  中有特征值  $ij$  的物品总数;  $B_{G_A}$  表示群组  $G_A$  放入预选篮的物品数;  $b_{G_A}^{ij}$  表示  $B_{G_A}$  中含有特征值  $ij$  的物品数;  $S_{G_A}$  表示群组  $G_A$  感兴趣的特征值总数,  $s_{G_A}^{ij}$  表示群组  $G_A$  选择的兴趣领域中包含特征值  $ij$  的总数; 参数  $\lambda_k$  为权重因子,其中  $\lambda_1 + \lambda_2 + \lambda_3 = 1$ 。

则群组  $G_A$  对特征值  $ij$  的相对兴趣度计算如下:

$$GR_{G_A}^{ij} = \frac{GA_{G_A}^{ij}}{\frac{1}{|P|} \sum_{p \in P} GA_{G_A}^{ij}} \quad (5)$$

其中,  $P$  是用户集,  $|P|$  是  $P$  中用户的人数,  $GR_{G_A}^{ij}$  反映了用户组  $G_A$  相对于其他用户组对特征值  $ij$  的相对兴趣度。

步骤 3 构建用户模型

用户的特征模型由单个用户信息和群组信息构建而成。

$$IGR_A^{ij} = (\lambda_I \times IR_A^{ij}) + (\lambda_G \times GR_{G_A}^{ij}) \quad (6)$$

$\lambda_I$  和  $\lambda_G$  为权重因子。在本文的实验中,取权重因子  $\lambda_I$  和  $\lambda_G$  各为 0.5。在实际应用中,可根据实际问题的需要来确定权重因子  $\lambda_I$  和  $\lambda_G$  的值。在用户本身的信息比较稀疏时,可加大群组信息权重因子  $\lambda_G$  的值来充分利用群体信息。

综合所有用户对所有物品的用户模型,最终对用户  $A$  特征模型进行定义。

定义 2 用户  $A$  特征模型<sup>[12]</sup>

$$SP_A = (IGR_A^{ij}, i=1, \dots, I, j=1, \dots, K_i) \quad (7)$$

应该指出的是,对于给定的用户  $A$ ,他的群组  $G_A$  包含了多个其他的相似用户,而用户  $A$  也可能被包含于多个其他用户的群组中。但对于有关用户  $A$  的推荐,只参考其群组  $G_A$ 。

### 2.3 构造推荐模型

使用用户模型和物品模型产生推荐集,为用户  $A$  推荐的物品集计算如下<sup>[12]</sup>:

$$D_{A_m} = \| SP_A - CC_m \| = \sqrt{\sum_{ij} (IGR_A^{ij} - c_m^{ij})^2}, m=1, \dots, M \quad (8)$$

首先使用欧氏距离计算用户  $A$  和每个物品集的相似度,  $D_{A_m}$  越小,相似度越高。选取相似度最高的  $R_G$  个物品集。再从选取的每个物品集中,选取相似度最高的  $R_C$  个物品作为推荐物品。

### 3 基于时序的用户模型

随着用户和系统交互时间的增长,用户的兴趣会逐渐发生变化,较近的数据更能反应用户当前的兴趣。而传统的推荐算法没有考虑时间的有效性,对所有数据平等对待,一定程度上影响了结果的准确性。

为此,采用了滑动窗口模型,对长为  $L$  的最新的时片内的数据进行分析,假设当前时间为  $t$ ,则需处理的是  $t-L+1$  内的数据。为了方便计算和更新汇总信息,将长度为  $L$  的时片里的数据平均分为  $k$  段,每段长为  $l$  个单位时间。在任意时刻,算法保存  $k$  个数据段。在每一个数据段加入后,汇总统计用户的点击数、加入购物车数等信息,并用了 *logistic* 函数对汇总信息进行时间加权修正,将汇总信息保存到存储区中,同时去掉最“旧”的一个数据段。

*logistic* 函数为:

$$\text{logistic}(t) = \frac{1}{1 + e^{-t}} \quad (9)$$

其中,  $-1 \leq t \leq 1, 0 \leq \text{logistic}(t) \leq 1$ 。*logistic* 函数是单调递增函数<sup>[17]</sup>,加权值随着时间  $t$  的增加而增加,并始终保持在  $(0, 1)$  的范围内,本文使用标准化转换方法,将时间  $t$  的变化范围映射到  $[-1, 1]$ 。

为了计算  $IGR_A^j$ ,需要在每个时间段  $l$  保存的汇总信息为  $C_A(l_i), c_A^j(l_i), B_A(l_i), b_A^j(l_i), C_{G_A}(l_i), c_{G_A}^j(l_i), B_{G_A}(l_i), b_{G_A}^j(l_i)$ , 并为其加上时间权值。

则  $L$  长时段内汇总信息分别为:

$$C_A(L) = \text{logistic}(l_1) \times C_A(l_1) + \text{logistic}(l_2) \times C_A(l_2) + \dots + \text{logistic}(l_k) \times C_A(l_k) \quad (10)$$

$$c_A^j(L) = \text{logistic}(l_1) \times c_A^j(l_1) + \text{logistic}(l_2) \times c_A^j(l_2) + \dots + \text{logistic}(l_k) \times c_A^j(l_k) \quad (11)$$

$$B_A(L) = \text{logistic}(l_1) \times B_A(l_1) + \text{logistic}(l_2) \times B_A(l_2) + \dots + \text{logistic}(l_k) \times B_A(l_k) \quad (12)$$

$$b_A^j(L) = \text{logistic}(l_1) \times b_A^j(l_1) + \text{logistic}(l_2) \times b_A^j(l_2) + \dots + \text{logistic}(l_k) \times b_A^j(l_k) \quad (13)$$

$$C_{G_A}(L) = \text{logistic}(l_1) \times C_{G_A}(l_1) + \text{logistic}(l_2) \times C_{G_A}(l_2) + \dots + \text{logistic}(l_k) \times C_{G_A}(l_k) \quad (14)$$

$$c_{G_A}^j(L) = \text{logistic}(l_1) \times c_{G_A}^j(l_1) + \text{logistic}(l_2) \times c_{G_A}^j(l_2) + \dots + \text{logistic}(l_k) \times c_{G_A}^j(l_k) \quad (15)$$

$$B_{G_A}(L) = \text{logistic}(l_1) \times B_{G_A}(l_1) + \text{logistic}(l_2) \times B_{G_A}(l_2) + \dots + \text{logistic}(l_k) \times B_{G_A}(l_k) \quad (16)$$

$$b_{G_A}^j(L) = \text{logistic}(l_1) \times b_{G_A}^j(l_1) + \text{logistic}(l_2) \times b_{G_A}^j(l_2) + \dots + \text{logistic}(l_k) \times b_{G_A}^j(l_k) \quad (17)$$

每当满足一个时间单位  $l$  时,计算汇总信息,去掉最老的一个时片,增加最新的时片信息。然后根据用户行为,将当前最新的推荐结果提供给用户参考。每当经过一个  $L$  长的时片后,重新计算用户的最近邻居群组,以修改离线群组的信息。

### 4 算法框架

整个推荐过程分为离线阶段和在线阶段。离线阶段计算物品模型和用户的初始邻居群组。在线过程根据用户的行为建立用户模型,并随时间递进不断更新模型和邻居群组。

在线过程的算法描述如下。

输入:用户的最近邻居群和物品模型

输出:实时的推荐物品集

Begin

1.  $T=0$ ;

2. while 推荐过程没有结束 do

3.  $t=t+1$ ;

4. if  $t \bmod l = 0$  then 计算各时间段的汇总信息  $C_A(l_i), c_A^j(l_i), B_A(l_i), b_A^j(l_i), C_{G_A}(l_i), c_{G_A}^j(l_i), B_{G_A}(l_i), b_{G_A}^j(l_i)$ , 使用 *logistic* 函数赋予调节权重因子,更新汇总信息;

5. 将该时间段汇总信息加入时间段组中。如数据段个数大于  $m$ ,则去掉最旧的一个数据段信息;

6. 计算  $D_{Am}$ ,得到相似度较高的若干物品,产生推荐结果;

7. End while

End

### 5 实验

本文通过模拟实验的方法来验证算法的有效性。使用 ASP.NET 开发了一个图书推荐系统,在学生网上的选书系统中随机抽取 200 个用户的信息,该信息记录了用户选书过程中的行为,如点击查看行为、放入预选篮的行为数据等。

首先将文中提出的算法 TW\_RS\_IGB 与文献[12]提出的 RS\_IB、RS\_IGB 算法进行比较。3 种算法采用相同的物品描述模型,使用不同的用户模型。RS\_IB、RS\_IGB 在推荐时都没有考虑时间因素,RS\_IB 算法在构建用户模型时,只考虑了单个用户的行为信息。而本文提出的算法 TW\_RS\_IGB 在推荐时考虑了目标用户和邻居用户的信息,同时对汇总信息加入时间权重,能更好地反应用户当前的兴趣。

用户在选书前,可对书籍进行打分。选书时可分别使用 3 种推荐算法 RS\_IB、RS\_IGB、TW\_RS\_IGB。随机选择 200 名用户对 120 本图书进行选择。根据实验,本文设定参数的取值为:  $\lambda_1 = 0.3, \lambda_2 = 0.3, \lambda_3 = 0.4, \lambda_I = \lambda_G = 0.5, R_G = 5, R_C = 2, L = 30, l = 5$ 。在本文的实验中,取权重因子  $\lambda_I$  和  $\lambda_G$  各为 0.5。在实际应用中,可根据实际问题的需要来确定权重因子  $\lambda_I$  和  $\lambda_G$  的值。在用户本身的信息比较稀疏时,可加大群组信息权重因子  $\lambda_G$  的值以充分利用群体信息。

本文用分类准确度中的准确率、召回率、覆盖率作为衡量指标。准确率定义为  $P = \frac{N_{rs}}{N_s}$ ,它表示用户对系统推荐物品感兴趣的概率,  $P$  值越大表示推荐的准确率越高。召回率  $R = \frac{N_{rs}}{N_r}$ ,表示用户喜欢的物品被推荐的概率。推荐覆盖率表示系统能够为用户推荐的物品占有所有物品的比例。其定义为  $COV = \frac{N_s}{N}$ 。其中  $N_{rs}$  表示用户感兴趣的且推荐系统进行了推荐的物品数,  $N_s$  为系统推荐的物品数,  $N_r$  表示用户喜欢的物品总数,  $N$  为物品总数。

在不同规模的用户集上的实验结果如图 1、图 2 所示。




图 1 RS\_IB、RS\_IGB、TW\_RS\_IGB 算法的分类准确度比较(100 个用户)




图2 RS\_IB,RS\_IGB,TW\_RS\_IGB 算法的分类准确度比较(200个用户)

由图1、图2可以看出,在用户数为100和200时,本文提出的算法相比于另外两种算法推荐的准确度更高,这是因为TW\_RS\_IGB会根据用户的行为不断调整推荐结果,更能反应用户当前兴趣,因而有更好的推荐效果。

图3示出了用户数为100和200时,TW\_RS\_IGB算法的分类准确度随时间的变化图。从图中看出在时间点10到20之间有较大的提高,随后逐步提高,趋于平稳。这是因为初始阶段获取的用户行为信息较少,准确率随着用户的选择行为逐渐提高。




图3 TW\_RS\_IGB算法的分类准确度随时间的变化

表2比较了RS\_IB,RS\_IGB,TW\_RS\_IGB算法的覆盖率。TW\_RS\_IGB覆盖率最高,RS\_IGB次之,RS\_IB最低。表明TW\_RS\_IGB算法可以推荐更多的物品种类给用户。

表2 RS\_IB,RS\_IGB,TW\_RS\_IGB算法在不同用户数时覆盖率的比较

	RS_IB	RS_IGB	TW_RS_IGB
Coverage (%) (u=100)	12	18	35.6
Coverage (%) (u=200)	14	20	38.6

此外,比较本文算法和传统的协同过滤算法 UBCF 算法的性能。从图4可以看出,在不同推荐列表长度下,TW\_RS\_IGB算法都能获得比 UBCF 更好的性能。




图4 TW\_RS\_IGB与UBCF算法的比较(100个用户)

结束语 本文提出了一种基于时间加权的混合推荐算法(TW\_RS\_IGB)。该算法首先根据目标用户的年龄、职业等特征和历史评分信息等得到与目标用户邻居群组并构建物品描述模型。然后根据目标用户和邻居群组的选择行为构建用户描述模型。使用衰减系数强调用户最近的兴趣度,以提高推荐质量。在滑动窗口模型下,每隔一定时间,更新用户模型,产生个性化的推荐。实验结果表明,本文提出的算法相比其他推荐算法有更高的准确性。根据对算法(TW\_RS\_IGB)开发的图书推荐系统的使用,证明其能够帮助学生选择所感兴趣的图书,具有较好的推荐效果。

在用户模型非常稀疏时,使用欧氏距离会降低在用户间的区分度,在接下来的工作中,将进一步研究如何选择较好的用户相似度标准,使本方法有更广泛的应用范围。此外,将研究如何自适应地调整用户模型的参数设置,以进一步提高推荐效果。

## 参考文献

- [1] 许海玲,吴潇,李晓东,等. 互联网推荐系统比较研究[J]. 软件学报,2009,20(2):350-362
- [2] Schafer J B, Frankowski D, Herlocker J, et al. Collaborative filtering recommender system [C] // The Adaptive Web, Lect Notes Comput Sci. Berlin, Heidelberg: Springer-Verlag, 2007, 4321:91-324
- [3] Park T, Pennock D M. Applying collaborative filtering techniques to movie search for better ranking and browsing [C] // Proceedings of the 13th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, San Jose, California, United States, 2007:550-559
- [4] Ma H, King I, Lyu M R. Effective missing data prediction for collaborative filtering [C] // Proceedings of the 30th Annual International ACM SIGIR Conference, Amsterdam, The Netherlands, 2007:39-46
- [5] Deshpande M, Karypiws G. Item-based top-N recommendation algorithms [J]. ACM Transactions on Information Systems, 2004,22(1):143-177
- [6] 马宏伟,张光卫,李鹏. 协同过滤推荐算法综述[J]. 小型微型计算机系统,2009,30(7):1282-1288
- [7] Somlo G, Howe A. Adaptive light weight text filtering [J]. Proc Lecture Notes in Computer Science, 2001,2189:319-329
- [8] Pazzani M J, Billsus D. Content-based recommendation systems [C] // The Adaptive Web, Lect. Notes Comput Sci. Berlin, Heidelberg: Springer-Verlag, 2007, 4321:325-341
- [9] Balabanovic M, Shoham Y. Fab: content-based collaborative recommendation [J]. Communication of the ACM, 1997,40(3):66-72
- [10] Burke R. Hybrid recommender systems: Survey and experiments [J]. User Modeling and User-Adapted Interact, 2002,12(4):331-370
- [11] Yoshii K, Goto M, Komatani K, et al. An efficient hybrid music recommender system using an incrementally trainable probabilistic generative model [J]. IEEE Transactions on Audio Speech and Language Processing, 2008,16(2):435-447
- [12] Park Y J, Chang K N. Individual and group behavior-based customer profile model for personalized product recommendation [J]. Expert Systems with Applications, 2009,36(2):1932-1939
- [13] Min S H, Han I. Detection of the customer time-variant pattern for improving recommender systems [J]. Expert Systems with Applications an International Journal, 2005,28(2):189-199
- [14] Koren Y. Collaborative filtering with temporal dynamics [C] // Proc. of the ACM SIGKDD Conf. on Knowledge Discovery and Data Mining. ACM Press, 2009:89-97
- [15] Ren Y L, Zhu T Q, Li G, et al. Top-N recommendations by learning user preference dynamics [C] // In: Proc. of the Annual Conf. on Neural Information Processing Systems. Springer-Verlag, 2013:390-401
- [16] 孙光福,吴乐,刘淇,等. 基于时序行为的协同过滤推荐算法[J]. 软件学报,2013(11):2721-2733
- [17] 郑志高,刘京,王平,等. 时间加权不确定近邻协同过滤算法[J]. 计算机科学,2014,41(8):7-12