

一种融合信任和用户情感偏好的协同过滤算法^{*}

秦继伟^{1,2,3}, 郑庆华^{1,2}, 田锋¹, 王康¹

¹(智能网络与网络安全教育部重点实验室,陕西 西安 710049)

²(西安交通大学 计算机科学与技术系,陕西 西安 710049)

³(新疆大学 现代教育技术中心,新疆 乌鲁木齐 830046)

通讯作者: 郑庆华, E-mail: qhzeng@mail.xjtu.edu.cn, <http://www.xjtu.edu.cn>

摘要: 以调节用户情感为应用背景,为使资源满足用户情感需求,提出一种融合信任和用户情感偏好的协同过滤算法。首先,针对现有协同过滤中用户偏好模型扩展性不足的问题,提出融合评分和信任的用户偏好模型,依据评分数据集设定共同评分资源数目的阈值,有策略地选择用户间评分相似度和信任值,计算用户偏好程度;其次,定制资源的情感内涵特征,在资源集合生成过程中,通过引入用户对资源情感内涵的偏好度量机制,弥补了以往协同过滤推荐对用户情感的忽略。最后,实验结果表明,该算法有效地解决了协同过滤中用户偏好模型扩展性不足的问题,提高了分类准确度,增加了用户选中满意资源的机会。

关键词: 用户偏好;扩展性;情感;情感内涵

中文引用格式: 秦继伟,郑庆华,田锋,王康.一种融合信任和用户情感偏好的协同过滤算法.软件学报,2013,24(Suppl.(2)):61–72. <http://www.jos.org.cn/1000-9825/13024.htm>

英文引用格式: Qin JW, Zheng QH, Tian F, Wang K. Collaborative filtering algorithm integrating trust and preference of user's emotion. Ruan Jian Xue Bao/Journal of Software, 2013, 24(Suppl.(2)):61–72 (in Chinese). <http://www.jos.org.cn/1000-9825/13024.htm>

Collaborative Filtering Algorithm Integrating Trust and Preference of User's Emotion

QIN Ji-Wei^{1,2,3}, ZHENG Qing-Hua^{1,2}, TIAN Feng¹, WANG Kang¹

¹(Key Laboratory for Intelligent Networks and Network Security of Ministry of Education, Xi'an 710049, China)

²(Department of Computer Science and Technology, Xi'an Jiaotong University, Xi'an 710049, China)

³(Center for Educational Technology, Xinjiang University, Urumqi 830046, China)

Corresponding author: ZHENG Qing-Hua, E-mail: qhzeng@mail.xjtu.edu.cn, <http://www.xjtu.edu.cn>

Abstract: Taking user's emotion regulation as application background, this paper presents a collaborative filtering algorithm integrating trust and preference of user's emotion to meet user's emotional needs. Firstly, a user preference model based on ratings and trust is presented to address the scalability issue of user preference model in collaborative filtering. The proposed model uses the number of ratings to set two thresholds to extend the calculation strategy of user similarity weight to selectively assign the trust value and correlation to the rating value in the user preference model. Secondly, in the process of producing the candidate set of items, the emotional connotation of items is customized. The user preference for emotional connotation of item is introduced to make up for the neglect of user's emotions in collaborative recommendation. Experimental results show that the presented algorithm has good scalability and therefore improves user satisfaction.

Key words: user preference; scalability; emotion; emotion connotation

情感作为一种有社会属性的、复杂的心理过程,与理性思维、逻辑推理能力一起在决策中扮演着重要的角

* 基金项目: 国家自然科学基金(61221063, 91118005, 91218301); 国家科技支撑计划(2013BAK09B01); 国家高技术研究发展计划(863)(2012AA011003); 长江学者基金

收稿时间: 2012-06-30; 定稿时间: 2013-05-24

色。积极情感可以提高人们的积极性和思维认知能力,而负面情感会影响人们的动机、决策过程及记忆的水平。为了减弱甚至消除负面情感对人们在认知、决策等过程中的消极作用,如何调节负面情感,满足人们情感需求引起了研究者们的关注。在情景上下文中,为了满足用户情感需求,需要对用户情感需求进行评估,匹配资源。然而,面对大量特征相似或相近的资源,用户在资源选择上表现得不知所措,并且用户对资源特征的需求不易被识别,资源的元数据描述资源特征的方式很难满足用户情感需求,因此,需要根据用户情感需求定制个性化的资源的情感特征。作为一种信息过滤的手段,协同推荐系统通过挖掘、分析用户与用户、用户与资源、资源与资源之间的关系,使用户对资源模糊的需求明确化、形式化,为实现情感调节,满足用户情感需求提供了技术方法。

用户偏好是影响推荐算法质量高低的关键因素^[1]。作为最成熟的推荐技术,协同过滤推荐以用户的历史评分记录为依据,计算用户间评分的相似度,建立用户偏好模型。但当用户对推荐资源评分矩阵稀疏时,难以建立用户模型,会造成冷启动问题而无法有效完成资源推荐。虽然,以信任值取代用户评分相似度作为偏好权重,在一定程度上缓解了冷启动问题。但现有基于信任建立的偏好模型顾此失彼,一方面考虑了用户信任关系,另一方面又忽略了用户评分对用户偏好模型构建的影响。因此,在建立用户偏好时需要一种策略,综合考虑用户间的信任值和用户对资源的评分,在解决冷启动问题的同时有效提升用户偏好模型的扩展性。

本文以用户负面情感调节为问题背景,针对用户情感的需要,提出融合信任和用户情感偏好的协同过滤算法。首先,借鉴用户普遍的认知心理,将信任作为用户选择的一个重要因素,同时强调对客观评分的动态处理,建立用户偏好模型。从用户情感需求角度来看,定制资源的情感内涵特征能够反映用户对资源的偏好,因此可以此作为资源推荐集合生成的依据。在公用数据集 Epinions 和数据集 EC 上的实验结果表明,与传统协同过滤推荐以评分建立用户偏好和基于信任推荐以信任关系建立用户偏好相比,融合评分和信任建立用户偏好,有策略地依据共同评分的资源数目计算用户偏好程度,能够适应数据集类型及稀疏程度的变化,保证了推荐的准确率,同时有效地提升了推荐的覆盖率,具有较强的扩展性;在数据集 EC 上的实验结果表明,推荐集生成过程中考虑了用户对资源的情感内涵的偏好,提高了推荐资源的分类准确度,增加了用户选中满意资源的机会。

本文第1节介绍相关工作的研究进展。第2节给出相关定义以及融入信任和用户情感偏好的协同过滤算法的实现过程。第3节通过实验验证所提算法的性能并进行分析。第4节对全文进行总结并提出下一步工作计划。

1 相关工作

1997年 Resnick 和 Goldberg^[2]为解决推荐问题,肯定了用户间相似性,提出了“兴趣偏好(profile of interesting)”(即用户偏好),并将其正式引入到推荐系统之中。典型的有:Breese 等人^[3]使用聚类(clustering)建立用户偏好模型,由 EM 算法学习得到聚类模型的参数,进一步提出贝叶斯网络(Bayesian network)方法对用户间相似关系建模。Heckerman^[4]等人提出用依存网络,在贝叶斯网络的基础上,用图表示用户间相似的概率。Hofmann^[5]等人将用户间存在的一些潜在变量引入到用户偏好模型,提出用潜在语义方法分析用户偏好关系。最近邻方法(nearest-neighbor method)^[6]直接采用相关度公式计算用户间相似性,建立用户偏好模型,成为最成功的推荐建模技术之一^[3]。随着分类技术的不断完善,用户偏好模型趋于成熟,但同时分类技术面临着无法克服推荐过程中出现的冷启动问题这样的困难。信任作为用户对推荐者推荐资源的满意程度的一种期望,取代了传统推荐用户之间偏好的相似权重,在某种程度上解决了冷启动问题^[7]。文献[8]指出,基于信任的朋友或熟人的推荐比传统的基于评分的推荐,更符合用户的需要,并指出综合评价会优于仅基于信任的评价,因为在推荐过程中,综合评价可能会发现一些珍稀的资源。

在情感推荐方面的研究包括:Park 等人^[9]基于模糊向量对温度、噪音、天气等上下文信息进行预处理,利用贝叶斯网络推理用户当前情感状态的概率,结合效用理论,预测用户在该状态下对音乐的偏好。Cai 等人^[10]将歌曲标题与歌词(或评论)与 Web 内容通过情感关联起来,建立概率模型(emotional allocation modeling),依据 Web 文本内容推荐相应的歌曲。尽管目前在用户情感推荐研究方面还未有公共数据集,但已有文献^[11]表明,音乐蕴含着情感内涵,作为诱导情感方式不仅具有娱乐作用,同时还具有增强或者减弱听者情感的功能,得到研究者的普遍认同。因此,音乐常被用作与用户情感有关的研究。

毋庸置疑,上述研究成果有效地推动了推荐系统的发展,并被成功地应用到情感推荐的研究之中。然而,通过深入分析我们不难发现,现有用户偏好模型未考虑到实际应用中评价数据扩展的可能,无法适应评价数据集类别的动态变化,用户偏好模型缺乏可扩展性。具体表现为:基于评分构建的用户偏好模型,仅适用于存在用户评分的推荐数据集,忽略了用户间的信任关系;而当以用户间信任值构建用户偏好模型时,有两种方式:以评分为基础构建用户间信任网络,或者直接将用户间信任值作为用户偏好程度。前者无法回避基于评分构建偏好中出现的冷启动问题,并且计算复杂;后者却忽略了评分对偏好模型建立的影响。此外,通过以上已有应用分析^[9,10]可以看出,音乐作为一种情感的载体,在推荐中未考虑用户对音乐情感内涵的偏好。因此,本文以满足用户情感需要为目的,针对以上问题,提出融合信任和用户情感偏好的协同过滤算法,以用户情感为上下文,采用最近邻建模的思路,通过设置共同评分资源数目的阈值,有策略地选择用户评分相似度、用户间信任值,使所提用户偏好模型不仅适用于只存在用户评分或者信任关系的数据集,而且适用于同时存在用户评分和信任关系的数据集,克服了现有协同过滤推荐中用户偏好模型扩展性不足的问题,并以音乐作为推荐资源,考虑了用户对音乐情感内涵的偏好。

2 融合信任和用户情感偏好的协同过滤算法

融合信任和用户情感偏好的协同过滤算法(a collaborative filtering algorithm integrating trust and preference of user's emotion,简称CFTE)是以用户情感为上下文的协同推荐系统,着重强调如何构建用户偏好,如何定制资源的情感内涵特征,满足用户情感需求,实现个性化资源推荐。CFTE 算法的实现过程与传统协同过滤推荐的区别在于,融入了用户情感信息,结合评分和信任建立用户偏好关系。因此,情感信息描述与分析是 CFTE 研究的基础,构建具有扩展性的用户偏好模型成为研究的核心。

2.1 相关定义

定义 1(情感). 它是用于描述某一具体场景下用户情感状态的信息,可以表示为 E_1, E_2, \dots, E_Q , 其中 Q 是情感类别的数目。如果用户 u_a 和 u_b 的情感状态分别是 $u_a^{E_x}$ 和 $u_b^{E_y}$, 有 $E_x = E_y$, 且 $1 \leq x, y \leq Q$, 则用户 u_a 和 u_b 处在同一情感。

定义 2(资源的情感内涵). 从激发用户情感、满足用户情感需求的角度,描述资源所具有的情感特性。与定义 1 中表示相同,可表示为 E_1, E_2, \dots, E_Q 。同样地,如果资源 I_i 和 I_j 的情感内涵为 $I_i^{E_x}$ 和 $I_j^{E_y}$, 有 $E_x = E_y$, 且 $1 \leq x, y \leq Q$, 则资源 I_i 和 I_j 具有相同的情感特征。

定义 3(信任). 它是信任者对被信任者的期望,认为被信任者有义务、有能力协助信任者在推荐产生过程中满足信任者的意愿,选到满意的资源。 $T \in [0,1]$, $T(u_a, u_b) = 0$ 表示用户 u_a 和 u_b 不存在信任关系, $T(u_a, u_b) = 1$ 表示用户 u_a 完全信任 u_b 。

定义 4(推荐质量决策函数). 设用户对资源的评价 R 有 h 个等级 r_1, r_2, \dots, r_h , 设 $L = \{l_1, l_2\}$ 为系统提供的推荐资源与质量的相关程度,其中, l_1 表示不相关资源, l_2 表示相关资源,则 L 和 R 之间的推荐质量决策函数为

$$\Phi(R) = \begin{cases} l_1, & r_1 \leq R \leq r_f \\ l_2, & r_f \leq R \leq r_k \end{cases} \quad (1)$$

这里,质量等级的分界点由推荐系统的评分等级确定,例如,某推荐系统的评分等级为 5 分制,分别为 1,2,3,4,5,设 $r_f=3$,当推荐资源的评分值 $r>3$ 时,则表示该资源与推荐质量相关,否则不相关。

定义 5(用户情感偏好). 它是用户 u_a 在 E_x 情景下对推荐的相关资源情感内涵的偏好,表示为

$$PEI = \frac{N_{l_2}^P - N_{l_2}^N}{N_{l_2}}, PEI \in [-1, 1],$$

其中, N_{l_2} 表示 u_a 在 E_x 情景下相关资源的总数, $N_{l_2}^P$ 表示相关资源中蕴含正面情感的资源数目, $N_{l_2}^N$ 表示相关资源中蕴含负面情感的资源数目。例如, u_a 在某一情感下,选择正面情感的资源数目是 5, 负面情感的资源数目是 2,

则 $PEI=0.43$.

2.2 CFTE算法

CFTE 算法遵循协同过滤推荐的基本流程,考虑到用户对资源情感内涵的偏好,基本流程包括 4 个阶段:建立用户偏好(user's preference)、预测评分(ratings prediction)、计算用户对资源情感内涵的偏好(user's preference for emotional connotation of item,简称 PEI)及产生推荐资源集(candidate set of item),如图 1 所示.

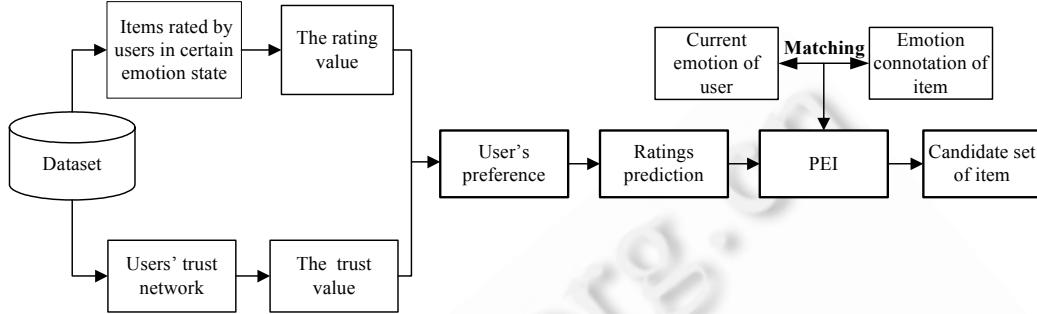


Fig.1 The work flow of CFTE

图1 CFTE算法的实现流程

CFTE 数据集中可以包含两部分数据,即用户在某种具体情感下对资源的评分和用户间的信任值.其中,用户对资源的评分数据是一个三维数据空间:用户、情感和资源,我们采用 reduction-based 方法减少情感^[12]维度,即若 $E=E_x, \forall (u,i,e) \in U \times I \times E$, 则 $R_{User \times Item \times Emotion}^H : U \times I \times E \rightarrow rating$ 转化为 $R_{User \times Item}^{H[Emotion=E_x]} : U \times I \rightarrow rating$, 将评分数据的三维数据空间转换为传统协同过滤推荐中评分数据的二维模型.同时,用户根据用户间社会关系、推荐中历史交互行为^[13]直接给出用户间的信任值.

(1) 建立用户偏好

用户偏好反映了用户之间对资源的喜好或感兴趣程度.CFTE 将信任作为用户决策选择时的一个主观概念,结合用户评分共同决定用户之间的偏好关系.其中,评分用来评价用户之间建立在共同评分基础上的相似程度,信任值表示用户间的信任程度.基于评分相似度和信任值构建用户偏好模型,通过设置共同评分资源数目的上、下限阈值,有选择地利用评分相似度值和信任值,计算用户偏好程度,如公式(2)所示:

$$\omega(u_a, u_b) = \begin{cases} T(u_a, u_b), & n \leq N_1 \\ \frac{n}{N_2} P(u_a, u_b) + \left(1 - \frac{n}{N_2}\right) T(u_a, u_b), & N_1 < n < N_2 \\ P(u_a, u_b), & n \geq N_2 \end{cases} \quad (2)$$

其中, n 是用户 u_a 和 u_b 推荐交互过程中所有共同评价的资源总数, N_2 和 N_1 分别是用户间共同评价资源数目的上、下限阈值, $T(u_a, u_b)$ 表示 u_a 和 u_b 间的信任值, $P(u_a, u_b)$ 是用户间共同评分的相似度.Pearson 相关因子被用来计算基于评分的用户间相似程度^[14],如果 $R_{a,i}$ 表示用户 u_a 对资源 I_i 的评分, I_{ab} 表示用户 u_a 和用户 u_b 共同评价过的资源集合, \bar{R}_a 表示用户 u_a 评价过资源的评分平均值,则 $P(u_a, u_b)$ 的计算方法如式(3)所示:

$$P(u_a, u_b) = \frac{\sum_{i \in I_{ab}} (R_{a,i} - \bar{R}_a) \times (R_{b,i} - \bar{R}_b)}{\sqrt{\sum_{i \in I_{ab}} (R_{a,i} - \bar{R}_a)^2} \sqrt{\sum_{i \in I_{ab}} (R_{b,i} - \bar{R}_b)^2}} \quad (3)$$

融合评分和信任的用户偏好模型,具体实现流程如图 2 所示.若 $n \leq N_1$,表示用户 u_a 和 u_b 共同评价的资源数目太少,无法根据评分评估用户之间的偏好程度,因此采用用户 u_a 和 u_b 间信任值 $T(u_a, u_b)$ 来评估用户间偏好关系.若 $N_1 < n < N_2$,用户间共同评分的资源数目不充分,则 $P(u_a, u_b)$ 不足以直接评估 $\omega(u_a, u_b)$,需要考虑 $T(u_a, u_b)$.若 $n \geq N_2$,用户间共同评分的资源数目足以判断用户间偏好关系,因此, $P(u_a, u_b)$ 直接被用来取代

$\omega(u_a, u_b)$. 特别地,如果用户 u_a 和 u_b 的信任值 $T(u_a, u_b) = 0$, 取 $N_2=n$, 此时,融合评分和信任的用户偏好模型转化为基于评分构建用户偏好关系,由评分相似度 $P(u_a, u_b)$ 直接作为用户间偏好程度;如果用户 u_a 和 u_b 之间不存在共同评分,即 $n=0$,融合评分与信任的用户偏好模型转化为基于信任的用户偏好模型,则 $T(u_a, u_b)$ 将作为用户间偏好程度.

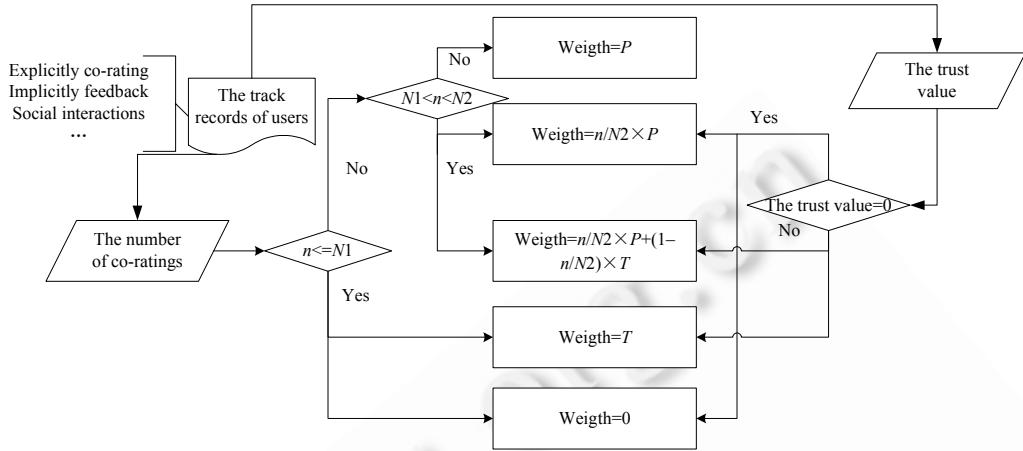


Fig.2 The user preference based on trust value and similarity of ratings

图 2 基于评分相似度和信任值的用户偏好

(2) 预测评分

利用目标用户邻居对资源的评分和目标用户与邻居的偏好程度,预测目标用户对待评价资源的评分.假设 u_a 为目标用户, N_a 为邻居集合,则 u_a 对资源 I_j 的预测评分为 $P_{a,j}$, 其计算公式如下所示:

$$P_{a,j} = \bar{R}_a + \frac{\sum_{u_b \in N_a} \omega(u_a, u_b) \times (R_{b,j} - \bar{R}_b)}{\sum_{u_b \in N_a} |\omega(u_a, u_b)|} \quad (4)$$

(3) 计算用户对资源情感内涵的偏好

为了提高用户满意资源被推荐的概率,CFTE 通过目标用户对推荐资源的历史反馈评价,分析目标用户对资源情感内涵的偏好,计算目标用户的 PEI(见定义 5).例如,当目标用户处于 Anxiety 时,分析用户在 Anxiety 下评分历史记录,从用户满意的推荐资源中分别确定蕴含正面情感和负面情感的资源数目,计算得到用户对资源情感内涵的偏好程度 PEI.PEI 越接近-1,表明在 Anxiety 下,此用户越喜欢含有负面情感的资源;而其值越接近 1,则表明在 Anxiety 下,此用户越喜欢含有正面情感的资源.

(4) 产生推荐集

最后,系统将计算得到的预测评分与 PEI 相结合,产生目标用户的推荐集合.若 Z 为最终推荐集合列表长度,与传统协同推荐生成推荐集合仅按照预测评分排序,输出最大的前 Z 个资源不同,CFTE 将根据 PEI 对已按照评分值排序的资源进行筛选,在当前情感状态下选取适合用户资源情感推荐的 $Z(1+PEI)/2$ 个蕴含正面情感的资源和 $Z(1-PEI)/2$ 个蕴含负面情感的资源.其中, $Z(1+PEI)/2$ 是所有预测资源中按预测评分排序的前 $Z(1+PEI)/2$ 个蕴含正面情感的资源.

整个推荐算法的具体实现过程如下所示:

算法 1. CFTE.

输入: 评价数据矩阵 R , 信任值矩阵 TR , 用户集合 $U = (u_1, \dots, u_i, \dots, u_n)$ 及当前用户 u_a , 资源集合 $I = (I_1, \dots, I_i, \dots, I_m)$, 评分上、下限阈值 N_2, N_1 ;

输出: Z 个资源组成的推荐列表.

步骤:

```

1) If  $u_a^E = u_a^{E_x}$ ,  $R_{User \times Item}^{H[Emotion=E_x]} : U \times I \rightarrow rating$  //发现  $E_x$  下所有用户评分;
2) For  $k=1$  to  $q$  do  $n = count(r_{a,i}, r_{b,i}), i \in [1, m]$  //计算用户  $u_a$  与其他用户  $u_b$  间的共同评分数目;
3)  $P(u_a, u_b) = \frac{\sum_{i \in I_{ab}} (R_{a,i} - \bar{R}_a) \times (R_{b,i} - \bar{R}_b)}{\sqrt{\sum_{i \in I_{ab}} (R_{a,i} - \bar{R}_a)^2} \sqrt{\sum_{i \in I_{ab}} (R_{b,i} - \bar{R}_b)^2}}$  //计算  $u_a$  与其他用户  $u_b$  间的评分相似度;
3.1. If  $n \leq N_1$ , then  $(u_a, u_b) = T(u_a, u_b)$ ;
3.2. If  $N_1 < n < N_2$ , then  $(u_a, u_b) = \frac{n}{N_2} P(u_a, u_b) + \left(1 - \frac{n}{N_2}\right) T(u_a, u_b)$ ;
3.3. If  $n \geq N_2$ , then  $(u_a, u_b) = P(u_a, u_b)$ ;
4)  $P_{a,j} = \bar{R}_a + \frac{\sum_{u_b \in N_a} \omega(u_a, u_b) \times (R_{b,j} - \bar{R}_b)}{\sum_{u_b \in N_a} |\omega(u_a, u_b)|}$  //预测  $u_a$  对未评价资源  $I_j$  的评分;
5)  $Z = (1+PEI)/2 + Z(1-PEI)/2$  //根据定义 5 计算 PEI, 结合 top-n 原则, 产生推荐集合;
6) 输出  $Z$  个资源.

```

3 实验及结果分析

本节通过两组实验验证 CFTE 算法的有效性并对结果进行分析和评价. 其中, 第 1 组实验为用户偏好扩展性实验及评价. 在不同数据集(Epinions 和 EC)上, 依据评价指标, 对比传统协同过滤(CF)中依据共同评分建立用户偏好、基于信任推荐(TR)中依赖信任值建立用户偏好, 验证本文提出的融合评分和信任的用户偏好模型的扩展性. 第 2 组实验为 PEI 有效性实验与评价, 在 EC 数据集上, 分别运行有、无 PEI 部分的推荐算法, 通过对评价指标的结果进行分析, 验证 PEI 对推荐效果的影响.

3.1 数据集

实验所用数据集 Epinions 由 Massa 和 Avesani^[15] 提供, 爬取自“Epinions.com”的网站. Epinions.com 中有用户对商品的评分(1 分~5 分), 用户可以标签信任的用户, 建立信任列表和不信任列表, 信任值取值为 {0,1}. 该数据集有 49 290 个用户和 139 738 个商品, 有 487 181 个信任评价, 评分矩阵稀疏度为 99.99135%, 这意味着在用户与商品评分矩阵中, 99.99135% 的元素是空值.

本文所提算法的应用场景来源于实际应用, 针对 e-Learning 下用户的负面情感, 以音乐作为推荐资源对用户进行情感调节, 提高用户的学习效率. 前期研究统计结果显示, 情绪学习过程中用户情感负面情感主要有: 焦虑(anxiety)、厌恶(disgust)、悲伤(sadness)、羞愧(shame)、生气(anger)、失望(hopelessness)这 6 类, 以这 6 类负面情感作为用户情感状态, 音乐作为推荐资源. 为了获取实验数据集(the dataset of emotion compensation, 简称 EC), 我们搭建了基于用户情感的音乐推荐实验平台, 含有音乐 1 268 首. 基于此平台, 用户评分总数是 8 684 次, 评分采用 5 分制, 取值为 1~5 的整数, 评分矩阵稀疏度为 51.2%; 用户间信任取值为 [0,1].

3.2 用户偏好扩展性实验及评价

用户偏好扩展性代表了用户偏好模型对评价数据集变化的适应能力, 主要体现在依据评价数据集的类型、稀疏程度提供策略, 建立可扩展的用户偏好模型. 扩展性强的用户偏好模型能够在评价数据集发生变化的情况下仍然能为用户提供满意的推荐资源.

(1) 评价指标

一般而言, 推荐质量从推荐的准确程度和覆盖程度两方面来加以衡量. 其中, 准确度是推荐准确性的度量, 包括预测评分准确度和分类准确度. 这里, 我们使用预测评分准确度, 它通过计算预测的用户评分与实际的用户评分之间的偏差来度量预测的准确性, 值越小, 误差越小, 推荐精度越高, 如平均绝对偏差(mean absolute error, 简称 MAE)、平均平方误差(mean squared error, 简称 MSE)和均方根误差(root mean squared error, 简称 RMSE); 覆盖率是对推荐系统的覆盖程度的度量, 包括评分覆盖率(rating coverage, 简称 RC)和用户覆盖率(user coverage,

简称 UC).下面给出实验所用指标的计算方法:

1) 准确度

若 $\{p_1, p_2, \dots, p_n\}$ 表示预测评分集合, $\{r_1, r_2, \dots, r_n\}$ 表示实际评分集合, 则有,

$$MAE = \frac{\sum_{1 \leq i \leq n} |p_i - r_i|}{N} \quad (5)$$

$$MSE = \frac{\sum_{1 \leq i \leq n} (p_i - r_i)^2}{N} \quad (6)$$

$$RMSE = \sqrt{\frac{\sum_{1 \leq i \leq n} (p_i - r_i)^2}{N}} \quad (7)$$

$$MAUE = \frac{\sum_{u_i \in U} AUE_{u_i}}{M} \quad (8)$$

其中, $AUE_{u_i} = \frac{\sum_{1 \leq i \leq n} |p_i - r_i|}{N}$, 算法对用户 u_i 的预测评分集合表示为 $\{p_1, p_2, \dots, p_n\}$, 对应的用户 u_i 的实际评分集合为 $\{r_1, r_2, \dots, r_n\}$.

2) 覆盖率

设所有用户评分的数量为 S , 其中, 算法可以进行预测的评分数量为 P , 则有

$$RatingCoverage = \frac{P}{S} \quad (9)$$

设用户总数为 M , 算法可以为其预测至少一个评分的用户数量为 F , 则有

$$UserCoverage = \frac{F}{M} \quad (10)$$

(2) 用户偏好扩展性实验及评价

实验目的是对基于评分和信任的用户偏好模型的扩展性进行验证.为了与 CF 中基于评分相似度的偏好模型、TR 中基于信任值的偏好模型进行对比, 基于评分和信任的偏好模型的协同推荐(RTR)不考虑图 1 中 PEI 部分.RTR 推荐过程与 CF、TR 类似, 在推荐集合产生过程中忽略 PEI 的影响, 仅考虑预测评分值的大小; 在整个推荐过程中, 保证 CF, TR 和 RTR 这 3 种算法仅存在偏好模型上的差异. 在不同数据集上, 分别运行 CF, TR 和 RTR, 根据准确度和覆盖率的结果来反映基于评分和信任的用户偏好模型的扩展性.

1) 参数设置

基于评分和信任的用户偏好模型针对数据集的类型和稀疏程度, 需要合理地设置用户间共同评分资源数目的上、下限阈值. 分别在 Epinions 和 EC 数据集上, 运行 RTR, 上、下限阈值(N_2, N_1)的取值变化会引起误差(MAE, MAUE, MSE, RMSE)和覆盖率(coverage)的变化, 选取其中误差最小、覆盖率最大时所对应的 N_1 和 N_2 .

• Epinions 数据集

Epinions 数据集上 N_2 值的确定. 因为只有当用户间共同评分的资源数目大于或等于 2 时, 存在 $P(u_a, u_b)$ (见公式(3)), 由此我们假定上限阈值 N_2 从 2 开始取值, 逐步增加至 30, 下限阈值不变化($N_1=0$), 实验结果如图 3 所示. N_1 确定的情况下, 误差随着 N_2 的增加呈现出先减后增的趋势, 当 $N_2=16$ 时, 误差达到最小; 同时, 随着 N_2 的增加, 覆盖率无变化, 是因为在信任值 $T(u_a, u_b)$ 不变的情况下, N_2 的变化不会引起 $P(u_a, u_b)$ 及 $\omega(u_a, u_b)$ 是否存在的变化, 进而不会引起覆盖率的变化. 在此数据集上, 取 $N_2=16$ 为共同评分资源数目的上限阈值.

Epinions 数据集上 N_1 值的确定. 因为 $N_1 < N_2$, 所以下限阈值 N_1 从 0 开始取值, 逐步增加至 15, 实验结果如图 4 所示.

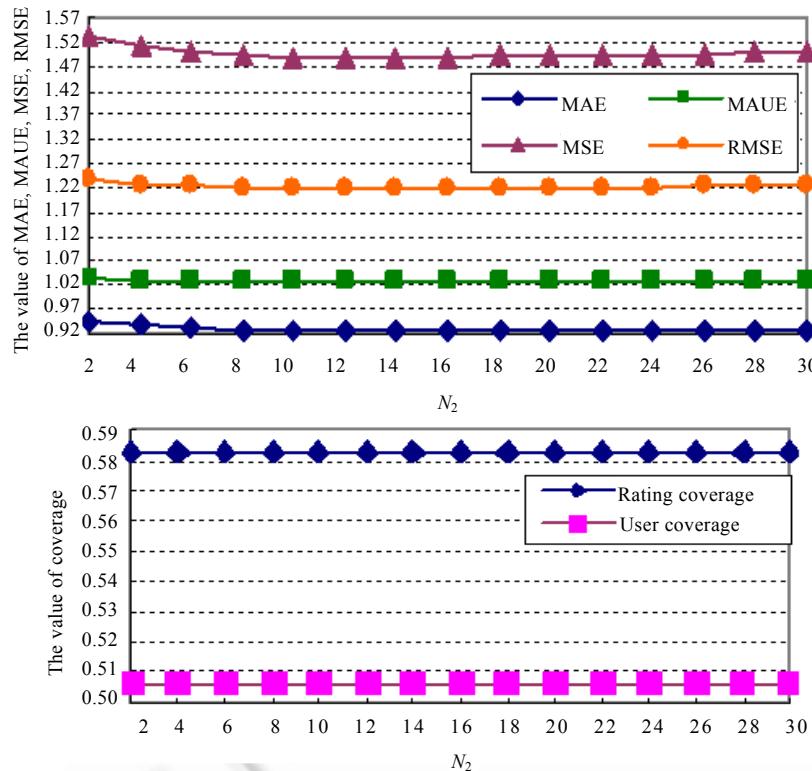


Fig.3 The experimental results of different upper threshold on Epinions

图3 Epinions数据集上不同上限阈值的实验结果

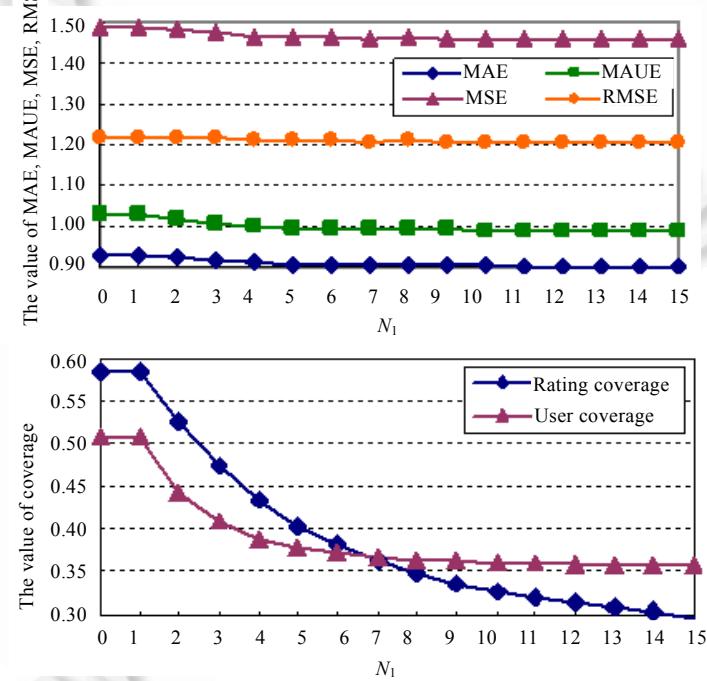


Fig.4 The experimental results of different lower threshold on Epinions

图4 Epinions数据集上不同下限阈值的实验结果

N_2 确定的情况下,误差和覆盖率随着 N_1 的增加呈现逐步降低的趋势.分析可知,在 $T(u_a, u_b)$ 不变的情况下, N_1 越大,计算 $P(u_a, u_b)$ 时可用共同评分资源的数目就越多,可靠性就越高.所以,随着 N_1 的增加,误差逐步降低.同时, N_1 越大,满足共同评分资源的数目大于 N_1 的用户数目将减小,覆盖率逐渐降低, $N_1=0$ 时,覆盖率最大.

在 Epinions 数据集上,当 $N_1=0, N_2=16$ 时,在保证推荐算法准确度的情况下,推荐覆盖率最大,推荐质量最好.

• EC 数据集

EC 数据集上 N_2 值的确定.假定下限阈值不变化($N_1=0$), N_2 从 2 开始取值,逐步增加至 30,如图 5 所示.当 $N_2=2$ 时,误差最小,随着 N_2 的增加,误差无变化,直至大于 10 后,误差逐渐增加,覆盖率无变化.

EC 数据集上 N_1 值的确定. $N_1 < N_2$,由公式(2)可知, $N_1=0$ 或 $N_1=1$ 不影响 $P(u_a, u_b)$ 存在的变化,从而不会影响覆盖率的变化.因此,在 EC 数据集上,当 $N_1=0$ 且 $N_2=2$ 时,推荐的准确度、覆盖率最高.

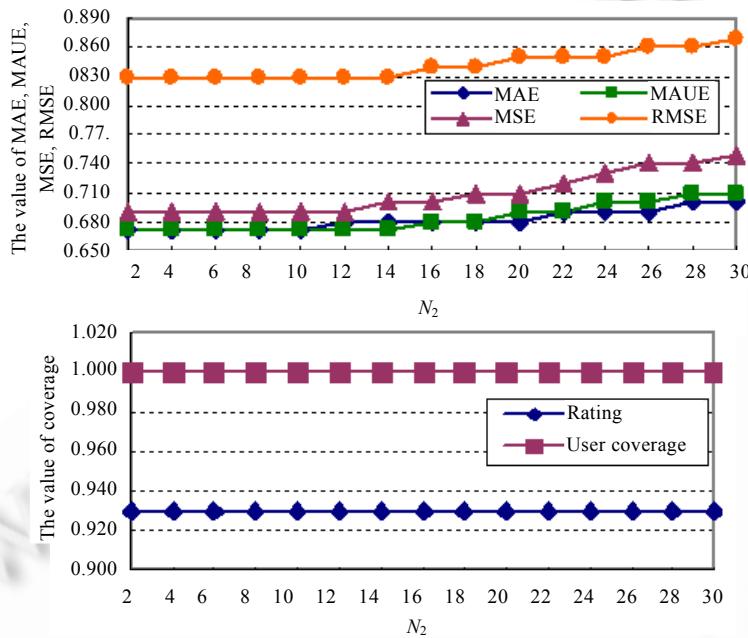


Fig.5 The experimental results of different upper threshold on EC

图5 EC数据集上不同上限阈值的实验结果

对以上在不同稀疏程度数据集上,共同评分资源数目上、下限阈值(N_2, N_1)的实验结果分析可以得出, N_2 的取值与覆盖率无关;随着下限阈值 N_1 的增加,推荐准确性提高,同时造成覆盖率降低.

2) 扩展性评价

在不同数据集上,利用不同用户偏好模型的推荐算法所产生的评价结果,反映出本文所提用户偏好模型的扩展性.在 Epinions 和 EC 数据集上运行 RTR,CF 和 TR,准确度和覆盖率结果如图 6、图 7 所示.由图 6 所示的比较结果可以看出,在评分稀疏度大的数据集 Epinions 上,在准确度方面,RTR 和 TR 推荐的准确度高于 CF, RTR 略逊 TR;在覆盖率方面,RTR 推荐覆盖率明显优于 TR 和 CF.说明在评分稀疏度大的数据集上,CF 受冷启动用户的影响,准确度有所下降;TR 改善了冷启动问题,却在覆盖率方面表现较差;而 RTR 基于本文所提模型,在保证准确度的情况下,覆盖率得到大幅度的提升.分析图 7 的比较结果:在评分稀疏度较小的数据集 EC 上,在准确度方面,RTR 和 CF 推荐的准确度高于 TR;在覆盖率方面,RTR,TR 优于 CF.说明在评分稀疏度较小的数据集上,利用共同评分计算用户偏好程度能够保证推荐的准确性,却无法改善推荐的覆盖率;基于信任建立用户偏好关系在一定程度上缓解了新用户问题,提高了覆盖率,但无法保证推荐的准确性;本文基于评分和信任的用户偏好模型,在准确度和覆盖率方面均表现出良好的性能.

由以上结果分析可知,随着数据集稀疏程度的变化,RTR 中基于评分和信任的用户偏好模型在保证准确率

的同时覆盖率得到大幅度的提升,表现出良好的性能.此外,CF 中基于评分的用户偏好模型的建立完全依赖于共同评分仅适用基于评分反馈的推荐系统;类似的 TR 推荐中基于信任的用户偏好模型依赖于信任值仅适用于存在信任关系的推荐系统;而基于评分和信任的用户偏好模型同时适用于基于信任、评分反馈及两者融合的推荐系统.本文所提融合评分和信任的用户偏好模型能够适应数据集类别及稀疏程度的动态变化,具有较强的扩展能力.

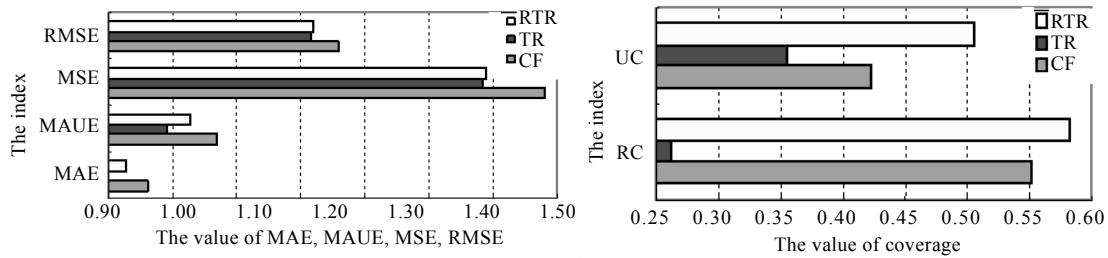


Fig.6 The evaluation of CF, TR, RTR on Epinions

图6 不同用户偏好模型在数据集Epinions上的实验结果

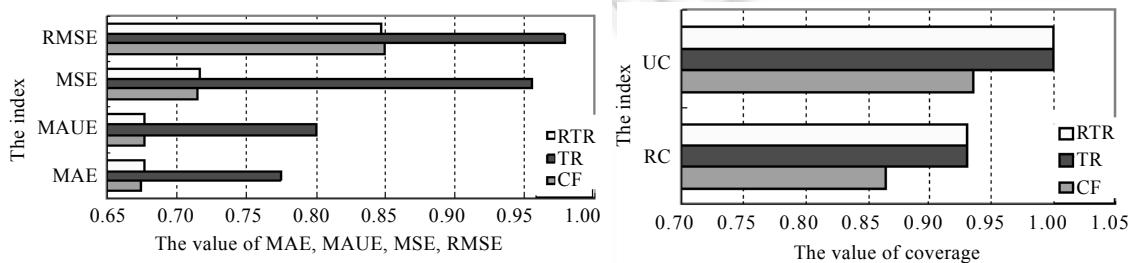


Fig.7 The evaluation of CF, TR, RTR on EC

图7 不同用户偏好模型在数据集EC上的实验结果

3.3 PEI有效性实验与评价

3.3.1 评价指标

如图 1 所示,推荐预测评分产生后,PEI 结合预测评分为用户产生推荐资源集合,改变了已有推荐技术仅按照资源预测评分进行排序产生推荐候选集的方式. PEI 作用于预测评分之后,上述预测评分的准确度(MAE 等)、覆盖率(coverage)等不能有效反映 PEI 在推荐算法中的作用. 我们采用分类准确度来评估 PEI 对推荐准确度的影响,分类准确度的指标包括准确率(precision)、召回率(recall)和 F_1 ,其中,准确率是用户对系统推荐资源感兴趣的概率,召回率表示一个用户喜欢的资源被推荐的概率、 F_1 指标综合考虑 Precision 和 Recall. 利用式(1)中决策函数 $\phi(R)$,设感兴趣资源评分为 I_2 ,将推荐资源分为 4 类,见表 1,则 Precision,Recall 和 F_1 的计算方法如下所示:

$$\text{Precision} = \frac{N_{ir}}{N_{ir} + N_{ur}} \quad (11)$$

$$\text{Recall} = \frac{N_{ir}}{N_{ir} + N_{in}} \quad (12)$$

$$F_1 = \frac{2\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (13)$$

Table 1 Showing the categorization of items

表1 资源分类

	Recommended	Not recommended
Interesting	N_{ir}	N_{in}
Uninteresting	N_{ur}	N_{un}

3.3.2 PEI 有效性

公共数据集 Epinions 中资源没有情感内涵的特征标签,不能满足 PEI 有效性实验数据的要求.为此,本组实验在数据集 EC 上进行验证.比较 CFTE 算法与 RTR(未考虑 PEI)算法在数据集 EC 上结果,Precision,Recall, F_1 的值越大,推荐列表中用户感兴趣的资源就越多,从而反映了 PEI 的有效性.

在 6 种负面情感下,推荐列表长度($Z=10$),分别执行 CFTE 算法与 RTR 算法,比较 Precision,Recall 和 F_1 指标的值,如图 8 所示,执行 CFTE 算法后产生的 3 个指标值都大于 RTR 算法上的指标值,CFTE 分类的准确度高于 RTR.因此,在资源推荐过程中考虑 PEI,提高了推荐资源分类的准确度,增加了用户选中满意资源的机会,因此,CFTE 算法优于 RTR 算法.

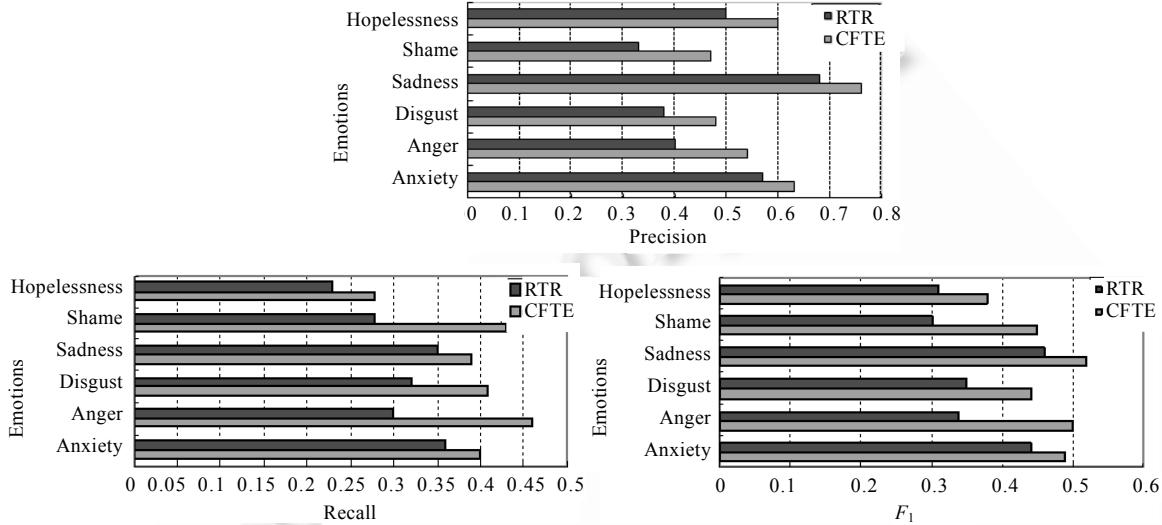


Fig.8 The evaluation of PEI

图 8 PEI 的评估

4 结 论

本文提出了一种融合信任和用户情感偏好的协同过滤算法.该算法依据评分稀疏程度,设定共同评分资源数目的上、下限阈值,有策略地选择评分相似度和信任值计算用户偏好程度,克服了已有模型对评价数据稀疏程度、类别等动态变化适应能力不足的问题.同时,引入 PEI 概念,建立了基于 PEI 的用户对资源的偏好模型,用来解决已有协同推荐系统中对用户情感忽略的问题,使推荐产生的资源更能满足用户情感需要.

本文所提推荐算法的主要贡献是:1) 依据评价数据集自身属性(稀疏度和类别),建立融合评分和信任的用户偏好模型,解决了现有偏好模型扩展性不足的问题.实验结果表明,与已有的偏好模型相比,该模型具有较强的扩展性,大幅度地提高了覆盖率,做到了准确度与覆盖率的良好平衡.2) 考虑用户对资源的情感内涵的偏好,实验结果表明,在算法中引入 PEI,提高了算法的分类准确度,增加了用户选中满意资源的机会.下一步工作将深入分析基于评分和信任的用户偏好模型中共同评分资源数目的上、下限阈值与数据集评分稀疏度的关系,并对融入用户情感的协同推荐算法继续深入加入研究.

References:

- [1] Zhang GW, Li DY, Li P, Kang JC, Chen GS. A collaborative filtering recommendation algorithm based on cloud model. *Ruan Jian Xue Bao/Journal of Software*, 2007,18(10):2403–2411. <http://www.jos.org.cn/1000-9825/18/2403.htm> [doi: 10.1360/jos182403]
- [2] Resnick P, Varian HR. Recommender systems. *Communications of the ACM*, 1997,40(3):56–58.
- [3] Breese JS, Heckerman D, Kadie C. Empirical analysis of predictive algorithms for collaborative filtering. In: *Proc. of the 14th Conf. on Uncertainty in Artificial Intelligence*. Morgan Kaufmann Publishers, 1998.

- [4] Heckerman D, Chickering DM, Meek C, Rounthwaite R, Kadie C. Dependency networks for collaborative filtering and data visualization. In: Proc. of the 16th Conf. on Uncertainty in Artificial Intelligence. Morgan Kaufmann Publishers, 2000.
- [5] Hofmann T. Latent semantic models for collaborative filtering. ACM Trans. on Information Systems (TOIS), 2004,22(1):89–115.
- [6] Herlocker JL, Konstan JA, Borchers A, Riedl J. An algorithmic framework for performing collaborative filtering. In: Proc. of the 22nd Annual Int'l ACM SIGIR Conf. on Research and Development in Information Retrieval. ACM, 1999.
- [7] Lee DH. Pittcult: Trust-Based cultural event recommender. In: Proc. of the 2008 ACM Conf. on Recommender Systems. ACM, 2008.
- [8] Sinha R, Swearingen K. Comparing recommendations made by online systems and friends. In: Proc. of the Delos-NSF Workshop on Personalization and Recommender Systems in Digital Libraries. 2001.
- [9] Park HS, Yoo JO, Cho SB. A context-aware music recommendation system using fuzzy bayesian networks with utility theory. In: Wang L, et al., eds. Proc. of the FSKD. 2006. 970–979.
- [10] Cai R, Zhang C, Wang C, Zhang L, Ma WY. Musicsense: Contextual music recommendation using emotional allocation modeling. In: Proc. of the 15th Int'l Conf. on Multimedia. Augsburg: ACM, 2007.
- [11] Hunter PG, Schellenberg EG. Music and Emotion. In: Springer Handbook of Auditory Research, 2010,36:129–164. [doi: 10.1007/978-1-4419-6114-3_5]
- [12] Adomavicius G, Sankaranarayanan R, Sen S, Tuzhilin A. Incorporating contextual information in recommender systems using a multidimensional approach. ACM Trans. on Information Systems, 2005,23(1):103–145.
- [13] Qin JW, Zheng QH. A trust-personality mechanism for emotion compensation. In: Proc. of the 11th IEEE Int'l Conf. on Advanced Learning Technologies. 2011. 88–92. [doi: 10.1109/ICALT.2011.32]
- [14] Kaminskas M, Ricci F. Location-Adapted music recommendation using tags. In: Joseph AK, ed. User Modeling, Adaption and Personalization. 2011. 183–194.
- [15] Wang LC, Meng XW, Zhang YJ. Context-Aware recommender systems: A survey of the state-of-the-art and possible extensions. Ruan Jian Xue Bao/Journal of Software, 2012,23(1):1–20. <http://www.jos.org.cn/1000-9825/4100.htm> [doi: 10.3724/SP.J.1001.2012.04100]

附中文参考文献:

- [1] 张光卫,李德毅,李鹏,康建初,陈桂生.基于云模型的协同过滤推荐算法.软件学报,2007,18(10):2403–2411. <http://www.jos.org.cn/1000-9825/18/2403.htm> [doi: 10.1360/jos182403]
- [15] 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. <http://www.jos.org.cn/1000-9825/4100.htm> [doi: 10.3724/SP.J.1001.2012.04100]



秦继伟(1978—),女,河南汲县人,博士生,工程师,主要研究领域为情感计算,智能网络学习。

E-mail: Jw.qin@stu.xjtu.edu.cn



田锋(1972—),男,博士,副教授,博士生导师,主要研究领域为智能网络学习,情感计算,Petri网,数据挖掘。

E-mail: fengtian@mail.xjtu.edu.cn



郑庆华(1969—),男,博士,教授,博士生导师,CCF高级会员,主要研究领域为智能网络学习,网络安全。

E-mail: qhzheng@mail.xjtu.edu.cn



王康(1989—),男,硕士生,主要研究领域为情感计算。

E-mail: Kksky_jason@163.com