

一种改进的偏好融合组推荐方法^{*}



胡川^{1,2}, 孟祥武^{1,2}, 张玉洁^{1,2}, 杜雨露^{1,2}

¹(智能通信软件与多媒体北京市重点实验室(北京邮电大学),北京 100876)

²(北京邮电大学 计算机学院,北京 100876)

通讯作者: 孟祥武, E-mail: mengxw@bupt.edu.cn

摘要: 近年来,组推荐系统已经逐渐成为推荐系统领域的研究热点之一。在电影电视和旅游推荐中,用户常常是参与活动的一组人,这就需要为多个用户形成的群组进行推荐。作为解决群组推荐问题的有效手段,组推荐系统将单个用户推荐扩展为群组推荐,目前已经应用在新闻、音乐、电影、餐饮等诸多领域。现有的组推荐融合方法主要是模型融合与推荐融合,其效用好坏目前仍没有定论,并且它们各有自己的优缺点。模型融合存在着群组成员间的公平性问题,推荐融合忽视了群组成员间的交互。提出一种改进的偏好融合组推荐方法,它结合了两种融合方法的优点。同时根据实验得出了“群组偏好与个人偏好具有相似性”的结论,并将它结合在改进方法中。最后,通过在 MovieLens 数据集上的实验分析,验证了该方法的有效性,证明了它能够有效地提高推荐准确率。

关键词: 组推荐;推荐系统;偏好融合;群组偏好建模;数据挖掘

中图法分类号: TP311

中文引用格式: 胡川,孟祥武,张玉洁,杜雨露.一种改进的偏好融合组推荐方法.软件学报,2018,29(10):3164–3183. <http://www.jos.org.cn/1000-9825/5288.htm>

英文引用格式: Hu C, Meng XW, Zhang YJ, Du YL. Enhanced group recommendation method based on preference aggregation. Ruan Jian Xue Bao/Journal of Software, 2018,29(10):3164–3183 (in Chinese). <http://www.jos.org.cn/1000-9825/5288.htm>

Enhanced Group Recommendation Method Based on Preference Aggregation

HU Chuan^{1,2}, MENG Xiang-Wu^{1,2}, ZHANG Yu-Jie^{1,2}, DU Yu-Lu^{1,2}

¹(Beijing Key Laboratory of Intelligent Telecommunications Software and Telecommunications (Beijing University of Posts and Telecommunications), Beijing 100876, China)

²(School of Computer Science, Beijing University of Posts and Telecommunications, Beijing 100876, China)

Abstract: Group recommender systems have recently become one of the most prevalent topics in recommender systems. As an effective solution to the problem of group recommendation, Group recommender systems have been utilized in news, music, movies, food, and so forth through extending individual recommendation to group recommendation. The existing group recommender systems usually employ aggregating preference strategy or aggregating recommendation strategy, but the effectiveness of both two methods is not well solved yet, and they respectively have their own advantages and disadvantages. Aggregating preference strategy possesses a fairness problem between group members, whereas aggregating recommendation strategy pays less attention to the interaction between group members. This paper proposes an enhanced group recommendation method based on preference aggregation, incorporating simultaneously the advantages of the aforesaid two aggregation methods. Further, the paper demonstrates that group preference and personal preference are similar, which is also considered in the proposed method. Experimental results show that the proposed method outperforms baselines in terms of effectiveness based on MovieLens dataset.

Key words: group recommendation; recommender system; preferences aggregation; group preference modeling; data mining

* 基金项目: 北京市教育委员会共建项目专项

Foundation item: The Mutual Project of Beijing Municipal Education Commission, China

收稿时间: 2016-12-28; 修改时间: 2017-02-07; 采用时间: 2017-03-28; jos 在线出版时间: 2017-07-12

CNKI 网络优先出版: 2017-07-12 15:33:45, <http://kns.cnki.net/kcms/detail/11.2560.TP.20170712.1533.008.html>

随着互联网信息的快速增长,越来越多的用户在信息检索领域需要高品质的个性化服务。推荐系统作为一种缓解信息过载的手段,充分利用各种技术为用户推荐感兴趣的项目^[1]。传统推荐系统根据用户的历史评分记录,为用户预测未评分的项目,取得了一定成就^[2~4]。

近年来,随着推荐系统研究发展的不断升温,推荐系统的种类也层出不穷。例如,适合实时推荐的移动推荐系统^[5]、上下文感知推荐系统^[6]、社会化网络推荐系统^[7]等等。这些推荐系统主要的推荐群体是单用户群体,它们不能向一组用户进行推荐。然而在实际生活中,以多用户组成群组的形式进行活动的例子数不胜数。例如,电影推荐、家庭电视推荐、餐饮饭馆推荐、旅游推荐等等^[8],诸如此类的推荐不能仅以某一个用户的需求为推荐依据,还要考虑群组各成员的偏好行为,根据成员的共同特征进行推荐。这种推荐系统称为组推荐系统(group recommender system)^[9],它将推荐对象由单个用户扩展为一个群组,因此,组推荐系统面临着传统推荐系统不包含的新问题。其与传统推荐系统最大的不同表现在偏好建模阶段,这是由于组推荐系统需要建立的群组偏好模型,需要同时考虑群组内所有成员的偏好,并需要通过某种共享机制来减小成员间的偏好差异,使得群组偏好能够较好地代表组内各成员的偏好^[10]。组推荐系统与传统推荐系统存在着一些共通之处。例如在推荐算法上,传统推荐系统使用的基于用户的协同过滤、矩阵分解等算法都可以应用于组推荐系统。在面临的挑战中,组推荐系统依然存在冷启动等传统推荐系统常见的问题。

20世纪70年代,Dyer等人^[11]在研究群组决策问题时提出了群组偏好(group preference)和群组偏好融合(group preference aggregation)的概念。在组推荐系统中,群组偏好建模是影响组推荐系统推荐准确度的关键步骤。偏好融合是指根据群组成员的偏好提取群组偏好^[11],偏好融合策略有时也被称为“融合策略”^[12],这里需要同时考虑成员的总体满意度以及公平性问题等等^[10]。偏好融合可以发生在推荐的不同阶段,根据组推荐过程中偏好融合的时机,偏好融合方法可以分为模型融合^[12]和推荐融合^[13]。目前存在的典型商业组推荐系统,例如MusicFX^[14]、HappyMovie^[15]、Netflix^[16]等采用推荐融合,Where2Eat^[17]、AGReMo^[18]等采用模型融合,具体应该采用哪种偏好融合方法目前没有统一的定论。现有的实验结果表明,两种融合方法的推荐准确度不相上下,不能一概而论。因此,在组推荐系统中,选择哪种具体的融合方法成为了一个问题。两种融合方法各有自己的优缺点:模型融合容易受到评分稀疏性的影响,对于评分较少的群组成员是不公平的^[7],推荐融合方法忽略了群组成员之间的交互,因为用户单独行为和在群组中的行为是不同的^[19]。

本文根据两种基本融合方法的特征,提出了一种改进的偏好融合组推荐方法,对现有组推荐系统采用的偏好融合方法进行了改进,该方法结合了推荐融合与模型融合的优点,能够有效地提高推荐准确率。同时创新性地提出并论证了“群组偏好与个人偏好具有相似性”的假设,并将它结合在一种改进的偏好融合组推荐方法中。最后,通过在Movielens数据集上的实验分析,验证了该方法的有效性,证明了它能够有效地提高推荐准确率。

本文第1节回顾传统协同过滤推荐系统,并描述组推荐系统的相关工作。第2节详细讨论改进的偏好融合组推荐方法。第3节结合本文提出的方法,设计对比实验,并给出实验结果和相关分析。第4节总结本文工作并展望下一步研究。

1 相关工作

1.1 传统协同过滤推荐系统

传统推荐系统的推荐过程主要为获取用户偏好和生成推荐列表两部分。生成推荐列表的前提是需要对未评分项目进行预测评分工作。

用户偏好往往以用户-项目评分矩阵表示,设其为 $m \times n$ 矩阵。一般地, u_i 表示第 i 个用户, i_k 表示第 k 个项目, r_{ik} 表示用户 u_i 对项目 i_k 的评分。通过寻找用户的若干个最相似近邻计算用户对某项目的预测评分。通常采用的用户间相似度计算方法有:余弦相似度、皮尔森相关系数、修正的余弦相似度等等。

1.2 组推荐关键技术

组推荐系统的关键技术主要包含两部分:一是群组偏好融合策略,它用于融合组内各用户的偏好;二是对成

员的未评分项目进行预测,生成推荐列表^[8].

文献[12]讨论了大部分典型的群组偏好融合策略:公平策略、均值策略、痛苦避免均值策略、最受尊敬者策略、最小痛苦策略、最开心策略等等.为了满足群组成员的总体满意度和推荐公平性,在实际应用中,根据需要使用不同的融合策略,这主要取决于不同类型的群组特征.在具体群组中(取决于群组成员数目、成员间的相关性等等数据),具体使用哪种融合策略能够达到最佳推荐效果,仍是该领域研究的热点问题之一^[8].

在基于偏好融合的组推荐过程中,需要选取某种融合策略进行偏好融合,但融合时机不同,融合的内容也不同,根据融合时机可以对采用的方法进行划分,称偏好融合方法.目前主要采用的偏好融合方法有模型融合和推荐融合.传统推荐系统的推荐过程主要包含两部分,分别为用户偏好获取阶段和推荐生成阶段.模型融合在推荐生成之前进行偏好融合,它根据群组成员的用户偏好模型融合生成群组偏好模型;推荐融合在推荐生成之后进行偏好融合,将所有群组成员的推荐结果融合得到群组推荐结果.文献[10,20,21]对融合方法进行了总结,目前常用的有推荐结果融合、评分融合以及群组偏好建模^[8].

在最近的组推荐系统研究中,Skowron 等人^[22]对组推荐系统作了形式化的模型定义.Garcia 等人^[23]认为,在偏好融合时群组内各成员是不对等的,并据此提出了一个异构群组谈判模型.Castro 等人^[24]通过使群组成员对推荐结果达成更高的共识度,采用推荐融合方法,使群组成员获得更高的推荐满意度.Ghazarian 等人^[25]通过改进传统协同过滤方法,加入支持向量机(SVM)来计算项目间的相似度,从而使评价数目较少的用户的推荐准确率有所提高.Amer-Yahia 等人^[26]基于群组成员间的亲密程度提出一种新的融合策略,并认为群组成员间的关系会随时间改变.Kassak 等人^[27]在传统预测评分的基础上提出一种混合评分方法,将基于用户的协同过滤与基于内容的推荐混合作为预测评分方法.Sanchez 等人^[28]回顾了几种传统融合策略,并通过分析群组特征(例如大小、结构、成员间的冲突和信任关系),提出一种结合社会化行为的组推荐构架.Christensen 等人^[29]在旅游领域提出一种结合社会化关系的组推荐方法.Liu 等人^[30]结合 LDA(latent Dirichlet allocation)主题模型,提出了一种群组项目概率选择模型,并描述了个人对群组决策进行影响的概念 PIT(personal impact topic),同时提出采用机器学习方法对该模型加以学习,并利用该模型进行预测评分.Yuan 等人^[31]提出一种共识模型,该模型认为,组内成员在不同场景下拥有不同的群组影响力,并且组内成员的行为是独立且不同的,据此,Yuan 等人提出了一种群组概率生成模型,并通过实验证明了该模型能够显著提高推荐准确率.

同时,目前已有不少研究者对模型融合与推荐融合的效果进行了实验对比.Berkovsky 等人^[32]的实验结果表明,模型融合方法的推荐效果较好,但在对比时仅采用了一种推荐融合实现算法.文献[33]的实验结果则表明,模型融合和推荐融合的推荐准确度并无明显差异.Pessemier 等人^[34]的实验结果表明,模型融合与推荐融合的推荐效果不能一概而论,且受实现的推荐算法的影响.在偏好融合方法的选择上,目前并没有统一的指导策略能够确定哪种方法更好.在一些组推荐典型应用中,偏好融合方法一般是根据实际情况得出的.

无论是模型融合还是推荐融合,都具有同一个特征:将群组偏好与个人偏好分别单独训练,即群组偏好只与群组偏好进行对比,个人偏好只与个人偏好进行对比.事实上,例如模型融合的结果,即各组偏好的代表,无论是数据结构还是实际意义,都与个人偏好相同.本文通过实验得出了“群组偏好与个人偏好具有相似性”的结论,通过将群组偏好与个人偏好同时进行训练,与现有方法进行结合.对于推荐融合,由于融合时机是在个人预测结果生成以后,没有机会进行群组偏好与个人偏好的结合.对于模型融合,融合时机在预测结果生成之前,根据文献[10,21,34]的描述,融合后的结果是群组偏好,最终目标是对群组偏好进行预测,因此便抛弃了个人偏好信息.由此看来,若要同时考虑群组偏好与个人偏好,必须在两种已知基本融合方法的基础上进行创新性设计.

由于已知的两种偏好融合方法的效用好坏目前仍没有定论,且两种方法都无法同时将个人偏好与群组偏好进行比较.因此本文提出一种将模型融合与推荐融合相结合的偏好融合方法,该方法在生成预测评分前后都进行偏好融合,并将个人偏好与群组偏好同时进行训练,最终对推荐列表进行融合生成统一的推荐结果.

2 一种改进的偏好融合组推荐方法

2.1 基本融合策略

定义 1. 设 m 为用户数,全体用户集合记为 $U, U = \{u_i | 1 \leq i \leq m\}$.

定义 2. 设 n 为项目数,全体项目集合记为 $I, I = \{i_j | 1 \leq j \leq n\}$.

定义 3. 设 l 为群组数,全体群组集合记为 $G, G = \{g_k | 1 \leq k \leq l\}$.

定义 4. 用户项目矩阵 $R = \{r_{ij} | 1 \leq i \leq m, 1 \leq j \leq n\}$ 是一个 $m \times n$ 矩阵,其中, r_{ij} 表示用户 u_i 对项目 i_j 的评分,例如在 MovieLens^[35] 数据集中,这个评分是 1~5 之间的整数.

定义 5. 群组项目矩阵 $H = \{h_{kj} | 1 \leq k \leq l, 1 \leq j \leq n\}$ 是一个 $l \times n$ 矩阵,其中, h_{kj} 表示群组 g_k 对项目 i_j 的评分. H 中的群组偏好代表了群组内各成员的偏好,为群组建立偏好模型的方法称为模型融合,也称群组偏好建模(group preference modeling)^[32]. 其输入数据是群组成员的偏好,输出数据是群组偏好模型. 融合过程可以如下表示^[32]:

$$h_{kj} = \frac{\sum_{u_i \in g_k} w(u_i, g_k) \cdot r_{ij}}{\sum_{u_i \in g_k} w(u_i, g_k)} \quad (1)$$

其中, $w(u_i, g_k)$ 表示用户 u_i 在群组 g_k 中的权重.

首先获取个人偏好并采用预测方法计算每个用户的预测评分,之后再根据预测评分进行融合的方法,称作推荐融合. 该方法也可以通过融合推荐项目列表得到群组推荐列表^[36]. 对于评分预测和 Top- k 推荐这两类问题,推荐融合方法可分为评分融合^[9]和排序融合^[36]. 采用评分融合的组推荐系统多与协同过滤方法相结合^[37,38].

在偏好融合时,每个用户在群组中的权重通过融合策略得到,使用不同的融合策略可以分别满足总体满意度、公平性、可理解性等不同的需要. 文献[38]详细分析了 10 种不同的偏好融合策略,表 1 列出了组推荐系统中几种常用的融合策略.

Table 1 Strategies for aggregating user preferences

表 1 偏好融合策略

名称	公式	说明
均值策略	$p(g_k, i_j) = \text{avg}(r_{ij} : u_i \in g_k)$	将群组成员评分的平均值作为群组评分
最小痛苦策略	$p(g_k, i_j) = \min(r_{ij} : u_i \in g_k)$	选择所有群组成员评分中的最低评分作为群组评分
最开心策略	$p(g_k, i_j) = \max(r_{ij} : u_i \in g_k)$	选择所有群组成员评分中的最高评分作为群组评分
最受尊敬者策略	$p(g_k, i_j) = r_{ij} : u_i \in g_k \wedge u_i = u_{resp}$	选择群组成员中的一名用户的评分作为群组评分

其中, $p(g_k, i_j)$ 是指群组 g_k 对项目 i_j 的评分.

2.2 群组偏好与个人偏好具有相似性

在现有的组推荐系统中,在进行协同过滤等预测算法时,群组偏好只与群组偏好进行相似度比较,而忽略了个人偏好的影响. 这导致在协同过滤时,能够找到的高相似度群组数目较少. 事实上,在进行群组融合时,相当于在为该群组寻找一个合适的代表,这必将导致在某些偏好特征上的缺失. 尤其是在组内相似度不高的随机分组推荐中,当采用常见的最小痛苦或均值策略作为融合方法时,只要有某个用户对一种类型的项目不感兴趣,则融合结果对该类型的项目往往表现出中立态度甚至不感兴趣. 例如在电影推荐中,若某个群组包含不喜欢恐怖电影的用户,则群组偏好的融合结果往往对恐怖电影不够喜欢,这导致了群组偏好的一个重要特征,即普遍的对任何类型的项目表现出中立或低兴趣(采用最小痛苦或均值策略),或者是喜爱(采用最开心策略). 这导致那些对某种项目表现出喜爱态度的群组(采用最小痛苦或均值策略),在寻找近邻时,高相似度近邻的数量普遍偏少.

通过实验我们发现,群组偏好与个人偏好具有相似性. 在推荐时,若对于某个群组能够找到更多的相似近邻,则在某种程度上可以提高推荐准确率. 为了证明群组偏好与个人偏好具有相似性,可以先按照传统协同过滤

方法,计算用户/群组间的相似度矩阵,然后找出所有用户/群组的高相似度近邻的个数.表 2 给出了不同方式下高相似度近邻的数目,这里,最大近邻数目取 20,高相似度阈值取 0.2.假设用户共 m 人,群组共 n 个,则纯用户间计算相似度时,相似度矩阵为 $m \times n$ 矩阵,统计高相似近邻时,计数所有 m 个用户超过相似度阈值的高相似近邻个数,结果见表 2 中方法 1.然后,将用户和群组放在一起共同计算相似矩阵,则该相似度矩阵为 $(m+n) \times (m+n)$ 矩阵,使用该矩阵,依然能够为这 m 个用户找到相似近邻,只是此时的相似近邻可能是用户偏好也可能是群组偏好,作为对比,计数 m 个用户的高相似近邻个数,结果见表 2 中方法 2.同理,群组与群组之间计算相似度,相似度矩阵为 $n \times n$ 矩阵,为这 n 个群组计数高相似近邻个数,结果见表 2 中方法 3.前面提到共同训练时,能够得到 $(m+n) \times (m+n)$ 的相似度矩阵,使用它可以为 m 个用户找到相似近邻,事实上也可以为 n 个群组找到相似近邻,计数高相似度近邻个数结果见表 2 中方法 4.这里使用的数据集包括 943 个用户以及由他们构成的 2 020 个群组.

Table 2 The number of high similarity neighbors

表 2 高相似度近邻个数

名称	公式	高相似度近邻个数
方法 1	$p = \{sim(i, j) : \exists sim(i, j) > \alpha 1 \leq i \leq m, 1 \leq j \leq m\} $	7 882
方法 2	$p = \{sim(i, j) : \exists sim(i, j) > \alpha 1 \leq i \leq m, 1 \leq j \leq m+n\} $	8 854
方法 3	$p = \{sim(i, j) : \exists sim(i, j) > \alpha 1 \leq i \leq m+n, m+1 \leq j \leq m+n\} $	20 028
方法 4	$p = \{sim(i, j) : \exists sim(i, j) > \alpha 1 \leq i \leq m+n, 1 \leq j \leq m+n\} $	20 190

表 2 中 α 表示相似度阈值, m 为用户人数, n 为群组个数.表 2 中方法 1 和方法 2 都是为 m 个用户找到的高相似度近邻个数, 对比后发现, 当用户的相似度近邻可以是群组时, 其高相似度近邻的个数有很大提升, 推荐融合就是融合用户的预测评分, 方法 2 由于比方法 1 能够找到更多的相似度近邻, 势必可以提高推荐融合方法的准确度. 同样地, 方法 3 和方法 4 是为群组寻找高相似近邻, 可以看出, 共同训练仍然能够提高高相似近邻的个数, 但是由于群组偏好普遍地对任何类型的项目表现出中立或低兴趣, 使得群组间本身相似度就较高, 这里, 若通过共同训练而使高相似度近邻的个数得到提高, 则比较有限.

2.3 改进的偏好融合组推荐方法

模型融合与推荐融合都有其缺点, 举一个极端的例子: 采用最受尊敬者策略的模型融合, 得到群组偏好时, 若群组数量为 g , 则模型融合的结果最多拥有 g 行不同的评价信息, 若平均每个群组为 3 人小组, 则至少丢失了 66% 非群组代表的个人信息. 此时再进行协同过滤, 则某个最受尊敬者 u_i 的最相似近邻只会在最多 g 个最受尊敬者中, 这大大降低了找到高相似近邻的个数. 同时, 模型融合受评分稀疏性影响较大, 对于评分少的群组成员, 其融合贡献较少, 这是不公平的^[32]. 推荐融合方法的缺点是忽略了群组成员之间的交互, 因为用户单独行为和在群组中的行为是不同的^[19].

我们将推荐融合与模型融合相结合, 提出一种改进的偏好融合组推荐方法 IMP(an enhanced group recommendation method based preference aggregation), 它同时包含了推荐融合与模型融合的融合特点. 采用该方法时, 利用到了群组偏好与个人偏好具有相似性的结论, 将推荐融合与模型融合统一.

在改进的偏好融合组推荐方法中, 首先采用模型融合得到群组偏好, 然后将它与个人偏好相结合, 共同作为预测评分输入, 而模型融合只将群组偏好作为输入, 这是改进方法与模型融合方法输入上的不同. 预测评分结果可以分为群组偏好预测结果和个人偏好预测结果, 采用推荐融合方法可以通过个人偏好预测结果得到群组推荐列表, 对群组偏好预测结果排序, 也可以得到群组推荐列表. 因此, 改进方法可以由模型融合部分和推荐融合部分得到两个群组推荐列表. 在推荐列表中越靠前的项目, 其预测评分越高, 因此, 通过融合这两个推荐列表, 可以得到最终的推荐结果.

改进方法最大的创新之处, 是将个人偏好与群组偏好同时作为预测评分输入, 在一次推荐过程中, 同时使用了模型融合方法和推荐融合方法, 从而有效地提高了推荐准确率.

(1) 偏好获取与预测评分

首先读取用户-项目信息获得用户项目矩阵 R , 这一步与传统单人推荐类似. 然后利用用户-项目-群组信息,

根据公式(1)获取群组项目矩阵 H .将矩阵 R 和矩阵 H 连结可构成一个结合矩阵 C ,它是一个 $(m+l)\times n$ 矩阵.其中, $C_{ij,i\in[1,m]}$ 是个人偏好, $C_{ij,i\in[m+1,m+l]}$ 是群组偏好.

应用群组偏好与个人偏好具有相似性的结论,利用结合矩阵 C ,采用相应的预测方法,就可以得到候选项目的预测评分,这与单人推荐类似.例如,在采用传统协同过滤预测时,可以表示如下:

$$pred(s_a, i_j) = \frac{\sum_{s_b \in U \cap G} sim(s_a, s_b) \cdot h_{bj}}{\sum_{s_b \in U \cap G} sim(s_a, s_b)} \quad (2)$$

其中, $pred(s_a, i_j)$ 表示 s_a 对未评分项目 i_j 的预测评分, $s_a \in \{U \cup G\}$; $sim(s_a, s_b)$ 表示 s_a 与 s_b 的偏好相似度; h_{bj} 表示 s_b 对 i_j 的评价, $s_b \in \{U \cup G\}$.

本文在进行协同过滤时,采用的相似度计算方法是皮尔森相关系数法,其公式如下:

$$sim(u_i, u_j) = \frac{\sum_{m \in I_{ij}} (r_{im} - \bar{r}_i)(r_{jm} - \bar{r}_j)}{\sqrt{\sum_{m \in I_{ij}} (r_{im} - \bar{r}_i)^2} \sqrt{\sum_{m \in I_{ij}} (r_{jm} - \bar{r}_j)^2}} \quad (3)$$

其中, I_{ij} 表示用户 u_i 和 u_j 共同评分的项目集合, \bar{r}_i 表示 u_i 的平均评分值.

(2) 偏好融合

通过对 C 进行训练,相当于同时对个人用户和群组用户进行预测,获取候选项目的预测评分后,可以得到预测评分矩阵 C^P .其中, $C_{ij,i\in[m+1,m+l]}^P$ 部分在预测评分前就表示了各群组的偏好,可以将它单独记为 H^P ,并有 H_{ij}^P 表示 g_i 通过先融合再评分的方法对 i_j 的预测评分.因此,可以直接通过 H^P 采用传统 Top-k 推荐方法生成推荐列表 L^P .

$C_{ij,i\in[1,m]}^P$ 是各用户的预测评分,它与推荐融合中获取的预测评分矩阵的不同之处是在预测时混合了群组偏好.预测评分时计算了群组成员 u_i 对未评分项目 i_j 的预测评分 $pred(u_i, i_j)$,然后,可通过融合群组成员的预测评分得到群组预测评分.融合过程根据用户 u_i 在群组 g_k 中的相对权值 $w(u_i, g_k)$ 和用户 u_i 对项目 i_j 的预测评分 $pred(u_i, i_j)$ 来计算群组 g_k 对项目 i_j 的预测评分 $pred(g_k, i_j)$,相对权值 $w(u_i, g_k)$ 由融合策略决定,几种常见的融合策略可见表 1,融合方法描述如下:

$$pred(g_k, i_j) = \frac{\sum_{u_i \in g_k} w(u_i, g_k) \cdot pred(u_i, i_j)}{\sum_{u_i \in g_k} w(u_i, g_k)} \quad (4)$$

此时的融合结果是一个 $g \times n$ 矩阵 H^R ,同理,可以按照传统 Top-k 推荐方法生成推荐列表,记为 L^R .事实上, L^P 与 L^R 都能够单独作为群组推荐的结果. L^P 由于在预测评分前进行偏好融合,群组成员之间的交互性有所保留; L^R 在预测评分后进行偏好融合,此时,预测矩阵不再包含大量的未评分项目,因此对于评分的稀疏性有所缓和.由于它们各有所长,因此对两个推荐列表进行融合,可以得到改进方法的推荐结果.

(3) 生成推荐列表

对于推荐列表,越靠前的项目表示群组越可能喜欢该项目,因此它的权重也应该越大,列表融合方法描述如下:

$$rat^C(g_k, i_j) = \frac{\alpha \cdot H_{kj}^P}{\log_2(1 + N^P(g_k, i_j))} + \frac{(1 - \alpha) \cdot H_{kj}^R}{\log_2(1 + N^R(g_k, i_j))} \quad (5)$$

其中, $rat^C(g_k, i_j)$ 表示群组 g_k 对项目 i_j 的最终预测评分, H_{kj}^P 表示群组 g_k 通过先偏好融合再预测评分的方法对 i_j 的预测评分, $N^P(g_k, i_j)$ 表示群组 g_k 对项目 i_j 的预测评分在 L^P 中的排名, H_{kj}^R 表示群组 g_k 通过先预测评分再偏好融合的方法对 i_j 的预测评分, $N^R(g_k, i_j)$ 表示群组 g_k 对项目 i_j 的预测评分在 L^R 中的排名. α 表示权重,并有 $0 \leq \alpha \leq 1$.

2.4 方法描述

输入数据:

- (a) 用户-评分矩阵 $R = \{r_{ij} | 1 \leq i \leq m, 1 \leq j \leq n\}$, 其中, r_{ij} 表示用户 u_i 对项目 i_j 的评分.
- (b) 用户-群组关系 $\{u_t, g_t\}, t = 1, 2, \dots, m$, 例如, $\{u_t, g_k\}$ 表示用户 u_t 属于群组 g_k .

输出数据:

- (a) 群组推荐列表, 项目在推荐列表中越靠前, 表示它的预测评分越高.

方法流程:

Step 1. 获取用户-项目信息, 生成用户-项目矩阵, 假设它是一个 $m \times n$ 矩阵.

Step 2. 获取用户-项目-群组信息, 根据选择的融合策略(如最小痛苦策略)进行偏好融合, 假设共有 g 个群组, 则得到一个 $g \times n$ 矩阵.

Step 3. 结合偏好矩阵得到一个 $(m+g) \times n$ 矩阵, 根据选择的预测评分方法(例如, 基于用户的协同过滤), 根据公式(2)和公式(3)获得预测评分矩阵.

Step 4. 将用户预测评分矩阵进行偏好融合, 可以采用公式(1), 并根据公式(4)计算得出 $g \times n$ 的群组预测矩阵.

Step 5. 通过两个预测矩阵生成推荐列表.

Step 6. 根据公式(5), 融合推荐列表得到最终推荐结果.

方法流程如图 1 所示.

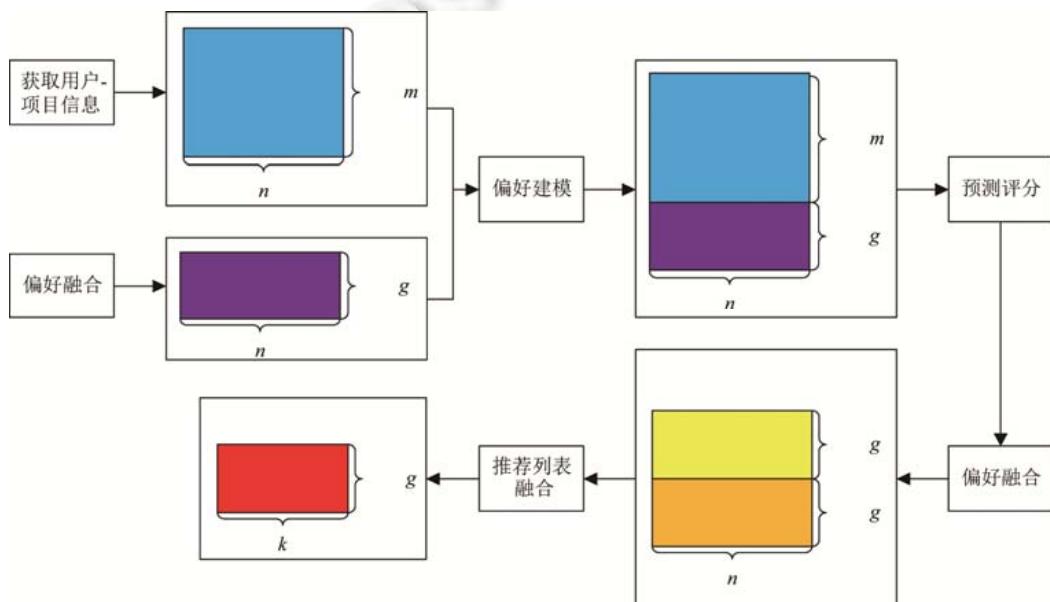


Fig.1 The work flow of IMP
图 1 改进的偏好融合组推荐方法工作流程

2.5 复杂度分析

本节主要分析改进方法和基本融合方法之间的计算复杂度差异, 假设用户规模为 m , 项目规模为 n , 群组规模为 g , 无论选取表 1 中的哪种融合策略, 进行一次偏好融合的时间复杂度都为 $O(gn)$, 所以模型融合和推荐融合方法中的进行偏好融合的时间复杂度为 $O(gn)$, 改进方法在预测评分前后都进行偏好融合, 因此时间复杂度为 $O(2gn)$. 在预测评分步骤, 选取不同的预测评分方法时, 时间复杂度是不同的, 这里以基于用户的协同过滤算法为例, 采用其他算法时, 复杂度分析类似. 模型融合方法只计算群组间的相似度, 一次相似度计算的复杂度为 $O(n)$,

则群组间相似度计算的时间复杂度为 $O(g^2n)$,计算预测评分的时间复杂度为 $O(gn)$.同理,对于推荐融合,相似度计算的输入是个人偏好,因此相似度计算的时间复杂度是 $O(m^2n)$,预测评分的时间复杂度为 $O(mn)$.改进方法的相似度计算输入是个人偏好和群组偏好,因此相似度计算的时间复杂度是 $O((m+g)^2n)$,预测评分的时间复杂度为 $O((m+g)n)$.改进方法增加了列表融合步骤,该步骤的时间复杂度为 $O(gn)$.因此,采用模型融合方法推荐的时间复杂度为 $O(2gn)+O(g^2n)$,采用推荐融合方法推荐时的时间复杂度为 $O(gn)+O(m^2n)+O(mn)$,采用改进方法推荐时的时间复杂度为 $O(3gn)+O((m+g)^2n)+O((m+g)n)$.

可以看出,采用不同方法时,推荐过程中的计算主要消耗在相似度计算步骤,同时,由于群组数量一般与用户数量成正相关,假设平均每个用户同时存在于 k 个群组,平均每个群组包含 l 个成员,因此可以认为 $O(g)=O((k/l \cdot m)=O(m)$,则模型融合的相似度计算复杂度约为 $O(k^2/l^2 \cdot m^2n)=O(m^2n)$,推荐融合的相似度计算复杂度为 $O(m^2n)$,改进方法的相似度计算复杂度约为 $O(1+2k/l+k^2/l^2) \cdot m^2n=O(m^2n)$.

可以看出,改进方法的时间复杂度对于两种基本融合方法,势必有所增加,但是它们仍然在同一个数量级上,当预测评分采用基于用户的协同过滤算法时,真正决定计算规模的是用户数量.

3 实验结果与分析

本节首先介绍 MovieLens^[35]数据集以及在其基础上构造群组的方法;然后给出评价指标以及对比方法;最后根据实验结果,对比了本文所提方法与其他各种方法,并对实验结果进行了分析.

3.1 数据集介绍

MovieLens 数据集由美国 Minnesota 大学的 GroupLens 研究小组创建并维护,该数据集包含了用户对电影的评分信息、电影的属性信息以及电影的标签信息^[35].

与传统推荐系统不同,组推荐系统的数据集中必须包含群组信息.在现有的公开数据集中,含有群组信息的数据集很少.利用传统推荐系统的数据集,根据实验评价所需群组特征,从公开数据集中构造群组^[13,36],是目前常用的解决方法.本文在 MovieLens 数据集的基础上,按照文献[34]记录的方法,生成随机群组数据集 MovieLens-Rand 进行实验.由于组内相似度对推荐结果具有一定的影响^[31],按照文献[31]记录的方法,同时生成高相似度群组数据集 MovieLens-Simi,该数据集的群组成员间具有较高的相似度.

本文同时还在真实数据集 CAMRa 2011^[39]上进行了验证实验.CAMRa 2011 是以家庭为群组单位的家庭电影推荐数据集.该数据集包含 290 个家庭,共 602 位用户对 7 740 部电影的评价,评价数值为 1~100 之间的整数.

3.2 群组划分方法

本文使用的 MovieLens 数据集包含较多的噪音数据,无法在实验中直接使用.筛选方法为:去除被不足 20 个用户共同评价过的电影以及评价不超过 20 个电影的用户,经过处理的数据集中包含 943 位用户、1 682 部电影,用户的评分区间为 1~5 之间的整数.

群组生成时,先将所有用户评价信息分为两部分,训练集占 80%,测试集占 20%;然后将所有用户随机分在 2~5 人的群组中,同一用户可能被分在多个群组中.Baltrunas^[13]等人证明,组内相似度对融合具有一定的影响,因此生成的群组区分高相似度群组和普通随机群组,组内相似度由 Pearson 相关系数计算.高相似度群组的构造方式:对每一随机群组计算组内相似度,若组内相似度高于高相似度阈值,则该组符合高相似度群组特征,高相似度数据集由所有符合高相似度群组的集合构成.

3.3 评价指标

组推荐的准确率是最重要的评价衡量指标,本文使用归一化折损累计增益(normalized discounted cumulative gain,简称 nDCG)作为推荐准确率评价指标^[34],它是一种信息检索(information retrieval)评价标准,用于衡量推荐列表的准确率^[13,34].每个用户的准确率基于推荐列表中的项目在测试集中的真实数值,采用折损累计增益(discounted cumulative gain,简称 DCG)表示,公式如下:

$$DCG_n(g_i) = r(g_i, i_1) + \sum_{k=2}^n \frac{r(g_i, i_k)}{\log_2(k)} \quad (6)$$

其中, $DCG_n(g_i)$ 表示取群组 g_i 推荐列表的前 n 项计算 DCG 的值, $r(g_i, i_k)$ 表示群组 g_i 对其推荐列表第 k 项的真实评价数值. 本文在实验时, 根据多次实际测试, 取 $n=5$.

nDCG 由真实 DCG 值与最大 DCG 值的比值来决定, 因此它是介于 0~1 之间的小数, 公式如下:

$$nDCG_n(g_i) = \frac{DCG_n(g_i)}{\max DCG_n(g_i)} \quad (7)$$

其中, $\max DCG_n(g_i)$ 是最好情况下的推荐列表 DCG 值. 例如, 测试集中群组 g_i 包含 5 个评价项目, 真实评价值分别为 [1, 3, 2, 4, 5], 则使用列表 [5, 4, 3, 2, 1] 计算 $\max DCG_n(g_i)$. nDCG 的数值越大, 且数值越接近 1, 说明推荐准确度越高.

(1) 多样性

即使推荐准确度是组推荐系统最重要的评价指标, 在实际推荐时, 若总是给用户推荐相同或类似的几样商品, 用户会产生厌烦情绪, 这将直接导致用户不满. 在组推荐中, 商品多样性同样重要. 评价商品多样性时, 可以计算物品间的相似度, 通常使用 Jaccard 相似度系数来计算两个项目之间的类型相似度^[12], 公式如下:

$$\text{sim}_J(i_j, i_k) = \frac{i_{j\text{genres}} \cap i_{k\text{genres}}}{i_{j\text{genres}} \cup i_{k\text{genres}}} \quad (8)$$

其中, $i_{j\text{genres}}$ 表示 i_j 包含的电影风格集合, 则对于某个群组推荐列表的相似度可用如下公式计算:

$$\text{IntraListSimilarity} = \frac{2 \cdot \sum_{j=1}^n \sum_{k=j+1}^n \text{sim}_J(i_j, i_k)}{n \cdot (n-1)} \quad (9)$$

则推荐多样性可用以下公式计算:

$$\text{Diversity} = 1 - \text{avg}(\text{IntraListSimilarity}) \quad (10)$$

Diversity 的数值越大, 说明推荐结果的多样性越高.

(2) 覆盖率

覆盖率指的是推荐结果覆盖的项目范围, 覆盖率越高, 商品推荐的种类越多, 对商品销售有着积极作用. 因此相比较于用户, 推荐系统的提供者更加关心推荐的覆盖率. 传统推荐系统通常采用目录覆盖率作为评价指标^[40]. 在组推荐系统中, 可以计算每个群组的推荐列表的目录覆盖率, 作为组推荐的覆盖范围. 覆盖率往往以降低准确率为代价, 因此组推荐的目录覆盖率必须与准确度同时进行评价^[34]. 覆盖率由如下公式计算:

$$\text{Coverage} = \frac{|\bigcup_{i=1..m} \text{rec}(u_i)|}{|\text{cat}|} \quad (11)$$

其中, $\text{rec}(u_i)$ 表示用户 u_i 的推荐列表, cat 表示全体项目.

3.4 对比方法与实验方法

本文提出的改进方法, 对比方法是两种基本融合方法: 模型融合和推荐融合方法. 在实际的推荐过程中, 无论采取哪种融合方法, 都需要经过预测评分步骤, 传统的预测评分算法有很多, 无论采用哪一种都可以构成一种特定算法, 例如“采用基于用户协同过滤的模型融合方法”与“采用基于用户协同过滤的推荐融合方法”, 都使用了同样的预测评分算法, 此时, 这两种融合方法是可比的. 因此, 在使用某种特定的融合方法时, 可以分别选取不同的融合策略和预测评分算法, 以组成一种特定的推荐算法.

对比方法有:

- pref(aggregating preferences strategy): 模型融合^[12];
- rec(aggregating recommendations strategy): 推荐融合^[13];
- imp(an enhanced group recommendation method based on preference aggregation): 本文提出的方法.

其中, 采用到的预测评分算法有:(1) UBCF: 基于用户的协同过滤;(2) IBCF: 基于物品的协同过滤;(3) Hybrid: 组合推荐;(4) SVD: 基于隐语义模型的矩阵分解方法. 使用到的融合策略有:(1) AVG(average strategy): 均值策

略^[12];(2) LM(least misery strategy):最小痛苦策略^[12];(3) MP(most pleasure strategy):最开心策略^[12];(4) MRP (most respected person strategy):最受尊敬者策略^[12].

实验中,特定算法的简称是由融合方法与预测评分算法的简称相结合组成的,例如“pref-UBCF”表示采用基于用户的协同过滤作为预测评分算法,融合方法是模型融合.

3.5 实验结果与分析

实验 1. 推荐准确率实验.

为了研究不同融合方法对推荐准确率的影响,选取几种不同的预测评分方法进行系列实验.在此实验中,为了减小其他因素对结果的影响,分组选取时,采用全随机分组的方法,并且固定群组大小为 2.采用改进的偏好融合组推荐方法时,参数 $\alpha=0.5$,表示两种基本融合方法的权重相等.推荐准确率使用 nDCG 计算,结果如图 2 所示.实验中基于隐语义模型的矩阵分解的方法,隐类个数设为 40,学习速率设为 0.01,正则项系数设为 0.005.

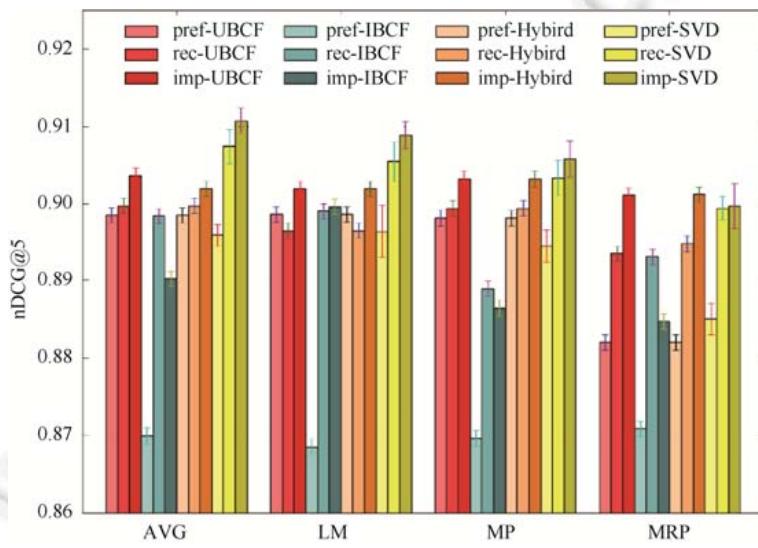


Fig.2 Accuracy of the recommendations (I)

图 2 推荐准确率(I)

从实验结果中可以发现:

1) 在大多数情况下,改进方法的推荐准确率要高于模型融合与推荐融合方法,并且大部分采用模型融合的算法,在推荐准确度上不如采用推荐融合的算法,这是采用随机分组数据集导致的.由于目前没有成熟的且包含群组划分信息的数据集,在组推荐系统的相关研究中,普遍采用自划分群组的数据集.由于模型融合在预测评分前进行偏好融合,导致融合结果非常依赖群组内共同评分的项目,随机群组在共同评分以及评分相似度上都有所欠缺,组内用户行为的关联性也较差,这导致其实验结果普遍低于推荐融合.

2) 实验中,采用基于物品的协同过滤算法时,大多数情况下,改进方法推荐准确率并不是最高的.这是因为,在采用基于物品的协同过滤时,主要通过物品间的相似性作为推荐依据,改进方法不能增加物品的数量,因此对物品间的相似度计算影响较小.同时,在采用基于物品的协同过滤时,推荐融合与模型融合方法的推荐准确率差距较大.由于模型融合在预测评分前将个人偏好融合为群组偏好,减少了大量的偏好信息,进行物品间相似度计算时,难以准确地获取相似度信息.该现象说明:改进方法同时受两种基本融合方法的影响,在两者推荐性能差距较大时,会出现推荐准确率介于两者之间的推荐结果.

在最近的组推荐系统研究中,一些基于模型的算法被提了出来^[30,31],不同于使用基于偏好融合方法的具体算法,基于模型的算法首先假定一种用户模型,通过对输入数据建模训练,从而获得模型参数,然后通过这些训练模型计算待预测评分,最终生成推荐列表.为了全面对比各种算法的推荐准确率,我们将基于 Personal Impact

Topic Model^[30](简称 PIT)模型和基于 Consensus Model^[31](简称 COM)模型的算法作为对比算法,进行了准确率实验.在进行对比时,由于基于模型的算法不需要进行偏好融合,因此我们需要选取一种具体的融合策略,以使用该策略的各算法作为对比算法进行实验.在图 2 所示的实验结果中,采用 LM 融合策略的算法,推荐准确率普遍较高,因此选择它作为本部分实验的融合策略.实验结果如图 3 所示.其中,基于 PIT 模型与基于 COM 模型的算法,topic 个数均取定值 200.

从实验结果中可以发现,基于 COM 模型的推荐算法,准确率是最高的,使用改进的偏好融合组推荐方法的各算法(以 imp 为前缀的各算法)比基于 PIT 模型的算法,推荐准确率要高.在改进方法中应用 SVD 算法时,是使用改进方法的算法中,推荐准确率最高的,它比基于 COM 的算法,推荐准确率稍低.这说明,基于 COM 模型的算法有着很好的推荐效果.不过,改进方法不是一种具体的推荐算法,在推荐过程中,它可以应用不同的预测评分算法和融合策略组合为一种具体的推荐算法,图 3 中仅列出了传统推荐算法在改进方法中的应用,而使用不同的预测评分算法时,改进方法也表现出不同的推荐效果.当使用好的预测评分算法时,改进方法也能表现出好的推荐效果,因此改进方法具有较好的扩展性,当应用不同的预测评分算法时,改进方法有很大的提升空间.

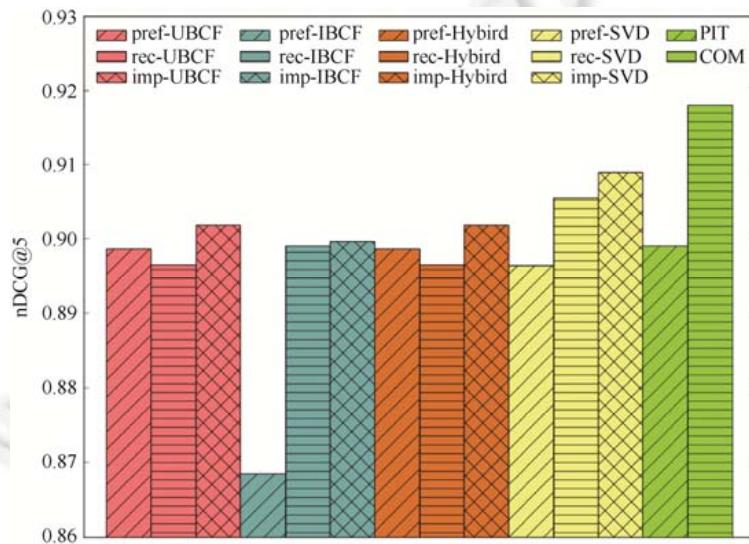


Fig.3 Accuracy of the recommendations (II)

图 3 推荐准确率(II)

实验 2. 推荐覆盖率实验.

覆盖率往往以降低准确率为代价,因此组推荐的目录覆盖率必须与准确度同时进行评价^[15].在推荐覆盖率实验中,采用与实验 1 中相同的数据集,并设置相同的参数.

实验结果如图 4 所示.与图 2 相结合可以看出,在大多数情况下,模型融合比推荐融合的覆盖率要高,而推荐的准确率要低,这验证了提高准确率会降低覆盖率的结论.同时还可以发现,采用改进方法时,覆盖率往往介于两种基本融合方法之间.事实上,在推荐准确率的实验中,改进方法的准确率相比两种基本融合方法是最高的,而在推荐覆盖率上并不是最差的,因此可以说明,在提高推荐准确率时,改进方法牺牲的推荐覆盖率是比较低的,也就是说,在同时考虑推荐准确率和推荐覆盖率时,改进方法较两种基本融合方法具有更高的性能.

其次,预测评分算法的选取对推荐覆盖率的影响是最大的,采用基于物品的协同过滤算法的推荐覆盖率显著高于其他算法.基于矩阵分解的算法,推荐准确率是最高的,但是它的覆盖率明显不如其他几种算法,因为采用 nDCG 作为准确率评价指标时,推荐列表中项目的顺序对准确率影响较大,实际评分高的项目在推荐列表中越靠前,准确率越高.这说明,基于矩阵分解的算法在推荐顺序上效果较好,能够将实际评分高的项目首先推荐给用户;而覆盖率低说明,该算法总是将相同的一小部分项目优先推荐.这一现象说明,

基于矩阵分解的算法总是将最热门、评价最高的一部分项目作为优先推荐,因此出现了准确率很高而覆盖率很低的现象.

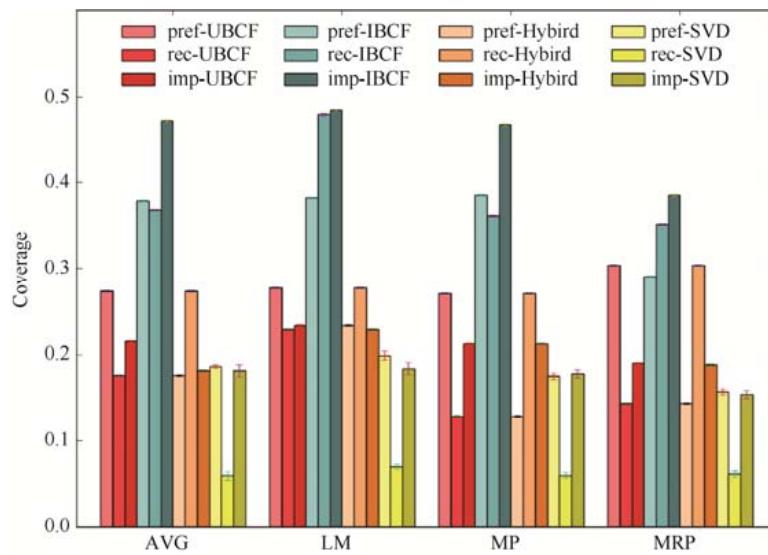


Fig.4 Coverage of the group recommendations

图 4 推荐覆盖率

实验 3. 推荐多样性实验.

推荐多样性反映出推荐系统是否总是将一些类似的项目推荐给用户,若多样性过低,则会导致用户产生厌烦情绪,本实验采用与实验 1 中相同的数据集,并设置相同的参数.实验结果如图 5 所示.

从图 5 可以看出,预测评分算法对推荐多样性的影响最大,并与覆盖率类似,采用基于物品的协同过滤算法时多样性最高;在对不同融合方法进行对比时,多样性的高低与推荐准确度的高低往往呈相反趋势,即推荐准确率相对较高的算法,在多样性上相对较低.同时,改进的偏好融合组推荐方法,在推荐多样性上介于两种基本融合方法之间,这说明改进方法在提高推荐准确性时,牺牲的多样性是较低的.

同时,结合推荐准确率、覆盖率和多样性的实验结果,可以发现,对于 4 种融合策略,最小痛苦策略在各方面的表现相较于其他融合策略更好,因此在进一步实验时,选取这种策略作为融合策略.

实验 4. 融合权重影响实验.

改进的偏好融合组推荐方法,基础是两种基本融合方法,在前面的实验中,设置融合权重 $\alpha=0.5$,使两种基本融合方法对推荐结果的贡献权重相等.本实验主要研究在生成推荐结果的融合过程中,采用不同的权重,对推荐结果的影响.本实验采用基于用户的协同过滤算法作为预测评分算法,融合策略使用最小痛苦策略,使用高相似度群组作为数据集.同时,为了进一步证明,在改进方法中,利用“群组偏好与个人偏好具有相似性”的结论能够有效提高推荐准确率,将单纯的推荐列表融合方法作为对比方法.单纯的推荐列表融合方法同样采用公式(6)生成推荐列表,但其输入的两个推荐列表是分别单独采用模型融合与推荐融合生成的推荐列表.图中的“base”方法表示单纯的列表融合方法,对于这种方法,当 $\alpha=0$ 时,推荐融合的权重为 0,推荐结果与采用模型融合方法的效果相同;同理,当 $\alpha=1$ 时,与推荐融合方法的推荐结果相同.

1) 从图 6 可以看出,采用单纯的推荐列表融合方法时,选取合适的权重 α 可以让推荐准确率高于两种基本融合方法,这说明,同时考虑两种融合方法时,能够得到更好的推荐准确率.

2) 从图 6 还可以看出,采用改进方法时,推荐准确率随 α 的改变趋势与单纯的推荐列表融合方法基本相同,都类似于二次曲线,但加入了群组偏好与个人偏好共同训练的改进方法后,在推荐准确率上,总是比单纯的推荐列表融合方法要好,这说明,利用“群组偏好与个人偏好具有相似性”的结论,将群组偏好与个人偏好共同训练,能

够有效地提高推荐准确率。

3) 在覆盖率和多样性上,从图 7 和图 8 可以看出,改进方法与单纯的推荐列表融合方法有着相似的变化趋势,且表现出的性能数值也类似,这说明,改进方法在提高推荐准确率的同时,牺牲的覆盖率和多样性较少,其整体推荐性能相对较高。

实验 5. 组内相似度影响实验。

实验 1~实验 3 在随机生成的群组中进行了推荐准确率、覆盖率和多样性的实验。Baltrunas 等人^[13]证明,组内相似度对推荐结果具有一定的影响。为了得到改进方法的推荐结果在随机群组和高相似度群组之间的差异,我们同时采用 MovieLens-Rand 和 MovieLens-Simi 数据集进行对比实验,得到改进方法在不同情况下的表现情况。高相似度群组的组内相似度由 Pearson 相关系数计算,阈值为 0.27。融合策略采用均值策略和最小痛苦策略。

从图 9 可以看出,采用高相似度群组时,大部分情况下,改进方法的推荐准确率都要高于两种基准方法;采用基于物品的协同过滤方法时,模型融合和推荐融合的推荐结果差异缩小,这使得改进方法的推荐准确率相比基准方法差距减小;采用矩阵分解的方法,在推荐准确率上有所提高,这是因为,用户相似度提高时,用户更可能喜欢那些热门和评分较高的项目,因此基于矩阵分解的推荐都有更高的推荐准确率。

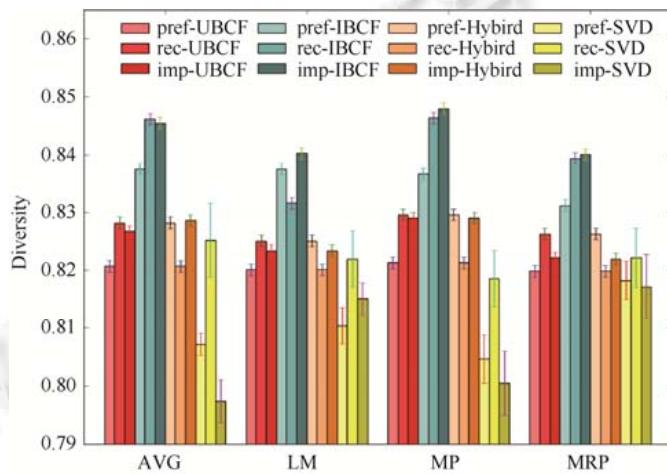


Fig.5 Diversity of the recommendations

图 5 推荐多样性

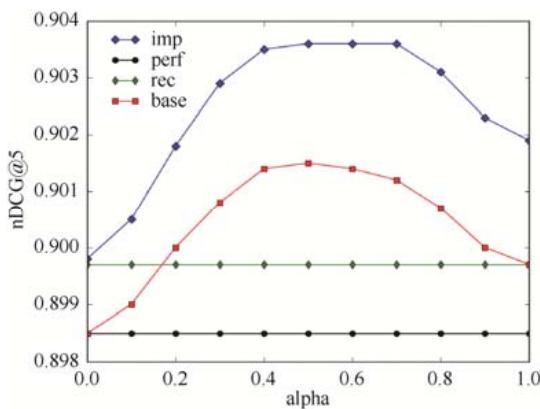


Fig.6 The accuracy of the recommendations for different aggregation weights

图 6 不同融合权重下的推荐准确率

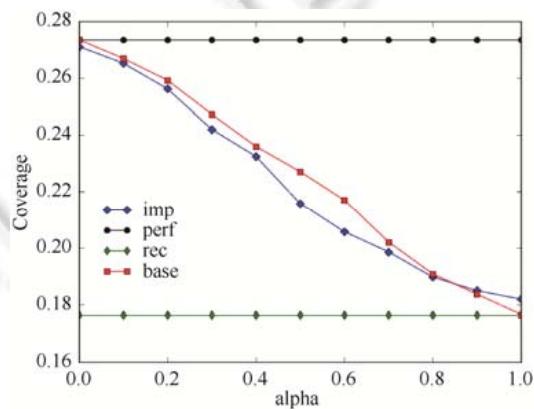


Fig.7 The coverage of the recommendations for different aggregation weights

图 7 不同融合权重下的推荐覆盖率

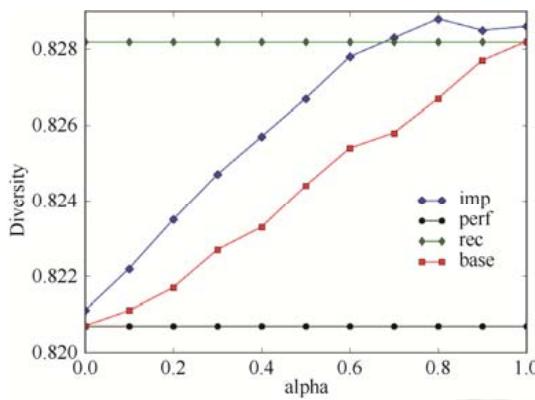


Fig.8 The diversity of the recommendations for different aggregation weights

图 8 不同融合权重下的推荐多样性

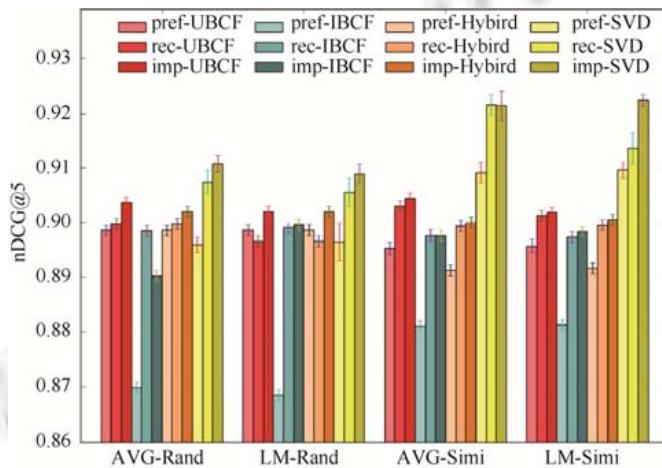


Fig.9 The accuracy of the recommendations for different dataset

图 9 不同数据集下的推荐准确率

实验 6. 群组规模影响实验。

群组规模会影响推荐质量^[34],本实验分别固定群组人数为 2、3、4、5、10 人,然后分别进行推荐准确率、覆盖率和多样性实验,为了方便对比,本实验的融合策略采用均值策略.实验使用 MovieLens-Rand 数据集,实验结果如图 10~图 12 所示.

由图 10 可以看出,推荐准确率随着群组规模的扩大逐渐下降,改进方法在大多数情况下的推荐准确率要高于其余两种融合方法,当群组规模比较大时(size=10),采用不同的预测评分算法进行推荐,推荐准确率间的差距明显减小.从图 11 可以看出,随着群组规模的扩大,推荐覆盖率有明显下降,当群组人数为 10 时,覆盖率降到很低.从图 12 可以看出,当预测评分算法采用基于物品的协同过滤时,多样性随着群组规模的扩大有所下降,采用其他算法时,群组规模对多样性的影响不是很大.

从图 10~图 12 可以看出,采用改进方法与两种基本融合方法进行对比时,无论群组规模大小如何,其推荐准确率、覆盖率、多样性,与实验 1~实验 3 中表现出的特性相似.因此,随着群组规模的扩大,并不影响改进方法与基准方法之间表现出的关系,即大多数情况下,改进方法的推荐准确率高于其他两种基准算法,覆盖率和多样性介于两者之间.

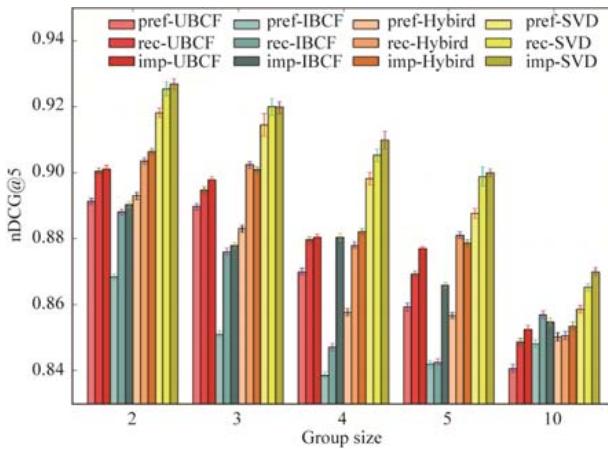


Fig.10 The accuracy of the recommendations for different group size

图 10 不同群组规模下的推荐准确率

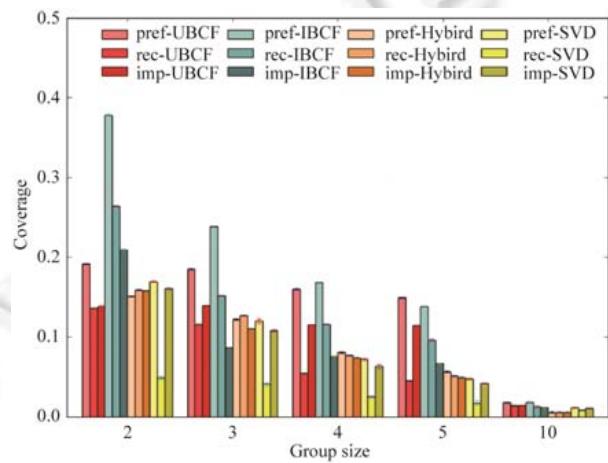


Fig.11 The coverage of the recommendations for different group size

图 11 不同群组规模下的推荐覆盖率

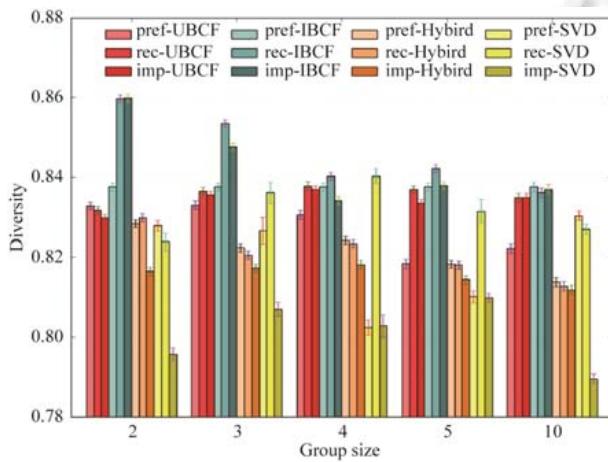


Fig.12 The diversity of the recommendations for different group size

图 12 不同群组规模下的推荐多样性

实验 7. 基于群组聚类的推荐实验.

基于用户的推荐算法的核心是找到偏好相似的用户群,为了提升算法效率和准确性,Ntoutsi^[41]等人提出了利用聚类进行快速推荐的组推荐模型.本文提出的一种改进的偏好融合组推荐方法,在推荐时也可以应用这种通过用户聚类进行计算加速的模型,从而加快计算速度.为了探究用户聚类对推荐的影响,尤其是对推荐效率的影响,本实验采用文献[41]中的模型,并应用于改进方法,进行对比实验.

本实验采用两种聚类算法:(1) 方法 1 采用与文献[41]相同的层次聚类算法,事先对用户进行聚类,为用户进行预测评分时,从与其属于同一类簇的用户中选取用户进行预测评分;(2) 方法 2 采用模糊聚类的方法,使用余弦相似度计算用户间的相似程度,得到[0,1]区间上的标准化相似矩阵,然后采用平方法求传递闭包,取 $\lambda=0.6$ 得到该 λ -截集下的聚类结果.

实验使用 MovieLens-Rand 数据集,融合策略采用均值策略,实验结果如图 13 所示,从图中可以看出,在该数据集中,采用模糊聚类的推荐准确率,相比普通层次聚类要高;无论采用哪种聚类方法,模型融合的推荐准确率最低,推荐融合的推荐准确率略高,改进方法的推荐准确率最高.这说明,采用聚类方法进行计算加速时,无论采用哪种聚类方法,改进的偏好融合组推荐方法总具有更好的推荐准确性.

为了直观地看出改进方法在使用聚类进行快速推荐时,随数据量的增加,快速推荐能够节省的时间,我们将程序运行时间记录下来,如图 14 所示,横坐标表示需要预测的群组个数,纵坐标为运行时间,单位是 ms,使用 MovieLens-Rand 数据集.从图中可以看出,基于聚类的组推荐方法可以应用在改进的偏好融合组推荐方法中,并且可以很好地缩短推荐时间,增加推荐效率.同时,结合图 13 还可以看出,采用基于聚类的组推荐方法时,在节省大量时间的同时,改进方法依然保持了较高的推荐准确率.

实验 8.CAMRa 2011 数据集推荐实验.

随机生成数据集适合进行群组规模、组内相似度等实验,因为在真实数据集中很难找到大量的群组数据用于这些检验群组自身性质的实验.例如,我们很难从真实数据集中找到大量包含 10 个成员的群组评分信息.因此,利用传统推荐系统的数据集,根据实验评价所需群组特征,从公开数据集中构造群组^[13,36],是目前常用的解决方法.

但是,通过数据随机生成的群组对象,其实验说服力存在局限,因此我们采集了真实数据集 CAMRa 2011 的数据,CAMRa 2011 是家庭电影推荐数据集,信息包括用户对电影的评价以及用户所属的家庭关系.我们在该数据集上进行了推荐准确率和覆盖率实验,但是由于该数据集未提供电影编号对应的具体影片信息,所以无法进行多样性实验.实验结果如图 15、图 16 所示.

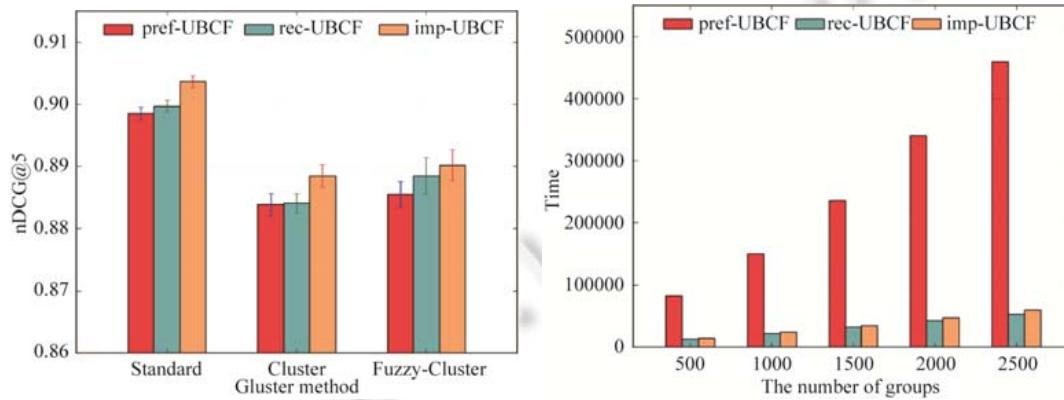


Fig.13 The accuracy of the recommendations for different cluster method

图 13 不同聚类方法下的推荐准确率

Fig.14 The run time of the recommendations

图 14 运行时间

从图 15 可以看出,在 CAMRa 2011 数据集上,与随机生成群组的数据集不同,采用推荐融合的基于用户的协

同过滤算法,推荐准确率在很多情况下都比较低;采用基于物品的协同过滤算法时,推荐效果都比较好,而在随机生成群组的数据集中,采用模型融合的基于物品的协同过滤算法效果不佳。从图 16 可以看出,基于矩阵分解的算法在覆盖率上非常低,这说明,该方法总是将最热门的项目推荐给用户,其他算法的推荐效果与随机生成数据集中的实验结果类似。

从图 15、图 16 可以看出,采用改进方法时,对比真实数据集 CAMRa 2011 和传统随机生成群组的数据集,其推荐效果是类似的,即在大多数情况下,改进方法的推荐准确率高于两种基本融合方法,同时,其覆盖率介于两种基本融合方法之间。这说明,改进的偏好融合组推荐方法具有更高的整体推荐性能。

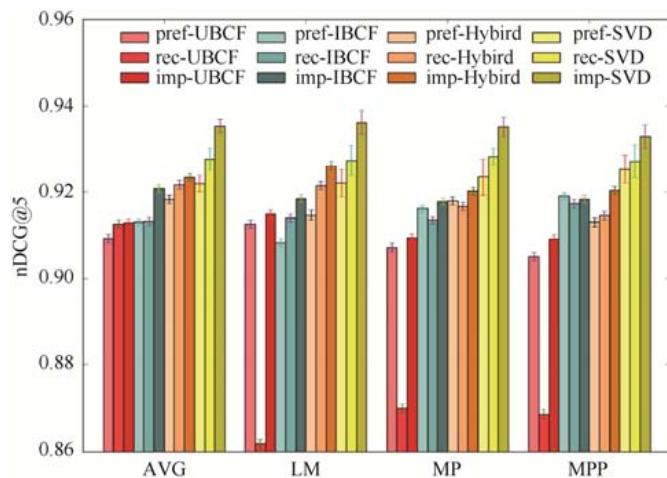


Fig.15 The accuracy of the recommendations for CAMRa 2011 dataset

图 15 CAMRa 2011 数据集下的推荐准确率

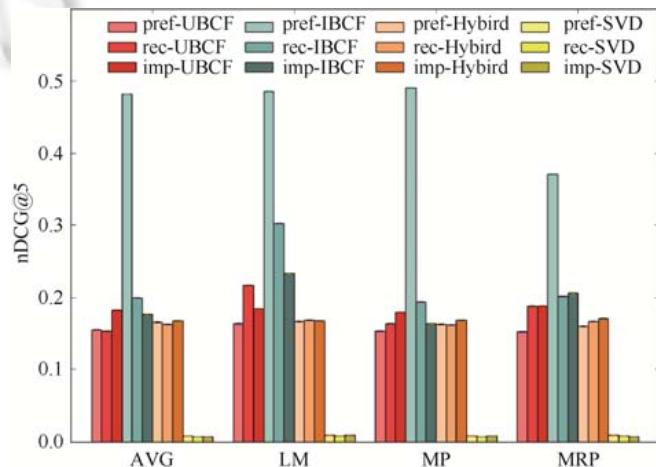


Fig.16 The coverage of the recommendations for CAMRa 2011 dataset

图 16 CAMRa 2011 数据集下的推荐覆盖率

4 总 结

本文根据组推荐系统的特征,首先通过实验得出了“群组偏好与个人偏好具有相似性”的结论,然后将它应用在群组偏好建模中,丰富了用户偏好信息,使推荐准确率有所提升;对于传统的模型融合与推荐融合方法,本文提出一种改进的偏好融合组推荐方法,将群组偏好与个人偏好共同进行训练,结合了两种基本融合方法的优

点。实验结果表明,在大多数情况下,本文提出的方法能够以牺牲较小的覆盖率和多样性为代价,有效提升推荐准确率,证明了该方法具有较高的整体推荐性能。目前,两种基本融合方法的效用好坏仍没有定论,本文提出的方法基于两种基本融合方法,在两种基本融合方法的推荐性能差距较小时,改进方法拥有比两种基本融合方法都要高的推荐准确率,因此,采用改进方法可以解决选择性问题。

改进方法将个人偏好与群组偏好混合起来,增加了相似度计算的时间复杂度,进行列表融合等操作时增加了方法实现的难度。因此,如何提高改进方法的推荐效率,是进一步研究时需要解决的问题。

References:

- [1] Xu HL, Wu X, Li XD, Yan BP. Comparison study of internet recommendation system. *Ruan Jian Xue Bao/Journal of Software*, 2009,20(2):350–362 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/3388.htm>
- [2] Park Y, Park S, Jung W, Lee SG. Reversed CF: A fast collaborative filtering algorithm using a k -nearest neighbor graph. *Expert Systems with Applications*, 2015,42(8):4022–4028. [doi: 10.1016/j.eswa.2015.01.001]
- [3] Ma H, Yang H, Lyu MR, King I. SoRec: Social recommendation using probabilistic matrix factorization. In: Proc. of the 17th ACM Conf. on Information and Knowledge Management. ACM Press, 2008. 931–940. [doi: 10.1145/1458082.1458205]
- [4] Shi Y, Larson M, Hanjalic A. Mining mood-specific movie similarity with matrix factorization for context-aware recommendation. In: Proc. of the Workshop on Context-Aware Movie Recommendation. Barcelona: ACM Press, 2010. 34–40. [doi: 10.1145/1869652.1869658]
- [5] Meng XW, Hu X, Wang LC, Zhang YJ. Mobile recommender systems and their applications. *Ruan Jian Xue Bao/Journal of Software*, 2013,24(1):91–108 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/4292.htm> [doi: 10.3724/SP.J.1001.2013.04292]
- [6] Wang LC, Meng XW, Zhang YJ. Context-Aware recommender systems. *Ruan Jian Xue Bao/Journal of Software*, 2012,23(1):1–20 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/4100.htm> [doi: 10.3724/SP.J.1001.2012.04100]
- [7] Meng XW, Liu SD, Zhang YJ, Hu X. Research on social recommender systems. *Ruan Jian Xue Bao/Journal of Software*, 2015, 26(6):1356–1372 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/4831.htm> [doi: 10.13328/j.cnki.jos.004831]
- [8] Zhang YJ, Du YL, Meng XW. Research on group recommender systems and their applications. *Chinese Journal of Computers*, 2016,39(4):745–764 (in Chinese with English abstract). [doi: 10.11897/SP.J.1016.2016.00745]
- [9] Garcia I, Sebastia L, Onaindia E. On the design of individual and group recommender systems for tourism. *Expert Systems with Applications*, 2011,38(6):7683–7692. [doi: 10.1016/j.eswa.2010.12.143]
- [10] Jameson A, Smyth B. Recommendation to groups. In: The Adaptive Web. Berlin: Springer-Verlag, 2007. 596–627. [doi: 10.1007/978-3-540-72079-9_20]
- [11] Dyer JS, Sarin RK. Group preference aggregation rules based on strength of preference. *Management Science*, 1979,25(9):822–832. [doi: 10.1287/mnsc.25.9.822]
- [12] Masthoff J. Recommender Systems Handbook. New York: Springer-Verlag, 2010. 677–702.
- [13] Baltrunas L, Makcinskas T, Ricci F. Group recommendations with rank aggregation and collaborative filtering. In: Proc. of the 4th ACM Conf. on Recommender Systems (RecSys 2010). Barcelona: ACM Press, 2010. 407–423.
- [14] McCarthy JF, Anagnost TD. MusicFX: An arbiter of group preferences for computer supported collaborative workouts. In: Proc. of the 1998 ACM Conf. on Computer Supported Cooperative Work. ACM Press, 1998. 363–372. [doi: 10.1145/289444.289511]
- [15] Quijano-Sánchez L, Díaz-Agudo B, Recio-García JA. Development of a group recommender application in a social network. *Knowledge-Based Systems*, 2014,71:72–85. [doi: 10.1016/j.knosys.2014.05.013]
- [16] Berry S, Fazzio S, Zhou Y, Scott B, Francisco-Revilla L. Netflix recommendations for groups. *American Society for Information Science*, 2010,47(1):150.
- [17] Guzzi F, Ricci F, Burke R. Interactive multi-party critiquing for group recommendation. In: Proc. of the Conf. on Recommender Systems (RecSys 2011). Chicago: ACM Press, 2011. 265–268. [doi: 10.1145/2043932.2043980]
- [18] Beckmann C, Gross T. AGReMo: Providing ad-hoc groups with on-demand recommendations on mobile devices. In: Proc. of the Conf. of the European Association of Cognitive Ergonomics. Rostock: ACM Press, 2011. 179–182. [doi: 10.1145/2074712.2074747]

- [19] Gorla J, Lathia N, Robertson S, Wang J. Probabilistic group recommendation via information matching. In: Proc. of the 22nd Int'l Conf. on World Wide Web. New York: ACM Press, 2013. 495–504. [doi: 10.1145/2488388.2488432]
- [20] Feng X, Zhang X, Wu G, Gu J. TV program recommendation for multiple viewers based on user profile merging. *User Modeling and User-Adapted Interaction*, 2006, 16(1):63–82. [doi: 10.1007/s11257-006-9005-6]
- [21] O'Connor M, Dan C, Konstan JA, Riedl J. PolyLens: A recommender system for groups of users. In: Proc. of the European Conf. on Computer Supported Cooperative Work. Bonn: Kluwer Academic Press, 2001. 199–218.
- [22] Skowron P, Faliszewski P, Lang J. Finding a collective set of items: From proportional multirepresentation to group recommendation. *Artificial Intelligence*, 2014, 241:191–216. [doi: 10.1016/j.artint.2016.09.003]
- [23] Garcia I, Sebastia L. A negotiation framework for heterogeneous group recommendation. *Expert Systems with Applications*, 2014, 41(4):1245–1261. [doi: 10.1016/j.eswa.2013.07.111]
- [24] Castro J, Quesada FJ, Palomares I, Martínez L. A consensus-driven group recommender system. *Int'l Journal of Intelligent Systems*, 2015, 30(8):887–906. [doi: 10.1002/int.21730]
- [25] Ghazarian S, Nematabkhsh MA. Enhancing memory-based collaborative filtering for group recommender systems. *Expert Systems with Applications*, 2015, 42(7):3801–3812. [doi: 10.1016/j.eswa.2014.11.042]
- [26] Amer-Yahia S, Omidvar-Tehrani B, Roy SB, Shabib N. Group recommendation with temporal affinities. In: Proc. of the 18th Int'l Conf. on Extending Database Technology. 2015. 159–168. [doi: 10.5441/002/edbt.2015.37]
- [27] Kašák O, Kompan M, Bieliková M. Personalized hybrid recommendation for group of users: Top-*N* multimedia recommender. *Information Processing & Management*, 2016, 52(3):459–477. [doi: 10.1016/j.ipm.2015.10.001]
- [28] Quijano-Sánchez L, Recio-García JA, Diaz-Agudo B. An architecture and functional description to integrate social behaviour knowledge into group recommender systems. *Applied Intelligence*, 2014, 40(4):732–748. [doi: 10.1007/s10489-013-0504-y]
- [29] Christensen I, Schiaffino S, Armentano M. Social group recommendation in the tourism domain. *Journal of Intelligent Information Systems*, 2016, 47(2):1–23. [doi: 10.1007/s10844-016-0400-0]
- [30] Liu X, Tian Y, Ye M, Lee WC. Exploring personal impact for group recommendation. In: Proc. of the 21st ACM Int'l Conf. on Information and Knowledge Management. Hawaii: ACM Press, 2012. 674–683. [doi: 10.1145/2396761.2396848]
- [31] Yuan Q, Cong G, Lin CY. COM: A generative model for group recommendation. In: Proc. of the 20th ACM SIGKDD Int'l Conf. on Knowledge Discovery and Data Mining. New York: ACM Press, 2014. 163–172. [doi: 10.1145/2623330.2623616]
- [32] Berkovsky S, Freyne J. Group-Based recipe recommendations: Analysis of data aggregation strategies. In: Proc. of the 4th ACM Conf. on Recommender Systems (RecSys 2010). Barcelona: ACM Press, 2010. 111–118. [doi: 10.1145/1864708.1864732]
- [33] Ortega F, Bobadilla J, Hernando A, Gutiérrez A. Incorporating group recommendations to recommender systems: Alternatives and performance. *Information Processing & Management*, 2013, 49(4):895–901. [doi: 10.1016/j.ipm.2013.02.003]
- [34] Pessemier TD, Dooms S, Martens L. Comparison of group recommendation algorithms. *Multimedia Tools & Applications*, 2014, 72(3):2497–2541. [doi: 10.1007/s11042-013-1563-0]
- [35] Shani G, Gunawardana A. Recommender Systems Handbook. New York: Springer-Verlag, 2010. 677–702.
- [36] Quijano-Sánchez L, Recio-García JA, Diaz-Agudo B. Personality and social trust in group recommendations. In: Proc. of the 22nd Int'l Conf. on Tools with Artificial Intelligence. IEEE Press, 2010. 121–126. [doi: 10.1109/ICTAI.2010.92]
- [37] Recio-García JA, Jimenez-Díaz G, Sanchez-Ruiz AA, Diaz-Agudo B. Personality aware recommendations to groups. In: Proc. of the 3rd ACM Conf. on Recommender Systems. New York: ACM Press, 2009. 325–328. [doi: 10.1145/1639714.1639779]
- [38] Gim G, Jeong H, Lee H, Yun D. Group-Aware prediction with exponential smoothing for collaborative filtering. In: Proc. of the 2nd Challenge on Context-Aware Movie Recommendation. Chicago: ACM Press, 2011. 11–14. [doi: 10.1145/2096112.2096115]
- [39] Said A, Berkovsky S, De Luca EW. Group recommendation in context. In: Proc. of the 2nd Challenge on Context-Aware Movie Recommendation. Chicago: ACM Press, 2011. 2–4. [doi: 10.1145/2096112.2096113]
- [40] Herlocker JL, Konstan JA, Terveen LG, John, Riedl T. Evaluating collaborative filtering recommender systems. *ACM Trans. on Information Systems*, 2004, 22(1):5–53. [doi: 10.1145/963770.963772]
- [41] Ntoutsi E, Stefanidis K, Nørvåg K, Kriegel HP. Conceptual Modeling. Berlin: Springer-Verlag, 2012. 126–140.

附中文参考文献:

- [1] 许海玲,吴潇,李晓东,阎保平.互联网推荐系统比较研究.软件学报,2009,20(2):350–362. <http://www.jos.org.cn/1000-9825/3388.htm>
- [5] 孟祥武,胡勋,王立才,张玉洁.移动推荐系统及其应用.软件学报,2013,24(1):91–108. <http://www.jos.org.cn/1000-9825/4292.htm> [doi: 10.3724/SP.J.1001.2013.04292]
- [6] 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]
- [7] 孟祥武,刘树栋,张玉洁,胡勋.社会化推荐系统研究.软件学报,2015,26(6):1356–1372. <http://www.jos.org.cn/1000-9825/4831.htm> [doi: 10.13328/j.cnki.jos.004831]
- [8] 张玉洁,杜雨露,孟祥武.组推荐系统及其应用研究.计算机学报,2016,39(4):745–764.



胡川(1992—),男,北京人,硕士生,主要研究领域为推荐系统,数据挖掘.



张玉洁(1969—),女,副教授,主要研究领域为网络服务,推荐算法.



孟祥武(1966—),男,博士,教授,博士生导师,CCF 高级会员,主要研究领域为网络服务,推荐服务,需求获取.



杜雨露(1987—),男,博士生,主要研究领域为个性化推荐系统.