

可提高多样性的基于推荐期望的 top-N 推荐方法

刘慧婷 岳可诚

(安徽大学计算机科学与技术学院 合肥 230601)

摘要 推荐系统帮助用户在海量信息中找到与用户相关的、个性化的产品,现有推荐技术大多致力于改进推荐系统的预测准确度。最近,推荐质量的另一个重要方面——推荐的多样性,越来越受到人们的重视。提出了一种基于物品推荐期望的 top-N 推荐方法,在向用户进行 top-N 推荐时,可以通过控制全体物品的推荐期望,来达到提高推荐总体多样性的目的。结合多种评价方法,使用不同的评分预测算法在真实的电影评分数据集上对提出的算法进行了实验,结果证明提出的算法能够在保证推荐准确度的同时,显著提高推荐的总体多样性。

关键词 推荐系统, top-N 推荐, 多样性, 推荐期望

中图分类号 TP391.4 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2014.07.056

Expectation-based top-N Recommendation Approach for Improving Recommendations Diversity

LIU Hui-ting YUE Ke-cheng

(School of Computer Science and Technology, Anhui University, Hefei 230601, China)

Abstract Recommender systems are used to help users find relevant and personalized items from a large set of alternatives in many online applications. Most existing recommendation techniques are focused on improving recommendation accuracy. Recently, diversity of recommendations has also been increasingly recognized in research literature as an important aspect of recommendation quality. This paper proposed a novel top-N recommendations generated approach to improve aggregate recommendation diversity by controlling the recommended expectations of the global candidate items, which is available for recommendation in the top-N recommendations generating process. The proposed approach was evaluated using real-world movie rating datasets and different rating prediction algorithms. Results demonstrate the approach proposed in this paper can generate more diverse recommendations while maintaining an acceptable level of accuracy.

Keywords Recommender systems, Top-N recommendations, Diversity, Recommendation expectation

1 引言

在过去的十几年里推荐系统取得了较大的发展,对推荐技术的研究大部分集中在改进推荐的准确度上。然而,越来越多的人意识到,仅仅精确对推荐来说是不够的,推荐结果其他方面的因素,如多样性、新颖性、覆盖率等都在对推荐的质量、用户的体验产生影响^[1-3]。特别地,多样化推荐的重要性已经在若干研究中^[4-8]被强调。这些研究认为推荐系统的一个目标是向用户提供高度异质或个性化的产品,而具有更高多样性的推荐会使用户有更大的机会获取这样的产品。

本文主要关注推荐的总体多样性(Aggregate Diversity)。总体多样性描述的是推荐系统向所有用户所推荐物品的多样性状况。最近,一些研究^[1,6,9]发现推荐的总体多样性会对产品的销售分布产生影响。“长尾”理论(“Long Tail” Literature)认为多样性能够促进产品在销售中形成长尾分布^[6,7],这将给用户和一些商业实体带来好处^[6,9]。为此,人们开始探索能够增加总体多样性的新技术^[4,10,11]。

通常,推荐系统为用户计算推荐可以分为两个阶段:阶段 1,预测用户未消费的产品评分;阶段 2,为每个用户生成 top-N 推荐列表。根据这两个阶段,增加多样性的技术可以分为两条研究路线。第一条研究路线^[10,11]通过在评分预测阶段增加干预来提高多样性,另一条则是在推荐产生阶段寻找一个最佳的推荐集合^[4,12]。后者由于是在预测评分已求出后再产生推荐,因此可与任意现有的评分预测算法相结合。本文提出的方法在研究线路上与后者相符,因此继承了其易扩展的优点,并且对比文献^[4,12]中提出的可改进多样性的重排名方法,本文的方法可以在同样的准确度水平上提供更高的推荐多样性。

2 相关工作

为了对实验结果做出有效的评估,本节讨论了推荐质量的两个重要方面:准确度和多样性。此外,为了与本文提出的方法作对比,还介绍了文献^[4,12]中提出的推荐重排名方法,该方法已被证明能够较好地提高推荐多样性,而造成的准确

到稿日期:2013-09-18 返修日期:2014-01-06 本文受国家自然科学基金项目(61202227)资助。

刘慧婷(1978—),女,博士,副教授,主要研究方向为数据挖掘、机器学习等,E-mail:htliu@ahu.edu.cn;岳可诚(1988—),男,硕士生,主要研究方向为数据挖掘。

度损失较小。

首先介绍一下本文使用的符号定义： U 为推荐系统中的用户集合， I 为物品集合。用户 $u \in U$ 对物品 $i \in I$ 的评分构成映射 $R: U \times I \rightarrow \text{Rating}$ ， Rating 的形式通常可以为数值、序数，或二元值。用 $R(u, i)$ 表示用户 u 对物品 i 的实际评分，即已知评分，用 $R^*(u, i)$ 表示利用预测算法预测出的用户 u 对物品 i 的预测评分。

2.1 推荐准确度和多样性

2.1.1 推荐准确度

对于 top-N 推荐列表的准确度的评估，通常使用信息获取技术中的准确率 (Precision) 方法^[1,4,13]。推荐系统的准确率是指推荐给所有用户的物品中“相关”物品所占的比例。

然而在实际应用中，用来计算准确率的评分 $R(u, i)$ 在物品 i 被特定用户消费前是未知的，因此所生成的 top-N 推荐列表的真实准确率在推荐时期也是未知的。为此，本文使用 Adomavicius 等^[12] 提出的基于预测评分的准确率评估方法——prediction-in-top-N 方法来评估推荐的准确率。Adomavicius 等^[12] 通过在两个真实的数据集 (Netflix 评分数据集和 MovieLens 评分数据集) 上用多种不同的协同过滤算法和交叉验证法进行实验，发现推荐的准确率与通过这些算法得出的预测评分的平均值高度相关 (Netflix 数据集上两者的 Pearson 相关系数为 0.974, MovieLens 上为 0.966)。因此，可以使用 top-N 推荐列表预测评分的平均值作为准确率方法的简单代理，这种方法即为 prediction-in-top-N，定义为：

$$\text{prediction-in-top-N} = \frac{\sum_{u \in U} \sum_{i \in L_N(u)} R^*(u, i)}{\sum_{u \in U} |L_N(u)|} \quad (1)$$

$L_N(u)$ 为用户 u 的 top-N 推荐列表。

2.1.2 推荐多样性

推荐结果的多样性可以分为个体多样性和总体多样性。个体多样性旨在避免向单个用户推荐过于相似的物品。一些研究^[5,14] 通过推荐列表中各物品对的相似性来评估个体多样性，文献^[8] 采用物品的新颖度来计算个体多样性。然而高的个体多样性并不意味着高的总体多样性，例如，推荐系统向所有用户推荐了同样的 5 个各不相同的物品，对于每个用户其个体多样性是较高的，但从全局角度看，仅向所有用户推荐了 5 个不同物品，因此总体多样性很低。本文研究的正是总体多样性。

本文采用文献^[4] 针对 top-N 推荐任务提出的一种总体多样性评估方法——diversity-in-top-N，该方法利用推荐给所有用户的不同物品数来评估总体多样性，定义为：

$$\text{diversity-in-top-N} = \left| \bigcup_{u \in U} L_N(u) \right| \quad (2)$$

diversity-in-top-N 虽然在一定程度上反映了推荐的多样性，但无法衡量出被推荐物品的整体分布情况。例如，当系统仅向一小部分用户推荐了新物品时，diversity-in-top-N 指标就能较为容易地得到提高，但这无法说明被推荐物品的分布是否朝着更加异质的方向变化。为此，本文还使用了两种基于分布的多样性评估方法：Entropy^[4,15]、Gini coefficient^[1,12]。它们利用不同方式来测量推荐物品的分布状况。基于 entropy 的多样性评价方法 Entropy-Diversity 的计算公式^[16] 为：

$$\text{Entropy-Diversity} = - \sum_{i=1}^n \left(\frac{\text{rec}(i)}{\text{total}} \right) \ln \left(\frac{\text{rec}(i)}{\text{total}} \right) \quad (3)$$

其中， $\text{rec}(i)$ 为推荐列表中拥有物品 i 的用户数， n 为可供推

荐的候选物品总数， total 为系统为所有用户产生的 top-N 推荐总数，即 $\text{total} = N|U|$ 。其函数值越大表示多样性越大。基于 Gini coefficient^[15] 的评价方法 Gini-Diversity 的计算公式为：

$$\text{Gini-Diversity} = - \sum_{j=1}^n (2j-n-1) \times \left(\frac{\text{rec}(i_j)}{\text{total}} \right) \quad (4)$$

其中， i_1, i_2, \dots, i_n 为按照 $\frac{\text{rec}(i_j)}{\text{total}}$ 大小升序排列的物品序列，函数值越小表示多样性越大。式(2)一式(4)所示的 3 个函数可以表示为同一个抽象多样性评估函数 $D(\bigcup_{u \in U} L_N(u))$ 。

2.2 可提高多样性的重排名方法

当已预测出每个用户对物品的未知评分后，即进入 top-N 推荐产生阶段，系统根据某种排序标准选择最相关的物品向用户做推荐。大部分推荐系统根据预测评分对候选物品进行排序，然后向每个用户推荐前 N 个评分最高的候选物品。因为用户一般只对有限个推荐感兴趣，所以 N 通常是一个相对较小的正整数。文献^[4,12] 将这种推荐选择策略定义为标准排名方法 (Standard Approach)，可以表示为排名函数：

$$\text{rank}_{\text{Standard}}(i) = R^*(u, i)^{-1} \quad (5)$$

尽管标准排序方法具有最好的推荐准确度，但它在推荐多样性方面的性能较差。

Adomavicius 等^[4,12] 提出一种参数化的重排名方法 (Re-Ranking Approach)。通过改变物品的排名 (相对其在标准排名方法中的顺序) 并引入“排名阈值”，使得系统可以在取得较高多样性的同时只引起很小的准确度损失。重排名方法定义为：

$$\text{rank}_x(i, T_R) = \begin{cases} \text{rank}_x(i), & \text{if } R^*(u, i) \in [T_R, T_{\max}] \\ \alpha_u + \text{rank}_{\text{Standard}}(i), & \text{if } R^*(u, i) \in [T_H, T_R) \end{cases}$$

where $\alpha_u = \max_{i \in I_u^*(T_R)} \text{rank}_x(i)$,
and $I_u^*(T_R) = \{i \in I | R^*(u, i) \geq T_R\}$ (6)

该方法可以结合不同的启发式排名方法 $\text{rank}_x(i)$ 。为与本文所提方法做比较，我们使用了两种启发式排名方法：按预测评分升序排名法 (Reverse Approach) 和随机排名法 (Random Approach)^[4,12]。前者可以定义为：

$$\text{rank}_{\text{RevPred}}(i) = R^*(u, i) \quad (7)$$

当预测评分大于阈值 T_R 时，使用 $\text{rank}_x(i)$ 计算物品排名；预测评分小于 T_R 时则使用标准排名方法计算物品排名。 α_u 随着 T_R 的改变而改变，其存在确保了预测评分落在 $[T_R, T_{\max}]$ 内的物品的排名领先于预测评分落在 $[T_H, T_R)$ 内的物品 (T_{\max} 为最大评分值， T_H 为判定物品是否与用户相关的阈值，例如在 5 分制的评分中经常取经验值 3.5)。 T_R 越趋近于 T_{\max} ，预测评分高的物品越可能被推荐，推荐的准确度将越大； T_R 越趋近 T_H ，重排名函数的行为越接近 $\text{rank}_x(i)$ ，带来更高多样性的同时会引起一些准确度损失。因此， T_R 具有平衡推荐结果的准确度与多样性的作用。

重排名方法的效率较高。假设系统中有 m 个用户， n 个物品，以按预测评分升序排名法为例，最坏情况下，每个用户拥有全部 n 个候选物品可推荐，对单个用户的候选物品进行排名需要 $O(n \log n)$ 的时间复杂度，对于全部 m 个用户则需要 $O(mn \log n)$ 。

3 本文提出的方法

重排名方法根据当前用户的预测评分,独立地对单个用户的候选物品应用启发式排名法,然后选择排名后的前 N 个物品形成 top-N 推荐列表。考虑总体多样性的全局性质,该方法在对单个用户进行推荐时,仅利用了当前用户候选物品这一局部信息,并未从全局的角度来进行选择推荐。针对重排名方法缺少全局性考虑的缺陷,本文提出了一种基于推荐期望的 top-N 推荐方法(Expectation Approach)。该方法从全局角度求解最大化多样性问题,其相比重排名方法能够找到总体多样性更高且分布更均衡的推荐集合,并且具有较好的时间效率。

3.1 算法的主要思想

首先介绍算法的出发点。如前所述,从“长尾”理论以及推荐系统的目标来看,用推荐列表中被推荐物品的分布状况来衡量推荐的总体多样性要比使用不同的物品数的方法更深刻。考查 Entropy-Diversity 和 Herfindahl-Diversity 等评价物品分布状况的函数可以发现:物品推荐的次数越均衡,函数值则越大,即总体多样性越大。于是最大化总体多样性的问题可以转化为更具体的最大化物品分布均匀度的问题。

另一方面,物品被推荐的次数显然与物品的推荐期望相关。用户之间同一候选物品被推荐与否相互独立,因此某一候选物品的全局推荐期望即为该物品被各用户所推荐的概率之和。可以利用物品的推荐期望来作为物品的推荐次数的代理。本文提出的方法即在推荐的过程中,通过动态地调整所有候选物品的推荐期望,达到平衡物品分布和最大化多样性的目的。

算法每次选择一个物品和一个用户进行推荐,直至所有用户的推荐列表已满为止。在选择候选物品时,我们遵循贪心策略:选择当前可供推荐的候选物品中推荐期望最小的物品。选择这样的物品作推荐,可以有效提高冷门物品被推荐的次数,并且在评分阈值的约束下,推荐结果的准确度也能得到保证。值得注意的是,向一个用户推荐了某物品后,与该用户相关的候选物品的期望会发生变化,因此一次只能选择一个用户来进行推荐,之后需要重新选择期望最小的物品进行下一轮的推荐。下面具体介绍物品的推荐期望模型和待推荐用户的选择策略。

3.2 物品的推荐期望模型

用 U 表示用户的集合, I 表示所有用户的 top-N 列表为空时(即推荐还未发生时)可供推荐的物品集合。为控制多样性与准确度之间的平衡,借鉴重排名方法,引入评分阈值 T_R 。 $I_u = \{i \in I \mid R(u, i) \geq T_R\}$ 表示用户 u 可供推荐的候选物品集合。 T_u 表示用户 u 的 top-N 推荐列表中的物品集合。 U_i 表示拥有物品 i 并且 top-N 推荐列表未滿的用户集合,即 $U_i = \{u \in U \mid i \in I_u, |T_u| < N\}$ 。需要注意的是 I_u 和 T_u 以及与这两者相关的其他集合在推荐产生的过程中是动态变化的,即当物品 $i \in I_u$ 推荐给用户 u 后,有 $I_u \leftarrow I_u - \{i\}$, $T_u \leftarrow T_u \cup \{i\}$, 其中 $I_u \cap T_u = \Phi$, $I_u \cup T_u$ 为用户 u 的初始候选物品集合。视已推荐给某用户的物品被推荐给该用户的概率为 1, 并且每个用户拥有同一件候选物品至多不超过 1 次, 物品 i 推荐给用户 u 的期望即为:

$$E_u(i) = \begin{cases} \frac{N - |T_u|}{|I_u|}, & \text{if } i \in I_u \\ 1, & \text{if } i \in T_u \\ 0, & \text{if } i \notin I_u \cup T_u \end{cases} \quad (8)$$

考虑到各用户之间物品被推荐与否是相互独立的,于是物品 i 被推荐的期望可表示为:

$$E(i) = \sum_{u \in U} E_u(i) \quad (9)$$

3.3 用户选择策略

在确定了待推荐物品后,还需选择待推荐的用户。类似于推荐物品的选择,对推荐用户的选择本文也使用贪心策略。考虑到物品的推荐次数与推荐期望的相关性,而推荐列表即为推荐的集合,基于用户推荐列表的多样性评估函数 $D(\bigcup_{u \in U} L_N(u))$ 可以转化为基于推荐期望的函数。当向用户 $u \in U_i$ 推荐物品 i 后,其所有候选物品的推荐期望发生变化,随之基于期望的多样性评估函数的值也改变。记 ΔD_{ui} 为用户 u 收到物品 i 后引起的多样性变化量。遵循贪心策略可选择用户 w 作为待推荐用户,其中 $w \in U_i$, 且 $\Delta D_{wi} = \max_{u \in U} \Delta D_{ui}$ 。选择不同的用户不会影响推荐物品的总数,因此在计算多样性改变量时只能使用基于分布的多样性函数,如 Entropy-Diversity。

假设系统中有 m 个用户, n 个物品。按照上述策略寻找待推荐用户时,需遍历整个集合 U_i 。最坏情况下,由于计算 ΔD_{ui} 需要 $O(n)$ 的时间复杂度,找到目标用户共需 $O(mn)$ 的时间复杂度。然而,利用下面的性质,可以在结果近似的情况下将时间复杂度降至 $O(1)$ 。假设 u, v 为 U_i 中的任意两个不同用户,不妨设 $|I_u| < |I_v|$, 可以证明,只要满足条件 $|I_u| \gg N + E(i)$, 则有 $\Delta D_{ui} > \Delta D_{vi}$ 。推而广之,只要满足条件 $\min_{u \in U_i} |I_u| \gg N + E(i)$ (实际应用中该条件较易满足), 用户 w 即为待选择用户,其中 $w \in U_i, |I_w| = \min_{u \in U_i} |I_u|$ 。可以用以下方式近似地找到用户 w : 首先对于物品 i , 对每个用户 $u \in U_i$, 按照 $|I_u|$ 值进行 1 次升序排序(需要 $O(m \log m)$ 的复杂度); 以后每次选择时只需选择第 1 个未被推荐过该物品的用户作为用户 w (时间复杂度为 $O(1)$)。由于实际应用中推荐列表的长度值 N 很小,以致整个推荐过程中 $|I_u|$ 的变化也很小,因此每次选择前都进行排序与整个过程中只进行 1 次排序的结果是近似的。

3.4 算法的主要步骤

根据上述讨论,算法的步骤为:

初始时,任意用户 $u \in U$ 的 top-N 推荐物品集合 $T_u = \Phi$ 。

步骤 1 从可供推荐的物品集合 I' ($I' = \{j \in I \mid |U_j| > 0\}$) 中找出当前推荐期望最小的物品 i , 即物品 i 要满足 $E(i) = \min_{j \in I'} E(j)$;

步骤 2 按照用户选择策略从拥有物品 i 且 top-N 推荐列表未滿的用户集合 U_i 中选择一个用户 u , 向其推荐物品 i ;

步骤 3 对 I_u, T_u 做如下更新: $I_u \leftarrow I_u - \{i\}$, $T_u \leftarrow T_u \cup \{i\}$, 并更新期望 $E(i)$, 其中 $i \in I_u$ 。

重复步骤 1-3, 直到所有用户的 top-N 列表 T_u 已滿为止。

对于一个有 m 个用户, n 个物品的推荐系统, 完成 top-N 推荐任务, 上述步骤需要执行 Nm 次。步骤 1 除了首次执行需要 $O(n \log n)$ 的时间复杂度外, 之后每次仅需 $O(n)$ 的复杂

度;使用前面介绍的用户选择策略,步骤2除首次执行需要 $O(nm \log m)$ 的复杂度外,之后每次仅需 $O(1)$ 的复杂度;步骤3的复杂度为更新期望所需的 $O(n)$ 。考虑到 top-N 推荐列表的长度 N 为较小的常数,本算法的时间复杂度即为 $O(Nmn + n \log n + nm \log m) = O(n(\log n + m \log m))$ 。相对于重排名算法的时间复杂度 $O(mn \log n)$,当 $m > n$ 时,本算法的时间复杂度趋近于 $O(nm \log m)$,效率较重排名算法低,但较为接近;当 $m < n$ 时,本算法的复杂度趋近于 $O(n \log n)$,效率较重排名算法高。

4 实验

本实验采用的数据是 MovieLens 的 1M 数据集 (<http://www.grouplens.org/>),该数据集是一个 5 分制的数据集。为便于与文献[4,12]的实验进行对比,本文利用文献[4,12]的数据预处理方法对数据集进行了预处理,即在原数据中选择评分数排在前 2830 位的用户,用户数排在前 1919 位的电影,共包含 775176 个评分。实验用已知评分进行学习,去预测未知评分(占整个 user-item 评分矩阵的 85.73%)。

实验使用前面介绍过的 3 种 top-N 推荐产生方法(标准排序方法、分别结合 Reverse 和 Random 策略的重排名方法、基于推荐期望的方法),并结合 3 种协同过滤技术,包括 user-based^[17]、item-based^[18]、matrix factorization^[18] 协同过滤技术进行 top-5 推荐。user-based CF 算法中,本文先用 Pearson 相关度^[17] 计算用户间的相似度 $\text{sim}(u, v)$,取前 50 个相似度最高的邻居作为用户 u 的最近邻,再按照式(10)预测用户 u 对物品 i 的评分。

$$r_{ui}^* = \bar{r}_u + \frac{\sum_{v \in N_i(u)} \text{sim}(u, v) \times (r_{vi} - \bar{r}_v)}{\sum_{v \in N_i(u)} |\text{sim}(u, v)|} \quad (10)$$

式中, \bar{r}_v 为用户 v 在用户 u 、 v 评分物品交集上的平均评分, \bar{r}_u 为用户 u 在全部物品空间 I 上的平均评分。item-based 与 user-based 类似,将式中 u, v 替换为物品 i, j 后即可得到其评分预测公式。本文实现了文献[2]中介绍的 matrix factorization 算法的基本版本,通过 5-fold 交叉验证法确定规则化常数 λ 为 0.043,潜在因子数(即用户、物品的向量维数)为 15,迭代次数为 30 次。利用 prediction-in-top-N 评价方法对实验结果的推荐准确度进行评估,用 Diversity-in-top-n、Entropy-Diversity、Gini-Diversity 对推荐多样性进行全面的评估。Gini-Diversity 数值越小,多样性越大;Entropy-Diversity 则相反。

图 1 展示了 3 个具有代表性的实验结果。图中准确度-多样性曲线是通过使用不同的评分阈值 T_R (3.5, 3.6, ..., 5) 获得的。

从图 1 可以看出,相对于文献[4]的重排名方法,本文所提出的基于期望的推荐方法不仅在侧重于不同物品数的 diversity-in-top-N 多样性上表现出了更好的性能,而且在基于物品分布的 Gini-Diversity 和 Entropy-Diversity 上表现出了更好的性能;并且通过改变评分阈值,能够在多样性和准确度的权衡中找到所需的平衡点。从图 1 还可以看出,仅需要降低很小的推荐准确度就能换来显著的多样性提升。为了更具体地说明这点,表 1 给出了进行 top-5 推荐时,不同准确度下

降程度下,各推荐产生算法对多样性(diversity-in-top-N)的提升程度。

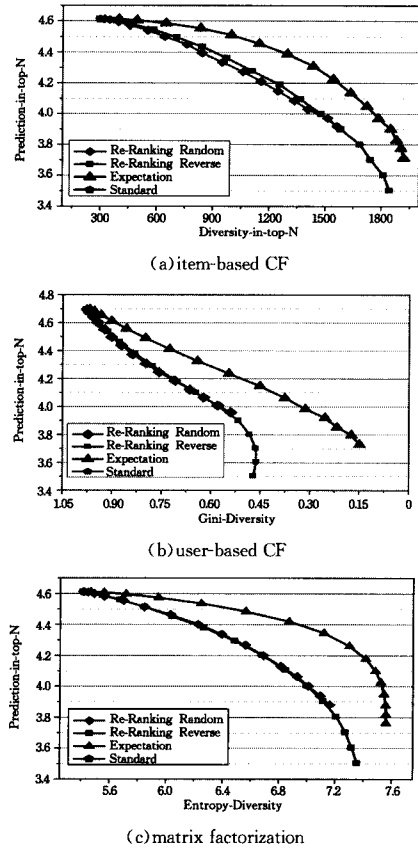


图 1 重排名方法与基于推荐期望方法的性能比较

表 1 给定准确度等级下的多样性(diversity-in-top-N)提升

top-5	user-based CF	item-based CF	mf
Standard	198, accuracy=4.694	298, accuracy=4.610	772, accuracy=4.611
(Accuracy level: Standard -0.01)			
Re-Ranking Random	320.0(61.6%)	368.1(23.5%)	828.4(7.3%)
Re-Ranking Reverse	309.1(56.1%)	382.6(28.4%)	835.3(8.1%)
Expectation- Based	559.8(182.7%)	520.2(74.6%)	994.6(28.8%)
(Accuracy level: Standard -0.05)			
Re-Ranking Random	458.4(131.5%)	487.5(63.6%)	926.1(19.9%)
Re-Ranking Reverse	472.3(138.4%)	523.1(75.5%)	935.3(21.1%)
Expectation- Based	734.0(270.7%)	787.6(164.3%)	1269.8(64.5%)
(Accuracy level: Standard -0.1)			
Re-Ranking Random	535.3(170.2%)	618.6(107.6%)	1008.1(30.6%)
Re-Ranking Reverse	586.2(195.9%)	667.0(123.8%)	1036.3(34.2%)
Expectation- Based	881.9(345.4%)	997.2(234.6%)	1455.7(88.6%)

表 1 中第 2 行为标准排名方法(即按准确度降序排名)对物品推荐时,分别在 user-based、item-based、matrix factorization 协同过滤算法下的 diversity-in-top-N 多样性。从第 4 行可发现,当准确度相对标准排名方法仅下降 0.01 时(通过降低评分阈值 T_R 可得),使用重排名方法结合 random 策略,在使用 user-based CF 预测算法时多样性从 198 增加到 320,增

加了 61.6%，而本文的基于期望的方法多样性则增加到 559.8，增加了 182.7%。同样在其它实验设置下，基于推荐期望的方法表现了同样的优势，尤其是当准确度稍微再下降时，多样性增加更为显著。

结束语 推荐多样性作为评价推荐质量的一个重要方面，最近引起了人们的关注。传统推荐系统通常向用户推荐 Top-N 个具有最高预测评分的物品，因此提供了较好的预测准确度，但是推荐多样性方面的性能却较差。本文提出的基于候选物品推荐期望的方法较文献[4]中提出的重排名方法在准确度-多样性的权衡上具有更好的性能，并且保持了较低的时间复杂度，保证了推荐的效率。另外本文提出的方法具有出色的灵活性，能够与不同的评分预测算法结合使用，可参数化选择准确度-多样性的平衡点。本文通过结合多种热门评分预测算法，在实际的 MovieLens 数据集上对提出的基于推荐期望的推荐产生方法进行测试，证明了该方法的有效性。

参 考 文 献

- [1] Herlocker J L, Konstan J A, Terveen L G, et al. Evaluating Collaborative Filtering Recommender Systems[J]. ACM Transactions on Information Systems, 2004, 22(1): 5-53
- [2] Koren Y, Bell R, Volinsky C. Matrix Factorization Techniques For Recommender Systems[J]. IEEE Computer, 2009, 42(8): 30-37
- [3] Guy Shani, Gunawardana A. Evaluating Recommendation Systems[M]// Recommender Systems Handbook. Springer, 2011: 257-297
- [4] Adomavicius G, Kwon Y. Improving Aggregate Recommendation Diversity Using Ranking-Based Techniques [J]. IEEE Transactions on Knowledge and Data Engineering, 2012, 24(5): 896-911
- [5] Bradley K, Smyth B. Improving Recommendation Diversity [C]// Proceeding of 12th Irish Conference on Artificial Intelligence and Cognitive Science. Ireland, 2001
- [6] Brynjolfsson E, Hu Y J, Simester D. Goodbye Pareto Principle, Hello Long Tail; The Effect of Search Costs on the Concentration of Product Sales[J]. Management Science, 2011, 57(8): 1373-1386
- [7] Fleder D, Hosanagar K. Blockbuster Culture's Next Rise or Fall; The Impact of Recommender Systems on Sales Diversity[J]. Management Science, 2009, 55(5): 697-712
- [8] Zhang M, Hurlley N. Avoiding monotony; improving the diversity of recommendation lists[C]// Proceedings of the 2nd ACM Conference on Recommender Systems, Lausanne, 2008
- [9] Goldstein D G, Goldstein D C. Profiting from the Long Tail[J]. Harvard Business Review, 2006, 84(6): 24-28
- [10] Kim H K, Kim J K, Ryu Y U. A Local Scoring Model for Recommendation[C]// Proceedings of the 20th Workshop on Information Technologies and Systems, St. Louis, Missouri, USA, 2010
- [11] Park Y J, Tuzhilin A. The Long Tail of Recommender Systems and How to Leverage It[C]// Proceedings of the 2nd ACM Conference on Recommender Systems, Lausanne, 2008
- [12] Adomavicius G, Kwon Y. Maximizing aggregate recommendation diversity: a graph-theoretic approach[C]// Proceedings of Workshop on Novelty and Diversity in Recommender Systems, Chicago, Illinois, USA, 2011
- [13] Cremonesi P, Koren Y, Turrin R. Performance of Recommender Algorithms on Top-N Recommendation Tasks[C]// Proceedings of the fourth ACM conference on Recommender systems, Barcelona, 2010
- [14] Smyth B, McClave P. Similarity vs. Diversity[C]// Proceedings of the 4th International Conference on Case-Based Reasoning; Case-Based Reasoning Research and Development. 2001
- [15] Shannon C E. A Mathematical Theory of Communication [J]. Reprinted with corrections from The Bell System Technical Journal, 1948, 27: 379-423, 623-656
- [16] Brynjolfsson E, Hu Yu, Smith M D. Long Tails vs. Superstars; The Effect of Information Technology on Product Variety and Sales Concentration Patterns [J]. Information Systems Research, 2010, 21(4): 736-747
- [17] Adomavicius G, Tuzhilin A. Toward the Next Generation of Recommender Systems; A Survey of the State-of-the-Art and Possible Extensions[J]. IEEE Transactions on Knowledge and Data Engineering, 2005, 17(6): 734-749
- [18] Sarwar B, Karypis G, Konstan J, et al. Item-Based Collaborative Filtering Recommendation Algorithm [C] // Proceedings of WWW10. Hong Kong, 2001

(上接第 241 页)

- [5] Liang J Y, Wang F, Dang C Y, et al. An efficient rough feature selection algorithm with a multi-granulation view [J]. International Journal of Approximate Reasoning, 2012, 53(6): 912-926
- [6] 陈玉明, 吴克寿, 谢荣生. 基于相对知识粒度的决策表约简[J]. 山东大学学报: 工学版, 2012, 42(6): 8-12
- [7] Qian Y H, Liang J Y, Pedrycz W, et al. Positive approximation: an accelerator for attribute reduction in rough set [J]. Artificial Intelligence, 2010, 174(9/10): 597-618
- [8] 葛浩, 李龙澍, 杨传健. 新的可分辨矩阵及其约简方法[J]. 控制与决策, 2010, 25(12): 1891-1895
- [9] 刘启和, 李凡, 闵帆, 等. 一种基于新的条件信息熵的高效知识约简算法[J]. 控制与决策, 2005, 20(8): 878-882
- [10] 马胜蓝, 叶东毅. 信息熵最小约简问题的若干随机优化算法[J]. 模式识别与人工智能, 2012, 25(1): 96-104
- [11] 钱文彬, 杨炳儒, 徐章艳, 等. 基于信息熵的核属性增量式更高效更新算法[J]. 模式识别与人工智能, 2013, 26(1): 42-49
- [12] 蒋云良, 杨章显, 刘勇. 不协调信息系统快速属性分布约简方法[J]. 自动化学报, 2012, 38(3): 382-388
- [13] 钱进, 叶飞跃, 孟祥萍, 等. 一种基于新的条件信息量的属性约简算法[J]. 系统工程与电子技术, 2007, 29(12): 2154-2157
- [14] 黄国顺, 刘云生. 不一致决策表信息熵约简与代数约简的核计算与转化[J]. 小型微型计算机系统, 2008, 29(2): 308-312
- [15] 黄国顺, 刘云生. 不一致决策表各种属性约简的不一致性分析与转化[J]. 小型微型计算机系统, 2008, 29(4): 703-708
- [16] 徐章艳, 刘作鹏, 杨炳儒, 等. 一个复杂度为 $\max(O(|C||U|), O(|C|^2|U/C|))$ 的快速属性约简算法[J]. 计算机学报, 2006, 29(3): 391-399
- [17] Blake C L, Merz C J. UCI Repository of Machine Learning Databases, University of California at Irvine[OL]. <http://www.ics.uci.edu/~mlern/MLRepository.html>, 1998
- [18] Liang J Y, Qian Y H. Information granularity and entropy theory in information system [J]. Science in China, (F), 2008, 51(10): 1427-1444