

# 一种多样性增强的推荐列表选择算法\*

李满天<sup>1,2</sup>, 王劲林<sup>1</sup>, 邓浩江<sup>1</sup>

(1. 中国科学院声学研究所 国家网络新媒体工程技术研究中心, 北京 100190; 2. 中国科学院大学, 北京 100049)

**摘要:** 针对传统的推荐算法过于强调推荐的精准度导致推荐列表的同质化现象突出的问题,提出了一种新的推荐列表选择算法 DivEnhance。首先给出了推荐列表的多样性和效用值的定义;然后将其建模为一个带约束的整数规划问题来求解,通过一个参数的调整,可以实现多样性和精准度的灵活控制。实验结果表明,该算法可以在一定精准度损失的条件下,大幅提高最终推荐列表的多样性。特别地,在推荐一些新颖性较高的内容上,该算法相对于传统的推荐算法具有较大的优势。

**关键词:** Top-*N* 推荐; 多样性; 精准度; 新颖性

**中图分类号:** TP393      **文献标志码:** A      **文章编号:** 1001-3695(2013)09-2591-03

**doi:**10.3969/j.issn.1001-3695.2013.09.007

## Recommendation list selection algorithm with diversity enhancement

LI Man-tian<sup>1,2</sup>, WANG Jin-lin<sup>1</sup>, DENG Hao-jiang<sup>1</sup>

(1. National Network New Media Engineering Research Center, Institute of Acoustics, Chinese Academy of Sciences, Beijing 100190, China; 2. University of Chinese Academy of Sciences, Beijing 100049, China)

**Abstract:** Traditional recommendation algorithms overemphasize recommendation accuracy and homogenization phenomenon of recommendation lists is prominent. In view of this problem, this paper proposed a new recommendation selection algorithm called DivEnhance. First, it gave definition of recommender lists' diversity and utility, and then constructed a constrained integer programming model to solve the problem, through a parameter adjustment, it could realize the flexible control of diversity and accuracy. Experiment results demonstrate that the proposed algorithm can enhance the diversity of recommendation lists at the cost of a certain accuracy reduction. Specially, it outperformed other recommendation algorithms in recommending some novel items.

**Key words:** Top-*N* recommendation; diversity; accuracy; novelty

推荐系统可以帮助用户从巨大的信息空间中找到用户感兴趣的或与用户相关的内容。现有的推荐技术大多强调提高推荐内容的精准性,而忽视了推荐列表的多样性问题<sup>[1]</sup>。这样导致的一个问题是,推荐的结果往往很片面,同质化问题突出。这里的同质化包含两个层面:a)推荐内容集中于流行度高的项目上;b)推荐列表内部各项目之间相似度高。

对于问题 a),可以通过提高总体多样性的方法解决。总体多样性这里是指推荐内容的覆盖度,即推荐系统向所有用户的推荐内容占所有内容的百分比。Adomavicius 等人<sup>[2]</sup>提出了一种排名模型,在保证一定精准度的条件下,向用户优先推荐相对比较冷门的内容,从而提高推荐的总体多样性。

问题 b)则是属于缺少个体多样性的问题。提高个体多样性是指避免向一个用户推荐过于相似的内容。推荐列表内部的相似度可以用来度量个体多样性<sup>[3]</sup>。Jambor 等人<sup>[4]</sup>指出,推荐的精准性与多样性往往是矛盾的,因此,推荐系统应该在保证推荐的精准度与尽量提高推荐的多样性之间做一个折中。

本文的研究内容主要集中在问题 b),具体来说包括三个方面:a)将推荐列表的选择问题建模为一个带约束的二次整数规划问题;b)参数化,通过一个参数的调节灵活地在精准度

与多样性两者间取折中;c)通过新颖性的定义,以及精心设计的仿真实验验证本文的算法在推荐新颖内容的精准度上优于传统算法。

### 1 多样性建模

#### 1.1 基本概念及定义

设  $n$  个用户的集合为  $U = \{u_1, u_2, \dots, u_n\}$ ,  $m$  个内容的集合为  $I = \{i_1, i_2, \dots, i_m\}$ ,用户对内容的评分数据可以用一个  $n \times m$  维的矩阵  $R$  来描述,矩阵的每一项  $r(u, i)$  表示用户  $u$  对内容  $i$  的评分。 $U_i$  为对内容  $i$  打过分的所有用户的集合。

设矩阵  $S$  为表示内容之间的相似度矩阵,其维度空间为  $m \times m$ 。其中每个元素  $s(i, j)$  表示内容  $i$  与  $j$  的相似度。类似地,定义一个  $m \times m$  维的多样性矩阵  $D$ ,表示内容之间的不相似度或者多样性。

#### 1.2 模型建立

设对用户  $u$  的推荐项目候选集为  $C, |C| = M$ 。再设最终的推荐项目集合为  $R, |R| = N$ 。那么,系统最终是推荐一个 Top- $N$  列表给用户  $u$ 。因此,如何从推荐候选集  $C$  中选取  $N$  个

收稿日期: 2012-12-19; 修回日期: 2013-01-30      基金项目: 国家“863”计划资助项目(2011AA01A102);国家自然科学基金资助项目(60972082)

作者简介:李满天(1986-),男,四川资阳人,硕士,主要研究方向为网络新媒体技术(limt@dsp.ac.cn);王劲林(1964-),男,天津人,研究员,博导,主要研究方向为宽带多媒体通信、网络新媒体技术;邓浩江(1971-),男,湖北黄冈人,研究员,硕导,主要研究方向为宽带多媒体通信、模式识别。

项目组成最终推荐列表  $R$ ,使得  $R$  对用户既满足尽量高的精准度,同时  $R$  中的各项目之间的相似性尽量小,即  $R$  的多样性尽量高。这就是本文研究的推荐列表多样性增强的问题。

设向量  $x$  表示  $M$  维的向量,表示从  $C$  中选取  $N$  个项目组成  $R$ ,其取值范围为  $x(i) \in \{0,1\}$ , $x(i) = 1$  表示项目  $i$  被选为最终的推荐内容;反之, $x(i) = 0$ 。为了量化推荐列表  $R$  的精准度或者说相关性,本文引入一个效用值的概念<sup>[5]</sup>。 $R$  的效用表示其对用户的有用程度。一般来说,效用值与推荐的精准度是正相关的,效用值越大,意味着推荐内容的精准度越高。

定义推荐列表  $R$  的效用为  $f(R, u)$ ,其值为  $R$  中各项内容的效用值累加:

$$f(R, u) = p_u^T x \tag{1}$$

其中每一项内容的效用值定义如下:

$$p_u(i) = \frac{2^{g(u,i)} - 1}{2^{g_{\max}}} \tag{2}$$

式中: $g(u, i) = \max(0, r(u, i) - \tau)$ 。 $\tau$  表示一个“不关心”值,表示用户不是特别喜欢,也不讨厌。

下面讨论推荐列表  $R$  的多样性定义。一些文献将推荐列表的内容之间的累计不相似度或者平均不相似度定义为多样性<sup>[3]</sup>。具体来说,设  $d(i, j)$  表示内容  $i$  与  $j$  的不相似度或者距离,候选集的所有项目的不相似度构成多样性矩阵  $D$ 。定义推荐列表  $R$  的多样性为  $d(R, u)$ ,其表达式为

$$d(R, u) = x^T D x \tag{3}$$

但是考虑到多样性除了体现在推荐列表内容之间不相似之外,还应该体现在推荐内容与用户框架 (user profile) 的不相似,故本文定义的推荐列表的多样性为

$$d(R, u) = \frac{1}{N} x^T D x + q_u^T \cdot x \tag{4}$$

式中:前一项是推荐列表内部的不相似度,后一项表示  $R$  与用户框架  $P_u$  的不相似度,对式(3)定义的内部不相似度取均值是为了使得两者可比。 $R$  与  $P_u$  的不相似度的计算方式是通过将  $R$  中的每一项推荐项目与  $P_u$  的不相似度  $q_u(i)$  累加得到。具体定义式如下:

$$q_u(i) = \frac{1}{|P_u|} \sum_{k \in P_u} d(i, k) \tag{5}$$

在以上定义中,不相似度  $d(i, j)$  的计算依赖于相似度  $s(i, j)$  的计算,而相似度的计算方式有多种,如余弦相似度、修正的余弦相似度及 Pearson 相关系数等,本文采用修正余弦相似度<sup>[6]</sup>来度量。其定义式为

$$s_{i,j} = \frac{\sum_{u \in U_i \cap U_j} (r_{u,i} - \bar{r}_u)(r_{u,j} - \bar{r}_u)}{[\sum_{u \in U_i \cap U_j} (r_{u,i} - \bar{r}_u)^2 \sum_{u \in U_i \cap U_j} (r_{u,j} - \bar{r}_u)^2]^{1/2}} \tag{6}$$

由修正余弦相似度的定义可以得知  $s(i, j) \in [-1, 1]$ ,因此可以定义不相似度为

$$d(i, j) = (1 - s(i, j))/2 \tag{7}$$

由式(7)可知  $d(i, j) \in [0, 1]$ , $d(i, j)$  的值越接近 1,说明  $i$  与  $j$  的不相似程度越大。

在有了效用值和多样性的定义之后,可以将 Top- $N$  推荐列表选择问题建模为一个最优化问题:

$$\begin{aligned} x^* &= \arg \max(d(R, u)) \\ \text{s. t. } &1^T x = N \\ &x(i) \in \{0, 1\} \\ &f(R, u) = p_u^T x \geq \beta \cdot f_{\max} \end{aligned} \tag{8}$$

其中: $f_{\max}$  是效用函数  $f(R, u)$  的最大值; $\beta \in [0, 1]$  是一个可调

整参数,表示在满足效用值不低于最大值  $\beta$  倍的情况下,最大化推荐列表的多样性。

### 1.3 新颖性的定义

为了证实本文算法在推荐新颖内容的精准度上优于传统算法,给出推荐内容的新颖性定义。新颖性是指推荐系统向用户推荐了他们所不了解的内容。关于新颖性的定义主要有两种<sup>[5]</sup>:a)基于发现的(discovery based),内容的流行度越低,其被用户已知的概率越低,因此其新颖度越高;b)基于距离度量的(distance based),这种定义下,内容的新颖度是用物品在一个上下文环境中,与其他内容的不相似度的加权平均来表示。在本文中采用定义 b),并令上下文环境为用户的推荐列表  $R$ ,设权重均匀分布,则推荐列表  $R$  中的任一内容  $i$  的新颖性定义退化为其与其他内容的平均距离:

$$n(i) = \frac{1}{|R|} \sum_{j \in R, j \neq i} d(i, j) \tag{9}$$

## 2 仿真实验及分析

### 2.1 算法描述

对式(8)提出的二次 0-1 规划问题,本文采用禁忌搜索算法来迭代求解<sup>[7]</sup>。与文献[7]不同的是本文的问题带有约束条件,但是可以通过罚函数的方式将其转换为无约束的二次整数规划问题求解。将式(8)中第三个约束条件  $f(R, u) = p_u^T x \geq \beta \cdot f_{\max}$  转换为罚函数,得到惩罚因子为

$$\text{penalty}(x) = 2^{u(\beta \cdot f_{\max} - p_u^T x)} - 1 \tag{10}$$

其中: $u$  是一个阶跃函数,表示当效用值不满足约束条件时才进行惩罚。而约束条件 1 通过邻域的选择方法实现。

算法的具体描述如下:

- a) 取初始解  $x_0 = (x_1, x_2, x_3, \dots, x_M)$ ,该初始解能取得最大效用值  $f_{\max}$ 。
- b) 设置最优解  $x^* = x_0$ ,最优目标函数值  $d^* = d(x_0)$ ,并初始化禁忌表。
- c) 计算当前解的邻居解的目标函数值(或变化值)。邻居解的产生方式是,从当前为 1 的  $x_i$  中选取一个翻转为 0,另从当前为 0 的  $x_j$  中选取一个翻转为 1。这样,保证所有解都满足约束条件 1。
- d) 从邻域解集中依次选择目标函数值最大的解,更新最优解和最优目标函数值。依据该解是否在禁忌表中有两种更新方式:(a)如果解被禁忌,但是满足此解优于历史最优解的条件,则特赦;(b)如果解未被禁忌,则直接更新最优解和最优目标函数值,并更新禁忌表。
- e) 重复进行步骤 c)d),直至满足收敛条件或者达到最大迭代次数。
- f) 输出最优解  $x^*$ 、 $d^*$ 。

### 2.2 数据集

本文使用在推荐系统领域广泛使用的 MovieLens<sup>[8]</sup>数据集来评价本文提出的算法。这里使用的是 MovieLens1M 数据集,它包含了 6 040 个用户对 3 982 部电影的 1 000 209 个评分数据,该评分数值取值在 1~5 的区间。

对于训练和测试集的划分,将候选数据集按照 50 : 50 的比例划分为两个部分,分别用于训练集和测试集。在仿真实验中,非主要参数设置是通过交叉验证获得,之后在整个实验过

程中保持不变。

### 2.3 评价指标

本文将 Top- $N$  推荐的评价分为两个部分,即精准度和多样性。对于精准度的评价标准,主要包括准确率 (precision)、召回率 (recall) 以及归一化折损累计增益 (NDCG) 等<sup>[9]</sup>。本文使用准确率作为评价指标,设用户  $u$  的测试集为  $T_u$ ,则整个系统的推荐准确率可以表示为

$$\text{Prec}@N = \frac{1}{|U|} \sum_u \frac{|T_u \cap R|}{N} \quad (11)$$

对于多样性的评价标准,覆盖率 (coverage) 是评测总体多样性的主要指标<sup>[10]</sup>,但对于本文的问题,推荐的个体多样性是更关注的目标。根据式(4)的定义,整个系统的推荐多样性可以表示为

$$\text{Div}@N = \frac{1}{|U|} \sum_u d(R, u) \quad (12)$$

### 2.4 精准度和多样性折中对比

在本实验中,取候选集的大小为 200,推荐集  $R$  的大小为 10。候选集  $C$  的选取方式有多种,本文采用选取最相关内容的方法,即选取预测评分最高的 200 项作为候选。推荐集  $R$  是从  $C$  中直接选取的,这里包含本文提出的算法 DivEnhance,加入两种对比算法 Random 和 Standard。

1) DivEnhance 即本文提出的多样性增强算法,通过参数的设置,可以在推荐的多样性与精准度之间作调整,在满足一定的精准度情况下,尽量提高推荐列表的多样性。

2) Random 随机选取算法,从候选集中随机选取项目到  $R$  中。

3) Standard 标准的排名选择算法,对候选集  $C$  中的项目按照预测评分降序排列,即评分越高,排名越靠前,然后选取排名最高的  $N$  项作为最终推荐。

实验结果如图 1、2 所示。图 1 是三种算法在不同  $\beta$  取值下的推荐结果准确度对比。从图中可以看出,当  $\beta$  逐渐减小时,DivEnhance 算法的推荐准确度也逐渐下降,到一定程度趋于平缓;当  $\beta$  值接近 1 时,下降不明显,甚至略有升高,说明满足较高的效用值时对推荐精准度影响不大。这也符合常理,因为人们对效用值排名在前一定比例的项目都表现出喜好的趋向,所以在这个范围内选择多样性最高的  $N$  个项目也应该获得相比拟的推荐精准度。对两种对比算法而言, $\beta$  的变化对其无影响,Standard 算法保持最高的推荐精度,而 Random 算法性能最差。

图 2 是三种算法的推荐多样性对比。可以看出,Standard 算法的多样性最低,Random 居中,而 DivEnhance 算法当  $\beta$  取值从 1.0 减小时,呈现迅速的上升趋势,到  $\beta$  取 0.6 之后趋于稳定。这里充分说明了 Top- $N$  推荐列表的多样性增强潜力,DivEnhance 算法可以在一定精度损失的条件下充分挖掘出其潜力。特别地,在本例中,选取参数  $\beta$  在  $[0.8 \sim 0.9]$  这个区间时,可以得到较满意的推荐结果。当  $\beta=0.9$  时,推荐精准度仅仅下降了 1%,而多样性按照式(13)的计算方式提高了 40%;当  $\beta=0.8$  时,精准度下降为 8%,多样性提高了近 52%。

### 2.5 对新颖内容的推荐精准度比较

由 1.3 节提出的新颖性定义,可以对训练集合和测试集合再作一个划分,从中选取新颖性较高的内容作为测试集,然后比较三种算法对这些新颖性较高的内容的推荐准确度。

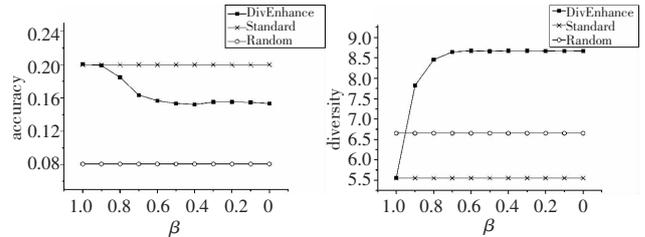


图 1 推荐准确度对比

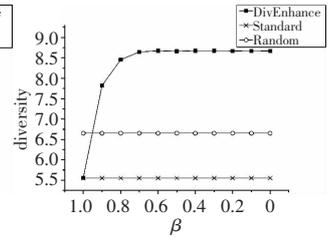


图 2 推荐多样性对比

具体的划分方式如下:首先由所有的用户数据建立起用户框架  $P_u$ ,然后根据式(8)计算出每个内容对用户的新颖度,再按照新颖度降序排列,从中选取首部一定比例  $\theta$  组成测试集  $T_u(\theta)$ 。这里  $\theta$  的取值为  $\theta \in [0, 1]$ , $\theta$  取值越小,则测试集的新颖性越高,推荐难度越大; $\theta=1$ ,则为从所有内容中随机选取,等同于一般情况,如前一节所讨论。

本节的对比算法仍为上节提出的三种算法。三种算法在不同的  $\theta$  取值情况下的推荐精准度如图 3 所示,其中 DivEnhance 算法的参数  $\beta$  取值为 0.8。

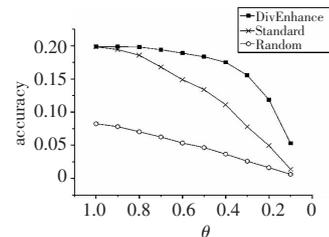


图 3 新颖内容的推荐准确度对比

从图中可以看出,当  $\theta$  取值从 1.0 逐渐减小时,三种算法的推荐准确度都呈下降趋势,但是 Standard 算法的下降程度最为明显,说明其对新颖项目的推荐精度较差;而 Random 因为是随机算法,其下降曲线呈线性;DivEnhance 算法下降趋势最缓,相比于 Standard 算法,在新颖项目的推荐上体现了巨大的优势。

## 3 结束语

本文主要研究了推荐系统的 Top- $N$  推荐列表选择的多样性增强问题。为了避免向用户推荐过度同质化的内容,在考虑推荐内容时,不应该仅仅以推荐精准度作为唯一指标,推荐内容的多样性同样是提高用户体验、增加用户粘度的重要指标。因此,本文提出了 DivEnhance 算法,它可以在损失一定精准度的条件下提高推荐列表的内容多样性;其中,可以通过参数  $\beta$  的设置,调整不同等级的多样性与精准度,非常灵活。同时,通过新颖性的定义以及仿真实验的设计,得出了新颖性较高的内容通过传统的排名选择算法较难得到推荐的结论,而 DivEnhance 算法则在推荐新颖性较高的内容上优于传统算法。

对于未来工作的展望,笔者计划对总体多样性和个体多样性的联系与区别进行研究,力求提出一个统一的标准或者框架,将两者进行有机的结合。另外,关于多样性、新颖度的评价标准也是一个可能的研究方向。

### 参考文献:

[1] MCNEE S M, RIEDL J, KONSTAN J A. Being accurate is not enough: how accuracy metrics have hurt recommender systems[C]//Proc of CHI'06 Extended Abstracts on Human Factors in Computing Systems. New York: ACM Press, 2006: 1097-1101.

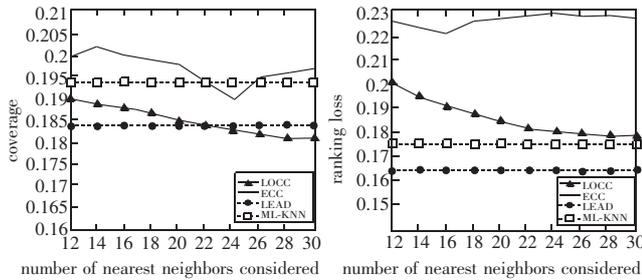


图 3  $k$  取值对 coverage 的影响

图 4  $k$  取值对 ranking loss 的影响

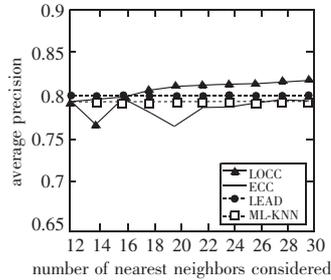


图 5  $k$  取值对 average precision 的影响

#### 4 结束语

由于标记相关性的存在,一个标记的信息可以通过分类器链形式传递给其他标记,为学习其他标记提供有用信息。由于分类器链中错误信息传递问题的存在,所以分类器链中分类器的顺序选择至关重要。本文充分考虑标记的局部分布特性,提出了局部顺序分类器链算法,通过 K-NN 找出样例最可能具有的标记,并根据可能性大小对分类器进行排序。对于近邻中不存在的标记采用多个随机顺序的处理方式,这样在很大程度上降低了错误信息的传播,提高了算法的分类效果。下一步笔者将在标记相关性的基础上引入样例间的相关性,并寻求更好的标记排序方法。

#### 参考文献:

[1] BOUTELL M R, LUO Jie-bo, SHEN Xi-peng, *et al.* Learning multi-label scene classification [J]. *Pattern Recognition*, 2004, 37 (9): 1757-1771.

[2] ZHANG Min-ling, ZHOU Zhi-hua. A k-nearest neighbor based algorithm for multi-label classification [C]//Proc of IEEE International Conference on Granular Computing. New York: IEEE Press, 2005: 718-721.

[3] GODBOLE S, SARAWAGI S. Discriminative methods for multi-labeled classification [C]//Proc of the 8th Pacific-Asia Conference on

Knowledge Discovery and Data Mining. Berlin: Springer, 2004: 22-30.

[4] TSOUMAKAS G, KATAKIS I. Multi label classification: an overview [J]. *International Journal of Data Warehousing and Mining*, 2007, 3(3): 1-13.

[5] HULLERMEIER E, FURNKRANZ J, CHENG W, *et al.* Label ranking by learning pairwise preferences [J]. *Artificial Intelligence*, 2008, 172(16): 1897-1916.

[6] DIMOU A, TSOUMAKAS G, MEZARIS V, *et al.* An empirical study of multi-label learning methods for video annotation [C]//Proc of the 7th International Workshop on Content-Based Multimedia Indexing. Washington DC: IEEE Computer Society, 2009: 19-24.

[7] JI Sui-wang, TANG Lei, YU Shi-peng, *et al.* Extracting shared subspace for multi-label classification [C]//Proc of the 14th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM Press, 2008: 381-389.

[8] READ J, PFAHRINGER B, HOLMES G. Multi-label classification using ensembles of pruned sets [C]//Proc of the 8th IEEE International Conference on Data Mining. New York: IEEE Press, 2008: 995-1000.

[9] LOZA M E, FÜMKRANZ J. Efficient pairwise multi-label classification for large-scale problems in the legal domain [C]//Proc of ECML-PKDD '08 European Conference on Machine Learning and Knowledge Discovery in Databases. Berlin: Springer, 2008: 50-65.

[10] SUN Liang, JI Shui-wang, YE Jie-ping. Hyper-graph spectral learning for multi-label classification [C]//Proc of the 14th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM Press, 2008: 668-676.

[11] READ J, PFAHRINGER B, HOLMES G, *et al.* Classifier chains for multi-label classification [C]//Proc of ECML/PKDD. 2009: 254-269.

[12] ZHANG Min-ling, ZHANG K. Multi-label learning by exploiting label dependency [C]//Proc of the 16th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM Press, 2010: 999-1007.

[13] HUANG Sheng-jun, ZHOU Zhi-hua. Multi-label learning by exploiting label correlations locally [C]//Proc of the 26th AAAI Conference on Artificial Intelligence. 2012: 949-955.

[14] CHENG W, HÜLLERMEIER E. Bayes optimal multi-label classification via probabilistic classifier chains [C]//Proc of the 27th International Conference on Machine Learning. Haifa: Omni Press, 2010: 279-286.

[15] READ J, PFAHRINGER B, HOLMES G, *et al.* Classifier chains for multi-label classification [J]. *Machine Learning*, 2011, 85(3): 333-359.

[16] ZHANG Min-ling, ZHOU Zhi-hua. ML-KNN: a lazy learning approach to multi-label learning [J]. *Pattern Recognition*, 2007, 40(7): 2038-2048.

(上接第 2593 页)

[2] ADOMAVICIUS G, KWON Y. Improving aggregate recommendation diversity using ranking-based techniques [J]. *IEEE Trans on Knowledge and Data Engineering*, 2012, 24(5): 896-911.

[3] ZIEGLER C, MCNEE S M, KONSTAN J A, *et al.* Improving recommendation lists through topic diversification [C]//Proc of the 14th International Conference on World Wide Web. New York: ACM Press, 2005: 22-32.

[4] JAMBOR T, WANG Jun. Optimizing multiple objectives in collaborative filtering [C]//Proc of the 4th ACM Conference on Recommender Systems. New York: ACM Press, 2010: 55-62.

[5] VARGAS S, CASTELLS P. Rank and relevance in novelty and diversity metrics for recommender systems [C]//Proc of the 5th ACM Conference on RecSys. New York: ACM Press, 2011: 109-116.

[6] SARWAR B, KARYPIS G, KONSTAN J, *et al.* Item-based collabora-

tive filtering recommendation algorithms [C]//Proc of the 10th International Conference on World Wide Web. New York: ACM Press, 2001: 285-295.

[7] 张爱君, 秦新强, 龚春琼. 求解 0-1 二次规划问题的迭代禁忌搜索算法 [J]. *计算机工程*, 2012, 38(1): 140-142.

[8] MILLER B, ALBERT I, LAM S, *et al.* Movielens unplugged: experiences with an occasionally connected recommender system [C]//Proc of the 8th International Conference on Intelligence User Interfaces. New York: ACM Press, 2003: 263-266.

[9] CREMONESI P, KOREN Y, TURRIN R. Performance of recommender algorithms on top-N recommendation tasks [C]//Proc of the 4th ACM Conference on RecSys. New York: ACM Press, 2011: 39-46.

[10] HERLOCKER J L, KONSTAN J A, TERVEEN L, *et al.* Evaluating collaborative filtering recommender systems [J]. *ACM Trans on Information Systems*, 2004, 22(1): 5-53.