

基于标签和协同过滤的个性化资源推荐

蔡强¹ 韩东梅¹ 李海生¹ 胡耀光² 陈谊¹

(北京工商大学计算机与信息工程学院 北京 100048)¹ (北京理工大学工业设计研究所 北京 100081)²

摘要 传统的协同过滤算法以用户评分体现用户兴趣偏好及资源相似度,忽视了用户、资源自身的特征,并且对稀疏数据和新资源的推荐质量明显下降。在 Web2.0 时代下,标签可被用户依个人偏好进行自由资源标注。因此,提出了基于标签和协同过滤的推荐算法。其基本思想是将标签作为体现用户兴趣偏好和资源特征的信息,依据用户、标签及资源的多维关系生成用户及资源的标签特征向量,并计算用户对资源的偏好程度和资源相似度,然后基于用户的历历史行为预测用户对其他资源的偏好值,最后依据预测偏好值排序产生 Top-N 推荐结果。通过与传统的协同过滤算法的比较,验证了本算法能有效缓解数据的稀疏性,解决推荐的冷启动问题,提升推荐的准确性,获得更好的推荐效果。

关键词 标签,协同过滤,推荐算法,用户偏好,资源相似度

中图法分类号 TP301 文献标识码 A

Personalized Resource Recommendation Based on Tags and Collaborative Filtering

CAI Qiang¹ HAN Dong-mei¹ LI Hai-sheng¹ HU Yao-guang² CHEN Yi¹

(School of Computer and Information, Beijing Technology and Business University, Beijing 100048, China)¹

(Institute of Industrial Design, Beijing Institute of Technology, Beijing 100081, China)²

Abstract Traditional collaborative filtering algorithm reflects the user interest preferences and similarity of items by user ratings. It ignores the characteristics of user and project, and performs not very well for sparse data and new items. Under the age of Web2.0, social tab allows the user to label resources based on personal preferences freedom. To solve the problems, a hybrid algorithm based on tags and collaborative filtering recommendation algorithm was proposed. The method uses the label as the user interest information and the item characteristic. Through making use of the multidimensional relationship of the user, social and labeling, algorithm generates user feature vector and Item feature, and calculates the user preferences for items and projects similarity. Then based on the historical behavior of the user, user preference on other projects is predicted. Finally, sorting the predicted preference, recommended results are generated. Experimental results show that our algorithm can effectively alleviate data sparsity, solve the cold start, and enhance the accuracy of the recommendation.

Keywords Tag, Collaborative filtering, Recommendation algorithm, User preference, Item similarity

1 引言

信息技术特别是互联网技术的飞速发展使人类进入了信息爆炸的时代,给人们带来了很大的信息负担。个性化推荐系统的出现为互联网信息过载提供了一个有效的工具。尤其在 Web2.0 时代下,用户使用社会标签对信息进行分类,可自由组织、管理和搜索所需的资源^[1]。这种易使用性使标签成为信息分类与索引的重要方式^[2],既能反映出用户的兴趣爱好,又能体现资源特征。

目前,推荐系统在电子商务、信息检索以及移动应用、互联网广告等众多应用领域中取得了较大进展,其中协同过滤

推荐算法应用较广泛。传统的协同过滤算法基本思想是使用统计技术寻找与目标用户有相同或相似兴趣爱好的邻居用户^[3],如根据邻居用户的评分预测目标用户对资源的评分值,选择预测分值较高的 N 个资源推荐给目标用户。而事实上资源的评分数据较稀疏,无法获知用户的偏好,导致推荐系统的性能下降。因此,研究者基于用户的协同过滤算法进行了改进,并提出了基于邻域、基于隐语义模型的协同过滤推荐算法。如基于邻域最近邻的协同过滤推荐算法^[3],缓解了评分数据稀疏性的问题,但忽视了资源自身的特征,且存在冷启动问题;不确定近邻的协同过滤推荐^[4]依据用户场景动态选择推荐方法,虽能改善推荐效果,但依据用户评分数据对资源分

到稿日期:2013-04-27 返修日期:2013-06-02 本文受国家自然科学基金项目(71071019),国家高技术研究发展计划(863 项目)(2012AA040904),北京市属高等学校人才强教计划资助项目(PHR201108075),重点学科—计算机应用技术(PXM2013_014213_000030_00042300)资助。

蔡强(1969—),男,博士,教授,主要研究方向为智能信息处理、科学可视化,E-mail:caiq@th.btbu.edu.cn;韩东梅(1988—),女,硕士生,主要研究方向为智能信息处理,E-mail:hdm26122@126.com(通信作者);李海生(1974—),男,博士,教授,主要研究方向为智能信息处理、科学可视化;胡耀光(1974—),男,博士,主要研究方向为敏捷制造、信息化咨询等;陈谊(1963—),女,博士,教授,主要研究方向为信息可视化与可视化分析、智能信息处理。

类,也忽视了用户、资源自身的特征信息;基于矩阵分解模型的协同过滤算法^[5],虽能提高推荐效果,但未能很好地解决数据稀疏性问题。

鉴于此,将标签自由标注的特性作为用户、资源的特征信息,将标签应用到推荐算法可提高推荐质量。针对标签推荐,研究者提出了多种推荐算法,其中文献[6]基于标签计算用户的兴趣爱好相似度,并构建信任网络,使用随机游走算法进行Top-N推荐,但该算法计算较耗时,并且存在冷启动问题。文献[7]将用户、标签及资源数据用张量表示,并进行高阶奇异分解,可有效减小数据稀疏性,提高了推荐质量,其缺点是数据量计算耗时。

现有的推荐算法存在冷启动,忽视用户、资源自身的特征,不能反映出产品兴趣爱好及产品特征的不同,或者由于计算量较大,不能直接应用于实际推荐系统等问题。因此,为解决上述问题,本文结合标签和协同过滤推荐提出了一种新的推荐算法。依据标签计算用户偏好程度和资源特征相似度,结合基于资源的协同过滤推荐实现对资源的个性化推荐。

2 基于标签的用户偏好和资源相似度计算

2.1 用户对资源的偏好

传统的协同过滤算法是基于用户对资源的评分来衡量用户的偏好,将与用户有相同兴趣爱好的用户喜爱的资源推荐给该用户。由于大型电子商务站点及商品项的数量庞大且不断增加,使得用户-资源评分矩阵成为高维矩阵,同时用户给予评分的资源很少,导致评分数据稀疏,无法提取标识用户兴趣偏好的特征。社会标签可实现对信息的分类^[8],被用户自由标注资源,通过用户使用标签标记资源的记录从用户、资源两个角度^[9]挖掘对资源的喜爱程度。鉴于此,利用用户使用的标签作为用户偏好模型的特征,并利用用户、标签和资源间的多维关系,计算用户对资源的偏好模型。

定义用户集合 $U = \{u_1, u_2, \dots, u_j, \dots, u_M\}$, 其中 M 为用户总数, $j=1, 2, \dots, M$; 所有资源的集合为 $I = \{i_1, i_2, \dots, i_j, \dots, i_N\}$, 其中 N 为资源总数, $j=1, 2, \dots, N$; 用户使用的标签集合为 $T = \{t_1, t_2, \dots, t_j, \dots, t_L\}$, 其中 L 为标签总数, $j=1, 2, \dots, L$ 。

(1) 用户及资源的标签特征向量

用户的标签特征向量^[10]是利用用户常使用的标签来表示用户的兴趣特征,记为

$$\overrightarrow{P_u} = \left(\frac{n_{ut_1}}{n_{ut}} \log \frac{M}{n_{t_1u}}, \dots, \frac{n_{ut_j}}{n_{ut}} \log \frac{M}{n_{t_ju}}, \dots, \frac{n_{ut_L}}{n_{ut}} \log \frac{M}{n_{t_Lu}} \right) \quad (1)$$

式中, n_{t_ju} 表示使用标签 t_j 的用户数, M 表示用户的总数, n_{ut_j} 表示用户 u 使用标签 t_j 的次数, n_{ut} 表示用户 u 所使用的标签的数量, $\frac{n_{ut_j}}{n_{ut}}$ 表示 u 使用标签的频率, $\log \frac{M}{n_{t_ju}}$ 表示在用户所有标签中该标签的重要性, $\frac{n_{ut_j}}{n_{ut}} \log \frac{M}{n_{t_ju}}$ 项表示标签对该用户 u 的重要度。

资源的标签特征向量是用标记该资源 i 的标签表示物品特征,记为

$$\overrightarrow{P_i} = \left(\frac{n_{it_1}}{n_{it}} \log \frac{N}{n_{t_1i}}, \dots, \frac{n_{it_j}}{n_{it}} \log \frac{N}{n_{t_ji}}, \dots, \frac{n_{it_L}}{n_{it}} \log \frac{N}{n_{t_Li}} \right) \quad (2)$$

式中, n_{t_ji} 表示被标签 t_j 标记的资源数, N 表示资源的总数,

n_{it_j} 表示资源 i 被标记的标签数, $\frac{n_{it_j}}{n_{it}}$ 表示标签 t_j 标记该资源的频率, $\log \frac{N}{n_{t_ji}}$ 表示针对资源 i 所有标签中标签 t_j 的重要度, $\frac{n_{it_j}}{n_{it}} \log \frac{N}{n_{t_ji}}$ 项表示各标签对该资源 i 的重要度。

(2) 用户对资源的偏好向量

用户 u_j 对资源 i_k 的偏好程度记为

$$P_{u_j i_k} = \overrightarrow{P_{u_j}} \cdot \overrightarrow{P_{i_k}} = \sum_{t=1}^L P_{u_j t} \times P_{i_k t} \quad (3)$$

式中, $u_j \in U, j=1, 2, \dots, M; i_k \in I, k=1, 2, \dots, N$ 。

用户 u_j 的资源偏好特征向量表示记为

$$\overrightarrow{P_{u_j}} = (P_{u_j i_1}, P_{u_j i_2}, \dots, P_{u_j i_k}, \dots, P_{u_j i_N}) \quad (4)$$

式中, $P_{u_j i_k}$ 表示用户 u_j 对资源 i_k 的喜爱程度。

依据用户对资源的偏好向量构造用户-资源偏好矩阵,记为

$$P_{M \times N} = \begin{pmatrix} P_{u_1 i_1} & \cdots & P_{u_1 i_k} & \cdots & P_{u_1 i_N} \\ \vdots & \ddots & & & \vdots \\ P_{u_j i_1} & & P_{u_j i_k} & & P_{u_j i_N} \\ \vdots & & \ddots & & \vdots \\ P_{u_M i_1} & \cdots & P_{u_M i_k} & \cdots & P_{u_M i_N} \end{pmatrix} \quad (5)$$

式中, $u_j \in U, j=1, 2, \dots, M; i_k \in I, k=1, 2, \dots, N$; 该矩阵记录了用户的兴趣爱好向量,且能反映用户对各资源的喜爱程度。

在计算用户及资源特征向量时,借助 TF-IDF 思想计算标签对用户、标签对资源的重要性,用以对较流行的标签和资源降低权重,增进推荐结果的新颖性和个性化。

2.2 资源相似性计算

资源的相似性表示两个不同资源之间的相似程度^[11]。传统的协同过滤算法是利用不同用户间共同喜爱的物品数量或资源计算,这种方法忽视了资源自身的特征。鉴于此,利用标签,将用户标记资源的历史行为作为资源特征信息并用于相似度计算,也利于用户发现新资源^[13]。

资源的特征信息可用基于标签的资源特征向量 $\overrightarrow{I_k}$ 表示:

$$\overrightarrow{I_k} = (n_{k1}, n_{k2}, \dots, n_{ki}, \dots, n_{kL}) \quad (6)$$

式中, $k=1, 2, \dots, N; i=1, 2, \dots, L; n_{ki}$ 表示 t_i 被用来标记资源 i_k 归一化后的值。

所有资源的特征信息可用资源特征向量矩阵 $I_{k \times k}$ 表示:

$$I_{k \times k} = \begin{pmatrix} n_{11} & \cdots & n_{1k} \\ \vdots & \ddots & \vdots \\ n_{kk} & \cdots & n_{kk} \end{pmatrix} \quad (7)$$

资源的相似度计算有多种方式,本文采用的是余弦相似度计算。通过资源特征向量计算资源间的余弦相似度:

$$\text{sim}(i_j, i_k) = \cos(\overrightarrow{I_j}, \overrightarrow{I_k}) = \frac{\overrightarrow{I_j} \cdot \overrightarrow{I_k}}{|\overrightarrow{I_j}| \times |\overrightarrow{I_k}|} \quad (8)$$

通过计算资源间的相似度,可构造资源相似度矩阵 $S_{N \times N}$, 用以描述不同资源间的相似度:

$$S_{N \times N} = \begin{pmatrix} 1 & \cdots & s_{1j} & \cdots & s_{1N} \\ \vdots & \ddots & & & \vdots \\ s_{j1} & & 1 & & s_{jN} \\ \vdots & & & \ddots & \vdots \\ s_{N1} & \cdots & s_{Nj} & \cdots & s_{NN} \end{pmatrix} \quad (9)$$

式中, $j=1, 2, \dots, N; s_{ij}$ 表示资源 i_i 和 i_j 的相似度。

2.3 预测偏好值计算

依据用户历史行为及资源相似度,可计算用户 u 对未使用资源 i_j 的偏好程度,并用预测偏好值 pp_{ui_j} 表示:

$$pp_{ui_j} = \sum_{k=1}^M p_{u_j i_k} \times s_{i_k i_j} \quad (10)$$

式中, $p_{u_j i_k}$ 表示用户 u_j 对历史使用资源 i_k 的偏好程度, $s_{i_k i_j}$ 表示资源 i_k 和 i_j 的相似度。

预测偏好值通过用户使用的资源 i_k , 计算各历史资源与资源 i_j 的相似度,进而求得用户 u 对 i_j 的偏好程度。充分利用用户历史行为和资源相似度,提高了推荐准确度。

3 基于标签和协同过滤的推荐算法描述

设 $user_tags(u, t)$ 为用户-标签矩阵,表示用户 u 使用标签 t 的次数; $tag_item(t, i)$ 为标签-资源矩阵,表示资源 i 被标签 t 标记的次数; n_u 为标签 t 被不同 u 使用的用户数, n_i 为物品 i 被不同的 t 标记的次数, pp_{ui_j} 为用户对资源 i_j 的预测偏好值, I_{rec} 为 Top-N 推荐集。则基于标签的协同过滤算法表述如下:

输入: 用户-标签-资源记录、推荐集 I_{rec} 资源数 N

输出: 目标用户 u 的 Top-N 推荐集 I_{rec}

第 1 步 通过用户-标签-资源记录中的用户-标签关系,统计 $user_tags$ 和 n_u , 通过标签-资源关系,统计 tag_items 和 n_i 。

第 2 步 计算用户对资源的偏好矩阵。首先分别依据式(1)、式(2)计算用户的标签特征向量和资源的标签特征向量,依据式(3)计算用户偏好向量,并构建用户-资源偏好矩阵 $P_{M \times N}$ 。

第 3 步 基于资源的特征信息 I_k ,根据式(8)计算资源相似度,并构造资源相似度矩阵 $S_{N \times N}$ 。

第 4 步 基于用户对资源的历史记录,查询用户 u 曾标记的资源与其他资源的相似度 s_{ij} ,并用式(10)依次计算用户与这些资源相似资源的预测偏好值 pp_{ui_j} 。

第 5 步 按预测偏好值 pp_{ui_j} 从大到小排序,并取前 N 个资源组成 Top-N 推荐集 $I_{rec} = \{i_1, i_2, \dots, i_N\}$ 并输出。

4 实验结果与分析

4.1 推荐算法数据集

本实验采用的数据集是在第五届推荐系统大会上公布的 Last.fm 数据集。Last.fm 是一个音乐网站,允许用户用标签标记音乐和歌手。该数据集有 1892 个用户、11946 个标签和 17632 个资源,共有 186479 个标记记录。本实验依据各标签被使用过 10 次以上且每个用户至少对音乐或歌手标记过 10 次的原则选取记录作为数据集,数据集被随机分为 90% 和 10%,90% 部分的数据作为训练集,其余部分为测试集。

4.2 推荐质量的度量标准

推荐的准确度是评价推荐算法最基本的指标。本文试验中采用准确率(Precision)和召回率(Recall)作为度量算法优劣的标准。准确率表示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商品被推荐的概率。准确率和召回率越高,表示推荐效果越好。此外,本文还采用 F-measure 指标^[12]度量算法。设 $R(u)$ 是根据用户在训练集上的行为给用户作出的推荐列表, $T(u)$ 是用户在测试集上的行为列表。那么推荐结果的准确率定义为:

$$Precision = \frac{\sum_{u \in U} |R(u) \cap T(u)|}{\sum_{u \in U} |R(u)|} \quad (11)$$

推荐结果的召回率定义为:

$$Recall = \frac{\sum_{u \in U} |R(u) \cap T(u)|}{\sum_{u \in U} |T(u)|} \quad (12)$$

F-measure 定义为:

$$F-measure = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (13)$$

4.3 实验结果

在实验中,Top-N 推荐时 Item 的个数在很大程度上会影响推荐结果,将 Item 数目选取 300、500、800、1300 等不同数值计算推荐结果,并与传统的协同过滤算法进行比较,其中 CF 为基于资源的协同过滤算法,该算法根据用户浏览的资源记录,计算物品间相似度,并产生推荐结果;TCF 为结合标签和协同过滤的推荐算法;CF++ 是基于用户行为仅在求项目相似度时使用标签的算法。实验结果如下所示:图 1 表示 Item 取不同值时的准确度,图 2 表示 N 取不同值时的 Precision,图 3—图 5 分别是当 Item 值取 1300 时,Top-N 取不同 N 值时的 Precision、Recall 和 F-measure。图 4 是当 Item 取 1300 时,随 Top-N 的 N 值增大 Recall 与 Precision 的变化。

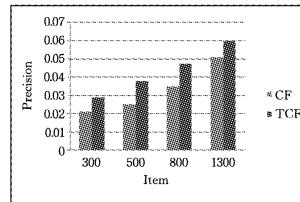


图 1 不同 Item 值下 Precision 值

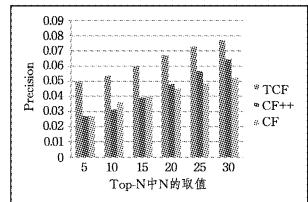


图 2 不同 N 值下的 Precision 值

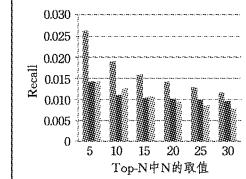


图 3 不同 N 值下的 Recall 值

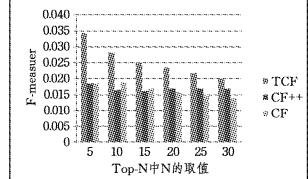


图 4 不同 N 值下的 F-measure 值

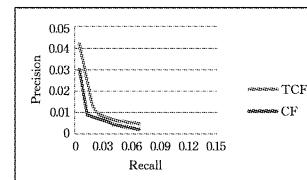


图 5 推荐结果准确率和召回率

从图 1 中可看出,Item 的数量越多,算法的准确度越高。从图 2—图 5 可以看出,本文算法在准确率、召回率和 F-measure 上明显优于 CF 和 CF++,且 CF++ 在推荐质量上优于 CF。表明标签能有效提高推荐准确度,本文的算法确实能明显提高推荐结果的质量。

结语 利用可自由标注的社会标签,并结合基于资源的协同过滤思想,提出一种满足用户个性化需求的推荐算法。该算法使用标签作为用户兴趣偏好及资源特征,既能提高推荐算法的质量,又能提供推荐解释;利用资源的标签特征向量计算资源相似度,可解决传统协同过滤算法的冷启动问题。另外,相比较基于图的推荐算法,该算法复杂度较低。但该方法在实际应用中仍有若干问题有待解决,如标签的质量及推

(下转第 110 页)

表 2 人工免疫算法、遗传算法和细胞优化算法的比较

	人工免疫算法	遗传算法	细胞优化算法
收敛性	全局收敛	易局部收敛	全局收敛
状态	浓度和亲和力	染色体的遗传信息	细胞核、质和能量
控制	优化等过程	遗传过程	细胞动力学方程
算法结构	非并行	非并行	分布并行

通过以上实验,我们验证了细胞优化算法的并行性、鲁棒性,以及与同类算法相比较,在 CDN 缓存资源分配问题上的高效能、解决问题的有效性。

结束语 由于目前存在的自然演化方法有其局限性,本文模拟自然细胞系统细胞内部结构和原理,对细胞核、细胞质的浓度、细胞间的亲和度、细胞优化机制、细胞的动态演化过程建立数学模型,以弹性网络理论和方法为基点,CDN 网络缓存分配问题为平台,发展提出了一种新的基于力的仿生算法——细胞优化算法。

参 考 文 献

- [1] Denning P. Computing is a natural science [J]. Communications of the ACM, 2007, 50(7):13-18
- [2] Durbin R, Willshaw D. An analogue approach to the travelling salesman problem using an elastic net method [J]. Nature, 1987, 326(6114):689-691
- [3] 惠雯,尹浩,林闯,等.内容分发网络请求路由研究[J].计算机科学,2012,39(2):1-7
- [4] So J C H, Wong P. Genetic Algorithm in Resource Provider Selection for Personal Live Content Delivery in User-Provided Platform [C] // 2012 IEEE 11th International Conference on Trust, Security and Privacy in Computing and Communications (TrustCom). Liverpool, United Kingdom, 2012:1748-1754

(上接第 71 页)

荐实时性问题等都有待进一步研究。

参 考 文 献

- [1] Kohi A, Ebrahimi S J, Jalali M. Improving the accuracy and efficiency of tag recommendation system by applying hybrid methods. comper[C]//2011 1st International eConference on Computer and Knowledge Engineering. Mashhad, Iran, 2011:242-248
- [2] 张斌,张引,高克宁,等.融合关系与内容分析的社会标签推荐[J].软件学报,2012,23(3):476-488
- [3] 李聪,梁昌勇,马丽.基于协同过滤与划分聚类的改进推荐算法[J].计算机研究与发展,2008,45(9):1552-1538
- [4] 黄创光,印鉴,汪静,等.不确定近邻的协同过滤推荐算法[J].计算机学报,2010,33(8):1369-1377
- [5] Koren Y, Bell R, Volinsky C. Matrix Factorization techniques for recommender systems[J]. IEEE Computer Society, 2009, 42(8):30-37
- [6] Jin Jian, Chen Qun. A Trust-based top-k recommender system using social tagging network[C]//2012 9th International Conference on Fuzzy Systems and Knowledge Discovery. China, 2012:1270-1274
- [7] Nanopoulos A, Rafailidis D, Symeonidis P, et al. MusicBox: per-

- [5] Mondal A, Trestian I, Qin Z, et al. P2P as a CDN: A new service model for file sharing [J]. Computer Networks, 2012, 56(14): 3233-3246
- [6] Kideok C, Hakkyung J, et al. How can an ISP merge with a CDN? [J]. IEEE Communications, 2011, 49(10):156-162
- [7] 叶剑虹,叶双.基于混合模式的流媒体缓存调度算法[J].计算机科学,2013,40(2):61-64
- [8] Mondal A, Trestian I, Qin Z, et al. P2P as a CDN: A new service model for file sharing[J]. Computer Networks, 2012, 56 (9): 3233-3246
- [9] Calafate C T, Fortino G, Fritsch S, et al. An efficient and robust content delivery solution for IEEE 802.11 p vehicular environments [J]. Journal of Network and Computer Applications, 2012, 35(2):753-762
- [10] Manfredi S, Oliviero F, Romano S P. Optimised balancing algorithm for content delivery networks[J]. IET communications, 2012, 6(7):733-739
- [11] Chakareski J. Multi-path content delivery: Efficiency analysis and optimization algorithms [J]. Journal of Visual Communication and Image Representation, 2012, 23(11):1189-1198
- [12] Isalan M. Systems biology: a cell in a computer [J]. Nature, 2012, 488(7409):40-41
- [13] Kelly T P, Jarmin S, MacKie-Mason J K. Variable QoS from Shared Web Caches: User-Centered Design and Value Sensitive Replacement [C]// Proc. MIT Workshop Internet Service Quality Economics. 1999, 12:14
- [14] Breslau L, Cao L P, et al. Web Caching and Zipf-Like Distributions: Evidence and Implications [J]. Proc. INFOCOM, 1999, 1(1):126-13

sonalized music recommendation based on cubic analysis of social tags[J]. IEEE Transaction on Audio, Speech, and Language Processing, 2010, 18(2):407-412

- [8] RauJen-wei, Huang Jen-wei, Yung Sheng. Improving the quality of tags using state transition on progressive image search and recommendation system[C]// 2012 IEEE International Conference on Systems, Man, and Cybernetics. Seoul, 2012: 3233-3238
- [9] Song Yang, Lu Zhang. Automatic tag recommendation algorithms for social recommender systems[J]. ACM Transaction on the Web, 2011, 5(1):1-31
- [10] Xia Xiu-feng, Zhang Shu, Li Xiao-ming. A personalized recommendation model based on social tags[C]// International Workshop on Database Technology and Applications. Wuhan, 2010: 1-5
- [11] 韦素云,业宁,朱健,等.基于资源聚类的全局最近邻的协同过滤算法[J].计算机科学,2012,39(12):149-152
- [12] Hao Fei, Zhong Sheng-tong. Tag recommendation based on user interest lattice matching[C]// IEEE International Conference on Computer Science and Information Technology. Daejeon, 2010: 276-280
- [13] Olvera E P, Godoy D. Valuating term weighting schemes for content-based tag recommendation in social tagging systems[J]. IEEE Latin America Transaction, 2012, 10(4):1973-1980