

# 一种基于动态角色标识和张量分解的推荐模型

肖云鹏, 刘晏驰, 刘 红, 刘媛妮

(重庆邮电大学网络与信息安全技术重庆市工程实验室, 重庆 400065)

**摘 要:** 社交网络推荐中,通常未依据用户兴趣变化进行用户角色动态标注,会造成推荐预测误差,并且用户评分数据稀疏造成评分预测不准确. 根据以上问题,本文提出一种基于动态角色标识和张量分解的推荐模型. 首先,针对用户角色无差别标识问题,引入信息熵指标度量用户兴趣多样性,对目标用户进行角色定量标识. 其次,考虑到用户兴趣漂移现象,提出基于时间窗的动态角色标识方式,解决静态角色标识产生的个体评分数据无偏好差异问题,实现用户评分数据层次化处理. 最后,为提高评分预测准确率,通过引入张量分解在数据维度转换和数据压缩的特性,构建基于“用户-项目-角色”张量分解的评分预测模型. 同时,在张量分解的过程中,通过对数据缺失值处理,提高评分预测精度,生成目标用户推荐列表. 实验表明,该方法缓解了用户无角色差异形成的预测误差问题,并能够有效改善评分数据稀疏情况下传统方法推荐精度不足的问题,提高推荐效率.

**关键词:** 推荐系统; 动态角色标识; 张量分解; 社交网络; 兴趣漂移; 稀疏性

**中图分类号:** TP393      **文献标识码:** A      **文章编号:** 0372-2112 (2018) 03-0569-06

**电子学报 URL:** <http://www.ejournal.org.cn>      **DOI:** 10.3969/j.issn.0372-2112.2018.03.008

## A Recommendation Model Based on Dynamic Role Identification and Tensor Decomposition

XIAO Yun-peng, LIU Yan-chi, LIU Hong, LIU Yuan-ni

(Chongqing Engineering Laboratory of Internet and Information Security, Chongqing University of Posts and Telecommunications,  
Chongqing 400065, China)

**Abstract:** In the current social recommendation system, user roles are typically not dynamically annotated based on changed user interest. The flaw may lead to the prediction inaccuracy of recommendation. Besides, sparsity of user rating data can also cause imprecise prediction. According to the above problems, this paper proposes a recommendation model based on dynamic role identification and tensor decomposition. Firstly, when user roles are quantitatively identified, information entropy is used to capture the diversity of user interest for solving the problem of indiscriminate user role identification. Secondly, considering user interest drifting, the dynamic role identification method based on time window is proposed, which enables the preference difference of individual rating data generated by static role identification and realizes the hierarchical processing of user rating data. Finally, a rating prediction model based on “user-item-role” tensor decomposition is constructed. And the characteristics of tensor in data dimension transformation and data compression is introduced into the model. In addition, by dealing with the missing value, accuracy of rating prediction is improved. Experiments demonstrate that this model can alleviate inaccurate prediction caused by indiscriminate identity of user role, and can effectively improve recommendation performance compared with the traditional recommendation model.

**Key words:** recommendation system; dynamic role identification; tensor decomposition; social network; interest drifting; data sparsity

收稿日期: 2017-03-20; 修回日期: 2017-10-10; 责任编辑: 覃怀银

基金项目: 国家重点基础研究发展计划 (No. 2013CB329606); 国家自然科学基金 (No. 61772098); 重庆市基础科学与前沿研究项目 (No. cstc2017jcyjAX0099)

## 1 引言

随着互联网技术的迅速发展和信息规模的急剧增长,大量冗余信息干扰了用户对有用信息的选择,如何向用户提供个性化、高质量的推荐服务成为了研究的重点<sup>[1,2]</sup>.对主流的协同过滤方法进行改进,准确的发现用户兴趣和兴趣的转移是个性化推荐的基础<sup>[3~7]</sup>,并且缓解数据稀疏对评分预测带来的精度不足问题<sup>[8,9]</sup>也是研究的关键.

传统推荐系统中,大多基于协同过滤推荐算法<sup>[10,11]</sup>.一些学者提出使用聚类<sup>[12]</sup>、分析上下文语境<sup>[13,14]</sup>、角色发现<sup>[15]</sup>等方法结合协同过滤分析用户偏好提高推荐效果,但并未直接表达用户在群体中的行为特性,对计算出的个性化推荐结果会造成一定偏差.并且考虑用户兴趣漂移现象,大多数会采用自适应的方法跟踪用户兴趣<sup>[16,17]</sup>,但对时间区域的标识较为模糊,而时间窗口的合适选择对解决兴趣漂移产生的推荐精度问题起到非常重要的作用.同时针对数据稀疏造成的评分预测不准确问题,已有研究人员提出利用奇异值分解<sup>[18]</sup>、张量分解等与其他模型进行融合的方法<sup>[19,20]</sup>,可以较好的改善数据稀疏造成的问题.但在不同推荐情境下,张量模型的构建与分解存在差别,选择合理的张量分解方式成为了推荐系统的重要环节.

围绕当前推荐系统领域存在的问题,本文针对现有协同过滤推荐方法的不足,提出一种基于动态角色标识和张量分解的推荐模型.该模型采用信息熵量化用户角色类型,并利用时间窗口动态标识用户角色.同时,利用张量分解方法挖掘用户间潜在因素,进一步分析用户的相关性,优化评分预测结果,进而生成目标用户推荐列表.

## 2 本文模型

### 2.1 整体框架

为解决以上问题,首先结合用户评分行为特性,设计一种利用信息熵理论度量用户角色的方法.其次,根据用户的评分行为数据,利用时间窗口将用户行为按时间序列切片处理,在有效时间窗口内度量用户角色,对用户实现动态角色标识.最后,构建“用户-项目-角色”的张量分解评分预测模型,预测目标用户对项目的评分,生成推荐列表.模型整体框架如图1所示.

### 2.2 角色标识

在个性化推荐中,越来越多的用户相关信息应用于推荐计算.为减小海量数据中的噪声干扰,本文基于信息熵理论度量用户兴趣的多样性,为用户标识所属角色,每个用户对项目的评分信息均被统计,具体公式如下:

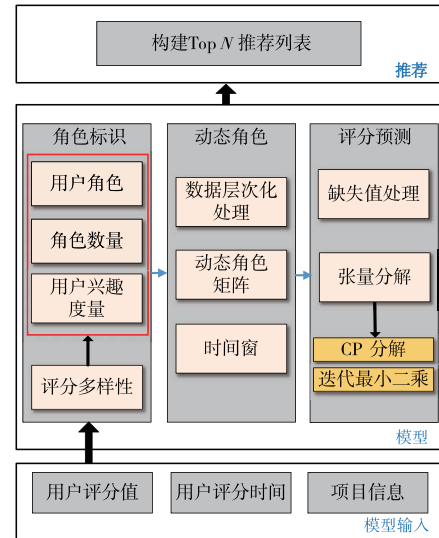


图1 模型框架图

$$H(u) = \sum_{w=1}^W -p_w \log_2 \frac{1}{p_w} \quad (1)$$

其中, $H(u)$ 表示用户对项目评分的多样性程度, $p_w$ 表示用户 $u$ 所评价的第 $w$ 类项目所占的数量比例, $W$ 是用户 $u$ 评价项目的类别数量.用户的信息熵值越大,则表明用户评价的项目越多样,也表示用户的兴趣越多样.因此,使用信息熵度量用户的兴趣多样性是一个十分合理的指标.

根据式(1)所定义的用户兴趣多样性计算方法,将兴趣多样性程度相似的用户标识为同一类角色.本文将兴趣多样性程度定量为用户角色值,利用K-Means聚类算法计算用户所属角色类别:

$$C = K \text{ Means}((H(u_1), H(u_2), \dots, H(u_i)), K), \\ i = 1, 2, \dots, I$$

$$\text{约束条件: } \min \sum_k \sum_i \sqrt{(H(u_{ki}) - S_k)^2} \quad (2)$$

其中, $C$ 表示用户的角色分布集合, $C_i$ 表示第 $i$ 个用户的角色, $H(u)$ 是用户兴趣多样性程度, $K$ 表示角色数量, $I$ 为用户数量.约束条件中 $H(u_{ki})$ 表示第 $k$ 类角色中的第 $i$ 个用户的兴趣多样值, $S_k$ 表示第 $k$ 类角色的质心点,进而计算每一类角色中的质心点与同类角色中兴趣多样值之间的误差,使其尽可能逼近最小值.通过该方法,即可计算出所有用户的角色类别.

### 2.3 基于时间窗口的用户角色动态标识

用户的兴趣漂移造成用户角色随时间发生改变,因此推荐引擎需要挖掘出用户兴趣的时序特性,从而优化推荐系统的性能.本文提出基于时间窗口的标识方式,对用户实现动态角色标识.

结合时间窗与式(2),计算出每个用户在不同时间窗下的角色类别,得到如下用户动态角色矩阵 $G$ :

$$\mathbf{G} = \begin{bmatrix} T_1 & T_2 & \cdots & T_t \\ C_{11} & C_{12} & \cdots & C_{1t} \\ C_{21} & C_{22} & \cdots & C_{2t} \\ \cdots & \cdots & \cdots & \cdots \\ C_{it} & C_{i2} & \cdots & C_{it} \end{bmatrix} \begin{matrix} U_1 \\ U_2 \\ \cdots \\ U_i \end{matrix} \quad (3)$$

上述矩阵中  $U_1, U_2, \dots, U_i$  表示用户,  $T_1, T_2, \dots, T_t$  表示时间窗,  $C_{it}$  表示用户  $i$  在第  $t$  个时间窗内的角色类别. 结合矩阵  $\mathbf{G}$ , 利用下述公式生成用户动态角色集合:

$$D = \{C_{it} | C_{it} \notin \emptyset\} \quad (4)$$

通过生成的用户动态角色向量, 可将用户评分数据进行层次化处理. 进一步规划了用户在不同角色下的评分数据, 减小了下一步的计算误差.

#### 2.4 张量分解评分预测模型

本文为解决基于用户角色的推荐, 构建张量分解模型进行评分预测, 该模型对缺失值填充处理, 计算出用户对项目的评分, 再依据评分对目标用户推荐项目.

##### 2.4.1 基于用户评分的张量构建

用户对项目的评分行为是基于某一角色下发生的, 可利用三阶张量  $\mathbf{X} \in \mathbb{R}^{i \times j \times k}$  表示. 其中, 张量的 1 模式表示评分的用户, 2 模式表示被评分的项目, 3 模式表示用户的角色. 需要说明的是, 用户角色随时间推移发生改变时, 对应的评分数据填充在相应的角色维度下. 张量填充的元素值如下表示:

$$\mathbf{X} = \begin{cases} \text{score}, & \text{在角色 } k \text{ 下 } u_i \text{ 对 item}_j \text{ 的评分} \\ 0, & \text{其他情况} \end{cases} \quad (5)$$

用户的角色是根据其动态角色集合  $D$  中的顺序依次获取, 当评分时间不处于角色集合包含的时间时, 该评分数据则不填充进张量模型.

##### 2.4.2 评分预测张量的分解方法

针对评分行为张量, CP 分解法符合高维数据阵列的特点和分解的唯一性, 因此本文使用 CP 分解对张量模型进行计算. CP 分解是一个典型的数值优化问题, 为使原始张量与分解张量之间的误差范数尽可能的小:

$$\min_{\hat{\mathbf{X}}} \|\mathbf{X} - \hat{\mathbf{X}}\| \quad (6)$$

对于张量  $\mathbf{X} \in \mathbb{R}^{i \times j \times k}$ , 使用 CP 分解法将其改写为向量和的形式:

$$\mathbf{X} \approx \sum_{r=1}^R \mathbf{m}_r \circ \mathbf{n}_r \circ \mathbf{q}_r \quad (7)$$

其中, 符号  $\circ$  为向量的外积,  $R$  为一个正整数且  $\mathbf{m}_r \in \mathbb{R}^i$ ,  $\mathbf{n}_r \in \mathbb{R}^j$ ,  $\mathbf{q}_r \in \mathbb{R}^k$ ,  $r = 1, 2, \dots, R$ . 因此可以将式 (7) 中的张量元素值与 CP 分解的元素值改成如下对应形式:

$$X_{ijk} \approx \sum_{r=1}^R m_{ir} n_{jr} q_{kr}, i = 1, 2, \dots, I; j = 1, 2, \dots, J; k = 1, 2, \dots, K \quad (8)$$

张量模型即可表示为有限个数目的秩-1 张量之

和. 同时设置  $\mathbf{M}, \mathbf{N}, \mathbf{Q}$  为因子矩阵, 大小分别为  $I \times R, J \times R, K \times R$ , 因子矩阵与张量  $\mathbf{X}$  的关系性质如下:

$$(1) \quad \mathbf{X}_{(1)} \approx \mathbf{M}(\mathbf{N} \odot \mathbf{Q})^T$$

$$(2) \quad \mathbf{X}_{(2)} \approx \mathbf{N}(\mathbf{M} \odot \mathbf{Q})^T$$

$$(3) \quad \mathbf{X}_{(3)} \approx \mathbf{Q}(\mathbf{N} \odot \mathbf{M})^T$$

利用上述转换过的因子矩阵, 常用的分解方法为交替最小二乘法, 被称为 CP-ALS 算法. 通过计算因子矩阵的值逼近  $\mathbf{X}$ , 将式 (6) 目标函数转换为:

$$\min_{\mathbf{M}, \mathbf{N}, \mathbf{Q}} \|\mathbf{X} - \hat{\mathbf{X}}\| = \min_{\mathbf{M}, \mathbf{N}, \mathbf{Q}} \|\mathbf{X}^{I \times JK} - \mathbf{M}(\mathbf{N} \odot \mathbf{Q})^T\| \quad (9)$$

在计算因子矩阵  $\mathbf{M}, \mathbf{N}, \mathbf{Q}$  时, 先初始化矩阵, 赋予其猜测值. 根据式 (10), 利用  $\mathbf{N}, \mathbf{Q}$  矩阵的值计算  $\mathbf{M}$  矩阵的值; 再利用式 (11) 中,  $\mathbf{Q}$  矩阵值和计算出的  $\mathbf{M}$  矩阵值, 求出  $\mathbf{N}$  矩阵值; 最后使用式 (12), 将计算出的  $\mathbf{M}$  和  $\mathbf{N}$  矩阵值结合求出  $\mathbf{Q}$  矩阵值. 重复迭代上述步骤, 直至式 (9) 的目标函数收敛.

$$\hat{\mathbf{M}} = \mathbf{X}_{(1)} [(\mathbf{N} \odot \mathbf{Q})^T] \quad (10)$$

$$\hat{\mathbf{N}} = \mathbf{X}_{(2)} [(\mathbf{M} \odot \mathbf{Q})^T] \quad (11)$$

$$\hat{\mathbf{Q}} = \mathbf{X}_{(3)} [(\mathbf{N} \odot \mathbf{M})^T] \quad (12)$$

在评分系统中, 用户与项目数据规模巨大, 但用户评分的项目数量少, 因此存在大量缺失值. 在计算过程中, 需要通过逐级优化的方式进行处理. 针对每一位用户, 缺失值的填充作为对项目的评分预测结果, 再利用 TopN 原则进行推荐.

### 3 实验结果及分析

在这部分, 将介绍本文模型的实验结果. 首先具体介绍本文使用的数据集情况, 统计分析数据集的特性, 并简要介绍本文所使用的实验方法以及对比算法; 然后, 展示实验对比的推荐结果, 并对实验结果进行分析.

#### 3.1 实验数据及评价指标

本实验采用豆瓣网 API 接口获取的数据集. 豆瓣网是一个提供电影、图书、音乐唱片评论的网站, 该网站的评论内容和评分全部由用户产生. 实验数据集中包含了 339 个用户对 2095 部电影的评分信息, 时间跨度为 2009 ~ 2016 年, 其中每个用户至少评价了 20 部以上的电影, 而每部电影至少被 20 位用户评论. 同时, 数据记录了电影的被评论时间以及电影标签信息. 该数据集可以看成一个大为  $I \times J \times K$  的张量, 即  $339 \times 2095 \times k$ ,  $k \in [2, 10]$ . 本实验采用的评价指标为准确率 precision, 召回率 recall 和 F1 值.

#### 3.2 动态角色标识的实验参数对比分析

实验比较了在不同时间窗设定下, 随着角色数量  $k$  增加的结果. 该实验设定角色数量  $k$  的范围是  $2 \leq k \leq 10$ , 时间窗的设定为, 方案 1: time window = year, 方案 2: time window = semester, 方案 3: time window = trimester,

方案4: time window = month. 实验将 80% 数据作为训练集, 20% 数据作为测试集, 进行推荐对比, 如图 2 所示.

图 2 展现了实验参数  $k$  以及时间窗大小的改变, 对推荐结果的影响. 以  $k$  值为变量, 推荐的准确率、召回率和  $F1$  值在不同时间窗下, 随着  $k$  值的增加均呈现先波动后平稳的变化规律. 在  $k \leq 6$  时, 时间窗范围越小, 其表现出的推荐效果越好. 在  $7 \leq k \leq 10$  时, 准确率呈现平

稳的上升趋势, 而召回率和  $F1$  值出现平稳状态. 综上所述, 在时间窗口为 month, 角色数量  $k$  为 4 时, 推荐效果最佳. 分析出现上述结果的原因, 推荐性能易受  $k$  值影响, 但随着角色数量  $k$  的不断增大, 数据的稀疏程度越来越高,  $k$  值的影响效果减弱, 推荐结果会逐渐趋于平稳甚至降低.




图2 不同时间窗和 $k$ 值设定对结果的影响

### 3.3 不同稀疏度环境下的实验对比分析

实验比较了各算法在不同稀疏度环境下的推荐准确率、召回率和  $F1$  值, 本实验使用了如下对比算法: slope one, LFM, UBCF 以及本文的 DRaT (Dynamic Role and Tensor) 算法. 在固定维度和规模的张量模型中, 训练数据集的比例越低, 填充的评分数据越少, 数据越稀疏, 稀疏度越大, 反之亦然. 因此, 训练数据集的比例从 0.1 ~ 0.9, 稀疏程度不断减弱. 实验结果如图 3 所示.

图 3 展示了稀疏度的改变对推荐结果的影响. 由图可知, 本文提出的方法 DRaT 效果优于其他算法, 在推荐准确率、召回率和  $F1$  值上都具有良好的表现. 在准确率和  $F1$  值的比较中, 推荐结果随着稀疏度的降低而降低. 在召回率上, 稀疏度的下降导致推荐召回率逐步增加. 实验证明本文提出的方法在较低的稀疏度上也具有良好的推荐性能, 可在一定程度上改善数据稀

疏环境下的推荐效果.

上述实验对比了不同算法的推荐性能, 接着, 本文展示了各算法基于角色标识后的推荐效果对比.

通过图 4 的实验展示证明, 基于角色标识后的 slope one、LFM 和 UBCF 算法推荐效果得到一定改善, 但本文提出的方法依然比基于角色标识后的各算法性能更好, 在准确率、召回率和  $F1$  值上都具有较好的结果. 其中召回率和  $F1$  值明显效果更好, 准确率的比较中只比 LFM 算法略好.

### 3.4 基于 TopN 推荐的实验对比分析

推荐系统的常见应用方式是 TopN 推荐, 因此最后选择 TopN 推荐的实验对比. 本实验比较了上述不同算法基于角色标识后在 TopN 推荐中准确率、召回率和  $F1$  值的表现, 该实验选择各算法最佳结果进行 TopN 推荐比较, 如图 5 所示.

本文的算法只在准确率比较上比 LFM 略差, 其余




图3 稀疏度对四种算法推荐结果比较

情况均比基于角色标识的各算法效果更佳. 主要原因在于本文的方法中, 不同角色的用户数据分布于张量的不同维度, 导致各维度数据分布不均匀. 在用户多的

角色层, 评分预测结果更精准的项目也越多. 随着推荐数量的增加, 整体上, 本文提出的 DRaT 方法具有良好的效果.




图4 稀疏度对四种算法(基于角色标识)推荐结果比较




图5 四种算法(基于角色标识)的TopN 推荐结果比较

## 4 结束语

本文结合用户兴趣和物品信息, 提出一种基于动态角色标识和张量分解的推荐模型. 首先, 提出利用信息熵原理度量用户角色, 为用户标识角色群体进而实现更精准的推荐. 其次, 该模型结合时间窗对用户角色实现动态标识, 有效的模拟用户的兴趣变化, 使推荐结果更符合实际环境. 最后, 使用 CP-ALS 张量分解方法进行评分预测, 对用户进行 TopN 推荐. 实验表明, 融合动态角色标识和张量模型的算法, 能够提高推荐效率以及改善数据稀疏造成的预测精度问题. 同时, 本文提出的方法比较其他基准算法及其改进算法具有更好的推荐性能.

## 参考文献

- [1] Linder H P, Johnson S D. The netflix recommender system: algorithms, business value, and innovation[J]. ACM Transactions on Management Information Systems, 2016, 6(4): 29-47.
- [2] Zoeter O. Recommendations in travel[A]. ACM Conference on Recommender Systems [C]. Vienna, Austria;

ACM, 2015. 234-234.

- [3] 黄震华, 张佳雯, 张波, 喻剑, 向阳, 黄德双. 语义推荐算法研究综述[J]. 电子学报, 2016, 44(9): 2262-2275. HUANG Zhen-hua, ZHANG Jia-wen, ZHANG Bo, YU Jian, XIANG Yang, HUANG De-shuang. Survey of semantics based recommendation algorithms[J]. Acta Electronica Sinica, 2016, 44(9): 2262-2275. (in Chinese)
- [4] Changyong Liang, Yajun Leng. Collaborative filtering based on information-theoretic co-clustering [J]. International Journal of Systems Science, 2013, 45(3): 589-597.
- [5] Luo X, Zhou M, Li S, et al. A nonnegative latent factor model for large-scale sparse matrices in recommender systems via alternating direction method [J]. IEEE Transactions on Neural Networks & Learning Systems, 2016, 27(3): 579-592.
- [6] Kim J, Lee D, Chung K Y. Item recommendation based on context-aware model for personalized u-healthcare service [J]. Multimedia Tools & Applications, 2014, 71(2): 855-872.
- [7] Recommending G. Group proximity measure for recommending groups in online social networks[J]. ACM Sigkdd Workshop on Social Network Mining & Analysis, 2008.



- [8] Hsu C N, Chung H H, Huang H S. Mining skewed and sparse transaction data for personalized shopping recommendation[J]. Machine Learning, 2004, 57(1-2): 35-59.
- [9] Sarwar B, Karypis G, Konstan J, et al. Item-based collaborative filtering recommendation algorithms [A]. International Conference on World Wide Web[C]. Hong Kong: ACM, 2001. 285-295.
- [10] Luo X, Zhou M, Xia Y, et al. An efficient non-negative matrix-factorization-based approach to collaborative filtering for recommender systems[J]. IEEE Transactions on Industrial Informatics, 2014, 10(2): 1273-1284.
- [11] Tang J, Hu X, Liu H. Social recommendation: a review [J]. Social Network Analysis & Mining, 2013, 3(4): 1113-1133.
- [12] 王兴茂, 张兴明, 吴毅涛, 等. 基于启发式聚类模型和类别相似度的协同过滤推荐算法[J]. 电子学报, 2016, 44(7): 1708-1713.  
WANG Xing-mao, ZHANG Xing-ming, WU Yi-tao, et al. A collaborative recommendation algorithm based on heuristic clustering model and category similarity[J]. Acta Electronica Sinica, 2016, 44(7): 1708-1713. (in Chinese)
- [13] 马慧芳, 贾美惠子, 张迪, 蔺想红. 融合标签关联关系与用户社交关系的微博推荐方法[J]. 电子学报, 2017, 45(1): 112-118.  
MA Hui-fang, JIA Mei-hui-zi, ZHANG Di, LIN Xiang-hong. Microblog recommendation based on tag correlation and user social relation [J]. Acta Electronica Sinica, 2017, 45(1): 112-118. (in Chinese)
- [14] Lee H, Ahn Y, Lee H, et al. Quote recommendation in dialogue using deep neural network[A]. International ACM SIGIR Conference on Research and Development in Information Retrieval[C]. Pisa, Italy: ACM, 2016. 957-960.
- [15] Hong L, Zou L, Zeng C, et al. Context-aware recommendation using role-based trust network[J]. ACM Transactions on Knowledge Discovery from Data, 2015, 10(2): 1-25.
- [16] 吴永辉, 王晓龙, 丁宇新, 徐军, 郭鸿志. 基于主题的自适应、在线网络热点发现方法及新闻推荐系统[J]. 电子学报, 2010, 38(11): 2620-2624.  
WU Yong-hui, WANG Xiao-long, DING Yu-xin, XU Jun, GUO Hong-zhi. Adaptive on-line web topic detection method for web news recommendation system [J]. Acta Electronica Sinica, 2010, 38(11): 2620-2624. (in Chinese)
- [17] Li B, Zhu X, Li R, et al. Rating knowledge sharing in cross-domain collaborative filtering [J]. IEEE Transactions on Cybernetics, 2015, 45(5): 1054.
- [18] Sharifi Z, Rezghi M, Nasiri M. New algorithm for recom-

mender systems based on singular value decomposition method[A]. International Econference on Computer and Knowledge Engineering[C]. Iranshahr, Iran: Ferdowsi University of Mashhad, 2013. 86-91.


- [19] Karatzoglou A, Amatriain X, Baltrunas L, et al. Multiverse recommendation: n-dimensional tensor factorization for context-aware collaborative filtering [A]. ACM Conference on Recommender Systems [C]. Barcelona, Spain: ACM, 2010. 79-86.

- [20] Lu W, Chung F L. Computational creativity based video recommendation[A]. International ACM SIGIR Conference on Research and Development in Information Retrieval[C]. Pisa, Italy: ACM, 2016. 793-796.

#### 作者简介



肖云鹏 男, 1979 年生于安徽蚌埠, 现为重庆邮电大学副教授、硕士生导师。主要研究方向为机器学习、社交网络。  
E-mail: xiaoyun@cqupt.edu.cn



刘晏驰 男, 1993 年生于重庆北碚, 现为重庆邮电大学硕士研究生。主要研究方向为推荐系统、机器学习。  
E-mail: liuyanchi030@sina.cn



刘红 女, 1981 年生于重庆巴南, 现为重庆邮电大学副教授、硕士生导师。主要研究方向为图像安全、图像搜索。  
E-mail: liuhong1@cqupt.edu.cn



刘媛妮 女, 1982 年生于河南邓州, 现为重庆邮电大学副教授。主要研究方向为移动群智感知网络、物联网安全。  
E-mail: liuyanni@cqupt.edu.cn