

# 基于知识聚合和迁移的跨领域推荐算法

刘 真,田靖玉,苑宝鑫,孙永奇  
(北京交通大学计算机与信息技术学院,北京 100044)

**摘 要:** 传统的推荐算法受限于单领域中用户和项目的稀疏关系,也存在用户冷启动等问题. 跨领域推荐能够通过学习辅助领域的知识去丰富目标领域的稀疏数据以提高推荐准确率. 本文提出了一种知识聚合和迁移相结合的跨领域推荐算法 ATCF. 与已有算法不同,在对共性知识和个性知识的表示学习中,ATCF 均充分融合了辅助域和目标域的知识,通过基于矩阵分解的两级矩阵拼接和两次矩阵填充,得到在群集矩阵及评分矩阵上的共性知识表示;通过知识迁移,构建了重叠用户和非重叠用户的个性知识表示,有效避免了负迁移. 在两个跨领域数据集上开展的实验表明,ATCF 算法与已有单领域和跨领域推荐算法相比 RMSE 降低了 3% ~ 7%,准确率召回率增加了 8% ~ 15%.

**关键词:** 跨领域推荐; 矩阵分解; 迁移学习; 知识聚合

**中图分类号:** TP391 **文献标识码:** A **文章编号:** 0372-2112 (2020)10-1928-05

**电子学报 URL:** <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2020.10.008

## Cross-Domain Recommendation Algorithm Based on Knowledge Aggregation and Transfer

LIU Zhen, TIAN Jing-yu, YUAN Bao-xin, SUN Yong-qi

(School of Computer and Information Technology, Beijing Jiaotong University, Beijing 100044, China)

**Abstract:** Cross-domain recommendation can study the knowledge of the auxiliary domains to enrich the knowledge in the target domain, so as to improve the recommendation precision in the target domain. This paper proposes an aggregation and transfer collaborative filtering algorithm for cross-domain recommendation (ATCF). In order to represent the sharing knowledge in different domains, the knowledge in the auxiliary domain and the target domain are fully aggregated, through two levels of matrix concatenation. Moreover, the personalized knowledge of the target domain is represented by knowledge transferring from auxiliary domain. By fusion the sharing and the personalized knowledge, we can obtain the final rating. Two different cross-domain datasets are used for the experiments. Our efforts show that the ATCF algorithm has better recommendation performance.

**Key words:** cross-domain recommendation; matrix factorization; transfer learning; knowledge aggregation

### 1 引言

推荐系统在一定程度上缓解了信息过载的问题. 随着用户和项目数急剧增长,传统的单领域协同过滤算法在应对冷启动<sup>[1]</sup>和数据稀疏性<sup>[2]</sup>问题时,显得力不从心. 研究表明来自不同平台的用户偏好和项目特征存在相似性和相关性. 例如电影和图书在体裁分类上具有相似性,它们的相似特征使得用户在电影/图书领域的兴趣和偏好可借鉴到用户在图书/电影领域中. 因此,学术界提出了跨领域推荐技术,对不同辅助领域 (Auxiliary Domain) 的用户和项目特征进行知识表示,

通过聚合或迁移,弥补目标领域 (Target Domain) 的信息稀缺问题.

但是不同领域存在数据异构性和知识独立性,使得传统单领域算法<sup>[3,4]</sup>无法应用于跨领域推荐.

跨领域推荐方法主要分为两类<sup>[5]</sup>: 基于连接/聚合 (Linking/aggregating) 领域间知识的方法以及基于共享/迁移 (Sharing/transferring) 领域间知识的方法.

领域间知识聚合的工作,主要是通过辅助域和目标域的评分矩阵拼接<sup>[6]</sup>或者通过张量构建和分解提取辅助域和目标域的联合评分模式<sup>[7]</sup>. 然后应用单领域推荐算法,但是直接拼接忽略了领域间的知识差异性,

也带来了较高的时间和计算代价。

在领域间知识迁移的工作中,文献[8]通过分解辅助域和目标域的评分矩阵,将辅助域的项目特征因子迁移至目标域.但是该方法对权重参数敏感,难以保留领域间差异.文献[9]从辅助域提取出聚类级的评分模式迁移至目标域,但只考虑到辅助域和目标域的共性,忽略了领域间的差异性.文献[10]利用辅助域的隐式反馈,迁移潜在的用户和项目因子,更新对角矩阵保留各自领域的特征,该方法不需要用户或项目重叠,但领域间必须存在强关联性.

为避免忽略领域间差异性导致负迁移(Negative Transfer)<sup>[11]</sup>,领域的共性和个性知识表示,还有进一步的研究空间.

## 2 基于知识聚合和迁移的跨领域推荐算法 ATCF

为对领域间共性知识进行有效表示,同时避免忽略领域间差异,提出了一种基于知识聚合和迁移的跨领域推荐算法,在对共性知识和个性知识的表示学习中,均是辅助域和目标域联合起来进行.

### 2.1 问题定义

假设  $R = [r_{ui}]_{n \times m}$  为评分矩阵,其中  $r_{ui}$  表示用户  $u$  对项目  $i$  的评分,  $n$  为用户数,  $m$  为项目数,  $u \in [1 \dots n]$ ,  $i \in [1 \dots m]$ . 如果用户集合中的某个用户  $u$  对项目  $i$  尚未有过评分,则  $r_{ui}$  为空值.  $R_s$  为辅助域的评分矩阵,  $R_t$  为目标域的评分矩阵.

$U^S = \{u_1, u_2, u_3, \dots, u_{n_s}\}$  为辅助域的用户集合;

$I^S = \{i_1, i_2, i_3, \dots, i_{m_s}\}$  为辅助域的项目集合;

$U^T = \{u_1, u_2, u_3, \dots, u_{n_t}\}$  为目标域的用户集合;

$I^T = \{i_1, i_2, i_3, \dots, i_{m_t}\}$  为目标域的项目集合.

考虑用户有重叠的场景,即  $U^S \cap U^T \neq \emptyset$ . 本文的目标是将辅助域  $R_s$  和目标域  $R_t$  联合,进行领域共性知识和个性知识的提取和表示,从而预测  $R_t$  中未观测到的评分值,进而对目标域用户进行推荐.

针对上述目标,本文提出了一种 ATCF (Aggregation and Transfer Collaborative Filtering for cross-domain recom-

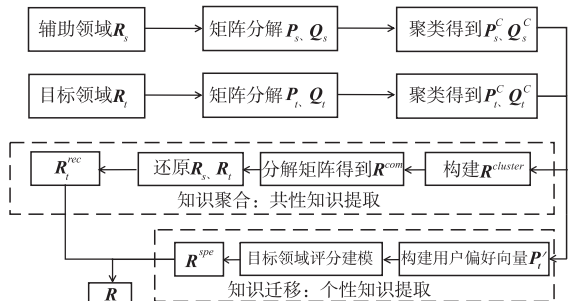


图1 ATCF算法框架图

mendation)算法,算法框架如图 1 所示,算法第一步采用知识聚合的方法,通过矩阵分解获得用户和项目的特征表示,将辅助域和目标域获得的特征进行群集拼接和填充,再对拼接的评分矩阵进行二次填充,获得辅助域和目标域的共性知识.第二步采用知识迁移,以重叠的用户作为桥梁将其在辅助域的潜在特征进行迁移,非重叠用户则保留其在目标域的个性化特征.最后通过共性和个性知识的加权融合形成新的评分预测,实现推荐.

### 2.2 知识聚合构建共性知识模型

**定义 1** 用户/项目特征聚类矩阵  $P^c/Q^c$  将用户特征矩阵  $P_s = [p_1, p_2, \dots, p_{n_s}]^T$  或  $P_t = [p_1, p_2, \dots, p_{n_t}]^T$  通过 Kmeans++<sup>[12]</sup> 聚类成辅助域的  $s$  个用户特征向量群  $P_s^c = [p_1^c, p_2^c, \dots, p_s^c]^T$  和目标域的  $t$  个用户特征向量群  $P_t^c = [p_1^c, p_2^c, \dots, p_t^c]^T$ . 同理,可得到项目特征聚类矩阵  $Q^c$ , 包括  $Q_s^c = [q_1^c, q_2^c, \dots, q_s^c]^T$  和  $Q_t^c = [q_1^c, q_2^c, \dots, q_t^c]^T$  ( $s, t \in N^*$ ).

**定义 2**  $R^{cluster}$  将  $P_s^c, Q_s^c, P_t^c, Q_t^c$  进行拼接后得到群集评分矩阵  $R^{cluster}$ ,  $R^{cluster}$  分为四个子区域,  $D_s D_s, D_s D_t, D_t D_s, D_t D_t$ . 其中  $D_k D_k$  ( $k = s$  或  $t$ ) 表示领域  $k$  的用户对项目产生的偏好. 令  $U_{ki}^c$  表示领域  $k$  中用户第  $i$  个群,  $I_{kj}^c$  表示领域  $k$  中项目第  $j$  个簇.  $r_{U_{ki}^c I_{kj}^c}$  表示领域  $k$  第  $i$  个用户群对领域  $k$  第  $j$  个项目簇的偏好程度.  $r_{U_{ki}^c I_{kj}^c}$  可由式(1)计算得出.

$$r_{U_{ki}^c I_{kj}^c} = \begin{cases} \frac{\sum_{u \in U_{ki}^c, i \in I_{kj}^c} r_{ui}}{\text{num}(r_{ui})}, N \neq \emptyset \\ \text{未观测评分}, N = \emptyset \end{cases} \quad (1)$$

**定义 3**  $R^{com}$  是对矩阵  $R^{cluster}$  进行矩阵分解填充空缺值后得到的矩阵. 对  $R^{cluster}$  进行偏置矩阵分解,使用随机梯度下降方法优化目标函数式(2),得到  $P^{cluster}$  和  $Q^{cluster}$ . 最终得到用户群对项目簇的预测值. 如式(3).

$$L = \sum_{ui \in \text{domain}} (r_{ui}^{cluster} - \mu^{cluster} - b_u^{cluster} - b_i^{cluster} - \sum_k p_{uf}^{cluster} q_{fi}^{cluster})^2 + \lambda (\|b_u^{cluster}\|_2^2 + \|b_i^{cluster}\|_2^2 + \|p_u^{cluster}\|_2^2 + \|q_i^{cluster}\|_2^2) \quad (2)$$

$$r_{ui}^{cluster} = r_{U_{ki}^c I_{kj}^c} = \mu^{cluster} + b_{U_{ki}^c}^{cluster} + b_{I_{kj}^c}^{cluster} + \sum_{f=1}^k p_{U_{ki}^c f}^{cluster} q_{f I_{kj}^c}^{cluster} \quad (3)$$

**定义 4**  $R^{rec}$  根据  $R^{com}$  依照式(4)对辅助和目标域的空缺值二次填充原评分矩阵.

$$r_{ui} = \begin{cases} \text{观测值}, \text{原评分矩阵有观测值} \\ r_{U_{ki}^c I_{kj}^c}, \text{原评分矩阵无观测值}, \\ \quad u \in U_{ki}^c, i \in I_{kj}^c, u \text{ 为非重叠用户} \\ \text{ave } r_{U_{ki}^c I_{kj}^c}, \text{原评分矩阵无观测值}, \\ \quad u \in U_{ki}^c, i \in I_{kj}^c, u \text{ 为重叠用户} \end{cases} \quad (4)$$

根据上述定义,构建共性知识模型是将辅助域和目

标域的用户和项目进行聚类后形成用户群对项目簇的偏好表示  $\mathbf{R}^{cluster}$ , 采用偏置矩阵分解对  $\mathbf{R}^{cluster}$  中的空缺值进行填充得到  $\mathbf{R}^{com}$ , 通过  $\mathbf{R}^{com}$  对原辅助域和目标域的评分矩阵进行还原得到  $\mathbf{R}^{rec}$ . 此过程通过在辅助域和目标域进行内部聚类和外部拼接, 并在拼接的群集矩阵和原始评分矩阵中进行两次填充, 使得偏好值能更有效地传播.

### 2.3 知识迁移构建个性知识模型

本文针对的是用户部分重叠的场景, 考虑到领域间存在知识差异性, 通过迁移用户的潜在因子向量, 将辅助域的用户隐式信息迁移至目标域, 并保留目标域用户独有的特征信息.

特征迁移过程按式(5)更新目标域用户特征矩阵  $\mathbf{P}_i$  为  $\mathbf{P}'_i$ . 按照式(6)进行评分预测, 最终得到  $\mathbf{R}^{spe} = [r_{ui}^{spe}]_{nt \times mt}$ .  $\alpha$  为迁移程度参数,  $\alpha \in [0 \cdots 1]$ ,  $f$  为特征数.

$$\mathbf{p}'_i = [p'_1, p'_2, \dots, p'_m]^T = \begin{cases} p'_i = \alpha * p_i + (1 - \alpha) * p_i, u_i \in U^s \cap U^t \\ p'_i = p_i, u_i \notin U^s \text{ 且 } u_i \in U^t \end{cases} \quad (5)$$

$$r_{ui}^{spe} = \mu^i + b_u^i + b_i^i + \sum_k p'_{uj} q'_{ji} \quad (6)$$

### 2.4 知识聚合和知识迁移相结合的评分预测

由 2.2 节学习得到的  $\mathbf{R}_i^{rec} = [r_{ui}]_{nt \times mt}$  ( $\mathbf{R}^{rec}$  取目标域部分) 和 2.3 节学习得到的  $\mathbf{R}^{spe} = [r_{ui}^{spe}]_{nt \times mt}$  进行加权得到最终预测评分. 加权参数为  $\omega \in [0 \cdots 1]$ .

$$\mathbf{R} = \omega \mathbf{R}_i^{rec} + (1 - \omega) * \mathbf{R}^{spe} \quad (7)$$

## 3 ATCF 算法讨论

### 3.1 KL 散度衡量评分模式相似性

本文提出通过计算基于 KL 散度<sup>[13]</sup> 的用户群对项目簇的偏好分布作为辅助域和目标域相似性度量的方法, 以衡量算法的适用范围. 令  $\mathbf{P}$  和  $\mathbf{Q}$  为辅助域和目标域的群集评分矩阵概率分布矩阵, 式(8)表示辅助域  $\mathbf{P}$  矩阵中用户群  $u$  对项目簇  $i$  的偏好概率:

$$P_{ui} = r_{ui}^c / \sum_k r_{uk}^c \quad (8)$$

其中,  $r_{ui}^c$  为用户群对项目簇的评分偏好程度, 同理可得目标域  $\mathbf{Q}$  矩阵中的  $q_{ui}$  计算不同用户群的评分分布的平均 KL 散度如式(9):

$$D_{KL}(p \parallel q) = \frac{\sum_u \sum_i p_{ui} \log \left( \frac{P_{ui}}{q_{ui}} \right)}{\text{num}(u)} \quad (9)$$

其中  $\text{num}(u)$  为聚类后的用户群个数.

领域间 KL 散度越小表明领域间越相似, 知识迁移的作用越明显, 4.2 节实验 2 可以验证, 因此 KL 散度值可作为辅助域选择的理论指导.

### 3.2 算法复杂度分析

ATCF 算法的计算主要包括评分矩阵分解及获取

用户群、项目簇的聚类. 矩阵分解的时间复杂度是  $O(n * f * m')$ , 其中  $n$  是矩阵的行数,  $f$  表示矩阵分解的特征数,  $m'$  是用户评分过的项目平均数. 对用户和项目进行聚类的时间复杂度是  $O(tkdf)$ , 其中  $t$  为迭代次数,  $k$  为簇的数目,  $d$  为样本数,  $f$  为特征数.

ATCF 算法的空间复杂度分析如下. 算法构建群集评分矩阵  $\mathbf{R}^{cluster}$  和还原矩阵  $\mathbf{R}^{rec}$ , 空间复杂度为  $O[(ns + nt) * (ms + mt)]$ . 其中  $ns$  表示辅助域用户数,  $nt$  表示目标域用户数,  $ms$  表示辅助域项目数,  $mt$  表示目标域项目数.

## 4 实验及结果分析

### 4.1 实验数据集和评价指标

本文实验采用了三个数据集: MovieLens 1MB 数据集\*、豆瓣\*\*图书数据集、豆瓣电影数据集.

实验对数据集进行了划分, 第一组为 MovieLens 数据集按照用户 ID 切分为辅助域  $M_s$  和目标域  $M_t$ . 第二组为豆瓣数据集, 划分为辅助域图书  $DB_s$  和目标域电影  $DM_t$  两部分, 两组数据都存在用户重叠, 即用户 ID 相同. 两组数据均将目标域划分为 80% 的训练集和 20% 的测试集.

本文采用平均绝对误差 (MAE)、均方根误差 (RMSE)、准确率和召回率作为算法的评价指标.

### 4.2 实验结果及分析

实验采用的对比算法有: 单领域推荐算法 PMF<sup>[14]</sup>、NeuMF<sup>[15]</sup>、跨领域推荐算法 CBT<sup>[9]</sup>、TCF (CSVD)<sup>[4]</sup>.

#### 实验 1 参数设置

表 1(a) 为构建个性知识模型中, 辅助域迁移权重  $\alpha$  不同时 RMSE 值的比较. 由结果可知迁移阶段  $\alpha$  值大时, 能够迁移辅助域更多的用户特征, 丰富目标域的用户建模, 提升算法性能. 表 1(b) 为知识聚合和迁移两阶段不同权重  $\omega$  下的 RMSE 值, 两组数据分别取  $\omega = 0.6$  和  $\omega = 0.4$  时 RMSE 值最低. 后续实验是在  $\alpha$  和  $\omega$  最优的条件下进行的.

表 1 权重参数对算法的影响

(a) 个性知识中的迁移权重 $\alpha$ 对 RMSE 的影响					
数据集	评价指标	$\alpha = 0.2$	$\alpha = 0.4$	$\alpha = 0.6$	$\alpha = 0.8$
MovieLens	RMSE	1.0021	0.9014	<b>0.8786</b>	0.8951
豆瓣	RMSE	0.9956	<b>0.9680</b>	1.0112	1.1561
(b) 共性知识权重 $\omega$ 对 RMSE 的影响					
数据集	评价指标	$\omega = 0.2$	$\omega = 0.4$	$\omega = 0.6$	$\omega = 0.8$
MovieLens	RMSE	1.014	0.9214	<b>0.8790</b>	0.9661
豆瓣	RMSE	1.1124	<b>0.9678</b>	0.9774	0.9841

\* <http://grouplens.org/datasets/movielens/>

\*\* <http://www.douban.com>

### 实验 2 算法性能对比

与对比算法的性能比较如表 2 所示. 结果表明单领域推荐算法 PMF 和 NeuMF 的 RMSE 和 MAE 均高于跨领域推荐算法, 相比于 CBT 算法和基于用户和项目特征迁移的 TCF 算法, ATCF 算法降低了 RMSE 和 MAE.

表 2 RMSE、MAE 对比结果

数据集	评价指标	PMF	NeuMF	CBT	TCF	ATCF
MovieLens	RMSE	0.9622	0.9438	0.9235	0.9041	<b>0.8854</b>
	MAE	0.7503	0.7427	0.7312	0.7245	<b>0.7189</b>
豆瓣	RMSE	1.0017	1.0121	0.9788	0.9679	<b>0.9666</b>
	MAE	0.7854	0.7949	0.7441	0.7412	<b>0.7302</b>




图 2 准确率、召回率对比结果

ATCF 算法将知识聚合和知识迁移相结合, 与单领域推荐算法 PMF 和 NeuMF 相比由于融合了辅助域的信息并且通过聚类缓解了目标域的数据稀疏性, 从而提高了推荐的准确性; 与跨领域推荐算法 CBT 相比, ATCF 算法挖掘了辅助域和目标域的共同评分模式, 得到对群集用户对项目的全面偏好特征, 丰富了偏好模型, 因而提高了推荐性能. 与 TCF 相比, ATCF 算法为了缓解负迁移的问题, 在对个性知识表示中同时考虑了辅助域和目标域特征, 因而提高了推荐准确性.

为了讨论算法的适用性, 通过式(9)计算了 MovieLens 和豆瓣数据集的 KL 散度值分别为 0.436 和 0.617, 实验二中可以发现算法在 MovieLens 数据集上的 RMSE 值相对于在豆瓣数据集上的 RMSE 值更小, 推荐更加准确. 即, ATCF 算法在 KL 散度值越小, 辅助域和目标域更相关的情况下推荐效果更好, 因此, 可以通过 KL 散度值来选取对目标域推荐更为有效的辅助域.

### 实验 3 算法对冷启动用户的影响

将评过分的项目占总项目的比例低于 5% 的用户定为冷启动用户, 计算算法针对冷启动用户的性能如表 3 所示. 从表 3 中可知, 与目标域的所有用户相比, 冷启动用户的推荐准确率提高了 0.6% ~ 1.2%, 召回率提高了 1.6% ~ 2.7%, 这说明 ATCF 算法在一定程度上能够缓解用户冷启动问题.

图 2 为算法的准确率和召回率结果对比, 可以看到 ATCF 算法相比于 PMF 和 CBT, 提高了准确率和召回率. 在  $k=5$  的情况下比 PMF 和 CBT 在算法准确率和召回率上分别提高了 15% 和 8% 左右.

表 3 ATCF 算法对不同用户的影响

数据集	评价指标	所有用户	冷启动用户
MovieLens	准确率	0.221	<b>0.233</b>
	召回率	0.239	<b>0.255</b>
豆瓣	准确率	0.217	<b>0.223</b>
	召回率	0.237	<b>0.264</b>

## 5 结论

针对用户部分重叠的应用场景, 本文提出了一种基于知识迁移和聚合的跨领域协同过滤推荐算法 ATCF. 通过融合辅助域和目标域的知识, 并进行基于矩阵分解的两级矩阵拼接和两次矩阵填充, 挖掘了领域间的共性和个性特征. 进一步的研究, 考虑将目标域的共性知识和个性知识进行聚合嵌入, 利用多层感知机来更好地捕获辅助域和目标域之间的非线性映射关系, 为学习不同域之间的用户项目交互特征提供更大的灵活性.

### 参考文献

- [1] ZHOU K, YANG S H, ZHA H Y. Functional matrix factorizations for cold-start recommendation [A]. Proceedings of the 34th International ACM SIGIR Conference on Research and Development in Information Retrieval [C]. Beijing, China, 2011. 315 - 324.
- [2] 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.
- [3] Shi L, Zhao W X, Shen Y D. Local representative-based matrix factorization for cold-start recommendation [J]. *ACM Transactions on Information Systems*, 2017, 36(2): 1 – 28.
- [4] Pan W, Liu Z, Ming Z. Compressed knowledge transfer via factorization machine for heterogeneous collaborative recommendation [J]. *Knowledge-Based Systems*, 2015, 85: 234 – 244.
- [5] Cantador I, Cremonesi P. Tutorial on cross-domain recommender systems [A]. 8th ACM Conference on Recommender Systems [C]. NY, US: Association for Computing Machinery, 2014. 401 – 402.
- [6] Berkovsky S, Kuflik T, Ricci F. Mediation of user models for enhanced personalization in recommender systems [J]. *User Modeling and User-Adapted Interaction*, 2008, 18(3): 245 – 286.
- [7] Hu L, Cao J, Xu G. Personalized recommendation via cross-domain triadic factorization [A]. *Proceedings of the 22nd International Conference on World Wide Web* [C]. New York, USA, 2014. 595 – 696.
- [8] Gordon A P S G J. Relational learning via collective matrix factorization [A]. *Proceedings of the 14th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* [C]. Las Vegas, Nevada, USA, 2008. 650 – 658.
- [9] Li B, YANG Q, XUE X. Can movies and books collaborate cross-domain collaborative filtering for sparsity reduction [A]. *Proceedings of International Joint Conference on Artificial Intelligence* [C]. Pasadena, California, USA, 2009. 2052 – 2057.
- [10] Weike P, YANG Q. Transfer learning in heterogeneous collaborative filtering domains [J]. *Artificial Intelligence*, 2013, 197: 39 – 55.
- [11] Pan S J, YANG Q. A survey on transfer learning [J]. *IEEE Transactions on Knowledge and Data Engineering*, 2010, 22(10): 1345 – 1359.
- [12] Aubaidan B, Mohd M, Albared M. Comparative study of k-means and k-means ++ clustering algorithms on crime domain [J]. *Journal of Computer Science*, 2014, 10(7): 1197 – 1206.
- [13] Joyce J M. Kullback-Leibler Divergence [M]. Springer, Berlin: Heidelberg International Encyclopedia of Statistical Science, 2011.
- [14] Mnih A, Salakhutdinov R R. Probabilistic matrix factorization [A]. *Advances in Neural Information Processing Systems* [C]. ACM, 2008. 1257 – 1264.
- [15] HE X N, LIAO L Z, ZHANG H W, et al. Neural collaborative filtering [A]. *Proceedings of the 26th International Conference on World Wide Web* [C]. Switzerland, 2017. 173 – 182.

### 作者简介



刘真女, 1977年6月出生, 江西南昌人。毕业于中国科学院计算技术研究所, 获博士学位。现为北京交通大学计算机与信息技术学院副教授, 博导。主要研究方向为推荐系统、社交网络与社会计算。  
E-mail: zhliu@bjtu.edu.cn



田靖玉女, 1994年2月出生, 河北邯郸人。毕业于廊坊师范学院数学与信息科学学院, 获学士学位。现为北京交通大学计算机科学与技术专业硕士研究生。主要研究方向为推荐系统。  
E-mail: jytian@bjtu.edu.cn