

直播电视推荐系统的评分预测算法研究

郭景峰^{1,2,3}, 朱晓松^{1,2,3}, 李爽^{4,5}

(1. 燕山大学信息科学与工程学院, 河北秦皇岛 066004; 2. 河北省计算机虚拟技术与系统集成重点实验室, 河北秦皇岛 066004;
3. 河北省文化旅游大数据技术创新中心, 河北承德 067000; 4. 天津大学建筑学院, 天津 300072;
5. 河北环境工程学院生态系, 河北秦皇岛 066102)

摘要: 伴随电视频道的不断增加, 推荐系统在直播电视领域应用成为研究热点. 然而, 直播电视独特的播放和收视方式使得传统的 VOD (Video On Demand) 推荐系统无法直接应用, 已有的推荐频道的方法不关注正在播出的节目状态从而影响了推荐准确率, 而推荐节目的方法难以应对节目冷启动. 为此, 本文提出了一种融合频道推荐和节目推荐的评分预测算法 OFAP (Over the First by Adding Preference). 首先, 利用聚类方法对每个用户实现差异性的收视时段划分, 构建他们的频道-时段偏好矩阵和预推荐评分权重矩阵; 其次, 提出一个评分替代策略使得已有的推荐节目的算法能够应对节目冷启动, 从而实现预推荐; 最后, 通过融合用户偏好、预推荐评分权重与预推荐结果, 构建评分预测函数, 将预推荐算法的评分预测结果作为评分预测函数的训练样本. 实验表明, 采用 Precision@N 和 Recall@N 作为评价标准, 本文所提方法 OFAP 明显优于对比算法.

关键词: 直播电视; 推荐系统; 冷启动; 时间相关; 预推荐; 协同过滤; 电视频道

中图分类号: TP302; TP391 **文献标识码:** A **文章编号:** 0372-2112 (2020)09-1735-06

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2020.09.010

Research on Rating Prediction Algorithm of Live TV Recommender Systems

GUO Jing-feng^{1,2,3}, ZHU Xiao-song^{1,2,3}, LI Shuang^{4,5}

(1. College of Information Science and Engineering, Yanshan University, Qinhuangdao, Hebei 066004, China;
2. The Key Laboratory for Computer Virtual Technology and System Integration of Hebei Province, Qinhuangdao, Hebei 066004, China;
3. The Technology Innovation Center of Cultural Tourism Big Data of Hebei Province, Chengde, Hebei 067000, China;
4. School of Architecture, Tianjin University, Tianjin 300072, China;
5. Faculty of Ecology, Environmental Management College of China, Qinhuangdao, Hebei 066102, China)

Abstract: With the increase of TV channels, the application of recommender systems in the field of live TV has become a research hotspot. However, a traditional VOD (Video on Demand) recommender system is unable to be directly applied in live TV because of its special way of broadcasting and watching, and the existing methods of recommending channels do not pay attention to status of TV shows being broadcasted, which affects recommendation accuracy, and the methods of recommending programs are difficult to handle cold start of TV shows. Therefore, this paper proposes a rating prediction algorithm by fusing TV channel recommendation method and TV program recommendation method OFAP (Over the First by Adding Preference). Firstly, we construct different channel-time preference matrix and rating weight matrix of pre-recommendation for each user by clustering their viewing logs. Secondly, we propose a rating strategy to alleviate the cold-start problem of TV programs for existing program recommendation algorithms, and we adopt one of them to perform pre-recommendation. Finally, we combine user's preference, rating weight and rating of pre-recommendation to construct a prediction function, which is trained with the results of pre-recommendation. Experiments on industrial datasets show that the proposed model OFAP significantly outperforms baseline algorithms when Precision@N and Recall@N are adopted as criterias.

Key words: live TV; recommender system; cold start; time-based; pre-recommendation; collaborative filtering; TV channel

1 引言

随着直播电视频道的不断增加及智能电视的普及,直播电视推荐系统逐渐成为研究热点.然而,直播电视的独特性给其推荐系统的研究带来困难:首先,直播电视受众群体多为家庭,多个家庭成员共享一个终端^[1,2],推荐系统需面对多观众偏好区分的问题;其次,直播电视推荐系统需在节目播出时将其推荐给观众,推荐窗口期窄,因而推荐系统需具有良好的实时性;最后,直播电视每天更新大量节目,这些节目从未播出,没有收视记录(评分)可参考^[3],节目冷启动突出.

目前,直播电视推荐系统的研究工作可分为推荐节目的方法^[4-9]和推荐频道的方法^[1,3,10,11].推荐节目的方法通常构建 user-item 偏好矩阵,对用户的偏好估计精准,一般作为协同过滤问题,但无法应对节目冷启动.推荐频道的方法则通常构建 user-channel-other 张量,在推荐时刻不必关注节目,因而可应对节目冷启动,但其推荐准确率通常低于推荐节目的方法.

针对当前直播电视推荐算法难以兼顾准确率及应对节目冷启动的现状,本文提出了一个直播电视推荐系统的评分预测算法(图1),将直播电视推荐任务看作基于预测评分的排序问题,融合推荐频道和推荐节目的方法来构建预测评分函数.

首先,利用聚类方法对每个用户实现差异性的收视时段划分,并构建该用户的频道-时段偏好矩阵和预推荐评分权重矩阵,以区分单用户下的多观众偏好;其次,提出一个评分替代策略使得已有的推荐节目的方法可应对节目冷启动,从中选择一个方法作为预推荐算法实施推荐;最后,将用户偏好、预推荐评分权重与预推荐结果融合,构建评分预测函数 F ,以预推荐算法的评分预测结果作为 F 的训练样本.

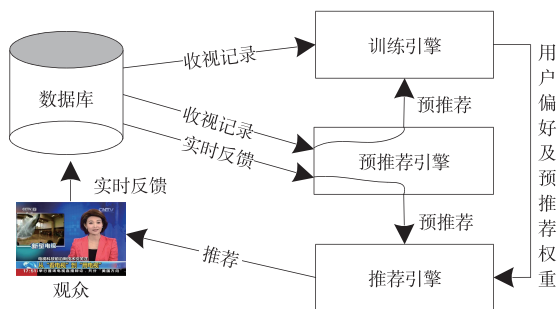


图1 本文算法

2 相关工作

直播电视推荐系统的研究工作分为三个方面:(1)偏好估计.先将用户的隐性反馈(比如收视时长)转换为显性反馈(比如评分),常见方法如时长累计^[4]、“0-1”法^[12],收视时长占比法^[6]等,然后以矩阵或张量等形

式表示用户偏好,如 user-item^[5,6]、user-item-time^[2]、user-channel-other^[1,10]、其它^[4]等。(2)偏好预测.在偏好估计的基础上预测未知偏好,常见方法如矩阵分解^[1,13]、KNN^[5]、神经网络^[6]等。(3)节目(或频道)推荐.调整偏好估计和偏好预测的结果^[4,6],依据预测得分产生 TOP-N 推荐列表.下面选择一些有代表性方法进行分析.

推荐节目的方法主要包含传统的基于内容的方法^[9]和协同过滤方法^[5-7].基于内容的方法是各类推荐任务中解决冷启动的通用方法.对于直播电视,基于内容的方法利用媒体信息(比如节目分类、导演等)将历史节目、用户、新节目关联起来.文献[9]通过计算节目间媒体信息的相似度来向用户推荐新的节目.但是,基于内容的方法要求运营商拥有丰富的额外信息,其推荐准确性依赖标签的维度和质量.直播电视领域中协同过滤方法的应用与 VOD(Video On Demand)领域相近.比如,文献[5]构造了关于用户的收视时长和观看时长占比的评分函数,利用 Pearson 相关系数计算用户间相似度,通过基于用户相似度的协同过滤算法(User-based CF,UCF)实现节目推荐.文献[6]利用最小二乘法对 user-item 偏好矩阵进行偏好预测生成最后的评分矩阵,利用收视概率模型对评分矩阵调节.这类方法面临数据稀疏和节目冷启动的问题.此外,文献[4]分别构建 user-item 偏好矩阵和收视频次矩阵,将用户对候选节目的偏好与对应的收视概率的乘积作为候选节目的预测值,但无法应对节目冷启动.文献[8]从用户收视历史和社会网络当中获得用户偏好.然而,无论线上还是线下,电视运营商都难以获得用户社会网络信息.

推荐频道的方法将用户对节目的偏好转换为对频道的偏好,以频道为媒介把历史节目和新节目关联起来^[1,3,10,11].这类方法的偏好估计模型(比如 user-channel)的规模远小于 user-item,因而缓解了数据稀疏问题.比如,文献[1]将一天分成 8 个时段为每个用户构建 time-channel 评分矩阵,利用每个收视时段的累积收视时长作为用户在该时段的收视偏好,最后通过张量分解实现偏好预测.文献[3]将一周等分成 336 个时段,结合节目分类信息捕捉用户偏好,构建 user-preference 张量.然而,上述方法的时段划分策略依赖经验且策略单一,将单一策略无差别的应用于所有用户,没有考虑不同用户间家庭成员的差异.

鉴于上述问题,本文工作仅以收视记录和电子节目指南(Electronic Program Guide, EPG)为研究基础,降低了对数据集的要求.本文考虑用户间家庭成员差异,为每个用户实施差异性时段划分策略,通过融合推荐节目和推荐频道的方法来兼顾推荐效果和应对节目冷启动.

3 直播电视推荐评分预测方法

3.1 准备工作

推荐内容为频道或节目,记为 $I = \{I_1, I_2, \dots, I_n\}$, n 表示频道数或者正在播出的节目数. 对于某算法(下文称预推荐算法)的推荐结果,期望推荐列表排名第一的项目(TOP-1 推荐项)就是用户实际消费的项目(消费项),然而图 2 中的结果不尽人意. 为改善推荐效果,在消费项 I_8 的预测评分 r_8 的基础上,通过加入用户 u 的收视偏好得分,使得融合评分超越 TOP-1 推荐项 I_3 的预测评分 r_3 ,从而重置推荐列表. 即将推荐模型的训练任务定义为:让消费项的预测值超过 TOP-1 推荐项的预测值. 具体的,在训练阶段,将 r_3 作为目标,将 r_8 作为追赶者,使 $F(r_8) > \beta r_3$, $\beta \geq 1$,其中 β 为调节系数. 令 $F(r_8) = \beta r_3$,通过训练获得评分预测函数 F ;在测试阶段,将任意候选项 I_c 的预推荐的预测值 r_c 经 F 变换后的结果作为最终预测评分,即 $\hat{r}_c \leftarrow F(r_c)$,按照评分从高到低排序,产生推荐列表.

排序	候选项	预测值
1	I_3 (TOP-1 推荐项)	r_3
2
3
4	I_8 (消费项)	r_8

图2 预推荐列表

3.2 评分预测算法

首先,通过划分收视时段定义收视偏好矩阵和预推荐评分权重矩阵;其次,利用预推荐算法产生 TOP-1 推荐项和消费项的预测评分,将其作为 F 的训练样本;最后,融合上述结果,构建评分预测函数 F .

3.2.1 定义用户偏好矩阵和预推荐评分权重矩阵

在什么时间向用户推荐节目是个关键问题,文献[4]和[6]在用户收看过程中产生推荐列表,这影响了用户体验. 为此,本文在用户寻找节目也就是切换频道的时刻产生推荐,这一时刻对应用户收视记录中的开始时间. 采用Kmeans++对用户 u 的所有收视记录的开始时间(只包含时分秒)聚类,获得 d 个收视时段(图3). 用户 u 的每个收视周期(一天 24 小时)由连续的收视子时段 d_{us} 组成,各时段没有交集. d_{us} 表示 u 的第 s 个收视时段.


为用户 u 定义频道-时段收视偏好矩阵 B_u , 用户 u 的每次收视行为都能从 B_u 中找到对应的偏好 b_{ucs} . b_{ucs} 表示当用户 u 的收视开始时间处于第 s 个时段时,其对频道 c 的收视偏好.

$$B_u = \begin{bmatrix} b_{u11} & \dots & b_{u1d} \\ \vdots & b_{ucs} & \vdots \\ b_{un1} & \dots & b_{und} \end{bmatrix} \quad (1)$$

为用户 u 定义预测评分权重矩阵 W_u . w_{ucs} 表示当用户 u 的收视开始时间处于第 s 个时段时,其对频道 c 的评分预测值的权重.

$$W_u = \begin{bmatrix} w_{u11} & \dots & w_{u1d} \\ \vdots & w_{ucs} & \vdots \\ w_{un1} & \dots & w_{und} \end{bmatrix} \quad (2)$$

以预推荐结果为训练样本,通过优化算法获得 B_u 和 W_u . 注意到,每组预推荐结果只能训练 B_u 和 W_u 中对应的元素,一些元素可能因无样本训练而仍为初始值,因此 B_u 和 W_u 初始值的选择十分重要,本文通过实验获得最佳初始值.

图3 用户 u 所有收视记录开始时间的聚类结果

3.2.2 预推荐

UCF 在各类推荐任务中表现稳定,且与收视偏好矩阵 B_u 实现优势互补,因而选择 UCF 作为预推荐算法. 由于协同过滤方法无法应对节目冷启动,为此,在推荐时刻 t ,利用同一视频已播部分的用户评分代替未播部分的用户评分. 采用收视时长占比法^[6]将用户的隐性反馈转化为显性反馈: $r = T/L$, r 为评分, T 表示收视时长, L 表示可收看的节目时长.

将 UCF 对用户 u 训练集中的收视行为的推荐结果(预测评分)作为 F 的训练样本. 即:

$$R_u = [r_{uft} \quad \dots \quad r_{uct} \quad \dots \quad r_{unt}]^T \quad (3)$$

3.2.3 构建评分预测函数

根据式(1)~(3),定义基于预推荐结果的预测评分 \hat{r}_{uct} 为:

$$\hat{r}_{uct} = F(r_{uct}) = r_{uct} + w_{ucs} r_{uct} + b_{ucs} \quad (4)$$

其中, $t \in d_{us}$, r_{uct} 为用户 u 在时刻 t 开始收视时,候选项 c 的预推荐评分.

将 $F(r_{uct}) = \beta r_{uft}$ 代入式(4), w_{ucs} 和 b_{ucs} 的求解转换为最优化问题(式5). r_{uft} 为用户 u 在时刻 t 的推荐列表中 TOP-1 推荐项的预测评分.

$$\arg_F \min_{u,c,t} \sum_{(u,c,t) \in K} (r_{uct} + w_{ucs} r_{uct} + b_{ucs} - \beta r_{uft})^2 \quad (5)$$

其中, K 表示所有用户的收视集合. 损失函数如下:

$$\text{loss} = \frac{1}{2} \min_{u,c,t} \sum_{(u,c,t) \in K} (r_{uct} + w_{ucs} r_{uct} + b_{ucs} - \beta r_{uft})^2 + \lambda \|w_{ucs}\|^2 + \lambda \|b_{ucs}\|^2 \quad (6)$$

在式(6)中加入正则化项 $\lambda \|w_{ucs}\|^2 + \lambda \|b_{ucs}\|^2$,

λ 为正则化系数. 采用随机梯度下降法 (Stochastic Gradient Descent, SGD) 获得参数 w_{ucs} 和 b_{ucs} . 对式 (6) 分别求 w_{ucs} 和 b_{ucs} 的偏导数, 并按式 (7) 和式 (8) 对参数进行更新, 直到满足终止条件.

$$w_{ucs} \leftarrow w_{ucs} - \alpha \frac{\partial \text{loss}}{\partial w} \quad (7)$$

$$b_{ucs} \leftarrow b_{ucs} - \alpha \frac{\partial \text{loss}}{\partial b} \quad (8)$$

其中 α 为步长. 为便于表达, 将该算法命名为 OFAP (Over the First by Adding Preference).

4 实验

4.1 数据处理与评价指标

数据源自直播电视生产系统, 包括用户收视行为数据 (用户 id、节目 id、频道 id、收视开始时间、收视结束时间) 和电子节目指南 (节目 id、频道 id、节目开始时间、节目结束时间). 整个数据集从 2017 年 5 月 17 日到 2017 年 6 月 20 日, 来自 35143 个机顶盒. 为便于实验, 随机选择 500 个账号, 每个账号至少 200 条收视记录, 生成用作实验的数据集, 并按照五折交叉法生成训练集和测试集. 按两种方案对数据集进一步处理: (1) 过滤掉训练集和测试集中所有收视时长小于 300 秒的收视行为; (2) 由于对比算法 ShowTime^[4] 需要原始数据, 为其只过滤掉测试集中收视时长小于 300s 的收视行为, 训练集不做处理. 采用 Precision@N、Recall@N 作为评价标准.

4.2 对比算法与实验设置

选择对比算法: (1) UCF (余弦相似度, 邻居数量 $k=30$) 和 LFM (隐变量 $f=120$, 迭代次数 $i=15$), 二者均属于经典方法, 在视频推荐领域有着良好的表现. 此外, UCF 作为本文预推荐算法, 将其作为对比算法便于考查 OFAP 的提升效果. (2) 选择针对直播电视特点提出的推荐算法, 包括基于张量分解的方法^[1,10] 以及表现优异的 ShowTime^[4]. (3) 采用基于 {用户, 项目, 标签} 三部图的方法 ST^[14] 来捕捉用户-频道-时段特征. 为公平比较, 基于同一数据集为 ST 产生三类标签信息: 将所有节目的播出开始时间聚类, 产生 24 个时段标签集 H_s ; 将所有节目的播出结束时间聚类, 产生 24 个时段标签集 H_e ; 频道名称标签集 T_c . 全部标签集为 $T = \{H_s, H_e, T_c\}$, 标签总数为 $24 + 24 + n$.

推荐列表的长度 N 的范围从 1 到 10, 参照三星的工业案例^[15], 尤其关注推荐列表长度 $N=5$ 处时各指标的表现. 针对 OFAP 的 SGD 求解, 设定 $\alpha = 0.05$, $\lambda = 0.05$, 迭代次数 $i=50$, 以随机和手动方式 (0 到 1) 初始化 B_u 和 W_u . 所有结论取 5 次实验结果的平均值.

由于很难穷尽 OFAP 各种参数组合, 本文首先根据

经验来设定参数, 通过少量的实验获得各参数对结果的影响. 然而, 按照参数对结果影响的大小逐一调整各参数. 最终, 得到收视时段划分数量 $p=24$, $\beta=8$, B_u 和 W_u 初始值分别为 0.8, 其中受限用户收视记录的数量, 未实验更大 p 值的情形.

4.3 算法效果对比

如图 4 所示, 随着 N 值的增加, 各算法的效果逐渐提升, 其中 OFAP 的表现明显优于其它方法. 在 Recall@1 和 Recall@5 处, OFAP 分别超过 ST、ShowTime、UCF 和 LFM 达到 6.47% 和 1.86%、15.33% 和 11.29%、16.01% 和 27.25%、42.92% 和 29.33%、573.98% 和 169.68%. ST 在对比算法中表现最好, 从侧面印证了本文以收视时段区分观众偏好思路的有效性. 由于 ShowTime 无法应对节目冷启动, 这里以用户-频道的偏好代替其用户-节目的偏好. 在缓解节目冷启动后, UCF 表现良好, 优于张量分解方法中表现最佳的 CT ($p=8$, 图 5), 特别在 $N=1$ 时, 相比 CT 提升了 23.17%. LFM 在五种算法中表现最差.




图4 算法对比




图5 Channel-Time (CT)^[1]和User-Time-Channel(UCT)^[10] (Tucker分解分别采用经验法 $p=8$ 及均值法 $p=24$, 采用Python Tensorly包及默认参数.)

4.4 OFAP 与预推荐算法的比较

OFAP 的表现相比预推荐算法 UCF 显著提升. 从两个角度分析其中原因:

(1) 邻居数量对 UCF 推荐范围的影响. 统计发现: 因邻居未看过目标视频, UCF ($k=30$) 无法推荐的情形

占总推荐任务的 32.09%。此时,式(4)中 $r_{uct} = 0$, $F(r_{uct}) = b_{ucs}$, b_{ucs} 扮演了决定性角色。而当 $k = 320$, 上述比例降至 6.03%。然而,由于较低的加权得分,这些随着邻居数量增加而被引入的节目仍难以进入推荐列表。邻居数量和质量制约了 UCF 的推荐能力。

(2) OFAP 对 UCF 推荐能力的影响。OFAP 对 UCF 的影响分正、负两方面(图 6):为了获得 w_{ucs} 和 b_{ucs} , OFAP 使 UCF 丢失了总推荐任务中 1.78% (Area3-A) 的正确项。然而,从那些由于较低加权得分而未进入 TOP-5 的项目中,OFAP 额外贡献了总推荐任务的 8.26% (B) 的正确项。通过满足个性化收视需求,OFAP 贡献了总推荐任务 8.17% (C) 的正确项。




图6 当k=30、N=5时，OFAP效果统计分析

在图 6 中,Area1 表示全部推荐任务。Area2 表示在推荐时刻,邻居看过的节目中包含目标节目的次数占全部推荐任务的比例,反映了 UCF 理想状态下的推荐能力。Area3 表示 UCF 在 Recall@5 处的推荐效果。Area4 表示超出 UCF 推荐能力的个性化的推荐任务。A, B, C 分别代表 OFAP 在各区域内完成的推荐任务占总任务的比例。

4.5 OFAP 的扩展性

为避免与本文所提频道-时间关联性策略重叠,将对比算法中唯一未考虑时间因素的 LFM 作为预推荐算法,以测试 OFAP 的扩展性。结果表明,OFAP 相比原始 LFM 在 Recall@1 和 Recall@5 处,分别提升了 180% 和 36.22%。

5 结论

针对直播电视的特点,本文提出了一种直播电视推荐系统的评分预测算法。它融合了推荐节目和推荐频道两类方法的优点,即缓解了直播电视节目冷启动问题,又保证了推荐效果。在工业数据集上的实验表明,该方法的推荐效果相比各参照算法均有明显提升。此外,本文提出的评分替代策略使得协同过滤算法能够应用于冷启动下直播电视推荐任务。文中所提出的将预推荐结果作为训练样本来改善推荐结果的思路也适用于其它推荐任务,未来将围绕这两项创新点进行扩展研究。

参考文献

[1] Cremonesi P, Modica P, Pagano R, et al. Personalized and

context-aware TV program recommendations based on implicit feedback[A]. Proceedings of 16th International Conference on Electronic Commerce and Web Technologies [C]. Valencia, Spain; Springer, 2015. 57 - 68.

[2] Wang Z, He L. User identification for enhancing IP-TV recommendation[J]. Knowledge-Based Systems, 2016, 98: 68 - 75.

[3] Turrin R, Condorelli A, Cremonesi P, et al. Time-based TV programs prediction[A]. First Workshop on Recommender Systems for Television and Online Video at ACM RecSys'14[C]. Silicon Valley, California, USA; ACM, 2014.

[4] Oh J, Kim S, Kim J, et al. When to recommend: A new issue on TV show recommendation [J]. Information Sciences, 2014, 280: 261 - 274.

[5] Jin Y, Junhua G, Suqi Z, et al. Spark-based distributed multi-features hybrid IPTV viewing implicit feedback scoring model[J]. Procedia Computer Science, 2017, 111: 441 - 447.

[6] Cho K J, Lee Y C, Han K, et al. No, that's not my feedback: TV show recommendation using watchable interval[A]. Proceedings of IEEE 35th International Conference on Data Engineering[C]. Macau, China; IEEE, 2019. 316 - 327.

[7] Park Y, Oh J, Yu H. Rectime: Real-time recommender system for online broadcasting [J]. Information Sciences, 2017, 409: 1 - 16.

[8] Chang N, Irvan M, Terano T. A TV program recommender framework[J]. Procedia Computer Science, 2013, 22: 561 - 570.

[9] Bambini R, Cremonesi P, Turrin R. Recommender Systems Handbook[M]. Berlin; Springer, 2011.

[10] Karatzoglou A, Amatriain X, Baltrunas L, et al. Multiverse recommendation: n-dimensional tensor factorization for context-aware collaborative filtering [A]. Proceedings of the 4th ACM Conference on Recommender Systems[C]. Barcelona, Spain; ACM, 2010. 79 - 86.

[11] Yu C, Ding H, Cao H, et al. Follow me: personalized IPTV channel switching guide[A]. Proceedings of the 8th ACM on Multimedia Systems Conference[C]. Taipei, Taiwan, China; ACM, 2017. 147 - 157.

[12] Hu Y, Koren Y, Volinsky C. Collaborative filtering for implicit feedback datasets[A]. Proceedings of the 8th IEEE International Conference on Data Mining [C]. Pisa, Italy: IEEE, 2008. 263 - 272.

[13] Xin Y, Steck H. Multi-value probabilistic matrix factorization for IP-TV recommendations [A]. Proceedings of the 5th ACM Conference on Recommender Systems[C]. Chicago, Illinois, USA; ACM, 2011. 221 - 228.

[14] Zhang Z K, Liu C, Zhang Y C, et al. Solving the cold-start problem in recommender systems with social tags[J]. Eu-


rophysics Letters, 2010, 92(2): 28002 – 28007.

- [15] Zhang R, Deng Y, Shi L. User research and design for live TV UX in China[A]. Proceedings of Adjunct Publication of the 2017 ACM International Conference on Interactive Experiences for TV and Online Video[C]. New York, NY, USA: ACM, 2017. 9 – 14.

作者简介



郭景峰 男, 1962 年 2 月出生于黑龙江哈尔滨. 现为燕山大学信息科学与工程学院教授、博士生导师. 在国内外发表学术论文 130 余篇.
E-mail: jfguo@ysu.edu.cn



朱晓松(通信作者) 男, 1982 年 11 月出生于河北唐山. 现为燕山大学信息科学与工程学院博士生, 从事推荐系统、机器学习方面的研究工作.

E-mail: xiaosongzhu@ysu.edu.cn



李爽 女, 1982 年 7 月出生于河北唐山. 现为河北环境工程学院副教授, 天津大学建筑学院博士生, 主要研究方向为数字景观、机器学习.

E-mail: 89732212@qq.com