

基于双图混合随机游走的社会化推荐模型

曹 阳^{1,2}, 高 旻^{1,2}, 余俊良³, 范琪琳^{1,2}, 荣文戈⁴, 文俊浩^{1,2}

(1. 信息物理社会可信服务计算教育部重点实验室(重庆大学), 重庆 400044; 2. 重庆大学大数据与软件学院, 重庆 400044;
3. 昆士兰大学信息技术与电气工程学院, 澳大利亚昆士兰州 4072; 4. 北京航空航天大学计算机学院, 北京 10019)

摘要: 近年来,可以有效缓解数据稀疏和冷启动问题的社会化推荐受到了研究者和业界的关注. 社会化推荐利用显式或隐式社交关系作为辅助信息,提升了推荐性能. 然而,目前的社会化推荐模型通常采用普通图描述社交关系. 普通图中的边常描述为成对节点的关系,这种方法适合描述显式关系,但难以描述复杂的隐式关系,如购买过同一商品的多个用户之间的集合关系,因此难以学习到准确的节点表示,影响推荐的性能. 针对此问题,本文结合超图和普通图,提出基于双图混合随机游走的推荐(BG-Rec)模型. 构建超图描述复杂的隐式关系,同时用普通图描述显式的社交关系,并在两种图上定义混合随机游走策略,生成结合隐式关系和显式关系的游走节点序列,学习更准确的节点嵌入表示. 根据用户评分的高低,构建了正反馈超图和负反馈超图,考虑更细粒度的朋友关系,以识别可靠的朋友. 融合可靠朋友的偏好和后验概率最大化优化物品个性化排序. 三个公开数据集的大量实验表明了BG-Rec在推荐性能上的优越性,冷启动和消融实验表明了其在缓解冷启动问题的有效性和超图建模的合理性.

关键词: 推荐系统; 社交关系; 随机游走; 超图; 个性化排序

基金项目: 国家自然科学基金(No.62176028); 重庆市自然科学基金面上项目(No.cstc2020jcyj-msxmX0690); 中央高校基本科研业务费项目(No.2020CDJ-LHZZ-039); 重庆市留学人员创业创新支持计划(No.cx2020097); 重庆市技术创新与应用示范专项产业类重点研发项目(No.cstc2019jsx-mbdxX0008); 重庆市技术创新与应用发展专项(No.cstc2019jsx-zdztzxX0031)

中图分类号: TP311

文献标识码: A

文章编号: 0372-2112(2023)02-0286-11

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20210504

Bi-Graph Mix-random Walk Based Social Recommendation Model

CAO Yang^{1,2}, GAO Min^{1,2}, YU Jun-liang³, FAN Qi-lin^{1,2}, RONG Wen-ge⁴, WEN Jun-hao^{1,2}

(1. Key Laboratory of Dependable Service Computing in Cyber Physical Society (Chongqing University),

Ministry of Education, Chongqing 400044, China;

2. School of Big Data & Software Engineering, Chongqing University, Chongqing 400044, China;

3. School of Information Technology and Electrical Engineering, University of Queensland, QLD 4072, AUS;

4. School of Computer Science and Engineering, Beihang University, Beijing 100191, China)

Abstract: In recent years, social recommendation approaches have attracted attention because they can effectively improve the recommendation quality when user-item interaction data is sparse. Explicit and implicit social relations, as auxiliary information, are used to improve the recommendation quality. However, social relations are represented by simple graphs in existing models. The nature of edges connecting pair-wise nodes in simple graphs makes it suitable for describing explicit relations. Still, it is incapable of modeling complex implicit relations, such as the collective relation between multiple users who have purchased the same product. Therefore, it isn't easy to learn the node representation accurately, only based on simple graphs, which even affects the recommender's performance. In this paper, we propose a recommendation model based on a bi-graph hybrid random walk (BG-Rec) to overcome this problem, which combines hypergraph and graph. We construct a hypergraph and a simple graph to depict complex implicit relations and explicit social relations separately. Next, the mixed random walk strategy (MixRandom) is used to generate node sequences that combine implicit and explicit relations. Furthermore, node sequences are used for learning more accurate representations of nodes. Then, positive feedback hypergraph and negative feedback hypergraph are constructed based on user ratings, so that more fine-grained friend relations can be considered to identify reliable friends. Finally, the personalized ranking of items is optimized by considering the preferences of reliable friends and the maximization of the posterior probability. Experiments on three public

datasets show the superiority of BG-Rec in recommendation performance. The cold-start study and ablation study validates the effectiveness of alleviating the cold-start problem and rationality of hypergraph modeling.

Key words: recommendation systems; social relations; random walk; hypergraph; personalized ranking

Foundation Item(s): National Natural Science Foundation of China (No.62176028); Natural Science Foundation of Chongqing, China (No.cstc2020jcyj-msxmX0690); Fundamental Research Funds for the Central Universities of Chongqing University (No.2020CDJ-LHZZ-039); Overseas Returnees Innovation and Entrepreneurship Support Program of Chongqing (No. cx2020097); Technological Innovation and Application Program of Chongqing (No. cstc2019jscx-mbdxX0008); Research Program of Chongqing Technology Innovation and Application Development (No.cstc2019jscx-zdztzxX0031)

1 引言

推荐系统根据用户历史交互记录推断其偏好并推荐其感兴趣的信息,能有效地缓解信息过载问题,已被广泛应用于日常生活中^[1,2],如音乐推荐^[3]和直播推荐^[4]等.然而,大多数用户只与少量产品产生过交互,这种数据稀疏的问题使推荐性能受到严重影响.由于用户的偏好会受到朋友喜好的影响^[5,6],引入社交关系的社会化推荐^[7]可以缓解该问题.

社交关系通常指社交平台上用户间的关系.这些关系体现为直接连边,被称为显式关系.已有研究^[8,9]表明,显式关系作为辅助信息能缓解交互数据稀疏的问题.SBPR(Social Bayesian Personalized Ranking)^[8]直接利用显式关系优化物品排序,STE(Recommendation with Social Trust Ensemble)^[9]通过显式关系把用户偏好优化为自身偏好和朋友偏好的线性组合.但推荐系统中的显式关系也很稀疏,推荐性能有待进一步提升.

随后,有研究者^[10-12]融合显式和隐式关系进行推荐.不同于节点间直接连边的显式关系,隐式关系有多种定义.如有相似偏好的用户关系及购买同一物品的多个用户通过该物品可以间接连接.隐式关系可以从稀疏数据中挖掘更多关键的信息.一些基于异构网络的推荐模型^[10-12]同时利用显式和隐式关系,进一步提升了推荐性能.例如,IF-BPR(BPR with Implicit Friends)^[12]设计了“用户-物品-用户”(隐式关系)、“用户-用户-用户”(显式关系)等元路径,用于指导随机游走,从而识别更可靠的隐式朋友关系.MoHINRec(Motif Enhanced Recommendation over Heterogeneous Information Network)^[11]基于 motif 结构的元路径指导随机游走,捕获异构网络中的高阶信息,得到更准确的节点嵌入.这些模型同时利用了显式和隐式关系,较好地学习到节点的表征,有效提升了推荐的性能.

现存模型中显式和隐式关系都采用普通图描述,虽然普通图中一条边连接两个顶点的结构适合描述显式关系,但难以描述与同一物品产生交互的多个用户间的隐式关系(多用户间存在的多元关系).因此普通图描述隐式关系难以充分提升推荐的性能.而超图中的超边可以包含任意个顶点,是一个超点集合.与同一物品产生交互的多个用户以集合(超边)的形式出现,可以解决

普通图难以描述用户间多元关系的问题^[13,14].

本研究将合理利用显式关系和隐式关系为用户找偏好相似的隐式朋友,缓解数据稀疏性,然后借助这种朋友关系辅助训练模型,提升推荐性能且缓解冷启动问题.需要应对如下挑战:(1)如何合理结合显式关系和隐式关系找到隐式朋友;(2)如何借助隐式朋友训练模型.

针对挑战(1),提出基于双图混合随机游走的推荐 BG-Rec (Bi-Graph Mix-random Walk Based Recommender)模型.模型用普通图和超图分别描述显式关系和隐式关系,然后基于 MixRandom 游走策略捕获用户间偏好关系,找到隐式朋友.为识别可靠的隐式朋友^[12],对朋友关系进行更细粒度的划分.分别用正反馈超图和负反馈超图识别两个维度的隐式朋友(与用户正/负偏好相似的为正/负面朋友,两者的交集为最佳朋友).针对挑战(2),融合正/负面朋友、最佳朋友的偏好对项目进行优先级划分,并根据优先级和后验概率最大化实现项目排序.本文主要贡献如下:

(1)提出双图混合随机游走的用户嵌入学习方法.不同于传统方法在普通图上的嵌入学习,本方法采用超图和普通图分别描述推荐系统中用户的隐式关系和显式关系,提出了在两种图上的混合随机游走策略,以得到更准确的用户表征.

(2)提出基于双图随机游走的细粒度社会化推荐(BG-Rec)模型,依据用户不同性质的评价构建正、负反馈超图,与普通图结合学习代表用户喜好、厌恶的嵌入,并划分细粒度隐式朋友提升推荐性能.

(3)在三个公开数据集上进行了大量实验,通过整体推荐性能对比表明 BG-Rec 模型的有效性,并分析了双图随机游走与单图随机游走的嵌入学习、细粒度社交关系对社会化推荐性能的提升作用.

2 相关工作

社会化推荐中的社交关系分为显式和隐式关系.显式关系表示在社交网络中有直接连边的用户关系;隐式关系是历史偏好相似的用户之间的非显式联系(例如,根据历史交互记录,用户间存在的兴趣偏好相似关系),不受社交网络上的距离限制.

在社会化推荐发展的早期,研究主要探索利用显式关系提升推荐性能.由于整合先验知识的灵活性,基

于矩阵分解的社会化推荐成为流行的模型,如协同矩阵分解方法^[15]、集合方法^[9]等. 这些研究中,SoRec(Social Recommendation Using Probabilistic Matrix Factorization)^[15]和 TrustMF (Social Collaborative Filtering by Trust)^[16]通过共享隐特征把用户的社交信息和评分信息联系起来,同时分解社交关系矩阵和评分矩阵. Ma 等人^[9]提出了基于信任集合的模型 STE,认为用户的基本偏好是其自身的显式偏好和其朋友偏好的线性组合. Chen 等人^[17]注意到用户对项目的曝光对推荐有很大影响,使用社交连接帮助捕获用户对项目的曝光. 各种协同过滤模型也被用在社会化推荐中. 例如 Zhao 等人^[8]将社交关系融入贝叶斯个性化排序 (Bayesian Personalized Ranking, BPR), 认为朋友买过物品的排序优先于没被用户买过的物品.

随后,有研究者发现直接利用显式关系可能会降低推荐性能^[19],因此把注意力转移到如何挖掘更可靠的显式关系. Wang 等人^[20]通过为每个用户学习独立的个性化相似度阈值来区分亲密朋友和普通朋友. 此外,还有工作^[21]提出了基于用户交互行为衡量用户间信任的度量标准,从而找到可靠朋友.

近年来的研究与以上在显式关系中筛选可靠关系不同,研究者开始识别隐式关系. IF-BPR^[12]在异构网络上设计基于元路径的图嵌入方法,识别可靠的隐式社交关系. 深度学习也被引入到一些工作中^[22-25]. 其中, RSGAN (Reliable Social recommendation system based on Generative Adversarial Networks)^[24]利用生成对抗网络识别可信隐式社交关系, ESRF (Enhanced Social Recommendation Framework)^[25]利用图神经网络和生成对抗获得更高质量的用户/物品特征表示,从而找到更可靠的隐式朋友. 它们利用显式和隐式关系时,采用普通

图描述关系. 图中一条边连接两个成对顶点,难以描述与同一个物品都产生过交互的多个用户之间的隐式关系.

这些模型提升了社会化推荐性能,但还存在一些问题:(1)很多模型未同时利用显式关系和隐式关系;(2)普通图的结构特点不适合描述隐式关系,这导致利用普通图描述隐式关系的模型性能难以提升. 针对这些问题,本文采用超图描述用户的隐式关系,并基于超图和普通图提出 BG-Rec 模型.

3 BG-Rec 模型

本文提出的 BG-Rec 模型包含 3 个部分即图的构建、随机游走、排序算法,如图 1 所示. 图 1 描述了模型利用稀疏的用户-物品交互数据、用户社交关系,挖掘隐式朋友的过程. 隐式朋友关系缓解了数据稀疏的问题. 加入隐式关系优化训练贝叶斯个性化排序模型,可以提升推荐性能且缓解冷启动问题.

其中,图的构建如图 1(a)所示,首先根据用户的社交关系构建社交网络图. 之后把用户的交互记录区分为正反馈(高评分)和负反馈(低评分),分别构建正反馈超图和负反馈超图. 正/负反馈超图可以描述多用户在喜好/厌恶方面的共同偏好关系.

随机游走过程如图 1(b)所示. 根据 MixRandom 游走策略在超图和普通图上进行混合随机游走采样表示用户关系序列库 C_p 与 C_n .

排序推荐如图 1(c)所示. 利用 Skip-gram 模型学习 C_p 与 C_n 获得用户表示. 经过用户表示的相似度计算为每个用户找到正面朋友和负面朋友,分别反映在喜好、厌恶上的相似度. 取两者交集作为最佳朋友^[12]. 最后通过融入正面朋友、负面朋友和最佳朋友的贝叶斯个性化排序模型进行推荐. 下面对相关内容进行详细介绍.

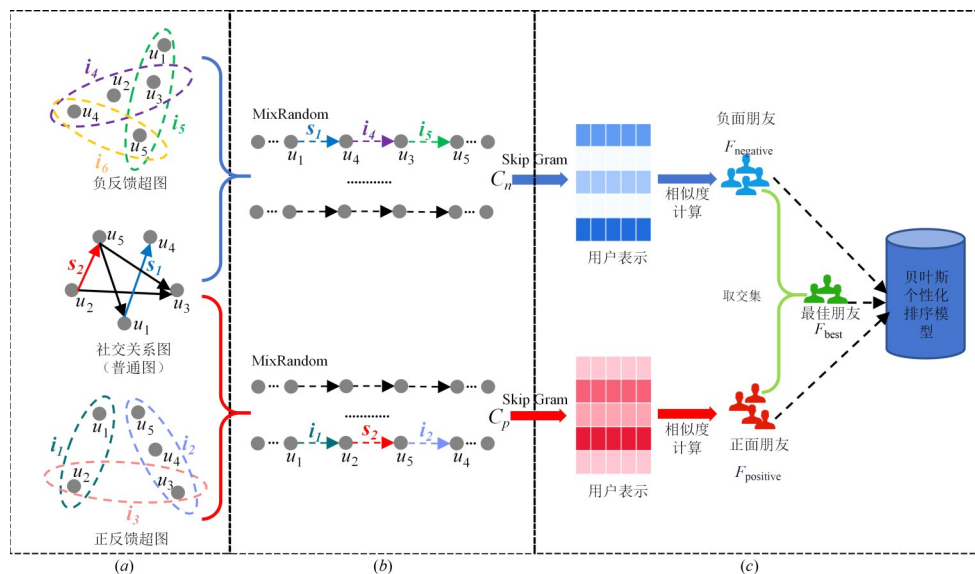


图 1 模型整体框架图

3.1 基本符号和定义

给定用户集合 $U = \{u_1, u_2, \dots, u_N\}$, N 为用户总数; 物品集合 $I = \{i_1, i_2, \dots, i_M\}$, M 为物品总数.

超图的每条边包含两个以上的点, 是普通图的泛化. 其中, 顶点被称为超点, 边被称为超边. 一条超边可以包含的超点数量大于或等于 2, 是一条包含该超边中所有超点的简单闭合曲线. 超点与普通图里的点一样. 形式化定义如下:

$G_H = (V, E, \omega, \gamma)$ 表示一个超图, 其中 $V = \{v_1, v_2, \dots, v_N\}$ 代表超点集合, N 是超点总数, $E = \{e_1, e_2, \dots, e_M\}$ 是超边集合, M 是超边总数. 一条超边 $e (e \in E)$ 可以包含 $n (n \in [2, N])$ 个超点 $v (v \in V)$. 超图可以用邻接矩阵 $H^{N \times M}$ 来表示, 其元素 $h(v, e)$ 如式(3)所示. 若 e 包含 v , 则 $v \in e$. 超边权重为 $\omega(e)$, 超点权重为 $\gamma_e(v)$. 若 $h(v, e) = 0$, 则 $\gamma_e(v) = 0$.

超点的度 $d(v)$ 等于包含超点 v 的所有超边的权重之和, 超边的度 $\delta(e)$ 等于超边 e 中所有超点的权重之和即

$$d(v) = \sum_{e \in E} h(v, e) \omega(e) \quad (1)$$

$$\delta(e) = \sum_{v \in V} h(v, e) \gamma_e(v) \quad (2)$$

其中,
$$h(v, e) = \begin{cases} 1, & v \in e \\ 0, & v \notin e \end{cases} \quad (3)$$

3.2 BG-Rec 模型中超图的构建

BG-Rec 模型借助超图 G_H 表达用户之间的复杂隐式关系: 根据用户-物品评分矩阵 $R^{N \times M}$ 构建 G_H , 将用户 u 作为超点、物品 i 作为超边^[21, 22], 并根据社会化推荐的场景设计超点和超边的权重计算方法. 其中, 用户 $V = \{u_1, u_2, \dots, u_N\}$. 物品 $E = \{i_1, i_2, \dots, i_M\}$. 超边中包含所有与该物品产生过交互的用户. 超图具体构建过程如图 2 所示, 包含正反馈超图和负反馈超图的构建过程. 区分正反馈和负反馈的原因见 3.3.3 小节. 以正反馈超图的构建为例, 图 2(a) 表明物品 i_1 与用户 u_1 和 u_2 产生过正反馈交互(高评分), 对应图 2(b) 中超边 i_1 包含超点 u_1 与 u_2 . 同理, 利用负反馈交互(低评分)构建负反馈超图. G_H 的一条超边 $i \in E$ 可以包含大于等于 2 的用户数量, 使得超图具备描述多元关系的能力.

受 Chitra 等人^[26]工作的启发, 同一超点在不同的超边中具有不同的权重. 例如, 在超图 2(b) 中, 超点 u_2 在超边 i_1 和 i_3 中有不同权重 $\gamma_{i_1}(u_2)$ 和 $\gamma_{i_3}(u_2)$.

设置超边 i 的权重 $\omega(i) = 1/|i|$. 其中 $|i|$ 是超边 i 中包含的超点(用户)数量. $|i|$ 越大, 表明 i 代表的物品越流行. 两个用户对同一个流行物品产生过交互, 可能只是因为该物品比较流行; 但两个用户对同一个非流行物品产生交互, 大概率是因为他们有相似的偏好, 他们更

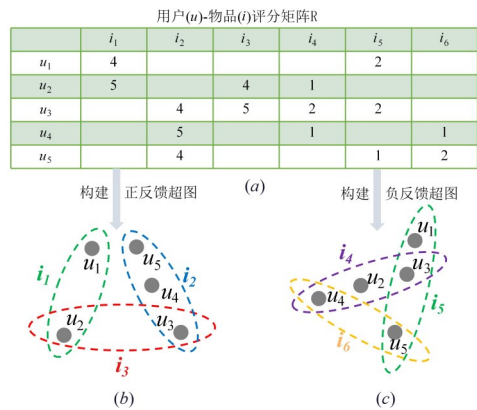


图 2 超图构建过程图

可能是潜在的隐式朋友. 这使得隐式朋友对更频繁地共现在游走序列中.

设置超点 u 在超边 i 中的权重 $\gamma_i(u) = R_{u,i}$. 矩阵 $R^{N \times M}$ 是用户和物品的交互矩阵, 元素 $R_{u,i}$ 代表用户 u 对物品 i 的评分. 评分值可以反映用户对物品的偏好, 对同一个物品评高分的两个用户有相似的偏好, 这样的一对用户是潜在的隐式朋友. 这使得隐式朋友对在游走序列中的共现频率更高.

3.3 MixRandom 游走策略

MixRandom 游走策略包含三个部分: 超图随机游走、普通图随机游走和混合随机游走. 分别在 3.3.1~3.3.3 小节展开介绍.

3.3.1 超图上的随机游走

在超图 G_H 中定义了随机游走策略, 实现从一个用户节点转移到下一个用户节点, 即从时间点 t , 由一个超点 u_t 转移到下一个超点 u_{t+1} 的过程, 该策略将使偏好相似的用户在游走序列中的共现频率更高. 决策过程分解为如下步骤:

Step1 从包含超点 u_t 的超边集合 $E(u_t)$ 中以概率 $\omega(i)/d(u_t)$ 选中超边 i .

Step2 从超边 i 包含的超点集合 $V(i)$ 中以概率 $\gamma_i(u_{t+1})/\delta(i)$ 选中超点 u_{t+1} .

以超图 2(b) 中 u_2 到 u_1 的概率转移过程为例: (1) 从包含 u_2 的超边集合 $E(u_2) = \{i_1, i_3\}$ 中以概率 $\omega(i_1)/d(u_2)$ 选中超边 i_1 ; (2) 从超边 i_1 包含的超点集合 $V(i_1) = \{u_1, u_2\}$ 中以概率 $\gamma_{i_1}(u_1)/\delta(i_1)$ 选中 u_1 .

超点 u_2 转移到超点 u_1 的概率:

$$P_{u_2, u_1} = \sum_{i \in E(u_2)} \left(\frac{\omega(i)}{d(u_2)} \right) \left(\frac{\gamma_i(u_1)}{\delta(i)} \right) \quad (4)$$

根据以上步骤使用概率转移矩阵 $P^{N \times N}$ 来模拟超点与超点之间的转移过程.

$$P = WR \quad (5)$$

而超点之间的转移过程可以分解为根据超点选超边、根据超边选超点两个过程,分别用矩阵 $W^{N \times M}$ 和矩阵 $R^{M \times N}$ 来模拟即

$$W_{u,i} = \omega(i)/d(u_i) \quad (6)$$

$$R_{i,u_{t+1}} = \gamma_i(u_{t+1})/\delta(i) \quad (7)$$

3.3.2 普通图上的随机游走

图3中的社交网络图描述了用户间的显式关系. 顶点代表用户,有向边代表用户间的信任关系.

不同朋友间的关系紧密程度是不同的,有更多共同朋友的用户间的关系更亲密. 因此,让用户间的有向边的权重与两个用户共同信任的朋友数量正相关. 在社交网络图中,顶点 u_1 指向顶点 u_2 的有向边的权重 ϖ_{u_1,u_2} 如式(8)所示. 在随机游走过程中,顶点间的转移过程由概率转移矩阵 $Q^{N \times N}$ 表示,顶点 u_1 跳转到顶点 u_2 的概率 Q_{u_1,u_2} 如式(9)所示,其中 $S(u)$ 代表用户 u 信任的用户集合,例如: $S(u_1) = \{u_2, u_3, u_5\}$, $S(u_2) = \{u_3, u_4, u_5\}$.

$$\varpi_{u_1,u_2} = |S(u_1) \cap S(u_2)| + 1 \quad (8)$$

$$Q_{u_1,u_2} = \frac{\varpi_{u_1,u_2}}{\sum_{v \in S(u_1)} \varpi_{u_1,v}} \quad (9)$$




图3 显式社交网络图

3.3.3 双图混合随机游走 MixRandom

为了同时利用显式和隐式关系, MixRandom 策略将结合超图和普通图进行随机游走. 从当前节点转移至下一个节点前需要引入概率参数 $\alpha (0 < \alpha < 1)$ 控制此次转移过程在超图或普通图上进行. 游走过程如下所示:

Step1 当前顶点 u_t 以概率 α 选择下一步在超图上进行游走, 跳转至 Step2; 以 $(1-\alpha)$ 的概率在普通图上进行游走, 跳转至 Step3.

Step2 以概率 $P_{u_t,u_{t+1}}$ 转移到下一个顶点 u_{t+1} , 跳转至 Step1.

Step3 以概率 $Q_{u_t,u_{t+1}}$ 转移到下一个顶点 u_{t+1} , 跳转至 Step1.

具体地, 在图1(a)中结合正反馈超图和社交关系图(普通图)进行混合随机游走, 并获得顶点序列 $\{u_1, u_2, u_5, u_4\}$: (1) 以概率 α 选择在超图上随机游走, 根

据超图游走策略从节点 u_1 通过超边 i_1 转移到节点 u_2 ; (2) 以概率 $(1-\alpha)$ 选择在普通图上进行随机游走, 并根据普通图随机游走策略, 节点 u_2 通过边 S_2 转移到节点 u_5 ; (3) 以概率 α 选择在超图上进行随机游走, 并根据超图随机游走策略从节点 u_5 通过超边 i_2 转移到节点 u_4 .

推荐系统通常把用户交互行为当做正反馈, 而忽略了负反馈的存在, 但负反馈有丰富的信息值得挖掘^[27]. 例如, 用户对一件物品评价低分体现了其对物品的负面情绪, 而推荐系统常常会错误地把此当做正反馈. 两个偏好相近的朋友不仅仅是在正反馈上相似, 在负反馈上也应该相似. 基于随机游走的图嵌入学习^[21]通常根据节点在上下文窗口中的共现来学习节点的代表. 为了区分正反馈和负反馈, 分别在正反馈构建的超图和普通图以及负反馈构建的超图和普通图上进行混合随机游走, 分别获得由顶点序列组成的序列库 C_p 和 C_n . 序列库将被用于学习用户表示向量.

3.4 排序算法

本文根据文献[12]所提方法, 首先识别隐式朋友, 利用 Skip-gram 模型学习正/负反馈序列库, 得到两组用户表示向量, 根据用户向量相似度计算识别出三种类型的隐式朋友, 然后利用隐式朋友优化用户偏好中的物品优先级, 进行贝叶斯个性化排序推荐.

3.4.1 隐式朋友识别

隐式朋友通过用户节点相似性计算获得, 需要先基于 Skip-gram 模型^[28]学习序列库, 并结合负采样提升计算效率^[29], 得到由所有用户表示向量组成的矩阵 $Z^{N \times d}$. 前文得到的正反馈序列库和负反馈序列库分别描述了用户的积极偏好和消极偏好. 通过两个序列库为每个用户学习两个表示向量, 基于此, 在两两用户进行两种余弦相似度的计算, 从而为每个用户识别出最相似的前 K 个正面朋友 $F_{\text{pos}}(u)$ 和前 K 个负面朋友 $F_{\text{neg}}(u)$. 正面朋友和当前用户喜欢相似的物品, 而负面朋友和当前用户讨厌相似的物品.

3.4.2 排序推荐

首先根据用户 u 的最佳朋友 $F_{\text{best}}(u)$ 、正面朋友 $F_{\text{pos}}(u)$ 和负面朋友 $F_{\text{neg}}(u)$ 的偏好对物品分类:

- (1) I_u 为用户 u 给予正反馈的物品;
- (2) $I_{u,b}$ 为 $F_{\text{best}}(u)$ 给予正反馈的物品;
- (3) $I_{u,p}$ 为 $F_{\text{posit}}(u)$ 给予正反馈的物品;
- (4) $I_{u,n}$ 为用户 u 或 $F_{\text{neg}}(u)$ 给予负反馈的物品;
- (5) $I_{u,\text{non}}$ 为不属于 $I_u, I_{u,b}, I_{u,p}, I_{u,n}$ 的物品;

以上五类物品集合互不相交. 模型目标是为每个用户 u 学习一个物品排序函数, 把所有物品按照以下顺序排序, 这些顺序被称为用户 u 的偏序关系:

$$I_u \geq I_{u,b} \geq I_{u,p} \geq I_{u,\text{non}} \geq I_{u,n}$$

设模型参数 $\Theta \equiv (X, Y)$, 其中 X 和 Y 分别是用户向量矩阵和物品向量矩阵. 根据以上排序学习规则, 最大化

后验概率:

$$P(\Theta|>_u) = \prod_{u \in U} \left(\prod_{i \in I_{u,p}, j \in I_{u,b}} p(i \geq j | \Theta) \prod_{j \in I_{u,b}, m \in I_{u,p}} p(j \geq m | \Theta) \prod_{m \in I_{u,p}, n \in I_{u,non}} p(m \geq n | \Theta) \prod_{n \in I_{u,non}, k \in I_{u,n}} p(n \geq k | \Theta) \right) \quad (10)$$

其中 $p(i \geq j | \Theta)$ 由 $\sigma(X_u^T Y_i - X_u^T Y_j)$ 定义, 为了防止过拟合, 加入正则化项 $\frac{\lambda_{\Theta}}{2} (\|X\|_F^2 + \|Y\|_F^2)$, 通过对后验概率取负对数得到损失函数:

$$\begin{aligned} \text{Loss} = & - \sum_{u \in U} \left(\sum_{i \in I_{u,p}, j \in I_{u,b}} \ln \left(\sigma \left(X_u^T Y_i - X_u^T Y_j \right) \right) \right. \\ & + \sum_{j \in I_{u,b}, m \in I_{u,p}} \ln \left(\sigma \left(X_u^T Y_j - X_u^T Y_m \right) \right) \\ & + \sum_{m \in I_{u,p}, n \in I_{u,non}} \ln \left(\sigma \left(X_u^T Y_m - X_u^T Y_n \right) \right) \\ & \left. + \sum_{n \in I_{u,non}, k \in I_{u,n}} \ln \left(\sigma \left(X_u^T Y_n - X_u^T Y_k \right) \right) \right) \\ & + \frac{\lambda_{\Theta}}{2} (\|X\|_F^2 + \|Y\|_F^2) \end{aligned} \quad (11)$$

通过训练优化模型参数, 模型将利用学习到的参数计算用户商品偏好并进行排序。

3.4.3 动态调整隐式朋友

对每个用户, 能影响其偏好的朋友数量不一样, 为每个用户都选 Top K 个正面和负面朋友会降低模型的性能^[12]. 因此需要根据训练集上的表现动态调整隐式朋友数量 K . 具体地, 参数 th_u 作为相似度阈值, 把与用户 u 相似度大于 th_u 的用户纳入 u 的正、负面朋友范围。

一个隐式朋友 f 对于用户 u 的重要程度由参数 β 表示, $\beta = \sigma \left(\frac{s_{u,f} - \text{th}_u}{\bar{s}_u - \text{th}_u} \right)$. 其中 $s_{u,f}$ 是用户 u 与正面朋友 f 的相似度, \bar{s}_u 是用户集 F 的所有用户与 u 相似度的平均值, F 由 $F_{\text{pos}}(u)$ 中与 u 相似度大于 th_u 的用户组成。

在式(11)中 $p(i \geq j | \Theta) = \sigma(X_u^T Y_i - X_u^T Y_j)$ 中加入系数 $1/(\beta + 1)$, 得到 $\sigma \left(\frac{X_u^T Y_i - X_u^T Y_j}{\beta + 1} \right)$, 实现 th_u 根据模型在训练集的表现动态变化. 其中 $\sigma(X_u^T Y_i - X_u^T Y_j)$ 使模型学习到相对于最佳朋友偏好的物品 j , 用户更偏好自己好评的物品 i . 重要朋友对应更大的 β , 更小的 $1/(\beta + 1)$, 这样可以减小用户与重要朋友之间的偏好差异. 最后加入 $\frac{\lambda_{th}}{2} \sum_u \|\text{th}_u\|^2$ 正则化项, 得到最终的损失函数。

4 实验结果及分析

本节在三个数据集进行实验以分析如下问题: (1) 验证动态调整朋友数量 K 的有效性; (2) BG-Rec 在推荐性能上的优越性; (3) BG-Rec 能有效缓解冷启动问

题; (4) MixRandom 游走策略的设计是合理的; (5) 超参数对 BG-Rec 性能的影响。

4.1 数据集

在实验中采用了三个含社交信息的数据集: LastFM, Douban, Epinions. LastFM 是音乐数据集, 把其中只被用户听过一次的歌曲当做负反馈数据, 其余的当作正反馈数据. Douban 是影评数据集, Epinions 是电商数据集. Douban 和 Epinions 中用户的评分范围是 1~5, 其中 1 分和 2 分作为负反馈数据, 4 分和 5 分作为正反馈数据. 数据集的具体统计数据如表 1 所示. 三个数据集 80% 的数据用于模型训练, 剩余的 20% 的数据用于模型测试. 为避免过拟合和保证实验结果的准确性, 本文在每个数据集进行十次五折交叉验证, 然后取平均值作为最终的实验结果。

表 1 数据集统计表

Dataset	Users	Items	Feedbacks	Density	Relations
LastFM	1 892	17 632	92 834	0.28%	25 434
Douban	2 831	22 129	606 467	0.97%	35 624
Epinions	15 064	23 575	356 959	0.10%	285 659

4.2 对比方法与评价指标

为了说明所提推荐方法的优越性, 本文选择 2 个经典推荐算法、2 个最新的社会化推荐算法、2 个基于深度学习的推荐算法作为对比算法。

(1) BPR: 一种经典的贝叶斯个性化排序推荐算法^[18]. 其认为和用户产生过交互的物品比其他物品排序更靠前。

(2) SBPR: 一种融入显式关系的贝叶斯个性化排序推荐算法^[8]. 相比没见过的物品, 用户会更偏好朋友(显式关系)消费过的物品。

(3) IF-BPR: 一种基于显式关系和隐式关系的社会化推荐算法^[12]. 基于元路径的随机游走识别隐式朋友, 从而提升推荐效果。

(4) RSGAN: 一种基于生成式对抗网络的社会推荐方法^[24]. 依靠元路径引导的随机游走获得种子朋友。

(5) LightGCN (Simplifying and Powering Graph Convolution Network for Recommendation): 一种基于图卷积的推荐算法^[30]. 其利用了更适合协同过滤的简单图卷积结构, 获得优异的推荐效果。

(6) SGL (Self-supervised Graph Learning for Recommendation): 一种基于图自监督学习的推荐算法^[31]. 其利用自监督学习提升推荐性能, 增强模型对噪声的鲁棒性。

评价指标: 三个基于相关性的评价指标即 Precision (Prec), Recall (Rec), F1; 两个基于排序的指标即 MAP, NDCG.

4.3 总体推荐性能对比

不同方法的推荐结果如表 2 所示, 其中 BG-Rec 在

数据集 LastFM 和 Douban 上的超参数 $\alpha=0.5$, 在数据集 Epinions 上超参数 $\alpha=0.1$, 通过观察可以得出以下结论:

(1) 针对表 2 中三个数据集的所有评价指标, 模型 BG-Rec 的表现明显高于其他对比方法. BG-Rec 的推荐结果相对次优算法的结果提升为 2.84%~5.49%.

表 2 BG-Rec 和其他算法的性能比较

Dataset	Metric	BPR	SBPR	RSGAN	IF-BPR	LightGCN	SGL	BG-Rec	Improve
LastFM	Prec@10	0.042 6	0.087	0.081 7	0.102 1	0.096 7	0.077	0.105 0	2.84%
	Rec@10	0.064 8	0.130 9	0.122 4	0.152 3	0.145	0.115 7	0.157 7	3.55%
	F1@10	0.051 4	0.104 5	0.097 9	0.122 2	0.116	0.092 5	0.126 1	3.19%
	MAP@10	0.025 8	0.058 7	0.054 5	0.070 1	0.064 5	0.052 6	0.072 6	3.57%
	NDCG@10	0.060 2	0.125 7	0.118 6	0.148 2	0.138 3	0.113 4	0.152 5	2.90%
Douban	Prec@10	0.123 6	0.158 8	0.173	0.175 7	0.125 7	0.146 2	0.182 0	3.59%
	Rec@10	0.041 3	0.055 4	0.057 5	0.058 3	0.047 6	0.048 4	0.061 5	5.49%
	F1@10	0.061 9	0.082 2	0.086 3	0.087 5	0.069	0.072 7	0.092 0	5.14%
	MAP@10	0.071 1	0.097 2	0.108 3	0.109 7	0.067 2	0.084	0.115 1	4.92%
	NDCG@10	0.140 8	0.181 2	0.195 5	0.197 4	0.137 8	0.162 1	0.205 4	4.05%
Epinions	Prec@10	0.011	0.014 5	0.018 6	0.015 7	0.016 7	0.019 2	0.020 0	4.17%
	Rec@10	0.025 1	0.030 9	0.041 5	0.034 2	0.036 9	0.042 4	0.044 0	3.77%
	F1@10	0.015 3	0.019 7	0.025 7	0.021 5	0.023	0.026 4	0.027 5	4.17%
	MAP@10	0.009	0.012 2	0.016 6	0.015 1	0.014 8	0.018 6	0.019 1	2.69%
	NDCG@10	0.019 4	0.025 3	0.033 5	0.029 2	0.030 1	0.035 9	0.037 3	3.90%
	NDCG@10	0.019 4	0.025 3	0.033 5	0.029 2	0.030 1	0.035 9	0.037 3	3.90%

(2) 融入显式关系的 SBPR 在 BPR 基础上推荐效果有小幅度的提升, 这表明在推荐系统中显式关系是有效的; 同时, 利用显式和隐式关系的 RSGAN 和 IF-BPR 在 SBPR 的基础上又有大幅度的推荐效果提升, 这说明同时利用显式关系和隐式关系能有效提升推荐性能.

(3) 本文所提出的模型 BG-Rec 在三个数据集上的推荐性能最佳. BG-Rec 对比其他算法的一个突出优势是利用了普通图和超图分别描述显式关系和隐式关系. 同时, 这也表明 MixRandom 游走策略结合利用显式关系和隐式关系的设计是合理的, 可以精确识别隐式朋友. MixRandom 游走策略的合理性将通过消融实验验证. 识

别的可靠隐式关系缓解了数据稀疏问题, 提升了推荐性能, 进而缓解了冷启动问题. 这一点将通过冷启动用户实验验证.

4.4 固定朋友数量对比动态朋友数量

本文将使用固定朋友数量模型称为 BG-Rec-, 动态调整朋友数量 K 的模型为 BG-Rec. 为验证动态调整 K 值的有效性, 本文进行了 BG-Rec- 和 BG-Rec 的对比实验, BG-Rec- 的 K 值范围设置为 $[10, 150]$, 间隔为 10. BG-Rec 的 K 初始化为 150.

如图 4 所示, 在 Douban 上当 K 值较小时, 限制了 $I_{u,b}, F_{\text{pos}}(u), F_{\text{neg}}(u)$ 的大小, 导致较差的推荐效果. 随 K

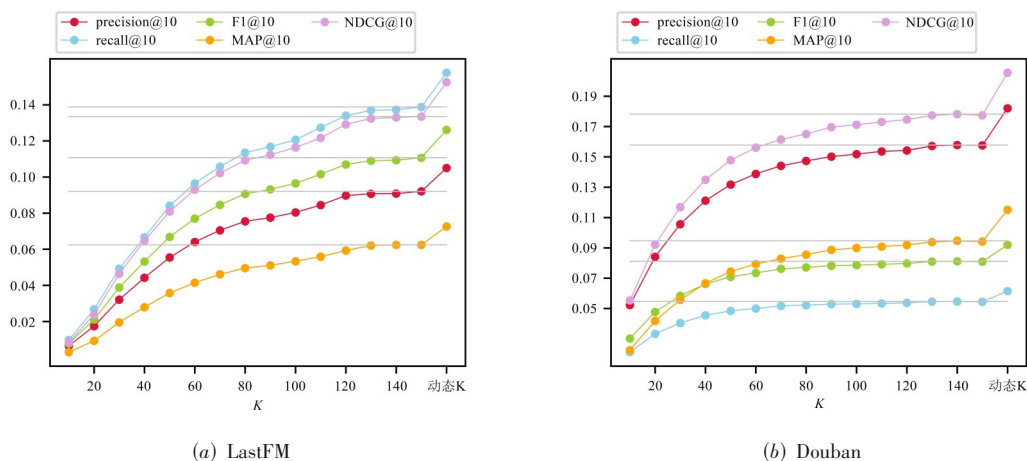


图 4 动态 K 与固定 K 对比实验

值增加, BG-Rec 的效果逐渐提升, 到达峰值后, 然后逐渐趋于平稳. 横坐标轴末尾的“动态 K”表示的是 BG-Rec 的分值, BG-Rec 性能明显高于 BG-Rec. 在 Epinions 上的表现与 LastFM 和 Douban 数据集相似(受篇幅限制本文省略描写). 这表明为每个用户动态调整朋友数量 K 是有效的.

4.5 冷启动用户实验

利用反馈或评分记录少于 10 的用户进行冷启动用户实验. 如图 5 和图 6, 在三个数据集中, SBPR, RSGAN, IF-BPR 的推荐效果都优于 BPR, 这表明显式和隐式关系都有助于提升推荐性能. BG-Rec 的推荐在所有指标上都优于其他对比模型, 说明 BG-Rec 在针对冷启动用户的推荐也表现出较强的鲁棒性. 这是因为 BG-Rec 识别的细粒度隐式朋友关系缓解了数据稀疏性, 且根据隐式朋友偏好进行物品优先级划分提升推荐性能, 缓解了冷启动问题.

4.6 消融实验

为分析 BG-Rec 中超图和普通图在整体模型的重要性, 以及 MixRandom 游走策略的合理性, 设计以下消融实验:

- (1) BG-Rec: 同时利用了超图和普通图.
- (2) BG-Rec^{w/oG}: BG-Rec 消去普通图, 只在超图上进行随机游走.

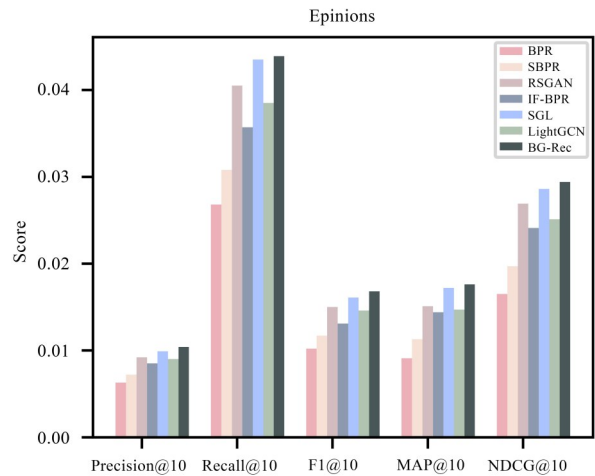


图 5 冷启动用户推荐性能对比(Epinions)

(3) BG-Rec^{w/oH}: BG-Rec 的超图部分退化为用户-物品普通图, 只在普通图上进行随机游走.

表 3 表明, 相对于 BG-Rec^{w/oG} 和 BG-Rec^{w/oH}, BG-Rec 表现更加优秀, 去掉超图或普通图都会降低推荐效果. 这说明普通图中的显式关系和超图中的隐式关系结合使用会比只用两者之一产生更好的推荐效果. 同时表明 MixRandom 游走策略能捕获用户间的偏好关系, 从




图 6 冷启动用户推荐性能对比

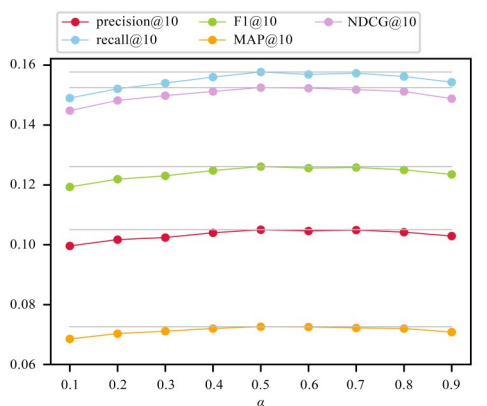
表 3 BG-Rec 分别消去超图和普通图的对比情况

Model	Component	Dataset	Prec@10	Rec@10	F1@10	MAP@10	NDCG@10
BG-Rec ^{w/oH}	Graph \checkmark	LastFM	0.102 1	0.152 3	0.122 2	0.070 1	0.148 2
		Douban	0.175 7	0.058 3	0.087 5	0.109 7	0.197 4
		Epinions	0.015 7	0.034 2	0.021 5	0.015 1	0.029 2
BG-Rec ^{w/oG}	Hypergraph \checkmark	LastFM	0.100 0	0.150 9	0.120 3	0.068 5	0.144 5
		Douban	0.152 7	0.055 9	0.081 9	0.092 7	0.173 4
		Epinions	0.010 2	0.023 1	0.014 2	0.009 2	0.018 6
BG-Rec	Graph \checkmark	LastFM	0.105 0	0.157 7	0.126 1	0.072 6	0.152 5
		Douban	0.182 0	0.061 5	0.092 0	0.115 1	0.205 4
	Hypergraph \checkmark	Epinions	0.020 0	0.044 0	0.027 5	0.019 1	0.037 3

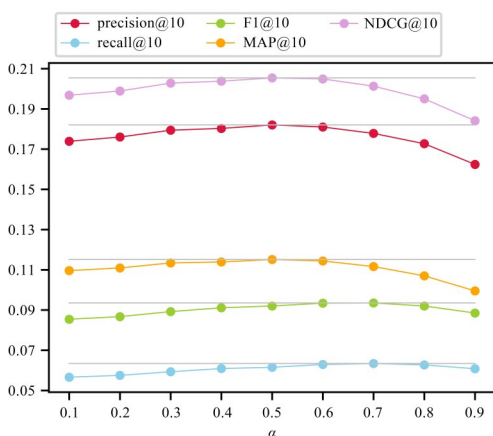
而精确识别隐式朋友.

4.7 参数敏感性分析

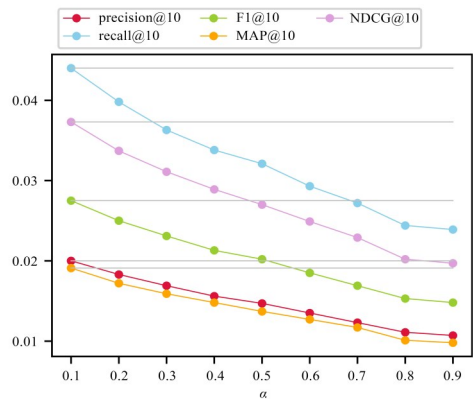
在 MixRandom 游走策略中,由参数 α 控制顶点转移时选择在超图或普通图上进行的概率. α 越大,随机游走过程越倾向于利用超图中的隐式关系,反之越倾向于普通图中的显式关系.如图 7(a)和图 7(b)所示,在 Douban 和 LastFM 数据集上大部分指标随 α 的增大都



(a) LastFM



(b) Douban



(c) Epinions

图7 α 参数敏感实验

呈现先上升后下降的趋势,且都是在 $\alpha = 0.5$ 时达到峰值.如图 7(c)所示,在 Epinions 数据集上的性能在 $\alpha = 0.1$ 时达到峰值.这是因为 Epinions 数据集的密度小,即用户-物品的交互数据过于稀疏,所以在 Epinions 数据集中构建的超图较稀疏,这导致模型更依赖社交关系(普通图).

5 总结

本文提出基于双图混合随机游走策略和 BG-Rec 推荐模型.混合随机游走策略利用显式关系和隐式关系,识别可靠朋友关系. BG-Rec 模型根据双图混合随机游走策略,利用可靠朋友关系进行贝叶斯个性化排序优化.在三个真实数据集上的实验表明 BG-Rec 在推荐效果上的优异性,以及在解决数据稀疏问题和冷启动问题上的有效性.此外,本文通过消融实验验证了混合随机游走策略的有效性.

本文中根据评分界定用户正/负反馈时没有考虑用户的评分偏好,在未来工作中,将考虑对不同用户采用不同的正、负反馈界定阈值,更准确地判断用户偏好,从而在利用自监督学习缓解数据稀疏问题的同时,学习到更精确的用户表示,提升推荐性能.

参考文献

- [1] YU X, JIANG F, DU J, et al. A cross-domain collaborative filtering algorithm with expanding user and item features via the latent factor space of auxiliary domains[J]. Pattern Recognition, 2019, 94(1): 96-109.
- [2] QI L, WANG X, XU X, et al. Privacy-aware cross-platform service recommendation based on enhanced locality-sensitive hashing[J]. IEEE Transactions on Network Science and Engineering, 2021, 8(2): 1145-1153.
- [3] 李琳,唐守廉.基于多层注意力表示的音乐推荐模型[J].电子学报,2020,48(9): 1672-1679.
- [4] LI L, TANG S L. Hierarchical attention representation model for music recommendation[J]. Acta Electronica Sinica, 2020, 48(9): 1672-1679. (In Chinese)
- [4] 郭景峰,朱晓松,李爽.直播电视推荐系统的评分预测算法研究[J].电子学报,2020,48(9): 1735-1740.
- [4] GUO J F, ZHU X S, LI S. Research on rating prediction algorithm of live TV recommender systems[J]. Acta Electronica Sinica, 2020, 48(9): 1735-1740. (in Chinese)
- [5] CIALDINI R B, GOLDSTEIN N J. Social influence: Compliance and conformity[J]. Annu Rev Psychol, 2004, 55(1): 591-621.
- [6] SINHA R R, SWEARINGEN K. Comparing recommendations made by online systems and friends[C]//Proceedings

- of the Second DELOS Network of Excellence Workshop on Personalisation and Recommender Systems in Digital Libraries. Sophia Antipolis: ERCIM, 2001: 1-6.
- [7] DOU K, GUO B, KUANG L. A privacy-preserving multimedia recommendation in the context of social network based on weighted noise injection[J]. *Multimedia Tools and Applications*, 2019, 78(19): 26907-26926.
- [8] ZHAO T, MCAULEY J, KING I. Leveraging social connections to improve personalized ranking for collaborative filtering[C]//*Proceedings of the 23rd ACM International Conference on Conference on Information and Knowledge Management*. New York: ACM, 2014: 261-270.
- [9] MA H, KING I, LYU M R. Learning to recommend with social trust ensemble[C]//*Proceedings of the 32nd International ACM SIGIR Conference on Research and Development in Information Retrieval*. New York: ACM, 2009: 203-210.
- [10] KANG M, BI Y, WU Z, et al. A heterogeneous conversational recommender system for financial products[C]//*Proceedings of the 28th ACM International Conference on Information and Knowledge Management*. New York: ACM, 2019: 26-30.
- [11] ZHAO H, ZHOU Y, SONG Y, et al. Motif enhanced recommendation over heterogeneous information network [C]//*Proceedings of the 28th ACM International Conference on Information and Knowledge Management*. New York: ACM, 2019: 2189-2192.
- [12] YU J, GAO M, LI J, et al. Adaptive implicit friends identification over heterogeneous network for social recommendation[C]//*Proceedings of the 27th ACM International Conference on Information and Knowledge Management*. New York: ACM, 2018: 357-366.
- [13] YU J, YIN H, LI J, et al. Self-supervised multi-channel hypergraph convolutional network for social recommendation[C]//*The Web Conference 2021*. New York: ACM, 2021: 413-424.
- [14] JI S, FENG Y, JI R, et al. Dual channel hypergraph collaborative filtering[C]//*Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. New York: ACM, 2020: 2020-2029.
- [15] MA H, YANG H, LYU M R, et al. Sorec: Social recommendation using probabilistic matrix factorization[C]//*Proceedings of the 17th ACM Conference on Information and Knowledge Management*. New York: ACM, 2008: 931-940.
- [16] YANG B, LEI Y, LIU J, et al. Social collaborative filtering by trust[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2016, 39(8): 1633-1647.
- [17] CHEN J, FENG Y, ESTER M, et al. Modeling users' exposure with social knowledge influence and consumption influence for recommendation[C]//*Proceedings of the 27th ACM International Conference on Information and Knowledge Management*. New York: ACM, 2018: 953-962.
- [18] RENDLE S, FREUDENTHALER C, GANTNER Z, et al. BPR: Bayesian personalized ranking from implicit feedback[C]//*In Proceedings of the Twenty-fifth Conference on Uncertainty in Artificial Intelligence*. Arlington: AU-AI Press, 2009: 452-461
- [19] TANG J, HU X, LIU H. Social recommendation: a review[J]. *Social Network Analysis and Mining*, 2013, 3(4): 1113-1133.
- [20] WANG X, HOI S C H, ESTER M, et al. Learning personalized preference of strong and weak ties for social recommendation[C]//*Proceedings of the 26th International Conference on World Wide Web*. Geneva: IW3C2, 2017: 1601-1610.
- [21] GOYAL P, FERRARA E. Graph embedding techniques, applications, and performance: A survey[J]. *Knowledge-Based Systems*, 2018, 151(1): 78-94.
- [22] FAN W, MA Y, LI Q, et al. Graph neural networks for social recommendation[C]//*Proceedings of the Web Conference 2019*. New York: ACM, 2019: 417-426.
- [23] WU L, SUN P, FU Y, et al. A neural influence diffusion model for social recommendation[C]//*Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval*. New York: ACM, 2019: 235-244.
- [24] YU J, GAO M, YIN H, et al. Generating reliable friends via adversarial training to improve social recommendation [C]//*2019 IEEE International Conference on Data Mining*. New York: IEEE, 2019: 768-777.
- [25] YU J, YIN H, LI J, et al. Enhance social recommendation with adversarial graph convolutional networks [EB/OL]. (2020-10-23)[2021-06-28]. <https://arxiv.org/abs/2004.02340>.
- [26] CHITRA U, RAPHAEL B J. Random walks on hypergraphs with edge-dependent vertex weights[C]//*Proceedings of the 36th International Conference on Machine Learning*. Long Beach: IMLS, 2019: 2002-2011.
- [27] FROLOV E, OSELEDETS I. Fifty shades of ratings: How to benefit from a negative feedback in top-N recom-

mendations tasks[C]//Proceedings of the 10th ACM Conference on Recommender Systems. New York: ACM, 2016: 91-98.

- [28] DONG Y, CHAWLA N V, SWAMI A. Metapath2vec: Scalable representation learning for heterogeneous networks[C]//Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2017: 135-144.
- [29] MIKOLOV T, SUTSKEVER I, CHEN K, et al. Distributed representations of words and phrases and their compositionality[J]. Advances in Neural Information Processing Systems, 2013, 26(1): 3111-3119.
- [30] HE X, DENG K, WANG X, et al. LightGCN: Simplifying and powering graph convolution network for recommendation[C]//Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2020: 639-648.
- [31] WU J, WANG X, FENG F, et al. Self-supervised graph learning for recommendation[C]//Proceedings of the 44rd International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2021: 639-648.



范琪琳 女, 1989年生. 工学博士. 重庆大学大数据与软件学院讲师、硕士生导师. 主要研究方向为网络优化、移动边缘计算与缓存、网络虚拟化和机器学习.

E-mail: fanqilin@cqu.edu.cn



荣文戈 男, 1975年生. 工学博士. 北京航空航天大学计算机学院教授、博士生导师. 主要研究方向为机器学习、自然语言处理、数据挖掘和信息系统等. 中国电子学会会员编号: E190029189M.

E-mail: w.rong@buaa.edu.cn



文俊浩 男, 1969年生. 工学博士. 重庆大学软件学院教授. 主要研究方向为计算智能与推荐系统.

E-mail: jhwen@cqu.deu.cn

作者简介



曹阳 男, 1996年生. 现为重庆大学大数据与软件学院在读硕士研究生. 主要研究方向为机器学习、推荐系统等.

E-mail: cqucaoy@cqu.edu.cn



高旻(通讯作者) 女, 1980年生. 工学博士. 重庆大学大数据与软件学院副教授、硕士生导师. 主要研究包括推荐系统、异常检测、社交媒体挖掘.

E-mail: gaomin@cqu.deu.cn



余俊良 男, 1990年生. 在重庆大学大数据与软件学院获得学士学位和硕士学位. 现为澳大利亚昆士兰大学信息技术与电气工程学院在读博士研究生. 主要研究方向为推荐系统和异常检测等.

E-mail: jl.yu@uq.edu.au