

# 基于Agent模拟的多利益相关者长期推荐策略

李文华<sup>1</sup>, 冯婧妮<sup>1</sup>, 郭均鹏<sup>1,2\*</sup>

- 天津大学管理与经济学部, 天津 300072;
- 天津大学复杂管理系统实验室, 天津 300072)

**摘要:** 面对多利益相关者情景下用户与提供者的不同目标, 旨在探索长期视角下平台的不同推荐策略在动态权衡中的表现形态与演化规律, 其中提供者追求曝光公平, 用户期待兴趣匹配的推荐, 平台需兼顾双方期望. 本文运用多智能体建模框架, 构建两阶段重排序算法, 分析平台对用户和提供者不同权衡在长期背景下对个体和整体的影响, 以探究平台的最优策略. 模拟结果表明, 完全偏向用户或者完全偏向提供者都充分暴露两者的矛盾的关系, 影响平台生态. 均衡策略能够妥善平衡提供者曝光公平与用户偏好的冲突. 同时, 完全偏向用户的策略会导致优质供给流失, 长远看反而损害用户信任; 反之, 适度偏向用户的混合策略可以保证内容供给质量, 进而促进用户信任的持续增长, 更有利于平台的长远发展.

**关键词:** 推荐策略; 多智能体建模; 公平性; 多利益相关者; 动态表现

中图分类号: TP391

文献标识码: A

文章编号: 1000-5781(2026)01-0128-17

doi: 10.13383/j.cnki.jse.2026.01.009

## Multistakeholder recommendation strategies based on agent-based modelling

Li Wenhua<sup>1</sup>, Feng Jingni<sup>1</sup>, Guo Junpeng<sup>1,2\*</sup>

(1. College of Management and Economics, Tianjin University, Tianjin 300072, China;

2. Laboratory of Computation and Analytics of Complex Management Systems, Tianjin University, Tianjin 300072, China)

**Abstract:** Facing the divergent objectives of users and providers in a multi-stakeholder context, we explore the performance and evolution of different recommendation strategies from a long-term perspective, balancing the differing objectives of users and providers. Providers seek exposure fairness, while users expect recommendations that match their interests, and the platform needs to accommodate the expectations of both parties. Using a multi-agent modelling framework, we construct a two-stage re-ranking algorithm to analyze the impact of different trade-offs between users and providers on individuals and the overall system in a long-term context, aiming to identify the optimal strategy for the platform. Simulation results indicate that the conflict between providers' exposure fairness and users' preferences can be effectively reconciled, and a balanced strategy can appropriately harmonize these two major goals. Moreover, a strategy that completely favours users may lead to a loss of high-quality supply, ultimately damaging user trust in the long run. Conversely, a mixed strategy that moderately favours users can promote sustained growth in user trust, which is more beneficial for the platform's long-term development.

**Key words:** recommender system; agent-based modelling; fairness; multistakeholder; dynamic performance

收稿日期: 2024-06-04; 修订日期: 2025-07-21.

基金项目: 国家自然科学基金资助项目(72171165); 教育部人文社会科学研究资助项目(21YJA630021).

\*通信作者

## 1 引言

随着信息科技的蓬勃发展和信息数量的井喷式上升,推荐系统作为一种信息筛选工具,能够帮助用户在海量数据中筛选出符合其偏好的信息,有效解决了信息过载的问题。据市场调查机构QuestMobile估计,以抖音、今日头条、小红书等将推荐系作为核心的内容平台月活分别达到7.2亿、3.7亿、1.8亿,成为中国移动互联网的中流砥柱。随着研究的不断深入,多利益相关者的概念引入推荐系统,研究者渐渐意识到用户并不是平台的唯一参与者<sup>[1]</sup>,无论是用户、提供者还是平台都是推荐机制的利益相关者。推荐系统可以根据用户和提供者的不同目的相应地以不同的方式为其创造价值。在推荐机制中,给予利益相关者不同的关注,其带来的推荐效果是不同的。

现有研究主要从用户相关性和平台利润的角度出发,探究平台最优策略,但其研究视角大多局限于单一提供者的电商平台。实际上,在现实场景中,除了类似于单提供者的自营电商模式外,还存在着大量的多提供者情况,不仅包括类似淘宝的C2C(消费者对消费者)电商平台,还包括像抖音、小红书这样的内容平台。在这些多提供者的环境中,平台不仅需要考虑如何协调用户与提供者之间的关系,还需进一步处理不同提供者的关系,以达到优化整体用户体验和促进平台长期发展的目的。在这样一个复杂的多提供者环境中,平台需要综合考量多种因素来制定策略。一方面,要确保用户能够获得个性化的推荐和服务,提高用户的参与度和忠诚度;另一方面,也需要合理分配资源和支持给不同的提供者,促进良性竞争和合作,避免市场失衡。鉴于此,本文将重点放在内容平台的多提供者环境上,探讨平台如何针对用户和提供者采取不同的策略,并观察这些策略在实际运行中的动态演化效果。通过对这些策略及其效果的深入分析,找到优质策略,促进平台的长期可持续发展。

在内容平台中,用户是推荐的接受者,其对平台的信任来源于获知与自身兴趣相匹配的推荐内容,即推荐内容与自身偏好之间的相关性,这也是目前主流推荐算法主要考虑的方向<sup>[2]</sup>。提供者是内容的提供者,主要关注自身内容的曝光情况。曝光量某种程度会直接与提供者的经济因素挂钩,决定了用户对平台的满意程度,如果没有获得满意的曝光,提供者会考虑离开平台<sup>[3]</sup>。而从平台的角度来说,面对两个不同目标,如何制定推荐策略,满足两种不同的期望,是平台亟待解决的问题。从某些角度来说,这两个目标是相互矛盾的,如果平台保护内容提供者,为曝光量低的内容提供者提供曝光机会完全不考虑用户体验,会导致用户对平台的体验感下降;反之,如果平台只关注用户体验,为用户提供最匹配的推荐服务,许多内容提供者会因没有曝光机会而考虑离开平台。因此平台的目标是制定出两者权衡的策略,保护平台生态,使得平台健康茁壮的发展。基于此,本文构建平台、内容消费者与内容提供者的模拟框架,基于智能体建模(Agent-based modelling, ABM)框架研究用户相关性和提供者公平权衡下的最优策略,拟解决以下问题: 1) 不同的平台策略对用户与内容提供者的效用有何影响? 其具体随时间的演化表现是怎么样的? 2) 提供者与内容消费者之间的矛盾是否可以缓和? 什么情况下可以实现两者矛盾的调和? 3) 是否存在最优策略以实现二者之间的权衡? 其权衡是怎么实现的?

近年来,越来越多的学者开始关注多利益相关者推荐系统的相关问题。早期的多利益相关者的概念主要存在于互惠推荐(reciprocal recommendation)中,比如在线交友、就业与招聘这类人与人的推荐<sup>[4]</sup>。但互惠推荐下多利益相关者是对等的,例如在交友情境下,推荐者和被推荐者是对等的,都希望找到合适的配对者,并在成功匹配后双方平分相同效用。但在很多情景下不同的利益相关者追求不同的目标,甚至各目标之间存在着利益冲突。例如Zhou等<sup>[5]</sup>验证了在电商情景下,平台的盈利能力和推荐的用户相关性是矛盾的目标,通过调整推荐的规则可以实现平台利润的提升。同时,也有部分研究者探究了多利益相关者情境下的公平与偏差的问题。Sühr等<sup>[6]</sup>将情景放置在网约车平台中,将司机收入公平与顾客等待时间构建为优化模型,研究两者之间的权衡。Mehrotra等<sup>[7]</sup>考虑音乐流媒体平台中消费者相关性和提供者公平性之间的权衡,运用反事实估计框架探究公平性和相关性对用户满意度的影响。Wang等<sup>[8]</sup>将相关性和群体公平性融入多任务学习

中,找到相关性与公平性权衡的帕累托前沿。Sürer等<sup>[9]</sup>和Karakolis等<sup>[10]</sup>都将提供者的公平加入约束模型,运用规划模型优化平台中提供者曝光与用户相关性。Rampisela等<sup>[11]</sup>过帕累托前沿量化推荐系统的公平性与相关性权衡,解决了传统方法的评估割裂问题,避免单纯优化其中一方而导致另一方的劣化,确保提升相关性的同时每个项目都有机会出现在推荐列表中,提高用户对系统的信任感和满意度。Vassøy和Langseth<sup>[12]</sup>认为推荐系统涉及消费者和提供商等多方利益,消费者端公平性关注用户免受不公平推荐的影响,而供应端则关注商品曝光的公平性,论述了推荐系统中的公平性问题不仅是数据偏差、算法偏差等技术问题,更是社会责任的体现。因此,公平性是推荐系统中的一个关键因素,它不仅关系到推荐的公正性和用户满意度,还涉及到如何避免系统偏见和歧视,保证所有项目和用户群体都能得到合理的关注,上述研究虽与本文相似均从用户相关性和提供者公平性出发,但最终问题的落脚点不同,本文将场景放置于内容平台,探究平台对内容消费者与内容提供者的权衡。同时相关研究多从静态角度出发。然而,这种策略的确定不能通过静态的一次性调查确定,平衡多个利益相关者目标通常需要长期的研究,因为当公平干预逐渐改善时,可能出现纵向动态<sup>[13]</sup>。目前只有少数研究从动态角度出发,运用强化学习的方法动态探究了提供者和用户的动态,但其本质仍是一种优化手段<sup>[14,15]</sup>。本文则是从平台策略角度出发,期望观察不同策略下利益相关者的效用演化表现,以期在长期背景下找到面对利益相关方的不同目标时合适的平台策略,为平台健康持续发展提供建议。

ABM方法能够有效的对复杂系统进行建模,通过模拟智能体(agents)之间的表现和交互实现长期效果的评估,其能贴近复杂的真实情境,模拟个体动作行径,捕捉个体在整体上的涌现现象<sup>[16]</sup>。因此本文拟运用ABM的方法探究平台推荐策略的动态性。基于智能体的建模不同于其他方法,其主要研究对象是智能体。智能体代表了相互之间或与环境相互作用的异质实体。基于智能体的建模本质是对智能体的行为进行建模,让这些智能体在一个重复的过程中相互作用,实现模拟,由此观察其整体趋势。尽管行动者看起来往往是作为一个群体一起行动的,但实际上他们只是彼此影响微观决策的个体的集合体。因此ABM可以模拟在静态模型中难以捕获的真实世界的行为,关注其过程随时间演化,以及不同策略对影响演化结果的影响<sup>[17,18]</sup>。目前ABM在社会科学、经济学等领域已经获得一些成功的应用,Axtell和Farmer<sup>[19]</sup>总结了ABM在金融市场方面获取的显著成就,在解集群波动、市场影响、系统性风险和住房市场等方面发挥了重要作用,不仅如此,ABM在管理科学中的应用也在不断拓展。Zhang等<sup>[20]</sup>提出了一个基于Agent的消费者购买决策模型;罗航等<sup>[21]</sup>将ABM引入公共管理和政策领域,对城市群多政府互动系统进行模拟仿真;李少英<sup>[22]</sup>利用多智能体对劳动人口居住区位选择行为进行模拟研究;李莹莹<sup>[23]</sup>基于Agent建立品牌层面扩散仿真模型;Chica等<sup>[24]</sup>提出了一个基ABM构建的决策支持系统,帮助营销人员针对口碑营销做出更好的决策;王歌等<sup>[25]</sup>利用ABM模拟了不同类型用户在区块链能源共享平台中的行为,分析了多种模式对光伏市场扩散的影响。近期,Zhang等<sup>[26]</sup>将ABM框架融入推荐情境,系统地提出了ABM在推荐中的应用框架,探究了用户对推荐依赖对推荐质量的影响,发现如果用户对推荐的依赖程度高,推荐质量将随时间的推移而下降。同时从策略角度提出使用个性化和非个性化推荐相结合的混合方法可以帮助缓解这类现象。使用ABM构建推荐模拟系统进行推荐系统研究的好处是显而易见的,它可以为研究人员探索各种推荐设置和测试不同的推荐算法提供便利,且能够灵活地引入人工干预以进行各种可重复试验。在Zhang等提出的ABM框架下,Zhou等<sup>[27]</sup>基于此研究潜在偏好偏差的影响对推荐系统性能动态的纵向影响并在正常的系统使用过程中和外部故意扰动的情境下,观察随着时间推移下其在系统中的传播作用。Ghanem等<sup>[28]</sup>将情境拓展至多利益相关者,在用户关注相关性,提供者关注利润的角度下制定策略,通过ABM模拟多种不同策略下的动态表现,发现在关注提供者的利润的前提下更偏向于用户,对平台来说是收益最优的选择。总体而言,现有文献运用模拟方法对推荐长期效果探究的仍然较少,现有文献对多利益相关者长期影响的探索局限在用户相关与平台利润角度,未见考虑多提供者公平方向,同时从结论角度出发,用户的重要性得到了一致公认,但其并没有对具体内因进行细致拆分,而本文从用户相关与提供者公平出发,得出适度偏向用户的混合策略则能促进用户信任的持续增长的结论,并从内容供给质量角度进行了细致的归因。

本文首先在现有研究基础上进一步探究推荐系统在多利益相关者情境下的策略选择问题,考虑多用户

和多提供者的复杂交互, 探究长期动态背景下平台的优质策略. 同时将场景放置在内容平台上, 结合多提供者公平角度, 探究内容平台下提供者公平导向或者用户相关性导向下的长期影响, 缩小了多利益相关者推荐领域的研究缝隙. 其次, 面对场景的变化和新问题的提出, 在基于多智能体建模框架下提出一种两步走的重排序框架, 将提供者公平曝光放在长期背景下, 提出一种新的基于长短期曝光的公平性权衡方法, 为长期公平的实现提出了一种新思路, 而后基于曝光公平的实现, 将用户相关和提供者公平综合考虑实现重排序, 为权衡用户和提供者提供新角度. 最后, 通过模拟观察平台对用户相关和提供者公平不同关注度下的长期变化趋势, 发现均衡策略可以有效调和用户相关和提供者公平之间的矛盾, 同时在内容供给固定的情况下, 过于倾向于用户反而会对用户信任产生副作用, 但在均衡下适当偏向用户可以实现平台的健康持续发展.

## 2 仿真模拟框架构建

考虑一电影内容推荐系统, 其中利益相关方包括平台、内容提供者(简称为提供者)和内容消费者(用户). 平台作为策略制定者, 通过设计不同的推荐算法来平衡对提供者的公平对待和满足用户需求, 以此增强用户和提供者对平台的忠诚度, 间接促进平台收益的增长. 内容提供者作为平台内容的来源, 依赖平台的推荐机制来放大自身内容的曝光度, 追求公正的展示机会以实现内容更好的商业化, 尤其是在多提供者共存的竞争环境下, 更显迫切. 然而, 由于内容的推荐性质, 提供者在平台上的地位相对被动, 若缺乏足够的曝光, 将减弱其对平台的依附, 甚至导致退出. 用户作为推荐系统的核心受众, 期望获取符合个人兴趣的内容, 基于平台推荐和自我意识集进行决策, 其对平台的信任度受推荐体验的影响, 这种互动循环推动着平台的持续发展. 平台、内容提供者与用户三者经由推荐列表的纽带, 交织成一个动态平衡的循环体系, 共同塑造平台的未来走向, 如图2所示.




图 1 推荐系统利益相关者关系图

Fig. 1 Relationship of stakeholders in the recommendation system

采用基于智能体建模的方法, 将用户、提供者和平台各自视为独立的智能体, 并基于真实数据模拟三方的交互, 通过时间迭代观察不同策略下的推荐表现. 整个模拟流程分为两个主要阶段: 1) 初始化阶段( $t = 0$ ): 构建平台、提供者、用户三类智能体并实现初始化. 平台制定推荐策略, 提供者分配内容并计算初始曝光, 用户构建个性化认知集合意识集. 2) 迭代阶段( $t = 1, 2, \dots$ ): 对每一个时间步 $t$ , 平台基于用户历史偏好预测用户对内容的评分. 用户随机到达平台, 对于每个用户, 平台根据曝光数据和策略对预测评分进行排序, 生成推荐列表. 基于推荐列表和自身意识集, 用户做出内容选择, 并更新对平台的信任. 与此同时, 提供者更新内容曝光情况, 并基于此为下一位到访的用户提供更精准的推荐排序. 一轮用户遍历结束后, 提供者依据本轮曝光成效决定是否继续留在平台, 随后系统步入下一周期的循环.

### 2.1 提供者仿真模型

对于提供者的初始化首先是要构建提供者角色. 由于Movielens数据集并不包括提供者数据, 故采取

预先指派的方式,将电影内容与提供者相匹配.存在一系列提供者,记为 $P = \{p_1, p_2, \dots, p_N\}$ 与电影内容集 $C = \{c_1, c_2, \dots, c_I\}$ ,其中 $I > N$ .为了保证提供者内容独特性,假设每部电影内容只有一个提供者,但每个提供者可以有多部电影内容.这一假设较好的反映了现实情境.为模拟这一情境,对MovieLens数据集中的电影内容进行随机分配形成合成数据,确保每部电影等概率地归属于任一提供者,因此提供者下内容分布也是均匀的<sup>[10]</sup>.

基于提供者角色计算其曝光量.在迭代开始之初,即 $t = 0$ 时,提供者的曝光量可以通过MovieLens数据集统计得到,其中每一次评分记录可以看做对应内容的一次曝光,统计对应提供者下所有内容的评分记录即可看作其初始曝光情况.随着时间步的推移,即 $t > 0$ 时,提供者的曝光是通过提供者下所有内容出现在用户推荐列表中的次数统计得到的.首先,需要统计内容 $c_i$ 出现在所有用户推荐列表 $R$ 中的次数,记为内容的曝光量 $E_{c_i}$ (变量命名取自Exposure单词的首字母,后文中与曝光次数有关的变量命名同样如此),其具体计算公式为

$$E_{c_i} = \sum_{j=1}^M 1_{R_{u_j}(c_i)}, \quad (1)$$

其中 $U = \{u_1, u_2, \dots, u_M\}$ 为用户列表,示性函数 $1_{R_{u_j}(c_i)}$ 是指内容 $c_i$ 是否出现在用户 $u_j$ 的推荐列表 $R_{u_j}$ 中,如果出现则该值为1,反之则为0.基于此,则可计算提供者的曝光,提供者的曝光是该提供者下所属内容曝光次数的加总.根据时间步 $T = \{t_1, t_2, \dots\}$ 可以将提供者曝光分为单步曝光和长期曝光两个概念,其中提供者 $p_i$ 在时间步 $t$ 时的单步曝光 $E_{p_i}^t$ 是指其所有内容获得的曝光次数总和,其计算公式为 $E_{p_i}^t = \sum_{i=1}^I E_{c_i}^t$ ;提供者 $p_i$ 到时间步 $t$ 的长期曝光 $E_{p_i}^l$ 为提供者进入推荐系统到当前时间步的曝光次数总和,其计算公式为 $E_{p_i}^l = \sum_{j=1}^t E_{p_i}^{t_j}$ .类似的计算公式也被Patro<sup>[29]</sup>也曾运用,用来解决静态情境下的公平问题,其分析框架并未融入时间变量.为了适应动态情境,我们引入时间维度,更精细地捕捉随着时间演进的曝光变化及公平性的演进.

提供者存续意愿紧密依赖于其在推荐系统中的曝光量.提供者在平台生态中处于被动地位,若平台没有给予足够的曝光机会,其将难以维系其市场参与度,进而出现离场的情况.为刻画该情境,引入提供者平台满意度 $c_{p_i t}^{\text{satis}}$ 的概念,提供者 $p_i$ 在时间点 $t$ 的满意度( $c_{p_i t}^{\text{satis}}$ ),由过往优质与劣质平台体验比例决定,而平台体验的优劣由其获得的曝光量决定,计算公式如下

$$c_{p_i t}^{\text{satis}} = \frac{\alpha_{p_i t}}{c + \beta_{p_i t}}, \quad (2)$$

其中参数 $\alpha_{p_i t}$ 代表优质体验频次, $\beta_{p_i t}$ 象征劣质体验频次,其计算公式如下

$$\{\alpha_{p_i t}, \beta_{p_i t}\} = \begin{cases} \left( \alpha_{p_i t} + \frac{E_{p_i}^t - E_{\text{mean}}}{E_{\text{mean}}}, \beta_{p_i t} \right), & \text{若 } E_{p_i}^t \geq E_{\text{mean}} \\ \left( \alpha_{p_i t}, \beta_{p_i t} + \frac{E_{p_i}^t - E_{\text{mean}}}{E_{\text{mean}}} \right), & \text{其他.} \end{cases} \quad (3)$$

在每一个时间步 $t$ ,推荐的总曝光量是有限的, $M$ 个用户接受到长度为 $K$ 的推荐,总曝光量为 $K \times M$ ,如果平均分配给 $N$ 个提供者,其每个提供者应得 $\frac{K \times M}{N}$ 次曝光,即 $E_{\text{mean}}$ ,类似共享资源理想分配概念文献<sup>[30,31]</sup>中也有提及.以 $E_{\text{mean}}$ 为基础,当提供者曝光量 $E_{p_i}^t$ 超越 $E_{\text{mean}}$ ,视作优质体验, $\alpha_{p_i t}$ 递增;反之,则标记为劣质体验, $\beta_{p_i t}$ 提升,而后通过曝光数据在平均水平上的相对变动实现对提供者体验的更新.初始化阶段设定基础体验,随时间更新提供者体验以计算退出概率.在初始化阶段,即 $t = 0$ 时,设定基础体验( $\alpha_{p_i 0}, \beta_{p_i 0}$ ),依托MovieLens数据集,将其中评分数据按时间戳排序,以 $K \times M$ 为单位划分时间步,将时间步中每一条评分记录看作一次曝光记录,统计各时间步中提供者的曝光量,应用式(3)进行统计得出初始体验.随着时间步的推移,即 $t > 0$ 时,在每一个时间步所有用户迭代结束后,更新提供者优劣质体验进而计算出其平台满意程度 $c_{p_i t}^{\text{satis}}$ ,基于此量化其退出概率.其退出的概率由提供者 $p_i$ 在时间步 $t$ 时对平台的不满意度决定,即 $1 - c_{p_i t}^{\text{satis}}$ ,且其决策遵循幂律分布,因为提供者只有在遭遇显著不利时才会考虑离场.关于提供者离

场Abdollahpouri<sup>[32]</sup>、Wang<sup>[33]</sup>等都有所提及,但其只是对可能性的探讨,并未明确捕捉任何形式的效用及建模.为了建立一个针对此场景的模型,并度量提供者对于平台的满意度,借鉴被Ghanem<sup>[28]</sup>、Chen<sup>[34]</sup>等用于评估信任的公式.与其不同的是,在对于平台体验优劣的度量上,文中方法针对提供者情境进行了适应性调整,通过计算曝光的相对变动实现度量.

实际曝光后的用户反馈提供者的内容质量评估.实际上,单个作品表现存在极端差异,高影响力作品对提供者整体声誉存在潜在贡献.为了更准确地描绘提供者在平台生态中的质量,累加提供者旗下各内容的曝光比例与其质量评分的乘积,以此反映该提供者的总体内容质量.具体而言,提供者 $p_i$ 的内容质量为

$$\text{Qual}_{p_i} = \sum_{j=1}^I \frac{E_{c_j}}{E_{p_i}} \text{Uti}_{c_j}, \quad (4)$$

其中  $\text{Uti}_{c_j}$  为内容 $c_j$ 的质量,即平台中所有用户对内容 $c_j$ 的预测评分的均值,  $E_{c_j}$ 和 $E_{p_i}$ 分别表示内容 $c_j$ 和提供者 $p_i$ 的总曝光量.若提供者无任何内容曝光,则采用其内容预测评分的平均值作为替代.传统的计算方法仅依赖于其所有作品评分的算术平均值,并没有考虑同一内容提供者的产出质量可能存在的显著异质性.与此不同,此处采用一种更加细致的评价方式,综合考虑提供者内容的声量及质量,提供了更为全面的内容质量评估.

## 2.2 用户仿真模型

用户基于流行与个性内容形成并更新意识集,与推荐共同构成信息来源.在实际用户决策环境中,信息获取途径多元,推荐系统仅是其中一环.为模拟该情景,假设用户基于个人认知形成一个个性化的内容选择集合,记为意识集 $A_{u_i}$ ,该集综合了平台的流行项目 $\text{Pop}_{u_i}$ 与用户个人兴趣高度相关的项目 $\text{Hut}_{u_i}$ ,并融入随机内容,既呼应用户对流行趋势与个性化内容的感知,也通过随机性补充了认知的不完备,使其构建更趋近于用户心理模型的真实写照.意识集在时间步之间的迭代更新源于用户接收到的推荐列表,每一次推荐不仅是选择的契机,也是认知扩大的过程.在每次迭代中,即使未被用户即时采纳,推荐列表中的项目亦会被纳入意识集,扩充其认知边界.鉴于用户认知能力有限,设定意识集规模恒定,新项目加入同时意味着旧项目兴趣值的自然衰退.尽管无法精确模拟兴趣减退机制,通过随机剔除项目的方式可以有效维持意识集容量的稳定,抽象模拟了用户兴趣领域的动态变化.Hazrati等<sup>[35]</sup>使用了相同的意识集的概念探究用户意识规模对选择多样性的影响,其对意识集的更新也仅仅停留于剔除已被推荐内容.与之不同,此处的意识集主要用于模拟用户除了推荐系统之外的信息来源.为了确保用户意识集的规模保持恒定,在每次迭代中,我们不仅会剔除已被推荐的内容,还会通过随机剔除其他内容的方式来纳入新的推荐内容,以此维持意识集规模的稳定.

用户对平台内容的选择受其信任水平影响.这一信任度构建逻辑与提供者满意度模型相仿,用户 $u_i$ 在任一时间点 $t$ 对平台的信任度 $c_{u_i t}^{\text{trust}}$ ,由其历史优质 $\alpha_{u_i t}$ 与劣质体验 $\beta_{u_i t}$ 决定,具体通过计算优质体验 $\alpha_{u_i t}$ 占总体体验比得出,表达式如下

$$c_{u_i t}^{\text{trust}} = \frac{\alpha_{u_i t}}{\alpha_{u_i t} + \beta_{u_i t}}. \quad (5)$$

初始状态下,即 $t = 0$ 时,用户信任度 $c_{u_i 0}^{\text{trust}}$ 基于其平台历史体验 $\{\alpha_{u_i 0}, \beta_{u_i 0}\}$ 计算,其中优质与劣质体验分别由用户历史评分是否超过期望阈值 $\underline{\eta}_{u_i 0}$ 界定.初始化时该阈值设定为用户历史评分均值,以量化其满意与不满意体验.其计算如下

$$(\alpha_{u_i 0}, \beta_{u_i 0}) = \left( \sum_{j=1}^I \left[ r_{u_i c_j} \geq \underline{\eta}_{u_i 0} \right], \sum_{j=1}^I \left[ r_{u_i c_j} < \underline{\eta}_{u_i 0} \right] \right), \quad (6)$$

其中  $r_{u_i c_j}$  表示用户 $u_i$ 对内容 $c_j$ 的历史评分,  $\underline{\eta}_{u_i 0}$  表示用户 $u_i$ 在 $t = 0$ 时的期望阈值.

随着时间步的迭代,用户期望阈值 $\underline{\eta}_{u_i t}$ 需要动态调整,由于每一轮可向用户推荐的内容都会随着时间步的迭代更新且用户消费过的项目不会给用户重复推荐,因此每一轮向每个用户推荐的内容是动态的且具有

异质性, 即用户的期望阈值也是动态性的, 根据用户所有历史反馈评分的 $\psi$ 位分位数确定, 确保每位用户拥有个性化的满意度标准. 当推荐内容预测效用高于此阈值, 用户选择消费后, 其优质体验更新; 反之, 劣质体验增加, 具体更新逻辑如下

$$(\alpha_{u_i t}, \beta_{u_i t}) = \begin{cases} (\alpha_{u_i t} + 1, \beta_{u_i t}), & \text{若 } r_{u_i c_j} \geq \eta_{u_i t} \\ (\alpha_{u_i t}, \beta_{u_i t} + 1), & \text{其他.} \end{cases} \quad (7)$$

值得注意的是, 意识集的引入意味着用户除了通过平台获取信息外, 还有其他的资讯来源. 用户信任度特指用户对平台的信任, 所以仅当用户响应平台推荐时, 体验数据才予以更新, 自主选择意识集内容则不触发更新机制. 信任经由式(5)周期性更新, 直接影响用户后续选择行为, 构建了信任驱动的个性化推荐闭环. 类似于Ghanem等<sup>[28]</sup>提出的计算方式, 该方法被用于评估和更新单一数据来源下的用户信任. 然而, 此处面临的是多数据来源的情境. 为更好的模拟这一复杂情境, 进一步细化平台信任的概念, 明确平台信任仅仅只指用户对平台的信任, 因此仅在平台推荐时触发更新机制.

用户决策基于内容效用计算选择概率, 其选择受用户对平台的信用影响. 在迭代进程中, 用户于每轮在推荐列表与意识集间挑选单一内容消费, 鉴于用户决策非绝对理性, 通过概率模型模拟选择的随机性. 即使效用较高的内容更可能被选, 用户也可能因随机性而不选择效用最高的内容, 从而更真实地反映用户在面对多元选择时的决策行为. 具体而言, 采用多项逻辑回归模型, 内容 $c_j$ 对用户 $u_i$ 的效用 $v_{u_i c_j}$ 决定了其被选概率 $p_{u_i c_j}$ , 表达式如下

$$p_{u_i c_j} = \frac{v_{u_i c_j}}{\sum_{j \in A_{u_i} \cup R_{u_i}} v_{u_i c_j}}, \quad (8)$$

其中  $A_{u_i}$  和  $R_{u_i}$  分别表示用户  $u_i$  对应的意识集和推荐列表, 效用  $v_{u_i c_j}$  依据推荐系统预测评分  $\hat{r}_{u_i c_j}$  确定.

不同的信息来源其效用的计算方式不同. 对于意识集内的内容, 效用直接由评分给出; 而对于推荐内容, 推荐对用户认知具有增强效应, 因此额外乘以强化系数  $c_{u_i}^{\text{boost}}$ , 强化系数  $c_{u_i}^{\text{boost}}$  直接决定了推荐对用户认知加强的作用程度, 其具体计算公式如下

$$v_{u_i c_j} = \begin{cases} c_{u_i}^{\text{boost}} \times \hat{r}_{u_i c_j}, & \text{若 } c_j \in R_{u_i} \\ \hat{r}_{u_i c_j}, & \text{其他.} \end{cases} \quad (9)$$

然而, 推荐对用户认知的增强效果并非统一的, 其是依据用户过往在平台上的推荐体验而变化的. 为了模拟该情况, 将用户对平台的信任度与推荐的强化系数直接挂钩, 用户对平台的信任度越高, 推荐内容的影响力也随之增强, 用户更倾向于选择平台推荐的选项. 由于用户对平台的信任是异质的, 推荐对不同用户的影响也是个性化的, 具体计算公式如下

$$c_{u_i}^{\text{boost}} = \delta c_{u_i}^{\text{trust}}, \quad (10)$$

其中  $c_{u_i}^{\text{trust}}$  与  $\delta$  分别表示用户信任度与调节因子. 由于  $c_{u_i}^{\text{trust}}$  在  $[0, 1]$  的范围内, 在此基础上乘上超参数  $\delta$ , 可以使推荐的强化系数实现等比例放大.

强化系数的概念Hazrati等<sup>[35]</sup>也有提及, 其同样用于放大推荐效果, 但其强化系数是一个固定值, 没有针对不同用户进行个性化调整. 相比之下, 该强化系数与用户信任直接关联, 实现了强化系数的个性化调整, 以更好地反映不同用户对推荐的不同反应.

基于选择内容进行评分, 用户将其反馈给平台优化平台推荐效果. 假设推荐算法预测的评分是用户真实效用的一个很好的近似, 但由于平台算法预测的评分与用户的实际评分仍存在一定的出入, 因此引入噪声因子来模拟用户  $u_i$  对内容  $c_j$  的反馈评分  $r_{u_i c_j}$ , 即

$$r_{u_i c_j} = \hat{r}_{u_i c_j} + \epsilon, \quad (11)$$

其中  $\epsilon \sim N(0, 0.1)$  为噪声因子<sup>[28]</sup>. 这些反馈数据被平台悉心收集与分析, 构成下一轮推荐策略制定的基础,

同时也作为用户更新其对平台推荐信任度的关键依据. 由此, 形成了一个从推荐、体验、反馈到优化的闭环机制, 不断迭代提升用户信任与平台推荐精度.

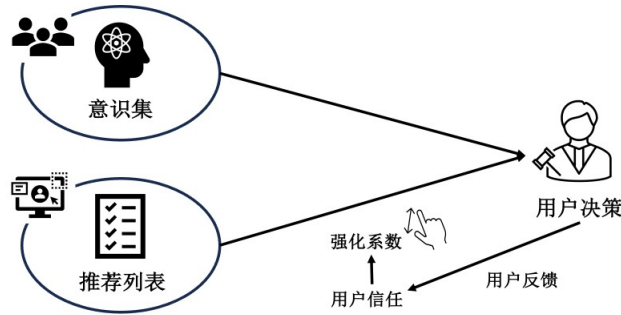


图 2 用户选择模型

Fig. 2 A user choice model

在用户视角下, 面对自我认知范围以外的平台推荐, 每一决策时刻, 用户挑选单一内容消费. 用户对平台的信任, 实质上调节着推荐内容对用户认知的影响力度——高信任度促使用户更倾向采纳平台推荐. 随后, 用户对选定项目评分, 反馈至平台, 此过程不仅指导后续推荐策略, 还重塑用户平台体验, 间接影响未来选择. 循环往复, 形成迭代闭环, 不断精炼推荐精准度与用户满意度, 构建了用户行为与平台响应的动态平衡, 其整体模型如图2.2所示.

### 2.3 平台仿真策略

内容推荐作为连接提供者与用户的关键桥梁, 其核心任务在于策略设计, 旨在平衡双方利益, 追求系统整体效用最大化. 鉴于推荐过程贯穿长期过程, 单纯沿用静态公平原则易滋生累积不公平问题<sup>[29]</sup>, 面对该困境, 创新性地引入长期视角下的重排序框架, 该算法确保提供者曝光机会均衡, 兼顾即时相关性与长期公平, 促进平台生态的可持续发展.

#### 2.3.1 基于提供者公平的重排序算法

曝光分数的计算应综合考虑提供者对长期曝光和短期曝光的综合需求. 在长期背景下, 仅关注长期曝光或短期曝光都是有失偏颇的. 为解决该问题, 构建曝光分数这一综合指标, 其具体计算公式如下

$$\text{Escore}_{p_i} = \lambda \times \text{Escore}_{p_i}^l + (1 - \lambda) \times \text{Escore}_{p_i}^t, \quad (12)$$

其中  $\text{Escore}_{p_i}^l$  和  $\text{Escore}_{p_i}^t$  分别代表提供者  $p_i$  的长期曝光和短期曝光,  $\lambda$  作为系数连结两者形成综合曝光的分数  $\text{Escore}_{p_i}$ . 具体而言, 长期曝光分数旨在揭示提供者在较长时间跨度内的曝光偏移情况, 代表提供者对长期曝光的需求程度, 通过标准化处理, 将长期曝光数  $E_{p_i}^l$  其映射至特定区间, 以直观反映个体与群体间的曝光差异, 其分数越高, 则表示该提供者在长期视角下的曝光机会相较于同行更显不足, 提示系统需采取措施平衡其曝光度, 具体计算如下:

$$\text{Escore}_{p_i}^l = 1 - \frac{E_{p_i}^l - \min_{i=1, \dots, N} (E_{p_i}^l)}{\max_{i=1, \dots, N} (E_{p_i}^l) - \min_{i=1, \dots, N} (E_{p_i}^l)}. \quad (13)$$

其次, 短期曝光分数聚焦于单步推荐场景, 旨在即时捕捉提供者单个时间步内曝光的公平状态, 代表提供者对短期曝光的需求程度. 该分数通过对比单步曝光  $E_{p_i}^t$  与理想平均曝光份额  $E_{\text{mean}}$ , 判断当前推荐操作是否导致了过度曝光或曝光不足, 正值表示曝光欠佳, 需增加曝光机会; 而负值则表示曝光过剩, 系统应适当减缓其推荐频率, 具体计算公式如下

$$\text{Escore}_{p_i}^t = 1 - \frac{E_{p_i}^t}{E_{\text{mean}}}. \quad (14)$$

Boutilier等<sup>[36]</sup>也注意到提供者公平的定义及实现不应仅仅局限于即时曝光, 认为提供者也会关注其内

容的长期互动趋势,因此,长短期曝光实际上是提供者公平性的两个不同层面的表现.随着系统演进,将这两者割裂开来考虑已经不再合适.基于此认识,建立了一个综合指标,旨在同时考量长短期曝光的影响,捕捉并平衡不同时间尺度上的曝光效应,从而更全面地反映提供者的公平性体验.

曝光分数计算框架是持续迭代更新的,可以确保在用户交互的每一瞬间,公平性得以精细考量.每当用户访问平台,触发推荐机制时,系统随即生成定制化的推荐列表,同步记录并更新各提供者在本轮交互中的曝光状态.这一过程实时反映了提供者曝光情况的变化,为后续用户的个性化推荐提供了动态调整依据.具体而言,随着新用户随机抵达,平台基于前序用户的互动数据,即时重算提供者的曝光分数,形成新一轮推荐的基础.此闭环迭代流程,不仅在连续的时间步骤间保持了曝光公平性的连贯性,更在每个步骤内部实现了动态微调,确保每一步骤内的曝光决策均基于最新、最精准的用户反馈,实现了时间步间和时间步内实现了双重动态性.在Patrode等<sup>[29]</sup>的研究中,提出了一个类似的公平调节机制.他们的方法采用了先分配后调整的策略,目的是确保每位用户都能获得等长的推荐列表.为了实现更精确的曝光控制,此处的框架将提供者的曝光更新精细地融入到了时间步和用户层面的每一个环节,从而实现了时间和用户层面的双重动态性.

### 2.3.2 用户相关和提供者公平的权衡

引入权衡系数 $\omega$ 以实现用户偏好与提供者公平之间的权衡.为此,针对每个用户 $u_i \in U$ ,定义其对内容 $c_j$ 的综合评分 $\text{Score}_{c_j}$ 作为推荐决策的关键依据,其主要包含两部分,第一部分为用户相关性 $\text{Uti}_{u_i c_j}$ ,通过矩阵分解预测的用户 $u_i$ 对内容 $c_j$ 的评分,量化了内容与用户兴趣的匹配度,第二部分为提供者曝光公平性 $\text{Escore}_{p_{c_j}}^{\text{Nor}}$ ,即标准化处理后的提供者 $p_{c_j}$ 曝光分数,确保其与用户评分维度一致,便于直接比较.这两部分通过权衡系数 $\omega$ 融合,表达式为

$$\arg \max_{c_j \in C_{u_i}} \text{Score}_{c_j} = \omega \times \text{Uti}_{u_i c_j} + (1 - \omega) \times \text{Escore}_{p_{c_j}}^{\text{Nor}} \times 1_{\{p_{c_j} \in P\}}, \quad (15)$$

其中 $1_{\{p_{c_j} \in P\}}$ 是一个指示函数,用于判断内容 $c_j$ 对应的提供者 $p_{c_j}$ 是否属于当前用户未被推荐的提供者列表 $P$ 中, $C_{u_i}$ 为用户 $u_i$ 的初步候选内容集.

推荐过程遵循贪婪算法,每次迭代都会从候选集 $C_{u_i}$ 中挑选出综合评分最高的内容,逐步构建最终推荐列表 $R_{u_i}$ .为保证推荐的多样性,在推荐列表中尽可能不要出现相同提供者内容,因此一旦某个内容被选入 $R_{u_i}$ ,其提供者随即从可推荐提供者序列 $P$ 中移除,此后,该提供者的曝光分数计算中, $1_{\{p_{c_j} \in P\}}$ 值变为0,显著降低了其内容再次被推荐的概率.最后在满足推荐列表长度时,迭代停止,得到最终推荐列表.Liu等<sup>[37]</sup>也考虑一种公平感知的重排序算法,该算法被应用于小额借贷推荐场景中平衡小额借贷推荐场景下,旨在平衡排序质量和借款方的公平性.相比之下,为解决内容平台中推荐相关性与提供商公平性,此处设计了一个重排序框架,并将其放置在动态情境中,以实现其在长期背景下的调节和优化.

本文的重排序算法流程为:

**步骤1** 初始化 $\text{Exp}_p^t = 0$ .

**步骤2** 对于随机到达的每个用户,根据式(13)和式(14)为每个提供者更新长期曝光分数 $\text{Escore}_p^l$ 和短期曝光分数 $\text{Escore}_p^t$ ,根据式(12)计算曝光分数 $\text{Escore}_p$ ,然后迭代生成推荐列表,根据式(15)计算并选取分数 $\text{Score}_c$ 最高的内容加入列表,直到推荐列表为指定长度,同时从候选集和提供者集中移除选中的内容和提供者.

**步骤3** 对每一个用户推荐后更新曝光数据,多次循环直到所有用户都处理完毕.

## 3 仿真实验

### 3.1 实验说明

前期实验所得的提供者曝光与用户效用为基点,细致探讨平台策略对其生态平衡的微妙影响.为深入解析平台在提供者与用户间的偏好平衡,特设五种代表性策略,旨在长远视角下,观测每种策略对个体与系统

全局的持久效应, 并进而挖掘平台的最优策略. 首先, 引入一种融合长期与短期曝光考量的动态排序机制. 此机制通过调节长期与短期曝光的比重, 从0至1渐进变换, 考察在不同权重下, 长期曝光与短期曝光波动性的变化, 以筛选出最适宜的均衡系数, 进而计算得到曝光分数. 继而, 我们将注意力转向提供者曝光与用户偏好间的协同作用. 在已确立的曝光评分基础上, 进一步整合用户相关性, 监控提供者流失率、用户信任水平、推荐接受率等关键指标的动态演变, 剖析不同策略对平台生态健康的影响. 设定涵盖提供者优先、用户优先、提供者和用户均衡、均衡下用户优先、均衡下提供者优先在内的五种策略模型, 借此洞察各类策略的长远影响力, 并特别聚焦于用户导向策略的细化研究, 以此探究平台的最优策略. 研究依托Movielens数据集展开, 选取两个有代表性的不同规模的数据集, 分别是经典的Movielens 1M数据集和最新的Movielens Small数据集. 其中Movielens 1M数据集有6 000名用户以及4 000个内容, 为了与第二个数据集对应, 随机选取其中的610名用户; Movielens Small数据集有610个用户以及9 742个内容, 其中610个用户看做一类智能体用户, 而另一类智能体提供者则是通过合成数据生成并分别将4 000和9 742个内容随机无重复分配给对应的提供者, 具体实验参数如表1所示.

表1 模拟参数表  
Table 1 Simulation parameters

参数	参数表示	参数数量
用户数量	$M$	610
提供者数量	$N$	300
内容数量	$I$	4 000/9 742
推荐列表长度	$K$	10
意识集大小	$A$	200
意识集中流行内容占比	$\gamma_1$	0.4
意识集中相关内容占比	$\gamma_2$	0.45
用户期望阈值百分数	$\psi$	0.96
基于信任的推荐放大系数	$\delta$	8
噪声因子	$\epsilon$	$N(0, 0.1)$

### 3.2 长短期曝光的权衡表现

调整长期曝光和短期曝光的不同权重 $\lambda$ , 观察其长短期曝光的方差, 衡量该方法对提供者公平性的实现程度. 对于提供者而言, 获得低效用的提供者可能会离开生态系统, 其效用的方差与均值一样重要<sup>[31]</sup>, 其效用与其获得的曝光程度直接关联, 因此本节对Movielens 1M与Movielens Small数据集进行了300个时间步的模拟实验, 观察提供者短期与长期曝光的方差演变轨迹, 如图3与图4所示. 从图中可以看出, 不同内容规模的数据集在特征上表现一致, 但内容量大的数据集(即Movielens Small数据集)因内容量丰富, 外部扰动或内生噪声往往能够通过整体的统计规律被平滑或抵消, 最终表现为方差曲线更平稳、收敛更快; 而内容量小的数据集(即Movielens 1M数据集)由于提供者可提供的内容较少, 中用户与提供者可交互的次数较少, 最终表现为方差曲线波动较大且不够稳定.

图3(a)与图4(a)追踪每一时间步后的短期曝光方差. 由图可以看出, 图中所有的权衡策略都在向低方差收敛, 只是起点和收敛速度有所差异. 当短期公平分配的权重越大, 即越关注短期公平, 其起点方差越低且越容易收敛至低点, 在只关注短期公平的权重下, 即 $\lambda = 0$ , 平台在推荐时期望实现每一步的曝光公平. 反之如果越关注长期公平, 其短期公平波动在开始时极大, 例如只关注长期曝光的场景下, 即 $\lambda = 1$ , 提供者会因为要满足长期曝光而进行补偿性曝光, 导致在推荐初期其曝光方差十分大, 虽然在后续随着对长期曝光偏差的满足其方差也趋于平稳, 但在曝光初期的不平衡曝光会导致提供者流失不利于平台的生态稳定. 图3(b)和图4(b)为提供者的长期曝光表现, 随着时间变化, 对长期曝光的不同关注会产生不同的收敛速度. 越

关注长期曝光,其收敛速度越快,在只关注长期曝光的情境下, $\lambda = 1$ ,长期曝光的方差会以最快速度收敛至低点,反之,如果只关注短期曝光,即 $\lambda = 0$ ,为满足短期曝光其长期曝光反而加剧,导致长期曝光的偏差会始终无法调和.综上所述,长期视角下,长期与短期曝光的调和需经历时间考验,更关注长期曝光会使长期曝光的方差收敛越快,更关注短期曝光会使短期曝光表现更平缓,但如果过于激烈的调整方式,会使平台动荡,提供者能够强烈的感知到平台的不公平行径,对平台失去信心而离开平台.

因此,多边平台需采用权衡策略平衡用户与提供者利益.面对多边平台中用户和提供者目标不同的情境,仍需考虑双方角色的需求,避免因单边倾斜导致生态失衡,增强平台长期竞争力.面对该问题,平台可以建立动态评估机制,实时监测用户满意度与提供者留存率,基于此及时调整平台的策略,实现对用户和提供者的有效维护.



图 3 Movielens 1M不同权重下的公平权衡图

Fig. 3 Movielens 1M fairness trade-offs under different weights




图 4 Movielens Small不同权重下的公平权衡图

Fig. 4 Movielens Small fairness trade-offs under different weights

为此,寻求平稳过渡的折衷策略尤为关键. $\lambda = 0.6$ 的设定下,不仅可以实现快速收敛,且长期曝光亦能平稳且迅速接近低方差状态,证实了该参数选取在确保长期短期曝光均衡方面的有效性,因此选用 $\lambda = 0.6$ 作为后续实验计算曝光分数的参数.

### 3.3 用户相关与提供者公平的策略权衡表现

权重 $\omega$ 用来调节用户偏好和提供者公平之间的矛盾.权重 $\omega$ 的不同设置,实质上描绘了平台在不同策略下的侧重点,通过将用户追求的内容相关性指标与提供者追求的公平性指标进行量化,并借助权重 $\omega$ 进行权衡,来对比寻求平台的优质权衡点.首先设计了5种对于提供者和用户不同关注的策略,分别为提供者优先策略( $\omega = 0$ )、均衡下提供者优先策略( $\omega = 0.2$ )、提供者和用户均衡策略( $\omega = 0.5$ )、均衡下用户优先策略( $\omega = 0.8$ )、用户优先策略( $\omega = 1$ ),在两种不同规模的数据集中,每种策略均分别历经600轮和1450轮迭代,观察其对关键性能指标的长远影响.

在多利益相关者框架下,推荐系统的评估超越了一维视角,转向多维分析,旨在全面衡量各参与者在平台互动中的获益情况.传统评价指标,诸如RMSE、precision、NDCG、diversity等都是从用户的角度评价推荐系统性能的不同方法.这些指标只是从侧面刻画了用户角度的效用,如果从更深层次的去挖掘,推荐系统服

务于用户的本质是期望提高用户对推荐平台的信任, 及其对推荐的接受程度. 在用户角度, 关注用户对平台的信任程度, 即式(5)定义的 $c_{u,t}^{trust}$ , 由于用户信息获取渠道多元化, 信任度直接影响用户对推荐内容的接受程度, 因此同样关注推荐接受率, 无论是用户信任还是对推荐的接受率, 都需要对所有用户进行平均, 观察所有用户的集中趋势. 针对提供者层面, 获得低效用的提供者可能因为曝光不足而离开平台, 因此这里同样关注提供者的流失率, 因曝光不足引发的高流失率映射出平台策略的不公, 反之, 低流失率彰显平台成功维护提供者公平曝光的能力, 具体而言, 就是通过流失的提供者数除以总提供者数计算得到.

从图5和图6中可以看出, 在不同规模的数据集下, 图像表现出相似的变化特征, 但内容量大的数据集(即Movielens Small数据集)因内容数据样本充足而显著降低了随机波动的影响, 能够更稳定地捕捉复杂系统的规律; 相比之下, 内容量小的数据集(即Movielens 1M数据集)受限于个体行为的统计偏差和噪声干扰, 易导致模拟结果的长期稳定性和可靠性下降. 从平台角度出发, 应综合观察平台生态中的用户和提供者两方的表现. 首先关注推荐接受率的表现, 推荐接受率是每一轮用户选择平台推荐项目的概率, 即图5(a)和图6(a), 考虑到用户选择行为的随机性质, 原始数据波动剧烈, 图中展现的已是经过平滑处理的结果, 而阴影区域则准确勾勒出波动的边界. 其次是提供者流失率表现, 直观反映为图5(b)和图6(b)中随时间推移提供者退出的比例, 值得注意的是, 图6(b)中仅显现三条曲线, 分别是用户优先策略代表的曲线、均衡下用户优先策略代表的曲线, 以及一条象征提供者优先策略下流失率为零的直线, 实际上, 均衡策略与均衡下用户优先策略的轨迹与提供者优先策略的零流失率线几乎重叠, 暗示以上两种策略策略下提供者群体的稳定性, 而在内容量小的数据集图5(b)中, 均衡策略下提供者流失率逐渐增大, 则是由于提供者拥有的内容较少, 群体的稳定性不足. 最后, 由于推荐接受率曲线受概率波动影响大, 不容易观察其变化, 因此我们综合观察用户信任, 如图5(c)和图6(c), 用户信任直接影响用户是否接受平台推荐, 因此这一指标成为评判策略长期效果的重要尺度.




图 5 Movielens 1M不同推荐策略下长期表现图

Fig. 5 Movielens 1M long-term performance of different recommendation strategies

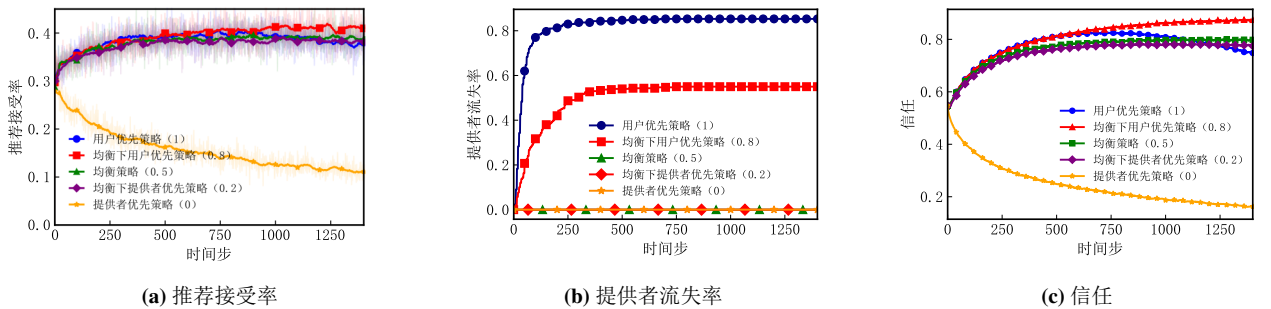


图 6 Movielens Small不同推荐策略下长期表现图

Fig. 6 Movielens Small long-term performance of different recommendation strategies

用户和提供者的矛盾并非完全不可调和的, 通过合理平衡提供者曝光公平与用户需求, 可以有效调和用户与提供者之间的潜在矛盾, 促进平台生态的健康稳定发展. 对比提供者优先的策略及均衡下提供者优先

策略( $\omega = 0.2$ )、提供者和用户均衡策略( $\omega = 0.5$ ),可以发现,如果只关注提供者而全然不考虑用户体验,用户对推荐的接受程度及用户对平台的信任程度都会随着时间大幅度下降,而提供者流失水平会保持在零点,说明用户对平台的信任以及对平台推荐的接受程度都会因随着用户体验不好而大幅下降,但提供者会因相对公平的曝光而留在平台.而观察均衡下提供者优先策略、提供者和用户均衡策略,可以发现推荐接受率与用户信任度均维系在理想状态,与此同时,提供者流失率亦锚定于零点,说明通过合理权衡,用户和提供者之间矛盾可以得到缓和,平台在确保提供者曝光公平的同时,优先推荐内部优质内容,既满足了用户的本质需求,又保障了提供者群体的稳定.进一步微调使其更偏向于用户,虽仅带来用户信任的细微增加,但此类均衡导向的策略已充分证实,其可以在有效维系提供者在平台上的持续参与的同时满足用户的基本需求,构筑平台与用户、提供者共赢的良性循环.现有的方法往往在损失推荐性能的情况下提高推荐的公平性,并且许多研究已经揭示了这种公平性和性能之间的权衡,其更多的在静态的情境下探究用户相关和提供者公平的折衷方案,而此处面向动态场景,且更多的立足于平台的视角,通过提供者流失率与用户接受度综合指标,探讨提供者与用户的核心矛盾,因此可以得出两者矛盾并非完全不可调和的矛盾.

用户优先的策略长期反而损害用户信任与推荐接受度.常理来说,只关注用户会带来更好的用户体验,但实际上从内容量大的数据集的长期模拟图6(a)和6(c)可以清晰的看见,用户优先策略( $\omega = 1$ )代表的曲线在迭代之初缓步上升,但随着时间的流逝,其推荐接受率与信任反而出现了下降的情况,尤其观察图6(c),可以清晰的看到,用户信任在前600步稳步上升,与均衡下用户优先策略( $\omega = 0.8$ )表现基本持平,在600步之后,其用户信任不升反降,在1600步迭代结束时,其用户信任已降至低于其他均衡策略,与之对应用户对平台推荐的接受程度也大幅削弱,而在内容量小的数据集图5(c)中,在300步之后用户信任就迅速下降,因此也能够看出,用户信任也与提供者拥有的内容相关,拥有更多内容的提供者能够减缓用户信任的下降速度.

不同程度的用户导向会带来不同的效果.深入探究用户导向策略的细微差别,进一步细化系数 $\omega$ 的设置,分别为0.7、0.8、0.9及1,每一数值标示着对用户关注度的递增梯度,其长期表现如图7和图8所示.在图8中,从 $\omega = 0.7$ 微调至 $\omega = 0.8$ ,用户信任度迎来显著提升,然而这一变化是以提供者利益的缩减为代价的,直观表现为提供者流失率自零激增至约50%.此阶段表明,尽管用户与提供者双方的满足并非全然不可兼得,但在追求任一方显著获益时,另一方的损失无可避免.进一步,当策略从 $\omega = 0.8$ 微调至 $\omega = 0.9$ ,提供者流失率再度攀升约20%,但此时用户信任并没有获得显著提升,甚至随着时间的流逝, $\omega = 0.9$ 时的策略在1000个时间步后表现略逊于 $\omega = 0.8$ 的策略,同样当 $\omega = 1$ 时,即完全考虑用户时,提供者流失率有增加了近20%,与此同时,用户信任在600个时间步后竟出现逆向下滑的态势.

完全的用户导向导致其信任下降是由于优质供给流失.从流失提供者内容质量的独特视角切入,深入剖析上述现象背后的成因,揭示问题本质.图9和图10分别给出了两个数据集上, $\omega = 0.8, 0.9, 1$ 三种情形下的提供者内容质量表现,两个图都表现出来相同的趋势.蓝色点状标记标识决定离开的提供者,横轴展现其离开时间,纵轴则表示其离开时内容质量水平.以图9为例,图9(a)中, $\omega = 0.8$ 时所有流失提供者的内容质量均在平台现有提供者的内容质量均值之下,且分布相对稀疏,图9(b)中,即 $\omega = 0.9$ 时其流失提供者也基本在均值线之下,但其部分点位紧贴均值线,图9(c)中,即 $\omega = 1$ 时大量流失提供者内容质量超越均值线,甚至个别点位超越留存提供者.总体来看, $\omega = 0.8$ 时虽然有一部分提供者离开了平台,但其内容质量都是明显低于平均水平的,也可以看做平台自动将一部分内容质量不够优的提供者筛选出平台,仍然留下了足够多的提供者足以平台提供推荐,因此其用户信任一直处于稳步攀升的状态.而 $\omega = 0.9$ 时提供者流失数量增多,其平台现有所有提供者内容质量均值附近小蓝点增多,有一小部分中等内容质量的提供者离开平台,导致最后平台在推荐时推荐质量没有 $\omega = 0.8$ 时更优,其用户信任出现增长乏力的情况.最后 $\omega = 1$ 时大量提供者流失,有一大部分提供者内容质量高于均值,说明在提供者大量流失的情景下,有部分优质提供者流失,因此在此时只关注用户的策略下,用户在开始时信任稳步上升,表现良好,但随着时间步的推进,由于其完全不考虑提供者体验,部分优质提供者及其内容离开平台,导致平台优质供给不足,反而导致用户信任下降.




图 7 Movielens 1M用户相关下各推荐策略下长期表现图

Fig. 7 Movielens 1M long-term performance of different recommendation strategies with a user-centric bias

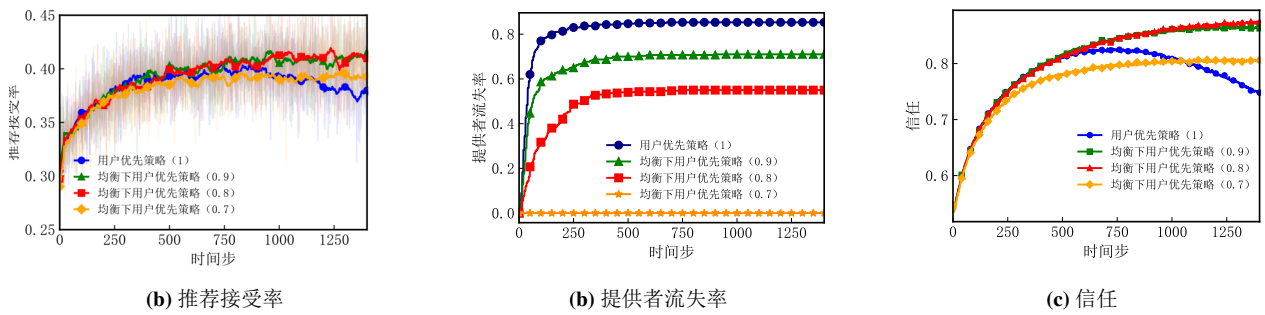


图 8 Movielens Small用户相关下各推荐策略下长期表现图

Fig. 8 Movielens Small long-term performance of different recommendation strategies with a user-centric bias

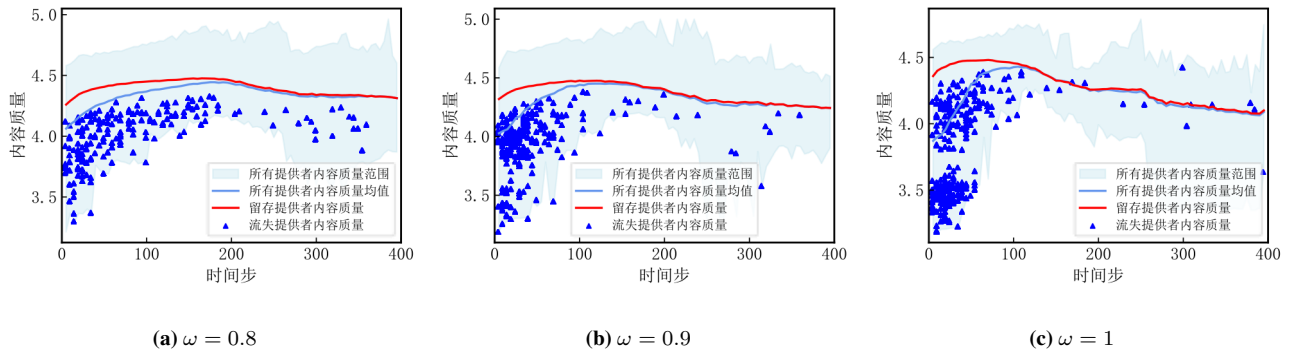


图 9 Movielens 1M用户相关下各推荐策略下提供者内容质量表现

Fig. 9 Movielens 1MContent quality performance of providers under different recommendation strategies with a user-centric bias

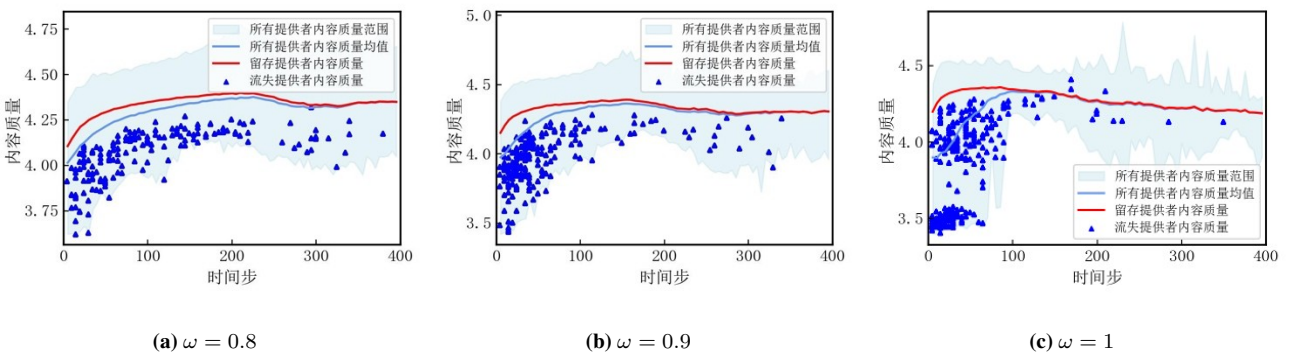


图 10 Movielens Small用户相关下各推荐策略下提供者内容质量表现

Fig. 10 Movielens Small Content quality performance of providers under different recommendation strategies with a user-centric bias

因此,从用户的角度来看,用户主导地位需适度倾斜,但需容忍提供者自然淘汰.用户作为平台价值的最终买单者,其体验和留存直接决定平台规模与收入.适度倾斜用户利益,旨在通过需求端驱动供给端优化.但适度偏向用户可能会导致提供者内部的自然选择,随着平台端对用户的重视程度加深,提供者侧不可避免的受到影响,提供者内部会基于用户倾向优胜劣汰,选取出最符合平台生态的内容.基于此,平台可以通过适度偏向用户实现对提供者的自然选择,进而提高供给质量,形成良性循环.

由此,纯粹用户中心策略虽短期内提振用户信任,但长期来看会导致大量提供者流失平台,优质供给锐减,最终反噬用户信任,而均衡下更偏向用户的策略虽然会使一小部分提供者流失,但这是平台优胜劣汰的自然选择,剩下的内容仍然足以给用户提供优质推荐,实现用户信任的稳步上升.但均衡更偏向于用户也要把握一个度,如果过于偏向用户有可能会筛选掉过多的提供者影响平台供给,导致用户信任增长乏力,而其最终结果是用户使用平台推荐的可能性降低,影响平台生态.近期Ma等<sup>[38]</sup>得出了类似的结论,其通过对比用户中心算法与融合生产者公平约束的先验加权评分系统,揭示出从长远来看,在推荐策略中同时考虑用户匹配效率和生产者结果公平的均衡设计,更能促进平台生态的可持续发展.然而,先前的研究主要聚焦于优化算法框架本身,缺乏对用户和提供者之间均衡策略的演化过程分析.为了弥足其策略探索的不足,从平台策略的角度切入,全面剖析了不同策略对平台整体表现的影响,并提供了直观且有利的证据,表明完全以用户为中心的策略,虽然短期内或许能提升用户信任,但从长期角度看却会侵蚀用户对平台的信任,同时文章进一步从内容供给质量的角度探讨了其与用户信任之间的作用关系.因此,长期生态健康应该优先于短期单边利益最大化,用户和提供者之间的利益权衡并不是一个短期问题,而是一个长期问题,平台应该制定长期发展战略,制定中长期指标关注用户和提供者的生命周期,避免过度忽略一方权益导致平台生态内部供需失衡.

#### 4 结束语

在多提供者情形下聚焦用户目标和提供者目标的权衡问题,探究不同策略的权衡在长期下的动态表现.首先我们将问题细化到长周期下提供者下动态公平的实现,提出了一种长期曝光和短期曝光权衡的动态公平实现方法,实现了时间层面和用户层面双重动态的公平调整方法,能够有效权衡两者之间的公平关系,其次,基于上述得到的提供者的曝光分数与用户相关的不同系数的权衡看作不同的推荐策略,观察不同策略下的多利益相关者情境下的动态变化.

综合考量提供者公平与用户相关,对平台而言,权衡策略展现出了更佳的综合效益.究其根源,提供者公平与用户相关并非截然对立,平台在确保提供者公平的基础上,推荐其内部优质内容,同样能够满足用户的基本需求.尤为关键的是,均衡下用户优先的策略对平台而言最具优势,它能促进用户信任的持续增长,不过,这种偏向性需谨慎控制边界,过度倾斜于用户可能过度筛选提供者,削弱平台供应能力,进而拖累用户信任的提升,影响整体用户体验.针对平台推荐策略的研究得到以下启发:单纯的用户导向会导致提供者流失,在长周期背景下反而影响用户体验,因此在多边平台还是应该尽可能满足两方需求,采用权衡策略对平台来说是最优的;用户作为平台消费主体,占据主导地位,适度偏重用户利益的策略对平台更优,尽管可能伴随提供者的离开,但这是提供者生态中的自然选择.

同时,研究中所进行的模拟仍存在一些局限性,在未来的研究中应该加以解决.首先,该模拟虽尽可能贴近真实情境,但与真实情境仍有较大差距.比如假设提供者提供的内容具有唯一独特性,但可能在真实场景下,内容平台中的内容存在互补、替代等复杂关系,这类关系的处理仍需进一步探究;本文目前还无法适应动态环境(如用户需求突变、供给端波动),后续工作可以基于此进一步探索动态调整策略,可以结合实时数据反馈优化权重分配,提升平台自适应性.同时真实场景下,会存在内容的更新和生产,提供者可能会依据用户的参与情况调整其内容的生产,因此,后续工作仍需在此研究基础上进一步深化,尽可能贴近真实情境.其次,在实际平台生态中,拥有不同用户和内容体量的平台面对提供者流失的现象可能有不同的反应,

目前运用现有数据集实现模拟方法, 该问题超出了我们当前研究的范围, 留待未来的工作。最后, 本文仅考虑的电影的内容平台, 其他类型的内容平台, 如音乐、游戏或社交媒体, 未来的研究可以进一步探讨这些领域, 以了解是否可以采用类似的策略, 或是否需要针对每种独特的情境制定专门的方案。

### 参考文献:

- [1] Burke R, Abdollahpouri H. Towards multi-stakeholder utility evaluation of recommender systems // *User Modeling, Adaptation and Personalization SOAP Workshop*. 2016.
- [2] 李建斌, 钱自顺, 蔡学媛, 等. 跨境电商下基于商品属性-情境的推荐算法. *系统工程学报*, 2024, 39(3): 333–343.  
Li J B, Qian Z S, Cai X Y, et al. Recommendation algorithm based on commodity attributes-context under cross-border e-commerce. *Journal of Systems Engineering*, 2024, 39(3): 333–343. (in Chinese)
- [3] Wu Y, Cao J, Xu G, et al. TFROM: A two-sided fairness-aware recommendation model for both customers and providers // *Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval*. Virtual Event Canada: ACM, 2021: 1013–1022.
- [4] Abdollahpouri H, Burke R. Multistakeholder recommender systems // *Recommender Systems Handbook*. New York: Springer, 2021: 647–677.
- [5] Zhou B, Zou T. Competing for recommendations: The strategic impact of personalized product recommendations in online marketplaces. *Marketing Science*, 2023, 42(2): 360–376.
- [6] Sühr T, Biega A J, Zehlike M, et al. Two-Sided fairness for repeated matchings in two-sided markets: A case study of a ride-hailing platform // *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. Anchorage AK USA: ACM, 2019: 3082–3092.
- [7] Mehrotra R, McInerney J, Bouchard H, et al. Towards a fair marketplace: Counterfactual evaluation of the trade-off between relevance, fairness & satisfaction in recommendation systems // *Proceedings of the 27th ACM International Conference on Information and Knowledge Management*. Torino Italy: ACM, 2018: 2243–2251.
- [8] Wang Y, Wang X, Beutel A, et al. Understanding and improving fairness-accuracy trade-offs in multi-task learning // *Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining*. Virtual Event Singapore: ACM, 2021: 1748–1757.
- [9] Sürer Ö, Burke R, Malthouse EC. Multistakeholder recommendation with provider constraints // *Proceedings of the 12th ACM Conference on Recommender Systems*. Vancouver British Columbia Canada: ACM, 2018: 54–62.
- [10] Karakolis E, Kokkinakos P, Askounis D. Provider fairness for diversity and coverage in multi-stakeholder recommender systems. *Applied Sciences*, 2022, 12(10): 4984–5003.
- [11] Rampisela T V, Ruotsalo T, Maistro M, et al. Joint evaluation of fairness and relevance in recommender systems with pareto frontier // *Proceedings of the ACM on Web Conference 2025*. Sydney NSW, Australia: ACM, 2025: 1548–1566.
- [12] Vassøy B, Langseth H. Consumer-Side fairness in recommender systems: A systematic survey of methods and rvaluation. *Artificial Intelligence Review*, 2024, 57(4): 101–162.
- [13] Deldjoo Y, Jannach D, Bellogin A, et al. Fairness in recommender systems: Research landscape and future directions. *User Modeling and User-Adapted Interaction*, 2024, 34(1): 59–108.
- [14] Zhan R, Christakopoulou K, Le Y, et al. Towards content provider aware recommender systems: A simulation study on the interplay between user and provider utilities // *Proceedings of the Web Conference 2021*. Ljubljana Slovenia: ACM, 2021: 3872–3883.
- [15] Mladenov M, Creager E, Ben-Porat O, et al. Optimizing long-term social welfare in recommender systems: A constrained matching approach // *Proceedings of the 37th International Conference on Machine Learning*. PMLR, 2020: 6987–6998.
- [16] Miller J H. *Complex Adaptive Systems: An Introduction to Computational Models of Social Life*. Princeton: Princeton University Press, 2007.
- [17] Garcia R. Uses of agent-based modeling in innovation new product development research. *Journal of Product Innovation Management*, 2005, 22(5): 380–398.
- [18] Schramm M E, Trainor K J, Shanker M, et al. An agent-based diffusion model with consumer and brand agents. *Decision Support Systems*, 2010, 50(1): 234–242.
- [19] Axtell R L, Farmer J D. Agent-Based modeling in economics and finance: Past, present, and future. *Journal of Economic Literature*, 2025, 63(1): 197–287.

- [20] Zhang T, Zhang D. Agent-Based simulation of consumer purchase decision-making and the decoy effect. *Journal of Business Research*, 2007, 60(8): 912–922.
- [21] 罗 杭, 张 毅, 孟庆国. 基于多智能体的城市群政策协调建模与仿真. *中国管理科学*, 2015, 23(1): 89–98.  
Luo H, Zhang Y, Meng Q. Modeling and simulation of multi-cities' policy coordination based on mas. *Chinese Journal of Management Science*, 2015, 23(1): 89–98. (in Chinese)
- [22] 李少英, 黎 夏, 刘小平, 等. 基于就业市场的劳动人口区位选择行为的多智能体模拟. *管理工程学报*, 2013, 27(1): 41–48.  
Li S Y, Li X, Liu X P, et al. Multi-Agent based simulation on residential location selection based on labor market. *Journal of Industrial Engineering and Engineering Management*, 2013, 27(1): 41–48. (in Chinese)
- [23] 李莹莹, 李 英. 基于Agent的手机银行品牌扩散微观模型及仿真研究. *系统工程学报*, 2022, 37(1): 1–11.  
Li Y Y, Li Y. Research on micro-model and simulation of mobile banking brand diffusion based on agent model. *Journal of Systems Engineering*, 2022, 37(1): 1–11. (in Chinese)
- [24] Chica M, Rand W. Building agent-based decision support systems for word-of-mouth programs: A freemium application. *Journal of Marketing Research*, 2017, 54(5): 752–767.
- [25] 王 歌, 张 奇, 李 彦, 等. 区块链共享模式下的分布式光伏扩散演化模拟. *系统工程学报*, 2024, 39(2): 189–199.  
Wang G, Zhang Q, Li Y, et al. Simulation of the distributed PV diffusion under blockchain sharing. *Journal of Systems Engineering*, 2024, 39(2): 189–199. (in Chinese)
- [26] Zhang J, Adomavicius G, Gupta A, et al. Consumption and performance: Understanding longitudinal dynamics of recommender systems via an agent-based simulation framework. *Information Systems Research*, 2020, 31(1): 76–101.
- [27] Zhou M, Zhang J, Adomavicius G. Longitudinal impact of preference biases on recommender systems' performance. *Information Systems Research*, 2023: isre.2021.0133.
- [28] Ghanem N, Leitner S, Jannach D. Balancing consumer and business value of recommender systems: A simulation-based analysis. *Electronic Commerce Research and Applications*, 2022, 55: 101195.
- [29] Patro G K, Biswas A, Ganguly N, et al. FairRec: Two-Sided fairness for personalized recommendations in two-sided platforms // *Proceedings of The Web Conference 2020*. Taipei Taiwan: ACM, 2020: 1194–1204.
- [30] Alslaity A, Tran T. Goal modeling-based evaluation for personalized recommendation systems // *Adjunct Proceedings of the 29th ACM Conference on User Modeling, Adaptation and Personalization*. Utrecht Netherlands: ACM, 2021: 276–283.
- [31] Diaz F, Mitra B, Ekstrand M D, et al. Evaluating stochastic rankings with expected exposure // *Proceedings of the 29th ACM International Conference on Information & Knowledge Management*. 2020: 275–284.
- [32] Abdollahpouri H, Adomavicius G, Burke R, et al. Beyond personalization: Research directions in multistakeholder recommendation. *User Modeling and User-Adapted Interaction*, 2020, 30(1): 127–158.
- [33] Wang Y, Ma W, Zhang M, et al. A survey on the fairness of recommender systems. *ACM Transactions on Information Systems*, 2023, 41(3): 1–43.
- [34] Chen G, Zeng F, Zhang J, et al. An adaptive trust model based on recommendation filtering algorithm for the internet of things systems. *Computer Networks*, 2021, 190: 107952.
- [35] Hazrati N, Ricci F. Recommender systems effect on the evolution of users' choices distribution. *Information Processing & Management*, 2022, 59(1): 102766.
- [36] Boutillier C, Mladenov M, Tennenholtz G. Recommender ecosystems: A mechanism design perspective on holistic modeling and optimization // *Proceedings of the AAAI Conference on Artificial Intelligence*. 2024, 38(20): 22575–22583.
- [37] Liu W, Guo J, Sonboli N, et al. Personalized fairness-aware re-ranking for microlending // *Proceedings of the 13th ACM Conference on Recommender Systems*. Copenhagen Denmark: ACM, 2019: 467–471.
- [38] Ma T, Bernstein M S, Johari R, et al. Balancing producer fairness and efficiency via prior-weighted rating system design // *Proceedings of the International AAAI Conference on Web and Social Media*. 2025, 19: 1139–1157.

### 作者简介:

李文华 (1974—), 女, 江西南昌人, 博士, 副教授, 硕士生导师, 研究方向: 推荐系统, Email: liwh@tju.edu.cn;

冯婧妮 (2000—), 女, 浙江金华人, 硕士生, 研究方向: 推荐算法, Email: fjn0620@163.com;

郭均鹏 (1973—), 男, 山东昌邑人, 博士, 教授, 博士生导师, 研究方向: 推荐系统, 运筹与决策, Email: guojp@tju.edu.cn.