

doi:10.19920/j.cnki.jmsc.2023.04.007

共享平台推荐系统对消费者行为影响的实证研究^①

冯路¹, 钱宇^{1*}, 葛昕钰¹, 袁华¹, 吴俊杰^{2,3}

(1. 电子科技大学经济与管理学院, 成都 611731; 2. 北京航空航天大学经济管理学院, 北京 100191;
3. 北京航空航天大学数据智能与智慧管理工业和信息化部重点实验室, 北京 100191)

摘要: 推荐系统(RS)通过分析用户(消费者)数据而向其提供感兴趣的产品信息,这些推荐的产品信息通过改变消费者的(后续)浏览路径以实现推荐目的. 由于相关研究数据的稀缺,以往研究鲜有在考虑“用户(消费者)-平台”关系情况下,探讨RS对平台消费者行为影响的成果. 为弥补这一研究空白,本文提出三个理论假设并实际验证了在“用户(消费者)-平台”亲近性下RS对消费者的信息处理效率、平台访问频率以及购买频率的影响. 提出假设时充分考虑了共享平台的特点,并利用一个家庭厨房共享平台的独特数据集进行实证检验. 研究结果表明,与未采用RS服务的消费者群体相比,采用RS服务的消费者的信息处理效率反而显著降低. 此外,研究结果进一步证实,与平台关系密切且采用RS的消费者具有更高的访问频率和购买频率.

关键词: 共享平台; 推荐服务; 点击行为; 双重差分模型; 倾向值得分匹配

中图分类号: F272 **文献标识码:** A **文章编号:** 1007-9807(2023)04-0132-16

0 引言

在互联网技术的助推下,共享平台在不同的行业 and 市场中迅速蔓延,用于连接各种产品/服务的供应商和消费者^[1]. 一般来说,共享平台有消费者、产品/服务供应商和平台提供商等参与者^[2,3]. 共享平台业务活动呈现的特点表现为上游(供应商)和下游(消费者)的自愿连接^[4,5]. 因此,如何有效连接产品供应商和消费者是平台型企业的主要考虑因素. 为了解决这类问题,被广泛采用的一种方法是将推荐系统(recommendation system, RS)引入在线平台的商务活动中^[6,7].

将RS直接用于改变消费者的信息行为,其方法是使得产品搜索过程变得更加容易,而文献中的大多数研究分别讨论了RS对共享平台上每个参与者的影响. 例如,从产品供应商的角度看,

RS可以帮助卖家快速准确地找到合适的买家,以增加有效产品的展示和交易机会^[8,9];从消费者的角度来看,RS可以减少平台上的搜索摩擦量,以实现更高的决策效率^[10,11]. 正如Jochen等^[12]所指出的共享平台是一个统一的生态系统,任何一方参与者的行为都可能对其他参与者产生影响. 这表明在平台上部署新的服务功能(如RS)可能是一个好的选择. 因而,共享平台更需要从整体的角度来探讨平台的共同发展,如综合考虑下游活动和上游利益的服务^[13,14].

以往的研究结果表明,RS服务不仅对平台有影响(如用户粘性^[15,16]),也对服务提供者产生影响(如销售收入^[17,18]),然而这些影响所产生的路径尚不明确^[19]. 在这个背景下,近些年国外学者分别从平台^[20]、消费者^[21,22]、供应商产品^[23,24]等角度进行了影响路径探索,然而这些

① 收稿日期: 2021-11-24; 修订日期: 2022-09-22.

基金项目: 国家自然科学基金资助项目(91846105; 71671027; 72242101; 72031001; 72021001).

通讯作者: 钱宇(1978—),女,重庆人,博士,副教授,硕士生导师. Email: qianyu@uestc.edu.cn

影响路径均来自于消费者、供应商、平台三者之一,并没有从参与者间的交互关系角度进行影响路径分析.国内近些年关于RS的研究主要在RS的设计和改进行上^[25, 26],只有少量关于RS影响的研究^[27],它们主要从消费者角度进行影响路径分析,也并未探索参与者的交互因素.笔者注意到,从技术角度来看,一个好的RS服务的基础是建立从用户历史数据中学习用户偏好的算法^[28].然而,一个平台能够获得(大量且维度丰富的)用户数据的前提条件是强大的用户与平台的关系^[29, 30].虽然RS能够通过历史数据学习群体用户的偏好,但是在短期内却很难根据用户的行为作出相应改变(算法的更新具有一定的周期性)^[31].因此,与以往的研究很大的不同之处在于本研究中尝试考虑引入“用户(消费者)–平台”的亲近性,而非单独分析某一参与者的因素.其次,与以往研究的不同在于使用数据的独特性.以往研究主要通过实验或问卷获取研究数据,数据量较少,缺乏普适性.本文利用消费者点击流数据^[32, 33],记录了(RS服务发布前后)三类数据:即消费者访问平台的频率、消费者访问产品页面的顺序以及消费者的交易情况.就研究数据而言,本研究能更客观地反映用户的真实行为,因而实验结论更容易被相关学者所借鉴.

在共享经济背景下,虽然RS在共享平台上被积极部署^[34],但是鲜有基于消费者的实际行为数据探讨RS对三方参与者影响的研究.为了填补这一研究空白,本研究与一家在中国处于领先地位的家庭厨房共享平台合作,从该平台上选择了7 984名在线用户(通过使用倾向值得分匹配方法)来检查他们在两周内的行为变化(即RS服务前后的情况).研究发现,平台提供的RS服务使得消费者的信息处理效率不但没有得到改善反而降低了,部分原因是由于RS为消费者提供了获得新产品的机会,而这些新的机会可能会给消费者带来更多的信息加工负担(信息处理成本),比如需要进行更为复杂的产品比较.此外,研究还进一步证实,平台实施RS可以为那些与平台关系密切的消费者提供更好的服务,因为该类消费者为平台提供了额外的数据.与此同时,这些消费者也表现出更高的平

台访问频率和购买频率.

1 相关工作

1.1 推荐系统及其影响

从技术角度讲,RS的设计是为了让消费者更便捷地进行产品搜索,它的构造是根据消费者的兴趣来筛选相关的信息和兴趣爱好在终端用户的个人资料或历史行为中表现出来^[28].在一个数字平台上,平台提供者有能力采集消费者的在线行为数据,然后推出RS以促进上下游交易^[3].因此,RS对平台上的三类参与者都将产生影响.

在当前网络双边市场蓬勃发展的情况下,消费者的搜索成本一直在增加是由于他们有更多的选择可以考虑^[35].随着信息过载在电商环境中的普遍存在,RS被引入电商平台旨在降低消费者的搜索成本^[36]和促进优选产品的发现^[37].沿着这样的思路,对于平台上的消费者来说,RS就有可能支持和提高消费者在网上搜索和选择产品时的决策质量^[38].

平台提供的RS服务将会对上游产品提供商产生显著影响.例如,Pathak等^[17]发现,推荐不仅提高了销售量,而且还为零售商提供了更多的定价灵活性.Oestreicher-Singer和Sundararajan^[39]的研究也显示了RS可以增加销售额的证据.Lee和Hosanagar^[8]使用亚马逊的数据证实RS增加了基线转化率(5.9%).最近的研究结果也表明,RS可能会对零售商和制造商带来利益或造成伤害,这取决于RS的替代效应和需求效应^[40].

此外,Parikh等^[41]的研究表明,决策支持系统的有效性应该以用户满意度和决策效率为标准进行评估.Zhang等学者^[42]也认为,个性化的产品推荐通过消费者在线产品经纪人的效率影响网店忠诚度.Zhang等^[43]的研究结果显示,商品筛选成本和决策质量显著影响了客户忠诚度.

RS应用广泛,很多研究都证明了其有效性,然而RS的影响路径却尚不明确.近些年关于RS影响的研究主要从消费者^[21, 22]、供应商产品^[19, 20]、平台^[24]三者之一入手研究RS的影响路径.例如Mousavi等^[20]研究表明推荐系统会诱导消费者从心理上对产品产生不同的认知和情感,从而影响其决策.胡春华等^[27]研究表明,消费者

教育程度、收入水平、性别、年龄等属性与消费者使用 RS 的意愿相关,从而影响推荐效果. Lee 等学者^[20]认为不同的平台形式(移动端和电脑端)会影响 RS 的效果,从而影响消费者行为. Lee 等^[8]的另一项研究表明,产品的属性和评价会对 RS 效果产生影响. 这些研究都仅从单一的参与者因素角度探索了 RS 的影响路径,并未涉及到参与者之间的交互影响因素.

1.2 实际行为数据

了解用户行为对在线服务的设计和运营非常重要. 在计算机科学中,点击流常常用来建模在线用户的点击事件(动作)序列^[44, 45]. 大量与在线用户行为相关的研究表明,点击流数据可以用来代表用户的实际行为^[46, 47].

网络消费者的一些主要行为构成了 ASBOME 行为序列,顺序为:进入平台 – 搜索产品^[48] – 浏览产品信息^[44, 49] – 获得候选产品^[10, 50] – 做出购买决策^[49, 51] – 退出平台. 据此,每个用户在电商平台上的实际行为可以描述为上述实际行动的一个序列(或子序列). 这为分析用户的在线浏览行为提供了数据来源和路径基础. 例如, Montgomery 等^[52]的研究成果提出,在线浏览路径可能反映用户的目标,而这一点可以帮助预测未来用户的动向和购买转化. 利用一组匹配的线上点击流和线下购买数据, Huang 和 Van Mieghem^[53]实证研究了点击流在改进库存管理方面的价值. 在推荐领域,由于点击流可以揭示用户的偏好以及偏好的转移,因而它成为建立推荐系统有效算法的重要数据来源^[54].

2 研究假设

本研究尝试探索在考虑“用户(消费者) – 平台”亲近性时,平台发布的 RS 服务对消费者、产品提供者、平台提供者的影响(从消费者的实际行为角度). 为此,本文从中国的一个家庭厨房共享平台收集了海量的消费者实际行为数据(点击流). 然后通过建立一系列相关的 DID(双重差分)和 DDD(三重差分)模型来解决这一问题. 本研究的方法在概念上来源于基本的搜索成本理论^[55]和终端用户的计算满意度理论^[56]. 研究模

型的结构如图 1 所示.

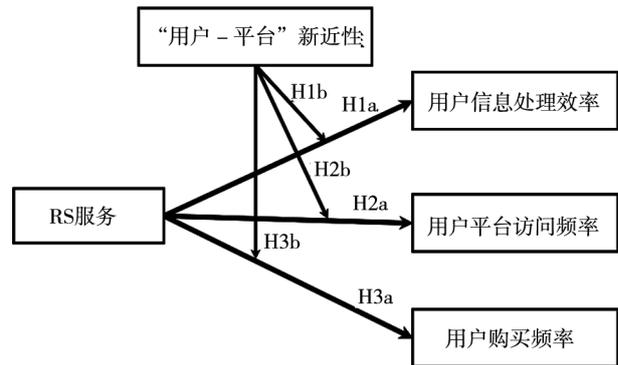


图 1 研究模型

Fig. 1 The research model

2.1 RS 对消费者信息处理效率的影响

由搜索成本理论得知,消费者为了满足自己的需求,不会无休止地搜索^[57];此外,消费者的搜索行为通常是理性的,因而涉及到时间约束和成本收益之间的权衡^[58].

RS 最初被设计用来帮助用户进行在线商业活动,尤其是利用信息检索匹配用户的个人偏好^[28]. 含有 RS 的平台,消费者可以选择跟随 RS 的推荐,或者单独搜索产品^[36, 48]. 因此,可以预计一个 RS 将从两个方面帮助用户在网上发现产品. 首先,当消费者面临许多选择的情况下,如果一个好的推荐被推送给他们,他们则不必广泛地进行产品搜索^[59]. 例如,当 RS 向用户推荐他们感兴趣的内容时,当用户在 YouTube 上搜索一个视频时,他们很可能会转向被推荐的目标,而没有持续的搜索行为. 因而,产品推荐可以减少消费者搜索产品的时间和精力^[38],同时提高他们的决策质量^[10]. 其次,企业和在线中介机构使用 RS 来提供个性化的产品或内容推荐,这可能会吸引部分消费者. 也就是说,RS 具备一种能力,即闯入 ASBOME 行为序列中“A”和“E”之间的任何事件的功能^[59]. 此外,如果 RS 提出的建议符合消费者的需求,它将使消费者查看相应的产品信息^[60],甚至改变消费者当前考虑集的组成^[38]. 也就是说,如果用户对 RS 推荐的结果感兴趣,它将导致用户的行为从序列“B”重新开始重构她/他的后续行为序列.

RS 根据对消费者历史行为的观察提出建议,因此建议与消费者的偏好一致或相关. 在这些情况下,无论信息是由他们自己检索还是由 RS 检

索,消费者都更容易评估一组产品并做出判断。基于以上的讨论和搜索成本理论,提出以下假设:

H1a RS对消费者的信息处理效率有积极影响。

在模型中引入“用户(消费者)–平台”的亲近性,是基于以下考虑:首先,消费者在网上购物时通过隐性和显性反馈来表达他们的偏好,例如,搜索产品^[34]或对已经购买的产品进行评级^[61]。其次,RS的技术基础决定了如果它需要了解消费者的偏好,它就需要收集并使用这些历史行为信息来推断消费者的偏好并自动推荐产品。然而,对于不活跃的用户,该平台只能获得稀少的数据,对其偏好的推断将会是有偏差的。从这个角度来看,平台对那些活跃的、与平台有较高亲近性的用户提供的推荐服务会更有效^[62, 63]。据此,提出如下假设:

H1b RS对那些与平台有密切关系的消费者的信息处理效率有更积极的影响。

2.2 RS对消费者平台访问频率的影响

在互联网的竞争环境中,用户的再次访问被认为是平台服务忠诚度和成功的最重要指标之一^[64]。由于推荐系统的使用减少了用户寻找合适产品的搜索成本,因此预期通过使用RS,消费者应该能够更有效地找到满意产品。进一步,消费者会对他们的选择更有信心,并认为在符合产品推荐的情况下,电子商店会有更高的互动性^[65]。上述研究结果表明,RS的良好性能可以提高用户满意度^[38]。

基于终端用户计算满意度理论,可以预期满意的消费者会有更高的意愿再次访问APP系统^[64]或更高的平台访问频率^[32]。例如,Cheng等^[61]的研究已经表明,RS为用户提供推荐的质量直接影响到用户对推荐系统的接受程度,进而影响到他/她继续与系统互动的意愿。为此,提出以下假设:

H2a RS对消费者的平台访问频率有积极影响。

H2b RS对那些与平台有着密切关系的消费者的平台访问频率有更积极的影响。

2.3 RS对供应商收益的影响

共享平台试图通过RS影响用户的信息获取行为,从而影响用户的购买决策。在文献中,许多

研究已经实证证明了RS对平台供应商销售的积极影响。例如,Oestreicher-Singer和Sundararajan^[39],Pathak等^[17]的研究都证明了RS可以增加供应商的销售额。具体来说,Park和Tuzhilin^[66]研究了改善长尾商品推荐的问题,结果表明RS能够增加小众商品的销售额。Lee和Hosanagar^[8]利用亚马逊的数据证实,RS将在线销售的基准转化率提高了5.9%。同样地,在数字内容平台上,笔者也注意到有许多证据表明,RS促进了消费者的消费,从而推动了产品销售。例如,60%的视频点击量来自于YouTube的主页推荐^[67],在Netflix上观看的80%的电影来自于推荐^[68]。据此,提出以下假设:

H3a RS对消费者的购买频率有积极影响。

这些RS服务的一个共同特点是,在预测用户偏好的过程中涉及大量的消费者–产品数据^[61, 69]。于是,消费者数据对RS显得非常重要。虽然平台可以观察到更多的消费者行为数据,但是消费者的活动行为在一个平台中呈现出非常不均衡的分布规模。对于那些不活跃的用户,由于数据量严重不足,平台所观察的是非常稀疏的数据。因此,由于RS对消费者的偏好有很高的不确定性,不活跃的消费者可能会收到有偏见的推荐建议^[70]。如果消费者体验的产品不符合他们的偏好,那么他们的满意度^[71]和支付意愿^[72]将受到极大的影响,其中消费者的支付意愿与供应商的收益直接相关。因此,基于终端用户计算满意度理论,提出以下假设:

H3b RS对那些与平台有密切关系的消费者的购买频率有更积极的影响。

3 研究背景和数据

本研究中使用的数据集来自于一家中国领先的厨房共享平台,该平台试图在餐饮专业人员或组织(餐饮提供者)和用户(餐饮消费者)之间架起一座桥梁。目前有超过一百万的注册用户。

3.1 研究背景

研究对象是一个基于互联网的家庭厨房共享平台。该平台的上游是各种餐饮服务专业人士(如,专业厨师)和组织(如,小餐馆)。与传统的餐

饮服务供应商不同,该平台上的服务供应商都遵循共享经济的理念^[4,73],往往不具备大规模服务的能力.通常,在经过严格的卫生资质检验之后,这些服务供应商可以在平台上开设“虚拟餐厅”(以下称为在线商店),并在“商店”中显示他们可以提供提供的餐食或服务.

相应的下游用户是有餐饮需求(例如中餐、晚餐、工作餐等)的终端消费者.消费者的消费流程通常是先使用 APP 搜索和浏览在线“虚拟餐厅”,然后选择他们喜欢的服务供应商,接着下单并付款.最后,订购的餐食通过物流系统交付给他们.

可以看到,上述过程与一般的电子商务过程没有太大的差异.特别是,在平台运营的初始阶段,用户非常依赖于在线页面的浏览和产品搜索来找到自己喜欢的产品.因此,随着上游供应商数量的增加,消费者在寻找产品时同样面临电商环境下类似的信息过载问题.为了帮助用户更有效地找到自己喜欢的在线商店和美食,2016年11月30日该共享平台发布了 APP 的版本更新,新版 APP 升级的关键内容是共享平台开始提供推荐(RS)服务.可以知道,与新版本 APP 相比,旧版本的 APP 没有推荐功能.由于更新 APP 软件对于用户来讲是自愿行为,因此,研究者便有机会观察到 RS 对用户在线行为的影响.

3.2 数据

本文收集了来自家庭厨房共享平台上的海量日志文件,这些文件主要记录用户点击行为.用户每次点击都会在日志文件中记录下用户 ID (u_i),点击的商店 ID (s_k),点击时间戳 (t_{ck}),用户设备类型(Android/MacOS)等信息.引入以下形式来定义用户 u_i 第 k 次点击

$$Click_{ik} = (u_i, t_{ck_i}, s_{k_i}, T_{k_i}) \quad (1)$$

其中 $T_{k_i} = t_{c(k+1)_i} - t_{ck_i}$ 表示用户点击两个相邻商店(s_k 和 s_{k+1})的时间间隔,也可以用来表示用户在店铺 s_k 上的停留时间.另外,用户在平台上完成订单后,在后台数据库中会生成购买记录.结合这两个数据源,最终共收集了15 083 493 条用户点击行为数据和331 008 条订单数据.

本研究的目标是分析 RS 对消费者在线行为的影响.为此,利用用户 ID 跟踪线上用户的浏览行为(点击流数据)并与之交易/购买数据相匹配.最终,收集了2016年11月1日—2016年12月

31日之间的数据用于实证分析(包括 APP 软件版本升级前1个月和升级后1个月生成的消费者在线行为数据).其中,本研究将平台更新前后1周的数据用于主模型分析(第5节),前后1个月数据用于平行趋势检验(第7.1节).将一系列基于相同目的(浏览或购买)的点击称为一个会话,为了减少噪音(例如,用户没有退出 APP,会记录一个较长的会话时间),将最长点击间隔设置为30 min(分钟),若超出此时间范围,则认为两次点击处于不同的会话之中.

针对此数据,定义了四类用户.第一类是及时更新的用户,即在2016年11月30日平台发布更新后,在随后的1 d(天)内立即更新的用户;第二类是延迟更新的用户,即在平台发布更新后,第1周正常使用老版本,第2周更新的用户.第三类是放弃更新的用户,即到采集数据结束时(2016年12月31日),都仍未更新的用户;第四类是推迟更新的用户,即在平台发布更新后3周~4周更新的用户.本研究重点关注于前两类用户,这主要是因为后两类用户存在更多无法观测的影响他们是否选择版本更新的因素.

4 消费者的自我选择问题

4.1 RS 影响下的消费者自我选择问题

面对产品推荐,消费者可能有如下反应:要么接受推荐产品,要么拒绝并搜索其他产品,要么离开网站^[36].虽然,本研究简化了研究对象,只研究及时更新和延迟更新的用户,然而他们是否选择更新仍然不是随机事件,依然存在着某些影响其是否选择更新的内生因素.

为了减小消费者的这种自我选择偏误,采用倾向值得分匹配(Propensity Score Matching Method, PSM)^[74]和双重差分模型(Difference-in-Difference Method, DID)^[75]相结合的方法来刻画 RS 和用户行为间的因果关系.PSM 可以建立可靠的对照组^[32],结合 DID 模型,衡量了 RS 更新前后两组消费者,即处理组(更新 APP 的消费者)和对照组(不更新 APP 的消费者)之间的行为差异.

4.2 倾向值得分匹配

与该领域以往的研究方法一致^[76],使用一对

一的最临近匹配方法进行数据预处理。

在选择匹配变量前,首先考虑什么因素可能导致用户延迟更新?主要有两个原因:其一,平台向用户推送更新的时间不同.平台往往会依据不同的用户历史行为,在不同时间给他们推送更新^[87, 88].其二,用户根据自身的使用需求,会选择及时或延迟更新^[86].例如,如果笔者是一个不怎么喜欢吃外卖的用户,即使他知道今天外卖平台发布了更新,也没有多少动力去及时更新。

通过以上分析,可以得知,用户是否及时更新,很大程度上取决于其在平台上的历史行为.这其中数“购买”和“搜索”行为最具代表性.据此,本研究刻画了以下几个变量用于匹配,包括平台发布更新前1个月内用户的总浏览会话数(*SessionCnt*),总订单数(*OrderCnt*),总点击次数(*ClickCnt*),实际购买量(*Amount*)和购买费用(*TotalFee*).值得注意的是,对上述变量进行了自然对数处理,以确保匹配更有意义。

在进行匹配之前,首先用匹配变量与用户是否更新APP进行了逻辑回归分析,结果见表1.从结果可以看出,这些匹配变量对用户是否接受RS都有显著相关性.从某种程度上讲,这表明选择的匹配变量是有效的。

表1 消费者对RS更新的接受程度的Logit回归模型

Table 1 Logit regression model of consumers' acceptance of RS updates

变量	参数	标准差
$\ln(\textit{SessionCnt})$	2.018***	0.073
$\ln(\textit{OrderCnt})$	-0.249*	0.143
$\ln(\textit{ClickCnt})$	-1.020***	0.036
$\ln(\textit{Amount})$	1.128***	0.369
$\ln(\textit{TotalFee})$	-0.996***	0.358
<i>Constant</i>	-1.424***	0.148
<i>AIC</i>	12 690	

注: * $p \leq 0.10$, ** $p \leq 0.05$, *** $p \leq 0.001$.

通过使用一对一的最近邻匹配方法(Nearest-Neighbor Matching),从10 473个用户中匹配了3 992对用户.为了进一步验证匹配质量,进行了平衡测试^[77]和倾向得分分布测试^[74].平衡测试主要比较倾向得分匹配前后各变量的标准化偏差,结果如表2所示.从表2的第5栏中可以看出,匹配后两组用户在各匹配变量上的标准化偏差均不高于20%^[78],这表明在该共享平台上启动推荐功能之前,处理组和对照组的行为没有显著差异.进一步分析表2第6栏中偏误减少的百分比可以看出,本次匹配减少了所有变量的标准化偏差,最大减少了93.8%,这进一步表明本次匹配减少了两组用户间的差异。

表2 PSM匹配前后平衡性检验表

Table 2 Balance check before and after PSM matching

变量	U/M*	Mean(Std.)T		Std. Bias \mp	Bias Reduced	t-test #	
		Control	Treatment			t	$p > t $
$\ln(\textit{SessionCnt})$	U	2.33(0.37)	2.45(0.38)	0.338	56.8%	-16.764	0.000
	M	2.40(0.37)	2.45(0.38)	0.146		-6.526	0.000
$\ln(\textit{OrderCnt})$	U	0.31(0.69)	0.38(0.78)	0.093	37.6%	-4.576	0.000
	M	0.33(0.73)	0.38(0.78)	0.058		-2.584	0.010
$\ln(\textit{ClickCnt})$	U	3.98(0.82)	3.71(0.67)	0.368	93.8%	18.720	0.000
	M	3.69(0.70)	3.71(0.67)	0.023		-1.039	0.299
$\ln(\textit{Amount})$	U	0.93(2.03)	1.11(2.23)	0.083	37.3%	-4.094	0.000
	M	1.00(2.11)	1.11(2.23)	0.052		-2.333	0.020
$\ln(\textit{TotalFee})$	U	0.96(2.09)	1.14(2.28)	0.081	37.0%	-3.967	0.000
	M	1.03(2.16)	1.14(2.28)	0.051		-2.301	0.021

注: U表示匹配前; M表示匹配后; T两组用户匹配前后在各变量上均值和标准差; \mp 标准化偏差; #处理组和对照组之间的均值差异。

倾向值得分分布检验比较匹配前后处理组和对照组之间倾向得分分布的差异.在理想的情况

下,处理组和对照组的倾向得分分布应尽可能相似.在图2中,左侧显示了匹配前处理组(左上)和

对照组(左下)的倾向值得分分布,右侧显示了匹配后处理组用户的倾向得分的分布(右上)和对照组用户(右下).通过比较这两组图的内容,可以看出,在匹配之前,处理组和对照组之间的倾向值分布存在较大差异.但是,匹配后,差异得到了显著改善,并且趋于一致.

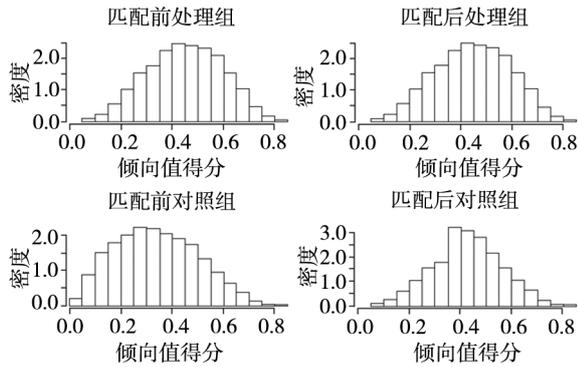


图2 匹配前后倾向得分的分布

Fig.2 Distribution of propensity scores before and after matching

从以上平衡性检验和倾向值得分分布检验结

果可以看出本次研究进行的倾向值得分匹配是有效的.

5 计量模型

下面将分别构建模型来分析RS对用户信息处理效率、访问频率、购买频率的影响.

5.1 双重差分模型(DID Model)

为了刻画用户行为,构建了若干重要变量,其描述性统计见表3,这些变量均是在“周”级别(更新前后)上进行统计.

在这些变量中,使用用户在每次点击停留的平均时间($PerClick = SumTime / SumClick$)来表征用户的信息处理效率.平均停留时间越短,信息处理效率越高.选用用户的浏览会话数($SessionCnt$)来表征用户的访问频率,用订单数($OrderCnt$)来表征用户的购买频率.除此之外,本研究还引入了新店铺的点击次数($NewClick$)作为控制变量.

表3 主要变量的描述性统计

Table 3 Descriptive statistics of the main variables

变量	描述	数量	最小值	最大值	均值	标准差
$SumTime$	在平台上花费的总时间(秒)	15 968	0	56 112	1 027.5	1 640.8
$SumClick$	总点击数(次)	15 968	1	443	14.08	17.0
$PerClick$	每次点击停留的平均时间(秒/次)	15 968	0	975.25	64.71	68.83
$NewClick$	点击的新店铺数(次)	15 968	0	390	5.23	8.17
$SessionCnt$	浏览会话数	15 968	1	51	3.52	2.63
$OrderCnt$	订单数	15 968	0	13	0.36	1.00

本研究使用双固定效应模型来估算平台提供RS服务对用户信息处理效率、访问频率和购买频率的处理效应.模型如下

$$Y_{it} = \alpha_0 + \alpha_1 After_{it} + \alpha_2 Treat_i + \alpha_3 After_{it} \times Treat_i + X_{it} \times \gamma + \mu_i + \theta_t + \varepsilon_{it} \quad (2)$$

其中 Y_{it} 表示 $\ln(PerClick)_{it}$ 、 $\ln(SessionCnt)_{it}$ 或 $\ln(OrderCnt)_{it}$, $After_{it}$ 和 $Treat_i$ 都是哑变量, $After_{it} = 1$ 表示用户 i 的行为发生在RS更新之后(2016年11月30日后1周),而为0表示发生在RS更新之前(2016年11月30日前1周); $Treat_i = 1$ 表示用户 i 在处理组中,0表示在对照组中. X_{it} 为控制

变量,在本研究中是指点击的新店次数 $\ln(NewClick)_{it}$. μ_i 是不可观测的个体差异, θ_t 是时间固定效应.从模型可以看出, $After_{it} \times Treat_i$ 的系数即是处理效应.

5.2 三重差分模型(DDD Model)

基于以往的研究,本研究刻画了消费者与共享平台的关系,并基于此对用户进行了分类.这种关系可以用三个维度来描述,即关系强度^[32],关系广度^[79]以及购买量^[80].表4中列出了这三个维度的衡量指标及其描述,这些指标是基于平台更新(2016年11月30日)前所有数据计算得出.

表 4 消费者与共享平台之间关系的三个维度

Table 4 Three dimensions of the relationship between consumers and sharing platforms

维度	指标	指标	描述
关系强度	访问会话数	Visiting sessions	更新前, 用户访问平台的会话总数
	平均会话时间	Average duration	更新前, 用户会话的平均持续时间
关系广度	访问商店数	Average shops	更新前, 用户会话访问的平均商店数量
购买量	平均订单数	Average orders	更新前, 用户会话的平均订单数

为了进一步探讨 RS 对不同类型用户信息处理效率以及访问、购买频率的影响差异, 利用表 4 中的第 k 个指标 ($k = 1, \dots, 4$) 的中位数将用户分为两类: 第 k 个度量值大于中位数的用户被划分为 N_K^H 组, 第 k 个度量值小于中位数的用户被划分为 N_K^L 组. 接着, 采用三重差分模型 (DDD) 来衡量处理效应在不同人群中的差异. 模型的定义如下

$$Y_{it}^{KH} = \beta_0^{KH} + \beta_1^{KH} After_{it} + \beta_2^{KH} Treat_{it} + \beta_3^{KH} After_{it} \times Treat_{it} + \mu_i^{KH} + \theta_t + \varepsilon_{it}^{KH}, i \in N_K^H \quad (3)$$

表 5 DID 模型实验结果

Table 5 DID experiment results

变量	ln(PerClick)		ln(SessionCnt)		ln(OrderCnt)	
	(i)	(ii)	(iii)	(iv)	(v)	(vi)
	模型(2)	模型(4)	模型(2)	模型(4)	模型(2)	模型(4)
$After \times Treat$	0.117 ** (0.046)	0.105 ** (0.043)	0.176 *** (0.014)	0.171 *** (0.012)	0.011 * (0.006)	0.01 * (0.007)
ln(NewClick)		0.527 *** (0.018)		0.225 *** (0.005)		0.032 *** (0.003)
R^2	0.001	0.117	0.025	0.258	0.001	0.023
N	15 968	15 968	15 968	15 968	15 968	15 968

注: * $p \leq 0.10$, ** $p \leq 0.05$, *** $p \leq 0.01$.

类似地, 对比表 5 中列 (iii) 和列 (iv) 以及列 (v) 和列 (vi) 结果可以得到结论: RS 能显著提升用户的访问频率 $\ln(SessionCnt)_{it}$ 和购买频率 $\ln(OrderCnt)_{it}$, 因此, 支持假设 H2a 和 H3a. 通过列 (iv) 和列 (vi) 中控制变量 $\ln(NewClick)_{it}$ 的表现

$$Y_{it}^{KL} = \beta_0^{KL} + \beta_1^{KL} After_{it} + \beta_2^{KL} Treat_{it} + \beta_3^{KL} After_{it} \times Treat_{it} + \mu_i^{KL} + \theta_t + \varepsilon_{it}^{KL}, i \in N_K^L \quad (4)$$

其中 Y_{it} 表示 $\ln(PerClick)_{it}$ 、 $\ln(SessionCnt)_{it}$ 或 $\ln(OrderCnt)_{it}$.

6 实证结果

6.1 双重差分模型结果

表 5 是模型 (2) 的结果. 首先, 对比列 (i) 和列 (ii), 当引入新店点击次数 $\ln(NewClick)_{it}$ 后, 模型拟合优度显著提升, 并且处理系数和控制变量均显著. 这说明, 及时更新的用户 (处理组) 在短期 (1 周) 内平均每个店的停留时间会有显著提升, 也即是表明其信息处理效率降低了. 因此, 不支持假设 H1a. 该结论与传统的 RS 会提升用户信息处理效率的结论相反. 通过列 (ii) 的结果, 可以猜想, 之所以会出现这个结果, 部分原因是由于推荐系统给用户带来了更多浏览新店铺的机会. 而相比传统电商平台, 本研究的家厨共享平台下的用户在下单前对自己的需求并不明确, 加之商家间的产品差异性较大, 当有新的店铺推荐给用户后, 会使得用户花费更多的时间去浏览新店铺, 而这些新店铺往往对用户来说是不熟悉的, 从而降低了其信息处理效率.

可以推测, 本研究背景下的 RS 在短期内 (1 周) 提升了用户对新店的访问频率和购买频率. 这说明消费者具有较强的尝鲜欲望.

6.2 三重差分模型结果

为进一步研究共享平台上的 RS 服务如何影响

不同类型用户的信息处理效率和访问、购买频率,根据消费者更新前与平台的关系将其分为“高”、“低”

两类(以关系度量指标的中位数为界),然后用两个 DDD 模型来探索该问题.实验结果见表 6~表 8.

表 6 用户信息处理效率($\ln(PerClick)$)的 DDD 模型结果

Table 6 DDD model results for Information processing efficiency of consumers ($\ln(PerClick)$)

变量	访问会话数		平均会话时间		访问商店数		平均订单数	
	高	低	高	低	高	低	高	低
$Aflie \times Treat$	0.079	0.151 **	0.11 **	0.109 *	0.099 *	0.099	0.078	0.109 **

注: * $p \leq 0.10$, ** $p \leq 0.05$, *** $p \leq 0.01$.

表 7 用户访问频率($\ln(SessionCnt)$)的 DDD 模型的结果

Table 7 DDD model results for platform-accessing frequency of consumers ($\ln(SessionCnt)$)

变量	访问会话数		平均会话时间		访问商店数		平均订单数	
	高	低	高	低	高	低	高	低
$Aflie \times Treat$	0.209 ***	0.134 ***	0.183 ***	0.156 ***	0.196 ***	0.146 ***	0.162 ***	0.174 ***

注: * $p \leq 0.10$, ** $p \leq 0.05$, *** $p \leq 0.01$.

表 8 用户购买频率($\ln(OrderCnt)$)的 DDD 模型结果

Table 8 DDD model results for ordering behavior of consumers ($\ln(OrderCnt)$)

变量	访问会话数		平均会话时间		访问商店数		平均订单数	
	高	低	高	低	高	低	高	低
$Aflie \times Treat$	0.015 *	0.006 *	0.026 ***	-0.005 *	0.02 **	0.001	0.048 *	0.002 *

注: * $p \leq 0.10$, ** $p \leq 0.05$, *** $p \leq 0.01$.

表 6 中前两列和最后两列结果表明,用户信息处理效率降低主要是由于更新前会话总数 ($Visiting\ Sessions$) 和会话平均订单数 ($Average\ Orders$) 低的用户导致的.这可能是由于这些用户相比其他用户而言对平台熟悉程度较低,当推荐给他们新店铺后,他们需要花费更多精力去处理信息.而对于其他分组,两组用户的表现均没有显著差异.并无证据表明与平台亲近性较高的用户信息处理效率降低较少,因此,不支持假设 H1b.

表 7 和表 8 中的结果表明,RS 服务对两种类型的用户的访问频率和购买频率都有积极显著的影响.这意味着在 RS 实施更新之前与平台亲近性较高的用户更愿意更加频繁地访问平台,并愿意在 RS 服务的作用下产生更多的订单.根据以上结果,支持假设 H2b 和 H3b.

7 鲁棒性检验

由于用户是否选择更新并非是随机的,为了进一步验证平台更新对用户行为的影响,进行了如下鲁棒性实验.

7.1 平行趋势检验

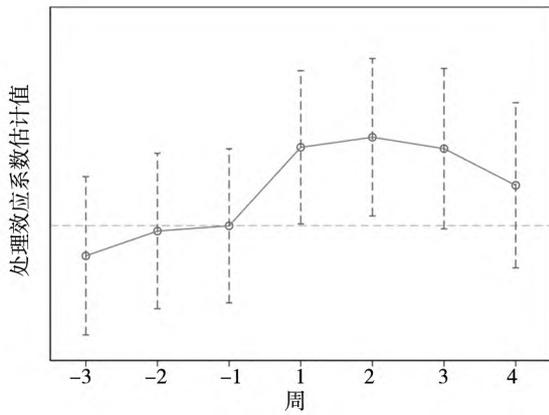
处理组和对照组间的事前平行趋势,是运用双重差分法的重要前提假定.借鉴 Liu 和 Qiu^[85]的研究方法,对处理组和对照组进行进一步考察,实证方程设定如下

$$Y_{it} = \beta_k \sum_{k=-3}^3 treat_i \times week_k + X_{it} \times \gamma + u_i + \theta_i + \varepsilon_{it} \quad (5)$$

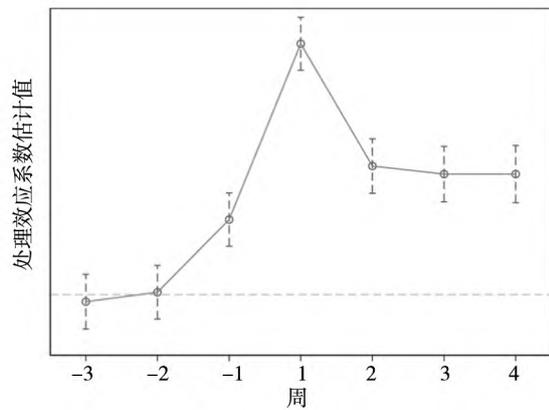
其中 $week_k$ 为周虚拟变量,当 k 为正时表示平台发布 RS 更新后的第 k 周,反之则为平台发布更新前第 k 周.其余变量与模型(2)一致.本文检测了平台发布更新前 3 周和后 4 周的拟合趋势变化,具体结果如图 3(a)、图 3(b)和图 3(c)所示.

在图 3 中,圆圈代表处理效应系数(β_k),虚线代表 95% 的置信区间.从结果来看,当被解释变量为平均浏览时长 $\ln(PerClick)$ 时,在发布更新前所有结果均不显著,平台发布更新后,处理组相对对照组信息处理效率显著降低.而对于被解释变量访问频率 $\ln(SessionCnt)$ 和购买频率 $\ln(OrderCnt)$,在平台发布更新前 1 周,有显著提升,再往前,则所有结果均不显著.平台发布更新后,处理组相对于对照组的访问频率和订单数均显著提

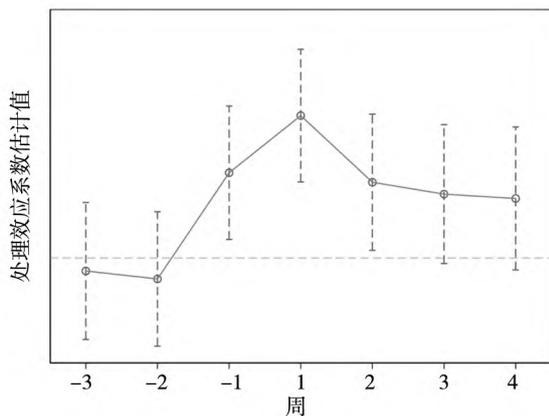
高。因此,样本通过了双重差分方法估计所需的平行趋势检验。



(a) $\ln(\text{PerClick})$ 的平行趋势图检验结果



(b) $\ln(\text{SessionCnt})$ 的平行趋势图检验结果



(c) $\ln(\text{OrderCnt})$ 的平行趋势图检验结果

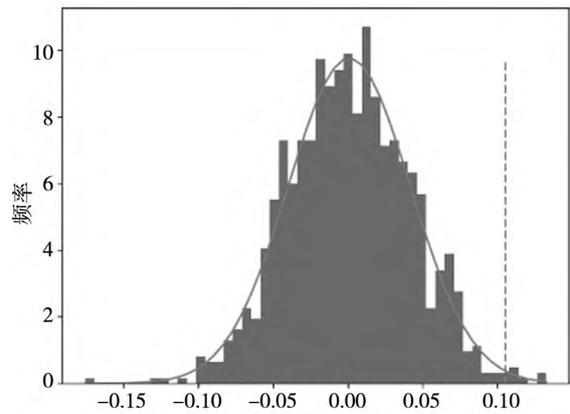
图3 因变量平行趋势图检验结果

Fig. 3 Dependent variables' parallel trend test result

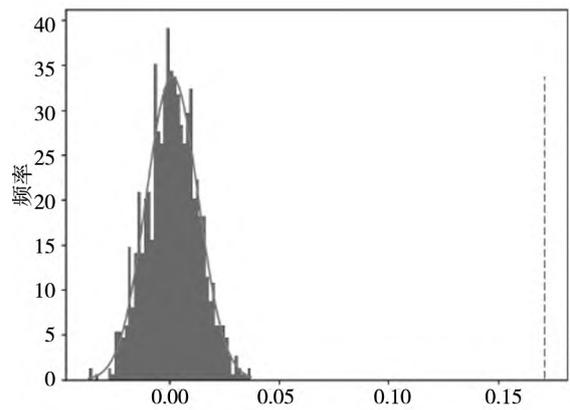
7.2 安慰剂检验

本研究进行了随机打乱处理组和对照组的安慰剂实验。即从所有用户中随机抽取 3 992 对用户分别当作处理组和对照组,并将上述随机过程重复

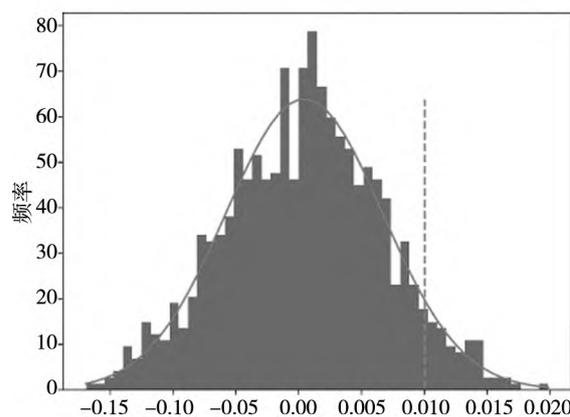
1 000 次。图 4 显示为随机处理 1 000 次后 $\text{After} \times \text{Treatment}$ 的系数分布图。由图可以发现其系数集中分布在 0 附近,远小于估计的真实值(虚线),这反向说明原处理组的测量误差是可容忍的。



(a) 因变量为 $\ln(\text{PerClick})$



(b) 因变量为 $\ln(\text{SessionCnt})$



(c) 因变量为 $\ln(\text{OrderCnt})$

图4 各因变量的随机分组处理的估计系数

Fig. 4 Estimated coefficient for random grouping of dependent variables

7.3 最长点击间隔鲁棒性实验

本研究以 30 m 为最长点击间隔,将数据切分

成会话数据的. 而后续实验数据, 均是基于此参数计算得出. 为避免人为设定带来的偶然因素, 针对此参数进行了鲁棒性实验, 其结果如表 9 所示. 结果可以看到, 无论是用户的信息处理效率 $\ln(\text{Per-}$

$\text{Click})$ 、访问频率 $\ln(\text{SessionCnt})$ 还是购买频率 $\ln(\text{OrderCnt})$, 在以不同的最长点击间隔生成数据后都得到了与原文类似的结论. 这进一步表明, 本研究的实验结论并非偶然.

表 9 最长点击间隔鲁棒性实验结果

Table 9 Robustness experiment results of the longest click interval parameter

最长点击间隔	$\ln(\text{PerClick})$	$\ln(\text{SessionCnt})$	$\ln(\text{OrderCnt})$
10	0.049	0.17 ***	0.01 *
20	0.105 **	0.168 ***	0.01 *
30	0.105 **	0.171 ***	0.01 *
40	0.126 ***	0.168 ***	0.01 *
50	0.146 ***	0.168 ***	0.01 *
60	0.151 ***	0.167 ***	0.01 *

8 结束语

RS 服务对共享平台的影响是一个值得研究的话题. 但在文献中, 很少有研究深入细致地探讨了 RS 对消费者、对产品供应者和对平台的影响.

本研究结果表明, 与消费者在 RS 的影响下提高信息效率会减少他们在平台上的停留时间^[82]的直觉相反, 共享平台上的 RS 服务使得用户在每个商店的平均停留时间更长. 这对于共享平台的运营管理来说, 表现为两个方面: 第一, 表 5 第(i)列和第(ii)列的结果显示, 消费者对于 RS 推荐的新店有很高的信息采纳率(更加仔细地浏览); 第二, RS 推荐的结果对消费者的平台访问频率和购买频率均有积极显著的影响, 特别是对于那些经常访问平台的消费者(在各关系刻画指标中高于中位数的消费者).

8.1 研究意义

本研究从消费者的实际行为和共享平台服务创新的角度出发, 在以下几个方面做出了贡献. 首先, 尽管许多文献研究都涉及了 RS 对平台的影响^[8], 但它们主要侧重于如何用 RS 来增加销量^[17]或研究 RS 如何影响销售多样性^[83]. 而本研究则以共享平台服务创新为背景, 从消费者的实际行为(路径)角度研究了 RS 对各平台参与者的影响. 从某种意义上讲, 本研究从消费者行为的角度丰富了关于 RS 服务如何对电子平台(尤其是共享平台)产生影响的理解.

其次, 通过使用 DID 和 DDD 方法分析来自共享家厨平台的独特数据, 可以全面可靠地刻画 RS 对消费者在线信息处理效率、访问频率以及对产品供应商销量的影响. 具体来说, 在数据和模型中同时考虑了消费者在线信息处理效率、平台访问频率和购买频率来揭示 RS 带来的影响. 以往文献认为, RS 会减少消费者在平台上的停留时间, 从而减少上游产品供应商对消费者的接触(可能会减少交易机会)^[82, 84]. 而本研究结果却表明, 在共享平台中 RS 服务虽然会增加消费者的消费, 但并不会提高消费者信息检索的效率, 这恰恰与以往研究结论相反.

第三, 通过衡量消费者与平台的关系, 本研究揭示了不同类型消费者受 RS 影响的差异. 特别是, 研究发现 RS 对平台亲近性高的用户(高类型的消费者)具有更大的影响, 这与 RS 的设计原理是一致的. 因为消费者的历史行为数据越多, RS 便能更轻松地观察和学习他们的群体偏好, 从而为他们提供更好的服务^[8, 9]. 这说明本研究也进一步反映了针对用户偏好数据的信息抽取能力对于 RS 有效性的具有重要作用^[60].

8.2 管理启示

本研究为共享平台的 RS 服务创新和产品供应商在平台上的运营管理提供了有益的洞见.

从共享平台 RS 服务创新的角度看, 本研究强调学习准确的消费者偏好的重要性. 由于影响消费者对共享平台交易满意度的因素更多地来自于消费者的偏好而非产品特性, 因此, 共享平台面

面临着同时提高 RS 推荐多样性和准确反映用户偏好的挑战。

从上游产品供应商的角度看,研究发现,准确的推荐服务使得消费者更愿意将不同的(新的)产品供应商纳入考虑范围^[37, 50],这对上游供应商是有利的。但对于提供同类产品的供应商而言,他们之间仍然存在很强的竞争,竞争点在于如何提高基于用户偏好的产品满意度^[38]。此外,从消费者角度看,产品供应商需要注意的是,尽管 RS 增强了对未知商店的信任度,但消费者仍然需要花费时间和精力来浏览推荐给他们的不熟悉的商店,并且还会对它们进行更仔细的评估(从消费者在新页面上花费的时间显著增加可以看出);进一步,从平台角度看,产品供应商需要注意的

是,平台每次提供的与 RS 相关的更新服务都可能会对产品供应商的流量产生巨大影响。

8.3 局限性

综上,本研究为共享平台上的 RS 服务对其三个关键参与者的影响提供了一些理论和管理方面的见解。尽管如此,仍存在一些局限,也为将来的研究提供了机会。首先,研究数据是来源于家厨共享平台,消费者决策时间间隔通常在 10 m(如即刻用餐)至 1 周(如预定用餐)之间。未来的研究可以比较在较小决策时间压力(如汽车共享)和较大决策时间压力(如住宿共享)情形下消费者行为受平台 RS 服务的影响。其次,由于受到数据的限制,消费者对新点击率和新订单之间的关系还未被准确研究。

参考文献:

- [1] Gawer A. Digital platforms' boundaries: The interplay of firm scope, platform sides, and digital interfaces[J]. *Long Range Planning*, 2020, 54(5): 102045.
- [2] 田林, 余航. 共享经济外部影响定量研究综述[J]. *管理科学学报*, 2020, 23(9): 1-18.
Tian Lin, Yu Hang. The social and economic impacts of sharing economy: A review on the quantitative literature[J]. *Journal of Management Sciences in China*, 2020, 23(9): 1-18. (in Chinese)
- [3] Malgonde O, Zhang H, Padmanabhan B, et al. Taming the complexity in search matching: Two-sided recommender systems on digital platforms[J]. *MIS Quarterly*, 2020, 44(1): 49-84.
- [4] Dreyer B, Lu deke-Freund F, Hamann R, et al. Upsides and downsides of the sharing economy: Collaborative consumption business models' stakeholder value impacts and their relationship to context[J]. *Technological Forecasting and Social Change*, 2017, (125): 87-104.
- [5] 陈斐然, 朱道立. 垄断双边平台的价格策略和数量策略设计问题[J]. *管理科学学报*, 2021, 24(3): 18-31.
Chen Feiran, Zhu Daoli. Price strategy and network-size allocation strategy in monopoly two-sided platform[J]. *Journal of Management Sciences in China*, 2021, 24(3): 18-31. (in Chinese)
- [6] 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.
- [7] Li S S, Karahanna E. Online recommendation systems in a b2c e-commerce context: A review and future directions[J]. *Journal of the Association for Information Systems*, 2015, (16): 72-107.
- [8] Lee D, Hosanagar K. When Do Recommender Systems Work the Best?: The Moderating Effects of Product Attributes and Consumer Reviews on Recommender Performance[C]. in: *Proceedings of the 25th International Conference on World Wide Web*, Montreal; Canada, 2016, 85-97.
- [9] Kumar A, Hosanagar K. Measuring the value of recommendation links on product demand[J]. *Information Systems Research*, 2019, 30(3): 819-838.
- [10] Häubl G, Trifts V. Consumer decision making in online shopping environments: The effects of interactive decision aids[J]. *Marketing Science*, 2000, 19(1): 4-21.
- [11] Li J, Netessine S. Higher market thickness reduces matching rate in online platforms: Evidence from a quasi-experiment[J]. *Management Science*, 2020, 66(1): 271-289.
- [12] Wirtz J, So K K F, Mody M A, et al. Platforms in the peer-to-peer sharing economy[J]. *Journal of Service Management*, 2019, 30(4): 452-483.
- [13] Kaartemo V, Nyström A G. Emerging technology as a platform for market shaping and innovation[J]. *Journal of Business*

- Research, 2021, (124): 458–468.
- [14] Jovanovic M, Sjödin D, Parida V. Co-evolution of platform architecture, platform services, and platform governance: Expanding the platform value of industrial digital platforms[OB/EL]. *Technovation*, 2022, 118, <https://doi.org/10.1016/j.technovation.2020.102218>.
- [15] Xu C, Peak D, Prybutok V. A customer value, satisfaction, and loyalty perspective of mobile application recommendations [J]. *Decision Support Systems*, 2015, (79): 171–183.
- [16] El-Manstrly D, Ali F, Steedman C. Virtual travel community members' stickiness behaviour: How and when it develops [J]. *International Journal of Hospitality Management*, 2020, (88): 102535.
- [17] Pathak B, Garfinkel R, Gopal R D, et al. Empirical analysis of the impact of recommender systems on sales[J]. *Journal of Management Information Systems*, 2010, 27(2): 159–188.
- [18] Lu W, Chen S, Li K, et al. Show Me the Money: Dynamic Recommendations for Revenue Maximization[C]. in: *Proceeding of the VLDB Endowment*, Hangzhou: China, 2014, 7(14): 1785–1796.
- [19] Li X, Grahl J, Hinz O. How do recommender systems lead to consumer purchases? A causal mediation analysis of a field experiment[J]. *Information Systems Research*, 2022, 33(2): 620–637.
- [20] Lee D, Gopal A, Park S H. Different but equal?: A field experiment on the impact of recommendation systems on mobile and personal computer channels in retail[J]. *Information Systems Research*, 2020, 31(3): 892–912.
- [21] Mousavi N, Adamopoulos P, Bockstedt J. The decoy effect and recommendation systems[OB/EL]. *Information Systems Research*, 2023, <https://doi.org/10.1287/isre.2022.1197>.
- [22] Yin K, Fang X, Chen B, et al. Diversity preference-aware link recommendation for online social networks[OB/EL]. *Information Systems Research*, <https://doi.org/10.1287/isre.2022.1174>.
- [23] Kumar A, Hosanagar K. Measuring the value of recommendation links on product demand[J]. *Information Systems Research*, 2019, 30(3): 819–838.
- [24] Lee D, Hosanagar K. How do product attributes and reviews moderate the impact of recommender systems through purchase stages? [J]. *Management Science*, 2021, 67(1): 524–546.
- [25] 刘业政, 吴 锋, 孙见山, 等. 基于群偏好与用户偏好协同演化的群推荐方法[J]. *系统工程理论与实践*, 2021, 41(3): 537–553.
- Liu Yezheng, Wu Feng, Sun Jianshan, et al. Group recommendation method based on co-evolution of group preference and user preference[J]. *Systems Engineering: Theory & Practice*, 2021, 41(3): 537–553. (in Chinese)
- [26] 朱茂然, 朱艳鹏, 高 松, 等. 基于深度哈希的相似图片推荐系统: 以 Airbnb 为例[J]. *管理科学*, 2020, 33(5): 17–28.
- Zhu Maoran, Zhu Yanpeng, Gao Song, et al. Similar picture recommendation system based on deep hashing: Evidence from the Airbnb platform[J]. *Journal of Management Science*, 2020, 33(5): 17–28. (in Chinese)
- [27] 胡春华, 赵 慧, 童小芹, 等. 推荐系统对消费者网购支出的影响研究[J]. *中国管理科学*, 2020, 28(6): 158–170.
- Hu Chunhua, Zhao Hui, Tong Xiaoqin, et al. Research on the impact of interlligent recommendation system on consumer online shopping[J]. *Chinese Journal of Management Science*, 2020, 28(6): 158–170. (in Chinese)
- [28] Ekstrand M D, Riedl J T, Konstan J A. Collaborative filtering recommender systems[J]. *Foundations and Trends in Human-Computer Interaction*, 2010, 4(2): 81–173.
- [29] Krafft M, Kumar V, Harmeling C, et al. Insight is power: Understanding the terms of the consumer-firm data exchange [J]. *Journal of Retailing*, 2021, 97(1): 133–149.
- [30] Kolotylo-Kulkarni M, Xia W, Dhillon G. Information disclosure in e-commerce: A systematic review and agenda for future research[J]. *Journal of Business Research*, 2021, (126): 221–238.
- [31] Kawaguchi K, Uetake K, Watanabe Y. Effectiveness of product recommendations under time and crowd pressures[J]. *Marketing Science*, 2019, 38(2): 253–273.
- [32] Rishika R, Kumar A, Janakiraman R, et al. The effect of customers' social media participation on customer visit frequency and profitability: An empirical investigation[J]. *Information Systems Research*, 2013, 24(1): 108–127.
- [33] 姜旭平, 王 鑫. 影响搜索引擎营销效果的关键因素分析[J]. *管理科学学报*, 2011, 14(9): 37–45.
- Jiang Xuping, Wang Xin. Study on the core factors impacting search engine marketing[J]. *Journal of Management Sciences in China*, 2011, 14(9): 37–45. (in Chinese)

- [34] Grbovic M, Cheng H. Real-Time Personalization Using Embeddings or Search Ranking at Airbnb[C]. in: Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, London: UK, 2018, 311 – 320.
- [35] Richards T J, Hamilton S F, Yonezawa K. Variety and the cost of search in supermarket retailing[J]. *Review of Industrial Organization*, 2017, (50): 263 – 285.
- [36] Choudhary V, Zhang Z. Product Recommendation and Consumer Search[R]. Working Paper, Irvine: University of California, 2019.
- [37] Tsekouras D, Dellaert B G C, Donkers B, et al. Product set granularity and consumer response to recommendations[J]. *Journal of the Academy of Marketing Science*, 2020, (48): 186 – 202.
- [38] Xiao B, Benbasat I. E-commerce product recommendation agents: Use, characteristics, and impact[J]. *MIS Quarterly*, 2007, 31(1): 137 – 209.
- [39] Oestreicher-Singer G, Sundararajan A. The visible hand? Demand effects of recommendation networks in electronic markets [J]. *Management Science*, 2012, 58(11): 1963 – 1981.
- [40] Li L, Chen J, Raghunathan S. Recommender system rethink: Implications for an electronic marketplace with competing manufacturers[J]. *Information Systems Research*, 2018, 29(4): 1003 – 1023.
- [41] Parikh M, Fazlollahi B, Verma S. The effectiveness of decisional guidance: An empirical evaluation[J]. *Decision Sciences*, 2001, 32(2): 303 – 332.
- [42] Zhang T C, Agarwal R, Lucas H C. The value of it-enabled retailer learning: Personalized product recommendations and customer store loyalty in electronic markets[J]. *MIS Quarterly*, 2011, 35(4): 859 – 882.
- [43] Zhang H, Zhao L, Gupta S. The role of online product recommendations on customer decision making and loyalty in social shopping communities[J]. *International Journal of Information Management*, 2018, 38(1): 150 – 166.
- [44] Bucklin R E, Sismeiro C. A model of web site browsing behavior estimated on clickstream data[J]. *Journal of Marketing Research*, 2003, 40(3): 249 – 267.
- [45] Wang G, Zhang X, Tang S, et al. Clickstream user behavior models[J]. *ACM Transactions on the Web*, 2017, 11(4): 1 – 37.
- [46] Johnson E J, Moe W W, Fader P S, et al. On the depth and dynamics of online search behavior[J]. *Management Science*, 2004, 50(3): 299 – 308.
- [47] Wang G, Konolige T, Wilson C, et al. You Are How You Click: Clickstream Analysis for Sybil Detection[C]. Proceedings of the 22nd USENIX Conference on Security, Washington D C: USA, 2013, 241 – 256.
- [48] Masatlioglu Y, Nakajima D. Choice by iterative search[J]. *Theoretical Economics*, 2013, 8(3): 701 – 728.
- [49] Huang H, Zhao B, Zhao H, et al. A Cross-Platform Consumer Behavior Analysis of Large-Scale Mobile Shopping Data [C]. in: Proceedings of the 2018 World Wide Web Conference, Lyon: France, 2018, 1785 – 1794.
- [50] Punj G, Moore R. Information search and consideration set formation in a web-based store environment[J]. *Journal of Business Research*, 2009, 62(6): 644 – 650.
- [51] 王风华, 郑宇杰, 万岩, 等. 在线商品的选择过载效应及调节定向作用研究[J]. *管理科学学报*, 2022, 25(9): 15 – 31.
Wang Fenghua, Zheng Yujie, Wan Yan, et al. Online choice overload effect and the moderatin role of cnsuer regulatory focus[J]. *Journal of Management Sciences in China*, 2022, 25(9): 15 – 31. (in Chinese)
- [52] Montgomery A L, Li S, Srinivasan K, et al. Modeling online browsing and path analysis using clickstream data[J]. *Marketing Science*, 2004, 23(4): 579 – 595.
- [53] Huang T, Van Mieghem J A. Clickstream data and inventory management: Model and empirical analysis[J]. *Production and Operations Management*, 2014, 23(3): 333 – 347.
- [54] Raza S, Ding C. Progress in context-aware recommender systems: An overview[J]. *Computer Science Review*, 2019, (31): 84 – 97.
- [55] Minkler A P. Why firms franchise: A search cost theory[J]. *Journal of Institutional and Theoretical Economics*, 1992, 148(2): 240 – 259.
- [56] Doll W J, Torkzadeh G. The measurement of end-user computing satisfaction [J]. *MIS Quarterly*, 1988, 12(2): 259 – 274.
- [57] Su B. Consumer e-tailer choice strategies at on-line shopping comparison sites[J]. *International Journal of Electronic Com-*

- merce, 2007, 11(3): 135 – 159.
- [58] Bucklin R E, Sismeiro C. Click here for internet insight: Advances in clickstream data analysis in marketing[J]. *Journal of Interactive Marketing*, 2009, 23(1): 35 – 48.
- [59] Verruck F, Nique W M. Bothering consumers: When recommendation agents don't really make our life easier[J]. *BASE*, 2017, 14(4): 240 – 252.
- [60] Sharma A, Hofman J M, Watts D J. Estimating the Causal Impact of Recommendation Systems from Observational Data [C]. in: *Proceedings of the Sixteenth ACM Conference on Economics and Computation (EC'15)*, Portland: USA, 2015, 453 – 470.
- [61] Cheng X, Zhang J, Yan L L. Understanding the impact of individual users' rating characteristics on the predictive accuracy of recommender systems[J]. *INFORMS Journal on Computing*, 2020, 32(2): 303 – 320.
- [62] Fu C. User intimacy model for question recommendation in community question answering[J]. *Knowledge-Based Systems*, 2020, (188): 104844.
- [63] Potdevin D, Sabouret N, Clavel C. Intimacy perception: Does the artificial or human nature of the interlocutor matter? [J]. *International Journal of Human-Computer Studies*, 2020, (142): 102464.
- [64] Park E. Motivations for customer revisit behavior in online review comments: Analyzing the role of user experience using big data approaches[J]. *Journal of Retailing and Consumer Services*, 2019, (51): 14 – 18.
- [65] Aljukhadar M, Senecal S, Daoust C E. Using recommendation agents to cope with information overload[J]. *International Journal of Electronic Commerce*, 2012, 17(2): 41 – 70.
- [66] Park Y J, Tuzhilin A. The Long Tail of Recommender Systems and How to Leverage It [C]. in: *Proceedings of the 2008 ACM Conference on Recommender Systems*, Lausanne: Switzerland, 2008, 11 – 18.
- [67] Davidson J, Liebald B, Liu J, et al. The Youtube Video Recommendation System [C]. in: *Proceedings of the Fourth ACM Conference on Recommender Systems*, Barcelona: Spain, 2010: 293 – 296.
- [68] Gomez-Uribe C A, Hunt N. The netflix recommender system: Algorithms, business value, and innovation [J]. *ACM Transaction on Management Information Systems*, 2016, 6(4): 1 – 19.
- [69] Trusov M, Ma L, Jamal Z. Crumbs of the cookie: User profiling in customer-base analysis and behavioral targeting[J]. *Marketing Science*, 2016, 35(3): 405 – 426.
- [70] Adomavicius G, Bockstedt J, Curley S, et al. The hidden side effects of recommendation systems[J]. *MIT Sloan Management Review*, 2019, 60(2): 13 – 15.
- [71] Wu L, Joung Y, Lee J. Recommendation Systems and Consumer Satisfaction Online: Moderating Effects of Consumer Product Awareness [C]. in: *Proceedings of The 46th Hawaii International Conference on System Sciences*, Wailea: USA, 2013, 2753 – 2762.
- [72] Adomavicius G, Bockstedt J C, Curley S P, et al. Effects of online recommendations on consumers' willingness to pay [J]. *Information Systems Research*, 2018, 29(1): 84 – 102.
- [73] Belk R. You are what you can access: Sharing and collaborative consumption online[J]. *Journal of Business Research*, 2014, 67(8): 1595 – 1600.
- [74] Rubin D B. *Fundamentals of Propensity Score Matching* [M]. In *Matched Sampling for Causal Effects*, Cambridge: Cambridge University Press, 2006, 167 – 169.
- [75] 李 琪, 王全胜, 宋培建. 自营竞争性进入对第三方绩效的影响研究——基于某大型混合零售平台的实证分析 [J]. *管理科学学报*, 2020, 23(2): 74 – 88.
Li Qi, Wang Quansheng, Song Peijian. The impact of reselling's competitive entry on the performance of agency selling: An empirical analysis based on a large hybrid retail platform [J]. *Journal of Management Sciences in China*, 2020, 23(2): 74 – 88. (in Chinese)
- [76] Girma S, Görg H. Evaluating the foreign ownership wage premium using a difference-in-differences matching approach [J]. *Journal of International Economics*, 2007, 72(1): 97 – 112.
- [77] Lee W S. Propensity score matching and variations on the balancing test [J]. *Empirical Economics*, 2013, (44): 47 – 80.
- [78] Rosenbaum P R, Rubin D B. Constructing a control group using multivariate matched sampling methods that incorporate the propensity score [J]. *The American Statistician*, 1985, 39(1): 33 – 38.
- [79] Verhoef P C, Donkers B. The effect of acquisition channels on customer loyalty and cross-buying [J]. *Journal of Interactive Marketing*, 2005, 19(2): 31 – 43.

- [80] Reinartz W J, Kumar V. The impact of customer relationship characteristics on profitable lifetime duration[J]. *Journal of Marketing*, 2003, 67(1): 77–99.
- [81] Bapna R, Ramaprasad J, Umyarov A. Monetizing freemium communities: Does paying for premium increase social engagement? [J]. *MIS Quarterly*, 2018, 42(3): 719–735.
- [82] Hostler R E, Yoon V Y, Guimaraes T. Assessing the impact of internet agent on end users' performance[J]. *Decision Support Systems*, 2005, 41(1): 313–323.
- [83] Fleder D, Hosanagar K. Blockbuster culture's next rise or fall: The impact of recommender systems on sales diversity[J]. *Management Science*, 2009, 55(5): 697–712.
- [84] Thirumalai S, Sinha K K. To personalize or not to personalize online purchase interactions: Implications of self-selection by retailers[J]. *Information Systems Research*, 2013, 24(3): 683–708.
- [85] Liu Q, Qiu LD. Intermediate input imports and innovations: Evidence from Chinese firms' patent filings[J]. *Journal of International Economics*, 2016, (103): 166–183.
- [86] August T, Niculescu M F. The influence of software process maturity and customer error reporting on software release and pricing[J]. *Management Science*, 2013, 59(12): 2702–2726.
- [87] Wu S, Chen P. Versioning and piracy control for digital information goods[J]. *Operations Research*, 2007, 56(1): 157–172.
- [88] Allon G, Askalidis G, Berry R, et al. When to be agile: Ratings and version updates in mobile apps[J]. *Management Science*, 2021, 68(6): 4261–4278.

An empirical study on the impact of sharing platform recommendation system based on consumer behavior

FENG Lu¹, QIAN Yu^{1*}, GE Xin-yu¹, YUAN Hua¹, WU Jun-jie^{2, 3}

1. School of Management and Economics, University of Electronic Science and Technology of China, Chengdu 611731, China;
2. School of Economics and Management, Beihang University, Beijing 100191, China;
3. Key Laboratory of Data Intelligence for Management, Ministry of Industry and Information Technology, Beihang University, Beijing 100191, China

Abstract: Recommender systems (RS) are based on analyzing user (consumer) data to provide them with information about products of interest, and these recommended products change consumers' browsing paths to achieve the purpose of recommendation. Due to the scarcity of relevant research data, few research have been conducted to explore the impact of RS on consumer behavior (path) of the platform considering the “user (consumer)-platform” relationship. To fill this research gap, this paper proposes three theoretical hypotheses to verify the impact of RS on consumers' information processing efficiency, platform access frequency and purchase behavior considering the “user (consumer)-platform” closeness. The hypotheses are formulated by taking into account the characteristics of the sharing platform and are tested using a unique dataset of a home-kitchen sharing platform. Interestingly, the results of the study show that consumers who adopt RS services have significantly lower information processing efficiency compared to consumers who do not adopt RS services. In addition, the findings further confirm that consumers with a close relationship with the platform and who also adopt RS have higher visit frequency and purchase intention.

Key words: sharing platform; personalized recommendation service; click behavior; DID model; PSM