

信息流广告的种草效应与加热效应

曾伏娥¹, 张天祐¹, 叶敏²

(1. 武汉大学 经济与管理学院, 湖北 武汉 430072;
2. 湖北经济学院 工商管理学院, 湖北 武汉 430205)

摘要: 文章探讨了信息流广告的间接效应,即在广告带动下,有更多用户通过算法推荐、商家发布的信息流内容产生订单。基于短视频平台数据,文章测算用户在信息流内容下产生的订单增量,检验广告投放量对订单增量是否存在显著作用。结果表明,信息流广告存在两类间接效应:其一,信息流广告对广告受众存在种草效应,算法后续会为广告受众持续推送商家发布的信息流内容;其二,信息流广告对商家发布的信息流内容具有加热效应,算法将热度更高的内容推送给更多非广告受众。此外,文章也揭示了间接效应的重要调节因素,即广告原生性与商家发布的信息流内容数量,这将有助于商家衡量信息流广告的真实效果,以及优化广告间接效应的表现。

关键词: 信息流广告;种草效应;加热效应;原生性;算法推荐

中图分类号: F713.50 **文献标志码:** A **文章编号:** 1000-2154(2023)06-0034-13

DOI: 10.14134/j.cnki.cn33-1336/f.2023.06.003

Recommend Effect and Heating Effect of News Feed Advertising

ZENG Fu'e¹, ZHANG Tianyou¹, YE Min²

(1. School of Economics and Management, Wuhan University, Wuhan 430072, China;
2. School of Business, Hubei University of Economics, Wuhan 430205, China)

Abstract: This article discusses the indirect effect of news feed advertising, which means that more users generate orders through algorithmic recommendations and information flow content published by businesses driven by advertising. Based on short video platform data, this article measures the order increment generated by users under information flow content, and tests whether the advertising amount has a significant impact on the order increment. The results show that there are two types of indirect effects in news feed advertising: first, news feed advertising has a recommend effect on the advertising audience, and the algorithm will continuously push the information flow content released by the merchant for the advertising audience in the future; secondly, information flow advertising has a heating effect on the information flow content published by businesses, and the algorithm pushes the more popular content to more non-advertising audiences. In addition, this article also reveals the important mediating factors of indirect effects, namely, the originality of advertising and the amount of information flow content released by businesses. This will help businesses measure the true effect of news feed advertising and optimize the performance of indirect effects of advertising.

Key words: news feed advertising; recommend effect; heating effect; native; algorithm-based recommendations

收稿日期: 2023-03-13

基金项目: 国家自然科学基金重点项目“移动互联网时代的新产品开发策略与商业模式创新”(71832010);教育部哲学社会科学研究重大课题攻关项目“我国重点产业链压力测试的理论、方法和实施框架研究”(22JZD012);国家自然科学基金重大研究计划培育项目“隐私大数据发掘与个性化营销研究”(91646121);国家自然科学基金面上项目“移动互联网时代网络社群的新产品沟通策略及机制:群体心理逻辑”(72072138)

作者简介: 曾伏娥,女,教授,博士生导师,管理学博士,主要从事组织营销、网络营销和新产品开发研究;张天祐,男,博士研究生,主要从事网络营销研究;叶敏(通讯作者),女,副教授,经济学博士,主要从事企业创新和营销管理研究。

一、引言

信息流广告已经成为媒体平台收入增长的新引擎。信息流广告之所以受到商家青睐,是因为其会被嵌入媒体平台的内容之间,即与平台用户生产的信息流内容混排在一起呈现,且两者在样式、内容表述上较为相似(Campbell和Evans,2018)^[1],这样更契合消费者的浏览习惯(Ferreira等,2017)^[2],因此相比传统展示广告更为有效(Wang等,2019)^[3]。而两者在推送规则上则有所区别,信息流广告由广告系统推送给用户,推送量取决于商家的付费金额;用户生产的信息流内容由推荐系统根据内容类型、热度等指标免费推送给其他可能感兴趣的人,热度高的内容能够获得更多推送量。

在商家投放广告后,部分用户会点击广告中的购买链接下单,这一行为产生的销量被称为信息流广告的直接效应,之前对于直接效应的研究已经比较深入,主要关注广告自身的点击率和转换率两个关键指标(Aribarg和Schwartz,2020^[4];Zarouali等,2017^[5])。但是由于信息流广告与平台上的信息流内容相互融合(Wojdynski和Evans等,2016)^[6],信息流广告的部分效果可能是通过用户点击媒体平台上的信息流内容来实现的,本文将其称为信息流广告的间接效应,这是其与传统展示广告的关键区别。更确切地说,这种间接效应来源于广告商家生产的信息流内容,因为在大流量媒体平台上,例如抖音、今日头条,商家一方面会作为广告主,利用平台投放信息流广告;另一方面也会在平台上注册账号,例如自己的抖音号、头条号,在账号中发布与自家产品相关的信息流内容,并在内容中嵌入购买链接,引导感兴趣的用户点击链接购买。

具体而言,本文基于某短视频平台的广告销售数据,利用元学习算法 X-learner 计算信息流广告投放后用户在算法推荐、广告商家发布的信息流内容下产生的订单增量,构建商家的广告投放量与订单增量之间的 Poisson 模型,用以检验信息流广告是否存在间接效应。本文研究发现,信息流广告投放存在两种间接效应:种草效应和加热效应,而信息流广告的原生性和商家发布的信息流内容数量则对以上两种效应具有显著的调节作用。本文的主要贡献有两方面。首先,本文研究了一种相对较新的广告类型,即信息流广告,并将其与商家生产的信息流内容结合起来,从理论和实证上共同探讨信息流广告可能存在的间接效应,即“种草效应”和“加热效应”。之前对信息流广告的研究只关注其直接效应,导致信息流广告的投放效果被严重低估,从而无法准确衡量广告投放的 ROI(投入产出比),这将不利于广告主科学有效地分配广告预算,部分直接效应表现不佳但间接效应优秀的广告往往面临减投甚至停投的风险。从本文结论中得出的管理见解可能会改变广告 ROI 的衡量方式,并鼓励商家更加关注信息流广告的间接效应,甚至带动行业的潜在变革。其次,本文揭示了影响种草效应和加热效应的重要调节因素,包括广告的原生性和商家发布的信息流内容数量,这不仅增加了对信息流广告间接效应的理解,也使从业者能够更好地优化信息流广告的表现。

二、理论分析和研究假设

(一) 信息流广告的种草效应

信息流广告是一种与其所嵌入平台的形式和特征相互融合的在线广告(Aribarg和Schwartz,2020)^[4],在设计上具有原生性(Kim等,2016)^[7],而原生性主要体现在广告形式和内容两方面。形式原生指的是信息流广告与其所嵌入平台的信息流内容在样式上存在一定的相似性(Sahni和Nair,2020)^[8],例如,抖音、快手的信息流广告是一条短视频,今日头条、百度的信息流广告是一篇图文资讯。内容原生性指信息流广告在展现风格上与平台上的信息流内容较为一致,其穿插于平台内容之间进行品牌信息的传递(范思等,2018)^[9],但如果没有特别标注“广告”字样,很容易让消费者误以为其是一则信息流内容(Harms等,2017)^[10]。

正是由于信息流广告与媒体平台的信息流内容在形式、内容上保持一致(Campbell和Evans,2018)^[1],

且两者被混排在一起呈现,所以信息流广告的间接效应很可能是通过信息流内容和推荐算法实现的。这是因为用户看到信息流广告后,对广告中的产品完全没有需求的用户会迅速划走,有强烈需求的用户会直接点击广告中的购买链接下单,但多数情况是用户对广告产品存在部分需求,他们可能会留下产品印象、认同产品价值,但往往不会在当下立即购买。过往文献指出,这些用户在看到广告后会产生大量包含品牌名称和关键字的搜索行为(Rutz和Bucklin,2011)^[11],通过搜索行为访问该商家的平台账号,甚至点击商家在其账号中发布的内容(Sahni和Nair,2020)^[8]。

这是因为根据说服效应理论(Friestad和Wright,1994)^[12],当消费者感知广告中隐藏的说服目的,他们的说服知识会被不同程度地唤起,从而运用搜寻者策略回应广告中的说服意图(Kirman和Campbell,2004)^[13],即主动从广告商家处收集信息,甚至对商家进行反馈。例如,在这一过程中,用户可能会对商家在其账号中发布的信息流内容进行浏览,甚至对感兴趣的内容进行点赞、评论等互动行为。而这些浏览、互动行为会被推荐算法捕捉到,推荐算法基于行为特征分析判断该用户可能对相关内容感兴趣,因此随后会将该商家发布的其他信息流内容持续推荐给他们(Ansari等,2000)^[14],这些与产品、品牌相关的信息流内容将对用户进行多次触达,从而促使这些广告受众点击信息流内容中的购买链接下单。根据Linden等(2003)^[15]的研究,通过个性化推荐系统为消费者展示他们之前浏览过的产品,能够增加产品销售。而Johnson等(2017)^[16]对在线零售商的研究也发现,对之前看过广告的用户进行多次触达,能够提高10.5%的购买量。Sahni等(2019)^[17]从认知心理学的角度对这一现象给出解释:一方面,从广告功能出发,多次触达能够提醒消费者关于产品属性和广告商的信息;另一方面,认知心理学描述了“输出干扰”的现象,多次接触该内容可以让消费者回忆起与产品相关的记忆,比较难回忆起其他类似的信息(竞品信息),从而提高购买转化率(白寅等,2022)^[18]。

综上所述,随着广告投放量的增加,即广告被展示给更多用户,因此有更多用户可能被广告“种草”,他们会通过搜索等行为访问该商家发布的信息流内容,并进行浏览/点赞/评论等行为,推荐算法基于行为特征给他们持续推送商家发布的其他信息流内容,从而带动这些广告受众在信息流内容下达成转化,本文将这种信息流广告的间接效应称为信息流广告的“种草效应”,图1的上半部分即为种草效应的具体形成过程。基于以上分析,本文提出以下研究假设H1:

H1:信息流广告对看过广告的用户(广告受众)存在种草效应,即广告投放量对广告受众在算法推送、商家发布的信息流内容下产生的订单量具有正向影响。

(二) 信息流广告的加热效应

信息流内容的实质是将用户或专业人士生产的内容通过推荐算法传递给其他平台用户(Devito,2016)^[19],推荐算法基于对用户行为的分析,挖掘用户对内容的偏好和潜在需求,从而实现个性化、精准化的信息推送(张香萍和李军,2019)^[20]。推荐算法在执行任务时一般存在两个阶段:召回阶段和排序阶段。召回阶段根据用户的历史行为数据,例如点赞、收藏、评论等,为用户在海量的信息中粗选一批其可能感兴趣的待推荐内容(Shin,2020)^[21]。召回阶段挑出候选集后会交到排序阶段,排序阶段将对所有召回结果进行更精细化的打分,使其变得有序,选出得分最高的少量结果推送给用户(Park等,2007)^[22]。在召回阶段的排序逻辑中,信息流内容的热度是决定算法推送量的重要因素。热度值根据用户互动行为数据来衡量,主要参考信息流内容的浏览、点赞、评论等项的数量,按照一定权重对各项得分进行加总计算,热度值更高的内容会被推送给更多用户。

如种草效应所述,部分看到信息流广告的用户(广告受众)会通过搜索行为访问该商家的平台账号,对商家在其账号中发布的信息流内容进行浏览/点赞/评论等行为,而他们的行为也提高了这些信息流内容的热度。首先,推荐系统会为热度更高的内容配比更多播放量,因此这些信息流内容会被推送给更多之前没有看过广告的用户(非广告受众),即他们虽然没有被广告“种草”,但在热度的作用下也会有更多非广告受众看到商家发布的信息流内容并点击其中的购买链接下单。其次,根据Chen等(2011)^[23]的说法,当产品互动量越多,后来的消费者推测产品质量越高,从而提高购买的可能性,因为在这些信息流内容下有更多的点赞、评论、分享等互动行为,所以非广告受众在看到热度更高的信息流内容后也会认为其推荐

的产品质量更高,从而具有更高的购买意愿。此外,韩雨彤等(2021)^[24]对抖音直播电商的研究、齐托托等(2021)^[25]对知识付费产品的研究、汪旭晖等(2018)^[26]对智能电视机的研究,也都支持互动量对销量的正向影响。

综上所述,随着广告投放量的增加,即广告被展示给更多用户,因此有更多被“种草”的用户会产生大量浏览/点赞/评论等行为,这些行为也提高了商家发布的信息流内容的热度,推荐算法会将其推送给更多之前没看过广告的用户(非广告受众),而这些非广告受众对于热度更高的内容也存在更强的购买意愿,从而带动他们在信息流内容下达成转化。本文将这种信息流广告的间接效应称为信息流广告的“加热效应”,图1的下半部分即为加热效应的具体形成过程。基于以上分析,本文提出以下研究假设 H2:

H2:信息流广告对商家发布的信息流内容存在加热效应,即广告投放量对非广告受众在算法推送、商家发布的信息流内容下产生的订单量具有正向影响。

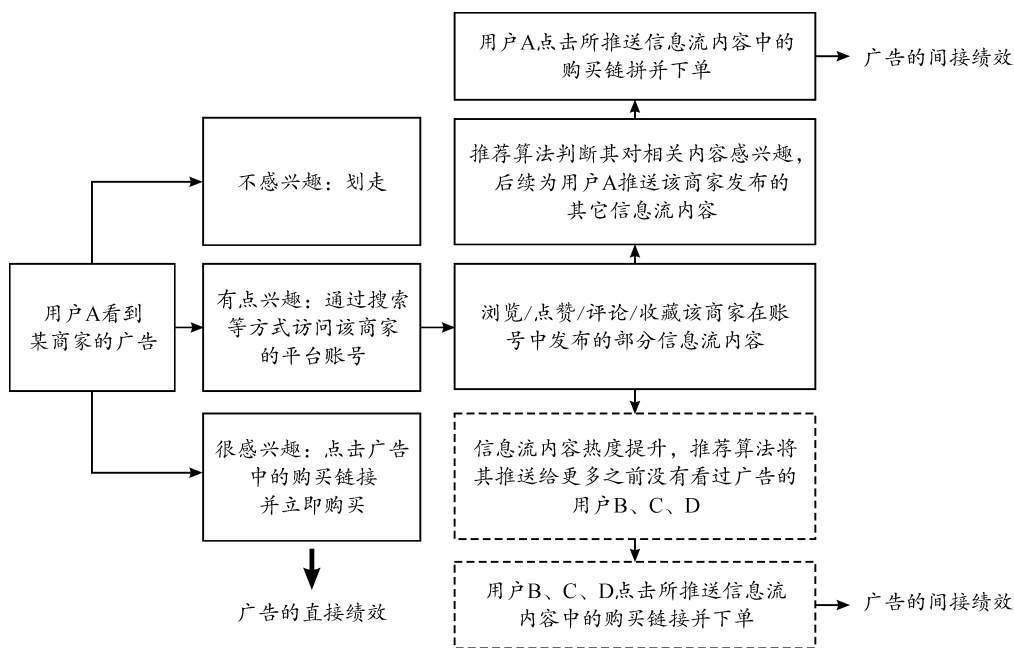


图1 种草效应和加热效应的具体形成过程

(三) 信息流广告的原生性

说服知识由 Friestad 和 Wright(1994)^[12]提出,是指消费者随着时间的推移而获得的一种用以合理应对营销人员的说服目标、潜在动机和说服策略的个人知识。用户在日常生活中面临大量营销人员的说服行为,在此过程中,用户会逐渐积累经验,对营销人员的说服策略形成一定程度的认识。说服知识表明营销人员怀有自私的动机(Campbell 和 Kirmani,2000)^[27],因此当用户再次接收到类似的营销信息时,他们的说服知识将被唤起,用户会主动思考营销人员背后的行为动机,从而形成应对态度。

说服知识理论(Friestad 和 Wright,1994)^[12],认为信息中隐藏的说服意图越容易被察觉,则用户的说服知识就会被更大程度地激活,而说服知识提高了用户的认知防御,并导致他们质疑广告主张的可信度(Xu 和 Wyer,2000)^[28]。过往的文献通常用该理论解释信息流广告的原生性与广告说服效果之间的关系,例如,Wojdynski 和 Evans(2016)^[6]发现,广告的内容原生性向用户隐藏了其说服意图,导致用户的说服知识和怀疑知识难以被唤起,而广告的形式原生性会降低说服的激活度,从而提升了用户对广告中产品、品牌的接受意愿。

当广告受众看到更加原生的广告时,他们很难察觉到广告中隐藏的说服意图,这将导致用户的说服知识更不容易被激活,从而减少对广告信息的怀疑态度和对营销人员动机的不信任感(Darke 和 Ritchie,

2007)^[29],也避免将这种怀疑与不信任转移到广告中的产品与品牌上(Xu和Wyer,2010)^[28]。基于此,相对于原生程度较低的广告,更加原生的广告能够防止用户后续对同一来源的信息产生负面印象(Darke和Ritchie,2007)^[29],当这些广告受众后续被算法推送商家发布的信息流内容时,他们将更有意愿下单购买。基于以上分析,本文提出以下研究假设 H3a:

H3a:原生性会增强信息流广告对广告受众的种草效应,更加原生的信息流广告具备更强的种草效应。

根据Friestad和Wright(1994)^[12]的描述,说服知识的主要功能不是让消费者营销人员的说服尝试产生怀疑,而是帮助消费者从营销人员处收集有用的、与自身目标相关的信息。在种草效应中,当用户感知广告中隐藏的说服目的,他们的说服知识被不同程度地唤起,其中对广告产品感兴趣的受众往往会产生大量包含商家品牌名称的搜索行为,通过搜索行为浏览商家在其账号中发布的内容甚至与其互动,在此过程中不断收集和广告产品有关的信息。此外,Kirman和Campbell(2004)^[30]的研究也佐证了这一现象,当用户感知信息中隐藏的说服意图时,他们会运用搜寻者策略予以回应。搜寻者策略包括询问、建立联系、奖励、测试、指导和接受帮助共六种,即用户会主动从营销人员处搜集有用信息和专业知识,甚至与营销人员积极互动以寻求反馈和协助。

综上所述,更加原生的广告虽然不容易唤起广告受众的说服知识(Wojdynski和Evans,2016)^[6],但他们因此也不会主动从营销人员处搜寻信息,例如更少浏览商家发布的信息流内容,更少通过评论等互动行为给予反馈、获取解答,而正是这些浏览/互动行为能够提高商家发布的信息流内容热度。基于此,相对于原生程度较低的广告,更加原生的广告对信息流内容热度的提升反而有限,这将导致推荐系统为其配比的推送量也相应更少。基于以上分析,本文提出以下研究假设 H3b:

H3b:原生性会减弱信息流广告对商家发布的信息流内容的加热效应,更加原生的信息流广告其加热效应反而更弱。

(四) 商家发布的信息流内容数量

除投放广告外,商家也会在自己的平台账号中发布与品牌、产品相关的信息流内容,值得说明的是,信息流内容的发布数量主要取决于商家的宣传策略、品牌调性等因素,其广告投放量与内容数量的相关性不高。当商家发布的信息流内容数量较多时,这为推荐系统提供了更充足的“弹药”,对于那些之前看到信息流广告并且通过搜索行为对该商家发布的信息流内容进行浏览、点赞、评论等行为的“种草”用户,推荐系统有更丰富的信息流内容能够推送给他们,这些广告受众更可能会被商家发布的信息流内容持续触达。一方面,这将有助于用户处理之前广告传递给他们的信息,并在此过程中更新他们对商家的印象,这是广告间接转化的重要驱动因素(Sahni和Nair,2020)^[8];另一方面,多次触达也能够提醒用户关于产品属性和广告商的信息(Sahni等,2019)^[17],从而提高产品的购买量(Johnson等,2017)^[16]。当商家发布的信息流内容数量较少时,即使有用户看过广告并被“种草”,推荐系统也没有足够的新内容推送给他们,从而降低了这些看过广告的用户后续被信息流内容触达并转化的可能性。基于以上分析,本文提出以下研究假设 H4a:

H4a:信息流内容数量会增强信息流广告对广告受众的种草效应,商家发布的信息流内容越多,信息流广告的种草效应也越强。

然而当看过广告的用户通过搜索等行为访问商家的平台账号,并对商家发布的信息流内容进行浏览、互动时,商家发布的信息流内容数量越多,这些用户的潜在选择也相应更多,因此不同用户更可能分别对不同的内容进行浏览、互动,每个信息流内容的热度相应更低。而当商家发布的信息流内容数量较少时,这些浏览、互动行为均集中发生在这几个有限的信息流内容上,它们的内容热度就相应更高。当之前没有看过广告的用户(非广告受众)被推荐系统推送了这些信息流内容,他们发现这些内容热度较低时,其可能推测所介绍商品的质量不高(Kirman和Campbell,2004)^[13],或认为这代表所介绍商品不够受欢迎,从而对销量产生负向影响。基于以上分析,本文提出以下研究假设 H4b:

H4b:信息流内容数量会减弱信息流广告对商家发布的信息流内容的加热效应,商家发布的信息流内容越多,信息流广告的加热效应反而越弱。

本文的假设模型见图2。

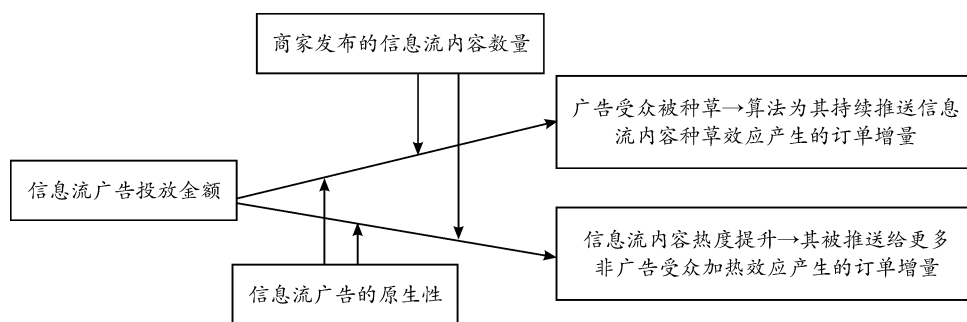


图2 假设模型

三、研究设计

(一) 样本选择

本文数据集来源于国内某短视频平台的面板数据,该平台也是业内领先的信息流广告服务商。本文选取的自变量为每个广告的投放量,其中同一广告的形式和内容(素材)完全相同,而种草效应和加热效应的因变量分别是广告受众/非广告受众在算法推荐、商家生产的信息流内容下产生的订单增量。考虑到业内通用的效果归因周期为7日,即只统计用户看到信息流广告后7日内产生的订单量,而且广告绩效也会受到以周为单位的周期性影响,因此本文将取样周期定为2021年3月1日(周一)至2021年3月28日(周日)共4周。此外,本文限制所取广告在取样周期内均有投放行为,同时剔除周期内任意一日存在数据缺失的广告计划2941个,剔除任意一日因存在违规行为而被停止投放的广告计划449个,最终得到样本广告计划共计40116个。

(二) 变量测量

1. 因变量。本文选取的种草效应/加热效应的因变量分别是广告受众/非广告受众在算法推荐、商家生产的信息流内容下产生的“订单增量”,这里的“订单增量”指的是在广告受众/非广告受众产生的“订单量”的基础上,剔除两类群体中的“非广告效应”订单。本文之所以选择“订单增量”而非“订单量”的原因是,存在一定比例的用户,无论商家是否投放信息流广告,其都会被算法推荐该商家发布的信息流内容,并且会点击信息流内容中的购买链接下单。这是因为,他们的行为特征与该商家发布的信息流内容极为匹配,即使商家没有投放信息流广告,这些用户也会被推荐算法识别并主动推送商家发布的信息流内容,所以他们产生的订单并非广告投放所带来的,应当属于“非广告效应”订单。随着自变量“广告投放量”的增加,看到广告的用户(广告受众)也相应增加,而没有看过广告的用户(非广告受众)则相应减少,广告受众和非广告受众产生的订单中属于“非广告效应”订单的绝对值也会更大/更小,因此“广告投放量”天然对种草效应/加热效应带来的“订单量”存在显著的正/负向作用,但“非广告效应”订单并未体现广告投放的价值。综合来看,选用“订单量”作为因变量无法度量真实的种草效应/加热效应,而“订单增量”则能够避免这一问题。

基于此,为了剔除“非广告效应”订单的影响,本文将度量广告受众/非广告受众在算法推送、商家生产的信息流内容下产生的“订单增量”。在目前的文献中,度量的最佳方法是采用线上随机试验 A/B 测试,将广告随机划分为两组,分别进行“投放”和“不投放”操作,直接计算两组广告的受众/非受众在信息流内容下产生的订单量的差值,Sahni 等(2019)^[17]采用了这种方法。

考虑到随机试验 A/B 测试需要人为干预广告的投放状态,存在成本过高等问题,因此本文决定选用二手数据进行度量。但二手数据不能使用随机分组来平衡混杂因素对结果的影响,针对该问题,Li 和 Kannan(2014)^[31]构建了一个包含客户转换决策阶段的三层测量模型,用以计算营销渠道的增量价值,而

Johnson 等(2017)^[16]则开发了“幽灵广告”方法,相比 A/B 测试可以降低实验成本,提高测量精度。

考虑到对于预测数值的准确率具有极高要求,因此参考 Künzel 等(2019)^[32]的测量方法,利用元学习算法分别估计每个广告样本在投放/不投放时的结果。此外,由于本文选用的广告数据集中对照组的数据量远大于实验组,当预估函数相对复杂时可能导致在预估实验组的“base learner”时出现过拟合问题,因此本文选用元学习算法中的 X-learner 模型,该方法主要用于解决组间数据量不均衡导致模型表现不佳的问题。本文对种草效应产生的订单增量度量步骤如下,加热效应同理,后续不再赘述。

(1) 样本选取。本文将被投放广告的账号匹配为实验组,未投放广告的账号匹配为对照组。实验组正例:被实验组的信息流广告触达,随后被算法推送实验组账号发布的信息流内容且点击购买链接下单的用户;实验组负例:被实验组的信息流广告触达,随后被算法推送实验组账号发布的信息流内容且没有点击购买链接下单的用户。对照组正例:未被实验组的信息流广告触达,但被推送对照组账号发布的信息流内容且点击购买链接下单的用户;对照组负例:未被实验组的信息流广告触达,但被推送对照组账号发布的信息流内容且没有点击购买链接下单的用户。

(2) 度量模型。第一步:将对照组和实验组数据分别建模,利用监督学习拟合相应函数,预估被投放的广告和未投放账号在信息流内容下产生的订单量,得到对照组和实验组模型如下:

$$\mu_{Control}(X) = E(Y^{Advertising} | X = \chi_{Advertising}) \quad (1)$$

$$\mu_{Treatment}(X) = E(Y^{noAdvertising} | X = \chi_{noAdvertising}) \quad (2)$$

第二步:交叉预估,用对照组模型 $\mu_{Control}(X)$ 训练实验组数据,再用实验组的真实值减去 $\mu_{Control}(X)$ 模型预估值,得到增量 $D_{Control}(X_i)$;用实验组模型 $\mu_{Treatment}$ 训练对照组数据,再用 $\mu_{Treatment}$ 模型预估值减去对照组的真实值,得到增量 $D_{Treatment}(X_i)$ 。

$$D_{Control}(X_i) = Y_i^{Treatment} - \hat{\mu}_{Control}(X_i^{Treatment}) \quad (3)$$

$$D_{Treatment}(X_i) = \hat{\mu}_{Treatment}(X_i^{Control}) - Y_i^{Control} \quad (4)$$

其中 $Y_i^{Treatment}$ 和 $Y_i^{Control}$ 分别表示实验组和对照组的真实值, $X_i^{Treatment}$ 和 $X_i^{Control}$ 分别是两组的特征向量。

第三步:分别用两组的增量 $D_{Control}(X_i)$ 和 $D_{Treatment}(X_i)$ 作为自变量,分别构建回归模型 $\hat{\tau}_{Control}(x)$ 和 $\hat{\tau}_{Treatment}(x)$ 拟合增量,再通过计算 $\hat{\tau}_{Control}(x)$ 和 $\hat{\tau}_{Treatment}(x)$ 的加权得到条件平均处理效果。

$$\hat{\tau}(x) = g(x) \times \hat{\tau}_{Treatment}(x) + (1 - g(x)) \times \hat{\tau}_{Control}(x) \quad (5)$$

$$\hat{\tau}(X) = E(D^{Treatment} | X = \chi_{Treatment}) = E(D^{Control} | X = \chi_{Control}) \quad (6)$$

其中 $\hat{\tau}_{Treatment}(x)$ 代表对 $D^{Treatment}(X_{Treatment})$ 的建模; $\hat{\tau}_{Control}(x)$ 代表对 $D^{Control}(X_{Control})$ 的建模。 $g(x)$ 代表先验权重函数,本文选用倾向性得分加权来控制非随机分配带来的可观测值差异,从而提高预估准确性。倾向性得分 $e(x)$ 描述一个属性为 x 的广告主属于处理组的概率,本文使用 probit 模型估计倾向性得分,即 $\hat{e}(x) = Pr(T = 1 | x_1, x_2, x_3, \dots, x_n)$,模型中的可观测协变量为账号特征 x_n (同后文)。

最后,本文利用前文描述的 X-learner 方法,按照广告维度进行测量。对于之前看过信息流广告的用户(广告受众),本文统计其后续7日在算法推送、商家发布的信息流内容下产生的订单增量。其中,7日周期为广告归因普遍采用的标准,根据样本统计,触达7日后产生转化的用户数仅为0.029%,可以不予考虑。本文将这些用户后续产生的订单增量归因到广告展示当日,如果存在同一用户看到同一商家发布的不同广告后在其信息流内容下产生订单的情况,本文按照学界和业界通用的“最后一次点击”原则进行归因,即将该用户产生的订单归因到他最后一次看到的广告上。对于之前没看过信息流广告的用户(非广告受众),本文只统计其在广告投放当日产生的订单增量,因为加热效应的作用时间较短,不存在以天为单位的滞后。

2. 自变量。本文选取的自变量为广告投放量,这些广告均按照展示量竞价及付费(CPM),它们根据广告形式的差异可分为短视频广告和直播广告。广告投入一般存在两种常见的衡量指标,其一为广告展示量,即将广告展示给用户的次数;其二为广告投放金额,龚诗阳等(2018)^[33]选用了该衡量方式。本文决定按照广告投放金额(Cos)计算,原因是,广告投放金额在考量广告展示量的基础上也反映了广告受众的转

化潜力,能够平衡受众之间的个体差异。

3. 调节变量。本文的第一个调节变量为信息流广告的原生性(*Nat*)。本文选取的短视频平台允许投放两种原生程度不同的信息流广告,即更加原生的“一类广告”与原生程度较低的“二类广告”,两者的区别具体表现在:

其一,在广告内容方面,更加原生的“一类广告”要求投放素材中对品牌、产品信息的曝光程度更低,不允许有明显的导购倾向,且与信息流内容共享内容审核规则,因此在内容表述上和与原生程度较低的“二类广告”具有明确的带货指向性。

其二,在广告形式方面,原生程度较低的“二类广告”在左下角会标注明显的“广告”标签,且底部带有引导购买的 button 元素,该类标签语言能够提升广告的可识别性(Wojdyski 和 Evans,2016)^[6],而更加原生的“一类广告”则没有这两类反映广告身份的标识。

综上,“一类广告”在内容和形式上都更加原生,更难让消费者识别出其是一则广告。基于此,对于原生性变量,我们将更加原生的“一类广告”赋值为1,原生程度更低的“二类广告”赋值为0。

本文的第二个调节变量为商家在其账号中发布的信息流内容数量(*Cnt*),本文将计算每个商家30天内在其平台账号中发布的信息流内容数量。

(三) 模型设计与变量定义

1. 信息流广告的种草效应。首先,为证明信息流广告存在种草效应,本文将检验随着广告投放量的增加,之前看过广告的用户(广告受众)在算法推送、该商家发布的信息流内容下产生的订单增量是否显著增加。由计算得到的种草效应订单增量数据可知,因变量均为非负整数,OLS 模型不适用于因变量为计数变量的情形,且变量中存在为零的数据,这也为使用对数线性模型带来障碍,基于此,本文转而采用 poisson 回归进行估计。

其次,本文对模型进行 Hausman 检验,结果显示原假设被高度拒绝($p < 0.001$),因此固定效应模型比随机效应模型更为适合。更进一步,本文采用双向固定效应模型,其一为行业固定效应,用于控制广告所属行业不随时间变化且未被观察到的异质性因素;其二为时间固定效应,因为时间因素也会对平台流量分布和广告订单量产生影响。本文采用的种草效应模型如下:

$$Adr_{i,t} = \beta_0 + \beta_1 Cos_{i,t} + \beta_2 Nat_{i,t} + \beta_3 Cnt_{i,t} + \beta_4 Cos_{i,t} \times Nat_{i,t} + \beta_5 Cos_{i,t} \times Cnt_{i,t} + \beta_6 \alpha For_{i,t} + \beta_7 Liv_{i,t} + \beta_8 Qua_{i,t} + \beta_9 Fas_{i,t} + \beta_{10} Sco_{i,t} + \lambda_t + \mu_i + \varepsilon_{i,t} \quad (7)$$

其中,角标 i, t 分别表示行业和时间, μ_i 表示行业固定效应, λ_t 表示时间固定效应, $\varepsilon_{i,t}$ 表示误差项。

表1为变量描述与统计分析结果,种草效应模型的自变量为广告投放量,因变量是之前看过信息流广告的用户(广告受众)在算法推送、该商家发布的信息流内容下产生的“订单增量”(*Adr*),调节变量为信息流广告的原生性(*Nat*)和商家在其账号中发布的信息流内容数量(*Cnt*)。

最后,为控制其他因素对种草效应的影响,本文也增加了部分控制变量:(1)广告形式,其中直播广告赋值为1,短视频广告赋值为0,两类广告在展现形式、转化能力等方面均存在差异;(2)直播时长,直播间是商家的重要转化渠道,因此直播时长对销售业绩存在积极影响;(3)商家发布的信息流内容质量,本文利用视频平均完播率指标衡量,视频质量越高,用户的转化率也相应提升;(4)粉丝数量,粉丝数量对线上销售业绩存在积极作用,更多粉丝意味着更大的信息传播范围,可以充分利用口碑力量;(5)商家评分,评分代表卖家声誉,是消费者制定购买决策的重要依据(汪旭晖和郭一凡,2020)^[34],商家声誉通过影响消费者对产品的看法,作用于在线销售业绩(严建援等,2020)^[35],本文选取的商家评分来源于用户购后对产品/服务/物流的综合评价。

本文并没有在模型中加入广告投放量的滞后项,因为本文是按照每一个用户在商家发布的信息流内容下产生的订单与广告展示进行一对一匹配,将后续7天内产生的订单归因至广告展示发生当日,同时广告展示对算法推荐信息流内容的影响是在短时间内发生的,因此并不存在以天为单位的滞后效应。本文也对模型进行了共线性诊断,计算得到 *vif* 的最大值为1.740(小于严格临界值5),说明模型不存在严重的多重共线性问题。

本文主要关注种草效应模型中 β_1 、 β_4 和 β_5 的系数, β_1 代表广告投放量对广告受众在算法推送、该商家发布的信息流下所产生订单增量的作用,若种草效应模型中 β_1 的系数显著为正,则证明信息流广告具有种草效应; β_4 代表广告的原生性对种草效应的调节作用,而 β_5 代表商家发布的信息流内容数量对种草效应的调节作用。

表1 变量与描述性统计

变量类型	变量名称	变量符号	变量定义	平均值	标准差	最小值	最大值
因变量	种草效应 订单增量	<i>Adr</i>	广告受众在商家发布、算法推送的信息流内容下产生的订单增量	353.042	744.544	0	16283.000
	加热效应 订单增量	<i>Adh</i>	非广告受众在商家发布、算法推送的信息流内容下产生的订单增量	139.705	252.557	0	5919.000
自变量	广告投放量	<i>Cos</i>	商家按照 CPM 竞价模式的广告投放金额(千元)	5.331	12.889	0.010	659.422
调节变量	原生性	<i>Nat</i>	一类广告=1;二类广告=0	0.284	0.446	0	1.000
	信息流 内容数量	<i>Cnt</i>	商家30天内发布的信息流内容数量	19.714	14.781	0	139.000
控制变量	广告形式	<i>For</i>	直播广告=1;短视频广告=0	0.712	0.394	0	1.000
	直播时长	<i>Liv</i>	直播时长(<i>h</i>)	3.151	3.833	0	22.107
	视频质量	<i>Qua</i>	视频的平均完播率	0.051	0.033	0	0.219
	粉丝数量	<i>Fas</i>	粉丝数量(万个)	6.721	78.862	0	1913.853
	商家评分	<i>Sco</i>	消费者对商家的综合评分(1—5分)	4.147	1.009	1.000	5.000

2. 信息流广告的加热效应。进一步地,为证明信息流广告的加热效应,本文将检验随着广告投放量的增加,之前没有看过广告的用户(非广告受众)在算法推送、该商家发布的信息流内容下产生的订单增量是否显著增加。如前所述,本文同样采用 Poisson 回归进行估计,同时控制了行业固定效应和时间固定效应。具体地,本文采用如下模型进行检验:

$$Adh_{i,t} = \beta_0 + \beta_1 Cos_{i,t} + \beta_2 Nat_{i,t} + \beta_3 Cnt_{i,t} + \beta_4 Cos_{i,t} \times Nat_{i,t} + \beta_5 Cos_{i,t} \times Cnt_{i,t} + \beta_6 \alpha For_{i,t} + \beta_7 Liv_{i,t} + \beta_8 Qua_{i,t} + \beta_9 Fas_{i,t} + \beta_{10} Sco_{i,t} + \lambda_t + \mu_i + \varepsilon_{i,t} \quad (8)$$

如表1所示,加热效应模型的因变量是非广告受众在算法推送、该商家发布的信息流内容下产生的“订单增量”(Adh),而自变量、调节变量、控制变量与种草效应模型完全一致。本文主要关注加热效应模型中 β_1 、 β_4 和 β_5 的系数, β_1 代表广告投放量对非广告受众在算法推送、该商家发布的信息流内容下产生订单增量的作用,若模型中 β_1 的系数显著为正,则证明信息流广告具有加热效应; β_4 代表广告的原生性对加热效应的调节作用,而 β_5 代表商家发布的信息流内容数量对加热效应的调节作用。

四、实证结果及分析

(一) 基准回归结果

在主效应方面,表2为模型基准回归结果,由模型可知,广告投放量(*Cos*)对广告受众/非广告受众在算法推送、该商家发布的信息流内容下产生的订单增量(*Adr*)均具有显著的正向影响,随着商家广告投放量增加,在排除“非广告效应”订单的作用后,广告受众/非广告受众在算法推送、该商家发布的信息流内容下产生的订单量也会显著增加,从而证明了假设 H1 和 H2,即信息流广告具有显著的种草效应和加热效应。

在调节效应方面,模型(3)中广告投放量(*Cos*)和原生性(*Nat*)的交互项系数正向显著($p < 0.01$),而模型(6)中两者的交互项系数负向显著($p < 0.05$),这说明更加原生的广告能够正向调节信息流广告的种草效应,而会负向调节信息流广告的加热效应,从而验证了假设 H3a 和 H3b。与此同时,模型(3)中广告投放量(*Cos*)和商家发布的信息流内容数量(*Cnt*)的交互项系数正向显著($p < 0.05$),模型(6)中两者的交互

项系数负向显著($p < 0.05$),这说明商家发布的信息流内容数量也能够正向调节信息流广告的种草效应,而会负向调节信息流广告的加热效应,从而验证了假设 H4a 和 H4b。

表2 基准回归结果

变量	种草效应(Adr)			加热效应(Adh)		
	(1)	(2)	(3)	(4)	(5)	(6)
<i>Cos</i>	0.049*** (0.006)	0.033*** (0.006)	0.021*** (0.006)	0.039*** (0.005)	0.038*** (0.004)	0.104*** (0.010)
<i>Nat</i>		1.509*** (0.076)	1.326*** (0.168)		0.086*** (0.022)	0.145*** (0.025)
<i>Cnt</i>		0.049*** (0.002)	0.048*** (0.005)		0.0005*** (0.0001)	0.011*** (0.002)
<i>Cos × Nat</i>			0.036*** (0.012)			-0.009** (0.004)
<i>Cos × Cnt</i>			0.0002** (0.00008)			-0.002* (0.0009)
<i>For</i>	0.399*** (0.074)	0.691*** (0.076)	0.791*** (0.088)	0.137*** (0.024)	0.123*** (0.024)	0.106*** (0.024)
<i>Liv</i>	0.019** (0.009)	0.036* (0.019)	0.044** (0.021)	-0.006 (0.006)	-0.006 (0.004)	-0.009 (0.006)
<i>Qua</i>	1.449*** (0.088)	1.764*** (0.106)	1.958*** (0.121)	0.676** (0.270)	0.581** (0.226)	0.443** (0.201)
<i>Fas</i>	0.054* (0.029)	0.069* (0.038)	0.082** (0.032)	0.012*** (0.003)	0.011** (0.005)	0.011** (0.005)
<i>Sco</i>	0.149** (0.076)	0.163** (0.064)	0.187* (0.097)	0.005*** (0.001)	0.005*** (0.001)	0.006*** (0.001)
<i>R</i> ²	0.388	0.476	0.561	0.422	0.556	0.629
<i>N</i>	1123248.000	1123248.000	1123248.000	1123248.000	1123248.000	1123248.000

注:括号内为 P 值,***表示 $p < 0.01$,**表示 $p < 0.05$,*表示 $p < 0.1$ 。

(二) 稳健性检验

为检验模型的稳健性,本文从调整变量和调整估计方法两个方面进行稳健性检验。首先,本文从变量出发将因变量的衡量指标由广告投放金额替换为广告展示量,其他变量与原模型设定一致;其次,本文从估计方法出发,根据现有文献做法,采用负二项回归(Nbreg)重复前文的实证分析。两项分析结果均显示,各模型的主要解释变量、调节变量及其交互项的系数符号及显著性情况并没有明显改变,本文的研究结果具备稳健性。限于篇幅,本文对以上稳健性检验结果不再报告。

(三) 内生性讨论与处理

本文虽然采用双向固定效应模型,但是当解释变量与误差项存在相关关系时,模型的估计结果还是会存在有偏的情况。本文涉及的内生性问题主要由双向因果导致,即种草效应/加热效应产生的订单增量可能与广告投放量存在双向因果关系,因为订单增加反映了消费者对产品的认可度,这会导致商家对市场份额扩张和广告预期收益有更高期待,从而提高广告投放量。

解决内生性问题的常用方法为引入工具变量,本文选取广告的每日平均展示出价(CPM 出价)作为工具变量,原因是,首先,每日平均展示出价与误差项不相关,对于潜在消费者而言,广告的每日平均展示出价是不可观察的,他们的购买决定通常无法考虑这一点;其次,每日平均展示出价与广告投放量相关,当展示出价更高时,即商家获取流量的成本提高,商家会选择降低广告投放金额,反之则会提高投放量,以期获取低价流量。

本文采用广义矩估计方法(GMM)解决内生性问题,首先检验工具变量的有效性和外生性。经检验,第一阶段 F 统计值均大于10,且 P 值为0.000,显著否定弱工具变量假设,说明选择的工具变量是有效的;而

过度识别检验显示,Sargan的 P 值均大于0.1,即两模型的检验结果不拒绝原假设,则说明工具变量是外生的。

表3为工具变量回归结果,使用工具变量后,两模型的主要解释变量(广告投放量)、调节变量及其交互项的符号和显著性未发生实质性变化,本文的核心结论依然是稳健的。

表3 工具变量回归结果

变量	种草效应(Adr)	加热效应(Adh)
Cos	0.017*** (0.006)	0.087*** (0.009)
Nat	1.596*** (0.209)	0.159*** (0.027)
Cnt	0.058*** (0.006)	0.012*** (0.002)
$Cos \times Nat$	0.033** (0.015)	-0.009** (0.004)
$Cos \times Cnt$	0.0002** (0.00007)	-0.002* (0.001)
For	0.566*** (0.063)	0.091*** (0.022)
Liv	0.045** (0.022)	-0.011 (0.007)
Qua	1.581*** (0.099)	0.421** (0.194)
Fas	0.069** (0.027)	0.010** (0.004)
Sco	0.201* (0.121)	0.007*** (0.002)
R^2	0.533	0.585
N	1123248.000	1123248.000

注:括号内为 P 值,***表示 $p < 0.01$,**表示 $p < 0.05$,*表示 $p < 0.1$ 。

五、结论、启示与展望

(一) 研究结论

本文将商家作为广告主投放的信息流广告与其作为内容生产者发布的信息流内容结合起来,深入探讨了信息流广告可能存在的两种间接效应,即对广告受众的“种草效应”和对信息流内容的“加热效应”,同时也检验了广告的原生性和商家发布的信息流内容数量对两种效应的调节作用,最终得到以下研究结论:

第一,信息流广告对广告受众具有种草效应,而对商家发布的信息流内容具有加热效应。用户在看到广告后会通过搜索等方式对商家发布的信息流内容进行浏览/点赞/评论等,一方面,这些行为会被推荐算法判定其对相关内容感兴趣,因此后续会给用户持续推送该商家发布的其他信息流内容,促使用户点击信息流内容中的购买链接下单;另一方面,这些信息流内容的热度也得到提升,推荐算法会将它们推送给更多非广告受众,促使其点击信息流内容中的购买链接下单。

第二,信息流广告的原生性对种草效应具有正向调节作用,但对加热效应具有负向调节作用。因为信息流广告的原生性能够隐藏广告的说服意图,避免激活用户的说服知识,一方面,这将降低用户对产品的不信任与反抗性态度,当他们后续看到商家发布的信息流内容时更有意愿下单购买;另一方面,这将导致用户不会运用搜寻者策略进行回应,即更少对商家发布的信息流内容进行浏览/点赞/评论等,其内容热度提升有限。

第三,商家发布的信息流内容的数量对种草效应具有正向调节作用,但对加热效应具有负向调节作用。当商家发布的信息流内容数量较多时,推荐算法有足够的新内容推送给被“种草”的用户,这将增加产品、品牌信息刺激用户的机会,从而提高产品购买量;同时这将导致商家信息流内容的热度不够集中,因为用户的浏览/互动行为会分散发生在更多内容上,当用户看到热度不高的信息流内容时,会对购买意愿产生负向影响。

(二) 管理启示

本文为信息流广告的广告主提供了新的管理启示:

第一,广告主应当建立包含信息流广告间接效应的 ROI 计算新标准,将消费者通过种草效应和加热效应产生的额外订单量计入信息流广告的投放价值,这将有助于其衡量信息流广告的真实作用,从而能够更加科学有效地分配广告预算。

第二,相比于信息流广告的种草效应,广告主更应当关注其加热效应。由模型结果可知,信息流广告投放表现出更强的加热效应,但目前广告主反而更重视看过广告的种草用户,对其进行多次广告触达。

第三,在信息流广告的形式、内容的呈现上,广告主应该选择适当原生的广告。虽然原生程度更高的广告会提高种草用户对广告产品的接受意愿,但他们也会更少浏览/评论商家发布的信息流内容,最后导致内容热度的提升有限,反而阻碍了效果更强的加热效应。

第四,对于信息流内容的发布策略,广告主应该发布适当数量的信息流内容。如果商家发布的信息流内容数量太多,用户的浏览、互动行为带来的热度相应更加分散,当非广告受众被推送热度较低的信息流内容,他们可能推测所介绍产品的质量不高或不受欢迎,反而对加热效应产生负向影响。

(三) 研究局限和未来研究展望

本文还存在以下局限:(1)本文仅验证了信息流广告能够带动更多用户通过算法推荐、商家发布的信息流内容产生订单,但未能完全还原用户的决策过程,即用户在浏览广告后产生的搜索行为和商家主页产生的浏览、互动等行为;(2)由于二手数据限制,本文只能采用“元学习 X-learner”模型度量广告受众/非广告受众在信息流内容下产生的“订单增量”,这难以将该种草效应和加热效应完美归因到广告投放。

参考文献:

- [1] CAMPBELL C, EVANS N J. The role of a companion banner and sponsorship transparency in recognizing and evaluating article-style native advertising[J]. *Journal of Interactive Marketing*, 2018, 43(2): 17-32.
- [2] FERREIRA C, MICHAELIDOU N, MORAES C, et al. Social media advertising: factors influencing consumer ad avoidance[J]. *Journal of Customer Behaviour*, 2017, 16(2): 183-201.
- [3] WANG P, XIONG G, YANG J. Serial position effects on native advertising effectiveness: differential results across publisher and advertiser metrics[J]. *Journal of Marketing*, 2019, 83(2): 82-97.
- [4] ARIBARG A, SCHWARTZ E M. Native advertising in online news: trade-offs among clicks, brand recognition, and website trustworthiness[J]. *Journal of Marketing Research*, 2020, 57(1): 120-165.
- [5] ZAROUALI B, PONNET K, WALRAVE M, et al. Do you like cookies? Adolescents skeptical processing of retargeted facebook-ads and the moderating role of privacy concern and a textual debriefing[J]. *Computers in Human Behavior*, 2017, 69(11): 157-165.
- [6] WOJDYNSKI B W, EVANS N J. Going native: effects of disclosure position and language on the recognition and evaluation of online native advertising[J]. *Journal of Advertising*, 2016, 45(2): 157-168.
- [7] KIM D H, SUNG Y H, LEE S Y, et al. Are you on timeline or news feed? The roles of facebook pages and construal level in increasing ad effectiveness[J]. *Computers in Human Behavior*, 2016, 57(12): 312-320.
- [8] SAHNI N S, NAIR H S. Sponsorship disclosure and consumer deception: experimental evidence from native advertising in mobile search[J]. *Marketing Science*, 2020, 39(1): 5-32.
- [9] 范思, 鲁耀斌, 胡莹莹. 社交媒体环境下一致性与社交性对信息流广告规避的影响研究[J]. *管理学报*, 2018(5): 759-766.
- [10] HARMS B, BIJMOLT T H A, HOEKSTRA J C. Digital native advertising: practitioner perspectives and a research agenda[J]. *Journal of Interactive Advertising*, 2017, 17(2): 80-91.

- [11] RUTZ O J, BUCKLIN R E. From generic to branded: a model of spillover in paid search advertising[J]. *Journal of Marketing Research*, 2011, 48(1): 87-102.
- [12] FRIESTAD M, WRIGHT P. The persuasion knowledge model: how people cope with persuasion attempts[J]. *Journal of Consumer Research*, 1994, 21(1): 1-31.
- [13] KIRMANI A, CAMPBELL M C. Goal seeker and persuasion sentry: how consumer targets respond to interpersonal marketing persuasion[J]. *Journal of Consumer Research*, 2004, 31(3): 573-582.
- [14] ANSARI A, ESSEGAIER S, KOHLI R. Internet recommendation systems[J]. *Journal of Marketing Research*, 2000, 37(3): 363-375.
- [15] LINDEN G, BRENT S, JEREMY Y. Amazon. com recommendations: item-to-item collaborative filtering[J]. *IEEE Internet Computing*, 2003, 7(1): 76-80.
- [16] JOHNSON G A, LEWIS R A, NUBBEMEYER E I. Ghost ads: improving the economics of measuring online ad effectiveness[J]. *Journal of Marketing Research*, 2017, 54(6): 867-884.
- [17] SAHNI N S, NARAYANAN S, KALYANAM K. An experimental investigation of the effects of retargeted advertising: the role of frequency and timing[J]. *Journal of Marketing Research*, 2019, 56(3): 401-418.
- [18] 白寅, 张荣, 任星耀. 再定向营销沟通研究述评与展望[J]. *管理学报*, 2022(6): 938-946.
- [19] DEVITO M A. From editors to algorithms: a values-based approach to understanding story selection in the facebook news feed[J]. *Digital Journalism*, 2016, 5(6): 1-21.
- [20] 张香萍, 李军. 新闻算法推送的困境、出路与展望[J]. *编辑之友*, 2019(4): 86-90.
- [21] SHIN D. How do users interact with algorithm recommender systems? The interaction of users, algorithms, and performance[J]. *Computers in Human Behavior*, 2020, 109(8): 1-10.
- [22] PARK D H, LEE J, HAN I. The effect of on-line consumer reviews on consumer purchasing intention: the moderating role of involvement[J]. *International Journal of Electronic Commerce*, 2007, 11(4): 125-148.
- [23] CHEN Y, WANG Q, XIE J. Online social interactions: a natural experiment on word of mouth versus observational learning[J]. *Journal of Marketing Research*, 2011, 48(2): 238-254.
- [24] 韩雨彤, 周季蕾, 任菲. 动态视角下实时评论内容对直播电商商品销量的影响[J]. *管理学报*, 2021(1): 17-28.
- [25] 齐托托, 周洵, 王天梅. 在线评论特征对知识付费产品销量的影响研究——基于产品类型的调节作用[J]. *管理评论*, 2021(11): 209-222.
- [26] 汪旭晖, 张其林, 杜航. 在线顾客评论对产品销量的影响: 品牌强度和成熟度的调节作用[J]. *管理工程学报*, 2018(3): 9-18.
- [27] CAMPBELL M C, KIRMANI A. Consumers' use of persuasion knowledge: the effects of accessibility and cognitive capacity on perceptions of an influence agent[J]. *Journal of Consumer Research*, 2000, 27(1): 69-83.
- [28] XU A J, WYER R S. Puffery in advertisements: the effects of media context, communication norms, and consumer knowledge[J]. *Journal of Consumer Research*, 2000, 37(2): 329-343.
- [29] DARKE P R, RITCHIE R J B. The defensive consumer: advertising deception, defensive processing, and distrust[J]. *Journal of Marketing Research*, 2007, 44(1): 114-127.
- [30] KIRMANI A, CAMPBELL M C. Goal seeker and persuasion sentry: how consumer targets respond to interpersonal marketing persuasion[J]. *Journal of Consumer Research*, 2004, 31(3): 573-582.
- [31] LI H S, KANNAN P K. Attributing conversions in a multichannel online marketing environment: an empirical model and a field experiment[J]. *Journal of Marketing Research*, 2014, 51(1): 40-56.
- [32] KÜNZEL S R, SEKHON J S, BICKEL P J, et al. Metalearners for estimating heterogeneous treatment effects using machine learning[J]. *Proceedings of the National Academy of Sciences*, 2019, 116(10): 4156-4165.
- [33] 龚诗阳, 李倩, 赵平, 等. 数字化时代的营销沟通: 网络广告、网络口碑与手机游戏销量[J]. *南开管理评论*, 2018(2): 28-42.
- [34] 汪旭晖, 郭一凡. 商品—卖家在线声誉不一致如何影响消费者购买意愿[J]. *经济管理*, 2020(11): 125-140.
- [35] 严建援, 李扬, 冯森, 李凯. 网络口碑中的剧透效应: 来自电影市场的证据[J]. *南开管理评论*, 2020(4): 37-48.

