

信息流平台的营销曝光效果研究 ——基于关键意见领袖营销沟通的分析

曾伏娥，曾怡萱，王雪莹，张天祐

[摘要] 随着信息流平台的快速发展,关键意见领袖(KOL)已成为营销沟通的主导力量。KOL作为一种与消费者在线沟通的有效媒介,鲜有研究深入分析其数量如何影响他们在信息流平台的曝光效果。本文基于一个信息流平台的面板数据,利用Poisson模型探索KOL数量对营销曝光效果的影响。结果发现,KOL数量对首位曝光效果具有正向影响,对多重曝光效果存在非线性影响。此外,信息流平台高效的推荐算法加剧了多重曝光的负面影响。通过深入探讨信息流平台KOL营销曝光效果的影响机制,本文挑战了以往的管理直觉,为KOL的相关研究提供了新的视角,发现与更多的KOL合作不一定会带来更好的营销曝光效果。本文对于优化信息流平台的沟通策略从而提高企业与消费者的营销沟通效果、实现品牌最终效益最大化具有指导意义。

[关键词] 关键意见领袖；曝光效果；首位曝光；多重曝光；说服知识

[中图分类号] F274 **[文献标识码]** A **[文章编号]** 1006-480X(2024)06-0174-19

一、引言

流媒体时代,利用关键意见领袖(Key Opinion Leaders, KOL)进行营销沟通,已成为备受企业和用户喜爱的沟通方式。根据《2024年中国市场KOL营销:投资增长与策略机遇洞察》的研究报告,预计2024年国内KOL市场规模增速依旧保持在26%,KOL在多个垂类市场成为值得信赖的时尚引领者(De Veirman et al., 2017)。从平台看,根据Topklout发布的《2023-2024广告主KOL营销市场盘点及趋势预测》,国内商家投放KOL集中于信息流平台,其中,抖音依靠强交互性获得31.3%的投放,而小红书基于强种草特性获取21.5%的投放。国外的信息流平台,以Instagram为例,品牌方与KOL合作费用的支出占比超过40%,预计2024年其支出将超过30亿美元,在信息流平台进行KOL营销沟通成为大势所趋。

[收稿日期] 2024-02-12

[基金项目] 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”(批准号22JZD012);国家自然科学基金青年项目“人工智能产品角色对消费者产品评价的影响研究:基于角色理论视角”(批准号71902067);国家自然科学基金青年项目“更新换代新产品上市时间管理研究”(批准号72202059)。

[作者简介] 曾伏娥,武汉大学经济与管理学院教授,博士生导师;曾怡萱,武汉大学经济与管理学院博士研究生;王雪莹,武汉大学经济与管理学院硕士研究生;张天祐,武汉大学经济与管理学院硕士研究生。通讯作者:曾伏娥,电子邮箱:zfee@sina.com。感谢匿名评审专家和编辑部的宝贵意见,文责自负。

KOL是对用户的态度和行为产生强烈影响的个人(Godey et al., 2016)。凭借其专业知识和社会声望,KOL积极促进了信息传播,成为信息发送方与消费者沟通的重要渠道(Xiong et al., 2018),有助于推广产品、促进销售、培育消费者忠诚度(Niu et al., 2023)。因此,企业通常会寻找多名KOL合作,以期获得更好的曝光效果。根据Influencing Marketing Hub(2024)的报告,超过60%的品牌方与超过10位KOL合作,甚至28.2%的品牌方合作的KOL数量超过100人。然而邀请更多的KOL与消费者进行沟通,能够产生更好的营销曝光效果吗?2021年,完美日记因KOL营销费用的过度增长而遭遇27亿元的巨额亏损;2023年,母公司逸仙电商减少了与KOL的大量合作,优化了营销策略,营销费用同比下降4.2%,实现扭亏为盈。此外,与高额支出相对应的并不一定是较高的营业收入,通过KOL销售的产品面临高达60%的退货率(Niu et al., 2023)。该现象表明,与更多的KOL合作并不总能带来积极的曝光效果,甚至可能产生负面影响。而以往的研究似乎都遵循一种直觉假设,与更多KOL合作总是能够带来更多的收入,即在暂不考虑合作成本的前提下,KOL的边际收入始终为正。学者们总是鼓励品牌方选择受欢迎和高价值的KOL(Park et al., 2021)、发布原创内容(Leung et al., 2022),试图通过改善推广内容、选择匹配目标人群的KOL、采用规模化和矩阵式投放来获得高曝光度与转化率,但这些研究忽视了KOL数量的问题,也未能完全解释上述不利可能的原因所在。

因此,本文旨在探讨品牌与KOL合作的数量对营销沟通效果的影响,并揭示其影响机制。本文希望解答品牌在与KOL合作时应如何优化数量以达到最佳营销效果这一问题,并为企业提供有效的策略指导。基于品牌方以信息流平台作为主要KOL投放阵地的现状,本文收集了某信息流平台的KOL广告接单数据,并对不同情况下的KOL沟通效果进行系统评估。信息流平台中的独特性使得KOL营销沟通的作用机制比传统媒体平台更加复杂,因此本文进一步探讨了信息流平台的推荐算法的影响。通过构建品牌方合作KOL数量与营销曝光效果的Poisson模型,本文发现两者之间并不是简单的线性关系,而是呈倒U型关联。品牌与更多KOL合作可以提升首位曝光效果,扩大信息覆盖面并提高用户的购买意愿,但过多的KOL合作会导致多重曝光效果呈现倒U型关系,因为消费者会感知品牌的盈利动机,从而降低KOL的可信度和营销效果。同时,分析结果还表明,信息流平台的推荐算法进一步放大了多重曝光的负面效应,当推荐算法的效率更高时,倒U型曲线的转折点将向左移动,因此,本文揭示了KOL营销在信息流平台与传统媒体平台的关键差异。

本文的主要研究贡献包括:①现有关于KOL营销的研究主要聚焦于探讨如何优化KOL沟通内容、如何选择最匹配的KOL进行营销沟通,本文则探索了KOL合作的数量效应,发现了一个重要的直觉假设漏洞——当合作KOL的数量达到峰值后,KOL合作数量的增加对营销曝光效果产生负面影响。本文的研究结论有助于补充KOL营销领域和品牌管理领域的研究,为品牌选择合适的KOL合作数量、最大化营销曝光效果提供理论指导。②基于说服知识理论,本文发现,在首位曝光中,KOL沟通并不会显著激活消费者群体的说服知识;而在多重曝光后,由于说服知识的激活,消费者觉察到KOL沟通的商业意图,对整体营销曝光效果产生不利影响。总的来说,本文通过数据科学量化了KOL合作的边际收益,拓展了说服知识理论的应用,增进了对说服知识的理解。③本文引入了一种新的度量模型,能够更准确地量化KOL推广活动所产生的订单增量。此外,本文还揭示了推荐算法效率在调节KOL数量与营销曝光效果关系中的作用,为调整营销策略以适应复杂的推荐系统环境提供了方法。④本文的研究结论也为从业者提供了实用的见解,建议企业在沟通过程中应该谨慎确定KOL的合作数量,将其保持在最佳水平。根据来自信息流平台的证据,本文倡导品牌通过渠道分配来削弱多重曝光的负向作用,并通过降低推广内容之间的相似性,以规避推荐算法的负面影响。这些方法为品牌方与KOL合作的沟通行为提供了指南,不仅有助于增强品牌的市

场表现,而且还能改善消费者的购物体验,优化整体的品牌曝光效果。

余文安排如下:第二部分概述了相关文献,总结了本文与现有文献的主要差异。第三部分提出了三项主效应假说和一个调节效应假说,阐明了品牌与KOL合作的机制。第四部分和第五部分介绍了实证分析的方法、数据和结果,详细说明了数据的收集和处理过程以及所得实证结果的统计分析。第六部分总结了研究结论和管理启示。

二、文献回顾

1.关键意见领袖(KOL)

与大众相比,KOL通常在某个领域具有更多专业知识(Zhao et al.,2024)、更优越的社会地位和社会声望(Xiong et al.,2018)。他们通过在小红书、快手等平台上发布文案、图片或视频,向平台用户分享日常生活、经验和专业知识,从而创建个人身份并获得知名度(Sokolova and Kefi,2020;Lyu et al.,2022)。通过持续不断的内容输出及精心的内容管理,KOL成功吸引了一批能产生共鸣的关注者,最终形成了庞大的粉丝群体。由于拥有大量的关注者和订阅者,KOL被视为具有显著的社会影响力(Leung et al.,2022)。近年来,随着媒体平台的快速发展,KOL的流行度不断提升,越来越多的品牌开始将其视为一种重要的沟通方式(Niu et al.,2023)。品牌通过付费或提供免费试用的方式,让KOL在分享日常生活的帖子中无缝融入品牌信息,从而推广产品和服务(Lyu et al.,2022),并最终被粉丝接受此推荐(Boerman et al.,2017;Zhang et al.,2024),这种做法被称为KOL营销。

利用KOL进行沟通已显示出诸多好处,包括提高电子口碑(Eelen et al.,2017)、增加购买意向(Lou and Yuan,2019)等。相关研究表明,KOL营销的成功源自他们的高可信度(由专业知识、社会地位等因素共同形成),而KOL亲自试用产品并向公众推广的行为也大大增强了其可信度(Sokolova and Kefi,2020)。然而,品牌与KOL合作并非没有风险。虽然,由于KOL内容的非商业性本质(Engeler and Barasz,2021),KOL发布的内容被视为“少数几种真实可靠的沟通形式之一”(Scott,2015);但是当消费者意识到KOL参与背后的盈利动机时,推广内容的真实性可能会被质疑(Leite et al.,2024),消费者认为KOL会因为商业导向而推广他们不感兴趣的品牌或产品,这会增加品牌操纵意图的推断(Isaac and Grayson,2017;Leite et al.,2024),对品牌和产品产生负面影响(Kim and Kim,2021)。

基于此,本文需要考虑如何安排KOL合作能够增强可信度而避免被质疑真实性,从而最大化广告效果,这在理论分析和管理实践中具有重要意义。通过广泛查阅KOL选择和调度的相关文献,本文发现已有研究通常关注KOL的受欢迎程度(Park et al.,2021)、KOL与产品或品牌之间的契合度(Chen et al.,2024)、KOL调度策略优化与预算分配(Mallipeddi et al.,2022)等,而本文则聚焦于品牌合作的KOL数量对营销效果的影响,并深入探究其在首次曝光、多重曝光等不同情境下的差异,为KOL营销领域和品牌管理领域的研究提供了新的视角和发现。

2.说服知识理论

说服知识(Persuasion Knowledge)是消费者逐渐积累的一种个人知识,用来准确识别和有效应对营销人员的各种说服目标和说服策略(Friestad and Wright,1994)。一般而言,消费者会在日常生活中接触各种说服行为,如开屏广告、拉新促销等。在这一过程中,消费者会逐渐了解、熟悉营销人员的说服策略,能够深层次理解行为背后的商业意图。当用户再次接收到类似的营销信息时,用户会主动思考营销人员背后的行为动机,做出应对行为(Isaac and Grayson,2017)。因

此,关于广告说服效果的研究表明,说服知识的激活对广告的说服成功有负面影响(曾伏娥等,2019)。

具体到KOL沟通方面,KOL的粉丝群体由被内容吸引的用户组成,正是因为这些内容被认为本质上是原生的、非商业性的,所以KOL比营销人员或名人代言更值得信赖(Engeler and Barasz,2021)。然而,随着越来越多的品牌使用KOL进行营销沟通,消费者逐渐意识到KOL与品牌的联系。特别是,当消费者频繁接收到多个KOL发布的品牌合作内容时,消费者的说服知识更容易被激活,对商业动机的感知更高(Campbell and Kirmani,2008)。一旦消费者感知KOL发布的内容中潜藏的商业动机,他们可能会对KOL或品牌产生怀疑或消极态度(Xie and Feng,2023)。

3.信息流平台与推荐算法

信息流平台通过推荐算法,将已生成的内容推荐给其他可能对此感兴趣的用户(DeVito,2017)。在这一过程中,推荐算法通过分析用户过往的行为数据,为用户的内容偏好“打上标签”,然后利用这些“标签”来匹配并推送用户可能感兴趣的内容,从而实现个性化推送的整个流程(Wang et al.,2024)。目前,信息流平台常见的推荐算法主要有两种:基于内容的推荐算法和基于用户的协同过滤算法。具体地,基于内容的推荐算法通过分析用户过往的行为数据,为用户推荐与其行为偏好相符的相似内容。例如,当某用户在一位KOL发布的好物分享帖子下方点赞、评论、转发后,推荐算法会基于用户的互动行为判断该用户“喜欢好物分享”,并持续为用户推荐包含这些“好物”的内容或者其他热门的“好物推荐”内容。即使用户并没有真正喜欢或者消费这些产品,他们仍然可能会持续看到类似的内容。而基于用户的协同过滤法则根据用户的喜好来匹配并推荐那些有相似喜好的其他用户所喜欢的内容。例如,推荐算法已经判定A用户和B用户有相同的偏好——“喜欢好物推荐”(二者有相同的行为“标签”),那么推荐算法会为B用户推荐A用户喜欢的内容,尤其是吸引A用户产生互动行为的内容。如果B用户之前看过这一内容,推荐算法会进一步为B用户推荐与A用户喜欢内容相似的其他内容。在这一过程中,可以观察到,推荐算法并非独立使用某一种算法逻辑运作;相反,其常常在基于用户的协同过滤算法的基础上,进一步融合基于内容的推荐算法的逻辑。

正是因为这种高效的推荐算法,品牌方利用KOL进行沟通、开展营销活动在信息流平台和传统媒体平台可能存在差异:一方面,推荐算法促进了沟通内容的传播(Gelper et al.,2021; Wang et al.,2024),即使一些用户并没有直接关注KOL,但由于他们和KOL的粉丝受众可能具有相似的偏好,所以KOL发布的品牌推广内容依然会通过推荐算法触达这些用户;另一方面,品牌与多个KOL的合作行为也更容易被用户观察到,推荐算法会进一步将更多KOL的内容曝光给相同用户,可能会暴露背后商业动机(Boerman et al.,2017; Leite et al.,2024),从而影响营销曝光效果。

三、理论模型与研究假说

1.合作KOL数量与总体营销曝光效果

为了研究KOL数量对总体营销曝光效果的影响,本文调查了品牌方合作的KOL数量对其营销曝光效果的影响。另外,由于信息流平台是KOL营销中最受欢迎和最重要的渠道(Grewal et al.,2016),因此本文的研究主要聚焦于信息流平台。基于广告效果的相关文献研究,KOL具有大量的

粉丝受众,通过视频、图文的方式触达并影响粉丝,从而帮助品牌信息实现更广泛的传播(De Veirman et al., 2017),有助于提高营销曝光效果。此外,由于信息流平台促进了内容传播(Gelper et al., 2021),KOL发布的推广内容可以被推送给更多的非粉丝受众(DeVito, 2017),即不同KOL的内容受众群体之间可能存在交集。例如,用户A虽然只关注了KOL账号B,但是C、D、E等KOL账号发布的内容也可能被推送给该用户。因此,当品牌与较多KOL合作时,更多的用户会接触推广内容从而导致总订单量上升。

然而,品牌信息的重复触达对营销曝光效果的影响并非始终是正向的,不能始终积极影响消费者的最终购买行为。如前文所述,较多的KOL内容会使得消费者意识到KOL与品牌方的商业联系。进一步,他们会将KOL发布的内容识别为营销人员的说服,激活其对KOL营销意图的判断,进而以怀疑态度、负面情绪应对KOL的沟通内容(Xie and Feng, 2023),甚至降低营销曝光效果。因此,本文推测,在达到最优点之后,品牌方与更多KOL合作可能因为信息过度重复而适得其反,甚至降低沟通效果,带来销售绩效的下降。综上,本文提出:

假说1:在信息流平台,品牌合作的KOL数量与其营销曝光效果呈倒U型关联,即随着合作KOL数量增加,带来的总订单量先上升后下降。

2. 合作KOL数量与首位曝光效果

由于KOL数量对营销曝光效果的影响因素较为复杂,而现有研究主要集中在传统广告展示领域,未考虑到信息流平台和传统媒体平台对于KOL沟通的关键区别——推荐算法会进一步加剧曝光效果差异,因此,依据信息流平台的曝光特性,本文将品牌与KOL合作带来的营销曝光效果进一步拆分为首位曝光效果和多重曝光效果(Mallipeddi et al., 2022),并对两种效果分别进行讨论与检验,有助于进一步阐述上述假设的合理性。

首位曝光效果指的是,用户只接触一位KOL发布的宣传内容后,直接点击内容中的购买链接下单,这种效果来源于品牌信息更广泛的传播和更高的可信度。一方面,KOL的连通性可以实现更大规模的信息覆盖(Libai et al., 2013),他们庞大的粉丝网络能够接触大量的潜在消费者,并在推荐算法的作用下进一步触达更多平台用户,促进信息进一步传播(Gelper et al., 2021),最终提升品牌销量。例如,根据He and Klein(2023)的研究,通过广告覆盖1%的人口会促进在线销售额在广告播出后的4个小时内增加1.55%。另一方面,KOL的推广内容也能够唤起可信度(Sokolova and Kefi, 2020),消费者可能会认为KOL是有效且可靠的消息发送者,从而赋予KOL更大的意见领导力。而KOL的可信度、意见领导力,将有效增强消费者的互动意愿,提高了KOL的在线营销曝光效果,最终增强消费者的购买意愿(Fink et al., 2020)。综上,本文提出:

假说2:在信息流平台,品牌合作的KOL数量对其首位曝光效果具有正向作用,不存在非线性的倒U型关系。

3. 合作KOL数量与多重曝光效果

在完成KOL内容的“首位曝光”后,当品牌和多个KOL合作,即使媒体平台提供的内容繁多,消费者往往被驱使继续访问多个KOL发布的同品牌推广内容,甚至部分消费者并不属于这些KOL的粉丝受众(Woolley and Sharif, 2022)。因此,本文将多重曝光效果定义为用户接触两位及以上KOL发布的宣传内容后,点击内容中的购买链接下单。多重曝光的出现,主要是因为媒体平台促进了信息的进一步传播,这对KOL营销的成功至关重要(Gelper et al., 2021)。根据Mallipeddi et al.(2022)的研究,品牌合作的KOL数量对多重曝光的作用主要体现在网络重叠和同伴影响两方面。网络重叠是指多个KOL之间的粉丝存在重叠现象,即他们可能共享一部分粉丝。这些共同的粉丝在接收

到不同 KOL 发布的同一品牌推广内容时,会经历多重曝光。而同伴影响则是指 KOL 发布的内容能够通过信息传播网络触及他们的粉丝的关注者(即二级关注者),这些二级关注者可能进一步将内容分享或转发给其他用户。例如,假设用户 Y 和 Z 分别关注 KOL X1 和 X2,同时用户 Y 和 Z 是好友关系(互相关注)。当 X1 和 X2 分别发布某品牌的合作内容时,这些内容会分别被 Y 和 Z 看到。如果用户 Y 选择转发 X1 的消息,那么有关该品牌的推广内容就会通过 Y 的分享再次触达用户 Z(或 Z 的其他关注者),从而实现了内容的二次传播。这就是同伴影响的作用。KOL 内容的多重曝光效果兼具提醒和信息传播的作用(He and Klein, 2023),这将有助于提高营销曝光效果(Leung et al., 2022)。一方面,消费者可能会忘记他们观看的首位 KOL 发布的推广内容、淡化随即产生的说服效果(He and Klein, 2023),而多重曝光会唤醒他们对首位 KOL 推广内容的记忆,尤其是对产品属性相关的信息,从而强化消费者对当前产品、品牌的记忆(Sahni and Nair, 2020)。这将增加消费者对品牌的熟悉度,有助于强化最终的沟通效果——实际购买行为(Rossiter and Percy, 1987)。另一方面,当消费者被推送多个 KOL 推荐的相同品牌时,他们推测这可能意味着该品牌的产品质量较高(Chen et al., 2011),这无疑增强了推广 KOL 内容所传递信息的说服力和产品的购买可能性(Boerman et al., 2017)。

然而,如果品牌已经与较多 KOL 合作,进一步增加合作数量可能适得其反。当用户持续被推送较多与品牌密切相关的 KOL 内容时,他们可能质疑内容的真实性和 KOL 的独立性(Sokolova and Kefi, 2020)。这是因为,KOL 推广内容的大量推送致使消费者感知到商业合作的存在和 KOL 参与背后的盈利动机(Boerman et al., 2017; Kim and Kim, 2021),推断品牌具有操纵意图(Isaac and Grayson, 2017)。这种操纵意图的判断会不同程度地激活说服知识,增强消费者对 KOL 和品牌的怀疑心理、降低可信度(Guo and Main, 2012),从而降低营销曝光效果,并影响最终的销售业绩(Campbell and Kirmani, 2000)。基于此,本文提出:

假说 3:在信息流平台,品牌合作的 KOL 数量与其多重曝光效果呈倒 U 型关联,随着合作 KOL 数量增加,多重曝光带来的订单量先上升后下降,且该倒 U 型曲线的转折点在数值上小于总体营销曝光效果模型(假说 1)中的转折点。

4. 推荐算法效率的调节效应

在信息流平台,KOL 的沟通效果和传统媒体平台可能存在关键差异,这种差异是由信息流平台的推荐算法造成的。当用户表现出对部分内容的兴趣时,推荐算法会基于行为特征进一步分析该用户感兴趣的关联内容,并将这些内容持续推荐给该用户(Wang et al., 2024)。由此可知,相比传统媒体平台,品牌在信息流平台利用 KOL 开展的商业行为更容易被用户完整观察到,当品牌合作的 KOL 数量较多时,推荐算法会进一步增加曝光给相同用户的 KOL 个数,这将促使消费者感知推广内容背后的商业动机(Boerman et al., 2017; Kim and Kim, 2021)。并且,当推荐算法更高效,即为用户更快地推荐更多其可能感兴趣的 KOL 发布的相关内容时,用户对其暗藏商业动机的怀疑会进一步加剧。与说服知识理论一致,当推广内容中的说服意图被消费者轻易觉察时,消费者的说服知识便更容易被激活,引起他们对 KOL 和品牌可信度的怀疑(Guo and Main, 2012)。总体而言,推荐算法通过增加多重曝光的次数和频率,从而放大了其可能带来的负面影响。在推荐算法的影响下,品牌合作的 KOL 数量与其营销曝光效果仍然存在倒 U 型关联;并且,当推荐算法更高效时,倒 U 型曲线将更早达到转折点(如图 1 所示)。基于此,本文提出:

假说 4:在信息流平台,当推荐算法的推荐效率更高时,品牌合作的 KOL 数量与其营销曝光效果之间的倒 U 型曲线会更加陡峭,边际收入下降越快,曲线达到最大值的转折点并向左移动。

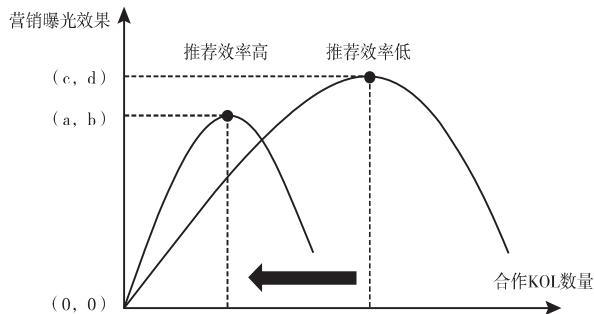


图1 倒U型曲线示意

综上所述,本文认为,品牌合作的KOL数量对品牌营销曝光效果呈现倒U型影响,当达到峰值后,与更多KOL合作会带来营销曝光效果的下降。并且,信息流平台高效的推荐算法会加剧这种倒U型影响——在高效推荐算法的影响下,品牌方会更早达到营销曝光效果的峰值点。将营销曝光效果进一步拆分为首位曝光效果和多重曝光效果后,基于KOL的可信度和传播力,KOL数量对首位曝光效果具有正向影响;基于多重曝光会激活消费者的说服知识、降低购买意愿,KOL数量对多重曝光效果具有倒U型影响。本文的研究假说演绎如图2所示。

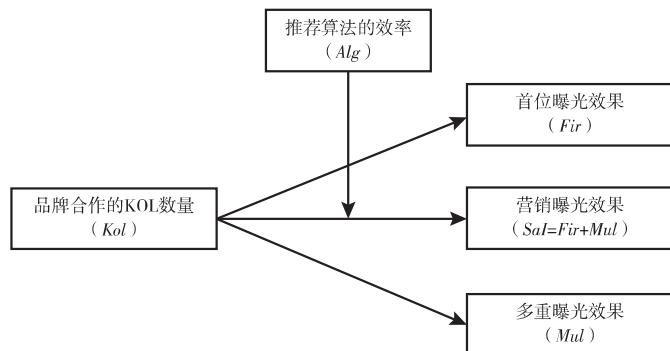


图2 假说演绎

四、研究设计

1. 样本选择

本文样本来自国内某知名短视频平台。该平台是备受推崇的信息流广告服务商,其广告主来源于数码、本地生活、服饰内衣、家具、钟表、运动户外等30个一级行业。该平台KOL生态活跃,截至2022年6月,粉丝量级在1万以上的KOL数量达到320万,同比增长约48%。基于此,在品牌营销的客观需求推动下,为了帮助广告主对接符合品牌、产品特性的KOL,平台建立了官方推广任务接单系统,为广告主和KOL提供内容交易过程中的角色连接与任务撮合服务,广告主可以在系统中选择合适的KOL并沟通推广内容需求,实现系统报价参考、订单流程管理、安全结算、数据统计等全流程管控。截至2022年6月,该接单系统的活跃KOL数量突破200万,同比增长300%,有效注册广告主数量超过190万,覆盖32个一级行业和259个二级行业。

本文从该平台接单系统的合作客户中随机抽取了2000名广告主样本,收集了2021年3月至2022年2月的月度数据,这种抽样方法避免了非随机抽样产生的数据选择问题。之所以选择月度数据,主要考虑到:①营销曝光效果会受到以月为单位的周期性影响;②品牌与KOL的合作包括品牌营销和活动营销两类,品牌营销的合作周期较长,合作计划制定一般逐月进行,而活动营销的持续时间较短,根据活动需求每周或每日调整,因此月度数据能够充分反映品牌合作KOL数量的变化。在数据集中,约91.9%的广告主合作的KOL数量至少发生过一次变化,平均变化幅度为3.06。因为KOL合作的平均数量较小,所以这种变化非常显著。此外,因为业内通用的广告效果归因周期为7日,即统计用户看到KOL营销广告后7日内产生的订单量并将其归因至广告触达当日,所以这里也将2022年3月1日至2022年3月7日的订单量补充入数据集中。因月度数据缺失、KOL合作中止,本文共计剔除66个广告主样本,最终得到1934个广告主样本。

2. 变量测量

(1)自变量。本文的自变量为每个品牌每月合作的KOL数量。由于信息流平台的内容时效性较高,营销效果自内容发布以来随着时间的推移而持续衰减,且推荐算法很少会为用户推送1月前发布的内容,因此,这里只计算在当月与品牌存在合作的KOL,合作时间与当月首条推广内容的发布日期保持一致。

(2)因变量。假说1、假说4中的因变量是品牌通过KOL营销获取的月度总订单量,假说2、假说3的因变量分别是首位曝光订单量和多重曝光订单量。本文选取的信息流平台允许在KOL发布的推广内容下方嵌入购买链接,用户可以点击链接直接购买,不同购买链接中分别标注了其所属的KOL和内容ID。因此,即使用户在品牌方合作的多个KOL发布的多个推广内容下购买了同样的商品,本文获取的数据集仍然可以区分订单来源。

总订单量:当用户在某日看过KOL和某品牌营销内容后,统计其后续7日内点击该KOL的购买链接产生的订单量。采取7日的归因标准有以下两个原因:一是业内普遍采用7日的周期进行广告效果归因;二是在7日后通过原始链接进行下单购买的用户仅占比0.029%,按照统计标准,可以忽略不计。此外,若存在同一用户看到多个不同KOL的内容后再点击链接进行下单购买,本文将用户购买前点击的最后一位KOL的品牌推广内容作为该订单的来源。随后,将该品牌方合作的每个KOL每日的订单量进行加总,从而计算得到KOL营销带来的月度总订单量。

首位曝光订单量:当用户接触到与某品牌合作的其中一位KOL发布的推广内容后,尚未通过算法推送、主动访问等方式触达该品牌合作的其他KOL发布的内容,并直接点击首位KOL内容中的购买链接下单。这一行为带来的订单量即为首位曝光效果。为此,本文在标准归因模型中增加了一项前置判断条件,即对于成功归因的订单量,当品牌ID与该广告主匹配时,限制消费者的KOL内容触点恒定为1,而该项限制的时间窗口为7日(理由同上),从而计算得到首位曝光订单量。

多重曝光订单量:当用户接触两位及以上KOL发布的推广内容后,点击内容中的购买链接下单。这一行为带来的订单量即为多重曝光效果。根据定义,品牌通过KOL营销获取的总订单量是首位曝光和多重曝光带来的订单量之和,该变量可由此计算。

(3)调节变量。本文选取的调节变量是推荐算法的推荐效率,并利用推荐算法带来的订单增量占总订单量的比率来衡量。当推荐算法识别到用户对KOL发布的推广内容进行点赞、评论、转发等行为时,便自动判定用户对该类内容或相关的内容感兴趣,进而将其他KOL发布的该品牌相关的内容推荐给用户。如果用户点击这些内容中的购买链接下单,这一订单即为推荐算法带来的订单增量。换言之,只需要额外计算这部分订单增量即可。参考过往文献,计算“订单增量”的最佳方

法是采用线上随机试验 A/B 测试。例如,某广告主与 A、B、C 三位 KOL 合作发布品牌推广内容,将用户随机划分为两组。对于 A 发布的推广内容,其中一组用户的点赞、评论等互动行为数据支持推荐模型调用训练;而另一组用户的相关数据回传链接失效,不支持模型调用。最后,直接计算两组用户在 B、C 两位 KOL 发布的推广内容下产生的订单量的差值,该差值即为推荐算法 A 带来的“订单增量”。随机实验能够保证两组广告除了互动数据被推荐算法应用与否这一区别外,其他控制因素都是相似的,从而将该差异完美归因到推荐算法的影响,Sahni and Nair(2020)在信息流广告相关研究中采用这种方法。

考虑到随机试验 A/B 测试需要人为干预互动数据的回传状态,以及利用广告主模拟 KOL 营销场景,存在伦理性、成本过高等问题,本文选用二手数据进行度量。二手数据不能使用随机分组来平衡混杂因素(Confounding effect)对结果的影响,因为本文观察到的效果差异同时包含了处理效应(Treatment Effect)和选择性偏差(Selection Bias),其中选择性偏差的出现是由于实验组和对照组的用户在 KOL 偏好、互动行为等多种影响因素上存在差异。针对该问题,Johnson et al.(2017)开发了“幽灵广告”(Ghost Ads)方法,比 A/B 测试在实验成本上更具优势,测量精度也更高,同时还提供一种变体“预测幽灵广告”(Predicted Ghost Ads)方法,能够与在线广告平台兼容。

鉴于本文对于预测准确率的较高要求,本文参考 Künzel et al.(2019)的测量方法,利用元学习算法(Meta Learning)分别估计用户在互动、不互动(即推荐算法是否产生作用)时的结果。因为选取的互动和不互动两组之间的数据量可能差异较大,所以借鉴元学习算法中的 X—learner 模型以解决该问题。具体来说,本文测算订单增量的步骤如下所示:

首先,构建实验组和对照组。将数据集中所有与广告主合作的 KOL 随机分为 group0 和 group1 两部分,将与 group0 中的 KOL 进行互动的用户样本归类于实验组,未与 group0 中的 KOL 进行互动的用户样本归类于对照组。对于实验组(与 group0 中的 KOL 产生互动行为的用户样本),其正例为产生互动后,被算法继续推送 group0 中 KOL 发布的内容并下单的用户(Convert);其负例为产生互动后,被算法继续推送 group0 中 KOL 发布的内容且并未下单的用户(No Convert)。对于对照组(未与 group0 中的 KOL 产生互动行为的用户样本),其正例为没有与 group0 的 KOL 产生互动行为,但与 group1 的 KOL 产生互动行为后,被算法继续推送 group0 中 KOL 发布的内容后下单的用户(Convert);其负例为没有与 group0 的 KOL 产生互动行为,但与 group1 的 KOL 产生互动行为后,被算法继续推送 group0 中 KOL 发布的内容且并未下单的用户(No Convert)。

其次,测量模型。第一步,利用监督学习预估用户在互动、不互动两种条件下因为算法推荐产生的订单量,分别对实验组和对照组进行建模,拟合模型如下:

$$\begin{aligned}\mu_{Control}(X) &= E(Y^{Advertising}|X = \chi_{Advertising}) \\ \mu_{Treatment}(X) &= E(Y^{no Advertising}|X = \chi_{no Advertising})\end{aligned}\quad (1)$$

第二步,利用上述拟合模型以交叉预估的方式得到实验组和对照组的增量。具体操作是,用实验组的模型 $\mu_{Treatment}$ 训练对照组数据,将预估结果减去对照组的真值,得到实验组的增量 $D_{Treatment}(X_i)$;用对照组的拟合模型 $\mu_{Control}(X)$ 训练实验组数据,并用实验组的真值减去结果,得到对照组的增量 $D_{Control}(X_i)$ 。具体模型如下:

$$\begin{aligned}D_{Control}(X_i) &= Y_i^{Treatment} - \hat{\mu}_{Control}(X_i^{Treatment}) \\ D_{Treatment}(X_i) &= \hat{\mu}_{Treatment}(X_i^{Control}) - Y_i^{Control}\end{aligned}\quad (2)$$

其中, $Y_i^{Treatment}$ 和 $Y_i^{Control}$ 分别代表实验组和对照组的真值, $X_i^{Treatment}$ 和 $X_i^{Control}$ 分别是实验组和对照组

的特征向量。

第三步:利用拟合模型预估的实验组和对照组增量 $D_{Control}(X_i)$ 和 $D_{Treatment}(X_i)$,本文将两者分别作为自变量构建了回归模型 $\hat{\tau}_{Control}(x)$ 和 $\hat{\tau}_{Treatment}(x)$ 拟合增量,然后通过对 $\hat{\tau}_{Control}(x)$ 和 $\hat{\tau}_{Treatment}(x)$ 两个模型进行加权计算,得到条件平均处理效应(CATE:比较样本中每个个体在政策施加与否时的效果差异)。具体模型如下:

$$\hat{\tau}(x) = g(x) \times \hat{\tau}_{Treatment}(x) + (1 - g(x)) \times \hat{\tau}_{Control}(x) \quad (3)$$

$$\hat{\tau}(X) = E(\tilde{D}^{Treatment}|X = \chi_{Treatment}) = E(\tilde{D}^{Control}|X = \chi_{Control}) \quad (4)$$

其中, $\hat{\tau}_{Treatment}(x)$ 是对 $\tilde{D}^{Treatment}(\chi_{Treatment})$ 的建模; $\hat{\tau}_{Control}(x)$ 是对 $\tilde{D}^{Control}(\chi_{Control})$ 的建模。其中,先验权重函数 $g(x)$ 选用了倾向性得分加权,以控制非随机分配带来的可观测值差异,同时提高预估准确性。同时,在模型中属性为 x 的广告主属于处理组的概率,通过倾向性得分 $e(x)$ 描述。最后,本文的倾向性得分是通过Probit模型进行估计的,也就是 $\hat{e}(x) = \Pr(T = 1|x_1, x_2, x_3 \dots x_n)$,其中,用户特征 x_n 则为模型中可观测的协变量。

3. 模型设计与变量定义

(1) 主效应。本文通过品牌月度数据分析检查了品牌合作KOL数量对其营销曝光效果的影响,最终采用Poisson回归进行估计。主要原因是:①由计算得到的月度总订单量、首位曝光订单量以及多重曝光订单量可知,因变量均为非负整数形式的计数数据,不适合使用OLS模型进行回归检验。②囿于变量存在零值数据,不适合使用对数线性模型。

本文对三项模型进行Hausman检验,结果显示固定效应模型更适合本文的研究情景($p < 0.001$)。此外,鉴于品牌方所处行业、平台推广的时间也可能对本文的估计结果产生影响,本文采用双向固定效应模型,以控制品牌所属行业可能带来的异质性影响和时间因素产生的异质性影响。具体的估计模型如下:

$$\begin{aligned} Sal_{i,t}/Fir_{i,t}/Mul_{i,t} = & \beta_0 + \beta_1 Kol_{i,t} + \beta_2 Kol^2_{i,t} + \beta_3 Qty_{i,t} + \beta_4 Qua_{i,t} + \beta_5 Fas_{i,t} \\ & + \beta_6 Sco_{i,t} + \beta_7 Sku_{i,t} + \lambda_t + \mu_i + \varepsilon_{i,t} \end{aligned} \quad (5)$$

其中, i, t 分别表示所在行业、时间, λ_t 表示时间固定效应, μ_i 表示行业固定效应, $\varepsilon_{i,t}$ 表示误差项。自变量为品牌合作的KOL数量,因变量分别为月度总订单量、首位曝光订单量以及多重曝光订单量(消费者可以通过KOL推广内容中的专属购买链接下单,或通过搜索品牌、商品名称进入品牌主页下单)。为了捕捉因变量与自变量之间可能存在的倒U型关系,本文在模型中添加了自变量的线性项和二次项。

此外,为控制其他因素的影响增加了部分控制变量:①内容数量。根据Escalas and Bettman (2017),KOL增加内容推送频率能够提高用户对其的信任度,用户开始相信他们与KOL很熟悉,从而带来更多的参与度,因此,更有可能做出回应。②内容质量。KOL通常使用个性化的方法来展示合作品牌的产品如何融入他们的日常生活,当推广内容的质量较高时,KOL可能被认为是知识渊博、可信的伙伴,用户更愿意与之互动(Kim and Kim, 2021),并且认为这些产品是值得信赖的(Leung et al., 2022),推广内容的转化率也相应提升,本文利用视频平均完播率指标衡量内容质量。③内容推送量。过去的研究已经观察到,过度曝光可能会对品牌产生反作用,信息的有效性持续下降,甚至最终唤起用户对品牌的负面情绪(Leung et al., 2022),为了准确评估KOL数量的影响,将内容推送量加入模型。④粉丝数量。更多粉丝意味着更多的潜在受众、更大的信息传播范围,KOL拥有更大的影响力(De Veirman et al., 2017),从而积极影响在线销售业绩。⑤品牌声誉(商

品/服务/物流)。声誉是品牌的无形资产(Rice, 2012),选用品牌体验分来衡量商家声誉,体验分源于用户购后对商品/服务/物流的综合评价。⑥商品SKU数量。现有研究认为,提供较多数量的商品能够满足多样性需求、优化体验(Levav and Zhu, 2009),而当商品SKU较多时,消费者体验到更多的选择困难,满意度降低,更容易产生后悔情绪(Chernev, 2003)。关键变量的描述性统计内容如表1所示。^①

表1 变量与描述性统计(部分)

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	总订单量	Sal	品牌通过KOL营销产生的月度总订单量(总订单量=首位曝光订单量+多重曝光订单量)	1468.1065	1726.2807	0.0000	21069.0000
	首位曝光订单量	Fir	用户只触达品牌合作的一位KOL后产生的月度订单量	877.0614	1244.5266	0.0000	15108.0000
	多重曝光订单量	Mul	用户触达品牌合作的两位及以上KOL后产生的月度订单量	591.0538	842.4945	0.0000	7594.0000
自变量	KOL合作数量	Kol	品牌当月合作的KOL数量	8.37692	19.2917	0.0000	149.0000
调节变量	推荐算法的效率	Alg	推荐算法带来的订单增量占总订单量(Sal)的比率	0.2097	0.2658	0.0000	0.4382

由于本文选取的短视频平台的接单系统能够实现将每一个用户产生的订单与推广内容的触达时间一一匹配,并且在数据处理时,能够将用户7日内的订单归因于他们看到KOL推广内容的那一天,所以本文不存在明显的以天为单位的滞后效应。因此,本文的模型并未包含自变量KOL合作数量的滞后项。此外,所有模型的VIF值小于严格临界值5,表明模型不存在显著的多重共线性问题。本文主要关注 β_1 和 β_2 的系数,分别代表品牌合作的KOL数量及其平方项对其营销曝光效果所产生的影响,若 β_1 系数显著为正,且 β_2 系数显著为负,则证明两者之间具有倒U型关系,并且可以通过计算获得KOL数量的关键拐点。若 β_1 系数显著为正,而 β_2 系数不显著,则证明KOL数量对其营销曝光效果具有正向影响,而不存在非线性关系。

(2)调节效应。为证明推荐算法效率的调节效应,在式(5)中引入调节变量(Alg)及其与自变量(Kol)、自变量平方项(Kol²)的交互项,因变量为月度总订单量,控制变量不变。与前文一致,采用Poisson回归结合双向固定效应模型检验调节效应假设。具体模型如下:

$$\begin{aligned} Sal_{i,t} = & \beta_0 + \beta_1 Kol_{i,t} + \beta_2 Kol^2_{i,t} + \beta_3 Alg_{i,t} + \beta_4 Alg_{i,t} \times Kol_{i,t} + \beta_5 Alg_{i,t} \times Kol^2_{i,t} + \beta_6 Qty_{i,t} \\ & + \beta_7 Qua_{i,t} + \beta_8 Fas_{i,t} + \beta_9 Sco_{i,t} + \beta_{10} Sku_{i,t} + \lambda_t + \mu_i + \varepsilon_{i,t} \end{aligned} \quad (6)$$

随后,将计算倒U型曲线的转折点,对式(6)求导可得转折点X:

$$X = \frac{-\beta_1 - \beta_4 Alg}{2\beta_2 + 2\beta_5 Alg} \quad (7)$$

假说4主要关注 β_1 、 β_2 、 β_4 、 β_5 的系数, β_1 和 β_2 分别代表品牌合作的KOL数量及其平方项对其营销曝光效果产生的影响,若 β_1 系数显著为正,且 β_2 系数显著为负,则证明两者之间具有倒U型关系。

^① 完整的变量与描述性统计参见《中国工业经济》网站(ciejournal.ajcass.com)附件。

此外,为了说明转折点是如何基于调节变量(Alg)而改变的,在式(7)对调节变量(Alg)进行求导得:

$$\frac{dX}{dAlg} = \frac{\beta_1 \times \beta_5 - \beta_2 \times \beta_4}{2 \times (\beta_2 + \beta_5 Alg)^2} \quad (8)$$

由于式(8)的分母 $2 \times (\beta_2 + \beta_5 Alg)^2$ 严格大于 0,因此转折点移动的方向取决于分子 $\beta_1 \times \beta_5 - \beta_2 \times \beta_4$ 的符号,如果 $\beta_1 \times \beta_5 - \beta_2 \times \beta_4$ 大于 0,证明转折点将随着调节变量(Alg)的增大向右移动,如果 $\beta_1 \times \beta_5 - \beta_2 \times \beta_4$ 小于 0,转折点将左移。利用该式继续检验倒 U 型曲线陡峭程度变化,如果 β_5 系数显著为正,曲线变平滑,若 β_5 系数显著为负,则曲线变陡峭。

五、实证结果及分析

1. 基准回归结果^①

在总体营销曝光效果方面,由表 2 第(1)列的回归结果可知,品牌合作的 KOL 数量(Kol)对其带来的总订单量(Sal)具有显著的正向影响,而其平方项(Kol^2)的系数显著为负($\beta=-0.003, p < 0.01$)。这证实了假说 1,即随着品牌合作的 KOL 数量增加,其带来的在线总订单量先上升后下降。并且 KOL 数量的转折点约为 20.22,在此处广告主能够相应获得最佳销售业绩,即最佳的营销曝光效果。

在首位曝光效果方面,由表 2 第(2)列的回归结果可知,品牌合作的 KOL 数量(Kol)对其带来的首位曝光订单量(Fir)具有显著的正向影响,而其平方项(Kol^2)的系数不显著($\beta=-0.001, p > 0.1$)。这一结果证实了假说 2,即随着合作 KOL 数量增加,首位曝光带来的订单量持续上升,而不存在非线性的倒 U 型关系。在多重曝光效果方面,由表 2 第(3)列的回归结果可知,品牌合作的 KOL 数量(Kol)对其带来的多重曝光订单量(Mul)具有显著的正向影响,且其平方项(Kol^2)的系数显著为负($\beta=-0.005, p < 0.01$)。这证实了倒 U 型假设(假说 3),即随着品牌合作的 KOL 数量增加,其带来的多重曝光订单量先上升后下降,而 KOL 数量的转折点约为 15.57,小于总体营销模型的倒 U 型转折点(20.22)。这也从侧面证明,当 KOL 数量过多时,其对订单量的负向影响主要是通过减少多重曝光效果而实现的,而其对于首位曝光效果的正向影响则暂缓了转折点的出现。

在调节效应方面,由表 2 第(4)列的回归结果可知,品牌合作的 KOL 数量(Kol)对其带来的总订单量(Sal)具有显著的正向影响,且其平方项(Kol^2)的系数显著为负($\beta=-0.001, p < 0.01$)。这证实了倒 U 型假设。继续检验转折点移动方向, β_4, β_5 系数是显著的($\beta_4=0.051, p < 0.01; \beta_5=-0.003, p < 0.05$),且 $\beta_1 \times \beta_5 - \beta_2 \times \beta_4$ 小于 0,说明随着推荐算法的效率提高,转折点将向左移动。最后,检验曲线形状变化, β_5 系数显著为负,说明随着推荐算法的效率提高,倒 U 型曲线更加陡峭,边际收入下降更快,曲线到达拐点的速度也相应更快。因此,结果支持了假说 4。

2. 倒 U 型关系的进一步验证

为了进一步验证倒 U 型假说,本文参考了 Lind and Mehlum(2010)的三步检验法,结果见表 3。二次项系数显著为负($\beta_2 < 0, p < 0.01$);KOL 数量的下边界处的斜率显著为正($\beta_1 + \beta_2 \times X_l > 0, p < 0.01$),而上边界处的斜率显著为负($\beta_1 + \beta_2 \times X_h < 0, p < 0.01$),其内部转折点($-\beta_1 / 2\beta_2$)及其 90% 的置信区间位于数据范围内。基于此,本文得出结论,品牌合作的 KOL 数量及其绩效之间的函数关系是一条完整的倒 U 型曲线。

^① 完整的基准回归结果参见《中国工业经济》网站(ciejournal.ajcass.com)附件。

表 2 基准回归结果(部分)

变量	(1)	(2)	(3)	(4)
	<i>Sal</i>	<i>Fir</i>	<i>Mul</i>	<i>Alg</i>
<i>Kol</i>	0.1246*** (0.0254)	0.1090*** (0.0173)	0.1400*** (0.0217)	0.0961*** (0.0089)
<i>Kol</i> ²	-0.0027*** (0.0002)	-0.0012 (0.0007)	-0.0045*** (0.0001)	-0.0009*** (0.0001)
<i>Alg</i>	/	/	/	1.0744*** (0.1192)
<i>Alg</i> × <i>Kol</i>	/	/	/	0.0509*** (0.0125)
<i>Alg</i> × <i>Kol</i> ²	/	/	/	-0.0030** (0.0014)
R ²	0.0916	0.1097	0.0733	0.0676
N	23208.0000	23208.0000	23208.0000	23208.0000

注:***、**和*分别表示在1%、5%和10%水平上显著,括号内为p值,以下各表同。

表 3 倒U型假说的三步检验结果

变量	<i>B</i> ₁	(1)	(2)
		<i>Sal</i>	<i>Mul</i>
<i>Kol</i>	<i>B</i> ₁	0.1548*** (0.0142)	0.1739*** (0.0196)
<i>Kol</i> ²	<i>B</i> ₂	-0.0044*** (0.0001)	-0.0052*** (0.0000)
下边界	<i>B</i> ₁ + <i>B</i> ₂ × <i>X</i> ₁	0.1554*** (0.0107)	0.1735*** (0.0143)
上边界	<i>B</i> ₁ + <i>B</i> ₂ × <i>X</i> _h	-0.4409*** (0.1172)	-0.5711*** (0.0815)
转折点	- <i>B</i> ₁ /2 <i>B</i> ₂	19.3339	16.0215
90%置信区间		∈(0, 149)	

3. 稳健性检验

为检验模型的稳健性,本文从自变量的测量方法和模型的估计方法两方面入手:对于自变量的测量,选择品牌方的KOL营销支出(*Spend*)代替原来的自变量品牌方合作的KOL数量(*Kol*)。因为品牌方在接单系统中按照合作计划付费,所以这里将营销支出的产生时间与计划内首条推广内容的发布日期保持一致,并对该变量进行对数化处理,而其他变量与原模型设定一致,使用替换后的自变量重复前文的实证分析。对于估计方法,采用负二项回归(Nbreg)方法代替原来的泊松回归(Poisson)。在实际操作中,本文保持其他模型设定不变,采用负二项回归再次进行模型检验。结果显示,四个模型主要变量的符号、显著性水平没有发生显著的变化。这意味着,本文的结果具有较好的稳健性。

4. 内生性讨论与处理

本文的回归结果仍可能面临内生性问题的挑战。具体来说,在本文的研究情境下,自变量与

因变量之间可能存在双向因果关系。一方面,如前文所述,KOL数量的增加能够带来更高的曝光度,从而有利于提升品牌的营销曝光效果;然而,当KOL数量过多时,也可能对营销曝光效果产生负面影响。另一方面,较好的营销曝光效果反映了用户对产品的认可度和喜爱度,这可能促使品牌方对营销收入和在线市场份额产生更高的期望,进而驱动品牌方与更多KOL建立合作关系以实现这些预期目标。

本文采用工具变量法处理上述可能存在的双向因果问题。具体地,选取KOL的平均合作费用作为工具变量,原因如下:①KOL的平均合作费用与误差项不相关。因为用户通常无法得知品牌方支付给KOL的合作费用,所以这种商业行为不会对用户的购买决策过程产生直接影响。进而,KOL的平均合作费用也不会直接作用于KOL营销沟通的曝光效果。②KOL的平均合作费用与品牌合作的KOL数量相关。品牌通常有相对固定的营销支出计划,他们会根据KOL的平均合作费用、品牌的营销支出计划来选择合作KOL的数量。当KOL的合作费用更高时(如拥有较多粉丝的头部KOL),商家会选择减少合作的KOL数量;而当商家倾向于和粉丝量级较少、收费较低的腰部KOL合作时,他们会适当提高签约的KOL数量。

在选取工具变量后,本文采用广义矩估计方法(GMM)进行检验。本文的工具变量通过了弱工具变量检验和过度识别检验,这意味着选取KOL的平均合作费用作为工具变量是有效的,并且这一工具变量是外生变量。具体的工具变量检验结果如表4所示,主要变量的符号、显著性水平并未发生显著变化,依旧支持原有假说。基于此,本文认为,本研究的模型不存在显著的内生性问题,结论是依旧是稳健的。^①

表4 工具变量检验结果(部分)

变量	(1)	(2)	(3)	(4)
	<i>Sal</i>	<i>Fir</i>	<i>Mul</i>	<i>Alg</i>
<i>Kol</i>	0.1088*** (0.0171)	0.0985*** (0.0204)	0.1167*** (0.0125)	0.0823*** (0.0057)
<i>Kol</i> ²	-0.0026*** (0.0001)	-0.0004 (0.0003)	-0.0033*** (0.0001)	-0.0008*** (0.0000)
<i>Alg</i>	/	/	/	0.8780*** (0.0721)
<i>Alg</i> × <i>Kol</i>	/	/	/	0.0405*** (0.0124)
<i>Alg</i> × <i>Kol</i> ²	/	/	/	-0.0021** (0.0009)
R ²	0.0739	0.1027	0.0683	0.0545
N	23208.0000	23208.0000	23208.0000	23208.0000

六、结论与政策启示

1. 研究结论

尽管利用KOL进行消费者沟通越来越受品牌方欢迎,但面对高昂的KOL合作成本,仍有一些

^① 完整的内容参见《中国工业经济》网站(ciejournal.ajcass.com)附件。

问题需要解决。特别是,在营销活动期间,品牌方往往通过KOL的规模化、矩阵式投放进行铺量,从而获得高曝光度与高转化率。但是,这种方法是否行之有效,与更多KOL合作是否能带来更多销量、更好的曝光效果?如果不是,品牌应当如何确定最佳的合作数量?这些问题本文的研究重点。

总体而言,本研究聚焦于信息流平台的KOL营销,利用Poisson模型估计了品牌合作的KOL数量对营销曝光效果的影响。同时,为了更全面地分析各影响因素在何种情况下产生作用,本文将营销曝光效果拆分为首位曝光效果和多重曝光效果,并分别检验KOL数量与两种曝光效果之间的关系。最后,本文还额外考虑了KOL营销在信息流平台和传统媒体平台的差异,将其归因为高效推荐算法的存在,随后检验了推荐算法效率的调节作用,本文利用元学习X-learner模型计算推荐算法的推荐效率,并进一步验证推荐效率的改变是否引起倒U型曲线转折点移动。最终得出以下研究结论:

(1) 品牌合作的KOL数量与其带来的总订单量这一最终沟通成果呈倒U型关联,随着合作KOL数量增加,总订单量先上升后下降。这是因为,品牌与适量KOL合作能够将品牌信息覆盖更多用户,并且对相同用户进行重复触达,这有助于改善营销曝光效果;但是过度重复也会激活用户的说服知识,这对用户的购买意愿造成负面影响,因此,品牌与过多KOL合作反而削弱了营销曝光效果。

(2) 当研究对象聚焦于用户只接触一位KOL的推广内容后产生的订单(首位曝光效果),本文发现品牌合作的KOL数量对这种首位曝光效果就只存在正向作用,而不是非线性的倒U型关系。这也验证之前的部分假说,在排除推广内容重复触达用户的影响后,更多KOL可以实现更大规模的信息覆盖,并且提高用户的购买意愿。

(3) 继续评估用户接触两位及以上KOL的推广内容后产生的订单(多重曝光效果),本文发现品牌合作的KOL数量与多重曝光效果呈倒U型关联,随着合作KOL数量增加,多重曝光订单量先上升后下降,且倒U型曲线的转折点在数值上小于假说(1)模型。这表明,KOL数量对于营销曝光效果的负面影响确实源于过多KOL触达用户,多重曝光固然能够通过提醒效应和信息传播效应将消费者的购买意图转化为实际购买行为,但是也更容易让消费者感知KOL背后的盈利动机,导致消费者质疑KOL及其推广内容的可信度,影响KOL沟通的营销曝光效果。

(4) 信息流平台的核心议题是推荐算法,本文证明了推荐算法具有显著的调节效应,随着推荐效率的提高,品牌合作的KOL数量与其营销曝光效果之间的倒U型曲线转折点将向左移动。这是因为,在KOL数量一定的情况下,高效的推荐算法进一步提高了曝光给相同用户的KOL个数,从而通过加剧多重曝光的负面效应来影响倒U型关联,这也是KOL营销在信息流平台和传统媒体的关键差异。

2. 管理启示

(1) 优化KOL合作策略。利用KOL进行营销沟通并不会和传统广告一样随着投放量增加而带来业绩的线性增长,而是呈现倒U型关系。随着KOL合作数量的增加,营销曝光效果将在某一点达到峰值,随后下降。换言之,即使品牌方在活动期间投入更多预算,选择更多受欢迎的KOL合作,也可能无法达到最佳沟通效果,甚至可能导致大量损失,这与一些品牌方的管理直觉相矛盾。基于此,本文建议品牌方优化KOL合作策略,了解和量化增加KOL合作数量所带来的边际收入变化,通过最优点(倒U型曲线的转折点附近)选择合适的KOL合作数量,以显著提高KOL营销的有效性。

对此,本文建议推动KOL营销沟通的数据科学与人工智能(AI)技术相衔接。对企业来说,通过分析信息流平台的历史数据、训练算法模型,AI技术可以不断优化对KOL数量带来的营销曝光效果的预测,从而给企业提供更好的决策建议。例如,品牌方可以利用大数据、AI工具量化KOL合作数量的边际收益。通过不断测试和调整合作策略,品牌方可以找到最优的KOL合作数量,从而最大化营销曝光效果。此外,品牌方应根据KOL的影响力和粉丝群体的特性进行分层级选择,以便更精准、更广泛的覆盖目标消费者群体。

而对平台方来说,平台方可以根据本文的发现,优化推荐算法以减少内容重复和提高内容多样性,从而提升用户体验。通过智能推荐系统,平台可以更有效地将品牌方的营销内容精准地推送给目标消费者,提升营销效果。此外,平台方也可以提供实时数据分析工具,为品牌方调整合作策略、提升营销效果提供一定的技术支持。

(2)强化首位曝光效应。鉴于过多KOL的负向影响主要源于多重曝光,而其与首位曝光效果之间的关系则始终是正向的,本文鼓励品牌方通过渠道分配来增强首位曝光的正向影响,而尽可能削弱多重曝光的负向影响。例如,品牌方可以将合作的KOL分散至多个信息流平台上,并且注意规避不同KOL粉丝群体的关联性。这一方面可以提高用户覆盖,在活动期间快速引爆话题点并提高转化率,另一方面也可以缓解多重曝光造成的边际收入下降趋势,从而增强沟通效果。

(3)优化推广内容设计。当品牌方已经与较多KOL保持合作时,推荐算法的存在能够加剧多重曝光的负面影响。为了削弱这一负面影响,本文也建议品牌方在与KOL合作时注重推广内容的优化,在活动期间尽可能降低不同推广内容之间的相似性和关联度,并尝试多样化的品牌披露形式。例如,品牌方可以允许KOL以自己的语言和风格制作内容,避免使用同质化的关键词,更不能直接复制品牌方提供的同一套宣传文案。这样做好处是,即使用户对某KOL发布的品牌推广内容产生点赞、评论、收藏等互动行为,推荐算法也不会持续给用户推荐其他KOL发布的相同或高度相似的品牌推广内容。

聚焦信息流平台的KOL营销沟通,本文挑战了以往的管理直觉,发现与更多的KOL合作不一定会带来更好的营销曝光效果,尤其在多重曝光中,过多KOL的弊端愈加凸显。未来研究应更深入地应用数据科学和人工智能技术,探索如何寻找最佳合作点,为企业和平台方提供更可行的最佳点测算方法,优化KOL营销决策。此外,本文仅研究了短视频平台KOL合作的营销曝光效果,并探讨了其与传统平台的差异性,未来可以进一步探索其他信息流平台和渠道,以及不同信息流平台营销曝光效果的差异性。

〔参考文献〕

- [1]曾伏娥,顾梅梅,刘敏.社交媒体图文型广告的“得”与“失”:商家形象 vs. 产品态度[J].中国工业经济,2019,(10): 175-192.
- [2]Boerman, S. C., L. M. Willemse, and E. P. Van Der Aa. “This Post Is Sponsored” Effects of Sponsorship Disclosure on Persuasion Knowledge and Electronic Word of Mouth in the Context of Facebook [J]. Journal of Interactive Marketing, 2017, 38(1): 82-92.
- [3]Campbell, M. C., and A. Kirmani. 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.
- [4]Campbell, M. C., and A. Kirmani. I Know What You’re Doing and Why You’re Doing It[A]. Haugvedt, C. P., P. M. Herr, and F. R. Kardes. Handbook of Consumer Psychology[C]. New York: Routledge, 2008.
- [5]Chen, L., Y. Chen, and Y. Pan. The Effect of Sponsored Video Customization on Video Shares: The Critical Moderating

- Role of Influencer and Brand Characteristics[J]. European Journal of Marketing, 2024, 58(4): 1047–1082.
- [6] Chen, Y., Q. Wang, and J. Xie. Online Social Interactions: A Natural Experiment on Word of Mouth Versus Observational Learning[J]. Journal of Marketing Research, 2011, 48(2): 238–254.
- [7] Chernev, A. When More Is Less and Less Is More: The Role of Ideal Point Availability and Assortment in Consumer Choice[J]. Journal of Consumer Research, 2003, 30(2): 170–183.
- [8] De Veirman, M., V. Cauberghe, and L. Hudders. Marketing through Instagram Influencers: The Impact of Number of Followers and Product Divergence on Brand Attitude[J]. International Journal of Advertising, 2017, 36(5): 798–828.
- [9] DeVito, M. A. From Editors to Algorithms: A Values-based Approach to Understanding Story Selection in the Facebook News Feed[J]. Digital Journalism, 2017, 5(6): 753–773.
- [10] Eelen, J., P. Özturan, and P. W. J. Verlegh. The Differential Impact of Brand Loyalty on Traditional and Online Word of Mouth: The Moderating Roles of Self-brand Connection and the Desire to Help the Brand[J]. International Journal of Research in Marketing, 2017, 34(4): 872–891.
- [11] Engeler, I., and K. Barasz. From Mix-and-Match to Head-to-Toe: How Brand Combinations Affect Observer Trust[J]. The Journal of Consumer Research, 2021, 48(4): 562–585.
- [12] Escalas, J. E., and J. R. Bettman. Connecting with Celebrities: How Consumers Appropriated Celebrity Meanings for a Sense of Belonging[J]. Journal of Advertising, 2017, 46(2): 297–308.
- [13] Fink, M., M. Koller, J. Gartner, A. Floh, and R. Harms. Effective Entrepreneurial Marketing on Facebook-A Longitudinal Study[J]. Journal of Business Research, 2020, 113: 149–157.
- [14] Friestad, M., and P. Wright. The Persuasion Knowledge Model: How People Cope with Persuasion Attempts[J]. Journal of Consumer Research, 1994, 21(1): 1–31.
- [15] Gelper, S., R. van der Lans, and G. van Bruggen. Competition for Attention in Online Social Networks: Implications for Seeding Strategies[J]. Management Science, 2021, 67(2): 1026–1047.
- [16] Godey, B., A. Manthiou, D. Pederzoli, J. Rokka, G. Aiello, R. Donvito, and R. Singh. Social Media Marketing Efforts of Luxury Brands: Influence on Brand Equity and Consumer Behavior[J]. Journal of Business Research, 2016, 69(12): 5833–5841.
- [17] Grewal, D., Y. Bart, M. Spann, and P. P. Zubcsek. Mobile Advertising: A Framework and Research Agenda[J]. Journal of Interactive Marketing, 2016, 34(4): 3–14.
- [18] Guo, W., and K. J. Main. The Vulnerability of Defensiveness: The Impact of Persuasion Attempts and Processing Motivations on Trust[J]. Marketing Letters, 2012, 23(4): 959–971.
- [19] He, C., and T. J. Klein. Advertising as a Reminder: Evidence from the Dutch State Lottery[J]. Marketing Science, 2023, 42(5): 892–909.
- [20] Isaac, M. S., and K. Grayson. Beyond Skepticism: Can Accessing Persuasion Knowledge Bolster Credibility[J]. Journal of Consumer Research, 2017, 43(6): 895–912.
- [21] Johnson, G. A., R. A. Lewis, and E. I. Nubbemeyer. Ghost Ads: Improving the Economics of Measuring Online Ad Effectiveness[J]. Journal of Marketing Research, 2017, 54(6): 867–884.
- [22] Kim, D. Y., and H. Y. Kim. Influencer Advertising on Social Media: The Multiple Inference Model on Influencer-product Congruence and Sponsorship Disclosure[J]. Journal of Business Research, 2021, 130: 405–415.
- [23] Künzel, S. R., J. S. Sekhon, P. J. Bickel, and B. Yu. Metalearners for Estimating Heterogeneous Treatment Effects Using Machine Learning[J]. Proceedings of the National Academy of Sciences, 2019, 116(10): 4156–4165.
- [24] Leung, F. F., F. F. Gu, and R. W. Palmatier. Online Influencer Marketing[J]. Journal of the Academy of Marketing Science, 2022, 50(2): 226–251.
- [25] Levav, J., and R. Zhu. Seeking Freedom through Variety[J]. Journal of Consumer Research, 2009, 36(4): 600–610.

- [26] Leite, F. P., N. Pontes, and B. Schivinski. Influencer Marketing Effectiveness: Giving Competence, Receiving Credibility[J]. *Journal of Travel & Tourism Marketing*, 2024, 41(3), 307–321.
- [27] Libai, B., E. Muller, and R. Peres. Decomposing the Value of Word-of-mouth Seeding Programs: Acceleration Versus Expansion[J]. *Journal of Marketing Research*, 2013, 50(2): 161–176.
- [28] Lind, J. T., and H. Mehlum. With or Without U? The Appropriate Test for a U—Shaped Relationship[J]. *Oxford Bulletin of Economics and Statistics*, 2010, 72(1): 109–118.
- [29] Lou, C., and S. Yuan. Influencer Marketing: How Message Value and Credibility Affect Consumer Trust of Branded Content on Social Media[J]. *Journal of Interactive Advertising*, 2019, 19(1): 58–73.
- [30] Lyu, W., Y. Qi, and J. Liu. Proliferation in Live Streaming Commerce, and Key Opinion Leader Selection [J]. *Electronic Commerce Research*, 2022, (9): 1–34.
- [31] Mallipeddi, R. R., S. Kumar, C. Sriskandarajah, and Y. Zhu. A Framework for Analyzing Influencer Marketing in Social Networks: Selection and Scheduling of Influencers[J]. *Management Science*, 2022, 68(1): 75–104.
- [32] Niu, B., X. Yu., Q. Li., and Y. Wang. Gains and Losses of Key Opinion Leaders' Product Promotion in Livestream E-commerce[J]. Omega (Oxford), <https://doi.org/10.1016/j.omega.2023.102846>, 2023.
- [33] Park, J., J. M. Lee, V. Y. Xiong, F. Septianto, and Y. Seo. David and Goliath: When and Why Micro-influencers are More Persuasive than Mega-influencers[J]. *Journal of Advertising*, 2021, 50(5): 584–602.
- [34] Rice, S. C. Reputation and Uncertainty in Online Markets: An Experimental Study [J]. *Information Systems Research*, 2012, 23(2): 436–452.
- [35] Rossiter, J. R., and L. Percy. *Advertising and Promotion Management*[M]. New York: McGraw-Hill Book Company, 1987.
- [36] Sahni, N. S., and H. S. Nair. Sponsorship Disclosure and Consumer Deception: Experimental Evidence from Native Advertising in Mobile Search[J]. *Marketing Science*, 2020, 39(1): 5–32.
- [37] Scott, D. M. *The New Rules of Marketing and PR: How to Use Social Media, Online Video, Mobile Applications, Blogs, News Releases, and Viral Marketing to Reach Buyers Directly* [M]. Hoboken: John Wiley & Sons, 2015.
- [38] Sokolova, K., and H. Kefi. Instagram and YouTube Bloggers Promote It, Why Should I Buy? How Credibility and Parasocial Interaction Influence Purchase Intentions[J]. *Journal of Retailing and Consumer Services*, 2020, 53: 101742.
- [39] Wang, X., S. Wuji, Y. Liu, R. Luo, and C. Qiu. Study on the Impact of Recommendation Algorithms on User Perceived Stress and Health Management Behaviour in Short Video Platforms [J]. *Information Processing & Management*, <https://doi.org/10.1016/j.ipm.2024.103674>, 2024.
- [40] Woolley, K., and M. A. Sharif. Down a Rabbit Hole: How Prior Media Consumption Shapes Subsequent Media Consumption[J]. *Journal of Marketing Research*, 2022, 59(3): 453–471.
- [41] Xie, Q., and Y. Feng. How to Strategically Disclose Sponsored Content on Instagram? The Synergy Effects of Two Types of Sponsorship Disclosures in Influencer Marketing[J]. *International Journal of Advertising*, 2023, 42(2): 317–343.
- [42] Xiong, Y., Z. Cheng, E. Liang, and Y. Wu. Accumulation Mechanism of Opinion Leaders' Social Interaction Ties in Virtual Communities: Empirical Evidence from China[J]. *Computers in Human Behavior*, 2018, 82: 81–93.
- [43] Zhao, L., Z. Sun, S. Chen, R. Gugnani, and N. Sahore. Social Media Opinion Leaders and Information Diffusion of Crowdfunding Projects: Evidence from China [J]. *Technological Forecasting and Social Change*, <https://doi.org/10.1016/j.techfore.2023.123110>, 2024.
- [44] Zhang, Y., Z. Shao, J. Zhang, B. Wu, and L. Zhou. The Effect of Image Enhancement on Influencer's Product Recommendation Effectiveness: The Roles of Perceived Influencer Authenticity and Post Type [J]. *Journal of Research in Interactive Marketing*, 2024, 18(2): 166–181.

Marketing Exposure Effect of Information Flow Platform: An Analysis Based on Key Opinion Leader Marketing Communication

ZENG Fu-e, ZENG Yi-xuan, WANG Xue-ying, ZHANG Tian-you

(Economics and Management School, Wuhan University)

Abstract: In the information flow era, enterprises increasingly leverage key opinion leaders (KOLs) on information flow platforms to enhance marketing communication and achieve greater exposure. This study investigates whether collaborating with more KOLs genuinely benefits marketing performance and examines the differences in marketing performance between KOL collaborations on information flow media platforms and traditional media platforms.

By using panel data from a short video platform, this study employs a Poisson model to analyze the relationship between the number of KOLs and marketing exposure effects. The findings reveal an inverted U-shaped relationship between the number of KOLs and marketing exposure. Initially, as the number of KOLs increases, the total number of orders rises because more KOLs help disseminate information more broadly and enhance brand credibility, thereby increasing users' purchase intentions. However, beyond a certain threshold, additional KOLs lead to negative effects due to perceived commercial motives and reduced credibility.

Furthermore, this study distinguishes between first-exposure effects and multiple-exposure effects. While the number of KOLs positively impacts first-exposure effects, indicating that users make purchases after initially encountering KOL content, multiple-exposure effects exhibit a non-linear inverted U-shape. This indicates that excessive exposure can trigger negative reactions from consumers, reducing the credibility of KOLs.

This study also finds that the efficiency of recommendation algorithms significantly moderates the impact of the number of KOLs. High-efficiency recommendation algorithms increase the frequency of repeated exposure to the same user, amplifying the negative impact of multiple exposures and shifting the inverted U-shaped curve leftward. In this case, brands should reduce the number of KOL collaborations to avoid negative effects.

This study provides new insights into KOL marketing mechanisms in the streaming media era, challenging the traditional intuition that more KOL collaborations always yield better results. The findings offer practical guidance for brands to optimize their KOL collaboration strategies, enhance marketing communication effectiveness, and achieve maximum brand benefits. This nuanced understanding of KOL collaboration will help brands navigate the complexities of KOL marketing in an increasingly digital and saturated market.

Keywords: key opinion leader (KOL) ; exposure effect; first exposure; multiple exposure; persuasion knowledge

JEL Classification: M00 M31 M37

[责任编辑:张永坤]