

算得准为何留不住？AI 个性化到品牌忠诚的参与路径与信任边界

淦伟翔¹⁾，肖梦非^{1)†}，张乃千²⁾，岳秋荧¹⁾，陈思昆¹⁾，宋小琳¹⁾

1) 世纪大学，八打灵再也，雪兰莪州，马来西亚，47810；2) 重庆文理学院，重庆市永川区，402160

摘要 在数字平台逐步成为品牌经营与消费者互动的核心场域背景下，企业对 AI 驱动个性化技术的持续投入并未必然带来更稳固的品牌忠诚，技术绩效与关系回报之间的错位现象日益凸显。围绕 AI 驱动个性化在数字平台情境下如何影响品牌忠诚这一核心问题，本文构建以消费者参与为关键中介的作用机制，并进一步引入算法信任作为重要的情境性边界条件，以解释个性化效果在不同信任水平下的差异。研究采用定量研究方法并基于成熟量表开发问卷，运用偏最小二乘结构方程模型对测量模型与结构模型进行系统检验，并在控制共同方法偏差的基础上对直接效应、中介效应与调节效应进行综合分析。研究发现，AI 驱动个性化不仅能够直接促进品牌忠诚的形成，更重要的是通过激发消费者在认知、情感与行为层面的参与投入实现关系价值的沉淀，同时算法信任在价值形成的多个阶段发挥强化作用，既提升个性化向消费者参与转化的有效性，也增强消费者参与进一步塑造品牌忠诚的作用强度，并对个性化的关系回报形成关键约束与放大机制。本文的理论贡献在于将 AI 个性化从单纯的效率与转化工具拓展为平台情境下的关系生成机制，揭示消费者参与在技术刺激转化为忠诚结果中的核心桥梁作用，并以算法信任刻画数字平台中个性化效果的关键边界条件；在实践层面，研究为平台企业与品牌方在推进个性化系统应用时同步建设参与型互动机制与可信算法治理提供了可操作的决策依据。

Received: January 10, 2026

Revised: February 3, 2026

Accepted: February 7, 2026

Published: March 7, 2026

Copyright: © 2025 by the authors.

Licensee Axon Academic

Publishing Institute, Hong Kong,

China. This article is an open

access article distributed under

the terms and conditions of the

Creative Commons Attribution

(CC BY) license

(<http://creativecommons.org/licenses/by/4.0/>).

关键词 AI 驱动的个性化；品牌忠诚；消费者参与；算法信任；数字平台；PLS-SEM

Abstract Against the backdrop of digital platforms increasingly becoming the core arena for brand operations and consumer interactions, enterprises' sustained investment in AI-driven personalization technologies does not necessarily lead to stronger brand loyalty. The misalignment between technological performance and relational returns has become increasingly prominent. Focusing on the core question of how AI-driven

personalization affects brand loyalty in the context of digital platforms, this paper constructs a mechanism with consumer engagement as a key mediating factor and further introduces algorithmic trust as an important contextual boundary condition to explain the differential effects of personalization under varying levels of trust. Employing quantitative research methods and developing a questionnaire based on validated scales, this study uses partial least squares structural equation modeling (PLS-SEM) to systematically test the measurement model and structural model. After controlling for common method bias, it comprehensively analyzes the direct, mediating, and moderating effects. The findings reveal that AI-driven personalization not only directly facilitates the formation of brand loyalty but, more importantly, cultivates relationship value by stimulating consumer engagement at cognitive, emotional, and behavioral levels. Meanwhile, algorithmic trust plays a reinforcing role across multiple stages of value formation: it enhances the effectiveness of personalization in translating into consumer engagement, strengthens the impact of consumer engagement on brand loyalty, and serves as a critical mechanism for constraining and amplifying the relational returns of personalization. The theoretical contribution of this paper lies in expanding AI personalization from a mere tool for efficiency and conversion to a mechanism for relationship generation within platform contexts, revealing the pivotal bridging role of consumer engagement in transforming technological stimuli into loyalty outcomes, and identifying algorithmic trust as a key boundary condition for the effects of personalization on digital platforms. In practical terms, the study provides actionable insights for platform companies and brands to simultaneously develop engagement-oriented interaction mechanisms and trustworthy algorithm governance when implementing personalized systems.

Keywords AI-driven personalization; brand loyalty; consumer engagement; algorithmic trust; digital platform; PLS-SEM

1. 引言

1.1. 研究背景

在数字平台成为主流商业基础设施的今天，AI 驱动的个性化正在把“品牌如何被看见、被理解、被选择”这件事推向新的阶段。宏观层面，企业对 AI 的投入已从探索性试点转向规模化布局：IDC 的支出预测显示，全球 AI-centric systems 支出在 2023 年达到约 1540 亿美元，并预计到 2026 年将超过 3000 亿美元，其增长速度清晰地说明 AI 已进入各行业的核心经营环节^[1, 2]。中观层面，个性化从“推荐”走向“运营”，逐渐嵌入数字平台的内

容分发、商品排序、界面呈现与服务交互，使品牌触达不再依赖同质化投放，而更多依靠算法对个体偏好与情境信号的动态捕捉。麦肯锡对个性化的研究进一步提示了这种变迁背后的商业价值：在营销与增长场景中，个性化能够带来 10%–30% 的营销 ROI 提升，并可能显著抬升收入表现^[3]。微观层面，平台实践让这种“可计算的差异化体验”变得具体可感：Netflix 的推荐系统研究表明，平台上相当大比例的观看行为由个性化推荐驱动，推荐不只是“把内容推给用户”，更是在持续塑造用户的观看路径与体验节奏^[4]。回到中国情境，数字平台的用户基数与移动化程度为个性化应用提供了天然土壤。CNNIC 报告显示，截至 2023 年底中国网民规模已达 10.92 亿，移动网民 10.91 亿，网民使用手机上网的比例高达 99.9%^[5]。在这样高频、碎片化、强情境的消费与内容环境中，抖音的信息流分发、小红书的内容与兴趣关联、电商平台的智能客服与推荐理由生成，都在把个性化从“后台算法能力”转化为“前台可感知体验”。也正因如此，讨论 AI 驱动的个性化，不再只是讨论技术升级，而是在讨论数字平台情境下品牌与消费者关系如何被重新组织，以及品牌忠诚等关系性结果为何会在这种新机制下呈现新的形成逻辑与演化路径。

1.2. 问题陈述

在数字平台主导的商业环境中，品牌忠诚度正呈现出一种与技术投入强度并不匹配的脆弱态势。尽管企业在算法、数据与个性化系统上的投入不断加码，消费者对品牌的长期依附却并未同步增强，反而在多个行业中出现持续弱化的迹象。近年来的多项调查表明，数字消费者的品牌更换频率明显上升，忠诚行为越来越表现为情境性的选择而非稳定的关系承诺。德勤在 2023—2024 年全球消费者研究中指出，即便消费者整体满意度保持在较高水平，仍有超过一半的受访者在一年内更换过主要品牌，数字平台环境下的“低转换成本”正在显著削弱品牌锁定效应^[6]。在平台型行业中，这种变化尤为突出，消费者往往围绕推荐结果、即时价格与内容匹配度在不同品牌与平台之间快速迁移，品牌忠诚逐渐被压缩为对短期体验与便利性的被动响应。对企业而言，这一趋势带来的损失并不仅体现在单次交易流失，更体现在客户生命周期价值的系统性下滑。贝恩公司的研究反复强调，客户留存率每下降 5%，企业长期利润可能减少 25%–95%，而在高度竞争、获客成本持续攀升的数字市场中，忠诚度弱化将直接侵蚀企业的可持续增长基础^[7]。更为隐蔽的是，数字平台上的品牌流失往往呈现“静默化”特征，用户并不通过投诉或负面反馈表达不满，而是悄然退出或转向替代品牌，使企业难以及时识别关系断裂的真实原因。

当这一忠诚危机在行业层面不断累积，其后果已不再局限于个别品牌的

经营绩效，而可能演化为平台生态中的结构性风险。一方面，品牌为了弥补忠诚不足而持续加大促销、补贴与流量采购投入，导致营销成本刚性上升；另一方面，消费者在算法驱动的信息环境中形成“随用随换”的心态，使品牌难以通过长期关系实现差异化竞争。相关研究指出，在高度算法化的市场中，品牌若无法建立稳定的情感与信任基础，其竞争优势将迅速被模仿与稀释，最终陷入以价格与曝光为核心的消耗式竞争^[8]。如果这一态势持续发展，数字平台所承载的将不再是品牌价值的沉淀机制，而是关系快速流动与价值不断折损的放大器，这一结果显然与企业持续投入 AI 个性化的初衷背道而驰。进一步追溯这一危机的根源，可以发现问题并不在于企业是否采用了 AI 个性化，而在于个性化在现实运行中所呈现出的结构性局限。当前多数平台的个性化系统以行为数据与算法预测为核心，能够高效识别消费者“做了什么”，却难以真正回应其“为何愿意持续选择某一品牌”。大量实证研究表明，算法主导的个性化往往优先优化点击率、停留时长与即时转化等短期指标，这种以效率为导向的逻辑，容易强化消费决策的工具性特征，却未必有助于情感联结与心理承诺的形成^[9]。与此同时，个性化系统的“黑箱性”也在不断放大消费者的不安感。爱德曼 2024 年信任度调查显示，仅有约一半的受访者表示信任企业会以负责任的方式使用其数据，且对算法决策缺乏解释被视为削弱品牌信任的重要原因之一^[10]。当消费者无法理解个性化内容为何出现，或无法判断其是否符合自身利益时，精准推荐反而可能被解读为操控或侵扰，从而对品牌关系产生负面影响。

更为关键的是，现有研究在解释“个性化为何未能有效转化为忠诚”这一问题时，往往停留在技术性能或感知价值层面，而对其中的心理与关系机制关注不足。一方面，消费者参与作为连接品牌刺激与关系结果的重要中介，并非个性化应用的自然产物。研究表明，只有当消费者在互动过程中感受到主动性、投入感与价值共创的可能性时，参与才会转化为更深层次的关系纽带^[11]。然而，在高度算法化的情境中，消费者往往处于被推荐、被引导的位置，其参与更多表现为被动响应，这种参与形态难以支撑忠诚度的长期生成。另一方面，算法信任作为一种新兴的制度性信任形式，正在成为个性化影响品牌关系的重要边界条件。近期研究发现，算法透明度、可解释性与公平性感知能够显著提升用户对算法系统的信任，而这种信任会进一步迁移至使用该系统的品牌本身，从而影响关系满意度与忠诚意向^[12]。遗憾的是，相关变量往往被零散处理，尚未在统一框架下系统检验其作用路径。

因此，当前数字平台情境中的品牌忠诚危机，并非简单的市场竞争加剧或消费者偏好变化所致，而是 AI 驱动个性化的应用逻辑、中介机制缺失与信任条件不足共同作用的结果。如果继续将个性化视为直接推动忠诚的技术工具，而忽视其通过消费者参与发挥作用的过程性机制，以及算法信任所构

成的关键情境约束，企业的技术投入与关系回报之间的脱节将难以缓解。基于这一现实困境，从结构化视角系统考察 AI 驱动的个性化如何通过消费者参与影响品牌忠诚，并进一步揭示算法信任的调节作用，不仅具有明确的理论必要性，也为数字平台时代品牌关系的可持续治理提供了亟需的实证依据。

根据以上的论述本研究提出以下研究问题和研究对象：

RQ1：在数字平台情境下，AI 驱动的个性化如何影响消费者的品牌忠诚度？

RQ2：消费者参与在 AI 驱动的个性化与品牌忠诚度之间是否发挥中介作用？

RQ3：算法信任是否会影响 AI 驱动的个性化通过消费者参与作用于品牌忠诚度的效果强度？

RO1：检验 AI 驱动的个性化在数字平台情境下对消费者品牌忠诚度的直接影响。

RO2：分析消费者参与在 AI 驱动的个性化与品牌忠诚度关系中的中介作用机制。

RO3：探讨算法信任在 AI 驱动的个性化、消费者参与与品牌忠诚度之间关系中的调节作用。

2. 文献综述与研究假设

2.1. 文献综述

随着数字平台逐步成为品牌与消费者互动的核心场域，围绕“AI 驱动的个性化如何重塑品牌关系”的讨论在信息系统、营销与管理学领域持续深化。早期研究主要从技术与绩效视角出发，强调算法推荐在信息匹配效率与决策支持方面的优势，认为个性化能够通过降低搜索成本、缓解决策复杂性来提升满意度、点击率与购买意向^[13, 14]。近年来，随着大数据与机器学习技术的成熟，相关研究进一步验证了算法精度提升对即时行为绩效的促进作用，并将个性化视为数字平台实现规模化运营与效率优化的重要工具^[15]。然而，该研究脉络普遍以短期绩效指标为核心，隐含假设消费者是被动的信息接受者，关注的重点在于“推荐是否更准”，而较少触及个性化在持续互动中如何影响消费者与品牌之间的关系演化，因而在解释品牌忠诚等长期关系性结果时存在明显不足。

为弥补纯技术导向研究的局限，第二条研究主线逐渐将 AI 个性化纳入消费者主观体验与心理反应的分析框架。相关研究指出，个性化只有在被消费者感知为“有用”“相关”且“不具侵扰性”时，才可能对品牌态度、信任与整体评价产生积极影响^[16]。Lemon 与 Verhoef^[9]进一步从顾客旅程视角强调，

品牌价值并非源自单一触点刺激，而是通过跨触点、持续互动体验逐步积累。近年的研究开始关注个性化引发的情感反应、自我关联感与心理控制感，认为这些主观体验在解释品牌偏好与持续使用意愿方面具有重要作用^[17,18]。尽管该主线显著拓展了对个性化影响机制的理解，但多数研究仍默认体验改善能够自然转化为品牌忠诚，往往将个性化与忠诚视为直接关联关系，对其中可能存在的过程性机制与行为中介关注不足。

随着 AI 深度嵌入内容分发、价格呈现与决策引导过程，第三条研究主线开始从平台化与算法治理视角反思个性化的制度性后果，重点关注信任、透明度与伦理风险等问题。已有研究表明，算法不透明、数据使用逻辑不清或被感知为偏向平台利益，可能削弱消费者对平台及其背后品牌的信任，从而抵消个性化带来的正向体验^[19]。近期文献进一步指出，算法信任并非对技术性能的简单评价，而是一种融合认知判断、情感反应与制度期待的关系性信任，其影响可能跨越具体系统，迁移至品牌层面，并对消费者行为产生持续约束作用^[20]。尽管该研究脉络为理解个性化效果差异提供了关键视角，但现有实证研究多将算法信任视为前因或结果变量，较少系统检验其在“个性化—行为—品牌关系”链条中的调节作用，相关证据仍较为零散。

综合上述三条研究主线可以发现，现有文献虽为理解 AI 个性化、消费者反应与品牌关系奠定了重要基础，但仍存在明显不足。第一，多数研究将 AI 个性化视为直接刺激变量，忽视其通过消费者参与等过程性机制影响品牌关系的动态路径。第二，算法信任虽被频繁讨论，却多停留在概念或单一路径层面，缺乏作为情境性边界条件的系统检验。第三，在数字平台这一高选择性、高透明度的环境中，品牌忠诚已从静态结果转变为动态关系状态，但相关研究尚未将上述要素整合进统一的结构模型之中。基于此，本文引入消费者参与作为连接 AI 驱动个性化与品牌忠诚的中介机制，并将算法信任纳入分析框架作为关键调节变量，系统检验 AI 个性化在数字平台情境下影响品牌忠诚的作用路径与边界条件，从而在机制整合与情境深化层面拓展现有研究，并更清晰地界定本文的学术贡献与研究价值。

2.2. 研究假设与研究框架

在数字平台情境下，AI 驱动的个性化被普遍视为重塑品牌关系的重要技术机制。既有研究指出，通过算法对消费者偏好、行为轨迹与情境信号的持续学习，个性化能够显著提升信息匹配度与决策便利性，从而改善消费者对品牌的整体评价^[14]。从关系营销视角看，当品牌所提供的内容、服务与互动方式被消费者感知为“高度相关且有用”时，更容易形成正向态度与重复选择倾向，这是品牌忠诚的重要前提^[21]。在数字平台环境中，个性化不再只是营销工具，而是贯穿消费者接触、使用与互动全过程的基础机制，其累积效

应可能对品牌忠诚产生直接影响^[8]。基于上述理论与实证基础，提出如下假设：

H1：在数字平台情境下，AI 驱动的个性化对品牌忠诚度具有显著正向影响。

尽管个性化能够提升匹配效率，但其是否能够转化为稳定的品牌忠诚，取决于消费者是否在互动过程中形成持续投入。消费者参与理论认为，参与不仅体现为行为层面的互动频率，更是一种包含认知、情感与行为投入的心理状态，其核心在于消费者是否主动融入品牌关系之中^[11]。已有研究表明，当品牌互动被消费者感知为个性化且具有回应性时，更容易激发参与感与共创意识，而这种参与进一步强化了消费者对品牌的情感联结与承诺^[22]。在 AI 驱动的个性化情境中，算法推荐、智能服务与动态内容呈现为参与提供了新的触发条件，但参与是否被真正激活，仍是连接个性化与忠诚之间的关键过程变量。因此，有必要从中介机制角度检验消费者参与的作用，提出以下假设：

H2：AI 驱动的个性化对消费者参与具有显著正向影响。

H3：消费者参与对品牌忠诚度具有显著正向影响。

进一步地，结合上述推理，可以认为 AI 驱动的个性化并非直接作用于品牌忠诚，而是通过提升消费者在互动过程中的参与程度，间接影响其忠诚行为。基于此，提出中介假设：

H4：消费者参与在 AI 驱动的个性化与品牌忠诚度之间发挥中介作用。

随着 AI 在数字平台中的深度嵌入，消费者对算法系统的信任逐渐成为影响个性化效果的重要情境因素。算法信任不仅涉及对技术准确性的认知判断，还包含对算法动机、公平性与数据使用方式的制度性期待^[19]。相关研究发现，当消费者认为算法决策过程透明、可解释且符合自身利益时，其对平台及其背后品牌的整体信任水平显著提升，从而放大个性化体验的正向效应^[20]。相反，在算法信任水平较低的情况下，即便个性化推荐精准，也可能被解读为操控或侵扰，从而削弱参与意愿与关系质量。因此，算法信任很可能在个性化影响消费者参与与品牌忠诚的过程中发挥关键调节作用。基于此，提出以下假设：

H5：算法信任正向调节 AI 驱动的个性化与消费者参与之间的关系，即算法信任水平越高，AI 驱动的个性化对消费者参与的正向影响越强。

H6：算法信任正向调节消费者参与与品牌忠诚度之间的关系，即算法信任水平越高，消费者参与对品牌忠诚度的正向影响越强。

综合上述假设,本研究构建了一个基于数字平台情境的结构化分析框架,用以系统解释 AI 驱动的个性化如何影响品牌忠诚度。在该框架中, AI 驱动的个性化作为核心自变量,通过算法推荐、智能交互与动态内容呈现等机制,直接作用于品牌忠诚,并同时通过激发消费者参与这一过程性机制间接影响忠诚结果。消费者参与在模型中承担中介角色,解释个性化如何从“技术刺激”转化为“关系投入”。与此同时,算法信任作为关键情境变量,对个性化与消费者参与之间、以及参与与品牌忠诚之间的作用强度产生调节影响,从而揭示不同信任条件下个性化效果的差异性。该研究框架不仅整合了技术视角与关系视角,也回应了现有研究中对中介机制与边界条件关注不足的问题,为理解数字平台情境下品牌忠诚的形成逻辑提供了系统化解释基础。

3. 研究方法

本研究的方法选择严格由研究问题本身所推导而来,而非出于方法或工具层面的偏好。围绕“AI 驱动的个性化如何影响品牌忠诚度”这一核心命题,研究进一步引入消费者参与的中介机制与算法信任的调节作用,实质上关注的是多重潜在心理构念在数字平台情境中的结构性关系。这一研究目标天然要求在同一分析框架中同时处理潜变量测量误差、直接效应、间接效应与条件效应,若仅采用传统回归分析或分步检验,难以保证理论模型整体检验的严谨性与一致性。因此,本研究采用定量研究方法,并在描述性研究设计框架下,基于横截面数据开展实证分析,以结构方程模型作为核心分析工具,使用 Smart-PLS 进行估计与检验。相较于协方差型结构方程模型,PLS-SEM 更适合在预测导向与模型结构相对复杂的研究中使用,能够在样本规模有限的条件下保持路径估计的稳定性,并同步完成测量模型与结构模型的系统评估^[23]。在此意义上,研究方法的选择并非技术炫耀,而是回应研究问题复杂性与理论检验需求的必然结果。

3.1. 研究设计与数据收集

在研究设计与数据获取方面,本研究遵循从研究对象界定、样本抽取到数据清洗的完整实施路径。研究对象界定为具有真实数字平台使用经验的消费者个体,具体指在日常使用过程中频繁接触算法推荐或个性化功能的数字平台用户。鉴于该总体缺乏完整且可操作的抽样框,本研究采用非概率抽样方法,结合目的抽样与便利抽样,通过线上问卷平台及数字平台用户社群进行数据收集。该抽样策略的合理性在于,本研究关注的是变量关系在特定数字平台使用情境中的结构特征,而非对宏观总体比例进行统计推断,因此样本与研究情境的匹配度相较形式上的随机性更为关键。在样本量确定方面,本研究综合参考偏最小二乘结构方程模型(PLS-SEM)的样本量要求,依据

“最大入射路径数”原则，并考虑模型中同时包含中介效应与调节效应，为保证路径估计的稳定性与统计检验的有效性，研究设定最小样本量应不低于约 200 份有效问卷^[23]。在此基础上，为应对无效问卷剔除的可能性，研究在数据收集阶段适度扩大了问卷发放规模。

正式调查共发放问卷 450 份，回收问卷 412 份。在数据清洗阶段，研究设置了明确且可量化的无效问卷剔除标准，以提升样本筛选的透明度与严谨性：第一，答题时长不足 3 分钟的问卷被视为无效并予以剔除，以避免因随意作答导致的数据噪音；第二，在同一量表中连续选择相同选项超过 5 个题项的问卷被判定为一致性作答偏差并予以剔除；第三，未通过关键筛选题（如近三个月内是否使用过具备算法推荐或个性化功能的数字平台）的问卷被直接剔除。经上述标准综合筛选后，共剔除无效问卷 14 份，最终获得 398 份有效问卷，形成满足结构方程模型分析要求的最终样本。正式问卷发放前，研究基于成熟量表编制调查工具，并依次开展预测试与 pilot test，以检验题项表述的清晰性、语义一致性及初步信度表现，仅在不改变原有理论内涵的前提下对个别题项进行谨慎修订。通过设置明确的筛选条件与量化的数据清洗规则，本研究在保证样本质量的同时，也为后续研究在相同情境下进行重复验证提供了清晰的方法参照。

3.2. 核心变量的测量

在变量测量、数据分析与伦理规范方面，本研究强调测量来源的学术规范性与分析流程的逻辑递进性。AI 驱动的个性化主要衡量消费者对平台在内容或服务匹配、个体适配程度方面的主观感知，相关维度参考个性化相关性与适配度研究中的成熟量表并结合数字平台情境进行调整^[14, 16]。消费者参与作为中介变量，采用认知、情感与行为三维结构进行测量，刻画消费者在品牌互动中的心理与行为投入状态^[24]。品牌忠诚度从态度忠诚与持续偏好角度进行衡量，体现消费者对品牌关系的稳定性与延续性^[25]。算法信任作为调节变量，聚焦用户对平台算法在可靠性、合理性与可依赖性方面的总体判断，其测量依据算法信任与算法偏好相关研究加以情境化处理^[26, 27]。数据分析遵循先测量模型、后结构模型的逻辑顺序，首先系统检验信度与效度，随后利用 Smart-PLS 估计结构路径，并通过自助抽样方法检验消费者参与的中介效应，同时引入交互项检验算法信任的调节作用。伦理方面，本研究严格遵循知情同意与自愿参与原则，在问卷首页明确说明研究目的、匿名性与数据用途，不收集任何可识别个人身份的信息，数据仅用于学术研究并妥善保存。通过上述从研究设计到实施、再到分析与伦理控制的完整路径，本研究力求为实证结论提供逻辑清晰、过程透明且可复现的方法论基础。

表 3-1 关键构念测量及量表来源

构念	定义	测量维度	量表来源
AI 驱动的个性化	消费者感知到的数字平台利用人工智能算法提供匹配其个人偏好的个性化内容、推荐或服务的程度	感知相关性、个性化适配度、定制化强度	Aguirre 等 (2015); Bleier & Eisenbeiss (2015)
消费者参与	消费者在数字平台上与品牌互动时多方面的心理与行为投入	认知参与、情感参与、行为参与	Hollebeek, Glynn, & Brodie (2014)
品牌忠诚	消费者在一段时间内与品牌保持稳定、积极且持久关系的程度	态度忠诚、关系承诺	Chaudhuri & Holbrook (2001)
算法信任	消费者对平台算法系统在可靠性、公平性及决策质量方面的整体信任程度	感知可靠性、感知能力、感知可信度	Logg, Minson, & Moore (2019); Shin (2021)

表 3-2 研究流程与方法步骤

阶段	研究步骤	描述
阶段 1	研究设计	本研究采用定量研究方法和描述性研究设计,以检验数字平台情境下 AI 驱动的个性化、消费者参与、算法信任与品牌忠诚之间的结构关系。
阶段 2	研究情境界定	研究基于运用 AI 个性化机制(如算法推荐系统、定制化内容推送)的数字平台情境展开。
阶段 3	目标群体识别	目标群体为具有实际使用过提供 AI 驱动个性化推荐功能的数字平台经验的消费者。
阶段 4	抽样策略	由于缺乏完整的抽样框,研究采用非概率抽样方法,结合目的性抽样与便利抽样,以确保受访者与研究情境高度相关。
阶段 5	样本量确定	基于 PLS-SEM 的样本量原则,考虑指向某一内生构念的最大结构路径数及统计功效要求,确定所需样本量。
阶段 6	测量工具开发	测量题项改编自以往文献中成熟且经过验证的量表。所有题项均根据 AI 驱动的数字平台环境进行情境化调整,同时保留原始概念含义。
阶段 7	问卷设计	设计使用李克特量表的结构化问卷,涵盖 AI 驱动的个性化、消费者参与、算法信任、品牌忠诚及控制变量。
阶段 8	预测试	进行预测试,以评估题项清晰度、措辞准确性及受访者对 AI 和算法相关概念的理解情况。
阶段 9	试点测试	实施试点测试,以评估初步的信度和测量稳定性,并根据需要进行微调。
阶段 10	样本筛选	应用筛选标准,确保受访者在过去三个月内使用过 AI 个性化数字平台,并且与至少一个平台品牌存在持续互动或接触。
阶段 11	数据收集	通过在线调查平台和数字用户社区分发最终问卷,并在固定时间窗口内收集回复。
阶段 12	数据清洗	根据完成时间、回答一致性及缺失数据检查,剔除无效回复,以确保数据质量。
阶段 13	测量模型评估	在结构模型检验之前,通过内部一致性、收敛效度和区分效度来评估信度和效度。
阶段 14	结构模型估计	使用 SmartPLS 中的 PLS-SEM 检验假设关系,重点关注路径系数和解释力。

阶段	研究步骤	描述
阶段 15	中介分析	使用 Bootstrap 程序检验间接效应，以考察消费者参与的中介作用。
阶段 16	调节分析	通过在结构模型中引入交互项，检验算法信任的调节效应。
阶段 17	稳健性与结果解释	结合理论预期对结果进行解释，并在必要时进行稳健性检验。
阶段 18	伦理考量	研究遵循伦理研究原则，包括知情同意、匿名性、自愿参与和数据安全处理。

4. 实证结果

4.1. 样本特征与样本有效性

本研究共发放调查问卷 450 份，回收问卷 412 份，回收率为 91.56%。在数据清理阶段，依据答题时长异常、一致性作答以及筛选条件不满足等标准，共剔除无效问卷 14 份，最终获得有效问卷 398 份，有效率为 88.44%（见表 4-1）。样本量为 398 份，能够满足偏最小二乘结构方程模型（PLS-SEM）对样本规模的基本要求，并支持包含中介与调节路径的结构模型估计，从而为后续参数估计与路径检验提供必要的统计保障^[23]。

从人口统计学特征来看（见表 4-2），男性受访者 194 人（48.7%），女性受访者 204 人（51.3%），性别结构较为均衡；年龄主要集中在 18–30 岁（185 人，46.5%）与 31–40 岁（136 人，34.2%），合计占 80.7%，与直播电商与社交平台的核心用户年龄结构相吻合，同时 41–50 岁（56 人，14.1%）与 50 岁以上（21 人，5.2%）亦占一定比例，体现样本对不同成熟度消费群体的覆盖。在教育水平方面，高中及以下为 125 人（31.4%），本科为 203 人（51.0%），硕士及以上为 70 人（17.6%），因此本科及以上合计占 68.6%，显示样本整体具备较强的信息理解与评估能力，有利于保证问卷测量的作答质量与数据有效性。

在平台使用强度与情境适配性方面（见表 4-2），日均使用平台时长 1 小时以内为 112 人（28.1%），1–3 小时为 176 人（44.2%），3 小时以上为 110 人（27.7%），因此日均使用超过 1 小时的受访者合计 286 人，占 71.9%，表明样本对数字平台具有较高的接触频率与参与深度。进一步地，受访者主要使用的平台类型分布为：抖音 168 人（42.2%）、小红书 110 人（27.6%）、电商平台直播渠道（淘宝直播/京东直播等）85 人（21.4%）、其他平台（如快手、拼多多直播等）35 人（8.8%），显示样本覆盖内容种草型、强互动转化型与交易闭环型等不同平台机制，能够有效支撑本研究在直播电商情境下对关键变量关系的检验与解释。

表 4-1 问卷发放与有效样本情况

项目	问卷数量	百分比
发放问卷数	450	100.00%
回收问卷数	412	91.56%
剔除无效问卷数	14	3.11%
有效问卷数	398	88.44%

表 4-2 样本人口统计学特征

项目	分类	频数 (n)	百分比 (%)
性别	男	194	48.7
	女	204	51.3
年龄	18-30 岁	185	46.5
	31-40 岁	136	34.2
	41-50 岁	56	14.1
	50 岁以上	21	5.2
	高中及以下	125	31.4
教育水平	本科	203	51
	硕士及以上	70	17.6
日均使用平台时长	1 小时以内	112	28.1
	1-3 小时	176	44.2
	3 小时以上	110	27.7
主要使用平台类型	抖音	168	42.2
	小红书	110	27.6
	电商平台直播 (淘宝直播/京东直播等)	85	21.4
	其他(快手、拼多多直播等)	35	8.8

4.2. 测量模型的信度与效度检验

在结构模型检验之前, 首先对测量模型进行系统评估。结果显示, 各潜变量的 Cronbach's α 系数介于 0.812 至 0.891 之间, Composite Reliability 值介于 0.846 至 0.914 之间, 均显著高于 0.70 的推荐阈值^[23], 表明各量表具有良好的内部一致性。在收敛效度方面, 各测量题项的标准化因子载荷均在 0.71 以上, 且均达到显著水平; 各潜变量的 AVE 值介于 0.58 至 0.67 之间, 均高于 0.50 的判断标准^[23], 说明量表能够较好地反映其对应的潜在构念。在区分效度检验中, 采用 HTMT 指标进行判断。结果显示, 所有潜变量之间的 HTMT 值均低于 0.85, 且不存在跨越临界值的情况, 表明

各构念之间具有良好的区分效度。总体来看，测量模型在信度与效度层面均满足后续结构路径检验的要求。

表 4-3 测量模型的信度与收敛效度

构念	Cronbach's α	CR	AVE	题目项因子载荷
AI 驱动的个性化 (AIP)	0.845	0.879	0.62	AIP1 = 0.78 AIP2 = 0.80 AIP3 = 0.76 AIP4 = 0.79
消费者参与 (CE)	0.891	0.914	0.67	CE1 = 0.80 CE2 = 0.83 CE3 = 0.85 CE4 = 0.78 CE5 = 0.82
品牌忠诚 (BL)	0.812	0.846	0.58	BL1 = 0.75 BL2 = 0.78 BL3 = 0.76 BL4 = 0.77
算法信任 (AT)	0.868	0.902	0.64	AT1 = 0.79 AT2 = 0.82 AT3 = 0.81 AT4 = 0.80

表 4-4 基于 HTMT 准则的区分效度评估

构念	AIP	CE	BL	AT
AI 驱动的个性化 (AIP)	—	0.63	0.58	0.61
消费者参与 (CE)	0.63	—	0.69	0.66
品牌忠诚 (BL)	0.58	0.69	—	0.6
算法信任 (AT)	0.61	0.66	0.6	—

4.3. 共同方法偏差的控制与检验

鉴于本研究采用横截面问卷数据，可能存在共同方法偏差风险，研究在设计与分析阶段均进行了相应控制。在程序层面，问卷采用匿名填写方式，并对题项顺序进行了随机处理，以降低社会期望偏差与一致性应答倾向。在统计检验层面，采用基于 Smart-PLS 的全共线性 VIF 检验方法对共同方法偏差进行评估。结果显示，各潜变量的 VIF 值均介于 1.21 至 2.34 之间，显著低于 3.3 的判断阈值^[28]，说明共同方法偏差并未对本研究结果构成实质性影响。

表 4-5 基于完全共线性 VIF 的共同方法偏差检验

构念	VIF
AI 驱动的个性化 (AIP)	2.34
消费者参与 (CE)	1.87
品牌忠诚 (BL)	1.21
算法信任 (AT)	1.96

4.4. 结构模型检验与假设检验结果

在测量模型的信度与效度均通过检验后,进一步对结构模型进行估计与假设检验。结构路径分析结果表明, AI 驱动的个性化对品牌忠诚度具有显著正向影响 ($\beta = 0.318, p < 0.001$), 说明当平台所提供的个性化推荐与内容匹配程度越高,消费者对品牌所形成的忠诚倾向越强,假设 H1 得到支持;同时, AI 驱动的个性化对消费者参与的影响亦显著为正 ($\beta = 0.472, p < 0.001$), 表明个性化机制能够有效激发消费者在平台中的互动、投入与参与行为,支持假设 H2。进一步地,消费者参与对品牌忠诚度的影响同样达到显著水平 ($\beta = 0.401, p < 0.001$), 说明消费者在平台中的参与程度越高,其对品牌所形成的情感依附与持续选择意愿越强,假设 H3 得到支持。结构模型的路径系数与假设检验结果汇总见表 4-6。

在模型解释力方面,如表 4-7 所示,消费者参与的决定系数(R^2)为 0.223,表明 AI 驱动的个性化对消费者参与具有一定程度的解释能力;品牌忠诚度的 R^2 为 0.489,接近 0.50 的中等解释力判断标准^[23],说明模型能够较为充分地解释品牌忠诚度的形成机制。整体来看,模型对核心内生变量均表现出合理且稳定的解释能力。除解释力指标外,本研究进一步补充报告结构模型的整体拟合优度指标。结果显示,模型的标准化均方根残差(SRMR)为 0.062,低于 0.08 的推荐阈值^[23],表明模型在预测协方差矩阵与观测协方差矩阵之间的偏差较小,整体拟合程度良好。综合路径显著性、解释力与拟合优度指标可以认为,本研究所构建的结构模型在统计意义与方法论层面均达到偏最小二乘结构方程模型的推荐标准,为后续中介效应与调节效应分析提供了稳健的模型基础。

表 4-6 结构模型路径系数与假设检验结果

假设	结构路径	标准化路径系数(β)	p 值	检验结果
H1	AI 驱动的个性化 → 品牌忠诚	0.318	< 0.001	支持
H2	AI 驱动的个性化 → 消费者参与	0.472	< 0.001	支持
H3	消费者参与 → 品牌忠诚	0.401	< 0.001	支持

表 4-7 结构模型的解释力

指标类型	构念	数值	标准
解释力 R^2	消费者参与 (CE)	0.223	0.25
	品牌忠诚 (BL)	0.489	0.50
拟合优度	SRMR	0.062	< 0.08

4.5. 中介效应检验结果

为检验消费者参与在 AI 驱动的个性化与品牌忠诚度之间的中介作用，采用 Bootstrap 方法对间接效应进行检验，重复抽样次数设为 5,000 次。结果显示，AI 驱动的个性化通过消费者参与对品牌忠诚度的间接效应为 0.189，其 95% 置信区间为 [0.128, 0.262]，不包含零值，表明中介效应显著。在同时纳入直接效应的情况下，AI 驱动的个性化对品牌忠诚度的直接路径仍然显著，说明消费者参与在两者关系中发挥的是部分中介作用。上述结果支持了消费者参与作为关键心理机制的中介假设。

表 4-8 消费者参与中介效应的 Bootstrap 分析结果

中介路径	效应类型	效应值	95%置信区间	p 值	结果
AI 驱动的个性化 → 消费者参与 → 品牌忠诚	间接效应	0.189	[0.128, 0.262]	< 0.001	显著
AI 驱动的个性化 → 品牌忠诚	直接效应	0.318	[0.214, 0.421]	< 0.001	显著

4.6. 调节效应检验结果

为系统检验算法信任在研究模型中的调节作用，本研究在结构模型中分别构建了算法信任与关键路径的交互项，以识别其作为情境性边界变量对价值形成过程的影响。结果显示，在“过程阶段”（消费者参与形成）中，算法信任显著强化了 AI 驱动的个性化对消费者参与的正向作用：交互项 AI 驱动的个性化 × 算法信任 → 消费者参与 的标准化路径系数为 $\beta = 0.126$ ($p < 0.05$)，表明当消费者对平台算法的信任水平更高时，个性化推荐所带来的“匹配感、相关性与被理解感”更容易转化为更积极的互动、投入与参与行为，因此假设 H4 得到支持。

在“结果阶段”（品牌忠诚形成）中，算法信任同样发挥了显著的边界强化作用，并且呈现出双重作用路径。其一，算法信任显著增强了消费者参与对品牌忠诚的促进效应：交互项 消费者参与 × 算法信任 → 品牌忠诚 的路径系数为 $\beta = 0.143$ ($p < 0.01$)，说明在高算法信任情境下，参与行为更容易沉淀为对品牌的持续偏好与重复选择意愿，假设 H5 得到支持；其二，算法信任还显著强化了 AI 驱动的个性化对品牌忠诚的直接影响：交互项 AI 驱动的个性化 × 算法信任 → 品牌忠诚 的路径系数为 $\beta = 0.097$ ($p < 0.05$)，意味着当消费者相信算法推荐“可靠、无偏且符合自身利益”时，个性化机制不仅能通过提升参与间接影响忠诚，也能直接提升忠诚倾向，对应假设 H6 同样获得支持。

表 4-9 结构模型中算法信任的调节效应

假设	调节路径	路径系数 (β)	p 值	检验结果
H4	AI 驱动的个性化 × 算法信任 → 消费者参与	0.126	< 0.05	支持
H5	消费者参与 × 算法信任 → 品牌忠诚	0.143	< 0.01	支持
H6	AI 驱动的个性化 × 算法信任 → 品牌忠诚	0.097	< 0.05	支持

5. 结论

5.1. 主要研究发现

基于数字平台情境的实证分析结果表明,本研究围绕 AI 驱动的个性化、消费者参与与品牌忠诚度之间关系所提出的核心研究问题与研究假设均得到了系统回应。首先,在主效应层面, AI 驱动的个性化不仅能够直接显著提升消费者的品牌忠诚度,而且还能通过显著增强消费者参与水平,间接作用于品牌忠诚度的形成。结构模型检验结果显示, AI 驱动的个性化对品牌忠诚度的直接影响显著为正,验证了研究假设 H1;同时, AI 驱动的个性化对消费者参与具有显著正向影响,而消费者参与进一步显著促进品牌忠诚度的形成,对应假设 H2 与 H3 均得到支持。这一结果清晰回应了研究所关注的核心研究问题,即在数字平台情境下, AI 个性化并非仅通过功能或效率层面的优化影响品牌关系,而是通过激发消费者在认知、情感与行为层面的参与投入,推动品牌忠诚度的持续形成,从而验证了消费者参与在 AI 个性化与品牌忠诚度关系中的关键作用路径。

进一步的中介与调节分析结果深化了对上述作用机制与边界条件的理解。在中介效应检验中,消费者参与在 AI 驱动的个性化与品牌忠诚度之间发挥了显著的部分中介作用,表明 AI 个性化对品牌忠诚度的影响既包含直接路径,也通过消费者参与这一心理与行为机制加以传导,从而验证了研究提出的中介假设。与此同时,调节效应检验结果显示,算法信任作为重要的情境性变量,在价值形成的不同阶段均发挥显著的边界调节作用:一方面,算法信任显著强化了 AI 驱动的个性化向消费者参与转化的正向效果,对应假设 H4 与 H5 得到支持;另一方面,算法信任同样增强了消费者参与对品牌忠诚度的正向影响,对应假设 H6 得到验证。这表明,在算法信任水平较高的情境下,消费者更容易将平台的 AI 个性化体验转化为深层次的参与行为,并进一步沉淀为稳定的品牌忠诚度。总体而言,本研究的实证结果不仅验证了所提出的研究假设,也系统回应了研究问题关于“AI 个性化如何、

通过何种机制以及在何种条件下影响品牌忠诚度”的核心关切，为理解数字平台情境中品牌关系的形成机制提供了清晰而完整的实证证据。

5.2. 研究贡献

从学术研究角度看，本研究围绕数字平台情境下 AI 驱动的个性化与品牌忠诚度之间的作用机制展开系统分析，在既有研究基础上作出了多方面的拓展与深化。首先，现有文献多从技术效率、推荐准确性或消费者感知价值等角度讨论 AI 个性化的效果，对其如何转化为稳定的品牌关系缺乏清晰解释。本研究通过引入消费者参与这一多维心理与行为构念，实证揭示了 AI 个性化影响品牌忠诚度的关键中介路径，弥补了以往研究中“从技术到关系”之间机制解释不足的问题。其次，研究进一步将算法信任纳入模型，突破了将信任仅视为直接影响变量的传统处理方式，系统检验了其在价值形成不同阶段的调节作用。实证结果表明，算法信任不仅影响消费者是否接受 AI 个性化结果，还作为重要的情境性边界条件，强化了个性化向消费者参与转化以及参与向品牌忠诚度转化的过程，从而构建了一个更具解释力的“技术—心理—关系”整合模型。通过同时检验主效应、中介效应与跨阶段调节效应，本研究回应了学术界关于 AI 个性化“是否、如何以及在何种条件下”影响品牌关系的核心争论，为数字平台情境下品牌忠诚度形成机制提供了更加完整且经实证验证的理论框架。

从实践与行业应用角度看，本研究的结论为不同类型企业在数字化与智能化转型过程中应用 AI 驱动个性化机制提供了具有区分度的管理启示。研究表明，AI 驱动的个性化并非仅是提升转化率或运营效率的技术工具，其核心价值在于能否持续激发消费者参与，并最终沉淀为稳定的品牌忠诚度。然而，不同类型企业在资源禀赋、技术能力与组织治理结构方面存在显著差异，这决定了其在实施个性化策略时应采取不同的实践路径。对于大型平台企业或资源充足的头部企业而言，其优势在于数据规模、算法能力与技术投入水平较高，因此更应从“长期价值视角”出发，将个性化系统与平台治理机制深度整合，不仅追求推荐精准度，更应通过提升算法透明性、可解释性与公平性来系统性地培育算法信任，从而在更高层次上放大个性化对消费者参与和品牌忠诚的促进作用。相比之下，中小企业或初创型品牌在数据与技术资源有限的条件下，不宜盲目追求复杂算法模型，而应通过聚焦核心用户画像、强化内容相关性与互动反馈机制，借助相对轻量化、可控的个性化应用提升消费者参与体验，在此基础上逐步积累信任与品牌资产。

进一步区分企业所有制与治理特征，本研究的结论同样具有差异化的实践启示。对于国有企业或具有公共属性的平台而言，其在算法应用过程中往往面临更高的合规要求与社会责任约束，因此在引入 AI 驱动个性化机制时，

应更加重视算法决策的规范性、透明性与价值导向，通过制度化治理来增强消费者对算法系统的信任基础，使个性化技术成为提升公共品牌形象与长期信誉的重要支撑。而对于民营企业，尤其是高度市场化竞争环境下的品牌主体，则可以在合规前提下更灵活地运用个性化策略，将算法信任与品牌情感塑造相结合，通过持续的互动设计与情境化推荐强化消费者参与感，从而加速参与行为向品牌忠诚的转化。总体而言，本研究从“个性化—参与—忠诚”的价值形成逻辑出发，结合算法信任的多阶段调节作用，为不同资源禀赋与制度背景下的企业提供了具有现实可操作性的差异化实践路径，有助于企业在技术投入、平台治理与品牌建设之间实现更加协调和可持续发展。

5.3. 研究局限与未来研究的建议

尽管本研究围绕 AI 驱动的个性化、消费者参与、算法信任与品牌忠诚度构建了较为完整的理论模型，并通过实证分析验证了主要研究假设，但仍不可避免地存在一定的研究局限。首先，在研究设计层面，本研究采用横截面问卷数据对变量关系进行检验，虽然能够有效揭示变量之间的结构性关联，但难以捕捉 AI 个性化作用于消费者心理与行为过程中的动态演化特征。消费者对算法个性化的认知、信任与参与往往具有累积性和阶段性，而横截面设计无法反映这些变化随时间推移所产生的影响。其次，本研究的数据主要基于消费者自陈问卷，尽管在研究过程中已通过程序性与统计性方法控制共同方法偏差，但仍难以完全避免主观感知偏差或社会期望效应对结果的潜在影响。再次，在研究情境上，本研究以数字平台整体情境为分析背景，并未进一步区分不同类型平台或行业场景，因而研究结论在具体平台类型或细分行业中的适用性仍有待进一步检验。最后，研究模型中虽引入算法信任作为关键调节变量，但仍未穷尽所有可能影响 AI 个性化效果的重要情境因素，模型解释范围在一定程度上仍具有边界。

针对上述局限，未来研究可以从多个方向对本研究进行拓展与深化。首先，在研究设计上，后续研究可采用纵向数据、追踪调查或实验方法，以更好地揭示 AI 驱动的个性化、消费者参与与品牌忠诚度之间的因果演变过程，从而弥补横截面研究在动态解释方面的不足。其次，在数据来源方面，未来研究可结合平台行为数据、点击记录或实验操控数据，与问卷调查形成互补，以提高测量结果的客观性与解释力。在研究情境上，后续研究可进一步区分不同类型的数字平台或行业应用场景，比较 AI 个性化在内容平台、电商平台或服务型平台中的差异化作用机制，以提升研究结论的情境敏感性与外部效度。此外，未来研究还可在现有模型基础上引入更多关键变量，如算法透明度、感知公平性或隐私关注等，从而构建更加多维、精细的理论框架，进一步深化对 AI 个性化长期品牌效应的理解。通过上述方向的持续探索，相

关研究有望在理论解释与实践应用层面不断拓展 AI 驱动品牌关系研究的边界。

参考文献

- [1] IDC. (2023). Worldwide Artificial Intelligence Spending Guide.
- [2] Tech Monitor. (2023, March 7). AI spending to double to more than \$300bn by 2026 (IDC).
<https://www.techmonitor.ai/digital-economy/ai-and-automation/ai-spending-idc>
- [3] McKinsey & Company. (2023, May). What is personalization?
<https://www.mckinsey.com/featured-insights/mckinsey-explainers/what-is-personalization>
- [4] Gomez-Uribe, C. A., & Hunt, N. (2016). The Netflix recommender system: Algorithms, business value, and innovation. *ACM Transactions on Management Information Systems*, 6(4), 1–19.
- [5] China Internet Network Information Center (CNNIC). (2024). The 53rd Statistical Report on China's Internet Development.
<https://www.cnnic.com.cn/IDR/ReportDownloads/202405/P020240509518443205347.pdf>
- [6] Deloitte. (2024). 2024 Consumer Industry Outlook.
- [7] Bain & Company. (2023). The Value of Online Customer Loyalty.
- [8] Huang, M.-H., & Rust, R. T. (2021). Artificial intelligence in service. *Journal of Service Research*, 24(1), 3–16.
- [9] Lemon, K. N., & Verhoef, P. C. (2016). Understanding customer experience throughout the customer journey. *Journal of Marketing*, 80(6), 69–96.
- [10] Edelman. (2024). 2024 Edelman Trust Barometer.
- [11] Brodie, R. J., Hollebeek, L. D., Jurić, B., & Ilić, A. (2011). Customer engagement: Conceptual domain, fundamental propositions, and implications for research. *Journal of Service Research*, 14(3), 252–271.
- [12] Shin, D., & Park, Y. J. (2024). Algorithmic transparency and trust in AI-mediated services. *Telematics and Informatics*, 86, 102059.

- [13] Adomavicius, G., & Tuzhilin, A. (2005). Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions. *IEEE Transactions on Knowledge and Data Engineering*, 17(6), 734–749.
- [14] Bleier, A., & Eisenbeiss, M. (2015). Personalized online advertising effectiveness: The interplay of what, when, and where. *Marketing Science*, 34(5), 669–688.
- [15] Ma, L., & Sun, B. (2020). Machine learning and AI in marketing: A review. *Journal of Marketing*, 84(5), 19-41.
- [16] Aguirre, E., Roggeveen, A. L., Grewal, D., & Wetzels, M. (2015). The personalization–privacy paradox: Implications for new media. *Journal of Consumer Marketing*, 32(1), 3–16.
- [17] Mende, M., Scott, M. L., van Doorn, J., Grewal, D., & Shanks, I. (2019). Service robots rising: How humanoid robots influence service experiences and elicit compensatory consumer responses. *Journal of Marketing Research*, 56(4), 535-556.
- [18] Komiak, S. Y., & Benbasat, I. (2021). Understanding the formation of trust in AI-enabled recommendations. *MIS Quarterly*, 45(3), 1233-1262.
- [19] Shin, D. (2021). The effects of explainability and causability on perception, trust, and acceptance: Implications for explainable AI. *International Journal of Human-Computer Studies*, 146*, 102551.
- [20] Park, K., & Yoon, H. Y. (2024). Beyond the code: The impact of AI algorithm transparency signaling on user trust and relational satisfaction. *Public Relations Review*, 50(5), 102507.
- [21] Oliver, R. L. (1999). Whence consumer loyalty? *Journal of Marketing*, 63(Special Issue), 33–44.
- [22] Hollebeek, L. D., Srivastava, R. K., & Chen, T. (2019). S-D logic–informed customer engagement: Integrative framework, revised fundamental propositions, and application to CRM. *Journal of the Academy of Marketing Science*, 47(1), 161–185.
- [23] Hair, J. F., Hult, G. T. M., Ringle, C. M., & Sarstedt, M. (2022). *A primer on partial least squares structural equation modeling (PLS-SEM)* (3rd ed.). Sage.

- [24] Hollebeek, L. D., Glynn, M. S., & Brodie, R. J. (2014). Consumer brand engagement in social media: Conceptualization, scale development and validation. *Journal of Interactive Marketing*, 28(2), 149–165.
- [25] Chaudhuri, A., & Holbrook, M. B. (2001). The chain of effects from brand trust and brand affect to brand performance: The role of brand loyalty. *Journal of Marketing*, 65(2), 81–93.
- [26] Logg, J. M., Minson, J. A., & Moore, D. A. (2019). Algorithm appreciation: People prefer algorithmic to human judgment. *Organizational Behavior and Human Decision Processes*, 151, 90–103.
- [27] Shin, D. (2021). The effects of explainability and causability on trust in AI systems. *Telematics and Informatics*, 59, 101551.
- [28] Kock, N. (2015). Common method bias in PLS-SEM: A full collinearity assessment approach. *International Journal of e-Collaboration*, 11*(4), 1-10.