

北京高校学生AI大模型持续使用意愿影响因素研究

张 哲¹, 刘娅婷²

¹北京工商大学数学与统计学院, 北京

²北京工商大学商学院, 北京

收稿日期: 2026年7月13日; 录用日期: 2026年8月5日; 发布日期: 2026年8月14日

摘 要

本文以北京高校学生为研究对象, 旨在探究其AI大模型的使用现状及持续使用意愿的影响因素, 为提升学生AI素养和优化教育场景下AI应用提供实证支撑。研究基于技术接受模型(TAM)与期望确认模型(ECM), 将影响因素区分为内部因素与外部因素, 并采用描述性统计、信效度检验、相关性分析和多元线性回归对数据进行分析。结果显示, ChatGPT与豆包为最常用模型, 写作辅助与语言翻译为主要应用场景, 回答不精准和复杂问题处理不足为突出问题; 回归模型显著, 内部因素($\beta = 0.614$)与外部因素($\beta = 0.374$)均正向影响持续使用意愿, 且内部因素作用更强。研究表明, 北京高校学生AI使用已较普及但应用层次偏浅, 提升使用意愿需重点优化产品性能, 尤以准确性与响应质量为优先。研究可为深化高校AI应用及提升学生数字素养提供实证参考。

关键词

北京高校学生, AI大模型, 持续使用意愿, 技术接受模型(TAM), 期望确认模型(ECM), 回归分析

Research on the Influencing Factors of Continuance Usage Intention of AI Large Models among Beijing College Students

Zhe Zhang¹, Yating Liu²

¹School of Mathematics and Statistics, Beijing Technology and Business University, Beijing

²School of Business, Beijing Technology and Business University, Beijing

Received: July 13, 2026; accepted: August 5, 2026; published: August 14, 2026

Abstract

This study takes Beijing college students as the research subjects, aiming to investigate their current usage of AI large models and the factors influencing their continuance usage intention, so as to provide empirical support for enhancing students' AI literacy and optimizing AI applications in educational contexts. Grounded in the Technology Acceptance Model (TAM) and the Expectation-Confirmation Model (ECM), the study categorizes influencing factors into internal and external factors, and employs descriptive statistics, reliability and validity testing, correlation analysis, and multiple linear regression for data analysis. The results show that ChatGPT and Doubao are the most frequently used models, with writing assistance and language translation being the primary application scenarios, while inaccurate responses and inadequate handling of complex problems are prominent issues. The regression model is significant, with both internal factors ($\beta = 0.614$) and external factors ($\beta = 0.374$) positively affecting continuance usage intention, and internal factors exerting a stronger influence. The findings indicate that AI usage among Beijing college students is relatively widespread but remains shallow in terms of application depth; enhancing usage intention requires prioritizing product performance optimization, particularly in terms of accuracy and response quality. This study provides empirical references for deepening AI applications in higher education and improving students' digital literacy.

Keywords

Beijing College Students, AI Large Models, Continuance Usage Intention, Technology Acceptance Model (TAM), Expectation Confirmation Model (ECM), Regression Analysis

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

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



Open Access

1. 引言

1.1. 研究背景与意义

自 2022 年 ChatGPT 的横空出世引发全球热潮, 不胜枚举的生成式人工智能大模型接连问世, 并迅速普及, 在全球范围内引发了技术革命与社会热议。人工智能技术的杰出表现促使众多学者投身于人工智能技术教育应用的研究, 随着 AI 技术进步, 其对高等教育的影响日益凸显, 尤其深刻地影响着大学生的学习模式和素养结构[1]。

在此背景下, 高校作为人才培养与科技创新的前沿阵地, 大学生群体已成为 AI 大模型工具最主要的使用者之一, 探究高校学生使用 AI 大模型现状及大模型持续使用意愿的影响因素, 已成为亟待回应的时代命题。

北京高校学生 AI 大模型使用已进入高普及阶段, 但不同群体在使用深度、应用场景和素养水平上存在显著差异。围绕大学生使用 AI 大模型的使用意愿、AI 素养教育等, 现有研究已开展了若干探索, 如基于多元逻辑回归等探究大学生 AI 素养教育的类型、成因及效果[2]; 基于统计分析、相关分析中介模型检验等分析国内大学生国产生成式人工智能的持续使用意愿与使用行为[3]。然而, 现有研究多聚焦于全国性样本或单一高校个案, 但缺乏针对于北京这一高校资源高度聚集、科技氛围浓厚地区的专门研究。因此, 本研究聚焦于北京高校学生 AI 大模型的使用现状, 探究其持续使用意愿的影响因素, 为提升学生

AI 素养以及推动大模型在高校中的进一步发展和深度应用提供实证参考。

1.2. 研究内容与方法

研究内容与方法主要包括：第一步，问卷设计与预调查，预调查阶段发放问卷 57 份，回收有效问卷 55 份，检验所设计的问卷的合理性及有效性，由此针对问卷进行了后续的修改与完善。第二步，为使数据更加易于理解和解释，将被调查用户的性别比例、所在专业、最常使用的 AI 大模型等数据进行描述性统计分析。第三步，本研究采用 SPSS 进行信效度检验、相关性分析与多元线性回归分析。最终构建多元线性回归模型，确定内部因素与外部因素对用户持续使用意愿的影响程度及回归方程。

2. 相关理论

本研究以技术接受模型(TAM)和期望确认模型(ECM)作为理论基础。技术接受模型由 Davis 提出，认为感知有用性和感知易用性是影响用户接受信息技术的关键因素[4]。期望确认模型由 Bhattacharjee 在期望确认理论基础上发展而来，专门用于解释信息系统用户的持续使用意愿，指出用户的满意度与感知有用性共同决定了其持续使用意向[5]。其中，TAM 中的感知有用性与感知易用性主要涉及产品性能层面的评价，ECM 中的确认度直接反映了用户对 AI 大模型性能表现的预期确认程度，而满意度则在此基础上形成，即预期被确定就会满意，二者均与产品的使用体验紧密相关，共同指向与 AI 大模型自身质量直接相关的内部因素。同时，在 TAM 的后续拓展研究中(如 TAM2)，社会影响等外部变量以及个体差异因素，则对应本研究中的外部因素。基于此，本研究将影响因素划分为内部因素与外部因素两个维度，且将影响用户持续使用 AI 大模型意愿的因素预先归纳为与产品性能直接相关的内部因素(如准确性、便捷性)及与社会环境、个体特质相关的外部因素(如政策、同伴推荐)。

线性回归是一种用于建立因变量(目标变量)与一个或多个自变量(解释变量)之间线性关系的数学模型。它能够把隐藏在大规模原始数据群体中的重要信息提炼出来，把握住数据群体的主要特征，从而得到变量间相关关系的数学表达式：

$$Y = \beta_0 + \beta_1 * X_1 + \beta_2 * X_2 + \dots + \beta_n * X_n + \varepsilon \quad (1)$$

其中 Y 为因变量， $X_1, X_2, \dots, X_n$ 为自变量， β_0 为截距项， $\beta_1, \beta_2, \dots, \beta_n$ 为需估计的回归参数， ε 为随机误差项。线性回归模型的核心思想是通过寻找一条最佳拟合直线(一元线性回归)或超平面(多元线性回归)，使得观测数据点到该直线或超平面的距离平方和最小，从而实现对因变量的预测和对变量间关系的分析。

3. 数据来源与预处理

预调查阶段发放问卷 57 份，回收有效问卷 55 份，检验所设计的问卷的合理性及有效性，由此针对问卷进行了后续的修改与完善及样本量的确定。最终，基于发布为期 15 天(2025 年初)的问卷展开研究，为确保数据的准确性和有效性，对问卷进行筛选：

- 1) 将不符合地域条件、答题时间过长或过短的受访者问卷剔除，获得有效问卷 523 份。
- 2) 将其中三份在第一道问题“你是否使用过 AI 大模型”中填写“否”的问卷剔除，得到 520 份问卷。
- 3) 针对问卷中测量用户持续使用 AI 大模型意愿的影响因素量表，本研究采用正向计分法，将五个影响程度等级从“很大程度影响”到“很小程度影响”依次赋值为 5 到 1 分；针对用户持续使用 AI 大模型的整体意愿程度量表，将“很强意愿”到“很弱意愿”依次赋值为 5 到 1 分，以此完成变量赋值，满足后续因子分析和回归分析对数据形式的要求。

4. 数据可视化

1) 性别比例和年级比例

如图 1 所示,此次研究的调查对象主要为在校的大学生。在被调查者的性别比例中,女性占比 51.3%,男性占比 48.7%,基本持平。调查对象聚焦于本科生群体,占比高达 96.7%,在本科生细分结构中,大学一年级同学占比 23.5%,大二年级同学占比 34.4%,大三年级同学占比 26.2%,大四年级同学占比 12.7%,研究生同学占比 3.3%。




Figure 1. Grade distribution of surveyed users
图 1. 被调查用户的年级比例

2) 被调查者所处院校类别及专业分类

接受调查人群的所处院校类型来看,如图 2 所示,综合类院校占比最多,共 134 人,占比 25.8%;其次为理工类院校,共 89 人,占比 17.1%;其他被调查者所处院校占比由高到低依次为财经类(14.0%)、师范类(11.5%)、政法类(5.0%)、农林类(4.8%)、语言类(4.4%)、医药类(4.0%)、艺术类(3.7%)、军事类(2.7%)、民族类(1.5%),此外,还包括公安类院校和司法类院校。整体来看,被调查者所处院校类别分布相对广泛,结构较为合理,能综合反映不同教育背景学生的情况。




Figure 2. College of the surveyed users
图 2. 被调查用户所处院校

同时我们将被调查者的专业进行分类, 得出如图 3 所示的结果。133 人的专业所属类别为工学, 121 人为管理类专业, 64 人为教育类专业, 53 人为法类专业, 42 人为理类专业, 37 人为经济类专业, 21 人为艺术类专业, 20 人为医学类专业, 19 人为文学类专业, 9 人为农类专业, 1 人为历史类专业, 共计 520 人, 专业类别较为分散, 其中工学与管理类专业居多。




Figure 3. Professional categories of surveyed users
图 3. 被调查用户专业分类

3) 被调查用户使用 AI 大模型年限

在我们筛选保留的 520 份问卷中, 47.1%的用户在 2023 年以前已经开始使用 AI 大模型, 32.7%在 2023 年时开始使用, 20.2%在 2024 年开始接触, 他们可能是在 AI 技术更为成熟和普及后才接触并使用 (图 4)。




Figure 4. Start time of AI large models use by surveyed users
图 4. 被调查用户开始使用 AI 大模型时间

4) 被调查用户得知 AI 大模型的途径

被调查者得知 AI 大模型的途径有社交媒体、朋友介绍、广告宣传、学校课堂以及新闻咨询, 依次占比 67.3%、58.7%、34.6%、29.8%、28.8%。社交媒体以 67.3%的占比位居首位, 社交媒体传播速度快、信息量大, 是人们获取各类新鲜事物的重要渠道; 朋友介绍占比 58.7%, 朋友间的口碑传播可信度较高,

容易引发用户尝试; 广告宣传占比 34.6%, 通过广告推广, 能让更多人知晓 AI 大模型的功能和优势; 学校课堂中引入 AI 大模型相关知识, 有助于学生系统了解; 新闻媒体的专业报道可以让用户更全面地认识 AI 大模型。以上数据表明, AI 大模型在高校学生中的传播主要依赖社交口碑和自然流量(图 5)。




Figure 5. Channels of learning about AI large models by the surveyed users
图 5. 被调查用户得知 AI 大模型的途径

5) 被调查用户使用过的 AI 大模型

在问卷“您使用过以下哪些 AI 大模型(可多选)”的统计中, 使用过 ChatGPT 的人占比最大, 达到了 60.0%, 其在全球范围内知名度较高, 其次为抖音旗下豆包(52.9%)和百度旗下文小言(文心一言)(45.4%), Kimi 智能助手(25.4%)、讯飞星火(16.3%)、智谱清言(11.9%)居中, 天工 AI、通义千问、腾讯元宝均为 9.0% 左右。豆包的高使用率可能与其依托字节跳动的流量生态、在国内网络环境下具有更高的可及性和便捷性有关。文小言(文心一言)的使用率也相对较高, 这可能与其受益于百度在国内搜索引擎市场的庞大用户基础有关, 用户在使用百度搜索时, 文心一言常以 AI 回答、智能摘要等形式被自动调用或引导使用, 从而获得较高的曝光率。除此之外的自愿补充部分, 两名被调查者填写使用过风云作文宝, 一名填写 Google Gemini, 一名填写 Claude 3.5 Sonnet, 还有一名填写手机自带 AI 助手。因在调查期间, DeepSeek 横空出世, 有 19 位调查者填写 DeepSeek, 但由于 DeepSeek 上市时间较短, 许多用户对其了解不足等原因, 此篇调查将不对其作为重点进行分析(图 6)。




Figure 6. AI large models used by the surveyed users
图 6. 被调查用户使用过的 AI 大模型

6) 被调查用户最常用的 AI 大模型

在问卷“您最常用的 AI 大模型是(单选)”的统计中,用户最常用的 AI 大模型为 ChatGPT, 占比 30.2%, 说明其先发优势和相对成熟的性能使其成为用户的首选工具。其次为豆包、文小言(文心一言)、Kimi 智能助手、讯飞星火、天工 AI、腾讯元宝、智谱清言、通义千问。共有 4 名被调查者填写了“其他”内容, 一名提到华为小艺, 一名提到手机自带 AI 助手, 还有两名提到 DeepSeek (图 7)。




Figure 7. Most frequently used AI large models by the surveyed users
图 7. 被调查用户最常用的 AI 大模型

7) 被调查用户使用 AI 大模型的频率

我们由图 8 的分布表可以得到 17.1%的人每天会使用 AI 大模型; 36.7%的人保持每天一次的较高频率。37.3%的人处于较低频率, 每周进行 3~5 次; 仅有 8.9%的人频率极低, 每月 3~5 次。较高和较低频率者占比相对突出, 接近且居多。高频使用者(每天一次及以上)合计占比达 53.8%, 表明超过半数的北京高校学生已将 AI 大模型纳入日常学习和工作流程。与此同时, 仍有 37.3%的学生处于中低频使用区间(每周 3~5 次), 说明 AI 工具尚未成为所有学生日常生活与学习中的刚需。




Figure 8. Frequency of AI large models usage among the surveyed users
图 8. 被调查用户使用 AI 大模型的频率

8) 被调查用户使用 AI 大模型的场景

如图 9 所示, 该图呈现了被调查用户使用 AI 大模型的常见场景及占比。其中, 写作辅助的使用比例最高, 达 58.30%, 可见被调查的大学生对文字创作支持需求旺盛。这一现象反映出当前高校学生面临较大的课业写作压力, 包括课程论文、实习报告等多种写作任务, AI 大模型因其能够快速生成初稿、提供结构框架和润色语言, 成为学生应对学业写作需求的重要辅助工具。语言翻译占 38.70%, 位列第二, 这可能与北京高校学生日常学习中大量接触外文文献或者需要阅读英文资料等学术需求有关。数据分析、信息查询和代码编写的占比接近, 在 28% 上下。图像生成、题目讲解和娱乐的占比依次降低, 分别为 23.80%、19.60% 和 12.30%。以上数据表明, AI 大模型在北京高校学生中主要扮演“学业助手”的角色。补充信息部分, 有一名填写者填写会使用 AI 大模型进行运算帮助, 另一名填写者会使用 AI 大模型进行对某些事件的预测。




Figure 9. Scenarios of AI large models usage by the surveyed users

图 9. 被调查用户通常使用 AI 大模型的场景

9) 被调查用户在使用 AI 大模型中遇到的问题

通过被调查用户使用 AI 大模型时面临的问题及占比发现, 其中, “回答内容不精准”与“对复杂问题处理能力不足”问题较为突出, 占比分别为 54.6% 和 53.8%。这一发现与 Ji 等关于大语言模型生成内容存在“幻觉”现象的综述结论一致, 表明信息准确性问题仍是制约用户深度使用 AI 大模型的关键技术瓶颈[6]。这些现象反映出当前 AI 大模型在认知可靠性方面仍存在固有局限。对于学生用户而言, 此类偏差的代价尤为严重, AI 生成错误信息且未被及时识别, 可能直接导致信息误用甚至学术不端等问题。因此, AI 素养教育应将对 AI 生成内容的批判评估能力作为核心培养维度。“与专业领域结合度不够”占 35.8%, “输出结果缺乏创新性”占 33.5%。另外, “输出内容缺乏深度”和“模型响应速度慢”占比接近, 均在 28.5% 左右, 说明这些也是用户常遇的困扰。此外, 还有一名调查对象补充了 AI 大模型回答时“数据失准”的问题(图 10)。

5. 信效度检验

5.1. 信度检验

采用 SPSS 软件中的可靠性分析对正式调查数据进行信度检验, 以评估量表各维度及总量表的内部一致性, 结果如表 1 所示。




Figure 10. Problems encountered during AI large models usage by the surveyed users
图 10. 被调查用户在使用 AI 大模型过程中遇到的问题

Table 1. Cronbach's Alpha coefficients in the formal survey among the surveyed users
表 1. 正式调查各量表的 Cronbach's Alpha 系数表

	项目数	Cronbach's α 系数
外部因素	6	0.876
内部因素	8	0.924
影响因素总量表	14	0.914

由表 1 可知, 影响因素的各维度 Cronbach's Alpha 值均大于 0.7, 信度较高; 影响因素分量表和总量表的 Cronbach's Alpha 值均为 0.8 以上, 为高信度, 能可靠测量用户使用 AI 大模型的情况。

5.2. 效度检验

首先通过 KMO 检验和 Bartlett 球形度检验判断样本是否适合进行因子分析。其中, KMO 检验用于评估变量间的共同性程度, 取值越接近 1 越适合因子分析, 通常以 0.8 为最低可接受标准; Bartlett 球形度检验用于判断变量间的相关性是否足够强, 若检验结果显著($p < 0.05$), 则表明变量之间存在共同因素, 适合提取公因子。对正式调查的数据进行 KMO 检验和 Bartlett 球形度检验, 检验结果如表 2 所示。

Table 2. Validity analysis of the influencing factors scale
表 2. 影响因素量表效度分析

KMO 和 Bartlett 检验		
KMO 取样适切性量数		0.938
巴特利特球形度检验	近似卡方	4252.773
	自由度	91
	显著性	0.000

根据表 2 可知, KMO 值为 0.938, 大于 0.8, Bartlett 的球形度检验值 p 为 0.000, 小于 0.05, 说明该量表效度良好, 适合做用户持续使用 AI 大模型意愿影响因素的因子分析。

在确认数据适合做因子分析后, 根据原有变量的相关系数矩阵, 采用主成分分析法对因子进行提取。得到如下表 3 所示的结果。

Table 3. Total variance explained for the influencing factors scale
表 3. 影响因素量表总方差解释

成分	初始特征值		
	总计	方差百分比	累积%
1	6.719	47.993	47.993
2	2.296	16.403	64.396
3	0.706	5.044	69.440
4	0.553	3.951	73.390
5	0.481	3.433	76.823
6	0.464	3.317	80.140
7	0.445	3.178	83.318
8	0.419	2.994	86.311
9	0.391	2.794	89.105
10	0.342	2.444	91.550
11	0.327	2.333	93.883
12	0.313	2.235	96.118
13	0.281	2.006	98.123
14	0.263	1.877	100.000

提取方法：主成分分析法。

由表 3 可知, 特征值大于 1 的公因子共有 2 个, 其累计方差贡献率为 64.396%, 大于 60%, 表明提取的 2 个公因子能够较好地解释原有 14 个题项的大部分信息。其中, 第一个因子的特征值为 6.719, 方差贡献率为 47.993%, 是解释力最强的核心因子; 第二个因子的特征值为 2.296, 方差贡献率为 16.403%。

为进一步确认因子提取的合理个数, 本研究同时绘制了因子分析的碎石图, 以观察特征值随因子数量变化的折线趋势。碎石图通过将各因子的特征值按大小顺序绘制成折线图, 通常以折线出现明显拐点处作为因子提取的终止位置。结果如图 11 所示。

根据图 11 看出, 从第三个因子开始, 特征值均小于 1, 且碎石图中的折线从第三个因子后趋于平缓, 进一步支持了提取 2 个因子的合理性。

通过主成分分析法得到的旋转后的成分矩阵, 使每个题项在单一因子上的载荷量尽可能大、在其他因子上的载荷量尽可能小, 从而提高因子的可解释性, 如表 4 所示。

各题项在其所属因子上的载荷量均大于 0.7, 表明所有题项与其对应因子之间具有较强的关联性; 同时, 题项在两个因子上的交叉载荷量均较低, 未出现跨因子高载荷现象。因子 1 所包含的 8 个题项均涉及 AI 大模型自身的性能表现(如内容可靠性、回答全面度、回答准确度等), 故命名为“内部因素”; 因子 2 所包含的 6 个题项均涉及社会环境与个体特质(如法律法规、广告推送、同伴推荐等), 故命名为“外部因素”。这一分类结果与基于 TAM 与 ECM 的理论的设想一致, 进一步验证了该量表具有良好的结构效度。




Figure 11. Scree plot of PCA for the influencing factors scale

图 11. 影响因素主成分分析碎石图

Table 4. Rotated component matrix for the influencing factors scale

表 4. 影响因素量表旋转后的成分矩阵

	旋转后的成分矩阵 ^a	
	成分	
	1	2
12、内容来源的可靠性	0.836	
9、问题回答的全面性	0.824	
8、问题回答的准确度	0.815	
10、问题回答的独特性	0.800	
14、保护用户隐私方面	0.772	
7、操作界面的便捷程度	0.754	
13、使用的收费情况	0.751	
11、生成内容的速度	0.733	
6、法律法规及相关政策		0.812
5、手机广告及相关推送		0.797
2、我在多个方面有很强需求去使用 AI 大模型		0.744
3、我对于 AI 大模型的认知程度与应用能力		0.744
4、周围朋友推荐或课程要求使用		0.737
1、以下外部因素影响我使用 AI 大模型的程度—— 我对于新事物有很强的好奇心		0.720

提取方法：主成分分析法。^a 旋转在三次迭代后已收敛。

为了更直观地呈现各题项在两个公因子上的分布情况,本研究绘制了因子载荷散点图,如图 12 所示。两类题项在空间上呈现明显的分离趋势,表明旋转后的因子结构清晰,不同维度的题项之间区分度良好。




Figure 12. The diagram of factor loadings
图 12. 因子载荷图

6. 相关性分析

首先通过 Pearson 相关分析考察用户持续使用 AI 大模型意愿与其影响因素之间的相关性,以初步判断各变量之间的关联强度,为后续回归分析提供基础。相关性分析的结果如下面表 5 所示。

Table 5. Correlation analysis between users' continuance usage intention toward AI large models and internal factors
表 5. 用户持续使用 AI 大模型意愿程度与内部因素相关性分析

		持续使用 AI 大模型的意愿程度	内部因素	外部因素
持续使用 AI 大模型的意愿程度	皮尔逊相关性	1	0.896**	0.815**
	显著性(双尾)		0.000	0.000
	个案数	520	520	520
内部因素	皮尔逊相关性	0.896**	1	0.472**
	显著性(双尾)	0.000		0.000
	个案数	520	520	520
外部因素	皮尔逊相关性	0.815**	0.472**	1
	显著性(双尾)	0.000	0.000	
	个案数	520	520	520

**在 0.01 级别(双尾),相关性显著。

相关性检验表显示,用户持续使用 AI 大模型的意愿程度与内部因素和外部因素均存在显著相关性。内部因素和外部因素的皮尔逊相关系数均较高,分别为 0.896 和 0.815,显著性均为 0.000,表示用户持续使用 AI 大模型的意愿程度与内部因素和外部因素存在强正相关关系。

7. 模型诊断与回归分析

7.1. 模型诊断检验

在进行回归分析之前, 本研究在 SPSS 分析的基础上, 进一步利用 R 语言进行了多重共线性、自相关与异方差性的诊断检验。多重共线性方面, VIF 均为 1.287, 小于 10, 表明任意自变量之间不存在多重共线性; 自相关检验方面, 得到 Durbin-Watson 统计量为 1.95 (≈ 2), 且 $p > 0.05$, 残差序列无明显一阶自相关; 异方差检验方面, 计算自变量的 Spearman 等级相关系数以及 Goldfeld-Quandt 检验, 其 p 值均大于 0.05, 模型不存在异方差性。综合以上诊断指标, 本模型无自相关、异方差以及多重共线性, 可认为回归结果具有可靠性。

7.2. 回归分析

本研究进一步通过多元线性回归分析考察内部因素与外部因素对用户持续使用 AI 大模型意愿的影响程度。回归模型的拟合优度(R^2)用于评估自变量对因变量的联合解释力, 结果如表 6 所示。

Table 6. Model summary for users' continuance usage intention toward AI large models and internal factors

表 6. 用户持续使用 AI 大模型意愿程度与内部因素模型摘要表

模型摘要 ^b				
模型	R	R ²	调整后 R ²	标准估算的错误
1	0.918a	0.843	0.843	0.346

^a.预测变量: (常量), 外部因素, 内部因素; ^b因变量: 向上。

表 6 的线性回归分析结果表明, 模型的调整后 R^2 值为 0.843, 表示模型可以解释用户持续使用 AI 大模型的意愿总变异的 84.3%, 模型拟合优度较高。对此作审慎说明, 在社会科学领域的实证研究中, 本模型调整后 R 方值偏高。由于所有变量均来源于同一问卷, 变量间的相关性可能受到共同方法偏差的影响。为进一步检验, 本研究采用 Harman 单因素检验进行诊断, 结果显示, 未旋转的第一个因子解释了总变异量的 50.532%, 略高于 50% 的临界值。对此作三点说明: 第一, 通过主成分分析法提取因子, 已消除了原始自变量之间多重共线性对因变量的影响; 第二, 本研究的自变量选取基于 TAM 与 ECM 两个成熟理论框架, 聚焦于影响持续使用意愿的核心驱动因素, 即内部因素与外部因素, 因此所选自变量对因变量具有较高的解释力。第三, 本研究在问卷设计上采取了匿名填写、平衡题目顺序的程序控制方法。综合以上三点, 回归分析结果仍具有参考价值。

进一步通过方差分析检验回归模型的整体显著性, 即判断模型中的两个自变量整体上是否对因变量具有显著的解释作用, 结果如表 7 所示。

Table 7. ANOVA for users' continuance usage intention toward AI large models and internal factors

表 7. 用户持续使用 AI 大模型意愿程度与内部因素 ANOVA 表

ANOVA ^a						
模型		平方和	自由度	均方	F	显著性
1	回归	332.945	2	166.473	1389.740	<0.001 ^b
	残差	61.930	517	0.120		
	总计	394.875	519			

^a.因变量: 持续使用 AI 大模型的意愿程度; ^b.预测变量: (常量), 外部因素, 内部因素。

上表显示, F 统计量的相伴 $p < 0.000$, 表示两个自变量整体上对因变量有显著影响。
在保证回归模型整体显著的基础上, 进一步考察各个自变量对因变量的独立解释能力, 回归系数与显著性检验结果如表 8 所示。

Table 8. Coefficients table for users' continuance usage intention toward AI large models and internal factors
表 8. 用户持续使用 AI 大模型意愿程度与内部因素系数表

模型	未标准化系数		标准化系数	t	显著性	共线性统计	
	B	标准错误	Beta			容差	VIF
(常量)	0.473	0.066		7.128	<0.001		
1 内部因素	0.614	0.019	0.653	33.043	<0.001	0.777	1.287
外部因素	0.374	0.018	0.407	20.620	<0.001	0.777	1.287

该系数表给出每一个内部因素自变量对用户持续使用 AI 大模型意愿程度的影响情况, 得出自变量与因变量之间的回归方程为:

$$\text{持续使用AI大模型意愿程度} = 0.473 + 0.614 * \text{内部因素} + 0.374 * \text{外部因素}$$

由此可知, 内部因素和外部因素的回归系数均大于 0, 即可正向影响用户持续使用 AI 大模型意愿程度, 其分别提升 1, 会导致持续使用 AI 大模型意愿程度提升 0.614、0.374, t 值的相伴 $p < 0.05$, 各回归系数均具有统计显著性。

8. 结论

本研究聚焦于北京高校学生, 从方程可以看出, 即使不考虑内部与外部因素的影响, 用户仍保有一定程度的持续使用意愿。内部因素对持续使用 AI 大模型意愿程度的影响更大, 这说明用户在考虑是否持续使用 AI 大模型时, 更看重大模型自身的性能和服务质量等方面。AI 大模型界面操作便捷程度高、回答问题准确度高、全面快速且具独特性有依据、收费合理、保护好用户隐私, 这些因素均可显著增强用户的持续使用意愿程度。而外部因素虽然影响相对于内部因素较小, 但也不可忽视需要考虑在内。除产品自身的性能外, 用户个人的好奇心驱动、实际需求、认知能力, 以及外界的推荐、广告和法律法规政策等因素, 也会对用户的持续使用意愿产生作用。

综合来看, 想要提高用户持续使用 AI 大模型的意愿, 不仅需要更大程度上优化大模型的自身性能, 还需要合理利用外部因素的推动作用。在大模型的自身性能上, 结合用户最突出的关注点, 应重点提升回答内容的精准度; 增强对复杂问题的理解与推理能力; 同时, 针对不同学科领域提升专业结合度与结果的创新性。在外部因素的利用上, 可从以下几个层面着手: 第一, 在社交媒体层面, 可在微信公众号、短视频平台等学生高频接触的社交媒介上, 策划系统性的 AI 工具功能展示与案例分享内容; 第二, 在同伴影响层面, 可通过学生社团、学习小组等渠道鼓励学生分享使用经验和技巧, 充分发挥同伴推荐在学生群体中信任度高的优势; 第三, 在课堂教学层面, 教师可将 AI 大模型的使用嵌入课程作业、项目研究等环节, 帮助学生建立科学使用 AI 大模型的认知框架。学校还可通过举办 AI 教学讲座、优秀案例展示等活动, 使学生通过现场演示、问题答疑等, 能够直观了解 AI 大模型的使用技巧。同时, 学校可邀请各学科教师结合自身专业领域, 开展“AI + 学科”主题讲座, 帮助学生将 AI 工具与具体专业学习场景建立连接, 针对不同专业背景学生提供差异化引导。

这与施雨和茆意宏的研究一致, 他们系统地指出, 针对大学生群体的 AI 素养框架与素养教育是当前

的研究重点[7]。因此, 高校应重视将 AI 素养教育纳入人才培养体系, 帮助学生建立科学使用 AI 大模型的认知框架。

致 谢

对在本研究的选题与问卷设计过程中提出了诸多宝贵建议与指导的同学, 致以诚挚的谢意。同时, 感谢所有参与问卷填写与反馈的受访者对本研究的支持与配合。

感谢李裕梅老师和徐美萍老师指导本文写作。

参考文献

- [1] 童慧, 徐大云, 曹林杰. 大学生人工智能工具使用及素养研究[J]. 教育信息技术, 2026(3): 71-75.
- [2] 孔新宇. 大学生 AI 素养教育的类型比较、影响因素及效果审思[J]. 电化教育研究, 2026, 47(7): 61-69.
- [3] 王鹏, 张彤. 大学生国产生成式人工智能持续使用意愿的影响因素及路径研究[J]. 中国教育信息化, 2025, 31(9): 56-68.
- [4] Davis, F.D. (1989) Perceived Usefulness, Perceived Ease of Use, and User Acceptance of Information Technology. *MIS Quarterly*, **13**, 319-340. <https://doi.org/10.2307/249008>
- [5] Bhattacharjee, A. (2001) Understanding Information Systems Continuance: An Expectation-Confirmation Model. *MIS Quarterly*, **25**, 351-370. <https://doi.org/10.2307/3250921>
- [6] Ji, Z., Lee, N., Frieske, R., Yu, T., Su, D., Xu, Y., *et al.* (2023) Survey of Hallucination in Natural Language Generation. *ACM Computing Surveys*, **55**, 1-38. <https://doi.org/10.1145/3571730>
- [7] 施雨, 茆意宏. 人工智能素养的概念、框架与教育[J]. 图书馆论坛, 2024, 44(11): 90-100.