



生成式人工智能对大学生学业表现的影响

——基于广义随机森林模型的异质性处理效应

万美希, 蒋墨冰, 吕品, 肖芊源

(浙江理工大学经济管理学院, 杭州 310018)

摘要: 生成式人工智能(生成式 AI)在教育领域的应用日趋广泛,但在高等教育场景中的有效性仍存在较大争议。为厘清这一争议,采用四阶段混合型抽样方法对杭州市多所高校进行问卷调查,并借助广义随机森林模型,系统分析生成式 AI 使用对大学生学业表现的平均与个体异质性处理效应。研究发现,生成式 AI 在大学生中普及率较高,且显著提升了大学生的学业成绩和学习效率。进一步分析表明,生成式 AI 的使用时长对大学生学业表现具有显著正向影响,而使用频率的作用则不显著。个体处理效应分析显示,生成式 AI 对大学生学业表现的影响存在显著异质性:学习适应能力越强的学生,生成式 AI 对其学习成绩的提升概率越大;初始成绩越差的学生,生成式 AI 对其学业成绩的提升幅度越大;初始成绩越好的学生,生成式 AI 对其学习效率的提升概率越大;抗干扰能力越强的学生,生成式 AI 对学习效率的提升幅度越大。该研究结论不仅为科学认识生成式 AI 在高等教育中的价值提供了实证依据,更为提升高校大学生学习效果、推进“人工智能+高等教育”战略落地提供了实践参考。

关键词: 生成式人工智能;大学生;学业表现;广义随机森林模型;异质性处理效应

中图分类号: G640

文献标志码: A

文章编号: 1673-3851(2025)12-0766-13

The impact of generative artificial intelligence on college students' academic performance: Heterogeneous treatment effect based on generalized random forest model

WAN Meixi, JIANG Mobing, LÜ Pin, XIAO Qianyuan

(School of Economics and Management, Zhejiang Sci-Tech University, Hangzhou 310018, China)

Abstract: The application of generative artificial intelligence (generative AI) in education is becoming increasingly widespread, but its effectiveness in higher education remains highly contested within the academic community. This study conducts a questionnaire survey using a four-stage mixed sampling method across several universities in Hangzhou and employs a generalized random forest model to analyze the average and heterogeneous impact of generative AI on college students' academic performance. The results show that generative AI has a high adoption rate among college students and significantly improves their academic performance and learning efficiency. Further analysis reveals that the duration of AI usage positively affects academic performance, while usage frequency has no significant effect. The analysis of individual treatment effects indicates substantial heterogeneity: students with higher learning adaptability are more likely to experience improvements in academic performance; students with lower initial grades benefit more in terms of performance gains; those with better initial performance are more likely to see

收稿日期: 2025-08-07

基金项目: 浙江省教育科学规划课题(2025SCG317); 国家社会科学基金项目(25CJL015)

作者简介: 万美希(2004—), 女, 广东中山人, 本科生, 主要从事生成式人工智能应用方面的研究。

通信作者: 蒋墨冰, E-mail: mercyjmb@qq.com

improvements in learning efficiency; and those with stronger anti-interference abilities experience greater gains in learning efficiency. These findings not only provide empirical evidence for scientifically understanding the value of generative AI in higher education, but also offer practical reference for enhancing the learning effectiveness of college students and promoting the implementation of the "AI + higher education" strategy.

Key words: generative artificial intelligence; college students; academic performance; generalized random forest model; heterogeneous treatment effect

在全球数字化转型加速的背景下,2024年中国政府工作报告提出“人工智能+”行动,推进以人工智能为引擎的新质生产力发展。生成式人工智能(生成式AI)作为“人工智能+”的重要组成部分,已快速普及并渗透到各行各业,在高等教育领域逐渐成为学生学习与开展学术活动的常用工具之一,深刻影响着知识资源获取、个性化学习和学术研究等方面。

虽然生成式AI对经济社会发展的积极作用已得到广泛认可,但随着其应用不断深入,学术界对其潜在负面影响的讨论也逐渐增多。部分研究表明,使用生成式AI不仅会削弱学生的批判性思维和独立解决问题的能力,还引发了关于学术诚信和成果原创性的争议^[1-3]。出于对学生过度依赖生成式AI的担忧,许多高校对其使用实施了严格的限制^[4-5]。这些讨论与实践共同反映出生成式AI在高等教育领域具有典型的“双刃剑”效应。由于不同学生群体在禀赋条件和学习能力等方面存在差异,生成式AI的影响也存在异质性,因此必须合理审视生成式AI对高校学生学业表现的异质性影响。已有研究在一定程度上忽视了不同学生群体之间的差异,造成研究结论片面或缺乏科学性,难以为高等教育相关的政策制定提供科学指导。鉴于此,本文采用四阶段混合抽样方法针对杭州市9所高校、12个专业大类的在校大学生收集问卷数据,并运用广义随机森林模型评估生成式AI使用对大学生学业表现的平均与个体异质性处理效应。这一研究不仅有助于厘清现有的学术争议,也可为优化高校学习效果与推进“人工智能+高等教育”战略提供实证依据与决策参考。

一、文献回顾与研究假说

生成式AI的发展源于早期神经网络和机器学习,而深度学习的突破特别是生成对抗网络和变分自编码器推动了其快速发展。区别于传统AI仅具备识别和分类的功能,生成式AI通过学习海量数

据,能够生成文本、图像、音视频等内容,其核心技术包括自然语言生成、图像生成和自动翻译等,已被广泛应用于内容创作和虚拟助手等领域^[6]。随着Transformer架构的提出及基于其发展的GPT系列模型的问世,生成式AI在语言处理和内容生成方面取得了显著进展,例如,能够执行多轮对话、故事创作等复杂任务^[7]。在中国,伴随“人工智能+”战略的实施,生成式AI取得飞速进展,文心一言、讯飞星火、DeepSeek等已广泛应用于教育、医疗和金融等领域,并展现出巨大的发展潜力。

凭借自动化文本生成、智能化语言翻译、数据增强等功能,生成式AI正逐渐融入教育实践,成为高校师生最常用的辅助工具之一^[8]。生成式AI在中国高等教育领域的应用主要集中在智能化教辅系统与在线教育平台,这些平台通过AI技术实现自适应学习,有效提升了学生的学习体验^[9]。在美国和欧洲高校中,生成式AI不仅用于个性化学习,还被用于学术研究和课程开发^[10]。国内外研究均表明,生成式AI的应用具有广泛的多样性,主要集中在自动化写作、个性化学习、辅助教学、智能辅导等方面^[11-12]。例如,GPT-5和Claude等生成式AI模型已被用来为学生生成文本内容、提供实时答疑和反馈,有效支持学生的知识积累和写作实践。

然而,生成式AI对学生学业表现的影响存在显著争议。一方面,生成式AI对学生学业表现具有积极影响,主要体现在学生学习效率提升、自学能力增强和学术写作水平提高等方面。Sun等^[13]认为生成式AI能够为学生提供定制化的学习内容,从而提升学生学习效率。Ayeni等^[14]基于编程学习的研究发现,AI驱动的智能辅导系统可以帮助学生更快掌握新技能,且通过个性化反馈改善学习成果,最终显著增强了学生自学能力。此外,生成式AI在学术写作中表现突出,可以提供语法纠正和文本优化等建议,从而提高学生的学术写作水平^[15]。

另一方面,也有学者认为生成式AI会对大学生学业产生负面影响,尤其不利于学生独立思考能力、

学术诚信意识和批判性思维的培养。生成式 AI 的应用强化了学生对智能技术的依赖,不仅导致学生独立思考能力下降^[16],还阻碍批判性思维的发展。在学术写作中,部分学生违规使用生成式 AI 生成内容,进一步加剧了学术道德问题^[17]。因此,应鼓励高校在确保学术诚信的前提下探索生成式 AI 在教学中的创新应用^[18]。此外,生成式 AI 生成的内容还存在内容造假和信息不准确性等问题,部分学生缺乏对生成式 AI 输出结果的辨别能力,容易导致错误信息的传播和误用^[19]。基于以上分析,本文提出两个竞争性假设:

假设 1a:生成式 AI 能提升大学生学业表现。

假设 1b:生成式 AI 会降低大学生学业表现。

生成式 AI 对学生的影响存在个体差异,这种差异主要受到学生个人特征、学习习惯、专业特点和学习阶段等因素的影响。Markauskaite 等^[20]强调人工智能使用者需要具备一定的信息识别和评估能力,不同学生之间存在的差异会导致生成式 AI 对其产生的影响呈现异质性。不同专业的学生对生成式 AI 的需求和应用方式也存在较大差异,如理工科学生会更倾向于借助生成式 AI 开展数据分析^[21],人文社科类的学生则更依赖其文本写作功能。此外,处在不同学习阶段的学生,从生成式 AI 应用中获得的收益也存在差别^[3]。基于以上分析,本文提出如下研究假设:

假设 2:生成式 AI 对大学生学业表现的影响具有显著个体异质性。

二、研究方法 with 数据

(一)广义随机森林模型

本文参考 Athey 等^[22]的研究,采用广义随机森林(Generalized random forest, GRF)模型探究生成式 AI 使用对大学生学业表现的个体异质性处理效应。该方法具备两个显著优势:一方面,GRF 基于自适应局部加权机制,在无需依赖严格分布假设的前提下,能够在高维特征空间中为每一位学生构建个性化预测模型;另一方面,GRF 可用于估计条件平均处理效应(Conditional average treatment effect, CATE),从而识别生成式 AI 对不同学生群体的具体影响机制。

GRF 的核心在于对局部目标量的加权估计,其权重大小反映了个体特征之间的相似程度。具体而言,GRF 通过随机森林中的子模型构建局部权重,假设第 i 样本在第 b 棵树中与预测点 x 落入同一叶

节点的频率为 $\alpha_{bi}(x)$,则个体 i 的总加权值为 $\alpha_i(x)$:

$$\alpha_i(x) = \frac{1}{B} \sum_{b=1}^B \alpha_{bi}(x) \quad (1)$$

其中: B 表示森林中树的总数。上述权重衡量了个体 i 在特征空间中与待估点 x 的相似程度,通过在森林结构中汇总局部相似性信息,GRF 能够更精准地捕捉个体间的异质性。基于上述权重构造,GRF 进一步估计给定特征条件下的异质性处理效应,即:

$$\tau(x) = E(Y(1) - Y(0) | X = x) \quad (2)$$

其中: $Y(1)$ 和 $Y(0)$ 表示学生在使用与未使用生成式 AI 情境下的学业表现, X 为学生个体特征,包括性别、成绩基础、专业类型、学习习惯等。相较传统方法对整体平均效应的估计,GRF 可以更精细地揭示个体层面的差异,识别哪些学生更有可能受益于生成式 AI 的使用。

确定权重计算后,GRF 模型通过加权估计方程来估计生成式 AI 的使用对学生群体的影响。加权估计方程的核心是对每个样本赋予不同的权重,而在局部进行估计,这一过程使模型能够更精确地捕捉学生个体之间的异质性。加权估计的方程形式如下:

$$\hat{\theta}(x) = \operatorname{argmin}_{\theta} \sum_{i=1}^n (\alpha_i(x) \psi_{\theta}(O_i)) \quad (3)$$

其中: $\hat{\theta}(x)$ 为目标参数,即在特定学生特征条件下生成式 AI 使用与否对学生学业表现产生的因果影响; $\alpha_i(x)$ 代表样本 i 在与学生 x 的特征相似度上的加权值,帮助模型根据学生的特定特征进行个性化的处理效应估计; $\psi_{\theta}(O_i)$ 则是样本 i 的得分函数,表示生成式 AI 使用该学生学业成绩或学习效率的影响。通过这种加权方式,GRF 模型能够根据学生的特征个性化估计生成式 AI 的影响。这样的估计不仅更为精准,还能有效揭示生成式 AI 使用在不同学生群体中的异质性影响。

GRF 模型通过分割准则来构建每棵树。分割准则用于决定如何在特征空间中选择最优的分割点,以最大化不同学生群体之间的异质性。这对于捕捉学生在使用生成式 AI 时所表现出的差异至关重要。分割准则的目标是找到能够最大化节点间差异的特征,其公式如下:

$$\Delta(C_1, C_2) = \frac{n_{C_1} n_{C_2}}{n_p^2} (\hat{\theta}_{C_1}(J) - \hat{\theta}_{C_2}(J))^2 \quad (4)$$

其中: C_1 和 C_2 分别代表父节点 p 的两个子节点, n_{C_1} 和 n_{C_2} 分别对应两个子节点中的样本数, n_p 是

父节点中的样本总数; $\hat{\theta}_{C_1}(J)$ 和 $\hat{\theta}_{C_2}(J)$ 分别是两个子节点中估计得到的目标参数。

分割准则通过最大化不同子节点之间目标参数 $\theta(x)$ 的差异,确保每一次树结构划分都能够充分反映学生群体间的异质性特征。该机制使 GRF 模型在训练过程中能够动态识别出最具解释力的特征变量,如性别、年级和学习背景等,进而更准确地捕捉生成式 AI 使用对学生学业表现和学习效率的差异化影响。通过引入以因果效应差异为导向的分裂标准,模型不仅提升了在高维数据环境下的处理能力,还具备自动甄别影响生成式 AI 使用效果的关键特征变量的能力。这一优势使得 GRF 不仅能够估计整体处理效应,还能揭示不同学生群体在生成式 AI 使用中呈现的异质性响应模式,从而为制定有针对性的个性化教育干预策略提供充分的实证依据。

此外,本文还使用核密度估计方法对数据分布与处理变量效应进行可视化呈现。该方法能够直观地显示处理变量(生成式 AI 的使用)对各个结果变量(学业成绩变化、学习效率变化)的影响。核密度估计的公式表达为:

$$\hat{f}(x) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{x-x_i}{h}\right) \quad (5)$$

其中:核密度估计 $\hat{f}(x)$ 表示在点 x 处的概率密度函数估计值, n 为样本容量, h 为带宽参数,用以控制核函数的平滑程度, $K(\cdot)$ 是核函数, x_i 为第 i 个样本点。与传统直方图相比,核密度估计具有更高的光滑性和连续性,能够更准确地刻画变量的分布形态,从而揭示不同群体在特征变量上的潜在差异。

在实证分析的最后部分,本文进一步利用 GRF 模型评估生成式 AI 使用对大学生学业成绩的异质

性处理效应。通过引入与学生个体特征的交互项,模型能够动态捕捉生成式 AI 与学生特征之间的非线性关系,进而揭示其在不同群体间的异质性影响模式。GRF 模型的灵活结构使其能够系统识别对生成式 AI 使用效果存在显著响应差异的学生群体,从而辨析哪些群体在生成式 AI 辅助下表现出更为显著的成绩提升,哪些群体的边际收益则相对有限。上述识别结果为推动高校制定更具针对性的个性化教育干预策略、优化 AI 教育资源配置提供了重要的实证支持。

(二) 研究对象

本文以杭州市的高校大学生为研究对象,研究数据基于笔者设计的《2024 年杭州市高校大学生生成式人工智能使用情况与学业表现调查问卷》。按照目的性抽样与分层抽样原则,在杭州市西湖区、钱塘区和临安区分别选取浙江大学、杭州电子科技大学、浙江工业大学、浙江理工大学、杭州师范大学、浙江工商大学、中国计量大学、浙江农林大学和浙江财经大学 9 所高校的在读大学生进行调查。调查对象涵盖 12 个专业大类,覆盖文学、历史学、哲学、法学、理学、工学、农学、医学、经济学、管理学、教育学和艺术学等多个领域。

(三) 问卷设置

为了使问卷能够收集到效果理想的数据,本文遵循功能性原则、可靠性原则、效率原则和可维护性原则编制调查问卷,其内容构成如表 1 所示。问卷分为以下四个部分:第一部分为个人基本信息,包括性别、年龄、专业、学习背景等,共 11 题;第二部分旨在了解大学生使用生成式 AI 的情况,共 14 题;第三部分用于了解生成式 AI 对学业的影响,共 13 题;第四部分针对未使用 AI 大学生进行调查,共 5 题。

表 1 问卷调查的基本构成

问卷板块	内容
个人基本信息	性别、年级、GPA、绩点排名、是否挂科、每周自主学习时间、学习时社交媒体的影响、电子资源依赖度等(共 11 题)
生成式 AI 的使用情况	了解 AI 的渠道、使用过的 AI 工具、使用 AI 的频率(矩阵量表题)、每次使用 AI 的时长、是否优化 AI 输入指令、是否为 AI 付费、对 AI 提供的信息的处理方式、对 AI 的依赖程度等(共 14 题)
生成式 AI 对学业的影响	使用 AI 前后的 GPA 变化、学业成绩提升/下降的原因、学习效率提高/下降的幅度、学习效率提升/下降的原因、AI 对学习方式的影响、AI 对学习自主思考能力的影响、AI 对创新能力的影响等(共 13 题)
未使用 AI 的大学生情况调查	未使用 AI 的主要原因、主要采用的学习方式、AI 普及前后的 GPA 变化、对 AI 相关观点的认同程度(矩阵量表题)(共 5 题)

(四) 数据收集

本文通过实地走访方式进行问卷发放和收集,共发放问卷 420 份。通过检查并纠正录入错误,以

及数据清洗和校验,最终收回有效问卷 407 份,有效率为 96.90%。对问卷的初步统计结果显示,参与调研的学生中,男生占比 47.67%,女生占比

52.33%。在学习成绩方面,68.06%的学生没有经历过课程成绩不合格,31.94%的学生曾经或目前存在成绩不合格的课程。

三、变量定义与描述性统计

(一)变量定义

1. 解释变量

本文的解释变量为学生是否使用生成式 AI(*if_use*)、使用频率(*frequency*)和使用时长(*duration*)。若学生使用了生成式 AI,将 *if_use* 赋值为 1;反之,赋值为 0。对于使用频率和使用时长两个变量,则采用 Likert 量表评分赋值,具体评分分为五个等级,其中最高等级 5 表示使用频率最高或使用时间最长,等级数值递减表示使用频率或使用时长逐渐减少,等级 0 表示学生从未使用过生成式 AI。

2. 被解释变量

本文的被解释变量是学业成绩是否提高(*Grade_change*)和学习效率是否提升(*Efficiency_change*),二者均为二元变量,将学业成绩或学习效率提高赋值为 1,否则赋值为 0。此外,本文还分析了学业成绩提高幅度(*GR_rate*)和学习效率提升幅度(*ER_rate*),均采用 Likert 量表赋值,分数从 1 到 5 表示提升幅度越来越高。

3. 控制变量

本文选取的控制变量包括个人特征和生成式 AI 使用情况。个人特征方面,包括学生性别(*gender*)、年级(*grade*)、初始学业成绩(*GPA*)、课程通过情况(*if_fail*)、学习投入(*sl_time*)、学习专注力(*effect*)、对新学习环境的适应程度(*adaptability*)、是否具有批判性思维(*Q_analysis*)、电子资源的使用情况(*eResource_using*)、学习计划的制定(*sp_making*)和执行情况(*sp_persist*)。生成式 AI 使用情况方面,包括学生对生成式 AI 的训练情况(*if_prompt*)、付费情况(*if_pay*)、相关课程学习情况(*aiCourse_learning*)、技能掌握程度(*mastery_level*),以及对生成式 AI 提供信息的处理能力(*info_processing*)和依赖程度(*dependency*)^①。

(二)描述性统计

核心变量的描述性统计如表 2 所示。总体来看,生成式 AI 在大学生中的使用普及度较高,82.8%的受访者表示曾使用该类工具,且平均使用频率和使用时长分别为 2.49 和 2.27,显示出较

强的个体差异。结果变量方面,69.0%的学生认为使用生成式 AI 后学业成绩得到提升,70.3%的学生表示学习效率有所提高,反映出较强的主观积极效应。从提升幅度看,无论是成绩(*GR_rate*)还是效率(*ER_rate*)均值均处于五点量表的中间水平,且标准差较大,表明群体内部差异显著。在控制变量中,样本性别分布较为均衡,年级覆盖范围较广,*GPA* 均值为 2.79,显示出较为多元的学业基础。学习行为变量如自主学习时间、抗干扰能力与学习适应性均处于中等偏上水平,而 AI 相关技能掌握程度、课程学习情况指标偏低,表明学生在使用生成式 AI 的技术成熟度方面仍有提升空间。

表 2 描述性统计

变量名	样本量	均值	标准差	最小值	最大值
<i>if_use</i>	407	0.8280	0.3778	0	1
<i>frequency</i>	337	2.4889	1.5149	0	5
<i>duration</i>	337	2.2678	1.8220	0	5
<i>Grade_change</i>	407	0.6904	0.4629	0	1
<i>GR_rate</i>	281	1.1916	1.1984	0	5
<i>Efficiency_change</i>	407	0.7027	0.4576	0	1
<i>ER_rate</i>	286	1.3587	1.3276	0	5
<i>gender</i>	407	0.4767	0.5001	0	1
<i>grade</i>	407	2.7985	1.3331	1	5
<i>GPA</i>	407	2.7936	0.8344	1	4
<i>if_fail</i>	407	0.3194	0.4668	0	1
<i>sl_time</i>	407	2.8182	1.2403	1	5
<i>effect</i>	407	3.1204	1.0908	1	5
<i>adaptability</i>	407	3.1450	1.0201	1	5
<i>Q_analysis</i>	407	0.2973	0.4576	0	1
<i>eResource_using</i>	407	3.4152	1.0584	1	5
<i>sp_making</i>	407	2.3538	0.8865	1	4
<i>sp_persist</i>	407	2.4201	0.8410	1	4
<i>if_prompt</i>	337	1.8870	1.1348	0	3
<i>if_pay</i>	337	0.4889	0.5005	0	1
<i>aiCourse_learning</i>	337	1.6658	1.3396	0	4
<i>mastery_level</i>	337	1.6462	1.1984	0	4
<i>info_processing</i>	337	1.8403	1.1280	0	4
<i>dependency</i>	337	2.1622	1.3329	0	5

四、基于广义随机森林模型的平均处理效应分析

(一)是否使用生成式 AI 与学业表现

表 3 报告了是否使用生成式 AI 对大学生学业成绩与学习效率的平均处理效应。回归结果显示,

① 各变量的具体定义、单位及赋值标准见附表 1。

核心解释变量 if_use 在四个模型中系数均为正,且在 1% 显著性水平下显著,表明使用生成式 AI 显著提升了学生的学习表现。具体而言,列(1)与列(2)结果显示,生成式 AI 的使用显著增加了学生主观感知的学业成绩提升概率($Grade_change$),并显著提高了其主观感知的成绩提升程度(GR_rate)。类

似地,列(3)与列(4)报告了在学习效率层面上的正向效应,使用 AI 的学生不仅更可能认为效率得到提升($Efficiency_change$),其主观感知的效率提升幅度(ER_rate)也更高。这一系列结果在控制学生基本特征、学校固定效应与专业固定效应后,依然保持稳健。

表3 是否使用生成式 AI 与学业表现

变量	(1) $Grade_change$	(2) GR_rate	(3) $Efficiency_change$	(4) ER_rate
if_use	1.3830*** (0.2728)	2.3710*** (0.7536)	1.2615*** (0.1847)	3.2933*** (1.0032)
控制变量	是	是	是	是
学校固定效应	是	是	是	是
专业固定效应	是	是	是	是
样本量	407	281	407	286

注: *、**、*** 分别表示在 10%、5% 和 1% 水平显著,括号内为稳健标准误。下同。

上述结果符合认知负荷理论^[23]。一方面,生成式 AI 能够承担资料检索、语言生成等低阶任务,释放学生有限的认知资源,使其将注意力集中在知识整合与批判性思维等高阶学习活动,从而提升学习产出。另一方面,生成式 AI 的即时反馈机制帮助学生更快发现知识盲点并调整学习策略,提高了学习的互动性和针对性。这一结果与 Sun 等^[13]的元分析研究结论一致,即生成式 AI 在整体上可显著改善学生的成绩与效率,同时也为 Wang 等^[12]关于 ChatGPT 类工具提升高阶思维能力的结论提供了补充。

(二)生成式 AI 使用时长与学业表现

表 4 分析了生成式 AI 使用时长($duration$)对大学生学业成绩与学习效率的影响。从列(1)和列

(2)可见, $duration$ 对学生是否提升成绩($Grade_change$)和提升程度(GR_rate)均存在显著正向影响。在控制个体特征、学校和专业固定效应后,使用时长每增加 1 个单位,对成绩提升的概率平均提高约 4.67%,且主观成绩提升程度显著增加 18.28%。这表明生成式 AI 不仅对学业成绩有促进作用,而且使用时间越长,成绩提升幅度越显著。列(3)的结果显示, $duration$ 对学习效率是否提升($Efficiency_change$)的系数为正但不显著,说明使用时长对“是否感知到效率提升”这个二元变量的边际效应较弱。然而,列(4)中效率提升程度(ER_rate)的回归系数为 0.1160,并且在 5% 水平下显著,表明较长的使用时长与更高的效率提升感知程度之间存在统计意义上的正相关关系。

表4 生成式 AI 使用时长与学业表现

变量	(1) $Grade_change$	(2) GR_rate	(3) $Efficiency_change$	(4) ER_rate
$duration$	0.0467** (0.0145)	0.1828*** (0.0408)	0.0081 (0.0141)	0.1160** (0.0494)
控制变量	是	是	是	是
学校固定效应	是	是	是	是
专业固定效应	是	是	是	是
样本量	337	281	337	286

上述结果综合说明,生成式 AI 的使用深度在促进学生学习表现方面确有边际效应:随着使用时长增加,学生更可能获得成绩和效率的实质性改善。其可能机制在于,较长的使用时间有助于学生更熟练地掌握生成式 AI 工具的功能,并将其更有效地嵌入到写作、整理、答题或资料搜索等具体学习任务

中,从而实现知识获取效率和产出质量的同步提升。此外,学习效率是否提升的二元变量未达显著水平,这可能是因为生成式 AI 带来的效率感知存在阈值特征,短时使用或浅层使用尚难以显著改善认知效率,只有当 AI 使用达到一定深度后,个体才可能获得可感知的效率增益。

(三)生成式 AI 使用频率与学业表现

表 5 报告了生成式 AI 的使用频率(*frequency*)对大学生学业成绩与学习效率的影响。列(1)与列(3)结果显示,*frequency* 对学业成绩是否提升(*Grade_change*)与学习效率是否提升(*Efficiency_change*)的系数均为负,但均不具备统计显著性,说明仅从使

用频率的角度,尚不足以显著解释学生是否获得正向学习成效。列(2)与列(4)中,*frequency* 对成绩提升程度(*GR_rate*)与效率提升程度(*ER_rate*)虽为正向,但系数数值较小且未通过显著性检验。这表明,在控制个体特征、学校与专业固定效应后,生成式 AI 使用频率对学生学业表现的边际影响不显著。

表 5 生成式 AI 使用频率与学业表现

变量	(1) <i>Grade_change</i>	(2) <i>GR_rate</i>	(3) <i>Efficiency_change</i>	(4) <i>ER_rate</i>
<i>frequency</i>	-0.0660 (0.0228)	0.0438 (0.101)	-0.0133 (0.0241)	0.0980 (0.101)
控制变量	是	是	是	是
学校固定效应	是	是	是	是
专业固定效应	是	是	是	是
样本量	337	281	337	286

生成式 AI 使用时长与频率对学业表现产生差异化影响,根源在于二者在认知机制、学习动机和反馈利用等方面存在不同。一方面,使用时长代表深度交互,学生在较长的使用过程中更有机会熟悉功能、优化交互方式,将资料检索、语言润色等低阶任务交给生成式 AI,从而释放认知资源投入到高阶学习任务上,触发熟练化效应。另一方面,较长的时长往往伴随明确的学习任务,如论文写作或复杂问题求解,使学生能够通过反复试错、优化 Prompt 并加工反馈来改善学习策略,这与自我调控学习理论^[24]观点一致。相比之下,使用频率更可能反映碎片化、浅层次的接触,这类零散使用既难以融入学习流程,又可能导致认知割裂,甚至产生工具替代效应,削弱自主学习动机和主动性。这一发现与 Kasneci 等^[3]关于高频使用 AI 可能削弱学生独立思考能力的担忧相吻合。

五、异质性处理效应分析

(一)个体异质性处理效应的存在性检验

为验证是否使用生成式 AI 对大学生学业表现和学习效率是否存在显著的个体异质性处理效应,本文基于广义随机森林模型估计的个体处理效应值,绘制了核密度分布图,如图 1 所示。从图 1 各子图的分布形态可以观察到,生成式 AI 对大学生学业表现的影响存在显著的个体差异。图 1(a)和图 1(c)分别对应生成式 AI 对“学业成绩是否提高”与“学习效率是否提升”的个体处理效应分布,二者均呈现宽幅分布,密度曲线既包含明显正向影响的集中区域,也存在部分接近于零的效应区间,表明生成

式 AI 使用对不同大学生的影响强度并不一致。图 1(b)和图 1(d)所展示的“学业成绩提高程度”和“学习效率提升程度”的处理效应分布呈现更明显的尾部展开,这说明在学习成效提升幅度的层面,学生之间的差异更为显著。

核密度分布图验证了生成式 AI 对学业表现与学习效率的个体处理效应的广泛异质性。这一结果为后续探讨异质性影响的来源提供了依据,也凸显了制定差异化 AI 教育策略的重要性。不同学生群体在生成式 AI 使用中的适配性和反应机制具有显著异质性,因此高校和教育工作者亟须基于个体特征进行精准识别,并制定差异化的指导与干预策略。

(二)变量重要性分析

为了识别生成式 AI 对大学生学业表现影响的个体异质性来源,本文进一步基于广义随机森林模型,对处理效应的决定因素进行变量重要性排序。具体而言,本文考察了各变量在 GRF 模型中作为划分变量用于构建分裂节点的频率,即变量重要性指标。该指标反映了每一可观察变量在随机森林中用于识别处理效应异质性的边际贡献,频率越高,表明该变量在预测个体处理效应方面的区分度越强。

图 2(a)报告了生成式 AI 使用对学业成绩是否提升异质性处理效应的变量重要性排序。结果显示,年级(*grade*)、对新学习环境的适应能力(*adaptability*)、学习计划制定与执行力(*sp_persist*、*sp_making*)、电子资源使用情况(*eResource_using*)为最具解释力的前 5 个变量。图 2(b)报告了生成式 AI 使用对学业成绩提升程度异质性处理效应的变量重要性排序。初始学习成绩

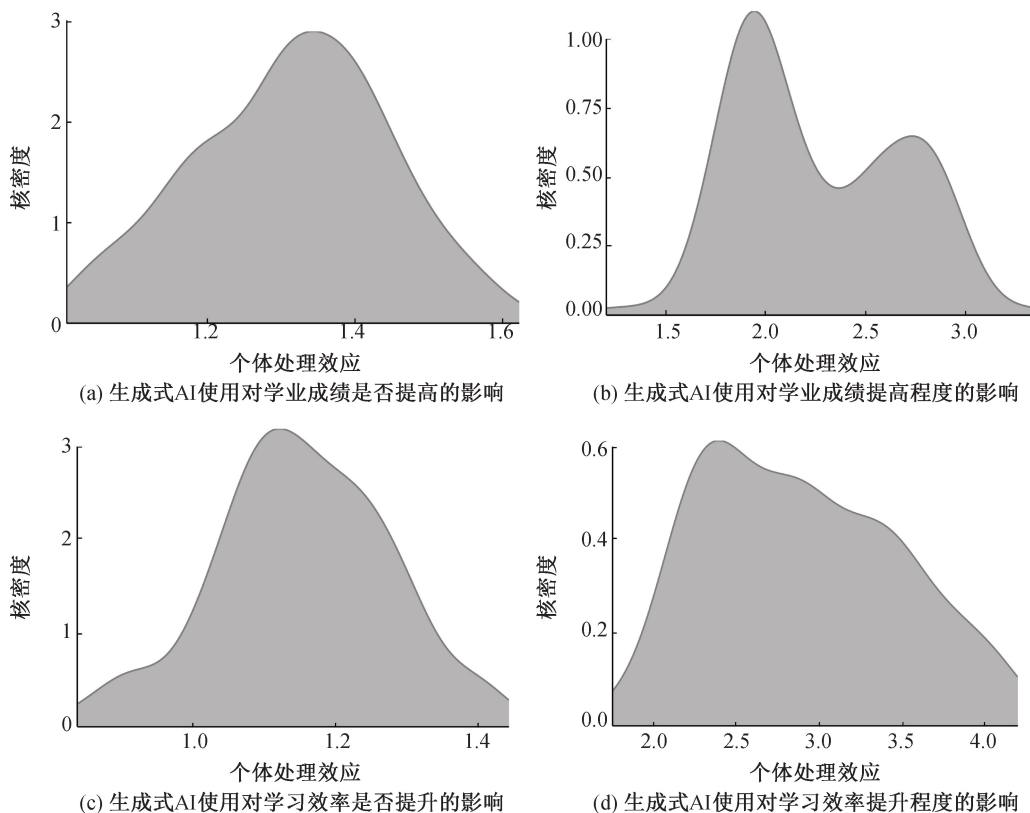


图 1 生成式 AI 使用对大学生学业表现个体处理效应的核密度分布图

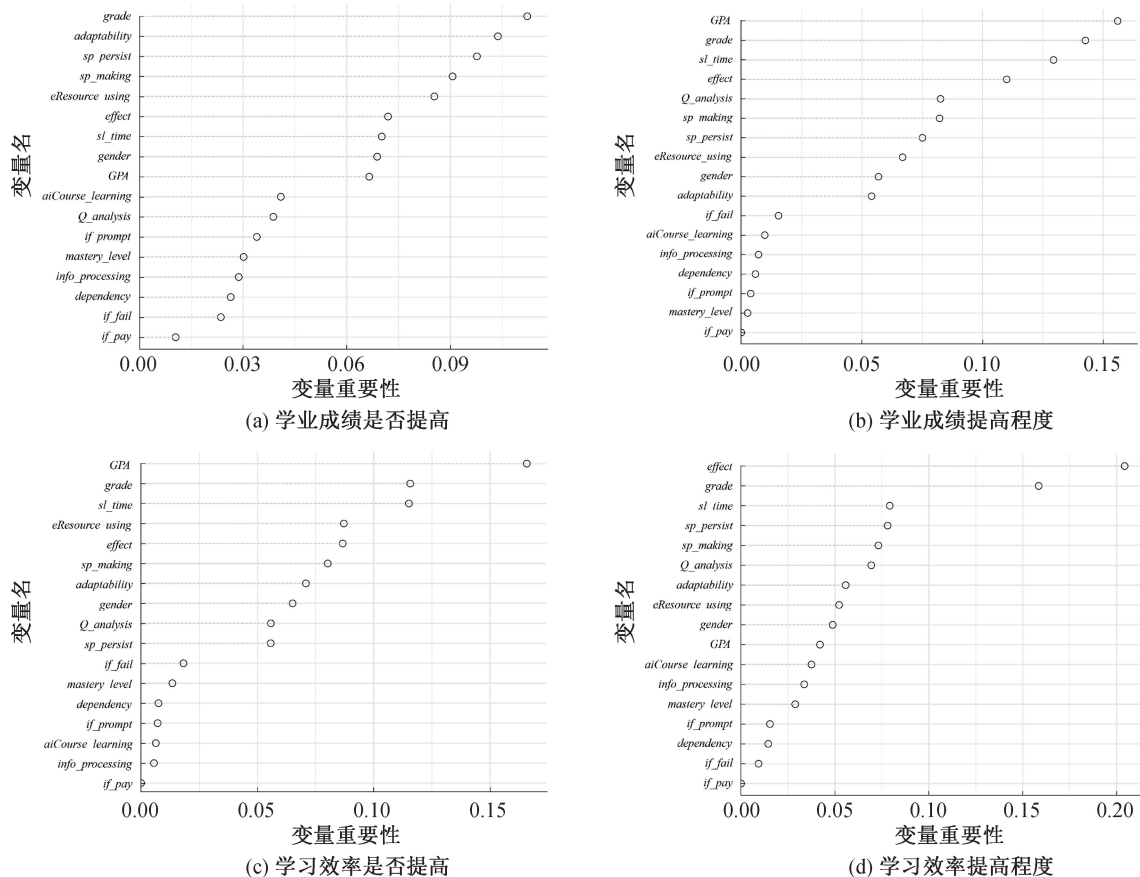


图 2 生成式 AI 使用对学业表现异质性处理效应的变量重要性排序

(GPA)、年级(*grade*)、学习投入(*sl_time*)和学习抗干扰能力(*effect*)为最具解释力的前5个变量。图2(c)报告了生成式AI使用对学习效率是否提升异质性处理效应的变量重要性排序。结果显示,初始学习成绩(GPA)、年级(*grade*)、学习投入(*sl_time*)、电子资源使用情况(*eResource_using*)以及学习抗干扰能力(*effect*)为最具解释力的前5个变量。图2(d)报告了生成式AI使用对学习效率提升程度异质性处理效应的变量重要性排序。学习抗干扰能力(*effect*)、年级(*grade*)、学习投入(*sl_time*)、学习计划制定(*sp_making*)和学习计划执行力(*sp_persist*)为最具解释力的前5个变量。

(三)重要变量与个体处理效应的交互分析

GRF方法在识别处理效应异质性方面具有较强的预测能力,尤其通过变量重要性排序为潜在调节变量的识别提供了有价值的参考。为增强结果的因果解释力,本文在识别出若干高重要性变量的基础上,进一步结合传统参数回归模型中交互项的统计显著性,对处理效应的调节机制进行检验。相比之下,参数回归模型在解释处理效应来源时具有更强的可解释性和稳健性,更契合实证研究对因果识别的要求。

对于在GRF中表现出较高重要性、但在回归分析中未显示统计显著性的变量,本文持谨慎解读态度。这类变量可能存在非线性效应或高阶交互结构,超出线性模型的识别能力,有待未来通过非参数或半参数方法进一步分析。在此基础上,本文选取了兼具高预测价值与显著调节效应的变量,绘制其与个体处理效应的交互关系图,以揭示异质性作用机制的具体表现。

1. 重要变量与生成式AI影响学业成绩的交互图

图3报告了学习适应能力(*adaptability*)对生成式AI影响学业成绩是否提高的调节作用。结果表现出两大异质效应:第一,低适应能力群体的受限效应。对于学习适应能力较弱的学生,使用生成式AI后成绩提升的可能性并不显著。这可能源于三个方面原因:一是这类学生在学习过程中缺乏有效的自我调节与元认知策略,难以筛选、评估和内化AI生成的信息;二是他们可能在与生成式AI的交互中陷入工具依赖,过度依靠低阶功能,削弱了自主思考和深度学习;三是生成式AI的操作与海量信息输出,可能增加额外的认知负担,导致学习过程更复杂。这些机制共同导致生成式AI在该群体中未

能转化为实质性的学业收益。第二,中高适应能力群体的放大效应。随着学习适应能力的提升,AI的积极作用逐渐显现并显著增强。适应能力较强的学生能够主动调整学习路径,合理分配认知资源,将AI工具用于资料整合、文本优化、知识拓展等辅助环节,从而把精力集中于理解复杂概念和开展批判性思维等高阶学习任务。因此,生成式AI在这一群体中表现出明显的边际效益递增。




图3 学习适应能力与学业成绩个体处理效应关系的散点平滑图

以上结果揭示了生成式AI可能加速学业表现的分化,若缺乏适应能力培训,本应普惠的技术红利可能演变为新的教育不平等。这意味着教学设计需要强化学习者的元认知训练与AI素养培养,例如教授学生如何批判性地使用AI输出内容、如何在学习过程中动态调整策略。只有实现能力与工具的良好匹配,生成式AI才能真正发挥提升学生学业成绩的作用。

图4报告了初始学习成绩(GPA)对生成式AI影响学业成绩提高幅度的调节作用,结果可概括为两大特征:第一,低起点学生的补偿效应。生成式AI为初始成绩较低的学生提供了更系统化的知识框架和即时反馈机制,能够在短时间内弥补其在知识储备、学习策略和自我调节方面的不足。例如,AI生成的个性化解释和示例,有助于他们突破理解障碍、降低学习门槛;自动化的写作和表达辅助,则使他们能更快地达到课程要求。这些作用使得低起点学生的成绩提升幅度显著高于高绩点群体,表现出一种“补短板”的教育功能。第二,高起点学生的边际递减效应。对于初始学业基础较强的学生,其学习策略、信息整合和批判性思维已相对完善,生成式AI在知识传递和技能支持方面的增量作用相对有限。这类学生在使用生成式AI时更多是“锦上添花”,收益空间受限,成绩提升幅度趋缓。这反映

了生成式 AI 的功能定位更偏向学习辅助而非学习替代,其对学业的增益会随着学习者自身能力的累积而逐渐下降。




图4 初始学习成绩与学业成绩个体处理效应关系的散点平滑图

这一发现凸显了生成式 AI 的“扶弱”特性。对于高等教育管理者而言,可以将生成式 AI 作为精准帮扶的工具,重点面向学业基础较弱的学生群体提供技术支持与使用指导,以缩小学业差距、提升整体教育公平性。同时,对于成绩较高的学生,应引导其将生成式 AI 作为创新平台,例如辅助研究探索和跨学科学习,避免边际效益递减带来的学习停滞,充分释放基础好的学生的发展潜力。

2. 重要变量与生成式 AI 影响学习效率的交互图

图5报告了初始学习成绩(GPA)对生成式 AI 影响学习效率是否提升的调节作用。结果显示,当学生的初始 GPA 较低时,生成式 AI 对其学习效率的提升作用相对有限;而随着 GPA 的提升,生成式 AI 对学习效率的正向影响显著增强。这一结果表明,学习基础较好的学生在使用生成式 AI 时,能够更有效地理解、整合和运用 AI 提供的信息与建议,从而优化其学习策略、节省时间并提升效率。相反,初始成绩较低的学生可能由于基础知识薄弱或学习策略欠佳,难以充分发挥 AI 工具的潜力,学习效率提升不明显。

上述结果表明,生成式 AI 的效率提升并非自动普惠,而是高度依赖于学习者的基础条件。因此,教育者在推广生成式 AI 时,应对基础较弱的学生提供使用引导和能力补偿,例如通过 AI 素养训练提升其信息甄别与策略应用能力;而对基础较好的学生,则可引导其将生成式 AI 用于更高阶的创新实践和跨学科学习,充分挖掘技术的增量价值。




图5 初始学习成绩与学习效率个体处理效应关系的散点平滑图

图6报告了学习抗干扰能力(effect)对生成式 AI 影响学习效率提升程度的调节作用。结果呈现两种不同趋势:第一,低抗干扰群体的负面溢出效应。这类学生更容易被生成式 AI 输出的多样化信息干扰,可能在信息筛选和任务聚焦环节出现认知分散,甚至陷入信息过载的困境。使用生成式 AI 虽然可用于提高学习效率,降低学习成本,但其在提供多渠道、多角度信息时,对注意力管理不足者反而制造了新的学习障碍。第二,高抗干扰群体的聚焦放大效应。这类学生能在生成式 AI 海量输出中迅速识别关键信息,过滤噪声,并将有效信息转化为可操作的学习路径,从而最大化发挥生成式 AI 的优势,实现学习效率的提升。




图6 学习抗干扰能力与学习效率个体处理效应关系的散点平滑图

这一结果揭示了生成式 AI 发挥作用的门槛特征,缺乏注意力控制会削弱甚至逆转生成式 AI 的积极效果,而注意力控制达到一定水平后,其效率提升效应才会显著释放。因此,开展个性化教育干预应将生成式 AI 使用培训与注意力控制能力培养相结合,以避免注意力管理不足的学生群体在生成式 AI 应用中被进一步边缘化。

六、结 语

(一)研究结论

本文聚焦生成式 AI 在高等教育场景中的应用,利用广义随机森林模型对杭州市 9 所高校 407 份调查问卷数据进行了实证分析,探究其对大学生学业表现的影响。研究发现,生成式 AI 在大学生群体中具有较高的普及率,其使用显著提升了大学生的学业成绩和学习效率,表明其在高等教育中具备较强的正向赋能潜力。具体而言,使用生成式 AI 显著提升了大学生的学业成绩,且使用时间越长,其对学习效果的改善越显著;然而,单纯提高使用频率并未显著增强学习成效,说明 AI 使用效果取决于使用方式与交互深度,而非频率本身。进一步,通过 GRF 模型分析发现,生成式 AI 使用对学生学业表现存在显著的个体异质性。变量重要性分析和交互效应图表明,年级、GPA、学习计划执行力、电子资源使用情况、学习适应能力与抗干扰能力等变量在影响生成式 AI 使用效果方面发挥关键作用。总体而言,学习基础较差、适应性强或抗干扰能力高的学生受益更大,而抗干扰能力较差的学生反而收益有限甚至可能出现负面效果。这表明,生成式 AI 并非对所有学生都“普惠”,其实际教育效果受到复杂个体特征与行为因素的共同调节。因此,在高等教育中应用生成式 AI 时,应结合学生特质进行有针对性地引导和资源配置,避免技术乐观主义下的简单推广策略,从而推动 AI 工具在促进教育公平和个性化教学中的精准落地。

(二)研究启示

上述研究发现为高校教育管理者 and 政策制定者提供了三方面重要启示:

第一,因材施教推进生成式 AI 精准赋能。生成式 AI 对不同学生的受益程度存在显著差异,呈现出“扶弱”特性。这意味着高校在推动“人工智能+高等教育”战略时,应避免同质化的推广方式,建立起以学生特质为基础的分层分类指导机制。例如,可为学习基础薄弱但适应力强的学生提供更多 AI 辅助资源与使用引导,提升其学习信心与自我驱动能力,实现教育公平与能力提升的双重目标。

第二,优化高校 AI 教育资源配置与课程设计。研究表明,生成式 AI 的学习收益取决于使用深度而非使用频率,高校应引导学生掌握高质量 AI 使用方法,提升其对 AI 结果的理解与加工能力。针对学生在 AI 技能掌握、信息处理能力与交互水平

方面的差异,高校可将 AI 素养纳入通识教育体系,开设“AI 写作指导”“AI 伦理规范”“Prompt 优化技巧”等实用课程,强化 AI 使用的策略性与批判性思维支持,提升学生的自主学习能力和学术创新能力。

第三,将个体学习行为特征纳入高等教育干预体系。个体学习行为在生成式 AI 赋能路径中具有关键作用。高校在推动 AI 辅助教学时,应同步开展学习行为干预,如通过时间管理训练、注意力控制课程、在线行为反馈系统等手段,提升学生在 AI 支持下的学习效能。构建“技术赋能+行为优化”的复合型干预体系,是生成式 AI 发挥教育潜力的制度保障。

(三)研究局限与未来研究展望

尽管本文基于广义随机森林模型,有效识别了生成式人工智能对大学生学业表现的异质性影响,为相关研究提供了实证参考,但仍存在若干局限,有待未来研究进一步深化。首先,在学科适用性方面,本文样本涵盖了 9 所高校和 12 个学科大类,能够较好地反映生成式 AI 在高等教育中的整体情况,但在更细层次的学科差异上仍有进一步研究空间。不同学科在知识结构和学习方式上的差异,可能影响生成式 AI 的应用效果。未来研究若能在更大样本和更细分学科维度上展开,将有助于更清晰地呈现 AI 在跨学科的差异作用。其次,在教育目标衡量方面,本文以 GPA 与学习效率作为学业表现的主要代理指标,虽能够较为直观地反映生成式 AI 的短期学习效应,但在批判性思维、独立探究和创新能力等教育核心目标方面的作用尚待更全面的考察。未来研究可结合纵向追踪数据与多维度测评指标,进一步深化对生成式 AI 长期教育价值的理解。

参考文献:

- [1] Chen X, Zou D, Xie H, et al. Two decades of artificial intelligence in education[J]. Educational Technology & Society, 2022, 25(1): 28-47.
- [2] Abdaljaleel M, Barakat M, Alsanafi M, et al. A multinational study on the factors influencing university students' attitudes and usage of ChatGPT[J]. Scientific Reports, 2024, 14: 1983.
- [3] Kasneci E, Seßler K, Küchemann S, et al. ChatGPT for good? On opportunities and challenges of large language models for education[J]. Learning and Individual Differences, 2023(103): 102274.
- [4] Johnson A. ChatGPT in schools: Here's where it's banned—and how it could potentially help students[N]. Forbes, 2023-01-31.
- [5] Weber-Wulff D, Anohina-Naumecca A, Bjelobaba S, et al. Testing

- of detection tools for AI-generated text[J]. International Journal for Educational Integrity, 2023, 19(1): 26.
- [6] Brown T, Mann B, Ryder N, et al. Language models are few-Shot learners[J]. Journal of Artificial Intelligence Research, 2020, 33: 1877-1901.
- [7] Radford A, Wu J, Amodei D, et al. Better language models and their implications[EB/OL]. (2019-02-14)[2025-10-10]. <https://openai.com/index/better-language-models>.
- [8] 刘明,郭烁,吴忠明,等. 生成式人工智能重塑高等教育形态:内容、案例与路径[J]. 电化教育研究, 2024, 45(6): 57-65.
- [9] 王思遥,黄亚婷. 促进或抑制:生成式人工智能对大学生创造力的影响[J]. 中国高教研究, 2024(11): 29-36.
- [10] An Y, Yu J H, James S. Investigating the higher education institutions' guidelines and policies regarding the use of generative AI in teaching, learning, research, and administration [J]. International Journal of Educational Technology in Higher Education, 2025, 22(1): 10.
- [11] 周洪宇,常顺利. 生成式人工智能嵌入高等教育的未来图景、潜在风险及其治理[J]. 现代教育管理, 2023(11): 1-12.
- [12] Wang J, Fan W. The effect of ChatGPT on students' learning performance, learning perception, and higher-order thinking: Insights from a meta-analysis [J]. Humanities and Social Sciences Communications, 2025, 12: 621.
- [13] Sun L, Zhou L. Does generative artificial intelligence improve the academic achievement of college Students? A meta-analysis [J]. Journal of Educational Computing Research, 2024, 62(7): 1676-1713.
- [14] Ayeni O O, Al Hamad N M, Chisom O N, et al. AI in education: A review of personalized learning and educational technology[J]. GSC Advanced Research and Reviews, 2024, 18(2): 261-271.
- [15] Malik A R, Pratiwi Y, Andajani K, et al. Exploring artificial intelligence in academic essay: Higher education student's perspective[J]. International Journal of Educational Research Open, 2023, 5: 100296.
- [16] Michel-Villarreal R, Vilalta-Perdomo E, Salinas-Navarro D E, et al. Challenges and opportunities of generative AI for higher education as explained by ChatGPT[J]. Education Sciences, 2023, 13(9): 856.
- [17] Hashmi N, Bal A S. Generative AI in higher education and beyond[J]. Business Horizons, 2024, 67(5): 607-614.
- [18] Reina Marin Y, Cruz Caro O, Maicelo Rubio Y C, et al. Artificial intelligence as a teaching tool in university education [J]. Frontiers in Education, 2025, 10: 1578451.
- [19] Holmes W, Porayska-Pomsta K, Holstein K, et al. Ethics of AI in education: Towards a community-wide framework[J]. International Journal of Artificial Intelligence in Education, 2022, 32: 504-526.
- [20] Markauskaite L, Marrone R, Poquet O, et al. Rethinking the entwinement between artificial intelligence and human learning: What capabilities do learners need for a world with AI? [J]. Computers and Education: Artificial Intelligence, 2022, 3: 100056.
- [21] Qu Y, Tan M, Wang J. Disciplinary differences in undergraduate students' engagement with generative artificial intelligence[J]. Smart Learning Environments, 2024, 11: 51.
- [22] Athey S, Tibshirani J, Wager S. Generalized random forests [J]. The Annals of Statistics, 2019, 47(2): 1148-1178.
- [23] Sweller J. Cognitive load during problem solving: Effects on learning[J]. Cognitive Science, 1988, 12(2): 257-285.
- [24] Zimmerman B J. Becoming a self-regulated learner: An overview[J]. Theory Into Practice, 2002, 41(2): 64-70.

附表1 变量含义及赋值

变量名	变量含义	对应问卷中的问题	变量赋值
<i>if_use</i>	是否使用生成式 AI	您是否使用过生成式人工智能?	1=是;0=否。
<i>frequency</i>	生成式 AI 使用频率(天/周)	您使用生成式 AI 工具的频率是?	0=每周使用 0 天;1=每周使用 1 天或更少;2=每周使用 2 天;3=每周使用 3 天;4=每周使用 4 天;5=每周使用 5 天及以上。
<i>duration</i>	生成式 AI 使用时长(分钟/次)	您平均每次使用生成式 AI 的时长为?	0=每次 10 分钟及以下;1=每次 11~30 分钟;2=每次 31~60 分钟;3=每次 61~90 分钟;4=每次 91~120 分钟;5=每次 121 分钟以上。
<i>Grade_change</i>	学业成绩是否提高	生成式 AI 广泛应用后,您学业成绩的变化情况是?	1=提高;0=无提高。
<i>GR_rate</i>	学业成绩提升幅度	生成式 AI 广泛应用后,您学业成绩的提高程度是? (仅上一题回答“提高”的学生作答)	0=提升 0~10%;1=提升 11%~20%;2=提升 21~30%;3=提升 31%~40%;4=提升 41%~50%;5=50%及以上。
<i>Efficiency_change</i>	学习效率是否提升	生成式 AI 广泛应用后,您学习效率的变化情况是?	1=提高;0=无提高。
<i>ER_rate</i>	学习效率提升幅度	生成式 AI 广泛应用后,您学习效率的提高程度是? (仅上一题回答“提高”的学生作答)	0=提升 0~10%;1=提升 11%~20%;2=提升 21~30%;3=提升 31%~40%;4=提升 41%~50%;5=50%及以上。
<i>gender</i>	性别	您的性别是?	1=男性;0=女性。

续附表1

变量名	变量含义	对应问卷中的问题	变量赋值
<i>grade</i>	年级	您的年级是?	1=大一;2=大二;3=大三;4=大四;5=研究生。
<i>GPA</i>	初始学业成绩	在生成式 AI 广泛应用之前,您的平均绩点是?	1=1.0~2.0;2=2.1~3.0;3=3.1~4.0;4=4.1及以上。
<i>if_fail</i>	课程通过情况	您当前或曾经是否存在成绩不合格的课程?	1=有不通过课程;0=无不通过课程。
<i>sl_time</i>	学习投入(小时/周)	您每周课后自主学习的时间为?	1=极少(小于等于5小时/周);2=少量(6~10小时/周);3=适中(11~20小时/周);4=较多(21~30小时/周);5=非常多(超过30小时/周)。
<i>effect</i>	学习专注力	您在学习时会被社交媒体所影响吗?	1=极低(总是很难专注学习,经常被社交媒体分散注意力);2=低(有时会很难集中注意力,但通常能专心学习);3=中等(通常能保持专注,偶尔会分心);4=高(有时会分心,但通常能保持专注);5=极高(社交媒体极少使我无法集中注意力)。
<i>adaptability</i>	对新学习环境的适应程度	您在面对新的学习环境或学习方式时的适应性如何?	1=极低(很难适应新的学习环境或方式);2=低(有些困难,但最终能适应);3=中等(通常能在一定时间内适应新的学习环境或方式);4=高(相对容易适应新的学习环境或方式);5=极高(非常容易适应新的学习环境或方式,几乎没有问题)。
<i>Q_analysis</i>	是否具有批判性思维	您在分析问题时,倾向于接受直觉想法还是考虑多个角度?	0=倾向于接受直觉想法;1=倾向于考虑多个角度。
<i>eResource_using</i>	电子资源的使用情况	您在学习过程中使用电子资源的频率如何?	1=极少(几乎不使用电子资源);2=少量(偶尔使用,但不经常);3=适中(一般情况下会使用电子资源);4=较多(经常使用电子资源作为学习的主要来源之一);5=非常多(几乎所有学习内容都依赖于电子资源)。
<i>sp_making</i>	学习计划的制定情况	您是否会制定学习计划?	1=很少或没有明确的学习计划;2=有时会制定计划,但长期规划不够明确;3=通常会制定比较明确的学习计划;4=对短期和长期学习目标都有清晰规划。
<i>sp_persist</i>	学习计划的执行情况	您是否能坚持执行学习计划?	1=难以坚持执行;2=执行不稳定;3=大部分情况能坚持执行;4=所有计划都能高效执行。
<i>if_prompt</i>	学生对生成式 AI 的训练情况	您是否会对 AI 输入指令(prompt)进行优化?	0=从未学习过 prompt;1=每季度学习 prompt;2=每月学习 prompt;3=每周学习 prompt。
<i>if_pay</i>	学生对生成式 AI 的付费情况	您是否曾为生成式 AI 付费?	1=我定期为生成式 AI 付费/我曾经为生成式 AI 付过一次费用;0=我从未为生成式 AI 付费。
<i>aiCourse_learning</i>	AI 相关课程学习情况	您是否学习过如何使用 AI 的教程、视频或论文等?	0=从未学习过;1=每季度学习;2=每月学习;3=每周学习;4=每天学习。
<i>mastery_level</i>	AI 技能掌握程度	您对您使用的 AI 工具的掌握程度如何?	0=几乎不了解生成式 AI 使用方法;1=会简单提问或复制使用 AI 输出;2=能用 AI 写短文、查资料或辅助学习;3=能设计 prompt、批判地使用 AI 输出;4=能结合 AI 进行创作、分析或编程辅助。
<i>info_processing</i>	对生成式 AI 提供信息的处理能力	在搜索信息时,对于 AI 工具生成的内容,您的做法通常是?	0=仅作为一个消遣工具,不作为具体学习参考;1=接受 AI 全部生成的内容,不做修改,直接采纳;2=结合自己的理解和知识稍加润色,进行适当的修改和调整;3=仅以 AI 生成内容为参考,仔细检查验证,取其精华;4=能以 AI 输出结果为基础,进行创作与分析。
<i>dependency</i>	对生成式 AI 的依赖程度	您对生成式人工智能的依赖程度如何?	0=几乎不使用 AI,对学习或工作完全不依赖 AI;1=偶尔使用 AI,仅在特殊情况下参考其结果;2=有时使用 AI,但主要依靠自己的思考与判断;3=经常使用 AI,学习或工作部分环节离不开 AI;4=在多数学习或工作任务中依赖 AI 支持;5=几乎所有学习或工作活动都依赖 AI 完成。