

生成式人工智能与企业劳动力 需求结构分化 ——基于ChatGPT发布的准自然实验

何 勤, 李鑫悦

(首都经济贸易大学 劳动经济学院, 北京 100070)

摘要: 生成式人工智能正深刻改变劳动力市场结构。基于2022—2023年中国在线招聘平台数据, 文章以ChatGPT发布为准自然实验, 构建广义双重差分模型考察其对企业劳动力需求结构的影响。研究发现, 生成式人工智能显著引发了招聘需求的结构性调整, 常规职业的收缩幅度明显大于非常规职业, 技术冲击主要集中于程序化程度较高的认知职业。基于任务分类的结果显示, 这种影响并非均匀作用于所有认知职业, 而是主要集中于常规认知职业以及信息分析与处理型非常规认知职业。机制分析表明, 任务效率提升和新任务创造共同推动了劳动力需求结构分化。异质性分析表明, 技术冲击在无经验岗位要求、民营企业、劳动密集型行业及传统产业中更为显著。进一步分析发现, 生成式人工智能在提高岗位工资的同时加剧了职业竞争; 相较于常规职业, 非常规职业的工资提升更明显、职业竞争更激烈, 体现出非对称技术红利和竞争加剧的特征。文章从企业招聘视角揭示了生成式人工智能重塑劳动力需求结构的微观机制, 为理解技术冲击下的就业结构调整提供了经验证据。

关键词: 生成式人工智能; 常规职业; 非常规职业; 劳动力需求; 结构分化

中图分类号: F241 **文献标识码:** A **文章编号:** 1009-0150(2026)04-0045-15

一、引言

生成式人工智能正在加速嵌入经济社会各领域, 并对企业组织形态与劳动力需求结构产生深远影响。2022年11月30日, ChatGPT发布, 生成式人工智能由此进入快速扩散阶段。与传统人工智能侧重于识别、预测和执行既定规则不同, 生成式人工智能基于大语言模型的内容生成和语义推理能力, 能够完成文本撰写、代码生成、信息整合等复杂任务, 其技术边界已由“感知理解”拓展至“生成创造”。随着技术的快速扩散, 企业内部的岗位任务组合正在发生重构, 劳动力需求的结构性调整问题逐渐凸显。从任务视角出发, 新技术往往通过改变不同任务的相对收益率来影响劳动力需求结构 (Autor等, 2003)。具体而言, 大语言模型在文本整理、标准化表达、基础代码编写等常规认知任务中表现出较强替代能力 (Felten等, 2023; Eloundou等, 2024), 技术嵌入可能压缩可编码、可拆解的常规任务空间 (Hui等, 2024)。此外, 在非常规认知任务内部, 生成式人工智能的影响存在异质性。对于以复杂决策、情境判断、社会互动为主的任务, 人与机

收稿日期: 2026-01-09

基金项目: 国家社会科学基金重点项目“通用人工智能下知识型劳动者就业转型困境及人机协作增强破解策略研究”(25AGL027)。

作者简介: 何 勤(1972—), 女, 四川青神人, 首都经济贸易大学劳动经济学院教授、博士生导师;

李鑫悦(1998—), 女, 河南南阳人, 首都经济贸易大学劳动经济学院博士研究生(通信作者)。

器可能形成互补关系;而对于以信息整合、结构化分析、模式识别为主的任务,机器则可能对人形成替代性冲击(马晔风等, 2024; Liu和Shen, 2025)。由此可见,生成式人工智能对劳动力需求的影响并不均匀,主要体现为认知任务内部的结构性重组,以及非常规认知任务内部的进一步分化。

现有文献围绕人工智能与就业关系展开了广泛讨论,但针对生成式人工智能的实证研究仍较为有限。部分研究通过构建职业暴露度指数,预测不同岗位面临的自动化风险(张丹丹等, 2025; Chen等, 2025),也有文献基于实验或调查数据,分析技术应用对特定行业的影响(马晔风等, 2024)。然而,在中国情境下,基于企业真实招聘行为识别生成式人工智能冲击的研究尚不充分,尤其缺乏对企业需求结构调整的系统分析。

基于此,本文利用2022—2023年中国大型在线招聘平台的月度数据,以ChatGPT发布为准自然实验,构建广义双重差分模型,识别生成式人工智能对企业劳动力需求结构的影响。本文重点关注不同任务类型的职业在技术冲击前后的需求变化,并分析其内在机制。本文的边际贡献主要体现在三方面:第一,在研究视角方面,既有研究多从职业或岗位层面评估生成式人工智能的替代风险,主要依赖年度统计数据或问卷调查数据(张展培等, 2024; 张咏雪, 2024),难以刻画企业招聘决策在技术冲击初期的动态调整。本文基于月度在线招聘数据,将分析维度从“哪些职业受到冲击”推进至“职业内部不同任务如何差异化地承受冲击”,为理解生成式人工智能对劳动力需求的差异化影响,尤其是非常规认知职业内部的任务结构分化,提供了更具时效性的微观证据。第二,在理论框架方面,既有研究在运用任务理论来分析生成式人工智能冲击时,往往将非常规认知职业视为一种相对整体的技术互补类型,而较少关注其内部任务结构的异质性。本文基于任务偏向型技术进步理论和新任务创造理论,将任务属性的识别维度进一步延伸至职业内部,按照不同任务的替代性和创造性,对非常规认知职业加以细分,从而拓展了相关理论对生成式人工智能阶段劳动需求变化的解释边界。第三,在机制识别方面,既有研究对生成式人工智能影响劳动力需求结构的内在渠道缺乏系统的微观检验。本文从任务效率提升和新任务创造两个维度开展识别:前者关注生成式人工智能是否通过提升不同类型任务的效率来处理效率来影响企业招聘决策,后者关注其是否通过催生新职业需求来重塑非常规认知职业的任务结构,进而为理解劳动力需求结构的差异化调整提供了微观机制层面的经验证据。

二、理论分析与研究假设

(一)理论框架构建

为解释生成式人工智能对企业劳动力需求结构的影响,本文基于任务偏向性技术进步理论构建分析框架。该理论指出,新技术并非均匀影响所有劳动类型,而是改变不同任务的相对收益率,进而重塑劳动力需求结构(Autor等, 2003)。在这一理论框架下,职业由不同任务构成,其中,遵循既定规则、流程清晰且可程序化处理的常规任务更易被技术替代,而依赖复杂判断、创造性思维、人际互动的非常规任务则总体上难以被技术完全替代,体现出更强的互补性。既有研究表明,技术冲击对劳动力市场的结构性影响呈现阶段性特征。早期的工业自动化与机器人技术主要替代常规体力任务(Graetz和Michaels, 2018),随后的信息化与预测型人工智能技术则集中替代基于明确规则的常规认知和计算任务(Autor和Dorn, 2013; Goos等, 2014),从而推动劳动力市场形成就业极化现象。生成式人工智能的出现推动自动化边界进一步向认知领域拓展。基于大语言模型的内容生成和语义推理能力,该技术能够处理标准化文本撰写、初级代码生成、基础数据分析等程序化认知任务(Felten等, 2023; Eloundou等, 2024)。技术冲击的

重心不仅从常规体力任务转向常规认知任务,更延伸至非常规认知任务内部,使其呈现出可替代和可互补并存的异质性特征(黄旭等, 2025)。

为了更直观地阐释生成式人工智能对任务结构的影响,本文参考Autor等(2003)以及Acemoglu和Restrepo(2024)的任务模型,构建生成式人工智能任务冲击框架^①,见图1。在该框架下,任务被划分为四个象限:常规体力任务(C_1)、非常规体力任务(G_1)、常规认知任务(C_2)、非常规认知任务(G_2)。如图1所示,生成式人工智能的冲击并未均匀压缩所有任务空间,而是呈现出显著的结构性偏向。与传统工业自动化主要替代常规体力任务(C_1)不同,生成式




图1 生成式人工智能的任务冲击框架

人工智能的冲击重心发生实质性跃迁,主要集中于认知任务领域。具体而言,常规认知任务(C_2)面临替代任务(A_1)带来的压力,非常规认知任务(G_2)则呈现内部再分化的特征。其中,信息分析与处理型任务(A_2)更易受到替代性冲击,人际互动与复杂决策型任务则更多体现为互补和增强,这一差异的关键边界在于任务的程序化程度和情境依赖度。与此同时,技术扩散过程中,围绕模型训练、提示设计、模型调优、算法合规、内容审核、人机协作等创造的全新任务空间,对应图1中的新任务区域(N)。基于此,本文进一步提出任务效率提升和新任务创造两种作用机制,以解释生成式人工智能如何通过改变职业内部任务组合、扩展新任务边界,来推动企业劳动力需求出现结构性分化。

(二) 生成式人工智能与劳动力需求的结构性调整

基于上述框架,生成式人工智能对企业劳动力需求的影响更可能体现为结构性分化而非均匀收缩,其关键在于不同任务类型在技术可替代性和互补性上的差异。与既有技术浪潮相比,生成式人工智能一方面延续了自动化替代常规任务的趋势,将能力边界由明确的流程性任务扩展至更广泛的程序化认知领域(黄旭等, 2025),使行政支持、文秘处理、初级分析等常规职业中可自动化任务占比上升,从而削弱企业对相关劳动力的需求(Goller等, 2025)。另一方面,在复杂决策、跨部门协调、社会互动等环节,生成式人工智能主要以辅助和增强方式嵌入生产流程,而非完全替代劳动投入(Liu和Shen, 2025)。

特别地,这一技术冲击过程在不同任务类型的认知职业间呈现显著的非对称性。常规认知职业的工作内容多以标准化文本处理、信息整理、规则执行、基础分析为主,与生成式人工智能的技术能力高度匹配,企业新增劳动力需求由此更易受到挤压(Felten等, 2023; Goller等, 2025)。相较而言,非常规认知职业内部并非同质性的整体。其中,以信息整合、结构化分析、模式识别为主的信息分析与处理型任务,具有较高的可分解性和可编码性,因而更易受到生成式人工智能的替代性冲击;而对于以情境判断、人际互动、复杂协调、创造性思维为主的人际互动与复杂决策型任务,生成式人工智能则更多发挥互补和增强作用(Deming, 2017; Webb, 2019)。因此,生成式人工智能对非常规认知职业的冲击并不会造成整体性收缩,更可能表现为职业内部任务结构的再分化。其中,以信息分析与处理型任务为主的职业面临更大的替代压力,而以人际互动与复杂决策型任务为主的职业则更可能承接新任务创造带来的新增需求

^①参考Acemoglu和Restrepo(2024)的任务模型自行绘制所得。

(Demirci等, 2025)。相比之下, 体力型任务与生成式人工智能的技术特征匹配度较低, 承受的直接冲击相对有限。综上, 本文提出以下研究假设:

假设1: 生成式人工智能将显著推动企业劳动力需求发生结构性分化, 常规职业的收缩幅度大于非常规职业。同时, 替代性冲击集中于常规认知职业和以信息分析与处理型任务为主的非常规认知职业。

(三) 任务效率提升效应

在生成式人工智能的冲击下, 企业劳动力需求的结构性调整更多体现为职业内部程序化任务处理效率的提升, 而非职业相关岗位数量的简单变化。根据任务偏向性技术进步理论, 技术进步会改变不同任务的相对生产率和边际成本, 进而影响企业的用工决策 (Acemoglu和Restrepo, 2018)。生成式人工智能凭借其内容生成和语义推理能力, 能够高效率地完成文本撰写、数据整理、初级分析等程序化认知任务, 显著提升此类任务的技术替代性。当原本需要人力完成的程序化认知任务转由生成式人工智能承担后, 企业完成既定工作量所需的人力投入将相应减少, 能够在不增加用工规模的条件下维持既定产出。

这一效率提升过程在常规职业与非常规职业间呈现出异质性。常规职业的核心工作内容以规则明确、流程清晰的程序化认知任务为主, 与生成式人工智能的能力具有较高契合度 (Hui等, 2024; Brynjolfsson等, 2025)。因此, 在生成式人工智能介入后, 企业可借助技术替代部分既有任务, 在不增加用工规模的情况下完成原本需要新增人力承担的工作内容, 显著提高常规工作的完成效率 (Acemoglu等, 2026), 并在招聘决策中优先压缩常规职业相关岗位的新增需求 (Marguerit, 2025)。相比之下, 非常规职业的核心工作内容包含情境判断、复杂决策、人际协调等任务, 高度依赖人类的经验积累和临场应变能力。生成式人工智能仅能替代非常规职业中的部分程序化认知任务, 难以从根本上替代其核心工作环节 (Demirci等, 2025; 汪红驹和丁少斌, 2025)。因此, 技术介入对非常规职业整体工作效率的提升相对有限, 其新增招聘需求受到的影响也偏弱。基于此, 本文提出以下研究假设:

假设2: 生成式人工智能通过任务效率提升效应来降低企业对常规职业相关岗位的招聘需求。

(四) 新任务创造效应

生成式人工智能的应用推动企业重新配置工作岗位, 该技术在替代部分传统劳动力的同时, 也催生出一批专注于人机协作与AI系统管理的新职业, 这些职业有助于企业进一步释放技术潜力 (Zarifhonarvar, 2024)。根据Acemoglu和Restrepo (2019)的新任务创造理论, 技术进步不仅通过生产率效应来提高产出, 还通过恢复效应来重塑生产中的任务构成, 创造新的、劳动者具有比较优势的任务领域。事实上, 生成式人工智能在应用过程中会催生模型训练、提示设计、算法合规、内容审核、风险控制等新任务。为了将技术潜力充分转化为实际生产率, 企业需开展适应性投资与组织能力升级, 并围绕这些新任务设置相应岗位 (Gulati等, 2025; Fang等, 2025), 例如人工智能训练师、算法合规专员、信息安全测试员、生成内容审核员等。这些岗位多属于非常规认知职业, 强调在问题解决、创造性思维、伦理判断等领域的高阶能力。与程序化认知任务不同, 生成式人工智能在上述领域更多发挥互补和增强作用, 从而提升相关技能的边际产出和任务收益率 (Jia等, 2024; Kanazawa等, 2026)。因而, 新任务的创造并非简单的岗位扩张, 而是企业将程序化认知任务所占用的组织资源转向驾驭新技术所需的人力资本投入。由此, 在生成式人工智能的冲击下, 非常规职业因新任务创造而呈现相对更强的韧性, 企业对相关岗位的新增招聘需求上升, 进一步强化劳动力需求的结构性分化。基于此, 本文提出以下研究假设:

假设3:生成式人工智能通过新任务创造效应来提高企业对非常规职业相关岗位的招聘需求。

三、研究设计

(一)数据来源

一方面,企业招聘数据来自智联招聘平台在2022年1月1日至2023年12月31日期间发布的企业招聘广告。该数据由研究团队与智联招聘平台合作获取,在平台全量数据库支持下,采用以一级职业分类为分层维度的随机抽样方法构建研究样本,使样本在职业结构、行业分布、企业类型等维度上与总体保持基本一致。本文最终获得约1万个招聘样本,主要包括企业代码、所属行业、职业名称、职业类别、职位描述、工作地点、需求人数、岗位投递人数、职业薪资等信息。

与传统劳动力调查数据相比,在线招聘平台数据具有高频、细颗粒度和实时性优势,能够更及时地反映企业招聘需求的边际变化,因而适用于识别新技术冲击下劳动力需求的短期结构调整(陈琳等,2024;张丹丹等,2025)。已有研究表明,在线招聘数据能够较好地反映劳动力市场的结构变化(马双等,2023)。此外,本文采用Bootstrap重抽样方法对样本代表性进行了检验,结果显示,样本在职业结构维度上具有较好的代表性。^①

需要指出的是,在线招聘数据反映的是企业招聘意愿而非最终雇佣结果,且部分企业可能存在重复发布招聘信息的情况。对此,本文在数据处理中严格去重,并主要关注不同类型岗位的相对变化,而非招聘规模的绝对数值。鉴于生成式人工智能冲击具有突发性和近期性,高频微观招聘数据仍是识别其对劳动力市场影响的重要数据来源。

另一方面,用于计算职业层面生成式人工智能暴露度的数据主要来自Felten等(2021,2023)构建的美国职业大语言模型暴露度指标,地区层面的宏观变量数据则来自EPS数据平台的中国经济宏观数据库。

综合上述数据,本文剔除兼职、实习、校园招聘岗位以及行业缺失样本,并对不合理薪资及中国特有职业类型进行清洗处理,最终获得7339个有效观测值,用于后续实证分析。

(二)识别策略

本文将ChatGPT的发布视为一项准自然实验,构建广义双重差分模型以识别生成式人工智能对企业劳动力需求结构的影响。识别策略的核心逻辑在于,不同职业因其任务内容与大语言模型能力的契合程度存在系统差异,因而受到的技术冲击强度并不相同。特别是在2022—2023年生成式人工智能扩散的早期阶段,技术冲击主要集中于程序化认知任务,对体力操作、复杂执行、高度情境依赖型任务的直接影响则相对有限。基于此,本文依据各职业的人工智能暴露度构建连续型处理强度指标,以识别不同职业在生成式人工智能冲击下的异质性反应。需要指出的是,该指标反映企业招聘端对潜在自动化能力的边际反应,而非现实中已经发生的全面替代。基准模型如下:

$$Lnlab_{j,o,t} = \alpha_0 + \beta(treat_o \times post_t) + \gamma X_{j,t} + \delta Z_{p,t} + \mu_o + \lambda_t + \eta_{pxi} + \varepsilon_{j,o,t} \quad (1)$$

其中, o 代表职业, j 代表企业, p 代表省份, i 代表行业, t 代表月份。被解释变量 $Lnlab_{j,o,t}$ 为劳动力需求,以企业 j 在 t 月份对职业 o 的劳动力需求数量取对数衡量。解释变量 $treat_o \times post_t$ 为生成式人工智能冲击, $treat_o$ 为职业 o 的生成式人工智能暴露度, $post_t$ 为ChatGPT发布时间虚拟变量。估计系数 β 反映生成式人工智能冲击对劳动力需求的净效应,是本文关注的核心系数。此外, $X_{j,t}$ 为可能

^①对一级职业分布进行1000次有放回抽样后,原始样本职业占比标准差为5.24%,落在95%置信区间[5.01%,5.55%]内,表明样本在职业结构维度上具有较好的代表性。

影响企业招聘需求的微观企业特征前定变量,包括企业规模、企业年龄; $Z_{p,i}$ 为省份层面的相关经济特征变量。鉴于本文使用职业层面的混合截面数据,难以对同一企业进行完整的跨期追踪,故引入高维固定效应以缓解遗漏变量偏误。其中, μ_o 表示职业固定效应, λ_t 表示月份固定效应, $\eta_{p \times i}$ 表示省份 $\times$ 行业交互固定效应。 $\varepsilon_{j,o,i}$ 为随机误差项,本文在回归估计时将标准误聚类至职业层面。

(三) 变量选取

1.被解释变量:劳动力需求($Lnlab$),以企业单条招聘广告中标注的招聘人数取对数来测度,反映企业在特定时期对某一职业相关岗位的计划用工规模。考虑到生成式人工智能对劳动的影响通常先作用于岗位内部任务层面(吕健和陆宣,2023),而本文实证部分观测的是职业相关岗位,因此,需依据岗位主导任务属性将任务分类映射为职业分类,并据此开展分组检验。遵循Autor等(2003)的任务模型框架,并借鉴陈琳等(2024)、曲英姿和范莎(2025)的分类思路,本文将样本职业划分为常规体力、常规认知、非常规体力、非常规认知四类,并进一步将非常规认知职业细分为信息分析与处理型和人际互动与复杂决策型,如表1所示。

表 1 基于任务的职业分类标准与对应岗位示例

大类	子类	主要任务	对应岗位示例
常规体力	信息分析与处理型 人际互动与复杂决策型	流程固定、规则明确、重复性的体力操作	普工、仓储分拣、基础装配
常规认知		标准化文本处理、信息整理、规则执行、基础分析	文秘、行政支持、基础客服、初级数据整理
非常规体力		非标准化体力操作、现场应变	医疗护理、保护服务、现场维修与应急处理
非常规认知		信息整合、结构化分析、模式识别 情境判断、人际沟通、复杂协调、综合决策	行业研究、投资分析、咨询资料分析 高级管理、复杂商务谈判、心理咨询、艺术创作

2.解释变量:生成式人工智能冲击($treat \times post$),反映不同职业受到的潜在冲击强度,而非职业整体已被替代的程度。其中, $post$ 为时间虚拟变量。考虑到ChatGPT于2022年11月30日发布,之后生成式人工智能进入快速扩散阶段,本文以2022年12月为时间节点, $post$ 在2022年12月之前赋值为0,在2022年12月及之后赋值为1。 $treat$ 为职业层面的生成式人工智能暴露度,用以刻画职业任务与生成式人工智能能力之间的匹配程度;生成式人工智能暴露度越高,则该职业受到技术影响的可能性越大。考虑到不同国家的相同职业在任务内容和技能结构上具有较强可比性,本文参考张咏雪(2024)的做法,使用Felten等(2021,2023)构建的美国职业大语言模型暴露度指标,将其映射至中国职业体系,得出中国职业层面的人工智能暴露度连续型分布。首先,本文提取中国在线招聘广告中的职业名称,利用中国天然产物数据库(CNPD)提供的O*NET中文职业翻译表,将美国O*NET职业名称转换为中文,从而构建中美职业名称的初始对照集合。接着,本文采用基于Sentence-BERT框架的中文预训练语义模型,对中国职业名称与翻译后的O*NET职业名称进行向量化编码,并根据余弦相似度完成自动匹配。最后,对于余弦相似度低于0.8或存在潜在歧义的职业样本,本文进一步结合招聘广告中的职位描述及O*NET数据库中的职业任务说明进行人工核对和修正,共涉及389个职业,以提高在任务内容层面匹配不同国家职业的合理性。此外,考虑到美国职业暴露度指标难以完全反映中国劳动力市场的技术应用特征,本文基于中国招聘广告文本构建替代性的“生成式人工智能关键词指数”,并将其用于稳健性检验。

3.控制变量。结合已有研究,本文选取两类控制变量:一是企业层面的控制变量,包括企业

规模、企业年龄、企业年龄的平方；二是地区层面的控制变量，包括该地区的工业增加值、居民消费价格指数、进出口总额。

表2报告了主要变量的描述性统计结果，各变量均具备一定离散性。表3报告了不同职业类型的生成式人工智能暴露度分布：认知职业的平均暴露度整体高于体力职业；常规认知职业和信息分析与处理型非常规认知职业的平均暴露度最高，而常规体力职业的平均暴露度最低。这表明，本文所构建的暴露度指标能够有效刻画不同职业任务与生成式人工智能能力间的契合程度，为后续的实证分析奠定了变量测度基础。

表 2 主要变量描述性统计结果

变量名称	变量符号	变量定义	样本量	均值	标准差	最小值	最大值
劳动力需求	<i>Lnlab</i>	招聘人数(人)取对数	7339	1.003	1.306	0.000	4.605
生成式人工智能冲击	<i>treat×post</i>	ChatGPT发布时间与职业暴露度的交乘项	7339	0.397	0.840	-1.822	1.926
时间虚拟变量	<i>post</i>	2022年12月之前赋值为0；2022年12月及之后赋值为1	7339	0.810	0.393	0	1
职业暴露度连续变量	<i>treat</i>	各职业生成式人工智能暴露度	7339	0.491	0.905	-1.822	1.926
企业规模	<i>size</i>	20人以下赋值为1；20~99人赋值为2；100~299人赋值为3；300~499人赋值为4；500~999人赋值为5；1000~9999人赋值为6；10000人及以上赋值为7	7339	3.553	1.866	1	7
企业年龄	<i>age</i>	企业发布该招聘广告的时间减去企业成立时间(年)	7339	8.238	7.731	0.044	31.833
企业年龄平方	<i>age_2</i>	企业年龄的平方	7339	127.627	203.913	0.002	1013.332
工业增加值	<i>iav</i>	各省份工业增加值的增速(%)	7339	4.925	6.831	-13.900	39.603
居民消费价格指数	<i>cpi</i>	各省份居民消费价格分类指数	7339	100.496	0.976	98.900	102.900
出口总额	<i>exp</i>	各省份出口总额取对数	7339	15.930	1.206	12.823	17.815
进口总额	<i>imp</i>	各省份进口总额取对数	7339	15.661	1.197	12.492	17.178

表 3 不同职业类型的生成式人工智能暴露度分布

职业类型	样本量	平均值	标准差
常规体力	1515	-0.150	0.670
非常规体力	3061	0.085	0.814
常规认知	1086	1.345	0.607
非常规认知	1677	1.258	0.539
信息分析与处理型	996	1.425	0.485
人际互动与复杂决策型	681	1.014	0.512

四、实证结果与分析

(一) 基准回归

表4报告了基准回归结果，各列均控制职业固定效应、月份固定效应、省份×行业交互固定效应。第(1)–(3)列为未加入任何控制变量的估计结果，第(4)–(6)列为加入控制变量后的估计结果。结果表明，*treat×post*的估计系数均显著为负，说明生成式人工智能冲击下的企业招聘需求显著降低。根据第(4)–(6)列的估计系数可知，全样本招聘需求降低13%；常规职业招聘需求的下降幅度为20.31%，显著高于非常规职业的6.62%，表明与常规职业相比，非常规职业的招聘需求虽然也会降低，但降幅更小，提示技术冲击可能体现为职业内部任务类型的分化调整。

表 4 基准回归结果

变量	(1)	(2)	(3)	(4)	(5)	(6)
	全样本	常规	非常规	全样本	常规	非常规
<i>treat</i> × <i>post</i>	−0.1401*** (0.0246)	−0.2214*** (0.0262)	−0.0705* (0.0338)	−0.1300*** (0.0251)	−0.2031*** (0.0299)	−0.0662* (0.0312)
<i>size</i>				0.0679*** (0.0179)	0.0795*** (0.0189)	0.0576** (0.0217)
<i>age</i>				−0.0587*** (0.0106)	−0.0565*** (0.0167)	−0.0604*** (0.0099)
<i>age_2</i>				0.0013*** (0.0002)	0.0012** (0.0005)	0.0014*** (0.0002)
<i>iav</i>				−0.0052** (0.0017)	−0.0043 (0.0029)	−0.0040 (0.0031)
<i>cpi</i>				0.0191 (0.0286)	0.0422 (0.0632)	0.0248 (0.0415)
<i>exp</i>				0.1608* (0.0871)	0.4785*** (0.0971)	0.0480 (0.1025)
<i>imp</i>				0.0372 (0.2532)	0.4417 (0.3726)	−0.1475 (0.2127)
职业固定效应	控制	控制	控制	控制	控制	控制
月份固定效应	控制	控制	控制	控制	控制	控制
省份×行业固定效应	控制	控制	控制	控制	控制	控制
样本量	7339	2601	4738	7339	2601	4738
<i>R</i> ²	0.228	0.292	0.221	0.248	0.312	0.241
系数差异 <i>P</i> 值		0.0004***			0.0010***	

注：***、**和*分别表示在1%、5%和10%的水平下显著；括号内数值为职业层面聚类的稳健标准误。下同。

表5进一步从任务属性维度检验生成式人工智能对不同类型职业的影响。结果显示，*treat*×*post*的估计系数在常规认知和非常规认知职业样本中均显著为负，而在常规体力和非常规体力职业样本中不显著，表明企业招聘需求的调整主要集中于认知职业。对于非常规认知职业，*treat*×*post*的估计系数在信息分析与处理型职业样本中显著为负，而在人际互动与复杂决策型职业样本中不显著。这表明，生成式人工智能对非常规认知职业的影响并非整体性替代，而是表现为内部任务结构的再分化，存在显著的异质性：以信息整合、结构化分析、模式识别为主的职业更易受到替代性冲击，而以人际互动、复杂协调、综合决策为主的职业则更具弹性。由此，假设1得到验证。

表 5 分类回归结果

变量	(1)	(2)	(3)	(4)	(5)	(6)
	常规体力	非常规体力	常规认知	非常规认知	信息分析与处理型	人际互动与复杂决策型
<i>treat</i> × <i>post</i>	−0.1289 (0.0824)	0.0628 (0.0525)	−0.2495*** (0.0485)	−0.1772* (0.0912)	−0.2477** (0.0792)	−0.0096 (0.1208)
控制变量	控制	控制	控制	控制	控制	控制
职业固定效应	控制	控制	控制	控制	控制	控制
月份固定效应	控制	控制	控制	控制	控制	控制
省份×行业固定效应	控制	控制	控制	控制	控制	控制
样本量	1501	3045	1045	1632	938	625
<i>R</i> ²	0.274	0.244	0.311	0.301	0.341	0.383
系数差异 <i>P</i> 值					0.0070***	

注：表5报告的是加入高维固定效应回归后的估计结果，故样本量与表3存在少量差异。

(二) 稳健性检验^①

1. 平行趋势检验。利用双重差分模型进行政策效应估计时,最重要的假设是处理组和控制组具有共同的事前平行趋势。对此,本文采用事件研究法进行检验。结果显示,2022年12月之前,估计系数均不显著,满足平行趋势假设。结合基准回归结果可以得出,以ChatGPT为代表的生成式人工智能显著降低了企业劳动力需求,并推动其发生结构性分化。

2. 安慰剂检验。为排除同期不可观测的偶然因素对结论的干扰,证实生成式人工智能与企业劳动力需求的因果关系,本文采用随机置换方法进行安慰剂检验。对 $treat \times post$ 进行1000次随机置换,可以发现,估计系数主要集中在零值附近且近似服从正态分布,表明基准回归结果具备一定的稳健性。

3. 其他稳健性检验。为排除其他因素干扰,本文从以下四方面开展进一步检验:(1)控制同期其他代表性大模型(包括文心一言、DALL-E 2、Midjourney大模型)的发布时间,以排除其他技术事件对企业招聘决策的影响。(2)替换职业暴露度。为避免核心结论过度依赖单一测度方式,本文使用Eloundou等(2024)构建的大语言模型暴露度指标来作为替代,该指标借助ChatGPT模型,依据职业任务与生成式人工智能能力之间的匹配程度对暴露度进行评分。此外,考虑到职业结构和任务内容差异可能会削弱美国职业暴露度指标在中国劳动力市场中的适用性,本文基于中国企业招聘文本构建本土化替代指标:从招聘职位描述中提取生成式人工智能较易完成的任务关键词,如文本生成、整理、总结、翻译、文档撰写等,据此构建职业层面的“生成式人工智能关键词指数”。(3)将时间单位由月调整为周,以提高识别的时间精度。(4)剔除百度指数处于峰值阶段的极端月份样本。结果显示,基准回归结论保持稳健。

(三) 作用机制检验

基准回归证实,以ChatGPT为代表的生成式人工智能显著降低了企业的劳动力需求。基于此,结合前文的理论分析,本文对生成式人工智能影响企业劳动力需求的机制进行检验。

1. 任务效率提升机制。本文借鉴王鹏和陈蝶欣(2025)使用Skip-gram神经网络架构扩充关键词的方法,以招聘岗位描述中的可替代任务词占比作为代理变量,刻画生成式人工智能接管可替代任务后,岗位内部任务配置的调整程度。表6第(1)–(3)列显示, $treat \times post$ 的估计系数在常规职业样本中显著为负,而在非常规职业样本中不显著。这表明,在生成式人工智能的冲击下,常规职业岗位描述中可替代任务词占比明显下降,此类任务被技术承接,由此压缩了常规职业的新增招聘需求。相比之下,任务效率提升效应并未显著作用于非常规职业。由此可见,生成式人工智能通过任务效率提升效应,推动企业劳动力需求在常规职业与非常规职业之间发生非对称的结构分化,假设2得到验证。

2. 新任务创造机制。本文依据《中华人民共和国职业分类大典(2022年版)》中的新职业目录构建企业层面的新任务创造指标,招聘岗位属于新职业类别时赋值为1,否则赋值为0。表6第(4)–(6)列显示, $treat \times post$ 的估计系数在非常规职业样本中显著为正,而在常规职业样本中不显著。这表明,生成式人工智能主要提高企业在非常规领域中创造新任务及相应新职业的概率,并未普遍扩大各类岗位的招聘需求。究其原因,常规任务更易被直接嵌入既有流程,而生成式人工智能应用所衍生出的系统部署、模型调优、场景整合、组织协调等新增任务,则更接近非常规领域,从而更容易催生新职业。由此可见,生成式人工智能通过新任务创造效应,改变新增岗位的类型分布,强化了常规职业与非常规职业之间的需求结构分化,假设3得到验证。

^①限于篇幅,稳健性检验结果未列示,备索。

表 6 机制检验结果

变量	任务效率提升机制			新任务创造机制		
	(1)	(2)	(3)	(4)	(5)	(6)
	全样本	常规职业	非常规职业	全样本	常规职业	非常规职业
<i>treat</i> × <i>post</i>	−0.0011 (0.0009)	−0.0031** (0.0014)	0.0007 (0.0005)	0.0141* (0.0077)	0.0075 (0.0093)	0.0214*** (0.0067)
控制变量	控制	控制	控制	控制	控制	控制
职业固定效应	控制	控制	控制	控制	控制	控制
月份固定效应	控制	控制	控制	控制	控制	控制
省份×行业固定效应	控制	控制	控制	控制	控制	控制
样本量	7339	2601	4738	7339	2601	4738
<i>R</i> ²	0.131	0.130	0.183	0.106	0.155	0.123
系数差异 <i>P</i> 值		0.0071***			0.0837*	

(四) 异质性分析

1. 岗位层面。依据招聘岗位对工作经验的要求, 本文将要求一年以下工作经验 (包括无经验要求) 的岗位划分为无经验要求岗位 (*exp*=0), 将要求一年及以上工作经验的岗位划分为有经验要求岗位 (*exp*=1)。表7第(1)–(2)列显示, 无论对于常规职业样本还是非常规职业样本, *treat*×*post*的估计系数均显著为负, *treat*×*post*×*exp*的估计系数均显著为正。这表明, 相较于有经验岗位, 生成式人工智能对无经验要求岗位的冲击更强, 技术替代更偏向这类程序化程度较高、技能要求较低的岗位, 使得其招聘需求被显著压缩。

表 7 岗位与企业层面异质性检验结果

变量	(1)	(2)	(3)	(4)
	岗位层面		企业层面	
	常规职业	非常规职业	常规职业	非常规职业
<i>treat</i> × <i>post</i> × <i>exp</i>	0.2858*** (0.0385)	0.0785* (0.0412)		
<i>treat</i> × <i>post</i> × <i>soe</i>			0.2472** (0.0989)	−0.0033 (0.1264)
<i>treat</i> × <i>post</i>	−0.2538*** (0.0440)	−0.0501** (0.0227)	−0.2126*** (0.0297)	−0.0658 (0.0391)
<i>exp</i>	−1.0110*** (0.1417)	−0.8779*** (0.1596)		
<i>soe</i>			−0.0005 (0.1475)	0.1881*** (0.0581)
控制变量	控制	控制	控制	控制
职业固定效应	控制	控制	控制	控制
月份固定效应	控制	控制	控制	控制
省份×行业固定效应	控制	控制	控制	控制
样本量	2601	4738	2601	4738
<i>R</i> ²	0.386	0.325	0.313	0.242

2. 企业层面。既有研究指出, 不同所有制企业在用工制度、成本约束、组织调整机制方面存在显著差异(陈琳等, 2024)。为探讨企业所有权是否会影响企业劳动力需求的调整程度, 本文引入国有企业虚拟变量 (*soe*), 考察民营企业 (*soe*=0) 和国有企业 (*soe*=1)。表7第(3)–(4)列显

示,在常规职业样本中, $treat \times post$ 的估计系数显著为负, $post \times treat \times soe$ 的估计系数显著为正,表明生成式人工智能对常规职业招聘需求的压缩主要发生在民营企业中。相比之下,在非常规职业样本中,无论基准项还是交乘项均未呈现显著差异,表明企业所有权差异对非常规职业的影响较为有限。总体上,生成式人工智能主要降低民营企业的常规职业招聘需求,在一定程度上反映出,相较于国有企业,民营企业在成本约束下的用工调整更为迅速。

3.行业层面。由于不同行业在技术构成和职业可替代风险上存在差异,本文将行业划分为劳动密集型($ind=0$)和技术密集型($ind=1$)两类。表8第(1)–(2)列显示,无论对于常规职业样本还是非常规职业样本, $treat \times post$ 的估计系数均显著为负, $treat \times post \times ind$ 的估计系数均显著为正,表明生成式人工智能对劳动密集型行业招聘需求的压缩幅度更大。究其原因,劳动密集型行业中存在大量程序化、可替代程度较高的任务,生成式人工智能更容易替代相应职业岗位;而技术密集型行业本身数字化程度较高,技术与岗位之间更多体现为互补关系,从而缓冲了技术冲击对企业招聘需求的负向影响。

表 8 行业与产业层面异质性检验结果

变量	(1)	(2)	(3)	(4)
	行业层面		产业层面	
	常规职业	非常规职业	常规职业	非常规职业
$treat \times post \times ind$	0.3454* (0.1666)	0.2962** (0.0959)		
$treat \times post \times sec$			0.2269*** (0.0388)	0.1004** (0.0341)
$treat \times post$	-0.2204*** (0.0324)	-0.1591*** (0.0442)	-0.2367*** (0.0284)	-0.0801*** (0.0251)
sec			-0.0560 (0.0434)	0.0086 (0.0780)
控制变量	控制	控制	控制	控制
职业固定效应	控制	控制	控制	控制
月份固定效应	控制	控制	控制	控制
省份×行业固定效应	控制	控制	控制	控制
样本量	2601	4738	2601	4738
R^2	0.314	0.245	0.315	0.242

注：行业异质性为时间不变特征，已被行业固定效应吸收，因此仅报告其与生成式人工智能冲击交乘项的估计结果。

4.产业层面。传统产业和战略性新兴产业在技术水平、岗位结构上存在明显差异。本文借鉴张建鹏和陈诗一(2021)的划分标准,将生物产业、新材料、高端装备制造、信息技术产业、新能源产业界定为战略性新兴产业($sec=1$),其他产业则界定为传统产业($sec=0$)。表8第(3)–(4)列显示,无论对于常规职业样本还是非常规职业样本, $treat \times post$ 的估计系数均显著为负, $treat \times post \times sec$ 的估计系数均显著为正,表明生成式人工智能对传统产业招聘需求的压缩幅度更大。究其原因,在战略性新兴产业中,技术赋能并与岗位互补的作用更强;而传统产业的常规任务占比较高,易受到技术替代性冲击。

五、进一步分析

为进一步考察生成式人工智能对劳动力市场配置结果的影响,本文从岗位工资和职业竞争强度两个维度展开分析。

(一) 岗位工资

工资作为劳动力市场的核心价格变量,不仅反映企业需求调整,也体现劳动者对技术冲击的预期变化(Acemoglu和Autor, 2011)。当生成式人工智能嵌入生产流程后,不同岗位的边际产出和技术互补性发生变化,进而对工资水平产生差异化影响(黄旭等, 2025)。本文利用企业招聘广告中的薪资信息构建岗位工资指标,检验生成式人工智能对岗位工资的影响。表9第(1)–(3)列显示,生成式人工智能对企业招聘岗位工资产生了显著的正向影响。在全样本回归中, $treat \times post$ 的估计系数显著为正,表明在生成式人工智能冲击下,岗位工资水平显著上升。这一正向影响在常规职业和非常规职业样本中均存在,但非常规职业对应的估计系数明显高于常规职业,表明在岗位工资水平整体上升的同时,非常规职业的工资提升更显著。究其原因,非常规职业包含更多难以被技术直接替代且能够通过技术增强而提高产出的任务成分,尤其是依赖复杂判断、人际互动、综合决策的任务,更可能因生成式人工智能的辅助而提高边际生产率,从而增强企业对相关岗位的支付意愿。相比之下,常规职业虽然也受益于技术赋能,但其任务结构中可替代的部分较多,工资提升幅度相对有限。因此,生成式人工智能在差异化压缩招聘需求的同时,也借助技能偏向和生产率提升,强化了劳动力市场内部的结构分化。

表 9 进一步分析回归结果

变量	岗位工资			职业竞争强度		
	(1)	(2)	(3)	(4)	(5)	(6)
	全样本	常规职业	非常规职业	全样本	常规职业	非常规职业
$treat \times post$	0.0569*** (0.0108)	0.0334* (0.0165)	0.0790*** (0.0149)	6.5930*** (1.2454)	5.5018*** (1.7404)	6.3971*** (2.0561)
控制变量	控制	控制	控制	控制	控制	控制
职业固定效应	控制	控制	控制	控制	控制	控制
月份固定效应	控制	控制	控制	控制	控制	控制
省份×行业固定效应	控制	控制	控制	控制	控制	控制
样本量	7339	2601	4738	7339	2601	4738
R^2	0.320	0.225	0.357	0.108	0.177	0.116
系数差异P值		0.0001***			0.0961*	

(二) 职业竞争强度

在劳动力市场中,工资作为重要的价格信号,必然引导劳动者在不同职业之间进行重新配置,从而影响不同职业的竞争强度。对此,本文使用求职者数量与岗位需求量之比构建职业竞争强度指标。表9第(4)–(6)列显示,生成式人工智能对企业招聘岗位的竞争强度产生了显著的正向影响。在全样本中, $treat \times post$ 的估计系数显著为正,表明在生成式人工智能冲击下,职业竞争强度显著上升。这一正向影响在常规职业和非常规职业样本中均存在,但非常规职业对应的估计系数高于常规职业,表明生成式人工智能不仅压缩企业招聘规模、提升工资水平,也通过影响岗位吸引力和劳动者预期,使得非常规职业竞争更激烈。究其原因,对于常规职业,因程序化任务被替代,岗位需求收缩,岗位的竞争强度随之上升;但常规职业总量收缩,会增强劳动者向非常规职业转移的意愿,从而降低常规职业竞争强度。相比之下,非常规职业招聘需求收缩幅度较小,且工资提升更明显、技术互补性更强,因此对劳动者吸引力更大。在常规职业岗位需求收缩和非常规职业工资提升的共同作用下,劳动力向非常规职业集中,而企业对相关岗位的新增劳动力需求却并未同步扩大,最终使非常规职业的竞争更为激烈。由此可见,生成式人工智能在重塑招聘需求结构的同时,也强化了劳动力市场内部的竞争分化。

六、结论与政策启示

生成式人工智能的快速发展正在重塑职业任务结构和企业用工模式。基于2022—2023年在线招聘平台月度数据,本文以ChatGPT发布为准自然实验,结合职业层面大语言模型暴露度构建广义双重差分模型,系统考察了生成式人工智能对企业劳动力需求的短期影响及其作用机制。研究发现,生成式人工智能显著引发了企业招聘需求的结构性调整:常规职业的招聘需求收缩幅度明显大于非常规职业,且技术冲击主要集中于程序化程度较高的认知职业。这一结论在多项稳健性检验后依然成立。此外,生成式人工智能的影响不仅体现为常规职业与非常规职业的分化,还深入到非常规认知职业内部,使信息分析与处理型非常规认知职业面临更强的替代压力,而人际互动与复杂决策型职业则更具弹性。机制检验表明,企业一方面通过任务效率提升压缩常规职业相关岗位需求,另一方面通过新任务创造催生新的非常规职业,两条路径共同强化了招聘需求的结构性分化。异质性分析表明,技术冲击在无经验要求岗位、民营企业、劳动密集型行业 and 传统产业中更显著。进一步分析发现,在常规职业招聘需求下降更快的同时,非常规职业的工资提升幅度更大、竞争更激烈。这意味着,生成式人工智能对于常规职业更多体现为替代效应,对于非常规职业则更多体现为技能互补、生产率提升,以及因常规职业需求收缩带来劳动力再配置所造成的竞争加剧。

基于上述研究结论,本文的政策启示如下:第一,推动企业围绕岗位内容开展任务拆分、流程再造和岗位重构,将标准化环节交由技术处理,将劳动者更多配置到判断、沟通、协同、审核等环节;同时,将技术应用和员工转岗相结合,避免简单按职业类别划分扶持对象或将任务替代直接转化为劳动力退出。第二,完善面向在岗劳动者的转岗培训和技能更新机制。对于常规认知岗位的劳动者,应重点加强其数字工具使用、人机协同、岗位转换等培训;对于非常规认知岗位的劳动者,尤其是以信息分析与处理为主要任务的群体,应重点提升其复杂决策、人际互动、结果审核等能力,推动政策支持由学历导向转向任务能力导向。第三,建立更细化的职业风险监测与预警体系。公共就业服务和职业信息平台应从职业层面下沉到任务层面,定期发布不同职业中可替代任务、互补性任务和新生任务的变化信息,帮助劳动者及时识别本岗位中真正面临技术冲击的任务,减少被动退出和结构性错配。

主要参考文献:

- [1] 陈琳,高悦蓬,余林徽. 人工智能如何改变企业对劳动力的需求?——来自招聘平台大数据的分析[J]. *管理世界*,2024,(6).
- [2] 黄旭,闫雪凌,朱启飏. 生成式人工智能技术应用与劳动收入差距[J]. *经济学动态*,2025,(5).
- [3] 吕健,陆宣. ChatGPT为劳动者带来的机遇、挑战及其应对[J]. *当代经济管理*,2023,(12).
- [4] 马双,肖翰,李丁,等. 最低工资与异质性人力资本需求:基于招聘网站数据的研究[J]. *世界经济*,2023,(12).
- [5] 马晔风,陈楠,崔雪彬. 生成式人工智能技术如何影响专业型工作?——来自软件工程行业的早期证据[J]. *劳动经济研究*,2024,(3).
- [6] 曲英姿,范莎. 机器人兴起与中国劳动力市场技能需求结构——来自中国招聘网站的证据[J]. *华东师范大学学报(教育科学版)*,2025,(4).
- [7] 汪红驹,丁少斌. 生成式人工智能的经济影响研究进展[J]. *经济学动态*,2025,(8).
- [8] 王鹏,陈蝶欣. 人工智能技术应用与企业韧性——来自机器学习构建AI词典的经验证据[J]. *经济学动态*,2025,(9).
- [9] 张丹丹,于航,李力行,等. 中国人工智能技术暴露度的测算及其对劳动需求的影响——基于大语言模型的新证据[J]. *管理世界*,2025,(7).
- [10] 张建鹏,陈诗一. 金融发展、环境规制与经济绿色转型[J]. *财经研究*,2021,(11).
- [11] 张咏雪. 从自动化技术到生成式人工智能——技术对劳动者影响的技能异质性研究[J]. *社会学研究*,2024,(4).
- [12] 张展培,梁洁莹,刘小勇. 生成式人工智能、就业变动与收入不平等[J]. *南方经济*,2024,(8).

- [13] Acemoglu D, Autor D, Johnson S. Building pro-worker artificial intelligence[R]. National Bureau of Economic Research 34854, 2026.
- [14] Acemoglu D, Autor D. Skills, tasks and technologies: Implications for employment and earnings [J]. *Handbook of Labor Economics*, 2011, 4: 1043–1171.
- [15] Acemoglu D, Restrepo P. Automation and new tasks: How technology displaces and reinstates labor [J]. *Journal of Economic Perspectives*, 2019, 33(2): 3–30.
- [16] Acemoglu D, Restrepo P. Low-skill and high-skill automation [J]. *Journal of Human Capital*, 2018, 12(2): 204–232.
- [17] Acemoglu D, Restrepo P. A task-based approach to inequality [J]. *Oxford Open Economics*, 2024, 3(S1): i906–i929.
- [18] Autor D H, Dorn D. The growth of low-skill service jobs and the polarization of the US labor market [J]. *American Economic Review*, 2013, 103(5): 1553–1597.
- [19] Autor D H, Levy F, Murnane R J. The skill content of recent technological change: An empirical exploration [J]. *The Quarterly Journal of Economics*, 2003, 118(4): 1279–1333.
- [20] Brynjolfsson E, Li D, Raymond L R. Generative AI at work [J]. *The Quarterly Journal of Economics*, 2025, 140(2): 889–942.
- [21] Chen Q, Ge J F, Xie H Q, et al. Large language models at work in China’s labor market [J]. *China Economic Review*, 2025, 92: 102413.
- [22] Deming D J. The growing importance of social skills in the labor market [J]. *The Quarterly Journal of Economics*, 2017, 132(4): 1593–1640.
- [23] Demirci O, Hannane J, Zhu X R. Who is AI replacing? The impact of generative AI on online freelancing platforms [J]. *Management Science*, 2025, 71(10): 8097–8108.
- [24] Eloundou T, Manning S, Mishkin P, et al. GPTs are GPTs: Labor market impact potential of LLMs [J]. *Science*, 2024, 384(6702): 1306–1308.
- [25] Fang X M, Tao L F, Li Z X. Closer to language than steam: AI as the cognitive engine of a new productivity revolution[R]. arXiv preprint arXiv: 2506.10281, 2025.
- [26] Felten E, Raj M, Seamans R. Occupational, industry, and geographic exposure to artificial intelligence: A novel dataset and its potential uses [J]. *Strategic Management Journal*, 2021, 42(12): 2195–2217.
- [27] Felten E, Raj M, Seamans R. How will language modelers like ChatGPT affect occupations and industries?[R]. arXiv preprint arXiv: 2303.01157, 2023.
- [28] Goller D, Gschwendt C, Wolter S C. This time it’s different – Generative artificial intelligence and occupational choice [J]. *Labour Economics*, 2025, 95: 102746.
- [29] Goos M, Manning A, Salomons A. Explaining job polarization: Routine-biased technological change and offshoring [J]. *American Economic Review*, 2014, 104(8): 2509–2526.
- [30] Graetz G, Michaels G. Robots at work [J]. *The Review of Economics and Statistics*, 2018, 100(5): 753–768.
- [31] Gulati P, Marchetti A, Puranam P, et al. Generative AI adoption and higher order skills[R]. arXiv preprint arXiv: 2503.09212, 2025.
- [32] Hui X, Reshef O, Zhou L F. The short-term effects of generative artificial intelligence on employment: Evidence from an online labor market [J]. *Organization Science*, 2024, 35(6): 1977–1989.
- [33] Jia N, Luo X M, Fang Z, et al. When and how artificial intelligence augments employee creativity [J]. *Academy of Management Journal*, 2024, 67(1): 5–32.
- [34] Kanazawa K, Kawaguchi D, Shigeoka H, et al. AI, skill, and productivity: The case of taxi drivers [J]. *Management Science*, 2026, 72(2): 1376–1388.
- [35] Liu Y, Shen L. Consolidating human-AI collaboration research in organizations: A literature review [J]. *Journal of Computer, Signal, and System Research*, 2025, 2(1): 131–151.
- [36] Marguerit D. Augmenting or automating labor? The effect of AI development on new work, employment, and wages[R]. arXiv preprint arXiv: 2503.19159, 2025.
- [37] Webb M. The impact of artificial intelligence on the labor market[R]. SSRN Electronic Journal, 2019.
- [38] Zarifhonorvar A. Economics of ChatGPT: A labor market view on the occupational impact of artificial intelligence [J]. *Journal of Electronic Business & Digital Economics*, 2024, 3(2): 100–116.

Generative Artificial Intelligence and the Structural Differentiation of Enterprise Labor Demand: A Quasi-natural Experiment Based on the Release of ChatGPT

He Qin, Li Xinyue

(School of Labor Economics, Capital University of Economics and Business, Beijing 100070, China)

Summary: Generative artificial intelligence (AI) is profoundly reshaping the occupational task structure and labor demand allocation of enterprises. Using monthly data from online recruitment platforms in China from 2022 to 2023, this paper treats the release of ChatGPT as a quasi-natural experiment and combines occupation-level large language model exposure to construct a generalized DID model, thereby systematically examining the short-run impact of generative AI on enterprise labor demand and its underlying mechanisms. The results show that generative AI significantly triggers a structural adjustment in the recruitment demand of enterprises, with the contraction in routine occupations being substantially greater than that in non-routine occupations, indicating that technological shocks are first concentrated in cognitive jobs with a higher degree of programmability. Further task-based analysis suggests that this effect is not evenly distributed across all cognitive occupations, but mainly concentrated in routine cognitive occupations and information-processing non-routine cognitive occupations, with a relatively limited impact on non-routine cognitive occupations centered on interpersonal interaction and complex decision-making. Mechanism testing shows that enterprises, on the one hand, compress demand for routine-related positions through task efficiency improvement and, on the other hand, increase the probability of new occupations in non-routine domains through new task creation. The two channels jointly reinforce the structural differentiation of labor demand. Heterogeneity analysis further indicates that the impact is more pronounced in positions without experience requirements, private enterprises, labor-intensive industries, and traditional industries, suggesting that sectors with greater market exposure and higher task replaceability are more vulnerable to generative AI shocks. Further analysis shows that although recruitment demand for routine occupations declines more rapidly, non-routine occupations experience stronger wage premiums and significantly higher competition intensity. This implies that generative AI mainly works through substitution in routine occupations, whereas in non-routine occupations it is more closely associated with skill complementarity, productivity enhancement, and intensified competition. From the perspective of enterprise recruitment, this paper uncovers the micro-level mechanisms through which generative AI reshapes labor demand structures and provides new empirical evidence for understanding employment adjustment and occupational differentiation under technological shocks.

Key words: generative AI; routine occupations; non-routine occupations; labor demand; structural differentiation

(责任编辑: 胡 婧)