

人工智能、任务重构与技术红利的分配

刘东升¹, 王永中^{1,2}

(1. 中国社会科学院大学 全球与区域国别学院, 北京 102488;

2. 中国社会科学院 世界经济与政治研究所, 北京 100732)

摘要:人工智能(AI)是推动全要素生产率增长的重要力量,但其创造的技术红利如何分配还不清晰。文章利用中国 A 股上市公司年报文本与网络招聘平台数据,从任务重构视角考察 AI 影响企业全要素生产率的微观机制及其分配后果。研究发现, AI 通过任务替代与任务拓展双重路径显著提高企业全要素生产率。尽管这两条路径均能促进全要素生产率增长,但其收入分配效应呈现显著差异:任务拓展提高工资水平与劳动收入份额,任务替代则显著降低工资水平与劳动收入份额。从整体上看,任务替代对劳动收入的负向影响大于任务拓展的正向影响,这导致 AI 技术红利对资本影响更大,并带来潜在的分配失衡风险。异质性分析显示,在服务业企业以及位于就业政策导向相对较弱城市的企业中, AI 的生产率提升效应更强,对劳动收入份额的抑制作用也更明显。文章从任务重构视角深化了对 AI 生产率效应及其分配后果的认识,为兼顾技术创新与收入分配公平提供了经验证据。

关键词:人工智能;任务替代;任务拓展;劳动收入份额

中图分类号:F272;F244 **文献标识码:**A **文章编号:**1001-9952(2026)08-0049-15

DOI:10.16538/j.cnki.jfe.20260720.401

一、引言

近年来,人工智能(AI)快速发展,已能够根据简洁的指令生成文本、编写代码、识别图像并开展艺术创作,展现出巨大的生产力增长潜能(Chui 等, 2023; Acemoglu, 2025)。这些突破性进展既重构了生产任务的实现方式,也对要素收入分配产生系统性冲击。在生产端, AI 既可替代部分传统任务,也可拓展新的任务类型(Eloundou 等, 2023; Acemoglu, 2025),推动生产流程优化和利润增长。在分配端, AI 重塑了价值创造与收益分配机制。劳动者借助 AI 能够提高单位时间产出,但由此形成的技术红利如何在劳动与资本之间分配仍存在较大不确定性。

现有理论指出, AI 可借助机器学习实现知识解耦,将原本依赖人类完成的复杂任务解构为可编码、可迁移的标准化模块(Agrawal 等, 2018; 王林辉等, 2023; 刘东升和袁媛, 2026),并通过算法迭代推动任务执行主体由劳动者转向技术系统(Choudhary 等, 2025),形成 AI 的任务替代(Task Substitution)效应。任务替代能够降低任务执行成本并提高生产效率(Acemoglu 和 Restrepo, 2018)。例如,在 AI 辅助诊断中, AI 可快速分析医学影像并识别人眼难以察觉的细节,从而提高诊断效率和准确性(Pieper 和 Gleasure, 2025),这表明部分诊断任务可以由 AI 替代。

收稿日期:2026-02-11

基金项目:中国社会科学院重大交办项目(2024YZDJ020)

作者简介:刘东升(1996—),男,安徽蚌埠人,中国社会科学院大学全球与区域国别学院博士研究生;

王永中(1974—)(通讯作者),男,安徽枞阳人,中国社会科学院大学全球与区域国别学院教授、中国社会科学院世界经济与政治研究所研究员。

与任务替代并存的是 AI 的任务拓展(Task Expansion)效应。Riemer 和 Peter(2024)指出, AI 在模式识别和知识处理方面具有比较优势,但其准确性、可靠性和可解释性仍需劳动者监督与修正。因此, AI 与劳动者之间既存在替代关系,也存在互补关系。当特定任务与 AI 形成互补时,相关岗位和企业的生产率可能快速增长(Choudhary 等, 2025)。以 AI 辅助诊断为例, AI 可以处理基础影像筛查工作,这使得放射科医生能专注于处理复杂病例等工作(Agarwal 等, 2024)。

大量研究已经证实 AI 能够促进生产率增长(Brynjolfsson 和 McAfee, 2014; Acemoglu 和 Restrepo, 2018; 姚加权等, 2024; Choudhary 等, 2025),但技术红利如何在劳动与资本之间分配仍存在争议(Autor 和 Salomons, 2018; 谢宇和索菲娅·阿维拉, 2025)。若 AI 主要通过替代劳动任务提高生产率,则可能压缩就业空间并使更多收益流向资本所有者(Acemoglu 和 Restrepo, 2024; Lei 和 Kim, 2024; 王林辉等, 2024),进而降低劳动收入份额;若 AI 主要通过拓展新任务促进生产率增长,则可能创造新的劳动需求,使劳动者与资本所有者共同受益(Acemoglu, 2025)。另有研究指出,劳动者为适应 AI 而进行技能投资,这有助于提高其议价能力(Korinek 和 Stiglitz, 2021),并对工资和劳动收入份额产生积极影响(卢国军等, 2023; 黄卓等, 2024)。因此,现有研究关于分配效应的分歧,很大程度上源于对 AI 生产率增长路径的不同判断。将增长路径与分配结果纳入统一框架的研究仍较为有限。

尽管现有研究已从多个角度考察 AI 的经济效应,但仍存在以下三方面不足:

第一,任务层面的微观数据仍较少。早期研究多以行业工业机器人渗透率、地区智能化指数等宏观指标衡量 AI 应用程度(孙早和侯玉琳, 2019; 陈东和秦子洋, 2022),难以表明企业异质性,也无法观测企业内部任务结构的变化。近年来,国内学者开始利用上市公司年报等文本数据,通过词频或机器学习方法构建企业层面 AI 应用指标(姚加权等, 2024; 安同良和吴致治, 2025)。这类研究增强了企业层面的识别能力,但受数据限制,多数研究仍难以直接测量岗位任务的具体变化及其属性,只能通过技能结构、就业规模等变量间接推断任务重构效应,微观机制证据仍较少。

第二,对传导机制的识别仍不充分。相关研究多关注 AI 对生产率或劳动收入份额的总体影响,或者仅在理论上区分任务替代与任务拓展,较少利用微观数据直接测量两条作用渠道。例如,Acemoglu(2025)在任务框架下区分了 AI 的自动化替代与新任务拓展效应,但其实证分析主要基于宏观总量数据,尚未从企业和岗位层面对两类路径进行量化;姚加权等(2024)从劳动力技能结构调整的角度解释了 AI 提升企业生产率的机制,但未进一步拆分任务替代与任务拓展的相对作用。

第三,现有研究较少按照生产率增长来源考察分配效应。多数文献关注 AI 对收入分配的总体影响,却较少区分不同生产率增长路径所对应的分配机制。例如, Autor 和 Salomons(2018)基于跨国行业数据区分了自动化与非自动化技术进步的分配效应,发现不同来源的生产率增长对劳动收入份额具有差异化影响,但没有聚焦 AI 场景,也未区分 AI 内部的任务替代和任务拓展路径;吕瑛等(2026)梳理了生成式 AI 影响收入分配的多重渠道,但尚未将生产率增长的具体路径与劳资分配结果进行比较分析。

因此,识别 AI 影响企业全要素生产率的具体路径,并考察不同路径下的劳资分配效应是理解 AI 时代就业与收入分配变化的重要问题。本文重点回答以下问题: AI 如何影响企业全要素生产率?由此形成的技术红利如何在劳资间分配?岗位任务重构在其中发挥什么作用?为回答上述问题,首先,本文利用企业年报文本及网络招聘平台信息,借助机器学习算法构建企业与岗位层面的多项关键指标;其次,本文采用工具变量法,识别 AI 对企业全要素生产率的影响及其作

用机制;最后,本文分析不同任务重构路径的收入分配效应。研究发现,AI能够通过任务替代和任务拓展促进企业全要素生产率增长,但两条路径的收入分配效应方向相反:任务拓展提高工资和劳动收入份额,任务替代则降低工资和劳动收入份额。由于任务替代的负向影响更大,因此,AI技术红利总体上对资本影响更大。

本文的边际贡献主要体现在三个方面:第一,在数据层面,本文结合企业年报与网络招聘平台文本,构建企业AI应用水平以及岗位任务替代度、任务拓展度和薪资水平等跨层级指标,为考察AI的微观经济效应提供了更细致的数据;第二,在机制分析层面,本文直接测量任务替代和任务拓展,并从岗位层面考察AI影响生产率的两条潜在路径,从而拓展了关于AI社会经济后果的研究;第三,在分配效应层面,本文比较不同任务重构路径的收入分配效应,为引导AI向劳动友好型方向发展、完善职业培训和收入分配调节机制提供经验证据。

二、理论分析与研究假说

本文借鉴Acemoglu和Restrepo(2022)、Acemoglu(2025)的任务模型框架,从理论层面分析AI对企业全要素生产率的影响机制及其衍生的收入分配效应。该模型假定,企业通过组合一系列总量为 N 的任务形成产出,总产出为所有任务产出的CES加总函数,具体如下式所示:

$$Y = B(N) \left[\int_0^N y(s)^{\frac{\sigma-1}{\sigma}} ds \right]^{\frac{\sigma}{\sigma-1}} \quad (1)$$

其中, Y 表示企业总产出;参数 $B(N)$ 刻画了任务范围扩大带来的全域系统性生产率提升效应,表明AI创造的新任务能够引入创新的生产方式和技术应用、重构生产流程和优化资源配置,从而推动整体生产率提升(Acemoglu, 2025); σ 表示任务间的替代弹性,其值大于0且 $\sigma < 1$,表明传统任务间以互补性为主,经验值约为0.5(Humlum, 2021; Acemoglu和Restrepo, 2022); $y(s)$ 表示单个任务的生产函数,每个任务由AI资本或人类劳动力排他性完成,如下式所示:

$$y(s) = \begin{cases} A_k \gamma_k(s) k(s) & s \in [0, I] \\ A_L \gamma_L(s) l(s) & s \in (I, N] \end{cases} \quad (2)$$

其中, A_k 、 $\gamma_k(s)$ 、 $k(s)$ 分别表示AI的平均生产率、AI对任务 s 的生产率和AI在任务 s 的投入量; A_L 、 $\gamma_L(s)$ 、 $l(s)$ 分别表示劳动力的平均生产率、劳动力对任务 s 的生产率和劳动力在任务 s 的投入量。该模型假设 $\gamma_L(s)/\gamma_k(s)$ 随 s 递增,即存在阈值 I ,使得 $s \in [0, I]$ 的任务由AI完成, $s \in (I, N]$ 的任务由劳动力完成。

随着AI技术突破与应用扩散,AI在更多任务上获得比较优势,自动化阈值 I 增大,原本由劳动力完成的这类任务转向AI执行,即任务替代效应,这一过程提高了企业整体生产效率;AI技术也会创造新的生产环节和岗位,使任务总量 N 扩大,即任务拓展效应,该过程通过引入创新的生产方式、重构生产流程和创造高附加值岗位,进而推动企业全要素生产率提升(Acemoglu, 2025)。因此,本文提出以下假说:

假说1:人工智能可以通过任务替代、任务拓展双重渠道提高企业全要素生产率。

在竞争性均衡下,工资(w)和资本租金(R)分别等于劳动力和AI资本要素的边际产出。对总产出函数分别关于劳动力投入 $l(s)$ 和资本投入 $k(s)$ 求导,可得任务层面的一阶条件:

$$w = [B(N)A_L\gamma_L(s)]^{\frac{\sigma-1}{\sigma}} l(s)^{-\frac{1}{\sigma}} Y^{\frac{1}{\sigma}} \quad (3)$$

$$R = [B(N)A_k\gamma_k(s)]^{\frac{\sigma-1}{\sigma}} k(s)^{-\frac{1}{\sigma}} Y^{\frac{1}{\sigma}} \quad (4)$$

本文进一步推导劳动市场和资本市场出清条件下的均衡工资与均衡资本租金,如下式所示:

$$w = \left(\frac{Y}{L}\right)^{\frac{1}{\sigma}} [B(N)A_L]^{\frac{\sigma-1}{\sigma}} \left[\int_I^N \gamma_L(s)^{\sigma-1} ds \right]^{\frac{1}{\sigma}} \quad (5)$$

$$R = \left(\frac{Y}{K}\right)^{\frac{1}{\sigma}} [B(N)A_K]^{\frac{\sigma-1}{\sigma}} \left[\int_0^I \gamma_K(s)^{\sigma-1} ds \right]^{\frac{1}{\sigma}} \quad (6)$$

均衡工资和资本租金受到劳动和资本平均生产率、任务分配(N 和 I)等多因素影响。本文主要关注任务分配对收入分配的影响,分别对均衡工资公式(5)和均衡资本租金公式(6)关于任务总量 N 和自动化阈值 I 求导,可分解出任务拓展和任务替代的异质性影响。

本文对公式(5)关于 N 求导,可得任务拓展对工资的影响:

$$\frac{d \ln w}{dN} = \frac{1}{\sigma} \frac{d \ln Y}{dN} + \frac{\sigma-1}{\sigma} \frac{d \ln B(N)}{dN} + \frac{1}{\sigma} \frac{\gamma_L(N)^{\sigma-1}}{\int_I^N \gamma_L(s)^{\sigma-1} ds} \quad (7)$$

公式(7)由三个效应构成。第一,总产出扩张效应:新任务创造扩大了企业生产规模,带动总产出增长,进而提升所有生产要素的边际收益。第二,生产率替代效应:由于任务间以互补性为主($\sigma < 1$),全域生产率 $B(N)$ 的提升会降低现有任务的相对边际价值,对工资产生向下的压力。第三,劳动需求提升效应:由于新任务主要由劳动力完成,这直接增加了对劳动力的边际需求,是任务拓展提升工资的核心机制。尽管存在负向的生产率替代效应,但现阶段经验研究表明,劳动需求提升效应和总产出扩张效应的绝对值之和大于生产率替代效应,因此任务拓展对工资的总效应始终为正(黄浩权等, 2024; 何小钢等, 2026),新任务的创造会显著提升劳动力工资水平。

本文对公式(6)关于 N 求导,可得任务拓展对资本租金的影响:

$$\frac{d \ln R}{dN} = \frac{1}{\sigma} \frac{d \ln Y}{dN} + \frac{\sigma-1}{\sigma} \frac{d \ln B(N)}{dN} \quad (8)$$

对比公式(7)和公式(8)可知,工资的增长幅度会大于资本租金的增长幅度。由于劳动收入份额 $LS = wL/Y$,在劳动力数量 L 和总产出 Y 变化幅度有限的情况下,工资快速增长会推动劳动收入份额上升。因此,新任务带来的技术红利更倾向于向劳动要素倾斜,这有利于提升劳动收入份额。

本文对公式(5)关于 I 求导,可得任务替代对工资的影响:

$$\frac{d \ln w}{dI} = \frac{1}{\sigma} \frac{d \ln Y}{dI} - \frac{1}{\sigma} \frac{\gamma_L(I)^{\sigma-1}}{\int_I^N \gamma_L(s)^{\sigma-1} ds} \quad (9)$$

公式(9)包含两个方向相反的效应。正向生产率效应:AI 替代具有比较优势的任务提升了整体生产效率,促进总产出增长,进而推高工资。负向岗位“挤出效应”:劳动力被替代,从而降低了劳动力的边际产出,降低其工资。当负向岗位“挤出效应”大于正向生产率效应时,AI 的任务替代会导致劳动力工资水平下降。

本文对公式(6)关于 I 求导,可得任务替代对资本租金的影响:

$$\frac{d \ln R}{dI} = \frac{1}{\sigma} \frac{d \ln Y}{dI} + \frac{1}{\sigma} \frac{\gamma_K(I)^{\sigma-1}}{\int_0^I \gamma_K(s)^{\sigma-1} ds} \quad (10)$$

可以发现,公式(10)右边两项均为正,因此任务替代对资本租金的影响始终为正。结合公式(9)可知,任务替代在降低工资的同时提高资本收益,使得技术红利对资本影响更大,从而降低劳动收入份额。

基于上述分析，本文提出以下假设：

假说 2：人工智能通过任务拓展形成的技术红利对劳动要素影响更大，并提高劳动收入份额。

假说 3：人工智能通过任务替代形成的技术红利对资本要素影响更大，并降低劳动收入份额。

三、研究设计

（一）模型设定

为考察企业 AI 应用水平对全要素生产率的影响，本文设定如下基准模型：

$$TFP_{jt} = \alpha_0 + \alpha_1 \ln AI_Shock_{jt} + \alpha_2 Control_{jt} + \mu_i + \gamma_t + \varepsilon_{jt} \quad (11)$$

其中，下标 j 、 t 和 i 分别表示企业、年份和行业；被解释变量 TFP_{jt} 为企业全要素生产率；核心解释变量 $\ln AI_Shock_{jt}$ 表示企业 AI 应用水平； α_1 是核心系数，反映 AI 应用水平对企业全要素生产率的影响； $Control_{jt}$ 是企业层面控制变量； μ_i 、 γ_t 分别是行业和年份固定效应； ε_{jt} 是随机扰动项。

控制变量包括企业规模、资产负债率、资产收益率、营业收入增长率、资本密集度、第一大股东持股比例、管理层持股比例和企业性质等。本文以 2017—2023 年中国 A 股上市公司为研究样本，相关数据来自 CSMAR 数据库。

（二）核心变量和数据说明

1. 被解释变量

本文的被解释变量为企业全要素生产率 (TFP)。现有文献多基于柯布—道格拉斯生产函数，通过残差法测算企业 TFP ，常用方法包括普通最小二乘法 (OLS)、Levinsohn-Petrin (LP) 法和 Olley-Pakes (OP) 法。由于 OLS 法难以克服同时性偏差等内生性问题，本文参考汪佩洁等 (2022)、姚加权等 (2024) 的做法，采用 OP 法估算企业 TFP ：以企业营业收入对数、固定资产净额对数、员工人数对数分别作为企业总产出、资本投入、劳动投入的代理变量，以企业购建固定资产、无形资产和其他长期资产支付现金的对数作为投资变量。

除全要素生产率外，本文还关注技术进步红利在劳动与资本之间的分配。本文参考肖土盛等 (2023)、曾帅等 (2026) 的研究，采用要素成本法近似测算企业劳动收入份额 ($Laborshare$)，以反映企业内部的劳资分配状况。计算公式如下：

$$Laborshare = \frac{\text{支付给职工以及为职工支付的现金}}{\text{营业收入} - \text{营业成本} + \text{支付给职工以及为职工支付的现金} + \text{固定资产折旧}} \quad (12)$$

其中，分母为按要素成本法估算的企业增加值；分子“支付给职工以及为职工支付的现金”为现金流量表项目，包括工资、奖金、社会保险和福利。此外，为考察 AI 对不同劳动群体的影响，本文进一步将劳动收入份额拆分为高管与普通员工两类：高管劳动收入份额以高级管理人员薪酬总额与企业增加值之比衡量；普通员工劳动收入份额以普通员工薪酬总额与企业增加值之比衡量，其中普通员工薪酬总额等于“支付给职工以及为职工支付的现金”减去“高级管理人员薪酬总额”。相关数据均来自 CSMAR 数据库。

2. 核心解释变量

企业 AI 应用水平是本文的核心解释变量。参考现有研究，本文采用两个相互补充的文本词频指标进行测量：一是全文 AI 词频指标 ($\ln AI_Shock$)，本文借鉴姚加权等 (2024) 的方法，从企业年报全文中提取 AI 关键词词频并加 1 取自然对数，用以反映企业 AI 应用广度；二是 MD&A 模块 AI 词频指标 ($\ln AI_MDA$)，本文仅基于年报“管理层讨论与分析”部分统计 AI 关键词词频并加 1 取自然对数，用以表示管理层对 AI 技术的战略关注。

3. 工具变量

为缓解 AI 应用与企业全要素生产率、劳动收入份额之间可能存在的反向因果和遗漏变量等内生性问题,本文以国家级人工智能产业政策冲击构建工具变量。具体而言,本文参考苏治等(2025)的做法,选取国家级“人工智能创新发展试验区”政策作为外生冲击。该政策自 2019 年起由国家层面分批次统筹推进,旨在通过政策引导促进区域 AI 产业发展与技术应用。本文构建了虚拟变量(*Policy*):若企业所在城市当年被列入 AI 创新发展试验区,则该变量取值为 1,否则为 0,并将其作为企业 AI 应用水平的工具变量。

工具变量需要同时满足相关性和外生性条件。就相关性而言,该试验区内企业可获得税收优惠、研发补贴、人才引进和场景开放等多方面的政策扶持,从而降低 AI 技术应用成本并拓展应用场景。苏治等(2025)的实证研究也证实,该政策显著提高了试验区企业的 AI 应用水平,满足工具变量的相关性要求。就外生性而言,该试验区由国家层面统筹确定,其选择主要依据城市产业基础、创新能力和区位条件等宏观因素,而非单个企业的生产率或收入分配状况。因此,该工具变量对企业个体而言具有准自然实验的外生性特征,能够有效排除反向因果与遗漏变量导致的内生性偏误。

(三)任务重构机制

本文关注 AI 通过重塑岗位任务结构影响企业全要素生产率的机制。由于公开数据库无法直接提供岗位任务变化数据,本文采用机器学习方法,选取 2018 年 7 月和 2024 年 7 月两个时间,分别对应国内 AI 产业商业化初期和大模型规模化应用阶段。本文采集智联招聘、前程无忧、58 同城和猎聘等平台发布的岗位信息,剔除无效岗位及核心字段缺失样本后,得到 215 245 条有效观测值,涵盖企业名称、岗位名称、任务内容、任职要求和薪资水平等字段。本文将招聘文本中的岗位任务与 2022 年版《中华人民共和国职业分类大典》(简称《职业大典》)所列标准化任务进行匹配,构建岗位层面的任务替代度和任务拓展度指标。

原始招聘数据包含约 9.75 万个岗位名称,普遍存在“异名同职”现象。例如,“仓管员”“仓储管理员”和“仓储库房管理员”可能对应同一职业。为统一岗位口径,本文以《职业大典》为基准规范岗位名称,具体采用序列匹配算法(*Sequence Matcher ratio*)计算招聘岗位名称与标准职业名称的字符序列相似度,并将岗位归入相似度最高的职业细类。若岗位名称与所有标准职业名称的相似度均低于 60%,则进一步比较招聘任务文本与《职业大典》标准任务文本,完成二次匹配。^①然后,本文对匹配结果进行人工抽样核查与校准。招聘岗位一共被归入《职业大典》的 1020 种职业细类。

在获得标准化任务数据后,本文按如下方法构造指标:设招聘岗位的实际任务集合为 *A*,其所属职业的标准化任务集合为 *B*,则任务替代度表示未在招聘信息中出现的标准任务占全部标准任务的比例,取值范围为 $[0, 1]$,数值越大表示岗位对标准任务的保留程度越低。任务拓展度表示新增非标准任务相对于标准任务总量的比值,数值越大表示岗位新增任务越多。技术上采用“jieba”分词工具分别生成招聘岗位任务集合 *A* 和标准职业任务集合 *B*,并据此计算两项指标。

(四)变量描述性统计

表 1 报告了主要变量的描述性统计。其中,企业层面共有 21 042 个观测样本, *TFP* 均值为 10.6423、标准差为 0.7783。 *lnAI_Shock* 和 *lnAI_MDA* 的均值分别为 1.1147 和 0.8809,标准差分别为 1.2655 和 1.1365,且最小值均为 0,说明企业 AI 应用水平具有较强异质性。岗位层面共有 215 245

^① 本文优先使用岗位名称进行匹配,这是因为岗位名称的信息和噪音比显著高于其他招聘文本字段。

个观测样本，任务替代度和任务拓展度的均值分别为 0.5940 和 1.7134，标准差分别为 0.1789 和 1.1061，表明不同岗位的任务重构程度存在较大差异。

表 1 变量描述性统计

变量符号	变量名称	样本量	均值	标准差	最小值	最大值
<i>TFP</i>	全要素生产率	21 042	10.6423	0.7783	7.3140	16.1128
<i>LS_M</i>	高管劳动收入份额	21 042	0.0058	0.0060	0.0001	0.0349
<i>LS_S</i>	普通员工劳动收入份额	21 042	0.3103	0.1404	0.0616	0.8499
<i>lnAI_Shock</i>	企业 AI 应用水平	21 042	1.1147	1.2655	0	4.7095
<i>lnAI_MDA</i>	企业 AI 战略关注度	21 042	0.8809	1.1365	0	4.3175
<i>Policy</i>	工具变量	21 042	0.3083	0.4618	0	1
<i>lnSize</i>	企业规模	21 042	7.8281	1.2327	5.2364	11.4138
<i>Lev</i>	资产负债率	21 042	0.4403	0.2033	0.0706	0.9273
<i>Roa</i>	资产收益率	21 042	0.0314	0.0694	-0.2942	0.2049
<i>Growth</i>	营业收入增长率	21 042	0.1332	0.3283	-0.5418	1.8015
<i>Capital</i>	资本密集度	21 042	3.1406	4.9640	0.4146	38.4430
<i>Top1</i>	第一大股东持股比例	21 042	0.3236	0.1446	0.0781	0.7053
<i>Mshare</i>	管理层持股比例	21 042	0.1251	0.1827	0	0.6667
<i>Dual</i>	是否两职合一	21 042	0.2826	0.4503	0	1
<i>Soe</i>	企业性质	21 042	0.3415	0.4742	0	1
<i>Sub</i>	任务替代度	215 245	0.5940	0.1789	0.0490	1
<i>Exp</i>	任务拓展度	215 245	1.7134	1.1061	0.0345	5.8957

四、实证结果与分析

(一) 基准回归

表 2 报告了企业 AI 应用水平对全要素生产率的估计结果。在 OLS 和 2SLS 模型中，AI 应用水平均在 1% 统计水平上显著提升企业全要素生产率。列(1)至列(4)为 OLS 估计结果，其中列(1)和列(3)报告了 *lnAI_Shock* 的估计结果，列(2)和列(4)报告了 *lnAI_MDA* 的估计结果。在不同测度指标下，两个 AI 指标系数始终在 1% 水平上显著为正。根据列(3)回归结果，在控制企业特征、行业和年份固定效应后，企业 AI 应用水平每提升 10%，全要素生产率约提高 0.69 个百分点，表明 AI 应用具有较为明显的生产率促进效应。

表 2 人工智能对企业全要素生产率的影响

变量	OLS 模型				2SLS 模型	
	(1)	(2)	(3)	(4)	(5)	(6)
<i>lnAI_Shock</i>	0.0500*** (0.0050)		0.0691*** (0.0045)		0.8867*** (0.0925)	
<i>lnAI_MDA</i>		0.0433*** (0.0054)		0.0609*** (0.0049)		1.0266*** (0.1144)
控制变量			控制	控制	控制	控制
行业固定效应	控制	控制	控制	控制	控制	控制
年份固定效应	控制	控制	控制	控制	控制	控制
<i>Kleibergen-Paap rk Wald F</i> 值					121.7550	104.5120
样本量	21 040	21 040	21 040	21 040	21 042	21 042
调整 <i>R</i> ²	0.3277	0.3263	0.4627	0.4604		

注：括号内为稳健标准误；***、**和*分别表示在 1%、5% 和 10% 的水平下显著；限于篇幅，省略控制变量估计结果，留存备索。下表同。

为缓解潜在内生性问题,列(5)和列(6)以“人工智能创新发展试验区”政策为工具变量进行 2SLS 估计。结果显示,核心解释变量的估计系数仍在 1% 统计水平上显著为正,与 OLS 模型结果方向一致。*Kleibergen-Paap rk Wald F* 统计值均高于 *Stock-Yogo* 检验 10% 水平的临界值,表明不存在弱工具变量问题。

(二)稳健性检验^①

1. 排除策略性披露干扰

本文参考孟庆斌等(2017)、赵璨等(2020)的做法,根据企业年报中 AI 相关表述的位置,将 AI 文本信息区分为“业务经营类表述”和“战略表态类表述”。考虑到年报“未来展望”部分可能包含较多战略性描述,本文剔除该部分文本后重新计算企业 AI 应用水平,得到指标 *lnAI_Shock_OP*。替换核心解释变量后,估计结果与基准回归一致,说明本文的结论是稳健的。

2. 基于 AI 相关资产投入重新测量 AI 应用水平

参考汪前元等(2022)的研究,本文从企业实际投入角度重新衡量 AI 应用程度。本文从资产负债表附注中识别 AI 相关无形资产中的“软件”以及固定资产中的“智能化设备”“数据设备”等项目金额,加总后取自然对数,构造 AI 相关资产指标 *lnAI_Asset*。采用该指标重新估计后,本文的结论不变。

3. 基于 AI 专利重新构造 AI 应用指标

本文还以企业当年申请的 AI 相关专利数量衡量其 AI 应用与创新能力,构造 AI 专利指标 *lnAI_Patent*。替换核心解释变量后,AI 应用对企业全要素生产率的影响方向和显著性均未发生明显变化,表明本文的结论是稳健的。

4. 排除受宏观政策冲击较强行业样本

部分行业可能受到较强的政策调整或外部冲击,从而干扰 AI 应用与劳动收入份额之间的关系。因此,本文剔除房地产、教育和医药制造等行业样本。重新估计后,核心结果仍与基准回归一致。

5. 排除 AI 服务供应商企业样本

为进一步区分 AI 技术应用对企业的影响,本文剔除专业技术服务业、软件和信息技术服务业、商业服务业等 AI 服务供应商企业样本,以避免 AI 产业供给端企业自身特征对估计结果产生干扰(陈琳等,2024)。根据回归结果,剔除相关企业后,本文结论依然成立。

6. 排除部分时期的样本

本文剔除 2020—2022 年样本后重新进行回归。根据回归结果,本文的结论是稳健的。

7. 调整样本区间

考虑到机制分析中岗位层面数据的时间覆盖区间,本文将企业层面样本调整为 2017 年和 2023 年,以保持企业层面与岗位层面研究样本的一致性。结果显示,核心解释变量的估计系数及显著性水平与基准回归基本一致,表明研究结论是稳健的。

(三)机制检验

为检验 AI 是否通过任务重构影响企业全要素生产率,本文考察 AI 应用对岗位任务结构的影响。为缓解反向因果等潜在内生性问题,本文采用工具变量法进行估计。第一阶段回归结果显示, *lnAI_Shock* 和 *lnAI_MDA* 两个核心解释变量对应的 *Kleibergen-Paap rk Wald F* 统计值均高于 *Stock-Yogo* 检验 10% 水平的临界值,说明未发现明显的弱工具变量问题。

^① 限于篇幅,省略稳健性检验结果,留存备索。

表 3 报告了 2SLS 模型的回归结果。在列(1)至列(4)回归模型中,本文控制了企业特征、行业固定效应、年份固定效应以及招聘文本长度,以减弱文本特征对任务指标的影响。根据回归结果,两个 AI 应用指标对任务替代度和拓展度的估计系数均显著为正。以基准指标 $\ln AI_Shock$ 为例,企业 AI 应用指标每提高 10%,任务替代度对应约提高 0.85 个百分点,表明 AI 能够替代部分标准化、重复性任务(Autor, 2015),任务拓展度约提高 0.56 个百分点,说明 AI 应用创造了新的岗位任务。

表 3 人工智能对岗位任务结构的影响(2SLS 模型)

变量	任务替代度		任务拓展度	
	(1)	(2)	(3)	(4)
$\ln AI_Shock$	0.0847*** (0.0057)		0.0561* (0.0304)	
$\ln AI_MDA$		0.0575*** (0.0035)		0.0381* (0.0206)
控制变量	控制	控制	控制	控制
行业固定效应	控制	控制	控制	控制
年份固定效应	控制	控制	控制	控制
Kleibergen-Paap rk Wald F 值	945.3150	2 143.8030	945.3150	2 143.8030
样本量	215 245	215 245	215 245	215 245
R^2	0.2022	0.3325	0.4939	0.4945

上述结果表明, AI 兼具任务替代与任务拓展双重作用,在替代部分传统岗位任务的同时,也显著增加了新的岗位任务,为 AI 通过任务重构路径提升企业全要素生产率提供了关键的中间机制证据,证明了假说 1。

五、基于任务重构的进一步分析

本部分利用招聘岗位微观大数据,考察任务重构与劳动收入之间的关系,随后分析新任务的来源,并讨论行业特征和地方就业政策环境下的异质性。

(一) AI 影响收入分配的传导路径

表 4 报告了任务重构与劳动收入之间的估计结果。在招聘岗位薪资回归中,任务替代度显著降低招聘岗位薪资,任务拓展度则对薪资存在正向提升作用,二者估计系数均在 1% 统计水平上显著,表明 AI 驱动的任务结构变迁对薪资的差异化作用。^①列(1)、列(2)回归结果显示,任务替代度显著降低了招聘岗位薪资,该结果与理论预期一致,表明 AI 依托深度学习、模式识别等技术替代标准化、重复性任务,进而降低了相关岗位的劳动报酬。同时,任务拓展度显著提高了岗位薪资,表明 AI 通过催生新业态、优化业务流程、强化人机协同等路径增加了新任务,提高了岗位薪资,这与 Acemoglu 和 Restrepo(2018)的 AI 任务创造理论一致。

以上结果表明,任务替代的负向效应明显大于任务拓展的正向效应。根据上文结论, AI 应用通过任务替代和任务拓展两种机制提高企业全要素生产率,但这两种机制对收入分配的作用存在显著的不对称性:任务替代在提高生产率的同时会降低劳动报酬,导致劳动收入份额下降;而任务拓展则可能抵消这一负面影响。

考虑到数据分属岗位和企业两个层面,本文先采用均值聚合法将企业和岗位维度的数据加总至企业层面,测算 2018 年、2024 年两期的企业任务替代度与任务拓展度均值,并剔除单期招

① 招聘岗位薪资($\ln Wage$)来源于招聘信息的“薪资区间”模块,以区间中位数的自然对数测量。

聘岗位数不足 5 个的企业样本,以增强数据有效性。^①为缓解内生性问题,本文实证采用长差分模型:被解释变量为 2024 年相对 2018 年企业劳动收入份额的变化值,核心解释变量为两类任务指标的 2018 年基期值,控制变量也选取基期数据。表 4 列(3)至列(6)的结果显示,任务结构变化对高管劳动收入份额无显著影响,但对普通员工存在显著作用:任务替代度降低了普通员工劳动收入份额,任务拓展度提高了普通员工劳动收入份额。可见,任务替代的抑制效应影响较大,AI 导致的任务重构整体上降低了普通员工的劳动收入份额。

表 4 人工智能影响收入分配的传导路径

变量	招聘岗位薪资		劳动收入份额(高管)		劳动收入份额(普通员工)	
	(1)	(2)	(3)	(4)	(5)	(6)
	招聘数据	招聘数据	企业数据	企业数据	企业数据	企业数据
任务替代度	-0.5038*** (0.0070)		0.0002 (0.0011)		-0.0537** (0.0233)	
任务拓展度		0.0589*** (0.0011)		0.0003 (0.0002)		0.0141*** (0.0051)
$\ln AI_Shock$	0.0168*** (0.0011)	0.0189*** (0.0011)	0.0002 (0.0001)	0.0001 (0.0001)	0.0033 (0.0025)	0.0031 (0.0025)
控制变量	控制	控制	控制	控制	控制	控制
行业固定效应	控制	控制	控制	控制	控制	控制
年份固定效应	控制	控制				
职业固定效应	控制	控制				
样本量	215 089	215 089	2 570	2 570	2 570	2 570
调整 R^2	0.3139	0.3055	0.0519	0.0524	0.0970	0.0980

综上所述, AI 的任务替代效应与任务拓展效应均可提升企业全要素生产率,但二者对收入分配的作用存在明显的不对称性。任务拓展小幅抬升普通员工的劳动收入份额,原因在于新增任务仍需劳动力参与,一定程度上提升了劳动者议价能力;任务替代依托自动化替代常规工作,在提升效率的同时降低劳动报酬,技术红利对资本影响较大,这验证了 Autor(2015)关于自动化技术偏向性的结论。上述结论验证了本文的假说 2 和假说 3。

(二)新任务的价值来源

相较于任务替代,任务拓展不仅可能促进生产率增长,还有助于改善收入分配,因而具有重要的研究和政策意义。本文进一步分析新任务的来源,深入探究不同类别新任务的影响差异。本文将新任务的来源归纳为两类:一是新创造任务(*New_Task*),指由 AI 技术直接创造并独立于传统职业边界的全新任务类型,如 AI 算法训练和智能系统运维;二是交叉任务(*Cross_Task*),即本职业向其他职业领域延伸形成的交叉性任务内容,这类任务原先归属于其他职业范畴,因 AI 技术应用而被纳入本职业的任务体系。在技术度量层面,两类新任务的测算方式如下:本文基于《职业大典》的四级分类标准,假设某一岗位的任务集合为 A,其对应职业细类的任务集合为 B,该职业细类所属小类中其他职业细类的任务集合为 D,则交叉任务以“A 与 D 的交集占 B 的比例”衡量;新创造任务则以“任务拓展度减去交叉任务”计算得出。

表 5 报告了 AI 影响不同来源新任务的 2SLS 估计结果。列(1)至列(4)显示, AI 应用对新创造任务和交叉任务均具有显著正向影响,且对交叉任务的促进作用更强。

^① 本文尝试剔除招聘岗位数量低于 10 个的企业样本后进行回归,研究结论不变,限于篇幅,省略这部分图表分析结果,留存备索。

表 5 人工智能与新任务的来源(2SLS 模型)

变量	新创造任务		交叉任务	
	(1)	(2)	(3)	(4)
$\ln AI_Shock$	0.0340*** (0.0078)		0.0484*** (0.0062)	
$\ln AI_MDA$		0.0231*** (0.0052)		0.0329*** (0.0041)
控制变量	控制	控制	控制	控制
行业固定效应	控制	控制	控制	控制
年份固定效应	控制	控制	控制	控制
<i>Kleibergen-Paap rk Wald F</i> 值	945.3150	2 143.8030	945.3150	2 143.8030
样本量	215 245	215 245	215 245	215 245
R^2	0.4941	0.5011	0.4397	0.4625

既然 AI 显著促进了两类新任务增长,那么不同来源的新任务对收入分配的影响是否存在差异?本文进一步考察此问题。表 6 列(1)、列(2)结果表明,新创造任务和交叉任务均在 1% 统计水平上显著提高招聘岗位薪资;列(3)、列(4)结果表明,两类新任务对高管劳动收入份额均无显著影响;列(5)、列(6)结果表明,两类新任务均对普通员工劳动收入份额有显著正向影响。上述结果表明,新任务带来的收入改善作用主要影响普通员工群体,为其创造了新的就业和收入增长机会。

表 6 新任务对收入分配的影响

变量	招聘岗位薪资		劳动收入份额(高管)		劳动收入份额(普通员工)	
	(1)	(2)	(3)	(4)	(5)	(6)
	招聘数据	招聘数据	企业数据	企业数据	企业数据	企业数据
New_Task	0.2017*** (0.0041)		0.0013 (0.0014)		0.0782*** (0.0277)	
$Cross_Task$		0.2658*** (0.0056)		0.0010 (0.0010)		0.0544*** (0.0198)
$\ln AI_Shock$	0.0192*** (0.0011)	0.0189*** (0.0011)	0.0001 (0.0001)	0.0001 (0.0001)	0.0030 (0.0025)	0.0033 (0.0025)
控制变量	控制	控制	控制	控制	控制	控制
行业固定效应	控制	控制	控制	控制	控制	控制
年份固定效应	控制	控制				
职业固定效应	控制	控制				
样本量	215 089	215 089	2 570	2 570	2 570	2 570
调整 R^2	0.3038	0.3030	0.0524	0.0524	0.0982	0.0978

(三)异质性分析

现有研究表明, AI 的经济效应可能因产业结构和制度环境而异。基于美国劳动力市场的研究发现, AI 的替代效应强于创造效应,并可能导致劳动收入下降(Acemoglu 和 Restrepo, 2018; Acemoglu, 2025);中国的初步证据则显示, AI 应用可能导致劳动收入份额上升(黄卓等, 2024; 苏治等, 2025)。这一差异表明,中国的产业结构与就业政策导向可能影响 AI 的生产率和收入分配效应。因此,本文从行业特征和地方就业政策导向两个维度进行异质性分析。

1. 行业异质性

有研究表明, AI 更容易影响标准化程度较高、规则较为明确的认知任务,而此类任务在各行业中并不相同(Felten 等, 2021)。因此,本文分别对制造业和服务业样本进行回归。表 7 报告

了行业分组估计结果。从生产率效应来看, AI 应用均显著提升两类行业企业的全要素生产率, 且服务业企业中的估计系数高于制造业企业, 说明 AI 技术在服务业中的生产率提升效应更为明显。从劳动收入份额来看, AI 影响具有明显的行业异质性与群体差异。对高管群体来说, AI 应用在制造业和服务业中的影响均不显著, 表明 AI 技术冲击尚未显著改变企业管理层收入分配。对普通员工群体来说, AI 的影响则存在显著行业差异: 在制造业中, AI 应用显著提高普通员工劳动收入份额; 在服务业中, AI 应用显著降低普通员工劳动收入份额。该结果表明, 在制造业中, AI 应用可能导致生产效率提升; 在服务业中, 部分标准化、程序化任务更容易被智能技术替代, 因此 AI 应用降低了劳动收入份额。

表 7 行业异质性估计结果

变量	制造业			服务业		
	(1)	(2)	(3)	(4)	(5)	(6)
	全要素生产率	劳动收入份额 (高管)	劳动收入份额 (普通员工)	全要素生产率	劳动收入份额 (高管)	劳动收入份额 (普通员工)
$\ln AI_Shock$	0.0627*** (0.0046)	-4.49×10^{-6} (3.53×10^{-5})	0.0023*** (0.0008)	0.0973*** (0.0108)	-1.51×10^{-5} (7.74×10^{-5})	-0.0079*** (0.0017)
控制变量	控制	控制	控制	控制	控制	控制
行业固定效应	控制	控制	控制	控制	控制	控制
年份固定效应	控制	控制	控制	控制	控制	控制
样本量	13684	13684	13684	5570	5570	5570
调整 R^2	0.3456	0.4597	0.4506	0.5492	0.4470	0.5356

2. 地方就业政策导向异质性

地方就业政策导向可能影响企业的技术应用方式, 进而改变 AI 的生产率效应及其收入分配后果。为考察这一异质性, 本文以地级市政府工作报告中“就业”关键词的出现频次衡量就业议题提及度, 按照年度中位数将样本划分为就业议题提及度较低组和较高组, 分别进行回归分析。

表 8 报告了分组估计结果。从全要素生产率来看, AI 应用在两组样本中均产生显著的正向影响。这表明较强的地方就业政策导向可能促使企业在应用 AI 时兼顾就业稳定。从劳动收入份额来看, 这种差异主要影响普通员工群体。对高管群体来说, AI 应用在两组样本中的影响均不显著, 说明地方就业政策导向的差异没有明显改变管理层的收入分配。对普通员工群体来说, AI 应用在就业议题提及度较低组中显著降低其劳动收入份额, 而在较高组中的影响不显著。这表明, 较强的地方就业政策导向可能有助于缓解 AI 任务替代对普通员工收入分配的不利影响。

表 8 就业政策导向异质性估计结果

变量	就业议题提及度较低			就业议题提及度较高		
	(1)	(2)	(3)	(4)	(5)	(6)
	全要素生产率	劳动收入份额 (高管)	劳动收入份额 (普通员工)	全要素生产率	劳动收入份额 (高管)	劳动收入份额 (普通员工)
$\ln AI_Shock$	0.0821*** (0.0065)	-4.45×10^{-5} (4.62×10^{-5})	-0.0018* (0.0010)	0.0531*** (0.0064)	-1.08×10^{-5} (4.71×10^{-5})	0.0007 (0.0011)
控制变量	控制	控制	控制	控制	控制	控制
行业固定效应	控制	控制	控制	控制	控制	控制
年份固定效应	控制	控制	控制	控制	控制	控制
样本量	9996	9996	9996	11043	11043	11043
调整 R^2	0.4961	0.4622	0.5004	0.4386	0.4551	0.4711

六、结论与建议

本文结合中国上市公司年报文本与网络招聘平台数据,考察 AI 影响企业全要素生产率的任务重构机制及其收入分配效应,得到以下主要结论:第一,企业 AI 应用水平提高能够显著促进全要素生产率增长。第二, AI 应用通过任务替代与任务拓展双重路径提高企业全要素生产率。第三,从收入分配来看, AI 的任务重构呈现双重属性。任务拓展促进全要素生产率增长并带动劳动收入份额提高,任务替代虽也提高企业全要素生产率,却导致工资和劳动收入份额降低。第四,由于任务替代对劳动收入的负向影响大于任务拓展的正向影响, AI 技术红利对资本的影响更大,表明 AI 技术可能存在分配失衡风险。

基于上述结论,本文提出以下三点政策建议:

第一,完善教育培训体系,提高劳动者的技能水平。AI 兼具拓展新任务和替代传统任务的特征,因此教育部门需调整课程体系,基础教育阶段应加强数字素养和 AI 思维培养,高等教育与职业教育应增加 AI 应用和人机协同相关课程。企业可结合岗位需求开展 AI 工具应用和新任务技能培训,帮助现有员工适应任务变化。

第二,优化产业支持政策,使得 AI 应用兼顾效率提升与就业稳定。研究表明, AI 的任务替代效应不仅促进生产率增长,而且可能导致分配失衡问题。因此,政府部门应制定差异化产业扶持政策:一方面,应鼓励企业利用 AI 优化生产流程和提高劳动者能力,并对实现生产率提高、就业稳定和劳动收入增长的企业给予政策支持;另一方面,应支持企业探索人机协同模式,使得劳动者参与新的岗位和任务,从而缓解任务替代对就业与收入分配的冲击。

第三,完善劳动保障与收益共享机制,促进技术红利合理分配。政府应根据 AI 应用对不同劳动者群体的影响,健全职业转换支持、失业保障和再培训制度,鼓励企业通过员工持股、利润分享、绩效奖励等方式,使劳动者分享 AI 带来的技术红利。另外,应完善相关收入分配调节机制来缓解技术进步可能带来的收入分配失衡问题。

主要参考文献:

- [1]安同良,吴致治.企业人工智能技术水平的分层测度及其创新效应——基于全球知识网络视角[J]. [中国工业经济](#), 2025, (6): 81-100.
- [2]陈东,秦子洋.人工智能与包容性增长——来自全球工业机器人使用的证据[J]. [经济研究](#), 2022, (4): 85-102.
- [3]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): 74-91.
- [4]何小钢,毛莘娅,郭晓斌.人工智能技术、职业技能重塑与工资效应[J]. [数量经济技术经济研究](#), 2026, (5): 54-78.
- [5]黄浩权,戴天仕,沈军.人工智能发展、干中学效应与技能溢价——基于内生技术进步模型的分析[J]. [中国工业经济](#), 2024, (2): 99-117.
- [6]黄卓,陶云清,刘兆达,等.智能制造、人力资本升级与企业劳动收入份额[J]. [经济学\(季刊\)](#), 2024, (5): 1412-1427.
- [7]刘东升,袁媛.人工智能、技能剥离与企业收入差距[J]. [财经研究](#), 2026, (1): 123-137.
- [8]卢国军,崔小勇,王弟海.自动化技术、结构转型与中国收入分配格局的演化[J]. [金融研究](#), 2023, (4): 19-35.
- [9]吕璞,乔歆然,孔晓.人工智能对就业格局演变影响研究进展[J]. [经济学动态](#), 2026, (5): 203-224.
- [10]孟庆斌,杨俊华,鲁冰.管理层讨论与分析披露的信息含量与股价崩盘风险——基于文本向量化方法的研究[J]. [中国工业经济](#), 2017, (12): 132-150.

- [11]苏治,李颖,程稚渊.人工智能如何重塑要素收入分配格局?——基于企业劳动力市场垄断势力的微观证据[J].[经济研究](#),2025,(9):218-238.
- [12]孙早,侯玉琳.工业智能化如何重塑劳动力就业结构[J].[中国工业经济](#),2019,(5):61-79.
- [13]王林辉,钱圆圆,周慧琳,等.人工智能技术冲击和中国职业变迁方向[J].[管理世界](#),2023,(11):74-93.
- [14]王林辉,周慧琳,钱圆圆,等.机器人应用冲击、职业可迁移技能和职业—技能合意性[J].[管理世界](#),2024,(11):85-103.
- [15]汪佩洁,蒙克,黄海,等.社会保险缴费率与企业全要素生产率和创新[J].[经济研究](#),2022,(10):69-85.
- [16]汪前元,魏守道,金山,等.工业智能化的就业效应研究——基于劳动者技能和性别的空间计量分析[J].[管理世界](#),2022,(10):110-125.
- [17]肖士盛,董启琛,张明昂,等.竞争政策与企业劳动收入份额——基于《反垄断法》实施的准自然实验[J].[中国工业经济](#),2023,(4):117-135.
- [18]谢宇,索菲娅·阿维拉.基于大语言模型的生成式人工智能的社会影响[J].[经济学\(季刊\)](#),2025,(2):273-292.
- [19]姚加权,张锬澎,郭李鹏,等.人工智能如何提升企业生产效率?——基于劳动力技能结构调整的视角[J].[管理世界](#),2024,(2):101-116.
- [20]曾帅,罗长远,李铮.外部需求、企业劳动力市场势力与劳动收入份额——来自中国上市企业的证据[J].[经济学\(季刊\)](#),2026,(1):114-131.
- [21]赵璨,陈仕华,曹伟.“互联网+”信息披露:实质性陈述还是策略性炒作——基于股价崩盘风险的证据[J].[中国工业经济](#),2020,(3):174-192.
- [22]Acemoglu D. The simple macroeconomics of AI[J]. [Economic Policy](#), 2025, 40(121): 13-58.
- [23]Acemoglu D, Restrepo P. The race between man and machine: Implications of technology for growth, factor shares, and employment[J]. [American Economic Review](#), 2018, 108(6): 1488-1542.
- [24]Acemoglu D, Restrepo P. Tasks, automation, and the rise in U. S. wage inequality[J]. [Econometrica](#), 2022, 90(5): 1973-2016.
- [25]Acemoglu D, Restrepo P. Automation and rent dissipation: Implications for wages, inequality, and productivity[R]. NBER Working Paper No. 32536, 2024.
- [26]Agrawal A, McHale J, Oettl A. Finding needles in haystacks: Artificial intelligence and recombinant growth[R]. NBER Working Paper No. 24541, 2018.
- [27]Agarwal R, Dugas M, Gao G D. Augmenting physicians with artificial intelligence to transform healthcare: Challenges and opportunities[J]. [Journal of Economics & Management Strategy](#), 2024, 33(2): 360-374.
- [28]Autor D, Salomons A. Is automation labor-displacing? Productivity growth, employment, and the labor share[R]. NBER Working Paper No. 24871, 2018.
- [29]Autor D H. Why are there still so many jobs? The history and future of workplace automation[J]. [Journal of Economic Perspectives](#), 2015, 29(3): 3-30.
- [30]Brynjolfsson E, McAfee A. The second machine age: Work, progress, and prosperity in a time of brilliant technologies[M]. New York: W. W. Norton & Company, 2014.
- [31]Choudhary V, Marchetti A, Shrestha Y R, et al. Human-AI ensembles: When can they work?[J]. [Journal of Management](#), 2025, 51(2): 536-569.
- [32]Felten E, Raj M, Seamans R. Occupational, industry, and geographic exposure to artificial intelligence: A novel data-set and its potential uses[J]. [Strategic Management Journal](#), 2021, 42(12): 2195-2217.
- [33]Humlum A. Robot adoption and labor market dynamics[R]. Study Paper No. 175, 2021.

- [34]Korinek A, Stiglitz J E. Artificial intelligence, globalization, and strategies for economic development[R]. NBER Working Paper No. 28453, 2021.
- [35]Lei Y W, Kim R. Automation and augmentation: Artificial intelligence, robots, and work[J]. *Annual Review of Sociology*, 2024, 50: 251–272.
- [36]Pieper M, Gleasure R. How AI helps to compile human intelligence: An empirical study of emerging augmented intelligence for medical image scanning[J]. *Information Systems Journal*, 2025, 35(5): 1399–1421.
- [37]Riemer K, Peter S. Conceptualizing generative AI as style engines: Application archetypes and implications[J]. *International Journal of Information Management*, 2024, 79: 102824.

Artificial Intelligence, Task Restructuring, and the Distribution of Productivity Gains

Liu Dongsheng¹, Wang Yongzhong^{1,2}

(1. School of Global and Regional Studies, University of Chinese Academy of Social Sciences, Beijing 102488, China; 2. Institute of World Economics and Politics, Chinese Academy of Social Sciences, Beijing 100732, China)

Summary: Artificial intelligence (AI) not only improves production efficiency but also reshapes the structure of job tasks and the distribution of income between labor and capital. AI can both substitute for existing tasks and create new ones, so different forms of task restructuring may have divergent effects on productivity and income distribution. Identifying the channels through which AI generates productivity gains and affects their distribution is therefore essential for reconciling technological progress with employment stability and income equality.

Drawing on the annual reports of China's A-share listed companies and data from online recruitment platforms, this paper uses text analysis and task matching to measure firm-level AI adoption and job-level task substitution, task expansion, and posted wages. Using an instrumental-variable approach, it examines AI's productivity effects, task-restructuring mechanisms, and distributional consequences. The results show that AI increases firm TFP through both task substitution and task expansion, although the two channels have opposing distributional effects. Task expansion increases posted wages and the labor income share of non-executive employees, whereas task substitution significantly reduces both. Because the negative effect of task substitution on labor income outweighs the positive effect of task expansion, AI-generated productivity gains disproportionately accrue to capital. These effects are more pronounced in service-sector firms, which experience both larger productivity gains and a greater decline in the labor income share of non-executive employees.

This paper develops measures that link firm-level AI adoption to job-level task restructuring. It explains both the generation and distribution of AI-generated productivity gains by distinguishing between the channels of task substitution and task expansion, thereby providing new micro-level empirical evidence on the economic effects of AI. The findings suggest that policymakers should improve education and vocational training systems, encourage firms to adopt human–AI collaboration and task-expanding applications, and strengthen labor protection and benefit-sharing mechanisms to enable workers to share more fully in the productivity gains generated by AI.

Key words: AI; task substitution; task expansion; labor income share

(责任编辑 顾 坚)