



北京大学中国经济研究中心
China Center for Economic Research

讨论稿系列
Working Paper Series

C2026006

2026-08-03

人工智能技术进步如何影响不平等？来自劳动就业的视角

李力行 王安琪

北京大学中国经济研究中心 北京大学国家发展研究院

摘要：人工智能技术进步正在重塑劳动需求、就业结构与收入分配格局。本文从劳动就业视角，系统梳理人工智能影响不平等的理论机制与经验证据。在宏观层面，本文考察自动化、资本深化、任务互补、鲍莫尔效应与新任务创造如何共同影响资本—劳动收入分配；在微观层面，本文以劳动经济学中任务模型的理论演进为线索，分析人工智能如何通过任务替代、劳动互补、任务创造与岗位重组，改变不同劳动者的就业机会和工资回报。对经验研究的综述表明，人工智能对不平等的影响取决于技术是否被实际采纳、被替代与被增强任务的分布、劳动者的技能结构、企业的组织调整以及制度和市场环境。本文进一步总结中国相关研究，并提出未来应加强人工智能实际采纳的度量，深入识别任务—技能—岗位结构的重组过程，关注灵活就业的分配效应，以及考察组织重构对青年和初级岗位劳动者的影响。

人工智能技术进步如何影响不平等？来自劳动就业的视角

李力行 王安琪

北京大学中国经济研究中心 北京大学国家发展研究院

2026 年

摘要：人工智能技术进步正在重塑劳动需求、就业结构与收入分配格局。本文从劳动就业视角，系统梳理人工智能影响不平等的理论机制与经验证据。在宏观层面，本文考察自动化、资本深化、任务互补、鲍莫尔效应与新任务创造如何共同影响资本—劳动收入分配；在微观层面，本文以劳动经济学中任务模型的理论演进为线索，分析人工智能如何通过任务替代、劳动互补、任务创造与岗位重组，改变不同劳动者的就业机会和工资回报。对经验研究的综述表明，人工智能对不平等的影响取决于技术是否被实际采纳、被替代与被增强任务的分布、劳动者的技能结构、企业的组织调整以及制度和市场环境。本文进一步总结中国相关研究，并提出未来应加强人工智能实际采纳的度量，深入识别任务—技能—岗位结构的重组过程，关注灵活就业的分配效应，以及考察组织重构对青年和初级岗位劳动者的影响。

一、引言

从第一次工业革命开始，机器会怎么替代人工，就业岗位是否会被技术进步所破坏以及技术创新是否会加剧不平等，在历史上就曾反复成为热议的话题。技术进步通常伴随着“创造性破坏”：一方面提高生产率、创造新的产业、职业以及就业机会，另一方面也会替代既有岗位，使部分劳动者面临收入下降和失业风险，甚至引发社会动荡。19 世纪初，英国就曾经爆发过工人以破坏机器来抗议失业的“卢德主义运动¹”，相关的讨论也成为理解技术进步、劳动替代与分配冲突的重要历史参照。

近年来，人工智能技术的快速进步及广泛应用，使失业风险、收入差距与阶层分化再次成为社会关注的热点问题。与以往主要替代体力劳动和规则化劳动的技术不同，生成式人工智能技术大量进入认知型工作领域，引发白领劳动者关于岗位被替代的担忧。与失业这种直接的担忧并存的，是对技术进步加剧不平等的担忧。例如，两位诺贝尔经济学奖得主 Acemoglu 和 Johnson 的著作《权力与进步》指出（Acemoglu and Johnson, 2023），技术进步本身并不会自动带来普遍繁荣，关键在于技术被引导到什么方向。如果 AI 和自动化主要用于替代劳动、压低工资和集中收益，就会加剧不平等；只有当技术更多用于增强劳动者能力、创造新任务并服务公共利益时，才能带来更广泛的共享繁荣。在国内，关于技术进步与不平等的话题也得到热议，并进而引发了针对技术创新的方向、技术管制等相关问题的讨论。例如，蔡昉（2025）强调，人工智能具有提高人类能力与替代人类工作两种倾向，具体结果将取决于技术扩散、制度安排与应用场景的选择。

为了回应这一关切，本文从劳动就业的视角，对人工智能技术进步的影响展开综述，试图建立一个技术进步与不平等的概念框架，以帮助读者理解人工智能在分配方面的潜在影响及其作用机制。本文将从宏观与微观两个层面梳理技术进步影响不平等的机制与相关研究，并强调人工智能技术与此前技术进步的相同点和不同点。在宏观层面，不平等的核心表现之一是资本与劳动之间的收入分配关系。传统增长理论通常假定技术进步以劳动增强型方式出

¹ 卢德主义运动指 19 世纪初英国纺织工人反对机器化生产的集体行动。实际上，工人破坏织机等机器，并非单纯反对技术本身，而是反对机器引入后导致的失业、工资下降和劳动控制加强。因此，“卢德主义”后来常被用来指代对技术替代劳动及其分配后果的担忧。

现，从而与劳动收入份额长期相对稳定的经验事实相一致。然而，现实中的自动化与人工智能技术往往表现为资本设备、软件和算法能力的提升，使资本能够承担更多原本由劳动完成的任务，因而具有压低劳动收入份额的潜在作用。由此产生的核心问题是：为什么自动化持续推进，劳动收入份额却没有无限下降？围绕这一问题，相关研究进一步引入任务互补、相对价格调整、鲍莫尔效应以及新任务创造等机制，说明劳动收入份额的变化取决于自动化替代与各种抵消力量之间的相对强弱，为解释人工智能时代资本—劳动收入分配关系的变化提供了基准参照。

在微观层面，不平等通常表现为不同性别、教育水平、技能和经验的群体之间在收入、就业机会和职业发展上的差距。在劳动力市场上，这些人口学特征可以被视为市场上的供给侧因素。与之相对应的，则是劳动力市场的需求侧，其变动常常体现在行业、企业、职业等层面。技术进步发生之后，会同时作用于供给侧与需求侧。虽然经典的人力资本理论强调教育和技能差异是收入不平等的重要来源，但技术进步通过需求侧产生的影响往往会更快地体现出来。现实的观察显示，人工智能技术的迅速扩散和采纳，正在迅速改变行业的生产方式、企业的组织与雇佣结构，以及职业内部的任务构成，进而引发了劳动力在不同行业、企业、职业，乃至不同任务之间的重新配置。劳动需求的变化，会与劳动者自身的特征相互作用，决定市场上的就业和工资等结果，并最终呈现为不同群体之间收入的分化。

本文将着重介绍人工智能通过“任务重构”（task reallocation）机制对劳动力市场产生的影响。与以技能为核心的分析框架不同，任务模型（task-based approach）强调，技术并非简单替代某一类劳动者，而是改变不同任务在资本与劳动之间的分配方式。人工智能能够自动化部分任务，也可能提高劳动者在其他任务中的生产率，甚至创造新的任务与职业。因此，人工智能对不同群体劳动者的影响，不仅取决于其技能水平，还取决于其所从事任务的性质、复杂程度以及是否容易被算法化和标准化。进一步地，人工智能还会通过组织结构调整、职业结构变化以及劳动需求重组等机制，影响工资结构与就业机会。近年来，伴随着生成式人工智能的发展，越来越多研究开始关注人工智能对认知型劳动、白领岗位以及高技能职业的影响，也推动了相关讨论从传统的“技能偏向型技术进步”的视角，进一步转向以任务为核心的分析框架。

在研究范畴方面，本文有几点说明。第一，人工智能技术进步影响不平等的机制是多样的，涉及财富分配、地区差异、教育机会、数字鸿沟、平台垄断以及国际分工等多个层面。本文并不打算覆盖所有相关讨论，而是聚焦于劳动就业这一核心维度，主要考察资本与劳动之间的收入分配，以及不同劳动者之间的工资和就业机会差异。第二，本文主要从劳动力市场讨论技术进步对不平等的影响，而不讨论金融市场、资产价格等渠道对收入与财富分化的作用。第三，本文关注的重点是技术进步对一次分配的影响，而不讨论税收制度、社会保障或财政转移支付等再分配政策对不平等的调节作用。

本文其余部分安排如下。第二节从宏观经济增长视角出发，梳理技术进步影响劳动收入份额的理论模型，重点讨论自动化、资本深化、鲍莫尔效应和新任务创造等机制如何共同决定资本—劳动收入分配关系。第三节转向微观层面，以 Autor（2022）提出的理论演进为线索，回顾从教育竞赛模型、任务极化模型到“自动化—再任务化”框架及 AI 时代任务模型拓展的主要观点，说明技术进步如何通过替代、互补和创造任务等渠道影响不同劳动者的就业机会与收入水平。第四节系统梳理人工智能技术进步对劳动就业不平等的实证研究，重点介绍技术暴露度与技术采纳的度量方法、在线招聘和劳动力市场数据中的经验证据，并讨论 AI 对不同技能、职业、就业形态和人口群体的异质性影响。第五节进行全文总结并提出研究展望。

二、宏观分析框架

从宏观经济的视角,技术进步对收入分配的影响主要体现为资本与劳动之间收入份额的变化。一方面,自动化和人工智能通常表现为资本设备、算法和软件能力的提升,直觉上似乎会扩大资本在生产中的作用范围,提高资本收入份额并压低劳动份额;另一方面,长期经济增长中有一个经典的经验事实——卡尔多事实(Kaldor facts),认为资本收入份额与劳动收入份额总体保持相对稳定,并未随着技术进步持续向某一要素深化。如何解释这一矛盾,成为技术进步与收入分配研究的核心问题。

围绕这一问题,相关理论经历了从标准增长模型到自动化与任务模型的扩展。早期新古典增长模型强调劳动增强型技术进步与平衡增长路径的一致性(Solow, 1956; Swan, 1956; Uzawa, 1961);后续研究则逐渐放松 Cobb-Douglas 生产函数(后文简称 C-D 生产函数)的限制,引入更一般的替代弹性设定,以讨论资本深化和自动化对劳动份额的影响(Aghion et al., 2019)。进一步地,近年来的研究开始强调,技术进步不仅提高生产率,也改变资本与劳动在生产中的任务边界,并通过价格调整、新任务创造以及组织与市场结构变化,共同决定劳动收入份额的长期演变(Acemoglu and Restrepo, 2018)。

(一) 自动化、任务配置与劳动收入份额

Zeira (1998) 建立了一个讨论自动化技术对于经济增长的影响的重要研究框架。文中定义了一个 C-D 生产函数²: $Y_t = A_t X_{1t}^{\alpha_1} X_{2t}^{\alpha_2} \cdots X_{nt}^{\alpha_n}$, 其中 $X_{nt}^{\alpha_n}$ 表示不同中间商品。在自动化技术引入之后,一些商品的生产便由机器,即资本来承担,不能被自动化的商品由劳动力来生产。若将总资本 K 与劳动力 L 最优配置于这些任务,则生产函数可简化表示为:

$$Y_t = A_t K_t^\alpha L_t^{1-\alpha}.$$

在新古典模型的框架下,假设 A_t 的增长率恒定为 g , 那么人均产出的增长率 g_y 则为 $\frac{g}{1-\alpha}$ ³。

这个结论意味着当自动化程度不断提高时(α 提高),不仅资本份额会不断上升,而且产出增长速率也会上升。然而,这一结论与卡尔多事实相违背。根据卡尔多事实,在长期经济增长过程中,资本收入份额与劳动收入份额通常保持相对稳定,而非随着技术进步和自动化的推进持续发生系统性变化。

后续的许多文献可以被视为在 Zeira (1998) 的基础上进行的扩展,主要围绕两个问题展开:第一,为什么自动化没有导致劳动份额持续下降;第二,自动化在提高产出增长的同时,会如何影响劳动收入、工资差距和收入分配。

首先, Aghion et al. (2019) 在模型中加入了“鲍莫尔成本病”的假设⁴。该模型假设经济中生产一种最终产品 Y , 是由一系列任务 X 组成, 并且这些任务之间的替代弹性小于 1, 即

$$Y_t = A_t \left(\int_0^1 X_{it}^{\frac{\sigma-1}{\sigma}} di \right)^{\frac{\sigma}{\sigma-1}},$$

替代弹性小于 1 意味着,如果某个任务的产出变得非常便宜,最终产品并不会全部使用该任务要素,所有任务都是必需品。该模型还定义了技术状态,假设在时间 t 已经有 β_t 单位的任务被替代,有 $1 - \beta_t$ 的任务还未自动化,代表了自动化的程度。若资本和劳动是对称地分配

² Aghion et al. (2019) 对 Zeira(1998)模型的表述形式进行了改写, 本文介绍的是改写后的模型。

³ 这里的推导基于平衡增长路径。对生产函数 $Y_t = A_t K_t^\alpha L_t^{1-\alpha}$ 取增长率, 有 $g_Y = g_A + \alpha g_K + (1-\alpha)g_L$ 。若 A_t 以恒定速度 g 增长, 且在平衡增长路径上资本产出比保持稳定, 即 $g_K = g_Y$, 则 $g_Y = g + \alpha g_Y + (1-\alpha)g_L$, 从而 $g_Y = g_L + \frac{g}{1-\alpha}$ 。因此人均产出增长率为 $g_y = g_Y - g_L = \frac{g}{1-\alpha}$ 。

⁴ 鲍莫尔成本病是指劳动密集型服务部门生产率提升较慢, 但工资仍需随整体经济工资水平上升而提高, 从而导致这些部门的单位成本和相对价格持续上升。

到所有已自动化和未自动化的任务中。那么每个已自动化任务获得的资本量是 $K_{it} = \frac{K_t}{\beta_t}$ ，每个未自动化任务获得的劳动量是 $L_{it} = \frac{L_t}{1-\beta_t}$ 。

将该要素分配代入生产函数可得：

$$Y_t = A_t \left[\beta_t \left(\frac{K}{\beta_t} \right)_{it}^{\frac{\sigma-1}{\sigma}} + (1-\beta_t) \left(\frac{L}{1-\beta_t} \right)_{it}^{\frac{\sigma-1}{\sigma}} \right]^{\frac{\sigma}{\sigma-1}},$$

该生产函数为 CES 形式函数，不同的是 β_t 会随自动化程度的不同而变化。当自动化程度提高，资本的占比上升，让资本去生产更多的任务，提高了资本份额。然而，由于任务之间替代弹性小于 1，那些没有被自动化的任务会越来越稀缺，因此劳动份额并不会下降为 0，并使得经济增长趋于稳定。这也解释了“鲍莫尔成本病”的来源：那些尚未被自动化、仍依赖劳动完成的任务，由于生产率提升较慢却变得越来越稀缺，其相对成本和价格会不断提高。

Jones and Liu（2024）在 β_t 自动化程度上进行进一步拓展，引入了资本质量参数 Z_t ，代表每个自动化任务生产率的调和平均数： $Z_t = \left[\frac{1}{\beta_t} \int_0^{\beta_t} \frac{1}{z_t(i)} di \right]^{-1}$ 。通过求解一般均衡，可以得到一个极其简洁的资本收入份额公式： $s_{K_t} = \beta_t Z_t^{-1}$ 。该式表示自动化程度上升会提高资本份额，但同时自动化效率提高会使得资本效率更高，由于任务间互补，生产率高的任务份额反而下降，从而降低资本份额。该模型的平衡增长路径在这两种影响下，资本份额趋于平衡。实证上，作者使用美国 KLEMS 行业数据和机器人采用数据进行分析，发现许多行业资本份额上升，这与自动化叙事方向一致，但机器人采用与资本份额变化之间并无明显系统相关性。因此，该文认为 AI 具有改变长期增长路径的潜力，但其实际影响取决于任务互补性、创新激励、企业组织和市场结构等制度与经济条件。




图 1：任务模型演示

Acemoglu and Restrepo（2018）将中间品视作不同的任务类型，生产由一系列连续的任务 $i \in [N-1, N]$ 组成，每个任务可以由资本或者劳动来生产（见图 1）。自动化对于任务集有两种不同的影响，一方面自动化使得资本可以执行的任务范围扩大（即 I 增加），另一方面，自动化还可以创造新任务（即 N 增加），这些新任务中劳动力具有比较优势。对于非自动化的任务 $i > I$ ，只能使用劳动，对于自动化的任务 $i < I$ ，可以使用劳动或资本，两者完全替代，在简化条件下，产出函数可以简化为：

$$Y = \frac{B}{1-\eta} K^{1-N+I^*} L^{N-I^*}$$

其中，劳动份额为 $s_L = \frac{WL}{Y} = N - I^*$ ，这一表达式清楚地揭示了自动化与新任务创造的反作用。

若自动化程度提高，即 I^* 上升，则劳动能够执行且具有比较优势的任务范围缩小， $N - I^*$ 下降，劳动份额随之下降。这对应于自动化的替代效应：资本替代劳动完成更多任务，从而压低劳动在总收入中的份额。相反，若技术进步主要体现为新任务创造，即

N 上升, 则劳动可执行的任务范围扩大, $N - I^*$ 上升, 劳动份额提高。这对应于新任务的恢复效应: 新任务重新扩大了劳动需求, 并可能提高工资和就业。因此, 自动化并不必然导致劳动收入下降, 其最终影响取决于两种力量的相对大小: 如果 I^* 的上升快于 N 的上升, 自动化的替代效应占主导, 劳动份额下降, 工资和就业也可能受到压制; 如果 N 的上升足以抵消甚至超过 I^* 的上升, 新任务创造效应占主导, 劳动份额、工资和就业则可能上升。

Acemoglu and Loebbing (2026) 构建了一个内生任务分配模型, 用以解释自动化为何会带来就业和工资极化。该文假设存在连续的技能空间和任务复杂度空间, 其中高技能劳动者在复杂任务上具有比较优势, 而资本也可以被分配到部分任务中。该文认为资本替代任务区间是内生行为, 当低技能工资较低时, 低复杂度任务由低技能劳动者完成仍然更便宜, 而高复杂度任务又更依赖高技能劳动者的比较优势。因此, 资本最有利可图的替代对象往往是中等复杂度任务。当资本价格下降或资本生产率提高会使自动化区间向两侧扩张, 从而将劳动者从中间任务挤出, 形成就业极化。工资极化则表现为, 自动化区间上方的劳动者相对受益, 技能溢价上升, 而自动化区间下方的劳动者相对受损, 技能溢价下降。工资水平的变化取决于两种力量的博弈, 一是位移效应, 即资本接管任务会压低与其直接竞争劳动者的工资; 二是生产率效应, 即资本成本下降提高总产出, 并可能带动劳动需求上升。文章最后指出, 若资本生产率继续提高, 自动化可能从中间任务扩展到低复杂度任务, 此时受冲击最大的群体可能从中等技能劳动者转向低技能劳动者。

(二) 人工智能与收入分配的扩展分析

在上述自动化模型的基础上, 近期研究进一步引入新任务创造、人工智能的任务互补作用以及市场结构等机制, 以分析人工智能条件下劳动收入份额和工资的变化。

Acemoglu (2024) 基于 Acemoglu and Restrepo (2018) 的任务模型, 从自动化技术扩展到人工智能技术, 认为 AI 对宏观经济的影响主要来自四种力量: 一是自动化, 即 AI 接管部分原本由劳动完成的任务并降低成本; 二是任务互补, 即 AI 辅助劳动者完成未被完全替代的任务、提高其效率; 三是自动化深化, 即 AI 提高已经由资本或算法完成任务的效率; 四是新任务创造, 即 AI 生成新的产品、岗位和生产组织方式。基于现有的 AI 暴露度和实验研究的估计, 作者认为未来十年对 TFP 的提升可能只有约 0.55%—0.71%, 对 GDP 的提升也较为温和。同时, 与之前的自动化技术相比, AI 对不同人口群体的暴露度更加均匀, 因此未必像机器人那样显著扩大组间工资差距, 但也没有充分证据表明其会降低劳动收入不平等, 更可能的结果是小幅提高资本收入相对于劳动收入的份额。

Trammell and Korinek (2026) 进一步从长期宏观增长视角讨论了 AI 的潜在影响。文章区分了生产自动化与研发自动化两类机制, 生产自动化意味着 AI 和机器可以替代劳动完成生产任务, 甚至实现机器的自我复制, 而研发自动化意味着 AI 可以替代科研人员和工程师, 从而加速技术进步。如果 AI 仅仅提高部分任务效率, 其宏观效应可能较为有限, 但如果 AI 使资本成为劳动的广泛替代品, 则经济增长可能显著加速, 传统的卡尔多事实将被打破。在生产自动化充分推进的情形下, 资本积累不再受到劳动供给约束, 劳动收入份额可能趋近于零, 而新增产出主要流向资本所有者。与此同时, 文章强调 AI 对于工资的影响并不确定。劳动份额下降并不必然意味着工资绝对下降, 因为在资本与劳动不完全替代的情况下, 资本积累仍可能提高劳动边际产出, 但如果技术进步主要是资本增强型, 或者自然资源、高技能监督能力等固定要素成为新的瓶颈, 普通劳动者工资可能停滞甚至下降。

Autor and Kausik (2026) 同样讨论了 AI 自动化可能降低劳动收入份额是否必然压低工资。作者认为工资是由劳动份额和人均产出共同决定的, AI 自动化虽然可能降低劳动份额, 但如果它显著提高产出, 劳动者分到的比例变小, 分到的绝对金额仍可能增加。在竞争性、

规模报酬不变的经济中，作者证明工资最大化的劳动份额只取决于资本—劳动比，因此劳动份额与工资之间并非单调关系；当实际劳动份额高于工资最大化水平时，进一步自动化即使降低劳动份额，也可能提高平均工资。作者使用美国 and 11 个工业化国家的数据估计发现，这些国家当前劳动份额均高于工资最大化水平，因此进一步自动化导致的劳动份额下降反而可能提高平均工资，其中美国 1954—2019 年劳动份额下降约解释了实际工资增长的 16%。

Athey and Morton (2025) 在开放经济一般均衡框架中，将 AI 建模为由国外上游供应商提供、可定价的进口生产投入，而非外生中性技术进步。下游企业采用 AI 后生产成本下降，但部分劳动任务被自动化替代，从而减少对相关劳动者的需求。文章的关键机制在于构建了 AI 上下游结构，若处于上游的 AI 供应商具有市场势力，下游的生产率收益可能通过使用费和接入费被上游攫取并外流，未必转化为国内价格下降或实际工资提高。同时，较高的 AI 费用还会抬高下游边际成本、限制企业进入和产品种类，损害消费者福利。该文认为 AI 的福利与分配效应不仅取决于技术效率，还取决于上游竞争程度、下游采用决策以及被替代劳动能否被其他部门吸纳。

（三）宏观分析框架小结

上述模型的具体设定有所区别，但都围绕同一个核心问题展开：技术进步如何改变劳动在生产中的作用范围，并进而影响劳动收入份额。早期自动化模型强调，技术进步使资本能够完成更多原本由劳动承担的任务，从而扩大资本在生产中的边界。这一机制意味着，若自动化持续推进而缺乏抵消力量，劳动承担的任务范围将不断缩小，劳动收入份额也会随之下降。因此，自动化首先提供了一个解释劳动份额下降的直接机制：技术并非只是提高总生产率，而是改变了资本与劳动在生产过程中的分工（Zeira, 1998）。

后续模型的重要拓展在于指出，劳动收入份额并不会简单地随着自动化程度提高而单调下降。第一，若任务之间存在较强互补性，自动化任务的生产率提高会降低其相对价格，而尚未自动化、仍由劳动完成的任务反而变得相对稀缺，这种价格效应或鲍莫尔机制会支撑劳动收入份额（Aghion et al., 2019）。第二，技术进步不仅会替代既有任务，也可能创造新的劳动密集型任务。如果新任务创造足够快，劳动可以转向新的生产活动，从而抵消自动化带来的位移效应（Acemoglu and Restrepo, 2018, 2019, 2022）。第三，资本深化或资本效率提升对劳动份额的影响取决于替代弹性：当资本与劳动容易替代时，资本深化倾向于压低劳动份额；当任务之间具有互补性时，资本效率提高未必持续推高资本份额，甚至可能通过相对价格变化稳定劳动份额（Jones and Liu, 2024）。

纳入人工智能技术特征的拓展模型则进一步丰富了这一理论框架。AI 既可能作为劳动替代型技术，扩大资本或算法对劳动任务的替代，降低劳动边际产出；也可能作为劳动互补型技术，提高劳动者在未被自动化任务中的生产率（Acemoglu, 2024）。与此同时，AI 带来的生产率提升并不必然转化为劳动收入份额上升：如果收益主要由资本所有者、平台企业、上游 AI 供应商或数据和算法控制者获得，劳动份额仍可能下降（Athey and Morton, 2025）。另一方面，劳动份额下降也不必然意味着平均工资下降，因为工资还取决于人均产出水平；当技术显著提高产出时，劳动者获得的比例下降，但获得的绝对收入仍可能增加（Autor and Kausik, 2026）。但是，如果 AI 使资本成为劳动的广泛替代品，甚至突破劳动供给对生产和研发的约束，传统增长路径和卡尔多事实也可能被打破，劳动收入份额面临更大下行压力（Trammell and Korinek, 2026）。

因此，从宏观层面看，人工智能技术进步与劳动收入份额之间并不存在单一方向的关系。劳动收入份额的变化取决于几组力量的相对强弱：自动化的位移效应是否超过新任务创造的扩张效应？资本深化是否通过替代劳动压低劳动份额，还是通过价格效应受到约束？人工智能技术获得的收益是被劳动者分享，还是集中于资本、数据和平台所有者？考虑到人工智能

技术进步的迅速迭代，这些相对力量的强弱会如何演进，值得持续观察。

值得指出的一点是，宏观生产函数框架通常强调生产侧机制，较少直接讨论产品市场上的需求结构变化。然而，技术进步对收入分配的影响，并不仅仅取决于资本与劳动之间的替代关系，也受到消费需求变化的影响。技术进步通过提高生产率和降低产品价格，可能改变居民消费结构，并在部门之间重新配置劳动（Comin et al. 2021）。例如，随着收入提高，居民对医疗、教育、文化娱乐等服务类产品的需求往往增长更快，而这些行业通常具有更高的劳动密集度，从而在一定程度上对冲制造业自动化带来的劳动需求下降。因此，技术进步对劳动收入份额的影响，不仅取决于生产侧的自动化与资本深化，也受到需求结构调整和跨部门劳动再配置的影响。

三、微观分析框架

上一节的宏观模型，主要从资本与劳动之间收入分配的变化来理解人工智能对不平等的宏观影响。本节将转向微观层面，讨论技术进步如何改变不同劳动者的就业机会、工资回报与职业结构。要理解技术进步为何会使某些劳动者受益、另一些劳动者受损，需要进一步考察哪些任务被替代，哪些任务被增强，以及哪些新任务被创造。围绕这一问题，任务模型逐渐成为理解技术进步与劳动市场不平等的重要分析框架，并在近年来人工智能快速发展的背景下得到进一步拓展。

在微观层面看，技术进步影响不平等的核心机制，是技术如何改变不同劳动者所从事的任务、所需要的技能以及相应的劳动市场回报。Autor（2022）对这一问题的理论演进进行了系统梳理，并将相关研究概括为四个相互衔接的分析框架。第一阶段是“教育竞赛”（Education race）模型，其核心思想源于 Tinbergen（1974）：技术进步不断提高对高技能劳动者的需求，而教育扩张通过增加高技能劳动者供给与之竞争，二者的相对速度决定技能溢价和收入差距。第二阶段是“任务极化”（Task polarization）模型，该框架将工作分解为不同任务，强调计算机和自动化技术主要替代可编码、可程序化的常规任务，从而压缩中等技能岗位，并推动高技能认知任务和低技能服务任务相对增长。第三阶段是“自动化一再任务化竞赛”（Automation-reinstatement race）框架，它进一步指出，技术不仅会替代既有任务，也会创造新的任务和职业，因此劳动需求的最终变化取决于自动化与新任务创造之间的动态平衡。第四阶段被称为“AI 不确定性时代”（Era of AI uncertainty）。

（一）第一阶段模型：教育竞赛

第一代分析框架通常被称为“教育竞赛”模型，其基本逻辑是，技术进步与收入不平等可以被理解为“技术需求”和“教育供给”之间的竞赛。在这一框架中，技术进步通常被视为技能偏向型技术进步，它提升高技能劳动者的生产率和相对需求，从而推动高技能工资的上涨。教育体系则通过扩大受教育机会、提高劳动者技能供给，提高劳动力整体的技能水平。若教育扩张足够快，更多劳动者能够进入高技能岗位，技能溢价不会持续扩大；若教育扩张滞后，高技能劳动者变得相对稀缺，技术收益便集中于少数受教育程度较高的群体，收入差距随之扩大。

对技能进行简单分类，分为高技能劳动力 H 和低技能劳动力 L ，生产函数为 CES 形式，即：

$$Y = \left[(A_L L)^{\frac{\sigma-1}{\sigma}} + (A_H H)^{\frac{\sigma-1}{\sigma}} \right]^{\frac{\sigma}{\sigma-1}},$$

其中 A_L ， A_H 是技能偏向型技术参数， σ 是高低技能之间的替代弹性，对于生产函数求偏导可以得到两类技能劳动者的工资，低技能工资 w_L 和高技能工资 w_H 分别为：

$$w_L = \frac{\partial Y}{\partial L}, \quad w_H = \frac{\partial Y}{\partial H}.$$

因此，高技能工人与低技能工人工资之比为：

$$\omega = \frac{w_H}{w_L} = \left(\frac{A_H}{A_L}\right)^{\frac{\sigma-1}{\sigma}} \left(\frac{H}{L}\right)^{-\frac{1}{\sigma}}.$$

该式意味着技能溢价由不同技能劳动力的相对供给和相对技术生产率共同决定，当 $\sigma > 1$ 时，高、低技能劳动之间具有较强替代性，若技术进步更偏向高技能劳动，则高技能劳动的边际产出相对提高，从而推高技能溢价。相反，若高技能劳动力供给 H/L 增加，则会稀释高技能劳动的稀缺性，从而降低技能溢价。

技能工资差距的变化可以被理解为技能偏向型技术进步与教育扩张之间相互作用的结果。因此，技术进步并不必然扩大工资不平等，关键取决于技术进步的方向和劳动力供给结构。如果高技能增强型技术进步较快，而高技能劳动供给增长不足，则技能溢价上升，工资不平等扩大；如果教育扩张使高技能劳动供给快速增加，则可能抵消技术进步带来的相对需求上升，甚至降低技能溢价。同时，在该模型中，技术进步通过提高劳动的边际产出，通常会提高劳动者的实际工资水平，但不同技能组工资上升的幅度不同，偏向高技能的技术进步会使高技能劳动者获得更大的工资收益，而低技能劳动者虽然也可能因总体生产率提高而受益，但其相对地位会下降。

Goldin and Katz（2008）关于美国“技术与教育竞赛”的著名研究，是这一分析框架的经典表述。美国 20 世纪前半期教育扩张较快，技术进步带来的技能需求增长在很大程度上被更广泛的人力资本积累所吸收，因此工资差距相对平稳；而 20 世纪后半期，教育扩张放缓，技术进步继续提高对高技能劳动者的需求，大学毕业生与高中毕业生之间的工资差距明显扩大。第一阶段模型的局限也很明显：它主要区分高技能与低技能劳动者，对收入差距变化的预测是线性的，难以解释后来出现的中等技能岗位萎缩但低端服务岗位扩张的“反常”现象。

（二）第二阶段模型：任务极化

本小节以 Acemoglu and Autor（2011）为例介绍任务模型。与之前的模型不同，任务模型明确区分了技能与任务，并允许采用技术来完成工作中的任务，令某些任务实现自动化。另外，为理解不同技术如何影响技能需求、收入水平以及技能在任务间的分配，任务模型允许不同劳动者在执行不同任务时具有比较优势，并纳入了三个不同的技能群体。劳动者并不是直接生产最终产品，而是通过完成不同任务参与生产。最终产品由连续任务 $i \in [0,1]$ 组合而成，生产函数设定为 Cobb-Douglas 形式：

$$\ln Y = \int_0^1 \ln y(i) di,$$

其中， $y(i)$ 表示任务 i 的产出。由于最终产品生产函数为 C-D 形式，均衡中每一个任务在最终产出中的支出份额相同⁵，即：

$$p(i)y(i) = \text{constant}, \quad \forall i \in [0,1],$$

⁵ 这一结果来自 Cobb-Douglas 生产函数的固定支出份额性质。将最终品价格标准化为 1，最终品厂商的利润为 $\Pi = Y - \int_0^1 p(i)y(i)di$ 。由 $\ln Y = \int_0^1 \ln y(i)di$ 可得 $\partial Y / \partial y(i) = Y / y(i)$ 。一阶条件 $p(i) = Y / y(i)$ 进一步推出 $p(i)y(i) = Y$ ，即所有任务具有相同的支出份额。

其中， $p(i)$ 是任务 i 的价格。模型假设劳动力市场存在三种类型的劳动者，分别是低技能劳动者 L 、中技能劳动者 M 和高技能劳动者 H 。每一类劳动者在不同任务上的生产率不同。设低技能、中技能和高技能劳动者在任务 i 上的生产率分别为：

$$\alpha_L(i), \alpha_M(i), \alpha_H(i).$$

若任务 i 由低技能劳动者完成，则任务产出为： $y(i) = \alpha_L(i)l(i)$ ，其中 $l(i)$ 是投入到任务 i 的低技能劳动数量。类似地，如果任务由中技能或高技能劳动者完成，则有： $y(i) = \alpha_M(i)m(i), y(i) = \alpha_H(i)h(i)$ 。

为了刻画不同技能劳动者的比较优势，模型假设任务按照复杂程度从低到高排列。低技能劳动者在低复杂度任务上具有比较优势，高技能劳动者在高复杂度任务上具有比较优势，中技能劳动者则主要适合中间复杂度任务。因此，在均衡中存在两个内生决定的任务边界 I_L 和 I_H ，使得：

$$\begin{aligned} i \in [0, I_L] & \text{ 由低技能劳动者完成,} \\ i \in [I_L, I_H] & \text{ 由中技能劳动者完成,} \\ i \in [I_H, 1] & \text{ 由高技能劳动者完成.} \end{aligned}$$

以低技能任务区间 $i \in [0, I_L]$ 为例，由于该区间内所有任务都由低技能劳动者完成，且低技能劳动者可以在这些任务之间自由流动，因此在均衡中，低技能劳动者在所有低技能任务上的工资必须相等。低技能劳动者在任务 i 上的工资等于其边际产出价值：

$$w_L = p(i)\alpha_L(i).$$

由于 w_L 在低技能任务区间内是相同的，因此：

$$p(i)\alpha_L(i) = w_L = \text{constant}, \quad \forall i \in [0, I_L].$$

另一方面，由 C-D 任务生产函数可知，每个任务的支出 $p(i)y(i)$ 相等。对于低技能任务，有： $p(i)y(i) = p(i)\alpha_L(i)l(i)$ 。

由于 $p(i)y(i)$ 是常数，且 $p(i)\alpha_L(i)$ 也是常数，因此 $l(i)$ 在低技能任务区间内也必须是常数。再结合低技能劳动市场出清条件：

$$\int_0^{I_L} l(i) di = L,$$

可得：

$$l(i) = \frac{L}{I_L}, \quad \forall i \in [0, I_L].$$

同理，对于中技能劳动者和高技能劳动者：

$$m(i) = \frac{M}{I_H - I_L}, \quad \forall i \in [I_L, I_H].$$

$$h(i) = \frac{H}{1 - I_H}, \quad \forall i \in [I_H, 1].$$

因此，低技能工资与低技能劳动者承担的任务区间长度正相关，与低技能劳动供给负相关：

$$w_L \propto \frac{I_L}{L}.$$

类似地，对于中高技能劳动者，有：

$$w_M \propto \frac{I_H - I_L}{M}.$$

$$w_H \propto \frac{1 - I_H}{H}.$$

因此，不同技能组之间的相对工资可以写为：

$$\frac{w_M}{w_L} \propto \frac{I_H - I_L}{I_L} \cdot \frac{L}{M}$$

$$\frac{w_H}{w_M} \propto \frac{1 - I_H}{I_H - I_L} \cdot \frac{M}{H}$$

以上结论表明，工资差异不仅取决于不同技能劳动者的相对供给，也取决于不同技能组所承担的任务范围。某一技能组承担的任务区间越大，该技能组的劳动需求越高，相应工资也越高；反之，如果技术进步压缩了某一技能组可执行的任务范围，即使该技能组的劳动供给不变，其工资也会下降。

在这一框架下，计算机化和自动化通常被理解为对中等技能、常规任务的替代。假设新技术替代了一部分原本由中技能劳动者完成的任务，即压缩了中技能任务区间 $[I_L, I_H]$ 。这意味着中技能劳动者可执行的任务范围 $I_H - I_L$ 缩小。由上面的工资表达式可知：

$$w_M \propto \frac{I_H - I_L}{M},$$

这意味着中技能工资会下降。与此同时，如果被替代的任务边界发生调整，使低技能和高技能劳动者承担的任务范围相对扩大，则低技能和高技能劳动者的相对工资可能上升。于是，技术进步会导致：

$$\frac{w_H}{w_M} \uparrow, \frac{w_L}{w_M} \uparrow.$$

总结起来，给定计算机和自动化主要替代中等技能和常规任务的假设，任务模型预测中等技能劳动者的就业机会和工资回报会被压缩，高技能劳动者从复杂认知任务的扩张中受益，低技能劳动者则可能因为低端服务任务难以自动化而相对保留需求，最终形成工资和就业极化格局。这一结论与西方发达国家出现的现象吻合。以美国为例，Autor and Dorn（2013）发现，1980—2005年间，就业增长呈明显的U形分布：中间技能岗位的就业份额持续下降，而最低和最高技能岗位的就业份额明显上升。与此同时，Goos et al.（2014）也发现，在16个西欧国家，1993—2010年间，中等收入职业的就业份额合计下降了9.27个百分点，从56%左右下降到不足47%，而高收入和低收入职业的就业份额分别上升了5.62和3.65个百分点。

（三）任务模型的拓展

Autor提出的第三阶段“自动化—再任务化竞赛”分析框架可以被视为任务模型的一种拓展。Acemoglu and Restrepo（2018）提出，技术进步不仅替代现有任务，还会创造新任务，从而增加劳动力需求，而劳动需求的变化取决于自动化和新任务创造的相对力量。Acemoglu and Restrepo（2019、2022）对这两种影响进一步定义，指出自动化对劳动力需求具有替代效应，机器直接替代劳动者原本执行的任务，导致相关劳动需求下降；与此同时，新任务的出现具有再任务化或扩张效应，使劳动者进入新的任务领域，从而增加劳动需求。在宏观层面，这一框架主要用于解释劳动收入份额和总劳动需求的变化；而在微观层面，它更重要的含义在于自动化与新任务创造会改变不同劳动者之间的任务分配和工资回报。技术进步并不是简单地减少或增加劳动需求，而是重新划定不同劳动者能够执行哪些任务、进入哪些职业、获得哪些技能回报。如果自动化主要发生在某些群体原本集中的任务上，而新任务又主要出现在其他群体更容易进入的职业中，技术进步就会扩大群体间收入差距；反之，如果新任务能够吸收被自动化挤出的劳动者，则可能缓解不平等。

Autor（2022）强调，新任务创造本身也可能具有极化特征。1940—1980年间，美国面向非大学劳动者的新工作较多出现在生产、文员、销售等中等技能岗位；但1980年以后，非大学劳动者的新工作更多转向低薪个人服务业，而大学劳动者的新工作则越来越集中在专

业、技术和管理岗位。这意味着，新任务创造虽然能够抵消自动化对总体劳动需求的侵蚀，却未必能够创造高质量、广泛共享的就业机会。

Hampole et al. (2025) 将任务模型进一步细化，将直接替代效应与节省劳动力的间接再分配效应区分开来。该模型将 AI 引入为任务特定的无形资产，其作用表现为降低某一任务中资本的价格，从而使资本在该任务上替代劳动。模型中，一个职业由多个任务组合而成，劳动者可以在职业内部重新配置时间；企业则由不同职业的产出组合而成。因此，AI 对劳动需求的影响被分解为三个机制：第一，平均任务暴露度，即一个职业中有多少重要任务受到 AI 冲击。由于 AI 在被暴露任务上替代劳动，平均暴露越高，该职业在企业内部的劳动需求越低；第二，任务暴露的集中度，即 AI 冲击是否集中在少数任务上。若 AI 只替代部分任务，劳动者可以将精力转向未被替代、且与其他任务互补的活动，因此集中度越高，反而可能缓解甚至抵消替代效应；第三，企业层面的生产率扩张效应，即 AI 采用提升企业生产率、销售和利润后，企业整体扩张会增加对劳动的需求。因此，AI 在任务层面具有显著替代效应，但这种替代并不必然转化为职业或总体就业的大幅下降，因为职业内部任务重组和企业扩张会产生抵消力量。

Agrawal et al. (2026) 构建了一个不涉及资本的任务模型，将 AI 视作增强工人生产力的工具，并将工人分为 AI 专家工人和普通工人，任务分成可以使用 AI 工具完成的任务（需要 AI 专家）和只能由普通工人完成的任务。该模型认为工资不平等随着 AI 专家的占比增加而下降，随着技术进步而上升，AI 专家比例越高，技术进步对工资不平等的加剧效应越小。此外，工资不平等随着技能分布越均匀，不平等越低。

Gans (2026) 强调 AI 对工资和不平等的影响不能仅理解为对既有任务的替代，还要考虑 AI 打破原有岗位边界后，企业如何重新组合剩余任务。文章将 AI 引入为对部分任务的自动化冲击，但当部分任务被替代后，剩余任务可能被重新捆绑为更综合的岗位，也可能被拆分为更专业化的岗位。前者更偏好技能覆盖面广的劳动者，后者更看重不同劳动者的比较优势。因此，AI 不仅改变任务的分配，也改变任务的组合定价。

Autor and Thompson (2025) 从“专业知识”（expertise）的角度拓展了任务模型。由于现实中的职业往往是多个任务的捆绑，同一项任务在某些职业中可能属于核心专家任务，在另一些职业中则只是辅助性任务。AI 除了替代劳动者执行的任务数量，也会改变一个职业剩余任务组合的专业知识要求。若被替代的主要是低专业性、辅助性任务，剩余任务会更加依赖专业判断和经验，该职业工资可能上升，但合格劳动者范围缩小，就业可能下降；若被替代的主要是原本需要较高专业知识的任务，则该职业进入门槛下降，更多劳动者可以进入，但工资可能下降。

Benzell and Myers (2026) 从任务层面解释了人工智能对劳动收入不平等的非单一影响的原因。模型认为劳动者在不同任务上的能力并不完全相同，当 AI 在某一任务上的能力超过劳动者自身水平时，劳动者会倾向于使用 AI 完成该任务。因此，AI 对不平等的影响取决于两个因素，一是劳动者在不同任务上的技能是否相关，二是 AI 能力处于不同劳动者技能分布的什么位置。若不同任务上的技能正相关，即高技能者通常在多数任务上都更有优势时，那么在 AI 发展早期，AI 可能替代低技能者相对薄弱的任务，帮助其弥补能力短板，从而缩小生产率差距。但随着 AI 能力的进一步提升，并开始替代高技能者也擅长的任务，不平等可能重新扩大。若不同任务上的技能负相关，即不同劳动者各自在不同任务上具有优势，那么 AI 自动化某类任务会帮助原本在该任务上处于劣势的劳动者，其分配效应便取决于被自动化的是哪一类任务。由此看，现有 RCT 实验中关于 AI 缩小还是扩大生产率差距的混合发现并不矛盾，而是反映了任务结构、技能相关性以及 AI 能力阈值差异所导致的不同结果。

（四）微观分析框架小结

综合上述理论演进可以发现，从微观层面看，理解技术进步对不平等的影响，需要抛弃高技能受益、低技能受损的刻板印象。第一代“教育竞赛”模型强调技能供求变化，第二代任务模型强调常规任务替代，第三代“自动化一再任务化”框架则进一步指出，技术既会替代旧任务，也会创造新任务。因此，在技术进步中谁受益、谁受损，不仅取决于原有技能水平，还取决于劳动者能否进入新任务、获得与新技术互补的能力。

人工智能时代的新近研究进一步把这一问题推进到更细的层面。第一，研究对象不再只停留在职业层面，而是进一步关注同一职业内部的任务结构。同一个职业往往包含多种任务，这些任务受人工智能影响的程度并不相同。劳动者也可能在不同任务之间重新分配时间，因此，一个职业的人工智能暴露程度较高，并不必然意味着这个职业整体都会受到负面冲击（Hampole et al., 2025）。第二，研究重点从对劳动力的替代或互补，过渡到关注企业如何重新组织岗位具体任务。当人工智能接管部分任务后，企业可能把剩余任务重新组合成更综合的岗位，也可能把岗位拆分成更专业化的角色。不同的组织方式会改变企业对劳动者技能的要求，并进一步影响不同技能劳动者的工资回报（Gans, 2026）。第三，分析对象从单一技能水平扩展到多维技能结构：劳动者在不同任务上的技能相关性、AI 能力相对于劳动者技能的位置，会决定 AI 究竟是帮助弱者追赶还是放大强者优势。因此，人工智能对不平等的影响是不确定的。它可能降低部分任务的技能门槛，使低经验、低绩效劳动者获得追赶机会；也可能通过强化互补型技能、专业化分工和组织重构，提高高技能劳动者、AI 专家或具备比较优势劳动者的回报（Benzell and Myers, 2026）。这也是为什么 Autor（2022）把技术变革与劳动市场不平等的理论演化的第四阶段称为“AI 不确定性时代”的原因。

值得指出的是，围绕任务模型构建的分析框架也存在明显局限，主要是这一框架较少刻画企业和劳动者在技术采用过程中的激励约束。事实上，人工智能能否被实际采用、以何种方式进入生产过程，并不只取决于技术可行性，也取决于企业的成本收益计算、组织结构、产权安排、劳动合同和工资制度（Bessen et al., 2025）。例如，当企业拥有技术使用权并能够通过岗位重组分享技术收益时，其采用人工智能替代劳动的激励可能更强；而当工资规制、工会力量或内部晋升制度限制企业单方面调整岗位时，人工智能更可能以辅助劳动者的方式被引入。另一方面，劳动者是否主动使用人工智能，也取决于使用收益是否能够转化为工资、晋升或工作负担下降（Fügener, Walzner and Gupta, 2025）。如果劳动者担心技术使用会导致岗位被削减，或者其生产率提升主要被企业占有，那么个人层面的技术采用激励就可能不足。进一步地，任务模型通常也较少纳入产品市场竞争、平台垄断、企业市场势力等产业组织因素，而这些因素会影响企业能否将 AI 带来的生产率收益转化为利润、工资或价格下降（Gans, 2024）。因此，任务模型虽然为理解人工智能影响劳动需求提供了重要微观基础，但要完整解释人工智能对不平等的影响，还需要进一步结合企业组织、劳动制度和市场结构等因素。

四、实证证据

从劳动力市场需求侧的角度来看，技术进步会沿着供应链，通过市场竞争等渠道在行业和企业之间扩散；企业在接触到新技术之后，会根据自身的财务状况、组织结构和人力资本基础决定是否采纳技术；技术被采纳之后，会对任务结构和生产流程进行重塑。一方面，部分标准化、重复性、可编码的任务可能被机器或 AI 替代；另一方面，围绕技术使用、模型维护、流程协调、质量控制和结果验证的新任务也可能增加。任务层面的变化进一步推动企业内部岗位体系和组织结构调整，表现为不同层级岗位需求的变化、技术岗位和非技术岗位比例的变化，以及企业内部劳动分工的重新配置。最终，这些变化会反映为劳动雇佣的调整，

包括部分岗位减少、原有岗位职责改变，以及新岗位的设立⁶。从新增业务及新创企业角度看，新技术不仅改变既有生产方式，也会创造新的产品、服务和商业模式。例如，生成式人工智能可能催生模型训练、数据标注、智能体开发、AI 应用服务等新业务，最终创造新的岗位需求⁷。图 2 概括了这一影响路径。




图 2：技术进步影响企业劳动需求的作用路径

在上述作用路径中，多个环节都可能产生不平等，并体现在不同层面。首先，在行业层面，技术扩散和技术采纳往往具有明显的不均衡性。技术密集型行业、资本密集型行业或数字基础较好的行业更可能率先采纳新技术，而传统服务业、低生产率行业或小微企业所在行业可能面临较慢的技术吸收过程（Cai and Li, 2019; Kalyani et al., 2025）。其次，在企业层面，不同企业之间存在技术能力、资本约束、管理能力和数据资源的差异，领先企业可能通过技术采纳进一步扩大生产率优势，而落后企业则可能被迫退出或在市场竞争中处于不利位置（Bloom et al., 2012; Autor et al., 2020; Babina et al., 2024）。再次，在职业和岗位层面，技术进步通常不是等比例影响所有岗位，而是根据任务内容产生差异化影响：常规性、重复性、可标准化任务更容易被替代，而复杂认知、跨部门协调、客户沟通、监督验证和创造性任务可能相对受益（Autor and Dorn, 2013; Acemoglu and Restrepo, 2022）。最后，在个人层面，劳动者的教育水平、技能结构、年龄、性别、地区和职业流动能力都会影响其能否适应技术变化（Akerman et al., 2015; Deming, 2017）。由此，技术进步可能同时改变行业间不平等、企业间不平等、职业间不平等以及劳动者个体之间的工资和就业机会差异。

本节将首先介绍实证分析的常用数据、常见的度量指标，然后对实证发现进行综述，其中会着重讨论产生不平等的原因，以及体现不平等的层面。

（一）常用数据

图 2 在列出技术进步影响企业劳动需求的作用路径的同时，也列出了相关的数据。本小节介绍常用的数据来源，包括专利数据、招聘数据、上市公司年报以及工商企业注册信息等。

一是专利数据。专利数据能够反映新技术的产生、研发方向和创新强度，尤其适合刻画

⁶ 麦肯锡公司 2025 年的报告发现，超过半数的 AI 企业计划利用 AI 来转型业务，其中大多数正在重新设计工作流程（McKinsey, 2025）。德勤公司 2026 年的报告指出，34% 的受访组织已经开始利用 AI 进行深度转型，包括创造新产品和服务，或重塑核心流程，让人工智能能够端到端地执行这些流程，而人类则专注于判断、异常处理和战略监督（Deloitte, 2026）。

⁷ 国家数据局 2025 年数据显示，截至 9 月底，全国 7 个数据标注基地已引进和培育标注企业 362 家，标注从业人员达到 8.5 万人，带动数据标注相关产值 163 亿元。

人工智能、机器人、自动化、数字技术等特定技术领域的知识生产活动。中国专利数据来源于国家知识产权局（CNIPA）官方公告与授权文献库，完整记录了自 1985 年《专利法》实施以来在中国申请的发明、实用新型及外观设计三大类专利，总计大约六千万项。每条专利记录均包含以下变量：专利名称、申请人地址、摘要、IPC 号、专利引用、申请年份、公开年份、授权年份、专利类型、申请号、申请人。该数据集覆盖 40 年完整时间序列，结构规范、核心字段覆盖率超过 99%，适用于技术创新趋势分析、技术生命周期预测及科技政策评估等场景。专利数据的优势在于能够较早捕捉技术前沿变化，并提供反映技术特征的关键词，便于与其他数据结合度量技术扩散和技术采纳。然而，专利更多反映研发和知识产出，并不必然意味着技术已经被企业实际采纳或进入生产过程。

二是招聘数据。中国主要的在线招聘平台包括智联招聘、前程无忧、58 同城以及猎聘等。公司发布的招聘广告，通常包含雇主名称、职位名称、职业类别、发布日期、工作地点、学历要求、职位空缺数量和薪资等内容，以及长约数百字的具体的职位描述。例如，莫怡青等（2026）使用了前程无忧平台 2014-2024 年期间招聘数据。经过去重，识别出了 254 万家企业在该平台发布的 7300 万条招聘广告，涉及约 3 亿个职位空缺。对比发现，各城市的招聘职位数量与城市的就业规模之间存在显著的相关关系，表明招聘数据在区域层面能够较好反映就业规模的空间。招聘数据具有公开可得、样本量大和更新及时等特点，从而能够覆盖传统调查数据难以捕捉的动态变化，能够观察岗位层面的任务和技能变化，这对一些快速发展的行业尤其重要。招聘数据的缺陷在于其主要反映新增招聘需求，并不能完全等同于企业存量就业结构。此外，企业在线上发布职位会具有一定的选择性，可能与其实际的劳动需求不完全吻合（Kurekova et al., 2015）⁸。除了衡量就业信息，还可以通过分析招聘数据包含的岗位任务和技能要求，反映技术扩散和技术采纳的过程。

三是上市公司数据。上市公司年报包含企业经营范围、主营业务、研发投入以及管理层讨论等信息。通过文本分析方法，可以识别企业是否在年报中披露人工智能、数字化、自动化、智能制造等相关内容，从而构造企业技术采纳或技术关注度指标。与此同时，上市公司数据还可以提供企业层面的财务表现、资本投入、研发支出、劳动雇佣规模和员工结构信息，可以进一步考察技术采纳对企业生产率、劳动收入份额、岗位结构和薪酬分布的影响。上市公司年报的优势在于财务变量较为系统、可追踪性较强，可以用于识别企业技术采纳、组织调整和存量就业的变化。然而，上市公司样本更偏向规模较大、治理结构较完善的企业，在代表性方面存在局限。

四是工商企业登记注册数据。工商登记数据通常包含企业名称、统一社会信用代码、注册资本、成立时间、注销或吊销时间、注册地址、经营范围、行业分类、法定代表人、股东信息和分支机构信息等，可以用于识别特定技术领域相关企业的进入，例如人工智能、软件服务、智能制造、工业互联网、数据服务等新企业的成立情况，也可以用于描述企业经营范围变化和市场进入退出等动态行为。

（二）常见度量指标

1. 技术暴露度

文献常采用“技术暴露度”来衡量技术对工作任务或岗位的潜在影响。按照 Staneva and Elliott（2023）的总结，技术暴露度的测算存在 5 种思路，包括基于工作任务、专利、岗位招聘、技能标尺、技能等进行新技术影响的评估。这些思路的核心是结合标准化量表、专家评分、自然语言处理、模型预测等手段，比较某种技术潜在应用和人所具备的技能或者所能

⁸ 莫怡青等（2026）将招聘数据与中国人口普查、企业工商登记注册数据的分布对比，发现其更侧重城市中相对年轻化、高学历、中高工资的职位招聘需求，对传统行业 and 低学历、低技能职业的覆盖相对不足。

完成任务的相似度，从而估算出在多大程度上该技术能够完成人工进行的工作。具体而言，通常从任务出发，判断每一项任务与特定技术能力之间的匹配程度，再将任务层面的可替代性加总到职业、行业、地区层面，最后形成“技术暴露度”或“技术暴露指数”指标。

构建技术暴露度的早期代表性研究是 Frey and Osborne (2017)。该文基于 O*NET 数据库中的 702 个美国职业⁹，邀请机器学习和机器人领域专家判断其中一部分职业是否可以被计算机化，如果一个职业所需的任务较少依赖感知与操作、创造性能力，则该职业更容易被自动化，再使用机器学习方法外推到所有职业，估算各职业的计算机化的概率。Webb (2020) 将暴露度构建推进到文本匹配的框架，文章利用专利文本与职业任务描述文本进行相似度匹配，从而构建不同技术对任务的暴露程度。Felten et al. (2019) 首先定义了若干 AI 能力维度，然后评估 AI 能力与 O*NET 中职业能力要求之间的关联程度。随后，对于每个职业，根据其所需能力的重要性加权，得到职业层面的 AI 暴露度-AI Occupational Exposure (AIOE)。该文还进一步将 AIOE 按就业权重加总到行业层面和地区层面。Eloundou et al. (2024) 一文的初稿于 2023 年初 ChatGPT 发布之后发表，该文使用 O*NET 职业任务数据，结合人工评估者和 GPT-4 对任务进行分类，构建了职业层面的大语言模型暴露指数，引发了广泛关注。

张丹丹等 (2025) 进一步将基于美国职业体系构建的大语言模型技术暴露度扩展到中国职业体系。与既有研究通常将中国职业名称直接匹配到美国职业分类不同，该研究尝试基于中国本土岗位工作内容构建独立的技术暴露指标，从而避免不同国家中“同名职业但工作内容并不完全一致”所带来的偏误。例如，同样被称为“销售”或“行政助理”的岗位，在中美两国可能承担不同的任务结构和工作要求，直接套用美国职业暴露度可能导致测度失真。具体而言，该研究利用 2018 年 1 月至 2024 年 5 月智联招聘平台约 125 万条招聘广告信息，重点提取岗位职责、工作内容等文本描述，并将其与美国 O*NET 数据库中的 2087 个“详细工作活动”进行匹配。该研究借助 AI 工具对每一项详细工作活动被大语言模型替代的可能性进行评分，再识别每个招聘岗位实际包含哪些工作活动及其相对重要性，据此构建岗位层面的暴露度，并进一步汇总为职业层面的暴露指数。研究发现，基于中国任务内容构建的暴露指数与基于美国劳动力市场资料构建的指数 (Felten et al., 2023) 具有较高相关性，但并不完全一致，说明中国职业结构具有自身特征，需要进行独立评估。

除了直接构造人工智能暴露度，现有研究还使用其他职业层面的指标来刻画技术的影响。例如，资本体现型技术进步暴露度 (capital-embodied technical change) (Caunedo et al., 2023) 衡量不同职业暴露于资本品效率提升的程度，并估计了职业层面的资本-劳动替代弹性。又比如，常规任务密集度 (Routine Task Intensity) 指标主要用于刻画职业任务是否具有规则化、程序化和可编码特征 (Autor and Dorn, 2013)。职业包含的常规任务比例越高，越容易被计算机、软件、机器人或算法替代；非常规认知任务和非常规互动任务则更依赖判断、沟通、创造和情境适应。与 AI 暴露指数相比，这一指标更关注任务是否可被规则化编码，而 AI 暴露指数则更关注人工智能是否具备完成或加速这些任务的能力。此外，Autor and Thompson (2025) 构造了职业任务的专业知识含量 (expertise) 指标，用来衡量被 AI 替代的任务在职业内部是核心专家任务还是辅助性任务，强调技术冲击的分配效应取决于这种专业知识含量指标在职业内的分布情况。

2. 技术采纳

一个职业的技术暴露度高，并不意味着技术一定会被该职业实际应用，也不必然意味着劳动需求立即下降。与之相对应的是技术采纳指标，它强调的是技术是否真正进入生产过程。

⁹ O*NET (Occupational Information Network) 是美国劳工部支持的一个全面的在线职业信息数据库，它为上千种职业提供了详细的标准化分类。SOC (The Standard Occupational Classification Code) 即标准职业分类代码，是在包括美国在内的多个国家使用的、根据工作内容对不同职业进行分类和归类标准。

就人工智能技术来说，企业是否采用人工智能，往往受到成本收益、组织调整、数据基础设施、法律监管、伦理约束以及劳动者技能等多方面因素影响，反映了人工智能对劳动市场产生实际影响的实现路径。正如 del Rio-Chanona et al.（2025）综述所强调的，仅依赖暴露指标容易高估技术冲击，因为大量研究衡量的是自动化的技术可能性，而非现实中的采用速度与范围。例如，大模型公司 Anthropic 利用 Claude 模型使用数据发布的报告显示，截至 2026 年初，生成式 AI 的实际应用主要集中在计算机与数学、法律、艺术与媒体、办公室与行政以及销售等职业类别。相比之下，管理和建筑与工程类职业虽然具有较高的理论 AI 暴露度，但实际观察到的 AI 使用覆盖度仍然较低（Anthropic, 2026）。

除了人工智能技术的提供商通过后台行政数据测算 AI 的实际使用情况之外，研究者通常使用如下几种办法，在企业、行业、职业等层面构建起采纳新技术的度量指标。

第一种是问卷调查法。调查法是最直接的度量方法，其基本思路是通过企业、机构、管理者或劳动者调查，直接询问受访对象是否在生产、经营、管理或具体工作任务中使用 AI 或生成式 AI。这一方法的最大优势在于采纳率具有清晰的经济含义，可以直接解释为某一类企业、机构或劳动者报告使用 AI 的比例。例如，McElheran et al.（2024）使用美国 2018 年 Annual Business Survey 发现，2017 年使用至少一种 AI 技术的企业比例低于 6%，但按就业加权后超过 18%；Bonney et al.（2026）基于美国 Census Bureau 的 BTOS 数据发现，2025 年底约 18% 的美国企业在至少一个业务功能中使用 AI，就业加权后达到 32%；Bick et al.（2025）的劳动者调查则显示，到 2024 年底，近 40% 的美国工作年龄人口曾使用生成式 AI，在上一周工作中曾经使用过的在职劳动者达到 23.1%。

就中国而言，有许多机构向企业和个人发放问卷询问使用 AI 的情况并据此发布报告。如中国互联网络信息中心发布的《第 57 次中国互联网络发展状况统计报告》显示，截至 2025 年 12 月，生成式人工智能用户在整体人口中的普及率为 42.8%。智联招聘 2025 年 9 月发布的《职场“人机共生”演进情况调研报告》显示，在 3112 名个人受访者中，有 78.2% 的劳动者每周都会借助 AI 开展工作。这些报告能够提供及时的 AI 使用动态信息，但在调查样本的选取上存在代表性不足的问题。其他更具样本代表性的研究报告包括：2024 年的全国经济普查首次收集了企业 AI 使用情况，报告的企业 AI 采用率约为 20%；北京大学企业大数据研究中心调查发现，2026 年第一季度小微经营者在经营中应用 AI 的占比为 25.5%。

调查法的主要问题在于，其结果高度依赖 AI 的具体定义、问题表述、样本、加权方式和受访者身份。企业管理者可能高估技术采纳率，因为 AI 已成为企业竞争力和技术先进性的信号；普通员工或行政人员则可能低估采用率，因为他们未必了解企业内部其他部门的技术使用情况。

第二种方法采用企业专利进行度量，主要衡量企业是否从事 AI 技术研发、发明或商业化。Calvino et al.（2022）将知识产权记录、公司网站、在线招聘和企业财务数据结合起来识别英国公司 AI 利用率。这类方法的优点是数据相对客观，专利申请和授权是具有成本的正式行为，因此非常适合研究 AI 技术创新、AI 产业供给、前沿技术积累以及 AI 创新企业的空间和行业分布。但是，专利法一般不能给出有经济解释的技术采纳率。原因在于申请 AI 专利的企业通常是 AI 技术开发者或供应商，而不是所有使用 AI 的企业；普通企业完全可以通过购买商业化大模型服务、订阅 AI 软件、调用 API 或使用嵌入式 AI 工具实现对 AI 的采用，而不需要申请任何专利。反过来，一个企业即使拥有 AI 专利，也可能只是将技术对外销售，并不意味着其内部生产、管理或组织流程已经广泛采用 AI。因此，专利法衡量的是 AI 创新，而不是 AI 技术采纳。

第三种度量方法依靠企业自我披露的信息，主要是利用企业年报、监管文件、财报电话会、官网或其他公开文本中的 AI 相关表述，构造 AI 关键词频率、AI 关注度或 AI 战略取向

指标。这类方法在上市公司研究中尤其常见。例如，姚加权等（2024）使用中国上市公司年报中的 AI 相关关键词或标准化词频来衡量企业对人工智能的关注、布局或战略投入。其主要优势是覆盖面较广，尤其适合上市公司样本；年报和公开披露材料可以形成较长时间维度的面板数据，并且容易与企业财务表现、生产率、投资、创新和市场价格等结果变量匹配。这一方法的局限也很明显，AI 相关文本并不等于真实采用。企业可能在年报中讨论 AI 是为了描述未来战略、回应政策导向、吸引投资者、宣传产品或进行市场信号释放，而未必已经在生产经营中部署 AI。关键词出现次数更多，也不一定意味着 AI 使用更深入。因此，这类方法通常不能直接转换为技术采纳率，它更准确地衡量的是人工智能相关战略方向和市场策略。

第四种方法利用招聘广告识别 AI 相关岗位或 AI 技能需求，进而在企业、行业、地区或时间层面构造 AI 技术采纳率或 AI 投资指标。如果企业发布 AI 相关岗位，说明其正在为 AI 能力建设投入人力资本。相比于企业自我披露的年报等信息，招聘广告反映的雇佣行为可能更接近真实企业组织行动。例如，Calvino et al.（2022）使用 AI 相关招聘广告数占总招聘数的比例来衡量英国企业的 AI 采用密度；Aleksseva et al.（2026）基于美国招聘数据识别企业 AI 相关岗位，构造公司层面的 AI 采用指标；Shi et al.（2025）使用在线招聘数据和大语言模型分类器构造 AI 岗位密度，并发现 Russell 1000 企业的 AI 相关岗位占比从 2018 年的 0.22% 上升到 2025 年的 0.78%。针对中国企业而言，Li et al.（2026）发现，截至 2025 年底，约 25% 的中国上市公司企业已经采纳生成式人工智能，其中大型企业和服务业企业的采纳率相对更高。

招聘数据的优势在于频率高、企业层面可观测、能够定位 AI 被引入的具体职能和岗位，例如技术研发、产品、营销、客服、管理或数据分析等。但是，招聘法衡量的仍然不是全部真实采用，而是企业对 AI 人力资本和组织整合能力的投资。如果企业员工个人使用 AI 工具，或者企业通过外包、API 和第三方服务实现 AI 应用，这些技术采纳就不一定会反映在招聘广告中。

3. 替代和互补的区分

技术进步对劳动需求同时具有替代效应与互补效应，但二者在经验研究中往往很难区分，因为同一项技术可能既替代人工完成既有的一些任务，又辅助人工更好的完成其它一些任务。技术进步在任务层面的替代与互补，以及对新任务的创造，最终会体现在职业层面，从而对不同职业的就业产生正向或是负向的冲击。Autor et al.（2024）对此作出了有代表性的尝试：该文结合美国人口普查中的新职业名称、专利文本以及职业任务描述，构造了“增强型创新”和“自动化创新”的度量，分别对应互补与替代两种效应。研究发现，增强型创新更容易催生新工作和新职业，并提高相关职业的劳动需求；而自动化创新则更多压低相关职业的就业和工资总额。

一些研究试图在度量职业的技术暴露度的基础上，进一步将职业受益于新技术的程度进行分离和单独的度量。例如，Pizzinelli et al.（2023）在 Felten et al.（2023）的职业 AI 暴露度基础上，构造了“AI 互补性指数”，进而得到一个经过互补性调整的暴露度指标。其逻辑是：同样是高 AI 暴露职业，如果工作需要面对面沟通、责任承担、复杂判断、非结构化环境或较高培训水平，那么 AI 更可能作为辅助工具而不是直接替代劳动；反之，高暴露但低互补性的职业则面临更高替代风险。文章据此将职业划分为“高暴露—高互补”和“高暴露—低互补”等类型，发现管理者和专业人员虽然 AI 暴露度高，但互补潜力也高；文员类岗位则属于高暴露、低互补，更可能面临替代压力。胡涟漪等（2026）则是直接对职业层面的 AI 暴露度进行线性分解，与“AI 易于学习任务”相匹配的部分被定义为替代效应，与“AI 难以学习任务”相匹配的部分被定义为互补效应，与新增任务相关联的部分被定义为创造效应，三

者之和等于总的暴露度。基于这一分解，文章发现 AI 暴露度对招聘需求有正向影响，且主要来自互补和创造效应。

莫怡青等（2026）在技能层面刻画了不同技能之间的互补关系。该文利用在线招聘文本识别岗位中的多类技能需求，发现人工智能技能通常与数据分析、专业软件、技术支持、认知能力、金融专业能力和文字能力等技能共同出现，表明 AI 相关岗位更需要复合型人力资本，而不是单一技术能力。与此同时，该文借鉴 Pizzinelli et al.（2023）构造了职业层面的 AI 互补性得分，并发现人工智能产业政策实施后，招聘结构显著向 AI 互补性更高的职业集中，说明 AI 不仅改变单个岗位的技能组合，也可能推动劳动力需求向更能与 AI 协同工作的职业转移。其不平等含义在于，能够将 AI 技能与行业知识、分析能力和表达能力结合起来的劳动者更容易获得工资溢价，而技能结构单一、难以完成技能组合升级的劳动者可能面临更大的进入障碍。

（三）实证结果综述

1. AI 对谁影响更大？——人工智能影响的异质性

根据上文的理论分析，人工智能的影响高度依赖于任务特征、技能结构以及组织环境。从任务特征的角度，对于目标明确、流程标准化、上下文依赖较低的任务，生成式 AI 通常具有较强的效率提升与替代能力，例如文本写作（Noy and Zhang, 2023; Choi et al., 2024）、翻译（Yilmaz et al., 2023）、基础代码生成（Peng et al., 2023）以及客服服务（Brynjolfsson et al., 2025a）。而对于依赖复杂判断、创造性思维、跨情境协调或隐性知识的任务，AI 的作用则更具有不确定性。

从劳动者异质性来看，一个重要问题是：低技能劳动者还是高技能劳动者受益更多？回答这个问题，需要将任务特征与劳动者技能特征放到一起考虑。在相对简单、标准化程度较高的任务中，AI 往往更有利于低技能、低绩效或经验不足者。例如，Noy and Zhang（2023）发现，在专业写作任务中，能力较弱参与者的表现提升更明显；Peng et al.（2023）发现，经验较少的程序员从微软的大模型助手 GitHub Copilot 中获益更多；Brynjolfsson et al.（2025a）在客服场景中发现，AI 辅助显著提高了新手客服的绩效，且提升幅度大于有经验员工。类似地，Choi et al.（2024）发现，表现较差的法学生在法律写作任务中受益更明显。总体而言，在规则相对清晰、可标准化的任务中，AI 往往能够发挥“能力补偿”（capability equalization）的作用，降低技能门槛，使低技能劳动者更接近高技能者的表现水平。

然而，在复杂、非结构化或高度依赖策略判断的任务中，AI 并不一定缩小差距，甚至可能强化原有能力差异。Otis et al.（2023）在肯尼亚企业家的实验中发现，AI 对平均绩效没有显著影响，但高绩效企业家的收入上升，低绩效企业家的收入下降。Jia et al.（2024）在电话营销研究中发现，当 AI 自动筛选掉容易成交的客户后，剩余任务变得更加复杂，高技能销售人员反而相对受益。Roldán-Monés（2024）的研究也发现，AI 更有利于高能力参与者。Dell’Acqua et al.（2023）进一步指出，AI 的能力边界具有明显非连续性：在 AI 能力范围内，咨询师绩效显著提高，且中低绩效者收益更大；但一旦任务超出 AI 能力边界，AI 辅助反而可能降低表现，此时不同绩效的咨询师的差距可能扩大。因此，AI 对不同技能劳动者的影响高度依赖任务复杂度和技术能力边界。

除了技能和能力差异外，AI 的影响还表现出明显的职业、年龄与职业生命周期等方面的异质性。与以往主要影响低技能、体力型和规则化工作的自动化技术不同，生成式人工智能的暴露对象更多集中在法律、金融、教育、媒体和咨询等认知型、白领职业。这意味着，AI 对高教育、高工资职业的影响可能比以往自动化更强。

一个值得关注的新现象是，AI 对职业生涯初期劳动者的影响可能更为不利。虽然大量

实验研究发现，新手劳动者在 AI 辅助下往往能够获得更高的短期生产率提升，但这并不意味着企业对初级劳动者的需求会上升。其原因在于，初级员工通常承担大量标准化、辅助性和训练性任务，这些任务不仅创造短期产出，更构成劳动者积累经验和进入高收入职业的重要“职业阶梯”（career ladder）。当 AI 能够完成这些任务后，企业可能倾向于保留高级员工和核心岗位，同时减少初级岗位招聘，从而形成新的就业机会不平等。Teutloff et al.（2025）发现，在与 AI 互补的职业中，经验和专业知识的重要性反而上升，企业对初级员工的需求下降；Hosseini and Lichtinger（2025）基于美国招聘与简历数据发现，采用生成式 AI 的企业在 2023 年后明显减少初级岗位招聘，且对中等层级学校毕业生影响更大；Brynjolfsson et al.（2025b）使用行政工资数据发现，在 AI 高暴露职业中，22—25 岁劳动者就业相对下降约 13%，而更有经验劳动者的就业则保持稳定甚至增长。这意味着，AI 可能在短期内通过提高新手劳动者生产率缩小绩效差距，但在长期中却通过削弱职业训练路径和减少初级岗位机会，加剧代际和职业发展机会的不平等。

2. AI 是否扩大不平等？——来自实证研究的综合判断

关于人工智能是否会扩大劳动收入不平等，现有文献尚未形成一致结论。总体来看，研究结果可以概括为两类相反但并不矛盾的发现。一类研究认为，人工智能具有缩小不平等的潜力。与传统自动化主要替代低技能劳动不同，暴露于人工智能技术的更多是认知型、白领和高工资职业。因此，AI 可能通过压缩部分高技能职业的工资溢价，降低职业间收入差距。Klein Teeselink（2025）基于英国数据发现，高暴露职业中的岗位减少更多集中于高工资行业，其结果更接近于压缩职业工资差距。De Souza（2025）使用巴西行政数据也发现，AI 在办公室岗位中减少中高工资劳动者就业，但在生产部门增加低技能年轻劳动者就业。此外，在大量实验研究中，AI 对低能力者、新手和低绩效者的更大生产率提升，也意味着 AI 在一定条件下可能发挥“追赶效应”，降低个体间能力差距。

另一类研究则强调，AI 可能通过新的互补关系与技能溢价机制扩大不平等。尽管 AI 可以提高普通劳动者生产率，但 AI 使用能力、AI 互补技能以及对复杂任务的驾驭能力本身可能成为新的稀缺资源。Pouliakas et al.（2025）发现，欧洲劳动力市场中 AI developers 具有显著工资溢价；Gambacorta et al.（2025）发现，GenAI 使用与约 2% 的收入回报相关，且 AI 使用更集中于男性、高教育和年轻劳动者；Bick et al.（2025）也发现，生成式 AI 使用者具有更高工资水平。

3. 来自中国的实证证据

（1）生成式人工智能之前的数字技术的影响

大部分关于技术进步与中国劳动市场分配效应的研究，主要围绕工业机器人、计算机化和一般意义上的企业数字化转型展开。已有研究发现，2010 年以来中国劳动力市场呈现就业极化、新职业分布不对称和职业技能溢价等特征，任务偏向型技术进步成为解释劳动力市场结构变迁的重要视角（王永钦、董雯，2023）。基于职业文本构建的技能指数进一步显示，1990—2015 年间，高抽象、低常规和高社交职业的就业份额持续上升，尤其是同时具有抽象和社交属性的复合型职业增长更快；与此同时，不同教育水平、年龄、出生队列和户籍身份群体在技能结构上存在明显差异（胡涟漪等，2024）。这些发现说明，数字技术扩散首先改变的是任务内容和技能组合，进而通过劳动者禀赋差异表现为不平等结果。

以工业机器人为代表的自动化技术进一步揭示了这种结构性变化的机制。相关研究普遍发现，机器人应用并不必然导致就业总量下降，企业可能借助成本降低、生产率提高和市场份额扩张增加总体用工需求（李磊等，2021；肖挺等，2025）。但是，这种就业扩张具有明

显的结构性偏向：机器人更容易替代可编码、重复性和程序化程度较高的常规任务，同时与高级认知、复杂问题解决、资源管理和社会互动等非常规任务形成互补，进而提高非常规任务劳动者的工资回报，扩大常规任务与非常规任务之间的收入差距（余玲铮等，2021；陈岑等，2023）。在个体层面，机器人应用会推动部分劳动者从繁重、常规岗位转向非繁重、非常规岗位，但通用性或专用性技能较弱的劳动者、非正规就业者和女性劳动者面临更高的调整成本，已育女性还可能遭遇更明显的“母职惩罚”（汪前元等，2022；王林辉等，2023）。此外，机器人应用增加了企业对可迁移技能的需求，并可能降低部分劳动者原有职业与技能之间的合意性：一部分学历不足但能够借助智能设备完成新任务的劳动者可能实现向上流动，另一部分不能适应岗位重构的劳动者则面临离职风险和工资损失（王林辉等，2024）。

因此，在工业机器人应用阶段，技术进步的不平等效应主要体现为任务结构和岗位类型的重新排序：就业总量效应可能并不显著为负，但收益更可能流向高技能、非常规任务和技术管理类岗位，调整成本则更多集中于常规任务、低技能和劳动密集型岗位。这一经验背景也构成理解人工智能影响的参照基准。

（2）人工智能与任务—技能结构重组

与工业机器人主要作用于制造业中的体力和常规任务不同，人工智能尤其是生成式人工智能开始进入认知型、服务型 and 知识型工作。较早的研究发现，智能化替代风险在低教育、大龄和流动人口等群体中更高，程式化、非认知交互型职业的替代风险更大，而技能宽度较高、非程式化认知交互型职业的风险较低（周广肃等，2021；王林辉等，2022）。随后，基于企业、招聘和专利数据的研究进一步表明，人工智能会减少企业对常规低技能岗位的需求，增加对非常规认知、技术、管理和社交型岗位的需求，并可能通过生产率提高、市场规模扩张和新岗位创造增加企业整体劳动需求（尹志锋等，2023；陈琳等，2024；姚加权等，2024）。

近期的研究进一步将分析单位从职业类型推进到职业内部的任务组合。胡漩漪等（2026）利用中国网络招聘数据与专利数据，将人工智能对任务的作用分解为替代效应、互补效应和创造效应。该文发现，2015—2021年间，人工智能显著推动了职业层面的招聘需求增长，且正向影响主要来自互补效应和创造效应，替代效应尚未在净招聘需求中占据主导。根据该文核算，2016—2021年人工智能引致的岗位净增长约为113.7万个，占招聘平台新增岗位总量的2.6%。这一结果表明，在中国人工智能扩散的较早阶段，仅以“技术替代岗位”的视角理解其就业影响并不充分；人工智能也会通过增强既有任务和创造新的工作内容扩大部分岗位需求。

但岗位增长并不意味着所有劳动者均等受益。上述研究同时发现，人工智能显著提高了对具有中等教育或研究生学历、较丰富工作经验、理工科专业背景以及复合型技能劳动者的需求。莫怡青等（2026）从招聘文本中的技能需求出发，发现AI相关岗位不仅要求人工智能、机器学习、数据分析、技术支持等专业技术能力，还更加重视金融相关、文字能力、专业软件等跨领域技能；AI技能在劳动力市场上获得平均约8%的工资溢价，与人工智能相关度较高的技能同样获得正向回报。由此可见，人工智能不仅提高对单一技术专长的需求，还是重新定义了岗位所需要的技能组合：能够把AI技术与行业知识、分析能力和协作能力结合起来的劳动者更容易获得新机会，而技能结构单一、难以完成技能转换的劳动者则可能被排除在新岗位之外。

人工智能还可能通过改变劳动力市场的匹配过程影响就业机会的分配。于航等（2026）利用2021年1月至2025年7月约162万条岗位—求职者匹配记录，构建职业层面的AI暴露度以及学历和专业错配指标。该文发现，尽管样本期内中国劳动力市场整体错配程度有所上升，但在ChatGPT等大语言模型冲击之后，高暴露度职业的纵向错配相对下降，其机制在于岗位需求信号变得更明确，同时技能要求和学历门槛随之提高。这个结果具有双重含义：

一方面，AI 可能减少低效匹配，提高求职者与岗位之间的教育适配程度；另一方面，更清晰、更高的技能门槛也可能使教育和技能不足的劳动者更难进入高暴露岗位，从而将不平等从“匹配失准”转化为“进入机会受限”。

（3）工资、收入与就业机会差距：人工智能分配效应的双重方向

在工资和收入结果方面，针对中国劳动力市场的研究发现呈现出明显的双重性。一方面，人工智能技术可能提高劳动生产率、增加企业整体岗位需求，并提高掌握 AI 技能和复合技能劳动者的收入。另一方面，这种收益并不均匀分布，人工智能可能扩大不同教育和技能层级之间的工资差距（何小钢等，2026；蒋为等，2025）。莫怡青等（2026）的研究发现，人工智能提高了平均工资和技能多样性回报，但也扩大了教育水平与技能组合不同的劳动者之间的工资差异。刘行等（2025）则发现，人工智能通过简化和标准化部分工作任务，提高了企业对灵活用工的需求：人工智能暴露度每提高一个标准差，企业灵活用工需求占总用工需求的比例显著提高 1.13 个百分点。其机制在于，企业可以利用成本较低的灵活用工人员与人工智能协作，替代部分低学历、低工资和低经验的全职员工。这意味着，AI 可能在提高企业用工灵活性和经营绩效的同时，增加低端全职岗位被转化或替代的风险。

生成式人工智能对零工的冲击，则提供了更加直接的收入不平等证据。张艺、姜珊（2026）使用中国大型招聘平台中覆盖 2022 年 7 月至 2023 年 6 月的 500 多万条在线兼职招聘信息，并依据职业大典中的任务内容构造生成式 AI 暴露度指标。研究发现，高暴露职业主要集中于网络编辑、程序开发、翻译、设计和写作等认知型零工岗位；ChatGPT 带来的冲击，导致这些岗位的日工资水平平均下降约 19.9%。进一步的异质性分析显示，高收入、线上工作、服务业和非高技术行业岗位受到的工资冲击更加明显。机制检验表明，工资下降主要来自企业对认知型零工岗位需求的减少，以及城市层面职业结构中此类岗位占比的下降，而非劳动供给短期增加所致。这一发现具有重要的不平等含义。传统自动化通常被认为更容易冲击低技能、体力或常规劳动者，而生成式人工智能开始对原本工资较高、具备一定专业知识、依托线上平台承接任务的认知型零工产生明显替代效应。由此，人工智能可能在某些场景降低高技能或高收入职业的相对优势，但也可能加剧零工劳动者的收入不稳定性 and 就业脆弱性。结合灵活用工研究可以看到，AI 对收入分配的影响不仅发生在正式岗位工资差距上，也会体现为全职工作与灵活就业之间、稳定职业路径与短期任务型就业之间的机会差距。

此外，已有研究还从劳资分配关系和组织效应角度提供了补充证据。例如，部分研究发现，AI 可能降低企业的劳动力市场垄断势力，改善劳动者相对于企业的分配位置（苏治等，2025）；另一些研究则强调 AI 通过促进协同创新和企业扩张增加新的就业机会（权小锋、李静蕾，2025）。因此，人工智能对工资和收入不平等的影响并不存在单一方向，而取决于其在具体场景中更主要表现为任务替代、能力增强、新岗位创造，还是用工关系重构。

（4）性别维度：人工智能是否可能缓解部分群体差距？

性别是观察技术进步异质性影响的一个重要维度。既有关于互联网、信息通信技术和数字经济的研究表明，数字化可能提高女性劳动参与率、扩大女性就业机会；关于工业机器人的研究则发现，其性别效应具有不确定性，这与机器人主要替代体力和常规任务，而男女劳动者在这些任务上的职业分布不同有关。人工智能与此前数字技术的重要差异在于，它更多进入分析、沟通、预测和部分非常规认知任务，因此可能对就业性别差距产生新的影响。

李力行、莫怡青（2025）区分工业机器人、计算机软件和人工智能三类数字技术，利用人口普查、CFPS 和在线招聘平台简历数据考察几种数字技术的暴露程度与就业性别差异之间的关系。该文发现，自动化暴露程度较高的职业通常具有更高的男性就业占比，而人工智能暴露程度较高的职业中女性就业占比相对更高。利用 CFPS 数据的分析进一步表明，在人

工智能暴露程度较高的职业中，女性与男性之间的工资和工作时间差距有所缩小：职业的人工智能暴露程度每提高一个标准差，女性相对于男性的工资提高约 12%，女性与男性之间的的工作时间差距也相应缩小。对简历投递数据的分析显示，女性对人工智能高暴露职业表现出更强的求职意愿，并更倾向于凭借相关专业技能在不同行业之间寻找就业机会。

这些发现表明，人工智能并不只是产生新的替代风险，也可能通过增强认知、分析、沟通和跨行业适用的专业技能，对女性劳动者产生一定的赋能效应。相较于机器人对体力和操作型岗位的冲击，AI 高暴露职业中女性原有的技能和职业分布可能更容易与技术形成互补，从而在工资和就业机会方面缩小与男性的差距。不过，女性能否持续受益，取决于其能否进入 AI 高暴露且技术互补性较强的岗位，能否获得必要的复合技能培训，以及企业内部晋升和组织调整是否给予女性平等的职业发展机会。由此，AI 对性别不平等的影响更接近一种条件性的赋能效应，而不是技术扩散自然带来的结果。

（5）补充性的宏观证据

上述研究主要关注劳动力市场中的就业、工资、技能需求和群体差异。作为补充，一些针对中国情境的宏观模型研究进一步讨论了人工智能如何通过劳动收入份额、资本回报和财富分配影响更广义的不平等。孙浩宁等（2026）构建包含任务分配与代际交叠结构的动态一般均衡模型，指出当人工智能对劳动任务产生广谱替代时，劳动收入份额可能下降，资本与劳动之间的横向收入差异随之扩大；同时，新进入劳动力市场的世代还可能承担人力资本贬值和职业机会减少的成本，形成代际分配失衡。该文的政策模拟表明，相比单纯限制自动化或实施劳动雇佣补贴，配合转移支付的智能化服务税可能更有利于兼顾效率与公平。陈斌开等（2026）则构建融合人工智能内生技术进步与家户异质性的动态一般均衡模型，并利用中国相关数据进行校准。该文将人工智能区分为岗位替代型和岗位增强型技术，指出当前中国人工智能技术进步可能呈现岗位替代偏向，从而提高资本回报率和技能溢价，加剧财富不平等；尽管技术进步提高了经济增长率，但增长收益不足以完全抵消分配恶化。其模拟结果进一步说明，岗位增强型研发补贴、数字基础设施投资以及适当的再分配政策，有可能减缓人工智能带来的不平等效应。

这些宏观模型分析与前述微观证据形成了呼应。微观研究所揭示的任务替代、复合技能需求提高、灵活就业扩张和认知型零工工资下降，可能在宏观上表现为劳动收入份额下降、技能溢价上升以及资本收益更加集中；而互补效应、新任务创造、匹配效率改善和部分性别差距缩小，则构成缓解分配恶化的可能力量。因此，理解人工智能对中国不平等的影响，既需要关注技术能否促进就业增长，也需要考察增长收益如何在资本与劳动、不同技能劳动者、不同就业形态以及不同人口群体之间分配。

（6）小结

总体而言，中国证据与国际研究在基本机制上具有较强一致性。中外文献均表明，人工智能通过改变职业内部的任务组合，产生任务替代、任务互补和新任务创造等多重效应。对于标准化程度较高的任务，人工智能通常具有较强的效率提升和替代能力，并可能帮助低经验或低绩效劳动者缩小短期绩效差距；但在复杂、非结构化和高度依赖判断的任务中，技术可能强化高能力劳动者的比较优势。中外研究也一致发现，人工智能的冲击已由传统的低技能和体力岗位扩展到认知型白领工作，并改变企业对劳动者技能组合的要求（Noy and Zhang, 2023; Dell'Acqua et al., 2023; Hampole et al., 2025; 胡涟漪等, 2026; 莫怡青等, 2026）。

然而，中国的实证证据在就业增长以及工资问题上与国外的证据存在差异。中国早期人工智能扩散的研究发现，互补和任务创造效应推动了招聘需求净增长，而国外生成式人工智能研究已经观察到较明显的初级岗位招聘下降和青年就业收缩（胡涟漪等, 2026; Teutloff et

al., 2025; Hosseini and Lichtinger, 2025; Brynjolfsson et al., 2025b)。与此同时，国际实验更强调人工智能对新手和低绩效者的能力补偿作用，中国劳动力市场证据则更多显示企业提高了学历、经验和技能门槛，并扩大灵活用工需求和不同技能组合之间的工资差距（刘行等，2025；莫怡青等，2026）。中国研究还发现，人工智能可能压低认知型零工工资，并在一定条件下缩小性别工资和工作时间差距（张艺、姜珊，2026；李力行、莫怡青，2025）。

在评价上述实证结果时，我们需要区分不同研究设计所能识别的效应及其局限。随机实验通常能够较为清晰地识别人工智能工具对特定劳动者和特定任务的短期因果影响。例如，实验可以比较使用与不使用人工智能的劳动者在完成写作、编程、客服或分析任务时的生产率和工作质量差异，并进一步考察不同技能和经验群体的异质性。但是，这类实验通常持续时间较短，研究对象、任务内容和组织环境也相对单一。因此，实验中观察到的个体生产率提升或能力差距缩小，不能直接回答人工智能长期扩散后职业结构、劳动收入份额和总体就业如何变化。因此，随机实验更适合识别任务层面的直接效应，而其对长期劳动市场结果的外推需要保持谨慎。

准实验研究更接近人工智能真实采用后的劳动市场调整，能够考察招聘、工资、就业结构和企业组织等结果，但其主要挑战是技术采纳的内生性。采用人工智能的企业往往本身具有更高的生产率、更完善的数字基础设施、更充足的资本和更强的管理能力，这些特征也会独立影响劳动需求和工资变化。与此同时，不少研究将职业或任务层面的人工智能暴露度作为处理变量，但若暴露指标不能准确反映真实采纳强度，就会产生测量误差，影响结果的解读。因此，基于暴露度的估计更适合被解释为高潜在影响岗位与低潜在影响岗位之间的相对变化，而不能自动等同于人工智能实际采纳的因果效应。

相关性分析和描述性证据在识别技术扩散范围、职业暴露结构、技能共现关系以及潜在受益和受损群体方面具有重要价值，尤其适合在技术快速变化、行政数据尚不充分的阶段描绘基本事实，但其因果解释相对有限。因此，对人工智能分配效应的可靠判断，需要将三类证据相互印证，并进一步结合实际使用记录、企业和劳动者匹配数据以及更长时间跨度的行政数据，区分短期局部效应与长期均衡调整。

五、结论与研究展望

本文从劳动就业视角出发，系统梳理了人工智能技术进步影响不平等的理论机制与经验研究。宏观层面的研究表明，技术进步并不必然导致劳动收入份额下降，其影响取决于技术进步的方向、资本与劳动之间的替代关系，以及自动化、鲍莫尔效应和新任务创造等机制之间的相互作用。与传统增长理论中劳动增强型技术进步保证要素收入份额长期稳定的逻辑不同，人工智能和自动化技术可能扩大资本可替代劳动的范围，从而对劳动收入份额形成下行压力；但若技术进步同时创造新的劳动任务，或者未被自动化的劳动密集型任务因稀缺性而相对价格上升，劳动收入份额也可能得到支撑。因此，人工智能对收入分配的影响取决于生产侧替代关系、任务结构变化和需求结构调整的共同作用。

在微观层面，任务模型进一步说明，人工智能的分配效应取决于哪些任务被替代、哪些任务得到增强，以及劳动者能否转向新任务。实证研究发现，人工智能可能依靠互补效应和创造效应增加部分岗位需求、改善匹配效率并缓解某些性别差距，也可能提高复合技能门槛、压低认知型零工工资、扩大灵活就业替代和技能回报差距。由此，人工智能时代的分配问题，不应仅被理解为“机器是否减少就业”的问题，而应进一步转化为：哪些任务被替代或增强，哪些技能获得新的回报，哪些劳动者能够进入新的职业路径，以及制度安排能否帮助受冲击群体分享技术进步带来的收益。未来，期待文献能提供更丰富的微观证据，与宏观层面的劳动收入份额、财富差距和代际不平等联系起来，以便进一步回答，人工智能提高生产率之后，

技术收益最终由劳动者、企业还是资本所有者分享，以及哪些制度安排能够使人工智能带来的增长更加包容。

需要说明的是，人工智能特别是生成式人工智能进入劳动力市场的时间较短，现有实证证据仍处于快速积累阶段。本文所综述的部分研究尚为工作论文、会议论文或机构研究报告，未经过完整的同行评议，稳健性仍有待进一步检验。同时，这些研究往往基于特定平台或较短的观察窗口，其结论可能受到样本代表性、识别策略以及技术扩散阶段的影响。因此，现有研究更适合被理解为对人工智能影响方向、作用机制和高风险群体的早期识别，而非关于其长期总体效应的最终判断。

本文最后提出四个方面的研究展望。

第一，发掘能够识别人工智能真实影响的数据。未来研究需要进一步从研究潜在暴露度转向实际采纳率。一方面，可以开展具有代表性的企业和劳动者调查，区分企业正式部署、员工自行使用、岗位要求 AI 技能以及 AI 实际参与任务完成等不同形式，并进一步测量使用频率、使用场景和工作时间节约情况。Bick et al. (2025) 的调查研究已经表明，实时使用调查能够提供暴露指标之外的重要信息。另一方面，可以将招聘广告、求职简历、企业披露、软件使用记录、平台行为和行政就业数据进行匹配，追踪企业采纳 AI 前后的岗位结构、工资、工时和人员构成变化。在因果识别方面，还需要寻找产品接入、技术服务供给、政策试点、企业历史数字基础或人才流动网络等外生变化，以区分 AI 采纳的真实影响与高生产率企业更容易使用新技术的选择效应。只有准确识别实际采纳及其强度，才能判断人工智能收益究竟流向哪些企业和劳动者，并将技术冲击与不平等结果可靠地联系起来。

第二，识别人工智能影响的任务特征、技能特征和群体特征。工业机器人主要作用于体力和重复性任务，计算机软件更多替代规则明确、容易编码的常规认知任务；相比之下，生成式人工智能已经进入写作、翻译、编程、法律分析、设计、咨询和管理等认知型工作领域。这意味着，以往相对受益于技术进步的高教育、高技能和白领劳动者，也可能成为人工智能的高暴露群体。不过，职业暴露程度较高，并不意味着整个职业都会被替代。更值得研究的是职业内部不同任务的变化。对于目标清晰、输出容易验证、主要依赖信息检索和文本生成的任务，人工智能可能具有更强的替代作用；对于依赖专业判断、责任承担、客户沟通、跨情境协调和隐性知识的任务，人工智能则可能更多发挥辅助作用，并提高具备综合判断能力者的回报。由此，人工智能带来的不平等将会是同一职业内部标准化认知任务劳动者与复杂判断型劳动者之间的分化。

未来研究需要进一步考察，人工智能技术对各种专业职业的影响，究竟主要表现为岗位消失，还是职业内部任务重新配置；在复杂任务中，人工智能是否帮助低经验劳动者追赶，抑或强化高能力劳动者的比较优势；企业是否更加重视判断力、沟通能力、责任承担能力以及“AI+行业知识”等复合能力。对这些问题的回答，将有助于理解人工智能是否正在改变技能回报与白领职业内部的不平等结构。

第三，考察人工智能是否推动就业关系向灵活用工和零工就业转变。人工智能的发展与平台经济、远程协作、项目制用工和灵活就业扩张同时发生。人工智能技术进步，促进了将工作拆分为更容易标准化、监督和外包的任务，从而降低企业使用兼职、项目制人员或平台零工的成本。已有中国研究初步发现，人工智能暴露程度提高与企业灵活用工需求增加相关，生成式人工智能对认知型零工岗位的工资与需求造成冲击。这些发现提示，未来不平等的重要表现之一是正规就业与非正规就业之间的差距。一部分劳动者可能在稳定合同、企业培训、晋升通道和社会保障支持下借助人工智能提高效率；另一部分劳动者则可能转向项目制、兼职制或平台零工市场，承担更大的收入波动、议价能力不足、社会保障缺失和职业发展不确定性。

随着零工就业规模的持续扩大,未来研究应重点追踪企业采用人工智能后是否减少正式岗位并增加外包、兼职、实习、劳务派遣和平台任务;考察灵活就业扩张究竟创造了新的进入机会,还是将原有稳定岗位转化为保障程度更低的就业形式;并评估社会保险、劳动合同、职业培训和平台治理制度是否能够适应人工智能时代的新就业形态。由此,对人工智能分配效应的评价也需要从工资水平进一步扩展到就业稳定性、保障水平和长期职业发展质量。

第四,关注组织重构以及对长期机会不平等的含义。初级岗位通常包含大量信息整理、简单分析、资料核查、客户支持等辅助性和训练性任务。这些任务是年轻劳动者获得行业知识、组织经验和专业判断能力的重要途径,但相对标准化,是生成式人工智能能够较快介入的任务。因此,人工智能对青年劳动者可能产生两种方向不同的影响:在已有岗位中,人工智能技术能够帮助新手提高工作效率;但在企业组织层面,如果大量初级任务可以由人工智能完成,企业可能减少初级员工招聘,并将剩余任务集中到经验更丰富的核心员工。已有国际研究发现,生成式人工智能采用与初级岗位需求下降之间的联系,并将其解释为企业职业阶梯底层环节的弱化。

这一问题对于中国具有特别重要的现实意义。随着高校毕业生规模扩大,初级白领岗位是年轻人进入专业职业、积累经验并实现向上流动的重要通道。因此,未来研究需要着重考察,生成式人工智能是否减少了企业对实习生、应届毕业生和初级白领的招聘需求;会计、法务、编辑、设计、程序开发和金融分析等岗位中的训练性任务是否正在被替代;这种变化是否对不同高校层次、不同专业和不同家庭背景的青年产生差异化影响。更进一步,还需要考察企业能否形成新的人机协作式训练路径,使青年劳动者在基础任务减少之后仍然能够获得职业经验和晋升机会。从这一角度看,人工智能引发的不平等将不仅体现为当期工资差距,还会体现为进入高质量职业、积累人力资本和实现长期流动的机会差异。

参考文献

- Acemoglu, D. (2024). The simple macroeconomics of AI. *Economic Policy*, 40(121), 13-58.
- Acemoglu, D., & Autor, D. H. (2011). Skills, tasks and technologies: Implications for employment and earnings. In O. Ashenfelter & D. Card (Eds.), *Handbook of labor economics* (Vol. 4B, pp. 1043-1171). Elsevier.
- Acemoglu, D., & Johnson, S. (2023). *Power and progress: Our thousand-year struggle over technology and prosperity*. New York: Public Affairs.
- Acemoglu, D., & Loebbing, J. (2026). Automation and polarization. *Journal of Political Economy*, 134(3), 1017-1072. <https://doi.org/10.1086/739330>
- Acemoglu, D., & Restrepo, P. (2018). The race between man and machine: Implications of technology for growth, factor shares, and employment. *American Economic Review*, 108(6), 1488-1542.
- Acemoglu, D., & Restrepo, P. (2019). Automation and new tasks: How technology displaces and reinstates labor. *Journal of Economic Perspectives*, 33(2), 3-30.
- Acemoglu, D., & Restrepo, P. (2022). Tasks, automation, and the rise in U.S. wage inequality. *Econometrica*, 90(5), 1973-2016. <https://doi.org/10.3982/ECTA19815>
- Aghion, P., Jones, B. F., & Jones, C. I. (2019). Artificial intelligence and economic growth. In A. Agrawal, J. Gans, & A. Goldfarb (Eds.), *The economics of artificial intelligence: An agenda* (pp. 237-290). University of Chicago Press.
- Agrawal, A. K., McHale, J., & Oettl, A. (2026). *Enhancing worker productivity without automating tasks: A different approach to AI and the task-based model* (NBER Working Paper No. 34781). National Bureau of Economic Research.
- Akerman, A., Gaarder, I., & Mogstad, M. (2015). The skill complementarity of broadband internet. *The Quarterly Journal of Economics*, 130(4), 1781-1824. <https://doi.org/10.1093/qje/qjv028>
- Alekseeva, L., Azar, J., Giné, M., & Samila, S. (2026). Artificial intelligence adoption and the demand for managerial expertise. *Strategic Management Journal*.
- Anthropic. (2026). *Labor market impacts of AI: A new measure and early evidence*. Anthropic Economic Index.
- Athey, S., & Morton, F. S. (2025). *Artificial intelligence, competition, and welfare* (NBER Working Paper No. 34444). National Bureau of Economic Research.

- Autor, D. H. (2022). *The labor market impacts of technological change: From unbridled enthusiasm to qualified optimism to vast uncertainty* (NBER Working Paper No. 30074). National Bureau of Economic Research.
- Autor, D. H., & Dorn, D. (2013). The growth of low-skill service jobs and the polarization of the U.S. labor market. *American Economic Review*, 103(5), 1553-1597.
<https://doi.org/10.1257/aer.103.5.1553>
- Autor, D. H., & Kausik, B. N. (2026). *Resolving the automation paradox: Falling labor share, rising wages*. arXiv. <https://arxiv.org/abs/2601.06343>
- Autor, D. H., Chin, C., Salomons, A., & Seegmiller, B. (2024). New frontiers: The origins and content of new work, 1940-2018. *The Quarterly Journal of Economics*, 139(3), 1399-1465.
- Autor, D., Dorn, D., Katz, L. F., Patterson, C., & Van Reenen, J. (2020). The fall of the labor share and the rise of superstar firms. *The Quarterly Journal of Economics*, 135(2), 645-709.
<https://doi.org/10.1093/qje/qjaa004>
- Autor, D. H., and Thompson, N. 2025. "Expertise." NBER Working Paper No. 33941.
- Babina, T., Fedyk, A., He, A., & Hodson, J. (2024). Artificial intelligence, firm growth, and product innovation. *Journal of Financial Economics*, 151, Article 103745.
<https://doi.org/10.1016/j.jfineco.2023.103745>
- Benzell, S. G., & Myers, K. R. (2026). *Automation experiments and inequality* (NBER Working Paper No. 34668). National Bureau of Economic Research.
- Bessen, J., Goos, M., Salomons, A., & van den Berge, W. (2025). What happens to workers at firms that automate? *Review of Economics and Statistics*, 107(1), 125-141.
- Bick, A., Blandin, A., & Deming, D. J. (2025). *The rapid adoption of generative AI* (NBER Working Paper No. 32966). National Bureau of Economic Research.
- Bloom, N., Sadun, R., & Van Reenen, J. (2012). Americans do IT better: US multinationals and the productivity miracle. *American Economic Review*, 102(1), 167-201.
<https://doi.org/10.1257/aer.102.1.167>
- Bonney, K., Breaux, C. L., Dinlersoz, E., Foster, L. S., Haltiwanger, J. C., & Pande, A. A. (2026). *The microstructure of AI diffusion: Evidence from firms, business functions, and worker tasks* (NBER Working Paper No. 35141). National Bureau of Economic Research.
- Brynjolfsson, E., Li, D., & Raymond, L. (2025a). Generative AI at work. *The Quarterly Journal of Economics*. Advance online publication.
- Brynjolfsson E., Chandar B., Chen R., (2025b), Canaries in the Coal Mine?: Six Facts about the Recent Employment Effects of Artificial Intelligence, Stanford Digital Economy Lab Working Paper.
- Cai, J., & Li, N. (2019). Growth through inter-sectoral knowledge linkages. *The Review of Economic Studies*, 86(5), 1827-1866. <https://doi.org/10.1093/restud/rdy062>

- Calvino, F., Samek, L., Squicciarini, M., & Morris, D. (2022). *Identifying and characterising AI adopters: A novel approach based on big data* (OECD Science, Technology and Industry Working Papers). OECD Publishing.
- Caunedo, J., Jaume, D., & Keller, E. (2023). Occupational exposure to capital-embodied technical change. *American Economic Review*, 113(6), 1642-1685.
- Choi, J. H., Monahan, A., & Schwarcz, D. (2024). Lawyering in the age of artificial intelligence. *Minnesota Law Review*, 109, 147.
- Comin, D., Lashkari, D., & Mestieri, M. (2021). Structural change with long-run income and price effects. *Econometrica*, 89(1), 311-374.
- de Souza, G. (2025). *AI in the office and the factory: Evidence from administrative software registry data*. Working paper.
- del Rio-Chanona, R. M., Ernst, E., Merola, R., Samaan, D., & Teutloff, O. (2025). *AI and jobs: A review of theory, estimates, and evidence*. arXiv. <https://arxiv.org/abs/2509.15265>
- Dell'Acqua, F., McFowland, E., Mollick, E. R., Lifshitz-Assaf, H., Kellogg, K., Rajendran, S., Kraymer, L., Candelon, F., & Lakhani, K. R. (2023). *Navigating the jagged technological frontier: Field experimental evidence of the effects of AI on knowledge worker productivity and quality*. Working paper.
- Deloitte. (2026). *The state of AI in the enterprise: Deloitte's 2026 AI report tracking adoption and impact*. Deloitte.
- Deming, D. J. (2017). The growing importance of social skills in the labor market. *The Quarterly Journal of Economics*, 132(4), 1593-1640. <https://doi.org/10.1093/qje/qjx022>
- Eloundou, T., Manning, S., Mishkin, P., & Rock, D. (2024). GPTs are GPTs: Labor market impact potential of LLMs. *Science*, 384(6702), 1306-1308.
- Felten, E. W., Raj, M., & Seamans, R. (2019). *The occupational impact of artificial intelligence: Labor, skills, and polarization*. NYU Stern School of Business Working Paper.
- Felten, E. W., Raj, M., & Seamans, R. C. (2023). *How will language modelers like ChatGPT affect occupations and industries?* SSRN Working Paper. <https://ssrn.com/abstract=4375268>
- Frey, C. B., & Osborne, M. A. (2017). The future of employment: How susceptible are jobs to computerisation? *Technological Forecasting and Social Change*, 114, 254-280.
- Fügener, A., Walzner, D. D., & Gupta, A. (2025). Roles of artificial intelligence in collaboration with humans: Automation, augmentation, and the future of work. *Management Science*, 72(1), 538-557.
- Gambacorta, L., Jappelli, T., & Oliviero, T. (2025). *Exploring household adoption and usage of generative AI: New evidence from Italy*. Bank for International Settlements.
- Gans, J. S. (2024). *Market power in artificial intelligence* (NBER Working Paper No. 32270). National Bureau of Economic Research.

- Gans, J. S. (2026). *Endogenous task bundling, skills and automation* (NBER Working Paper No. 35211). National Bureau of Economic Research.
- Goldin, C., & Katz, L. F. (2008). *The race between education and technology*. Belknap Press of Harvard University Press.
- Goos, M., Manning, A., & Salomons, A. (2014). Explaining job polarization: Routine-biased technological change and offshoring. *American Economic Review*, 104(8), 2509-2526.
- Hampole, M., Papanikolaou, D., Schmidt, L. D. W., & Seegmiller, B. (2025). *Artificial intelligence and the labor market* (NBER Working Paper No. 33509). National Bureau of Economic Research.
- Hosseini, S. M., & Lichtinger, G. (2025). *Generative AI as seniority-biased technological change: Evidence from U.S. résumé and job posting data*. Harvard University Working Paper.
- Jia, N., Luo, X., Fang, Z., & Liao, C. (2024). When and how artificial intelligence augments employee creativity. *Academy of Management journal*, 67(1), 5-32.
- Jones, B. F., & Liu, X. (2024). A framework for economic growth with capital-embodied technical change. *American Economic Review*, 114(5), 1448-1487.
- Kalyani, A., Bloom, N., Carvalho, M., Hassan, T., Lerner, J., & Tahoun, A. (2025). The diffusion of new technologies. *The Quarterly Journal of Economics*, 140(2), 1299-1365.
<https://doi.org/10.1093/qje/qjaf002>
- Klein Teeselink, B. (2025). *Generative AI and labor market outcomes: Evidence from the United Kingdom*. SSRN Working Paper.
- Kurekova, L. M., Beblavy, M., & Thum-Thysen, A. (2015). Using online vacancies and web surveys to analyse the labour market: A methodological inquiry. *IZA Journal of Labor Economics*, 4, 1-20.
- Li, L., Liu, Z., Wang, A., Wang, H., Yu, S. (2026) Now Hiring: Firm-Level Adoption of Generative AI in China. NBER Economics of Artificial Intelligence Conference, Toronto.
- McElheran, K., Li, J. F., Brynjolfsson, E., Kroff, Z., Dinlersoz, E., Foster, L., & Zolas, N. (2024). AI adoption in America: Who, what, and where. *Journal of Economics & Management Strategy*, 33(2), 375-415.
- McKinsey & Company. (2025, November 5). *The state of AI in 2025: Agents, innovation, and transformation*. McKinsey & Company.
- Noy, S., & Zhang, W. (2023). Experimental evidence on the productivity effects of generative artificial intelligence. *Science*, 381(6654), 187-192.
- Otis, N. G., Clarke, R., Delecourt, S., Holtz, D., & Koning, R. (2023). *The uneven impact of generative AI on entrepreneurial performance*. Working paper.
- Peng, S., Kalliamvakou, E., Cihon, P., & Demirer, M. (2023). *The impact of AI on developer productivity: Evidence from GitHub Copilot*. arXiv. <https://arxiv.org/abs/2302.06590>

- Pizzinelli, C., Panton, A., Tavares, M. M., Cazzaniga, M., & Li, L. (2023). *Labor market exposure to AI: Cross-country differences and distributional implications* (IMF Working Paper No. 23/216). International Monetary Fund.
- Pouliakas, K., Santangelo, G., & Dupire, P. (2025). Are artificial intelligence skills a reward or a gamble? Deconstructing the AI wage premium in Europe. *Eurasian Business Review*, 15(4), 1091-1128.
- Roldán-Monés, A. (2024). *When GenAI increases inequality: Evidence from a university debating competition*. Esade Center for Economic Policy Working Paper.
- Shi, H., Gupta, A. K., Ding, W., & Zhang, K. (2025). *Identifying AI jobs in online job postings: Existing versus newly developed LLM-based approaches and a dataset on demand for AI jobs among Russell 1000 firms, 2018-2025*. Robert H. Smith School of Business Working Paper.
- Solow, R. M. (1956). A contribution to the theory of economic growth. *The Quarterly Journal of Economics*, 70(1), 65-94.
- Staneva, M., & Elliott, S. (2023). Measuring the impact of artificial intelligence and robotics on the workplace. In *New digital work: Digital sovereignty at the workplace* (pp. 16-30). Springer.
- Swan, T. W. (1956). Economic growth and capital accumulation. *Economic Record*, 32(2), 334-361.
- Teutloff, O., Einsiedler, J., Kässi, O., Braesemann, F., Mishkin, P., & del Rio-Chanona, R. M. (2025). Winners and losers of generative AI: Early evidence of shifts in freelancer demand. *Journal of Economic Behavior & Organization*, 235, 106845.
- Tinbergen, J. (1974). Substitution of graduate by other labour. *Kyklos*, 27(2), 217-226.
- Trammell, P., & Korinek, A. (2026). Economic growth under transformative AI. *Annual Review of Economics*. Advance online publication. <https://doi.org/10.1146/annurev-economics-051624-061002>
- Uzawa, H. (1961). Neutral inventions and the stability of growth equilibrium. *Review of Economic Studies*, 28(2), 117-124.
- Webb, M. (2020). *The impact of artificial intelligence on the labor market*. SSRN Working Paper. <https://ssrn.com/abstract=3482150>
- Yilmaz, E. D., Naumovska, I., & Aggarwal, V. A. (2023). *AI-driven labor substitution: Evidence from Google Translate and ChatGPT* (INSEAD Working Paper No. 2023/24/EFE). INSEAD.
- Zeira, J. (1998). Workers, machines, and economic growth. *The Quarterly Journal of Economics*, 113(4), 1091-1117.
- 蔡昉. 引领人工智能创造更多更高质量就业[J]. 劳动经济研究, 2025, 13(3): 3-17.

- 陈斌开, 张梓润, 夏俊杰, 陈思. 人工智能、经济增长与财富分配[J]. 经济学(季刊), 2026, 26(3).
- 陈岑, 张彩云, 周云波. 信息技术、常规任务劳动力与工资极化[J]. 世界经济, 2023, 46(1): 95-120. DOI:10.19985/j.cnki.cassjwe.2023.01.017.
- 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).
- 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, 43(5): 54-78. DOI:10.13653/j.cnki.jqte.20260507.009.
- 胡涟漪, 盖庆恩, 潘珊. 人工智能与职业需求: 基于任务内容的替代、互补与创造效应分析[J]. 经济学(季刊), 2026, 26(3).
- 胡涟漪, 盖庆恩, 朱喜, 郭士祺. 中国职业技能的结构转型: 基于任务内容的视角[J]. 经济研究, 2024(1).
- 蒋为, 陈星达, 倪诗程. 人工智能、产业结构转型与跨越“中等收入陷阱”[J]. 经济研究, 2025, 60(10): 239-260.
- 李磊, 王小霞, 包群. 机器人的就业效应: 机制与中国经验[J]. 管理世界, 2021(9).
- 李力行, 莫怡青. 从自动化、信息化到人工智能: 数字技术演进与就业的性别差异研究[J]. 劳动经济研究, 2025, 13(3).
- 刘行, 张昊天, 田轩. 人工智能、人力资本结构与灵活用工: 来自在线招聘大数据的经验证据[J]. 经济研究, 2025(7).
- 莫怡青, 王安琪, 李力行. 人工智能技术重塑劳动技能需求: 基于在线招聘数据的发现[J]. 经济学(季刊), 2026, 26(3).
- 权小锋, 李静蕾. 人工智能与企业协同创新: 基于国家新一代人工智能创新发展试验区的准自然实验[J]. 经济研究, 2025, 60(8): 72-93.
- 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, 60(9): 218-238.
- 孙浩宁, 李金璞, 董丰. 人工智能冲击下的收入分配与政策权衡: 基于任务替代与代际交叠的一般均衡分析[J]. 经济学(季刊), 2026, 26(3).
- 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, 38(10). DOI:10.3969/j.issn.1002-5502.2022.10.018.
- 王林辉, 胡晟明, 董直庆. 人工智能技术、任务属性与职业可替代风险: 来自微观层面的经验证据[J]. 管理世界, 2022(7).
- 王林辉, 钱圆圆, 宋冬林, 董直庆. 机器人应用的岗位转换效应及就业敏感性群体特征: 来自微观个体层面的经验证据[J]. 经济研究, 2023(7).
- 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, 40(11): 85-104. DOI:10.19744/j.cnki.11-1235/f.2024.0120.
- 王永钦, 董雯. 中国劳动力市场结构变迁: 基于任务偏向型技术进步的视角[J]. 中国社会科学, 2023(11).

- 肖挺, 陈周永, 何小钢. 工业机器人价格变化的就业效应: 基于宏微观的经验证据[J]. 管理世界, 2025, 41(11): 28-42, 80, 43-44. DOI:10.19744/j.cnki.11-1235/f.2025.0146.
- 姚加权, 张锬澎, 郭李鹏, 冯绪. 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).
- 尹志锋, 曹爱家, 郭家宝, 郭冬梅. 基于专利数据的人工智能就业效应研究: 来自中关村企业的微观证据[J]. 中国工业经济, 2023(5).
- 于航, 李泓宇, 张丹丹, 张润博, 李强. 人工智能技术进步有助于缓解劳动力市场教育错配: 来自“岗位-求职者”匹配数据的证据[J]. 经济学(季刊), 2026, 26(3).
- 余玲铮, 魏下海, 孙中伟, 吴春秀. 工业机器人、工作任务与非常规能力溢价: 来自制造业“企业—工人”匹配调查的证据[J]. 管理世界, 2021(1): 47-59.
- 张丹丹, 于航, 李力行, 胡佳胤, 莫怡青, 李泓宇. 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).
- 张艺, 姜珊. 生成式人工智能对零工工资的影响[J]. 经济学(季刊), 2026, 26(3).
- 智联招聘. 职场“人机共生”演进情况调研报告[R]. 北京: 智联招聘, 2025.
- 中国互联网络信息中心. 第 57 次中国互联网络发展状况统计报告[R]. 北京: 中国互联网络信息中心, 2026.
- 周广肃, 李力行, 孟岭生. 智能化对中国劳动力市场的影响: 基于就业广度和强度的分析[J]. 金融研究, 2021(6).