人工智能对中国制造业全要素生产率的影响

蔡振军

(湖南涉外经济学院，长沙 410205)

摘要：以 2013—2024 年中国 A 股制造业上市公司为研究对象，基于广义矩估计(GMM)，发现人工智能(AI)扩散对中国制造业全要素生产率增长的影响整体呈现出“当期受抑-滞后回升-边际收敛”的 J 曲线轨迹特征。从时序结构看，人工智能影响生产率的渠道结构具有阶段性差异，表现为由资本深化主导逐步演进为技术进步主导；在多重替换变量后，结论仍然具有稳健性。异质性分析表明，人工智能生产率收益随企业所处的行业环境、所有制和 AI 应用强度等不同而分化。对此，中国推动人工智能赋能制造业高质量发展，不但要注重硬件投入，更要重视导入初期成本缓释、软硬协同能力建设与分类分层推进治理体系完善。

关键词：人工智能(AI)；制造业；全要素生产率；上市公司；J 曲线

中图分类号：F49 **文献标志码**：A **文章编号**：1671－1807(2026)15－0032－11

中国正处于由制造大国向制(智)造强国转型阶段，加快人工智能(artificial intelligence，AI)采用与扩散是实现中国技术进步和高质量发展的关键所在。国家统计局公布 2025 年中国制造业增加值规模增长至 34.7 万亿元，同比增长 6.1%，连续 16 年保持全球第 1 的位置；中国人工智能(AI)发展呈现出由“点状突破”走向“系统跃升”的扩散态势，AI 企业超过 6 000 家，产业规模突破 1.2 万亿元，累计建成 230 余家卓越级智能工厂，工业机器人新增装机量的全球占比超过 50%，体现出制造业向高端化、智能化方向演进的结构特征。

AI 通过数据、算法、算力与组织体系的耦合，广泛嵌入制造业设备更新及生产改进环节，重塑信息处理、知识积累和决策形成过程，推动研发生产、质量控制、设备运维等协同优化。一方面，AI 应用能够显著提升制造企业的发明专利产出并提高创新效率，被概括为“发明方法的发明”，即通过改变传统研发范式来提升创新活动生产率[1]。人工智能的技术创新机制是其生产率效应由资本深化主导逐步走向技术进步主导的关键纽带。AI 作为继蒸汽机、电力和信息技术之后的新一代通用目的技术(general-purpose technology，GPTs)，被寄望引发制造业生产方式与增长范式的根本性重构，并成为推动长期经济增长和全要素生产率(TFP)跃迁的关键引擎。另一方面，“索洛悖论”显示了重大技术突破与宏观生产率增长之间明显脱节的经验事实[2]；OECD 统计数据显示，21 世纪以来，全球生产率增长普遍放缓，中国劳动生产率的平均增速逐渐下降到 5%左右，G7 国家劳动生产率增速长期徘徊在 1%～3%，现代生产率悖论表明 AI 技术突破并未同步转化为统计上的生产率跃升。如何利用 AI 提高中国制造业全要素生产率，对进一步深化 AI 与实体经济融合、实现经济高质量发展具有明确意义。现梳理 AI 影响中国制造业全要素生产率的现实基础、理论机制、动态演进及阶段性约束条件，构建完整的逻辑框架，以回答 AI 扩散如何动态影响中国制造业全要素生产率增长的命题，回应现代生产率悖论。

1 研究假设

1.1 企业 AI 采纳的微观决策框架

内生增长理论强调，研发投入和人力资本规模不仅直接推动技术创新，也是企业吸收外部知识的重要前提[3-4]。AI 通过推动生产决策自动化、提升流水线效率与扩大有效劳动供给，能够带动劳动生产率增长并提升企业层面全要素生产率[5]。从企业微观行为决策角度看，AI 是企业在预期收益、投入成本和组织约束之间进行权衡后的动态采纳结果。构建企业 AI 采纳决策框架。设企业 i 在 t 期选择 AI 投入水平 a_{it}，其生产函数可表示为

收稿日期：2026-04-14

基金项目：教育部高等学校科学研究发展中心人工智能赋能产教研融合创新专项重点项目(2025RGZN161)

作者简介：蔡振军(1987—)，男，湖南长沙人，博士，副教授，研究方向为人工智能与产业高质量发展、人工智能经济。

$$Y_{it} = A_{it}\left[(1+\phi a_{it})K_{it}\right]^{\alpha}L_{it}^{1-\alpha} \quad (1)$$

式中：Y_{it} 为产出；K_{it}、L_{it} 分别为资本和劳动投入；A_{it} 为广义技术效率；效果参数 $\phi>0$，为 AI 对资本质量或有效资本服务的提升作用；α 为资本产出弹性。AI 替代重复性任务的同时释放人力投入，将低效率要素投入转移到工艺优化与复杂装配等高价值端环节，使有效劳动质量上升、冗余劳动时间下降，并在任务框架下形成净 TFP 提升[6]。AI 在导入初期表现为智能资本或资本质量提升，即通过提高单位资本的信息处理、感知反馈和优化控制能力，改善有效资本投入水平。

企业选择 AI 投入时，并不只面对设备和软件的显性采购成本，还需要承担数据治理、系统集成、流程改造、技能培训和组织协调等隐性成本。设企业当期利润为

$$\pi_{it} = P_{it}Y_{it} - rK_{it} - wL_{it} - c_{A}a_{it} - \Omega(a_{it},S_{it}) \quad (2)$$

式中：P_{it} 为产品价格；r 为资本要素价格；w 为工资率；c_{A} 为 AI 投入的直接成本；S_{it} 为企业互补性资产水平，包括数据基础、组织学习能力、人力资本和管理制度适配程度；$\Omega(a_{it},S_{it})$ 为调整成本。为体现 AI 导入期摩擦成本，可设

$$\Omega(a_{it},S_{it}) = \frac{\chi}{2}(a_{it}-a_{i,t-1})^{2} + \mu(1-S_{it})a_{it} \quad (3)$$

式(3)表明，AI 投入扩张越快，系统切换和组织重构成本越高；企业互补性资产越不足，同等 AI 投入带来的适配成本越大。

AI 对技术效率的影响具有滞后性，设企业技术效率演化过程为

$$\ln A_{i,t+1} = \rho\ln A_{it} + \eta a_{it} + \lambda S_{it}a_{it} - \psi\Omega(a_{it},S_{it}) + \mu_{i} + \lambda_{t} + \varepsilon_{it} \quad (4)$$

式中：ηa_{it} 为 AI 通过算法、数据和模型能力带来的直接效率潜力；$\lambda S_{it}a_{it}$ 为互补性资产对 AI 效率释放的放大作用；$\psi\Omega(a_{it},S_{it})$ 为调整成本对当期效率的抑制；ρ 反映生产率惯性；μ_{i} 和 λ_{t} 分别表示企业固定效应和时间效应；ε_{it} 为误差项。可见，AI 投入对 TFP 的净影响更取决于“技术收益-调整成本”的相对大小。企业 AI 导入初期，技能摩擦和调整成本超过 AI 引致的效率提高，当期 TFP 增长直观受抑；进入适配期阶段，企业随着流程重构和组织学习推进，调整和摩擦成本下降，AI 技术潜力逐渐转化为可观测效率改善；进入释放期阶段，随着 AI 嵌入研发、生产制造、质量控制和供应链协同等核心环节，领先企业顺利摘取 AI“低垂果实”、率先兑现效率提升红利，技术效率和资源配置效率显著提升；在深化扩散后期，随着后续复杂场景的治理成本和协同难度上升，生产率边际促进效应收敛。

可将上述识别框架 AI 生产率效应直观改进表示为

$$\Delta\ln TFP_{i,t+h} = B_{h}(a_{it},S_{it}) - C_{h}(a_{it},S_{it}) \quad (5)$$

式中：B_{h} 为 AI 在第 h 期通过资本质量提升、技术创新、流程优化和管理协同带来的效率收益；C_{h} 为系统集成、组织调整、技能适配和制度磨合带来的成本损失。若 $h=0$ 时 $C_{0}>B_{0}$，则当期效应可能为负；若 $h=1$ 或 $h=2$ 时互补性资产积累使 B_{h} 上升且 C_{h} 下降，滞后效应可能转为正；当 h 继续增加时，受边际收益递减和治理复杂度上升影响，$B_{h}-C_{h}$ 趋于收敛。由此，AI 影响制造业企业全要素生产率增长的 J 曲线特征，可由企业最优化行为、调整成本前置和互补性资产滞后积累共同解释。

1.2 AI 对制造业全要素生产率影响的阶段性表现

1.2.1 导入初期：资本深化效应先行显现

首先，基于新古典增长理论框架视野，企业初期引入工业机器人、机器视觉系统、工业软件等投入时，主要通过扩大资本存量、提升资本质量的方式，使资本品由传统机械设备逐步演化为具备感知、识别、反馈和优化能力的“智能资本”。此时 AI 以边际报酬递减的“资本品”角色进入制造业生产体系，经由资本扩张与资本质量提升渠道形成资本深化效应，促进全要素生产率提升。基于柯布-道格拉斯生产函数和 Solow增长核算框架，将劳动生产率增长分解为技术进步效应与资本深化贡献，生产函数可表示为

$$Y_{it} = A_{it}F(K_{it},L_{it}) \quad (6)$$

式中：A_{it} 为技术效率或广义技术水平。当 AI 主要以工业机器人、智能装备、软件系统和算法平台等资本品形态进入生产过程时，当期作用主要体现为资本-劳动比上升与资本质量改善，即资本深化效应。将 AI 引致的资本质量提升刻画为

$$K_{it}^{*} = K_{it}(1+\varphi AI_{it}) \quad (7)$$

式中：AI_{it} 为企业的 AI 投入或发展水平；$\varphi>0$，为资本质量提升的效率系数。初期边际报酬递减和组织摩擦并存条件约束下，资本深化贡献体现为当期生产率沿既定生产函数的平滑扩张移动。

企业引入 AI 改善信息处理与决策能力、促进流程再造和创新扩散，经历模型迭代、业务流程适配与组织学习，逐步提升企业的技术效率与资源配置效率，才能将 AI 赋能嵌入核心生产体系，其演化

过程可表示为

$$A_{it} = A_{it-1} + \varphi \mathrm{AI}_{it-s} \tag{8}$$

式(8)表明,AI 对制造业全要素生产率的影响呈现资本深化贡献先行显现、技术进步贡献滞后的效应结构。该逻辑判断与新古典增长理论和内生增长理论的解释相一致,前者强调资本投入扩张主要表现为沿既定生产函数平滑移动[7],而后者强调知识积累与创新扩散在边际报酬递增作用下,能够推动生产函数整体平行扩张并形成可持续的效率增长[3]。基于 Solow 增长核算框架,将劳动生产率增长分解为技术进步效应与资本深化效应,假设生产函数服从柯布-道格拉斯形式且满足规模报酬不变:

$$Y_{it} = A_{it} K_{it}^{\alpha} L_{it}^{1-\alpha} \tag{9}$$

将式(9)生产函数两边同时除以劳动投入并取对数,可得:

$$\ln \frac{Y_{it}}{L_{it}} = \ln A_{it} + \alpha \ln \frac{K_{it}}{L_{it}} \tag{10}$$

进一步对式(10)进行时序差分,可得到基于劳动生产率增长率的加法分解公式:

$$\Delta \ln \left(\frac{Y}{L} \right)_{it} = \Delta \ln A_{it} + \alpha \Delta \ln \left(\frac{K}{L} \right)_{it} \tag{11}$$

式(11)表明,劳动生产率提升来源于技术进步效应($\Delta \ln A_{it}$)与资本深化贡献$\left[\alpha \Delta \ln \left(\frac{K}{L} \right)_{it} \right]$,前者反映全要素生产率增长,后者反映由资本密集度提高带来的产出增长,由此可以在经验层面区分并量化 AI 对资本深化效应与技术进步效应的相对影响机制。

1.2.2 短期受抑:调整摩擦成本集中前置

通用目的技术经济增长效应不仅表现为单点技术突破,更表现为通过互补性创新网络重塑生产函数与产业结构,从而推动长期技术进步。人工智能赋能生产率提升需要数据、算法、组织和制度等“软硬协同”的创新生态支撑[8]。经历人工智能资本品导入、互补投入积累、组织流程重构与创新扩散外溢等阶段,AI 的生产率作用机制才可能由资本深化逐步转向技术进步。尤其是在制造业场景下,调整与摩擦成本支出具有时间前置性,即大量投入和摩擦集中发生在技术导入初期,并通过生产试错、协同失灵、流程中断等方式抑制当期生产率提升。设企业生产函数满足柯布-道格拉斯形式,且技术效率、资本投入和劳动投入均可能受到当期及滞后期 AI 投入,以及由此诱发的互补条件变化影响,记 $\boldsymbol{\Omega}_{it} = (\mathrm{AI}_{it}, \mathrm{AI}_{i,t-1}, \cdots, \mathrm{AI}_{i,t-s})$ 为企业当期及其多期滞后 AI 投入向量,C_A、C_K 和 C_L 分别表示作用于技术效率、资本积累和劳动配置的互补条件或调整环境,可包括数据治理、系统整合、组织重构、人力资本适配以及制度支持等因素,则企业产出可表示为

$$Y_{it} = A_{it}[\boldsymbol{\Omega}_{it}, C_A(\boldsymbol{\Omega}_{it})] K_{it}[\boldsymbol{\Omega}_{it}, C_K(\boldsymbol{\Omega}_{it})]^{\alpha} \times L_{it}[\boldsymbol{\Omega}_{it}, C_L(\boldsymbol{\Omega}_{it})]^{1-\alpha} \tag{12}$$

式(12)表明,AI 既会改变技术效率 A_{it},又同时作用于 A_{it}、K_{it} 和 L_{it},并通过互补条件项 C_A、C_K 和 C_L 形成间接影响。由此,对 AI 变化量作一阶全微分,将 AI 产出影响分解为技术效率渠道、资本贡献渠道和劳动效率渠道的综合表现。

$$\Delta Y_{it} = \sum_{X \in \{A,K,L\}} \frac{\partial Y_{it}}{\partial X_{it}} \left[\sum_{j=0}^{s} \left(\frac{\partial X_{it}}{\partial \mathrm{AI}_{i,t-j}} + \frac{\partial X_{it}}{\partial C_X} \frac{\partial C_X}{\partial \mathrm{AI}_{i,t-j}} \right) \Delta \mathrm{AI}_{i,t-j} \right] \tag{13}$$

由式(13)可知,AI 扩散对产出的影响既包括直接作用于 A、K、L 的边际效应,也包括通过互补条件变化所形成的间接效应。进一步利用柯布-道格拉斯生产函数的偏导结构,并将技术效率项等同于 TFP,可将其转化为增长率形式:

$$\frac{\Delta Y_{it}}{Y_{it}} = \frac{\Delta \mathrm{TFP}_{it}}{\mathrm{TFP}_{it}} + \alpha \frac{\Delta K_{it}}{K_{it}} + (1-\alpha) \frac{\Delta L_{it}}{L_{it}} \tag{14}$$

式(14)表明,总产出增长由 3 部分构成:全要素技术效率增长、资本投入增长和劳动投入增长。进一步将其转换为劳动生产率形式,并将劳动投入增长从两边扣除,则可得到标准的劳动生产率分解式:

$$\frac{\Delta(Y_{it}/L_{it})}{Y_{it}/L_{it}} = \frac{\Delta \mathrm{TFP}_{it}}{\mathrm{TFP}_{it}} + \alpha \frac{\Delta(K_{it}/L_{it})}{K_{it}/L_{it}} \tag{15}$$

由式(15)可见,劳动生产率增长由两部分构成:一部分是全要素生产率增长,反映(纯)技术效率提高;另一部分是资本深化贡献,反映资本-劳动比提高所带来的产出提升,整理后可得到 AI 引致的全要素生产率净效应表达式:

$$\frac{\Delta \mathrm{TFP}_{it}}{\mathrm{TFP}_{it}} = \frac{\Delta(Y_{it}/L_{it})}{Y_{it}/L_{it}} - \alpha \frac{\Delta(K_{it}/L_{it})}{K_{it}/L_{it}} \tag{16}$$

式(16)的经济含义在于:AI 引致的全要素生产率效应本质上是 AI 引致的人均产出效应扣除 AI 引致的资本深化效应之后的净剩余部分。换言之,资本深化贡献并不直接并入 TFP 定义,而是在劳动生产率增长分解中单列呈现。因此,即使观察到 AI 导入后人均产出提高,也并不能直接认定其全部来源于技术进步,还必须扣除资本-劳动比上升所带来的资本深化部分。将 AI 对 TFP 增长的净效应参数

化为当期与多期滞后 AI 投入共同作用、并受到导入期调整摩擦抑制的形式，可得：

$$\frac{\Delta TFP_{it}}{TFP_{it}} \approx \eta_0 \Delta AI_{it} + \eta_1 \Delta AI_{i,t-1} + \cdots + \eta_s \Delta AI_{i,t-s} - \Psi_{it} \quad (17)$$

式中：η_j 为滞后 j 期 AI 变动对 TFP 增长率的边际贡献；Ψ_{it} 为 AI 导入阶段的数据治理、系统整合、组织重构、技能再配置和制度磨合等短期摩擦成本。由此，人工智能影响 TFP 变动的逻辑脉络可以更清楚地界定为：先通过资本深化推动人均产出提升，再在扣除资本深化贡献之后，识别其对纯技术效率的净作用。若短期摩擦项较大，则即便资本深化已经启动，TFP 增长仍可能当期受抑；随着互补条件改善与学习适配完成，Ψ_{it} 逐步减弱，而滞后 AI 项的正向作用开始显性化，人工智能对 TFP 的净贡献才会逐步释放。这也正是后文“当期受抑-滞后回升”动态结构的理论基础。

1.2.3 适配学习：技术进步贡献滞后释放

AI 通过算法、数据与学习能力嵌入研发设计、生产制造与经营管理全过程，推动工艺创新、产品创新与组织重构，从而实现真正意义上的（纯）技术进步贡献。此时，AI 作为“知识载体”呈现边际报酬递增特征，并通过知识积累、工艺改进与组织重构推动技术进步，在更长时期内改善企业效率前沿。人工智能可以通过技术创新降低企业成本、优化劳动力结构和促进创新，从而提升企业全要素生产率[9]。AI 与高技能人力资本、研发能力和数字化基础设施具有显著互补性。当企业具备相应吸收转化能力时，AI 从短期资本投入转化为长期技术进步贡献，并通过创新扩散形成持续的全要素生产率增长。可知，当 AI 以内生创新要素的形式嵌入制造业生产体系，其生产率效应向技术进步主导转化，并表现为持续、可累积的全要素生产率改进。

1.2.4 动态收敛：技术效率红利阶段转换

GPTs 扩散会诱发广泛的互补创新与部门重组，而这些调整在初期可能造成生产率“暂时性下降”，当互补创新成熟后将出现更显著的生产率增长回报[10]。初期，制造业企业内部数字基础设施、数据要素供给、组织变革能力与技能结构尚不足以支撑 AI 深度应用时，AI 更可能停留在局部试点与“孤岛式”改进，表现为成本先行、收益滞后；当互补要素逐步完备、组织学习跨过临界点后，AI 从“点状效率”扩展为“系统效率”，并在更长周期内推动制造业全要素生产率提升。从动态演化角度看，随着人工智能系统覆盖范围扩大，企业对数据质量管理、模型训练更新、算法责任界定和跨部门协同的要求也会同步提高；企业组织治理能力、流程标准化和人力资本结构亟待与系统复杂度扩张相匹配，新增 AI 可能形成重复建设、系统冗余、资源错配和协调摩擦，使边际回报出现收敛甚至回落。基于此，提出如下假设。

H1a（短期调整成本假设）：在控制企业固定效应与时间效应后，人工智能对企业当期全要素生产率增长的影响不显著或为负；

H1b（滞后收益释放假设）：人工智能对企业全要素生产率存在显著的滞后正向影响，且滞后效应强于当期效应；

H1c（动态收敛假设）：随着滞后期数增加，人工智能对企业全要素生产率的边际促进效应呈收敛趋势，并可能表现出边际递减。

1.3 AI 影响制造业全要素生产率的阶段性条件约束

AI 对制造业企业全要素生产率的影响具有阶段性条件约束。企业需要历经识别、消化与利用新知识的过程，将 AI 投入转化为生产率收益[11]。可知，AI 生产率收益取决于技术，以及企业所处的应用强度区间、互补条件水平与组织承载能力，设企业 i 在 t 期的生产函数为

$$Y_{it} = A_{it}(AI_{it}, C_{it}) K_{it}^{\alpha} L_{it}^{1-\alpha},\ 0 < \alpha < 1 \quad (18)$$

式中：AI_{it} 为企业 AI 应用强度；C_{it} 为企业的互补能力，包括数据治理、人力资本、流程数字化、组织协同与治理能力等协同条件。AI 并不是通过改变资本和劳动投入的形式孤立起作用，而是通过影响技术效率项 A_{it} 进而作用于企业产出。将技术进步效率项表示为

$$\ln A_{it} = \omega_i + g(AI_{it}, C_{it}) - h(AI_{it}, C_{it}) \quad (19)$$

式中：ω_i 为企业既有技术禀赋；$g(\cdot)$ 为 AI 通过流程优化、预测决策、质量改善和知识复用带来的效率增益函数；$h(\cdot)$ 为 AI 导入、扩张和系统化嵌入所产生的调整成本与治理成本函数，包括数据治理、系统整合、组织重构、技能升级和协调摩擦等。当人工智能与制造业互补性无形资本投入、企业组织变革与生产任务重构相结合时，才能从“资本品”转化为“技术进步”，实现可持续的全要素生产率增长[12]。根据 AI 作为通用目的技术的扩散特征，将技术效率分解为效率增益函数与调整成本函数：

$$\frac{\partial g}{\partial AI} > 0,\ \frac{\partial^2 g}{\partial AI^2} < 0,\ \frac{\partial h}{\partial AI} > 0,\ \frac{\partial h}{\partial C} < 0 \quad (20)$$

由式(20)可得,AI 对技术效率的净边际影响为

$$\frac{\partial \ln A_{it}}{\partial \mathrm{AI}_{it}} = g_{\mathrm{AI}}(\mathrm{AI}_{it}, C_{it}) - h_{\mathrm{AI}}(\mathrm{AI}_{it}, C_{it}) \quad (21)$$

式(21)表明,AI 扩散对制造业全要素生产率增长的净边际影响本质上取决于效率增益与调整成本的相对大小。企业互补能力较弱时,AI 主要停留在试点部署和局部嵌入阶段,其资本深化效应被数据治理、系统兼容和流程重构等摩擦成本抵消;企业形成稳定技术、数据与组织的协同效应后,效率增益超过摩擦成本损失;企业组织治理能力、系统整合能力和资源配置能力未能同步提升时,AI 引致系统复杂化成本上升,从而使边际回报趋于收敛甚至回落。AI 生产率效应呈现出分段变化特征,令 $\beta(\mathrm{AI}_{it}, C_{it})$ 表示 AI 生产率净边际回报系数,可得:

$$\beta(\mathrm{AI}_{it}, C_{it}) = \begin{cases} \beta_1 \leqslant 0, & \mathrm{AI}_{it} \leqslant c_1(C_{it}) \\ \beta_2 > 0, & c_1(C_{it}) < \mathrm{AI}_{it} \leqslant c_2(C_{it}) \\ \beta_3, & \mathrm{AI}_{it} > c_2(C_{it}) \end{cases} \quad (22)$$

式(22)说明了 AI 生产率回报的阶段性演进特征,表明采纳初期学习成本与集成摩擦会抑制效率表现,当 AI 投入处于较低水平时效率提升作用不明显;当 AI 积累足以支撑规模化应用后,效率增益逐步显现,但继续扩张可能出现边际回报下降[13]。其中,$c_1(C_{it})$ 和 $c_2(C_{it})$ 分别表示由低强度试点阶段进入有效协同阶段,以及由协同增强阶段进入高复杂度治理阶段的临界点,两者均依赖于企业互补能力水平;β_3 满足 $0 < \beta_3 < \beta_2$,生产率收益也可能在配置失效的情形下进一步弱化。成熟期阶段,领先企业率先兑现生产率红利,市场生态从需求引导创新-技术效率跃迁的竞争范式,转向内卷式的价格战竞争,低质扩张对长期效率提升形成抑制作用。此时,竞争机制不再是生产率的驱动者,而是生产率的消耗者,产生过度 AI 化风险。将上述分段边际回报嵌入动态生产率增长方程,可得:

$$\Delta \mathrm{TFP}_{it} = \rho \Delta \mathrm{TFP}_{i,t-1} + \beta(\mathrm{AI}_{it}, C_{it})\mathrm{AI}_{it} + \gamma' X_{it} + \mu_i + \lambda_t + \varepsilon_{it} \quad (23)$$

式中:$\Delta \mathrm{TFP}_{it}$ 为企业全要素生产率增长率;ρ 为生产率惯性;X_{it} 为控制变量。初期 AI 多为试点部署和局部嵌入,生产率回报有限且易被调整成本抵消;当企业跨越关键适配节点后释放系统协同效率,生产率边际回报显著增强;AI 可能引致高度复杂度的协调成本,使生产率边际回报趋于收敛。AI 应用不仅要求技术人员具备建模和维护能力,也要求业务人员理解场景、解释结果并推动应用落地;数据治理能力和数字化认知、组织结构的协同能力,都会影响 AI 生产率收益的释放。基于此,提出如下假设。

H2a(分段效应假设):人工智能对制造业企业全要素生产率的影响存在显著分段特征,不同应用强度区间下其边际效应存在显著差异;

H2b(高强度收敛假设):人工智能对全要素生产率的边际影响并非单调递增,在较高应用强度阶段可能出现边际回报趋于收敛,甚至由强转弱的现象;

H2c(互补条件约束假设):企业互补性资产和组织吸收能力影响人工智能分段效应的显现与强度。

2　AI 与制造业全要素生产率的指标测度

2.1　AI 的指标测度

结合以往文献经验,考虑微观企业视角及指标的可获取性,选取 AI 技术专利、企业年报 AI 关键词频率、AI 总投资、AI 制造设备投入等指标,从创新产出、投入规模和投资强度维度构建 AI 指标体系,见表 1。

表 1　AI 水平指标体系

维度	指标	符号	单位
创新产出	AI 技术专利申请数	$\mathrm{AI}_{_Patents}$	件
	AI 关键词频率	$\mathrm{AI}_{_Keywords}$	频率
投入规模	AI 总投资	$\mathrm{AI}_{_Total_Invest}$	元
	AI 制造设备投入	$\mathrm{AI}_{_Equipment_Invest}$	元
	AI 技术投资金额	$\mathrm{AI}_{_Tech_Invest}$	元
投资强度	AI 投入占企业总投资比重	$\mathrm{AI}_{_Invest_Ratio}$	%

专利数据能够有效反映技术扩散与创新产出的真实水平,是衡量 AI 技术积累、技术成熟度及企业创新能力的关键指标[14]。因此,采用主成分分析(principal component analysis,PCA)法提取权重构建替代口径下 AI 综合指数,并进一步选取企业层面的 AI 专利数量作为替代变量展开稳健性检验,各指标互相交叉印证。

2.2　制造业全要素生产率的指标测度

采用 OP(Olley-Pakes)法测度中国制造业企业全要素生产率,以对数差分形式构造 TFP 增长率作为核心被解释变量;同时,考虑到企业投资可能存在“零投资/投资稀疏”年份、代理变量条件对 OP 法有效性的潜在约束,将 Wooldridge 法测度结果构建制造业企业 TFP 增长率面板数据,作为稳健性对照[15],构建制造业全要素生产率指标体系,见表 2。

表 2　制造业全要素生产率指标体系

指标类别	指标名称	指标符号	单位	全要素生产率计算用途
总产出	营业收入	Revenue	万元	总产出指标
资本投入	固定资产净额	$\text{Net}_{\text{Fixed_Assets}}$	万元	资本投入指标
劳动投入	员工人数	Employees	人	劳动投入指标
投资	购建固定资产无形资产和其他长期资产支付的现金	$\text{Capex}_{\text{Cash}}$	万元	投资指标
中间投入	营业成本	$\text{Operating}_{\text{Cost}}$	元	加项
	销售费用	$\text{Selling}_{\text{Expenses}}$	元	加项
	管理费用	$\text{Admin}_{\text{Expenses}}$	元	加项
	财务费用	$\text{Financial}_{\text{Expenses}}$	元	加项
	折旧摊销	$\text{Depreciation}_{\text{Amortization}}$	元	减项
	为职工支付的现金	$\text{Wage}_{\text{Cash}}$	元	减项

3　AI 对制造业全要素生产率影响的实证分析

3.1　模型设定与变量说明

3.1.1　动态面板基准模型

制造业企业全要素生产率($\text{TFP}_{\text{Growth}}$)当期效率表现会受前期技术积累、组织学习与资源配置状态的持续影响,具有显著的动态惯性特征;同时,企业 AI 扩散($\text{AI}_{\text{Growth}}$)也可能受到预期生产率回报的反向影响。为更稳健地识别 AI 扩散对中国制造业全要素生产率增长的动态因果效应,采用两步系统广义矩估计(two-step system GMM)方法构建动态面板模型进行实证分析。设定基准动态面板模型如下:

$$\text{TFP_Growth}_{i,t} = \rho \text{TFP_Growth}_{i,t-1} + \sum_{k=0}^{K} \beta_k \text{AI_Growth}_{i,t-k} + \gamma' Z_{i,t} + \mu_i + \lambda_t + \varepsilon_{i,t} \quad (24)$$

式中:i 为企业;t 为年份;$\text{TFP_Growth}_{i,t}$ 为企业全要素生产率增长率;$\text{TFP_Growth}_{i,t-1}$ 为一阶滞后项,刻画生产率增长的路径依赖,参数 ρ 预期为正且小于 1;$\text{AI_Growth}_{i,t-k}$ 为 AI 扩散的当期及滞后项,参数 β_k 描述 AI 生产率效应的动态时间结构;$Z_{i,t}$ 为控制变量向量,包括企业规模、财务杠杆、企业年龄及行业竞争度等。变量内生性处理方面,将 $\text{TFP_Growth}_{i,t-1}$ 视为内生变量,将 AI 扩散 $\text{AI}_{\text{Growth}}$ 视为预定变量,允许与其过去误差项相关但不与当期误差项相关,并使用其滞后项构造内部工具变量。在控制变量中,对可能存在同步性或反向因果风险的变量采用预定处理,其余控制变量作为外生工具进入模型,以在降低工具变量维度时提高估计稳定性。

3.1.2　变量说明与描述性统计

以 2013—2024 年中国 A 股制造业上市公司为对象,主要数据来源于 CSMAR 和 Wind 数据库,最终纳入 3 385 家企业 24 638 个样本的实证数据。利用 2013—2024 年中国 A 股制造业上市公司数据,引入 TFP 的滞后项与 AI 指数多期滞后项。其中,被解释变量为基于 OP 法测算的制造业企业全要素生产率增长($\text{TFP}_{\text{Growth}}$),核心解释变量为基于熵值法测度的制造业企业 AI 发展水平变动率($\text{AI}_{\text{Growth}}$),两者均采用对数差分构造。控制变量包括:企业规模(Size_{it}),取期末总资产的自然对数用以控制规模经济效应;财务杠杆(Lev_{it}),用总负债/总资产衡量以控制财务风险与融资约束;企业年龄(Age_{it}),基于观测年份-成立年份(取对数),以控制生命周期效应;市场竞争度(HHI_{it})采用营业收入计算赫芬达尔-赫希曼指数,控制行业竞争结构。主要变量描述性统计见表 3。

3.2　基准估计与动态效应检验

设置静态固定效应(Stati FE)模型作为动态效应模型的对照检验,考察忽略生产率惯性与 AI 滞后项情况下的静态估计结果将可能发生何种偏差,报告估计结果见表 4。System GMM 模型中全要素生产率滞后 1 期的系数均显著为正,且数值稳定在 0.624 4～0.713 3,表明中国制造业全要素生产率增长具有惯性与路径依赖性,当期 AI 生产率效应受到前期技术积累、组织学习和资源配置状态的持续影响。可知,考察 AI 生产率效应时,若不显示性纳入生产率惯性,将容易产生动态遗漏偏误,从而削弱对真实经济效应的识别能力。

静态 FE 模型仅识别出 AI 变动当期的微弱负向系数,难以揭示 AI 影响制造业全要素生产率增长的跨期演化路径,本质上是由于静态模型将多期动态效应压缩为单一的当期线性关系。以模型(2)的 Lag2 设定作为基准模型,AI 生产率效应呈现出较为清晰的动态结构:AI 变动当期系数显著为负,滞后 1 期系数显著为正,而滞后 2 期系数不显著。该结果说明,AI 扩散并不会在导入期即时带来生产

表 3　变量描述性统计

变量符号	变量说明	均值	标准差	最小值	中位数	最大值
TFP_{Growth}	TFP 增长率(OP 法)	0.002 4	0.028 4	−0.268 0	0.003 2	0.298 1
AI_{Growth}	AI 变动率(熵值法)	0.056 5	0.457 8	−3.884 5	0.015 1	3.286 9
Size	企业规模(ln 总资产)	22.186 0	1.175 0	19.774 0	22.041 0	25.629 0
Lev	财务杠杆	0.411 3	0.197 7	0.014 3	0.402 8	1.000 0
Age	企业成立年限	24.890 0	6.270 0	3.000 0	25.000 0	68.000 0
HHI	市场竞争度	0.063 1	0.053 5	0.014 0	0.039 4	0.280 2

表 4　基准回归结果:静态 FE *vs* System GMM

变量指标	(1)	(2)	(3)	(4)
	Static FE	System-GMM (Lag 2)	System-GMM (Lag 3)	System-GMM (Lag 4)
TFP 增长率滞后 1 期		0.713 3*(0.040 0)	0.687 7*(0.038 7)	0.624 4*(0.039 6)
AI 变动当期	−0.003 2**(0.001 3)	−0.154 9*(0.048 9)	−0.178 8*(0.060 2)	−0.095 4*(0.038 5)
AI 变动滞后 1 期		0.128 2*(0.040 5)	0.149 7*(0.051 2)	0.074 9(0.032 1)
AI 变动滞后 2 期		0.003 8(0.003 6)	0.000 3(0.003 0)	−0.001 5(0.002 6)
AI 变动滞后 3 期			−0.004 0*(0.002 4)	−0.003 3(0.002 2)
控制变量	Yes	Yes	Yes	Yes
年份固定效应	Yes	Yes	Yes	Yes
企业固定效应	Yes	Yes	Yes	Yes
样本数	24 638	17 967	15 231	12 850
Hansen 检验 P 值		0.672	0.125	0.081
AR(1)检验 P 值		0.000	0.000	0.000
AR(2)检验 P 值		0.506	0.511	0.942

注:括号内为稳健标准误;*、**、***分别表示 $P<0.05$、$P<0.01$、$P<0.001$。

率改善,企业更可能首先面临系统集成、流程重构、数据治理和技能适配等调整成本,从而抑制当期 TFP 增长。随着组织学习与技术适配推进,AI 收益在后一时期开始释放,推动全要素生产率回升。

3.3　动态时序效应与 J 曲线检验

3.3.1　动态时序效应分解

AI 变动对制造业企业全要素生产率增长呈现当期为负、滞后转正、远期趋于收敛的动态特征。该结果与导入期受抑-适配期回升-后期边际收敛的理论判断总体一致。仅凭单个时期系数的符号和显著性变化,仍不足以判断 AI 生产率效应的跨期传导路径具有 J 曲线型动态结构,需进一步通过动态时序效应估计,考查 AI 冲击在不同时间维度上的作用方向、强度及长期传导特征。通过对当期负向效应与滞后正向叠加效应联合检验,识别 AI 扩散生产率效应的阶段性时间结构,是否表现为“短期调整-滞后释放-边际收敛”的 J 曲线型动态演化过程。基于 Lag2 的 System GMM 基准模型,AI 变动对全要素生产率增长的滞后累积效应与长期均衡效应可分别表示如下。

滞后累积效应(不含当期冲击):

$$\mathrm{LGE}=\frac{\beta_1+\beta_2}{1-\rho}=\frac{0.128\ 2+0.003\ 8}{1-0.713\ 3}=0.460\ 4 \tag{25}$$

长期均衡效应(含当期冲击):

$$\mathrm{LRE}=\frac{\beta_0+\beta_1+\beta_2}{1-\rho}=\frac{-0.154\ 9+0.128\ 2+0.003\ 8}{1-0.713\ 3}=-0.08 \tag{26}$$

式中:LGE 为 AI 在导入当期之后通过技术适配、组织学习与互补性资产积累所释放的后续累计收益;LRE 为在纳入导入当期调整成本冲击后的长期净均衡影响。表 5 进一步展开了 AI 变动对制造业企业全要素生产率增长的动态时序效应。

AI 变动当期系数显著为负($\beta_0=-0.154\ 9$,$P=0.002$),表明 AI 导入初期并不会立即转化为可观测的生产率改善,企业反而首先面临系统集成、流程重构、数据治理和技能再配置等调整成本,从而压低当期 TFP 增长表现。滞后 1 期系数显著转正($\beta_1=0.128\ 2$,$P=0.002$),说明随着技术适配、组织学习和互补性资产积累逐步推进,AI 收益开始在后续阶段释放,并推动全要素生产率回升。滞后 2 期系数虽仍为正,但未达到统计显著水平($\beta_2=0.003\ 8$,$P=0.294$),说明更远期边际促进作用已明显收敛,AI 生产率效应进入平缓释放阶段。

3.3.2　J 曲线效应检验

进一步对当期负向效应与滞后正向叠加效应进行联合检验。表 6 显示,AI 当期效应显著为负

表 5　$AI_{_Growth}$ 对 $TFP_{_Growth}$ 的动态时序效应

时间维度	系数	标准误	t	P	经济意义
AI 变动当期	−0.154 9	0.048 9	−3.17	0.002	调整成本期
AI 变动滞后 1 期	0.128 2	0.040 5	3.17	0.002	收益显现
AI 变动滞后 2 期	0.003 8	0.003 6	1.05	0.294	平稳期
滞后累计长期效应(不含当期)	0.460 4	0.155 6	2.95	0.003	长期收益红利(滞后释放)
长期均衡效应	−0.080 0	0.026 2	−3.05	0.002	长期净效应(成本-收益抵扣后)

注：基于 Lag2 的 System GMM 基准模型估计结果整理。

表 6　J 曲线型动态结构的联合检验结果

检验内容	统计量	P	结论
H1a：当期负向效应检验	$z=-3.17$	0.002	成立(显著)
H1b：滞后正向叠加检验	Wald $\chi^2=10.56$	0.001	成立(显著)
综合判断			存在典型的 J 曲线效应

注：H1a 检验 AI 当期系数是否显著为负，对应短期调整成本假设；H1b 检验 AI 滞后 1 期与滞后 2 期系数之和是否显著为正，对应滞后收益释放假设。

($z=-3.17$，$P=0.002$)，支持短期调整成本假设，说明在导入阶段，数据治理、系统整合与组织调整等成本显著抑制当期 TFP 增长；滞后两期系数之和显著为正(Wald$\chi^2=10.56$，$P=0.001$)，表明在技术适配、组织学习和流程优化逐步推进后，AI 收益能通过滞后渠道显著释放与带动 TFP 增长回升。

AI 生产率效应的当期负向冲击与滞后正向回升在经验上成立，说明 AI 对中国制造业全要素生产率增长的影响支持 J 曲线型动态结构。J 曲线刻画的是动态形态，即导入期成本先行、适配后收益释放；长期净效应何时由负转正，取决于企业对 AI 的持续投入、组织学习深化及互补性无形资产积累的速度。

3.4　资本深化与技术进步效应分解

AI 对制造业企业全要素生产率增长的影响具有跨期结构性，即导入期表现为显著受抑，随后在滞后期逐步回升。J 曲线动态路径的效率贡献来源是什么？具有何种结构特征？AI 进入制造业生产体系后，其生产率贡献可能同时作用于资本深化与技术进步维度，且二者释放节奏不一致。因此，在 Solow 增长核算框架下，将劳动生产率增长分解为技术进步效应与资本深化贡献，以识别 AI 扩散在不同阶段的作用来源。

采用 Difference GMM 对上述分解项估计，使用滞后两期的内生变量作为工具变量，以缓解 AI 引入可能受企业既有经营状态和生产率预期影响而带来的反向因果问题。表 7 显示，AI 变动($AI_{_Growth}$)对劳动生产率总体增长的影响系数为 −0.015 3，说明样本期内 AI 的快速扩散并未立即带来劳动生产率的同步改善，而是呈现出总体净效应偏弱甚至下降的特征。从分解项看，AI 变动对资本深化贡献的系数显著为正(0.008 2，$P<0.001$)，表明制造业企业在 AI 导入初期，首先通过引入智能装备、自动化系统、工业软件和算力基础设施等方式提升资本存量和资本质量，从而推动资本-劳动比上升，资本深化效应已经开始显现。同时，AI 变动对技术进步效应的系数显著为负(−0.021 5，$P<0.01$)，说明 AI 扩散在短期并未立即改善企业的技术效率和资源配置效率，反而对效率项形成了显著抑制。由于技术进步项的负向影响幅度大于资本深化项的正向贡献，劳动生产率总体净效应最终表现为弱负方向。

导入初期，AI 引入更接近于智能资本品扩张，企业增加智能设备、软件系统和算力投入改善生产条件，此时资本深化贡献虽然已呈现正向，但作用幅度相对有限。此时技术进步效应显著为负，反映 AI 技术导入与扩散初期的流程再造、岗位调整与组

表 7　AI 变动影响劳动生产率的效应分解

变量指标	(1)	(2)	(3)
	劳动生产率增长	技术进步效应	资本深化效应
AI 变动	−0.015 3* (0.008 1)	−0.021 5** (0.008 8)	0.008 2*** (0.003 8)
企业规模	−4.892***	−5.731***	0.835**
财务杠杆	2.103*	1.984	0.122
企业年龄	−0.541	−0.422	−0.118
国有企业	1.325	1.104	0.221
行业集中度	−12.44	−13.21	0.765
样本数	21 253	21 253	21 253
R^2	0.212	0.218	0.275
AR(1)检验 P 值	0.000	0.000	0.004
AR(2)检验 P 值	0.342	0.415	0.288
Hansen 检验 P 值	0.156	0.182	0.245

注：*、**、***分别表示 $P<0.05$、$P<0.01$、$P<0.001$；括号内为稳健标准误；AR(2)检验 $P>0.1$ 表明残差无二阶序列相关，模型设定有效；Hansen 检验 $P>0.1$ 表明工具变量有效(外生)。

织磨合扰动成本抑制了直观效率提升，生产员工技能错配短期内会削弱劳动效率表现。技术进步项建立在组织学习、数据治理、业务适配和知识沉淀逐步完成的基础上，反映的是企业整体效率提升和资源配置优化，其释放具有更明显的滞后性。技术进步效应在短期内受到显著压制，恰恰构成了 J 曲线动态路径中“当期受抑”的结构性来源。AI 扩散早期，资本深化的正效应不足以抵消技术进步效应的负向冲击，劳动生产率总体净效应表现为偏弱甚至为负，此时不足以推动生产函数整体外移。综合看，AI 导入初期通过资本投入扩张形成资本深化贡献，技术效率改善仍受到调整成本压制，因而总体生产率短期受抑；随着适配、吸收与学习过程推进，AI 生产率贡献才可能由资本深化主导逐步演进为技术进步主导。

3.5　稳健性检验

（1）从被解释变量与核心解释变量进行变量替代，检验主要结论对变量测度口径的敏感性。在被解释变量方面，采用 Wooldridge 法测算并构造 TFP 增长率指标，代入模型进行重复估计以检验结论是否依赖特定 TFP 测度口径；在解释变量方面，将 AI 熵值法替换为 PCA 法测度结果代入模型进行重复估计。表 8 表明，AI 生产率效应当期受抑、滞后回升的阶段性路径特征，在变量替代条件下仍能实现交叉验证，说明核心结论具有良好稳健性。PCA 口径下当期负向、滞后 1 期正向，表明 PCA 法提取的共同成分更为集中，凸显了企业 AI 引入初期“摩擦成本负向抑制”的特征，从而在动态回归中呈现更强的估计强度。两类 TFP 测度口径下的持续性系数接近且均显著，说明生产率变动的惯性特征对 AI 指数构建方式不敏感。

（2）选取 AI 专利数量作为替代性指标对估计结果进行交叉印证。AI 专利指标同时具备“创新含量高、技术关联度强、公开透明、可量化”等特征，科学反映企业 AI 研发与应用水平，被广泛用于衡量企业在 AI 及相关领域的技术积累与创新能力。表 9 基于 AI 专利数作为替代性指标的交叉验证结果显示，该“当期受抑-滞后回升”的动态结构与基准模型的 J 曲线效应完全一致，说明企业在加大 AI 研发投入的初期存在较高的调整成本与试错摩擦成本，从而抑制当期的效率表现；滞后 1 期系数显著为正，反映出技术积累与创新成果转化为可观测的效率增长。

表 8　稳健性检验：替代 TFP 测度方法

被解释变量	解释变量	样本数	AI 当期（β_0）	滞后 1 期（β_1）
$TFP_{_OP_Growth}$	AI_熵值法	15 350	−0.188**	0.155**
$TFP_{_Wooldridge_Growth}$	AI_熵值法	15 350	−0.097*	0.082*
$TFP_{_OP_Growth}$	AI_PCA 法	15 350	−0.229**	0.193**

注：*、**、***分别表示 $P<0.05$、$P<0.01$、$P<0.001$。

表 9　基于 AI 专利的稳健性检验结果

变量指标	TFP 增长率（OP 法）
AI 专利当期	−0.004 9**（0.002 0）
AI 专利滞后 1 期	0.025 7***（0.007 2）
TFP 增长率滞后 1 期	0.683 1***（0.153 0）
控制变量	Yes
常数项	0.219 9***（0.062 0）
样本量	15 350
AR(2)检验 P 值	0.241 2
Hansen 检验 P 值	0.196 1

注：*、**、***分别表示 $P<0.05$、$P<0.01$、$P<0.001$；括号内为稳健标准误。

4　异质性分析

基准估计与动态时序检验表明，AI 扩散对中国制造业企业全要素生产率增长的影响总体上呈现“当期受抑-滞后回升-边际收敛”的 J 曲线型动态结构。不同企业约束条件下，AI 生产率回报具有明显的分段性和条件依赖性，进一步从企业内部能力差异与外部资源配置环境两条主线出发，结合制造业企业的行业属性、所有制结构、区域环境、企业规模和 AI 应用强度等维度开展分组检验，结果见表 10。

从行业属性看，标准 J 型动态结构主要出现在技术密集型行业，AI 当期系数显著为负（$\beta_0=-0.085\ 7$，$P<0.05$），滞后 1 期系数显著为正（$\beta_1=0.068\ 7$，$P<0.05$），说明在技术复杂度较高、知识密集度较强的技术密集型行业中，企业通常具备更好的研发基础、人力资本储备和数据积累能力，更容易跨越 AI 应用门槛、更快进入效率释放阶段；非技术密集型行业的当期和滞后 1 期系数均不显著，说明 AI 应用较难形成稳定系统性生产率回报，尚不足以推动生产函数曲线的整体扩张外移。行业间差异本质上反映了技术基础、吸收能力和资源配置效率的差异，与本文“互补条件越成熟，越容易跨越低效应用阶段”的理论判断一致。

从所有制结构看，国有企业与非国有企业表现出明显不同的动态路径。在国有企业组中，AI 当期系数显著为负（$\beta_0=-0.101\ 0$，$P<0.05$），滞后 1 期系数显著为正（$\beta_1=0.084\ 7$，$P<0.05$），呈现较为典型的标准 J 型结构。国有企业在 AI 导入初期更容

表 10　异质性分析：System GMM 结果

分组维度	子分组	AI 当期	AI 滞后 1 期	TFP 持续性	J 曲线特征
行业类型	技术密集型	−0.085 7*	0.068 7*	0.701*	显著
	非技术密集型	−0.036 9	0.031 9	0.723***	不显著
所有制	国有企业	−0.101 0*	0.084 7*	0.748***	显著
	非国有企业	0.164 5*	−0.132 5*	1.221***	不显著
规模	大企业	0.059 6	−0.047 2	1.130***	不显著
	小企业	−0.112 9	0.100 1	0.732***	不显著
地区	东部地区	0.141 5*	−0.116 4*	1.227***	显著
	中部地区	−0.021 5	0.020 3	1.160***	不显著
	西部地区	−0.181 6*	0.151 9*	0.187	显著
	东北地区	−0.104 7	0.102 5	−0.156	不显著
AI 强度	高 AI 投资	0.055 2*	−0.029 7*	0.716***	显著
	低 AI 投资	−0.005 5	−0.016 5	0.749***	不显著

注：*、**、*** 分别表示 $P<0.05$、$P<0.01$、$P<0.001$；样本量为进入 GMM 回归的有效观测数（因差分少于全样本）。

易受到组织重构、制度适配和流程磨合成本的影响，依托相对稳定的资金来源、较强的组织承载能力和持续投入能力，能够在完成适配后逐步释放 AI 带来的生产率增益。非国有企业则呈现直观相反的“倒 J 曲线型”局部动态模式：AI 当期系数显著为正（$\beta_0=0.164\ 5$，$P<0.05$），滞后 1 期系数显著为负（$\beta_1=-0.132\ 5$，$P<0.05$），表明初期非国有企业可更快地通过局部自动化、流程优化或数据驱动决策完成资本深化，从而获得效率改善；受制于持续投入能力不足、组织稳定性较弱及治理机制不完善，后续生产率边际回报出现回落。

从企业规模看，当前样本期内均未呈现稳定显著的 J 型动态证据，表明规模优势并不会自动转化为 AI 生产率收益。大企业通常具有更强融资能力、更完善数字基础设施和更高的技术投入能力，能够承担 AI 导入所需的固定成本和互补性投入；但其层级结构更复杂、决策链条更长、部门壁垒更强，组织惯性和协调摩擦也更显著，可能延缓收益释放甚至掩盖短期效应。小规模企业生产率效应虽然接近标准 J 型，但也未达到显著水平。一方面，可能因为规模优势与组织摩擦、灵活性与资源约束等因素同时存在，样本期内企业规模差异尚未形成清晰的生产率红利释放路径；另一方面，也可能源于选择上市公司企业作为样本，导致规模异质性分组不敏感。

区域分组结果表明，AI 生产率效应具有明显的空间分化。中国东部地区 AI 当期系数显著为正（$\beta_0=0.141\ 5$），滞后 1 期系数显著为负（$\beta_1=-0.116\ 4$），表现为“短期改善、随后回落”的反向动态模式。中部地区当期和滞后 1 期系数均不显著，说明样本期内 AI 扩散尚未形成稳定可识别的生产率增量，更可能仍处于扩散推进和消化吸收阶段。西部地区则呈现较典型的标准 J 型路径：AI 当期系数显著为负（$\beta_0=-0.181\ 6$，$P<0.05$），滞后 1 期显著为正（$\beta_1=0.151\ 9$，$P<0.05$），表明 AI 导入初期更容易受到组织调整、系统磨合和技能匹配等成本冲击，但随着后续学习积累和应用稳定化，效率增益会在滞后期集中释放。中国东北地区样本量较小且未达到显著水平，不宜作强结论。

AI 应用强度分组检验显示，在高 AI 投资企业中，AI 当期系数显著为正（$\beta_0=0.055\ 2$，$P<0.05$），滞后 1 期系数显著为负（$\beta_1=-0.029\ 7$，$P<0.05$），呈现出“早期改善、后续回落”的反向动态模式。高 AI 应用强度企业凭借更好的数字基础、数据资源和技术储备，更容易在导入初期通过局部自动化、管理优化或决策支持系统获得即时效率改善；后续随着系统复杂度、跨部门协同需求、模型治理要求和内部控制成本上升，若组织治理能力、流程标准化水平和人才结构未能及时跟进，新增 AI 投入的边际收益便趋于收敛甚至回落。相比之下，低 AI 应用强度企业的当期与滞后 1 期系数均不显著，说明在较低应用强度下，AI 更可能停留在试点部署和局部应用阶段，尚不足以形成稳定可识别的生产率增量。

5　结论与对策

通过分析 AI 影响中国制造业全要素生产率的作用逻辑、动态路径、结构差异与异质性条件，形成了完整结论：人工智能对中国制造业全要素生产率的影响具有显著的跨期动态性、结构阶段性和条件异质性，整体呈现“当期受抑、滞后回升、边际收敛”的 J 曲线型动态轨迹。导入初期，AI 以边际报酬递减的“资本品”角色进入制造业生产体系，AI 生产率效应表现为沿既定生产函数曲线平滑移动。适配阶段，AI 以内生创新要素形式嵌入制造业生产体系，作为“知识载

体”呈现边际报酬递增特征;GPTs 扩散诱发广泛的互补创新与生产重组,初期局部试点阶段“孤岛式”改进表现为成本先行、集中前置;企业具备相应吸收转化能力后,AI 从短期资本投入转化为长期技术进步贡献,并通过创新扩散形成持续的全要素生产率增长。成熟期阶段,新增 AI 可能形成重复建设、资源错配和协调摩擦,AI 生产率增益趋于收敛甚至回落。AI 扩散初期通过智能设备、软件系统和算力等资本性投入推动资本深化贡献,而技术进步效应在短期内受到效率扰动和组织摩擦压制,呈现显著负向;由于资本深化的正向贡献不足以抵消技术效率项的负向冲击,劳动生产率总体净效应在样本窗口内表现为偏弱甚至为负。AI 生产率回报异质性与分段效应检验表明,技术密集型行业、国有企业和西部地区呈“J 曲线型”动态结构;非国有企业、东部地区和高 AI 强度企业更容易表现出短期改善、后续回落的“倒 J 曲线”动态模式。据此,提出如下政策建议:①强化数据算法、软件平台和人才体系建设,政策重心由硬件购置转向软硬协同的场景应用;②完善分层分类推进和差异化支持机制,增强政策工具与企业吸收能力、区域数字基础条件及产业场景成熟度之间的匹配性;③营造有利于竞争、扩散与协同创新的产业环境,使人工智能效率红利长期可持续性兑现,推动人工智能更有效赋能制造业高质量发展。

参考文献

[1] 戚聿东,沈天洋. 人工智能赋能新质生产力:逻辑、模式及路径[J]. 经济与管理研究,2024,45(7):3-17.

[2] 程文. 人工智能,索洛悖论与高质量发展:通用目的技术扩散的视角[J]. 经济研究,2021,56(10):22-38.

[3] ROMER P M. Endogenous technological change[J]. Journal of Political Economy,1990,98:272-287.

[4] SHAHID M K,KHIN A A,SEONG L C,et al. Mapping the relationship of research and development expenditures and economic growth through bibliometric analysis:a theore-tical perspective[J]. Journal of the Knowledge Economy,2024,15(4):17529-17555.

[5] 吕越,谷玮,包群. 人工智能与中国企业参与全球价值链分工[J]. 中国工业经济,2020(5):80-98.

[6] ACEMOGLU D. The simple macroeconomics of AI[J]. Economic Policy,2025,121:13-58.

[7] SOLOW R M. A Contribution to the theory of economic growth[J]. Quarterly Journal of Economics,1956(1):65-94.

[8] 汪玖明,王凤羽,齐义山. “软硬”兼施:人工智能产业创新生态如何赋能新质生产力:基于动态 QCA 的研究[J]. 管理现代化,2026(1):1-13.

[9] 唐要家,王蜡,唐春晖. 人工智能如何提升企业全要素生产率:基于技术创新和技术应用视角[J]. 财经问题研究,2025(1):87-100.

[10] BRESNAHAN T F,TRAJTENBERG M. General purpose technologies:“engines of growth”?[J]. Journal of Econometrics,1995,65(1):83-108.

[11] COHEN W M,LEVINTHAL D A. Absorptive capacity:a new perspective on learning and innovation[J]. Administrative Science Quarterly,1990,35(1):128-152.

[12] BRYNJOLFSSON E,ROCK D,SYVERSON C. The productivity J-curve:how intangibles complement general purpose technologies[J]. American Economic Journal Macroeconomics,2021,13(1):333-372.

[13] 曲帅,郑蒋博文,李富强. 人工智能投入与企业生产率:对“生产率悖论”的经验证据[J]. 科学决策,2025(10):94-106.

[14] 张应武,李家文. 人工智能驱动新质生产力:理论逻辑与实证检验[J]. 成都理工大学学报(社会科学版),2025,33(3):51-71.

[15] 鲁晓东,连玉君. 中国工业企业全要素生产率估计:1999-2007[J]. 经济学(季刊),2012,11(2):541-558.

Impact of Artificial Intelligence on Total Factor Productivity of China's Manufacturing Industry

CAI Zhenjun

(Hunan International Economics University, Changsha 410205, China)

Abstract: Chinese A-share manufacturing listed companies from 2013 to 2024 were selected as the research sample. Analyses were conducted using the generalized method of moments (GMM). It is found that the overall impact of artificial intelligence(AI) diffusion on the growth of total factor productivity in China's manufacturing industry exhibits a J-curve trajectory characterized by “suppression in the current period, lagged recovery, and marginal convergence”. From the perspective of temporal structure, the channel structure through which artificial intelligence affects productivity shows phased differences, evolving from being dominated by capital deepening to being dominated by technological progress. After multiple variable substitutions, the conclusions remain robust. Through the heterogeneity analysis, it is shown that the productivity gains of artificial intelligence vary across industry environments, ownership structures, regional conditions and AI application intensities where enterprises operate. To promote the high-quality development of manufacturing industry empowered by artificial intelligence, China should not only prioritize hardware investment, but also attach great importance to the mitigation of initial costs, the construction of software and hardware collaboration capabilities, and the improvement of a classified and hierarchical governance system.

Keywords: artificial intelligence(AI); manufacturing industry; total factor productivity; listed company; J curve