DOI:10.13502/j.cnki.issn1000-7636.2026.11.005

人工智能重塑创新绩效:机制解构与实践探索

胡朝阳 张自然

摘要:人工智能(AI)正深度融入中国创新体系,其微观机制亟须结合本土实践加以探究。本文拓展离散时间无限期优化模型,将AI赋能水平内生嵌入知识演化、创新成本、创新产出与市场收益函数,构建赋能、降本与激励效应的统一分析框架,验证三重机制的存在性及交互影响。在此基础上,选取科大讯飞公司作为典型案例,剖析机制协同及"AI漂洗"风险防范路径,实现理论与实践的交叉验证。理论推导发现:过度激励易诱发"AI漂洗",进而弱化赋能效应与降本效应。其中,赋能效应着眼于创新弹性与转化效率的提升;降本效应关注压缩结构性成本的筛选;激励效应聚焦信号传递及其引发的融资溢价。本文的案例研究揭示了三重机制在企业实践中的动态耦合,精准契合创新主体通过AI赋能、AI降本与AI推动的融资激励驱动创新绩效提升的核心诉求,并识别出战略自律、财务透明与生态约束等防范"AI漂洗"风险的有效机制。本文为理解AI如何提升创新绩效提供统一理论解释与本土实证证据,亦为完善AI相关政策设计提供了有益启示。

关键词:人工智能 创新绩效 赋能效应 降本效应 激励效应 AI漂洗

中图分类号:F49;F273.1 **文献标识码**:A **文章编号**:1000-7636(2026)11-0061-15

一、问题提出

当前,全球正经历以人工智能(artificial intelligence,AI)为核心的新一轮科技革命。在此背景下,中国将"人工智能+"行动作为推动经济高质量发展、实现高水平科技自立自强的重要战略抓手。《中华人民共和国国民经济和社会发展第十五个五年规划纲要》明确指出,"深化拓展'人工智能+',赋能经济社会发展和治理能力提升,促进生产方式深层次变革和生产力革命性跃迁"。马里亚尼等(Mariani et al.)将AI定义为"旨在使机器具备类人的感知、推理与行动能力的智能代理系统",并进一步指出AI的核心能力包括知识表示与获取、自主学习、智能推理与决策[1]。正是凭借这些独特能力,AI在知识萃取、模式识别与智能推演等方面具备显著优势,从而为创新主体突破知识积累瓶颈[2-3]、成本控制难题[4-5]、价值回报梗阻[6-7]等现实困境提供了理论上的可能性。前沿企业的突破性实践已将上述理论潜力转化为现实,并呈现出三个相互关联的典型事实:其一,在知识生产端,AI通过将隐性经验即时转化为显性资产,使单位知识投入的产出效率实现指数级跃升[8];其二,在成本控制端,AI通过虚拟筛选与智能推演大幅压缩试错周期与物料消耗[9-10];其三,在价值回报端,动态的AI技术采纳行为本身已演变为一种高价值的市场信号,触发了独特的资本市场激励机制,形成了"技术信号—融资溢价—创新反哺"的正向闭环[11-12]。

收稿日期:2026-03-13; 修回日期:2026-09-28

基金项目:国家社会科学基金重点项目"降碳、减污、扩绿、增长协同推进的理论与实践研究"(24AZD074)

作者简介:胡朝阳 中国社会科学院大学经济学院博士研究生,北京,102488;

张自然 中国社会科学院经济研究所研究员,博士生导师,通信作者,北京,100836。

作者感谢审稿快线专家的评审意见。

随着“人工智能+”行动向微观创新场景纵深推进,AI 已从辅助性工具跃升为重塑创新生态的核心引擎。然而,在 AI 技术快速渗透的表象之下,仍有两方面核心问题亟待厘清。一是 AI 系统性提升创新主体绩效的内在作用机制有哪些?尽管现有文献已广泛证实 AI 在提升研发效率[13]、压缩试错成本[14-15]及释放积极市场信号[16]等方面的显著效应,但既有研究多将 AI 视为外生冲击,或停留于平均效应的现象描述,未能将 AI 赋能有机嵌入内生理论框架中,致使 AI 重塑创新底层逻辑的系统性作用被掩盖。二是不同机制在创新者跨期决策中的运行逻辑是什么?彼此是否存在交互影响?当前研究多聚焦单一维度的静态考察,呈现明显的碎片化特征,鲜有学者将不同机制纳入统一分析框架。这不仅难以系统阐释多重路径如何协同作用于创新全周期,更缺乏对机制间交互影响的深入剖析。

本文旨在系统回答上述核心问题,真正打开 AI 推动创新传导机制的“黑箱”,揭示 AI 与人类创新活动深度融合的微观逻辑。立足个体创新者决策优化的现实需求,梳理 AI 作用于个体创新者决策行为的潜在机制,并实现理论层面与实证层面的深度互证。在理论层面,拓展离散时间无限期优化模型,将 AI 赋能水平嵌入知识积累过程、成本约束结构与资本市场信号生成机制,通过比较静态分析精准识别赋能效应的作用边界,借助成本最小化推导厘清降本效应的函数特征,并依托信号传递范式验证激励效应的单交叉条件与贝叶斯更新逻辑。这不仅实现三重机制在统一框架内的逻辑分离和数理自洽,还进一步引入 AI 质量信号,验证过度的激励效应会诱发“AI 漂洗”,从而弱化赋能效应与降本效应。在实证层面,聚焦中国创新实践前沿,选取科大讯飞公司作为典型案例,系统解构 AI 如何通过赋能效应、降本效应和激励效应三重机制提升企业创新绩效,并进一步梳理“AI 漂洗”风险诱因与防范路径,从而完善相关政策设计,为促进 AI 与创新活动的深度融合提供理论依据与现实参考。

本研究的边际贡献主要体现在以下三个方面。一是构建了 AI 影响企业创新的整合性理论框架与机制体系。通过拓展离散时间无限期优化模型,将 AI 赋能水平内生嵌入知识演化方程、非线性成本函数与信号生成机制,从而在统一的跨期动态优化框架下实现了赋能效应、降本效应与激励效应三重机制的逻辑整合与数理自洽。二是揭示了三重机制间的交互影响与风险传导路径。通过数理推导验证激励效应过度可能诱发“AI 漂洗”行为,并进一步阐明该行为通过资源挤出与配置扭曲弱化赋能效应与降本效应,从而深化了对 AI 赋能创新系统性与复杂性的认知。三是实现了理论推导与典型案例的交叉验证。选取扎根中国创新实践的科大讯飞作为典型案例,生动阐释 AI 通过三重机制激活创新主体内生动力的现实运行逻辑,精准契合理论模型的推导结果。案例研究揭示的“AI 漂洗”风险诱因与防范机制,亦在交互效应的理论推导中得到逻辑自洽的解释,从而实现理论与实践的完整双向互证,为打开 AI 赋能创新的机制黑箱提供了可检验、可拓展的学理解答和实践注脚。

二、典型事实与文献综述

(一)典型事实

在 AI 技术加速渗透创新全链条的背景下,一系列突破性的实践现象正挑战着对技术创新的传统认知。通过对华为技术有限公司(简称“华为”)、英矽智能科技(上海)有限公司(简称“英矽智能”)、科大讯飞股份有限公司(简称“科大讯飞”)等前沿企业的深度观察,识别出三个相互关联却机制迥异的特征化事实,它们共同构成了本文理论探索的现实起点。

事实 1:AI 驱动的知识增殖效应超越了传统“干中学”的线性积累逻辑。以华为鸿蒙生态的开发为例,开发者并非孤立地依赖个人经验进行代码编写,而是深度嵌入一个由 AI 驱动的协同知识网络。AI 助手不仅能实时生成、调试和优化代码,更能基于海量历史项目数据主动推荐最优解决方案,并将个体的隐性经验即时转化为可复用的显性知识资产[8]。这一过程推动单位知识投入的产出效率呈指数级增长,产品迭代速度远超传统模式。这表明,AI 不仅是知识处理的工具,更是内生于知识演化方程、系统性重塑“知识存量—

创新产出”转化效率的结构性变量。

事实 2:AI 重构了创新的成本函数,降本逻辑从节约开支转向规避风险。英矽智能的药物研发实践提供了一个典型例证。传统药物发现高度依赖高成本、高失败率的物理实验试错,成本结构呈现显著的非线性特征。而英矽智能通过其自主研发的生成式张量强化学习模型,能够对海量化合物进行虚拟筛选与智能推演,在靶向药开发中快速筛选出可行性高、风险可控的技术路径,大幅压缩研发周期[9]。这种智能筛选模式,仅需 46 天即可完成 6 种盘状结构域受体抑制剂的设计、合成和测试,物料消耗与人力投入均大幅降低[10]。这表明,AI 的作用并非简单地降低平均成本,而是通过改变技术路径的选择逻辑,内在地重塑了整个创新活动的成本结构与风险分布。

事实 3:AI 技术采纳本身构成一种高价值的市场信号,触发了独特的资本市场激励机制。科大讯飞的案例揭示了 AI 赋能的第三重维度。该公司通过构建从基础大模型到行业应用的纵向贯通式 AI 技术体系,向市场持续传递其深厚的技术适应能力与系统性创新能力[11]。例如,在确立围绕 AI 技术体系的发展战略后,科大讯飞于 2021 年完成 1 次定向增发,募集资金净额约 25.37 亿元,重点投向底层技术研发与生态构建,持续强化 AI 技术研发强度与人才集聚能力。此后,企业依托开放平台汇聚开发者生态,将技术能力转化为教育、医疗等民生领域的解决方案。资本市场敏锐捕捉并解读了这一信号,将其视为企业未来高成长潜力的可靠标识,从而给予显著的融资溢价与估值提升[12]。根据万得(Wind)数据库的数据,2023 年 9 月“星火”大模型 V3.5 版本突破多模态推理瓶颈后,公司市值当月增长约 9.80%。这形成了“技术信号—资本市场溢价—创新资源反哺”的正向激励闭环。这一现象超越了传统企业信号理论中对专利、学历等静态指标的关注,凸显了动态技术采纳行为作为一种新型能力信号的独特价值及其在资本市场的定价逻辑。

综上所述,这三个典型事实共同指向一个核心命题:AI 对创新的影响是系统性、内生性且多维交织的。它既作用于微观层面的知识生产函数,又重塑了中观层面的成本结构,还激活了宏观层面的资本市场反馈机制。然而,现有研究尚未提供一个统一的理论框架来解释这三重机制如何在个体创新者的跨期决策中协同运作。这也正是本文试图填补的理论空白。

(二)文献综述

1. AI 与创新效率

创新效率的理论根基可追溯至阿罗(Arrow)[17]提出的“干中学”模型,该模型将知识积累作为推动生产过程的内生变量,揭示其对创新能力的持续塑造。格里利谢兹(Griliches)进一步构建了知识生产函数框架,阐述了知识存量转化为研发投入,并最终形成创新产出的“存量—流量”转化逻辑[18],这一框架成为理解创新效率微观机制的经典范式。近年来,伴随 AI 技术逐步渗透至创新活动的全流程,学者们开始关注 AI 对创新效率的提升效应。范德舒特等(van de Schoot et al.)基于全球科研行为大数据证实,AI 辅助工具使文献检索与知识整合效率提升 50%以上,并促进跨学科知识迁移与创新构思的生成[13]。比安基尼等(Bianchini et al.)通过案例比较指出,生成式模型通过增强模式识别与联想推理能力,缩短了从知识输入到创新产出的转化周期[19]。然而,现有研究虽已指出 AI 的技术效应不应仅被视作外生效率参数,但在理论建模层面仍沿袭格里利谢兹[20]的知识生产函数与哈勒等(Hall et al.)[21]的专利生产模型框架,将 AI 效应简化为静态乘数,忽视了其对知识存量跨期演化的内生嵌入作用。这一局限导致对“技术赋能—认知增强—知识增殖”微观路径的刻画不足,未能揭示 AI 如何通过重构知识演化轨迹提升创新效率。

2. AI 与创新成本

创新成本结构的理论脉络始于弗里曼(Freeman)[22]对技术不确定性的经典论述,该文献指出研发过程中的试错行为构成创新成本的核心组成部分。辛普森等(Simpson et al.)进一步将创新成本解构为固定成本与可变成本,并系统阐释了可变成本中试错成本与风险成本的非线性特征,奠定了成本分析的理论基础[23]。在 AI 赋能背景下,生物医药领域的大量研究证实,AI 驱动的虚拟筛选与数字孪生技术能将候选分子验证周

期大幅压缩,降低了实验物料与人力消耗[14,24]。鲁道夫(Rudroff)通过药物研发的实证研究进一步指出,虚拟实验将药物研发的总开发成本降低 50%~70%,并压缩工程迭代周期[25]。而在制造业领域,德国企业的数据表明,AI 辅助设计工具通过智能优化迭代路径,使产品开发边际成本大幅下降[15]。然而,现有研究均停留于现象描述与平均效应估计,理论模型缺乏针对性拓展。AI 赋能背景下创新成本的既有阐述既未将 AI 筛选机制内生化为成本函数中的结构性参数,亦未揭示 AI 赋能水平与边际成本弹性间的动态关系。

3. AI 信号传递与资本市场定价

信号传递理论在创新领域的应用始于斯彭斯(Spence)[26]对学历信号的经典阐释,后经苏霍罗科娃等(Soukhoroukova et al.)[27]拓展至创新情境,验证了专利质量、研发强度等可观测信号对资本市场定价的影响,确立"能力—信号—溢价"的传导逻辑。近年来,学者开始关注技术采纳行为本身的信号价值。例如,施和赫尔尼曼(Shi & Herniman)发现企业采用前沿技术的行为本身可作为组织学习能力的可信信号,进而影响投资者风险评估[28];冯和赵(Feng & Zhao)进一步指出,技术信号的完整性与场景落地实效能增强其在融资筛选中的辨识度[29]。巴比纳等(Babina et al.)验证了技术信号对资本市场定价的积极影响[16],却未将 AI 技术采纳内生化为动态信号载体。显然,传统的信号传导逻辑难以阐明 AI 作为一种体现高技术适应能力的可信信号如何影响市场预期,导致信号理论在智能技术情境下的适用边界和解释力均不足。

综上所述,现有 AI 与创新交叉研究虽在效率提升、成本压缩与信号识别等维度取得进展,但仍存在三方面的不足。一是微观主体的动态视角缺失。多数研究将 AI 效应简化为静态外生参数,忽视其在个体跨期决策中对知识演化、成本结构与信号生成的内生嵌入,缺乏对创新者"努力投入—知识积累—创新能力"反馈循环的动态刻画[20-21]。二是多维机制碎片化特征明显。已有研究分别聚焦 AI 赋能下技术效率提升路径[13]、AI 筛选引发的成本压缩机制[24-25]、技术工具推动资本市场信号精准识别[16,29],但尚未将不同机制纳入统一的跨期动态分析框架进行数理推导与实证检验,尤其缺乏对机制间交互效应的探索。三是中国情境证据薄弱。既有实证研究多植根于西方制度背景,缺乏对"人工智能+"国家战略下中国创新主体实践逻辑的深度解构,难以揭示技术工具、创新行为与制度环境间的本土化互动机制,亦无法为优化中国国家创新体系提供针对性学理支撑。

三、理论模型:AI 赋能下个体创新者的跨期动态决策

为揭示人工智能影响创新绩效的内在机制及交互效应,本文构建一个逻辑自洽的理论框架,厘清人工智能影响创新绩效的作用机制与交互效应。建模思路以离散时间无限期动态优化模型为基准,将 AI 赋能水平内生化为核心决策变量,沿着"知识积累—研发生产—市场反馈"的传导链条对经典模型加以拓展①。具体而言,通过重构知识演化方程刻画 AI 对知识转化效率的赋能路径,拓展创新成本函数揭示 AI 压缩研发试错成本的降本逻辑,引入市场收益函数阐释 AI 采纳向资本市场传递能力信号的激励机制。此外,进一步纳入信号质量变量,在信息不对称条件下刻画企业夸大 AI 成效的策略性行为,从而揭示多重机制间的交互作用。

(一)模型设定

1. 知识演化方程

本文继承了"干中学"模型的知识存量约束、知识生产函数的"存量—流量"逻辑和具有动态演化特征的内生增长理论框架[30],并借鉴贝西罗格鲁等(Besiroglu et al.)[31]的思路,将 AI 赋能水平作为独立生产要素嵌入知识生产函数,刻画其通过增强信息检索、模式识别与跨域联想能力来提升单位努力的知识转化效率的过程。具体演化方程如式(1)所示。

①限于篇幅,仅保留核心推导逻辑,具体推导和详细参数设定略,备索。

$$K_{t+1} = \max\{K_L, (1-\delta)K_t + \eta e_t^{\alpha_k} A^{\beta_k}\} \tag{1}$$

其中,K_t 和 K_{t+1} 分别表示第 t 期和第 t+1 期风险中性个体创新者的知识存量;e_t 表示创新者在第 t 期投入创新的时间与精力的强度,为经行业标准化后的变量;A 为跨期固定决策变量,表示 AI 赋能水平。参数 δ 表示知识的遗忘或迭代;η 为基准学习效率,即无 AI 赋能时单位努力的知识转化效率;α_k 表示努力对知识积累的弹性;β_k 表示 AI 赋能弹性,即 AI 通过增强信息检索精度、模式识别速度与跨域联想广度所提升的知识转化效率。常数 $K_L>0$,反映行业知识门槛,$K_t \geqslant K_L$ 用于确保风险中性个体创新者的知识存量始终非负。

2. 创新产出函数

格里利谢兹指出创新产出由研发投入与知识存量共同决定[20],由此构建了专利生产函数的经典框架。哈勒等不仅沿用专利生产函数的核心范式,还将行业知识溢出与技术机会窗口作为外生变量纳入函数设定,将创新产出函数的核心结构表示为 $q_t=f$(研发投入, 知识存量, 技术效应)[21]。比安基尼等进一步指出,AI 的技术效应不应仅被视作外生效率参数,而应理解为内生过程的机制,能够通过重构要素组合方式直接拓展创新产出边界[19]。基于此,本研究刻画 AI 通过生成式内容辅助、智能算法优化与跨模态推理等途径,提升单位努力产出效率的过程,具体创新产出函数如式(2)所示。

$$q_t = K_t^{\gamma} e_{tq}^{\alpha} A_q^{\beta} \tag{2}$$

其中,q_t 表示个体创新者在第 t 期的创新产出水平,为经行业标准化后的变量。参数 γ 表示知识存量对产出的弹性,刻画既有知识库对当期创新效率的提升强度;α_q 表示努力产出弹性,即边际努力的产出贡献率;β_q 表示 AI 产出弹性,即 AI 工具对创新产出效率的即时增强作用。其余变量或参数如前文所述。

3. 创新成本函数

创新活动同样面临固定成本与可变成本的双重约束。遵循弗里曼[22]关于创新不确定性的经典论述与辛普森等[23]对试错成本的系统分析,创新领域的可变成本进一步被划分为三类:由日常运营产生的基础成本、由技术不确定性引致的风险成本和由研发迭代过程产生的试错成本。黑夫纳等(Haefner et al.)进一步指出,AI 通过虚拟实验、数字孪生与智能仿真等技术路径,能够有效压缩创新过程中的试错成本与风险成本[24]。本文在沿用上述经典成本分析框架的基础上,将 AI 赋能水平作为关键调节变量嵌入创新成本函数,刻画 AI 通过降低实验试错频率与抑制技术不确定性等途径,对创新成本的结构性压缩作用,具体创新成本函数如式(3)所示。

$$C_t = \underbrace{c + c_0 e_t}_{\text{基础成本}} + \underbrace{c_1(1-\mu A^{\lambda})\, e_t^{\rho}}_{\text{试错成本}} + \underbrace{c_2 \sigma^2 e^{-\upsilon A} e_t^{\rho}}_{\text{风险成本}} \tag{3}$$

其中,C_t 表示个体创新者在第 t 期的创新总成本;常数 c 表示初期购买厂房设备的一次性成本;日常运营成本项 $c_0 e_t$ 反映常规运营支出总量,其中,c_0 是单位努力所消耗的运营基础成本,涵盖人力成本、常规设备能耗以及 AI 技术应用所产生的额外能源消耗。需要特别说明的是,不少文献指出,大语言模型的训练与推理过程必然伴随电力消耗,且模型复杂度越高,其能源成本将呈现指数级增长趋势[32]。然而,中国依托全球规模最大的特高压电网、智能调度系统及“东数西算”工程构建的算力基础设施,在平抑区域性能源价格波动方面具有积极作用[33]。因此,能源成本被纳入日常运营成本项。试错成本压缩项 $c_1(1-\mu A^{\lambda})$ 用于刻画 AI 通过智能筛选实验方案与优化设计路径,降低迭代次数的效果。具体而言,c_1 为基准试错成本系数,即无 AI 时单位努力的试错成本;μ 为 AI 试错成本压缩强度;λ 为压缩非线性参数。风险成本控制项 $c_2\sigma^2 e^{-\upsilon A}$ 表示 AI 通过虚拟验证与数字孪生技术筛选高风险路径、规避无效投入的机制,其中,c_2 为风险成本基础系数,即无 AI 时单位努力的风险成本;σ 是外生给定的波动率标准差,用于反映创新不确定性的程度;υ 表示 AI 风险抑制效率,υ 越大,说明 AI 通过虚拟验证压缩高风险领域成本的效果越强。ρ 为成本凸性参数,$\rho>1$ 不仅用于保证成本函数是严格凸以满足优化问题的二阶条件,从而确保唯一均衡解的存在,还进一步表明试错

成本和风险成本随着努力投入的增加而上升,直接影响当期决策。为确保试错成本非负,必须满足 $\mu A^{\lambda} \leqslant 1$。其余变量和参数如前文所述。

4. 市场收益函数

传统经济学中,市场收益指跨期产出的净利润流,即产品市场收益与支出间的差额。阿贝尔(Abel)沿用厂商利润最大化的数理模型,把不确定性放进跨期框架,从而搭建起经典的跨期收益函数[34]。不过,伴随 AI 技术嵌入以及融资实践的不断深入,个体收益结构表现出明显的多维特征。一方面,技术采纳成本因社会系统在创新性、价格敏感性和需求等方面存在固有差异而具有显著的异质性,尤其受技术适应能力的影响,高学习能力的个体能以更低的边际成本采纳前沿技术工具[35]。另一方面,资本市场通过观测历史创新成果与技术采用行为,对创新者能力进行前瞻性定价,从而有选择地增加个体创新者的收益[28]。本文在继承经典跨期收益框架的基础上,融合信号传递理论[26]、技能偏向型技术采用的异质性成本结构[36]与创新资本市场实证发现[27],类比传统厂商行为,将个体创新者的市场收益重构为三重维度:跨期创新产出净利润、AI 投资成本与金融市场融资溢价,具体表达如式(4)至式(6)所示。这一拓展不仅突破了传统产品市场收益范式的局限,将产品市场收益与资本市场溢价统一于系统性个体决策框架中,更通过内生化“历史产出”的双信号机制,揭示了 AI 在技术效率提升与资本市场信号传递中的双重价值。

$$R = \underbrace{\mathrm{E}\left[\sum_{t=0}^{\infty} \beta^{t}(pq_{t} - C_{t})\right]}_{\text{跨期创新产出净利润}} - \underbrace{I^{A}(A,\tau)}_{\text{AI投资成本}} + \underbrace{\theta(q_{0},A)}_{\text{金融市场融资溢价}} \tag{4}$$

$$I^{A}(A,\tau) = \iota(\tau)A^{\tau} \tag{5}$$

$$\theta(q_{0},A) \equiv \Theta(e^{e}(q_{0},A)) \tag{6}$$

其中,R 表示个体创新者的完整市场总收益;$\mathrm{E}[\cdot]$ 为基于融资时点信息集的条件数学期望,是对所有未来外生随机冲击路径的加权平均收益[34];常数 p 表示单位创新产出的平均市场价格;参数 β 为时间贴现因子,反映个体对未来的重视程度。函数 $I^{A}(A,\tau)$ 表示期初的一次性 AI 投资;函数 $\iota(\cdot)$ 是能力依赖的成本系数,受个体创新者能力异质性的影响;参数 τ 表征不可观测技术适应能力,反映个体对 AI 工具的理解深度、适配速度与创新应用能力。函数 $\theta(q_0, A)$ 表征融资时点资本市场基于信号 (q_0, A) 设定的估值上限,即融资条件改善带来的净收益增益,常数 q_0 为融资时点可观测的历史创新产出信号,$\Theta(\cdot)$ 为价值转化函数。

个体的目标是选择最优努力序列 $\{e_t\}$,以最大化其贴现总收益。该问题可表述为一个标准的动态规划问题,其值函数 $V(K_t;A)$ 存在唯一解,且最优努力水平 e_t^{*} 为严格内点解。通过求解一阶条件(FOC),可得到刻画最优决策的核心均衡方程,即式(7)。将式(1)至式(3)的偏导数代入式(7),得到最优努力路径的均衡方程,如式(8)所示。

$$FOC = \underbrace{p\frac{\partial q_{t}}{\partial e_{t}}}_{\text{当期边际收益}} + \underbrace{\beta l_{t+1}\frac{\partial K_{t+1}}{\partial e_{t}}}_{\text{跨期知识价值}} - \underbrace{\frac{\partial C_{t}}{\partial e_{t}}}_{\text{当期边际成本}} = 0 \tag{7}$$

$$\begin{cases} \text{当期边际收益} = p\ \alpha_{q} K_{t}^{\gamma}(e_{t}^{*})^{\alpha_{q}-1} A^{\beta_{q}} \\ \text{跨期知识价值} = \beta\ l_{t+1} A^{\beta_{k}}\ \eta\ \alpha_{k}(e_{t}^{*})^{\alpha_{k}-1} \\ \text{当期边际成本} = c_{0} + \rho\ (e_{t}^{*})^{\rho-1}\left[c_{1}(1 - \mu\ A^{\lambda}) + c_{2}\sigma^{2}e^{-\upsilon A}\right] \end{cases} \tag{8}$$

(二)核心机制:命题与证明

前文通过严谨求解个体跨期动态优化问题,导出了刻画最优努力决策的核心均衡条件。式(8)不仅揭示个体创新者在创新过程中要避免“知识停滞”或“成本失控”的非理性极端情形,还发现了创新者在“当期产出—知识积累—成本约束”间的理性权衡。更为关键的是,等式两端同时嵌入边际收益项、边际成本项及

跨期收益预期项,清晰地映射出 AI 赋能水平影响创新行为的多重内生通道。这一结构并非模型巧合,而是对现实创新生态的精准刻画。正如巴比纳等[16]所指出的,AI 既作为生产要素提升技术效率,又作为信号载体影响资本市场定价。为此,本文严格遵循“逻辑分离、路径清晰”的识别原则,依次证明关于 AI 三重效应的核心命题。

命题 1:AI 通过赋能效应提升创新绩效。

所谓赋能效应,即 AI 对创新边际收益的跨期增强作用,是指 AI 通过提升单位努力的知识转化效率与产出效率,系统性提升创新活动全周期的边际收益,从而激励个体创新者增加努力投入的机制。具体在本文中,赋能效应是指,在给定条件下,个体最优努力水平随 AI 赋能水平单调递增,即 $\frac{\partial e^*}{\partial A} > 0$。

证明:为分离赋能效应,暂时关闭成本函数中的 AI 通道(令 $\mu = \upsilon = 0$)。由隐函数定理,有 $\frac{\partial e^*}{\partial A} = -\frac{\partial FOC/\partial A}{\partial FOC/\partial e^*}$,其中,$\frac{\partial FOC}{\partial A} > 0$ 且 $\frac{\partial FOC}{\partial e_t{}^*} < 0$ 同时成立,故必有 $\frac{\partial e^*}{\partial A} > 0$。

上述推导严格揭示了 AI 通过赋能效应推动创新绩效提升的内在机理。该结果与阿西莫格鲁(Acemoglu)[36]的技能偏向型技术进步理论相一致,表明 AI 作为典型的技能偏向型技术,通过提升创新者努力投入的边际生产力,从而引导创新资源向高效率方向配置。

命题 2:AI 通过降本效应提升创新绩效。

所谓降本效应,即 AI 对创新边际成本的结构性压缩,是指当产出水平固定时,AI 通过筛选降低试错成本和风险成本,从而减少达到相同创新产出所需的最小成本,进而重构创新者努力投入的边际成本结构,激励其加大资源投入的机制。具体在本文中,降本效应是指实现给定产出所需的最小成本随 AI 赋能水平单调递减,即 $\frac{\partial C_{\min}}{\partial A} < 0$。

证明:考虑成本最小化问题,针对 $\min_e C(e, A)$, s. t. $q = K^{\gamma} e^{\alpha_q} A^{\beta_q}$,构建拉格朗日函数并应用包络定理,可得 $\frac{\partial C_{\min}}{\partial A} = \frac{\partial C_t}{\partial A}\Big|_{e_t{}^*} - \chi \frac{\partial q_t}{\partial A}\Big|_{e_t{}^*}$,其中,$\chi$ 为拉格朗日乘子。右侧第一项为负,右侧第二项为正。两项之差必然小于 0,故 $\frac{\partial C_{\min}}{\partial A} < 0$ 成立。

上述推导不仅验证了降本效应的独立存在性,还揭示了 AI 通过重构边际成本结构,系统性压缩实现同等产出所需的最小成本的内在机制。该逻辑与拉姆纳等(Rammer et al.)[15]的实证发现一致,即在控制产出与知识存量后,AI 赋能水平的提升会导致创新活动的边际成本下降。

命题 3:AI 通过激励效应提升创新绩效。

所谓激励效应,即 AI 作为能力信号向资本市场传导的机制,是指个体创新者通过采用更前沿的 AI 技术向金融市场传递自身高技术适应能力的信号,从而获得更高的融资溢价,最终通过收益预期反向激励努力投入的作用路径。在本研究中,激励效应是指融资溢价随着 AI 采纳水平的提高而增加,即 $\frac{\partial \theta}{\partial A} > 0$。

证明:激励效应的成立依赖于一个有效的信号分离均衡。首先,AI 投资成本函数满足单交叉条件 $\frac{\partial^2 I_A(A\tau)}{\partial A\, \partial \tau} < 0$,这意味着技术适应能力 τ 更高的个体,其提升 AI 采纳水平 A 的边际成本更低。在此条件下,市场能够形成一个分离均衡。此时,资本市场作为贝叶斯理性推断者,会基于观测到的信号(q_0, A)更新其

对创新者能力的后验信念 $E[\tau \mid q_0, A]$。由于均衡信号策略是严格递增的,后验期望能力必然随 A 单调递增。将上述结果代入市场信号的贝叶斯学习机制公式,融资溢价 θ 被设定为该后验期望能力的严格增函数。因此,更高的 AI 采纳水平会被市场解读为更强技术适应能力的可信信号,从而获得更高的融资溢价,即 $\frac{\partial \theta}{\partial A} > 0$。

上述推导严格验证了激励效应的独立存在性。该结论与冯和赵[29]关于创新激励需兼顾探索与信号传递的结论相一致。该结果进一步支持了“AI 不仅被视作生产工具,更是能力认证载体”的理论论断,AI 的信号价值通过资本市场定价机制塑造创新者的技术采纳决策。

(三)交互效应:信号质量与“漂洗”行为

前述分析假设市场观测到的 AI 水平是真实的。然而,在现实中,企业可能存在实施“AI 漂洗”行为的动机。所谓 AI 漂洗,是指企业对外高调宣称采用人工智能技术提升产品或服务质量、获取竞争优势,但实际上并未进行相应投入,或实际效果远未达到所声称的水平[37]。本文通过引入信号质量变量 $S \in (0,1]$,重构了创新成本函数和市场收益函数。该框架发现,当信息不对称存在时,激励效应可能诱发企业的策略性漂洗行为,进而对赋能效应和降本效应产生负面影响。为此,本文依次证明关于漂洗行为及其交互效应的两个核心推论。

推论 1:过度的激励效应会诱发“AI 漂洗”行为。

在本文中,过度的激励效应诱发“AI 漂洗”行为是指,当 AI 的激励效应足够强时,企业有动机降低 AI 的信号质量 S,以获取更高的融资溢价。即,当 $\frac{\partial \theta}{\partial A_{ob}}$ 足够大时,必有 $\frac{\partial R_{total}}{\partial S} < 0$。

证明:假设企业存在 AI 漂洗行为,资本市场中观测到的 AI 采纳水平必然高于企业真实 AI 采纳水平,即 $A_{ob} = \frac{A}{S}$。此时,收益函数重构为 $R_{total} = \underbrace{E\left[\sum_{t=0}^{\infty} \beta^t (pq_t - C_t)\right]}_{\text{跨期创新产出净利润}} \underbrace{-I^A(A,\tau)}_{AI\text{投资成本}} + \underbrace{\theta(q_0, A_{ob})}_{\text{金融市场融资溢价}} - \underbrace{C_{wash}}_{AI\text{漂洗成本}}$,其中,成本函数包括 AI 投资成本、创新成本函数以及 AI 漂洗成本函数。将重构的收益函数 R_{total} 对信号质量 S 求偏导数,得 $\frac{\partial R_{total}}{\partial S} = -\frac{\partial \theta}{\partial A_{ob}} \frac{A}{S^2} - \frac{\partial C_{wash}}{\partial S}$。$S$ 越低意味着 AI 漂洗越严重,漂洗成本 C_{wash} 越高,所以 $\frac{\partial C_{wash}}{\partial S} < 0$。但当激励效应 $\frac{\partial \theta}{\partial A_{ob}} \to \infty$ 时,第一项 $\left(-\frac{\partial \theta}{\partial A_{ob}} \frac{A}{S^2}\right)$ 的绝对值会超过第二项 $\left(\frac{\partial C_{wash}}{\partial S}\right)$。此时,$\frac{\partial R_{total}}{\partial S} < 0$ 必然成立,即 AI 的信号质量越低,创新主体的收益将越高。

上述推导严格验证了过度的激励效应会诱发“AI 漂洗”行为。该结论与袁春生和郭振雄[37]关于融资激励会加剧 AI 漂洗行为的结论相一致,即由于“AI 漂洗”具有监管难度大、潜在收益高的特征,管理者倾向于借此修饰财务表现、勾勒成长叙事,以换取资本市场关注与融资便利。

推论 2:“AI 漂洗”行为会弱化赋能效应。

在本文中,“AI 漂洗”行为弱化赋能效应是指,当企业存在漂洗行为时,漂洗成本的增加会降低真实 AI 水平,从而削弱 AI 对创新努力的边际激励作用。从公式推导看,需要证明以下两点:一是漂洗成本增加会导致最优边际努力水平下降,即 $\frac{\partial e^*}{\partial C_{wash}} < 0$;二是赋能效应强度 $\frac{\partial e^*}{\partial A}$ 随漂洗成本的增加而呈现递减趋势。

证明:假设企业面临总成本约束 $C_{total} = C_{R\&D} + C_{wash}$,其中,$C_{R\&D}$ 为真实研发成本,C_{wash} 为 AI 漂洗成本。首先,根据链式法则 $\frac{\partial e^*}{\partial C_{wash}} = \frac{\partial e^*}{\partial A} \frac{\partial A}{\partial C_{wash}}$。由于 $\frac{\partial e^*}{\partial A} > 0$ 且 $\frac{\partial A}{\partial C_{wash}} < 0$,必有 $\frac{\partial e^*}{\partial C_{wash}} < 0$ 成立。在此基础上,定义

赋能效应强度函数 $\varphi(A)=\frac{\partial e^*}{\partial A}$，并对漂洗成本 C_{wash} 求偏导数，得到 $\frac{\partial \varphi}{\partial C_{wash}}=-\frac{\partial^2 e^*}{\partial A^2}\frac{\partial A}{\partial C_{wash}}$。由于 $\frac{\partial A}{\partial C_{wash}}<0$，同时，在标准凹性假设下，边际激励效应递减，即 $\frac{\partial^2 e^*}{\partial A^2}<0$，因此，$\frac{\partial \varphi}{\partial C_{wash}}<0$，即赋能效应强度 $\varphi(A)$ 随着 AI 漂洗成本的增加呈现递减趋势。

上述推导严格验证了“AI 漂洗”行为会弱化赋能效应，进一步揭示了“信号失真”的负面后果，即企业为获取短期融资便利而进行的漂洗行为，会通过资源挤出机制削弱 AI 技术对创新活动的真实赋能作用，最终可能损害企业的长期创新能力。

推论 3：“AI 漂洗”行为弱化降本效应。

在本文中，“AI 漂洗”行为弱化降本效应是指，当企业存在漂洗行为时，漂洗成本的增加会降低真实 AI 水平，从而削弱 AI 对创新成本的压缩能力。从公式推导看，需要证明：当漂洗成本 C_{wash} 增加时，降本效应强度的绝对值 $\left|\frac{\partial C_{min}}{\partial A}\right|$ 呈现递减趋势。

证明：假设企业面临总成本约束 $C_{total}=C_{R\&D}+C_{wash}$，其中，$C_{R\&D}$ 为真实研发成本，C_{wash} 为“AI 漂洗”成本。首先，根据命题 2 和推论 2，有 $\frac{\partial A}{\partial C_{wash}}<0$ 且 $\frac{\partial C_{min}}{\partial A}<0$，同样代入 $\frac{\partial C_{min}}{\partial C_{wash}}=\frac{\partial C_{min}}{\partial A}\frac{\partial A}{\partial C_{wash}}$，有 $\frac{\partial C_{min}}{\partial C_{wash}}>0$，即“AI 漂洗”行为会加快企业创新产出最小成本的上升。由于 $\frac{\partial C_{min}}{\partial A}<0$，本文定义降本效应强度函数 $\xi(A)=\left|\frac{\partial C_{min}}{\partial A}\right|=-\frac{\partial C_{min}}{\partial A}$，并对漂洗成本 C_{wash} 求偏导数，得 $\frac{\partial \xi}{\partial C_{wash}}=\frac{\partial^2 C_{min}}{\partial A^2}\frac{\partial A}{\partial C_{wash}}$。由于 AI 系统往往具有互补性和网络效应，随着企业 AI 采纳水平的提升，最小化成本的下降速度会逐渐加快，即 $\frac{\partial^2 C_{min}}{\partial A^2}>0$。此时，$\frac{\partial \xi}{\partial C_{wash}}<0$，即降本效应强度 $\xi(A)$ 随着“AI 漂洗”成本的增加呈现递减趋势。

上述推导严格验证了“AI 漂洗”行为会弱化降本效应。该结论与汪兵韬等[38]关于资源配置扭曲降低全要素生产率的研究发现相一致。推导的结果进一步揭示了资源错配的负面后果，即企业为获取短期融资便利而进行的漂洗行为，会通过资源配置扭曲削弱 AI 技术对创新成本的真实压缩作用，最终损害企业的长期成本竞争优势。

四、AI 提升创新绩效的案例分析

上文通过拓展离散时间无限期动态优化模型，系统论证了 AI 赋能水平提升通过赋能、降本与激励三重机制促进创新绩效提升，并进一步揭示了激励效应与赋能、降本效应之间的交互影响。理论推导表明，AI 不仅作为生产要素直接嵌入知识演化与产出函数，更通过重构成本结构与信号传递路径，深度激发创新主体的内生动力。模型还揭示了过度的激励效应可能诱发“AI 漂洗”这一策略性行为，并通过资源挤出与配置扭曲弱化赋能效应与降本效应，进而对创新生态产生负向影响。为实现理论推导与案例发现的双向互证，本文选取科大讯飞股份有限公司作为案例样本，检验 AI 提升创新绩效的赋能、降本与激励效应在企业实践中的动态耦合和交互影响，并为深化理论认识与完善政策设计提供现实依据。需要说明的是，本文案例所涉企业经营、研发投入及生态建设等相关数据，均来源于科大讯飞历年年度报告。

科大讯飞成立于 1999 年，2008 年在深圳证券交易所上市，长期致力于技术创新与产业应用的深度融合，形成了显著的技术积累与生态优势。在创新能力方面，截至 2025 年末，公司研发人员占比达 59.70%，累

计获得授权发明专利超 5 200 项,主导和参与制定国际及国内标准 200 余项,其中已发布实施的国际标准 5 项、国家标准 60 项、行业标准 15 项、地方标准 17 项,彰显了其在技术研发与标准引领方面的突出实力。在经营绩效方面,2025 年公司全年实现营业收入 271.05 亿元,研发投入占营业收入比重达 19.80%,体现了对技术创新的持续投入与重视。在创新生态建设方面,截至 2025 年底,讯飞 AI 开放平台已汇聚超 1 000 万开发者,覆盖教育、医疗、智慧城市等 18 个重点行业,构建了开放协同的创新生态系统。

样本选择主要基于四点考虑。一是典型性。作为中国人工智能领域的领军企业,科大讯飞自成立以来完整演绎了从技术研发到产业应用的创新历程。其构建的讯飞星火大模型体系已成为国内基于全国产算力训练的主流大模型,在教育、医疗、汽车等民生领域形成了规模化应用场景,具有鲜明的时代特征和行业代表性。二是特殊性。不同于单纯的技术供应商,作为首批国家 AI 开放创新平台,公司依托讯飞 AI 开放平台汇聚超千万名开发者,形成了可获取、可靠且可信赖的 AI 开放式创新生态系统,实现了技术能力与产业生态的深度耦合。三是与研究问题的适配性。该公司将 AI 深度融入研发全链条的实践,为理论模型中赋能、降本与激励三重机制提供了鲜活的现实印证,且其在战略自律、财务透明与生态约束等方面的探索,为识别“AI 漂洗”风险诱因与防范路径提供了重要观察窗口。四是数据可获得性。公司近五年的财务报告与公开披露信息翔实完整,为系统梳理三重机制的动态耦合过程及交互影响提供了扎实的数据支撑。

(一)赋能效应

面对技术碎片化带来的知识转化效率瓶颈,科大讯飞自 2022 年起实施技术整合战略。公司专门成立大模型专项工作组,研发投入资金超 33 亿元,研发人员约 9 300 人。但在大模型技术处于专项攻关初期阶段,技术向商业价值的转化存在明显滞后,知识存量未能充分转化为创新产出。随着国产大模型“讯飞星火”的多轮迭代,科大讯飞成功将分散的技术模块整合为统一的认知智能底座,从而提升了知识转化效率和创新产出弹性。在教育业务线,公司将语音识别、自然语言处理、知识图谱等分散模块进行系统集成,重构个性化学习引擎,实现了从作业采集、智能批改到学情分析、方案生成的全流程自动化。在医疗业务线,公司对智医助理进行架构升级,融合多模态医学影像识别与临床决策支持系统,通过真实诊疗场景数据持续优化算法性能。

经营结果验证了 AI 对创新边际收益的跨期增强效应。2022—2025 年,公司智慧教育业务收入从 72 亿元增至 90 亿元,搭载星火大模型的 AI 学习机 T30 系列上市首月销量突破 10 万台,较上一代产品销量提升 60%。在医疗领域,智医助理辅助诊断准确率从 98%提升至 99.20%,单次诊断耗时缩短 40%,覆盖区县从 426 个扩展至 512 个,累计辅助诊断次数从 7 亿次跃升至 9.30 亿次。高频交互所积累的数据密度,正是 AI 提升知识转化效率的直接体现。AI 将海量场景数据转化为可复用的知识资产,推动单位研发人员产出效率显著提升,创新产出呈现非线性增长特征。这一实践印证了 AI 通过增强单位努力的知识转化效率与产出效率,系统性提升创新活动全周期边际收益的理论机制,即赋能效应。

(二)降本效应

在降本效应方面,AI 通过重构研发流程显著压缩了创新活动的试错成本与风险敞口。2022 年,科大讯飞在汽车智能座舱开发中仍需依赖大量实车测试,单次迭代周期长达三个月,物料与人力成本居高不下。此外,部分项目因市场需求误判造成资源浪费,导致产生大量沉没成本。为系统解决上述问题,近年来科大讯飞持续投入资源升级 AI 虚拟验证平台和 AI 决策支持系统。截至 2025 年底,升级后的虚拟验证平台已能够覆盖 23 种海外语言、60 余款海外车型,在数字环境中完成 90%以上人机交互逻辑测试。与此同时,基于大数据的智能决策支持系统,通过对市场需求趋势、技术可行性和竞争格局的实时分析,建立了研发项目动态评估机制,实现了资源的精准配置与风险的前置识别。

这一系列降本举措重塑了研发端的成本结构,并带动经营质量的系统性改善。在试错成本方面,虚拟验证平台完成 90%以上人机交互逻辑测试的数字替代,使单次迭代周期从 3 个月压缩至 1.5 个月,研发物料消耗降低 35%,直接减少了创新活动的边际试错投入。在风险敞口方面,智能决策支持系统通过前置识别与动态评估,主动规避 3 个高风险项目,将研发失败率从 18%降至 9%,研发资金使用效率提升 2.1 倍,有效抑制了沉没成本的产生。研发端成本结构的优化进一步传导至经营端,经营活动现金流净额从 6.31 亿元增至 32.08 亿元,销售回款总额从 176.43 亿元增长至 274.12 亿元,企业逐步从战略性投入期的利润承压转向可持续的高质量增长。上述从数字替代压缩试错投入、智能决策抑制风险损失到经营现金流与回款同步增长的完整传导过程,支撑了 AI 通过降低试错成本参数 μ 和风险抑制参数 v、内生化重构研发成本函数的理论机制,即降本效应。

(三)激励效应

面对市场对国产大模型技术实力的普遍质疑,科大讯飞启动了围绕自身 AI 能力的信号构建战略,即建立标准化的 AI 技术披露框架。在技术验证层面,企业年报中系统性披露星火大模型在国产算力平台上的训练数据规模、参数量级及推理性能指标;在场景应用层面,选择教育、医疗等高价值领域开展试点项目,通过第三方审计机构验证 AI 学习机提分效果和智医助理诊断准确率等可量化指标。此外,作为首批国家 AI 开放创新平台,讯飞开放平台构建了市场化技术验证机制,通过开放 API 接口与 MaaS 服务,使开发者和企业用户在真实业务场景中检验大模型能力,有效降低了市场对国产大模型能力的信息不对称,为信号构建战略提供了坚实的市场化支撑。

经营结果验证了信号传递机制对市场估值的正向催化作用。2022—2025 年,公司市场认可度持续提升,讯飞星火大模型相关项目中标金额从 8.30 亿元增长至 23.16 亿元,2025 年中标额超过行业第二至第六名企业总和;讯飞开放平台开发者数量从 673 万增长至 1 000 万,其中专注大模型开发的技术人员新增 127 万人。资本市场反馈积极,公司市值从 2022 年的 896 亿元增长至 2025 年的 1272 亿元,市盈率稳定维持在 42 倍,较行业平均溢价 15%;融资成本优势凸显,2025 年发行的 15 亿元科技创新公司债券票面利率为 3.95%,较同期同评级企业平均利率低 0.8 个百分点。资本市场的正向反馈形成创新投入的良性循环,公司累计将融资资金的 60%投入研发,研发投入强度从 17.83%提升至 19.79%,全年营业收入从 188.20 亿元增长至 271.05 亿元。这一实践完整呈现了“信号构建—市场识别—溢价实现—再创新”的动态闭环,验证了贝叶斯学习机制下资本市场通过持续更新先验信念形成技术溢价,进而反哺创新投入的理论路径,即激励效应。

(四)“AI 漂洗”行为

2023 年起,资本市场对“AI 概念股”的追捧引发了概念包装风险。部分企业将传统信息化项目重新命名为“AI 解决方案”,或通过关联交易虚增 AI 业务收入,短期内获得估值提升,但长期因缺乏核心技术支撑而业绩暴雷。科大讯飞在年报中明确承认这一风险,并指出这种过度包装的本质是激励信号与创新实质的背离。近年来,科大讯飞逐步建立起预防“AI 漂洗”行为的自律框架,有效阻断了策略性包装的空间,使激励效应始终服务于实质性创新而非概念套利。具体做法主要包括三个方面。一是战略约束,杜绝纯概念性投入。科大讯飞所有人工智能项目被要求必须是真实存在的应用案例、必须能够规模化推广、必须有统计数据验证成效。二是财务约束,严格区分 AI 相关收入与传统业务收入,同时对研发费用资本化持谨慎态度,确保会计信息真实反映技术不确定性。三是生态约束,通过开放平台汇聚开发者,以市场化机制检验技术价值。只有真正解决实际问题的 AI 能力才能获得开发者认可,形成“用脚投票”的开发者监督机制。

经营实践验证了风险防范机制对创新可持续性的保障作用。在技术积累方面,累计获得授权发明专利

从 2022 年的不足 4 000 项增至 2025 年的超过 5 200 项,主导和参与制定的国际国内标准数量从 137 项扩展至 200 余项。公司经营质量持续优化,营业收入三年复合增长率保持在合理区间,净利润波动系数从 0.35 降至 0.12,显著低于同行业 0.48 的平均水平。这一实践不仅印证了数理模型所揭示的风险——当激励效应过度时,企业可能为迎合市场预期而采取“AI 漂洗”策略性行为,更阐述了有效的风险约束机制能够阻断短期激励与长期创新相背离的路径,为资本市场理性估值与企业可持续创新的良性互动提供了可复制的制度样本。

五、结论与建议

本文立足人工智能深度融入国家创新体系的时代背景,通过拓展离散时间无限期优化模型,将 AI 赋能水平内生嵌入知识演化、成本结构与信号生成机制,构建了统一的跨期动态优化框架。在理论层面,该框架不仅实现了赋能、降本与激励三重机制的逻辑统一与数理自洽,拓展了内生增长理论与信号传递理论在 AI 情境下的解释边界,更揭示了过度激励诱发“AI 漂洗”的风险传导逻辑及机制间的交互效应。在实证层面,科大讯飞的本土典型案例印证了三重机制在效率提升、风险缓释与价值实现中的协同作用,且案例所揭示的“AI 漂洗”风险诱因与防范,与理论模型中交互效应的推导结果高度契合。这种理论推导与案例发现的双向互证,印证了研究结论的逻辑一致性。本文的核心结论如下:

第一,通过数理推导揭示 AI 的双重属性,验证三重机制的存在性与作用机理。理论模型表明,AI 兼具生产要素与能力信号载体的双重属性。赋能效应通过提升信息检索精度、加速模式识别与拓展跨域联想,显著提高单位努力的知识转化效率与创新产出弹性,强化当期收益与跨期知识积累;降本效应依托智能筛选与虚拟验证技术,系统压缩试错成本与研发不确定性,推动同等产出下的成本结构优化;激励效应则满足信号传递的单交叉条件,使高适应能力主体以较低成本传递可信信号,资本市场经贝叶斯更新将 AI 赋能水平识别为能力标识,形成“信号识别—融资溢价—创新反哺”的闭环。上述推导不仅实现了三重机制的逻辑分离与纯净识别,更明确了 AI 赋能水平在知识演化方程、非线性成本函数与信号生成机制中的内生嵌入方式,确保了三重机制在统一跨期动态优化框架内的数理自洽,为后续识别机制边界与交互影响奠定了严谨的理论基础。

第二,通过交互分析识别风险诱因,阐明过度激励诱发“AI 漂洗”的传导机制。三重机制并非孤立运行,而是存在复杂的交互关系,尤其是当资本市场的激励效应过度时,可能诱发创新主体的“AI 漂洗”策略性行为。作为激励效应异化的产物,“AI 漂洗”生成逻辑在于过度的外部融资溢价诱导,使得企业将资源从实质性知识积累与成本压缩环节转移至信号包装环节,从而通过资源挤出与配置扭曲弱化 AI 的赋能效应和降本效应,最终对创新主体绩效产生负向影响。这一发现不仅从理论上厘清了 AI 赋能创新的系统性风险边界,解释了部分企业高调宣称 AI 转型却未能实现绩效实质提升的现象,更在统一框架内完成了对三重机制正向协同与负向传导的完整刻画,强调了防范“AI 漂洗”对于维持赋能与降本效应有效性的关键意义。

第三,通过典型案例实现交叉检验,验证三重机制的动态耦合与风险防范路径。科大讯飞的案例生动诠释了 AI 驱动创新的现实逻辑。在赋能端,底层技术突破提升了知识获取与转化效率;在降本端,智能技术压缩了研发试错周期与风险敞口;在激励端,构建了“底层突破—能力转化—场景落地”的信号体系,获得了资本市场的理性识别与持续溢价。更为重要的是,案例进一步识别出以战略自律、财务透明与生态约束为核心的风险防范机制,有效规避了“AI 漂洗”风险,确保了激励效应与赋能、降本效应的良性互动。这不仅精准契合了理论模型的推导结果,呈现了三重机制在企业创新实践中的动态耦合过程,更印证了只有通过实质性的知识积累与成本压缩支撑信号传递,才能避免激励效应异化为“AI 漂洗”,从而在本土情境下完整验证了三重机制协同提升创新绩效的核心命题,为 AI 赋能创新的机制研究提供了可

检验、可拓展的实践支撑。

从实践维度看,本文研究结论对多元主体具有重要启示。对创新个体而言,应主动将 AI 工具嵌入知识积累与研发全流程,在善用其认知增强与成本压缩功能的同时,构建可验证的实质性技术应用信号以提升市场认可度,并自觉规避虚假宣传陷阱。对企业主体而言,需着力构建纵向贯通的技术体系并提升场景落地实效,以此强化信号传递的完整性与可信度,既要优化融资策略以充分获取资本市场对高质量硬科技信号的溢价反馈,又要加快建立内部合规与风险预警机制以防范“AI 漂洗”带来的长期价值损害。对政策制定者而言,应通过优化科创板信号敏感度设计来完善资本市场对硬科技信号的甄别机制,加大“人工智能+”民生场景开放力度以加速技术信号的实地验证,并推动研发、金融与产业政策的协同设计,系统性放大 AI 赋能、降本、激励三重机制的循环效能,从而为构建自主可控、安全高效的国家创新体系提供坚实制度支撑。

尽管本文基于理论模型与典型案例的互证,揭示了 AI 提升创新绩效的三重机制及不同机制间的交互效应,但仍存在进一步深化的空间。在理论层面,当前模型假设创新主体为风险中性,未来可纳入风险偏好异质性设定,以更贴近个体决策的现实复杂性。在实证层面,受限于企业 AI 相关微观数据的可得性与颗粒度,本文采用典型案例分析法,伴随统计指标和 AI 细分领域数据的逐步积累,后续研究可通过构建计量模型实证检验三重机制的交互效应与门槛特征。此外,随着生成式 AI 技术的迭代发展,其与人类创新者的协同演化路径,以及新型“AI 漂洗”形态的演变趋势,亦值得学界长期追踪研究。

参考文献:

[1]Mariani M,Machado I,Magrelli V,et al. Artificial intelligence in innovation research:a systematic review, conceptual framework, and future research directions[J]. Technovation,2023,122:102623.

[2]洪元元,王宁,刘晓康. 从技术引进到自主突破:人工智能对企业关键核心技术突破的影响研究[J]. 经济与管理研究,2026,47(4):49-63.

[3]Cheng X S,Fu S X,de Vreede T,et al. Idea convergence quality in open innovation crowdsourcing:a cognitive load perspective[J]. Journal of Management Information Systems,2020,37(2):349-376.

[4]Rhaiem K,Amara N. Learning from innovation failures:a systematic review of the literature and research agenda[J]. Review of Managerial Science,2021,15(2):189-234.

[5]Lin J Y,Liu Z W,Zhang B. Endowment, technology choice, and industrial upgrading[J]. Structural Change and Economic Dynamics,2023,65:364-381.

[6]Jia H J,Zhou J. Patent output and patent transfer network in China universities:moderating roles of absorptive capacity and desorptive capacity[J]. Heliyon,2024,10(18):e37762.

[7]胡朝阳,张自然,陈璐怡. 创新成果转化的困局及其破解:理论拓展与机制解析[J]. 理论月刊,2026(4):62-75.

[8]沈志锋,李静,李智慧. 人工智能参与下的创新生态系统构建研究[J]. 科研管理,2024,45(10):12-23.

[9]Vatansever S,Schlessinger A,Wacker D,et al. Artificial intelligence and machine learning-aided drug discovery in central nervous system diseases:state-of-the-arts and future directions[J]. Medicinal Research Reviews,2021,41(3):1427-1473.

[10]郝亚楠,高剑平. 生成式人工智能赋能中国自主知识体系建构:理论基础、实现路径与支持保障[J]. 理论月刊,2025(10):16-25.

[11]Xiao F,Ke J T. Pricing, management and decision-making of financial markets with artificial intelligence:introduction to the issue[J]. Financial Innovation,2021,7(1):85.

[12]张长江,兰凯,张玥,等. 社会责任履行、创新生态系统构建与开放式创新战略绩效提升:基于科大讯飞的纵向案例研究[J]. 系统管理学报,2025,34(1):277-294.

[13]van de Schoot R,de Bruin J,Schram R,et al. An open source machine learning framework for efficient and transparent systematic reviews[J]. Nature Machine Intelligence,2021,3:125-133.

[14]Hasselgren C,Oprea T I. Artificial intelligence for drug discovery:are we there yet? [J]. Annual Review of Pharmacology and Toxicology,2024,64:527-550.

[15]Rammer C, Fernández G P, Czarnitzki D. Artificial intelligence and industrial innovation: evidence from German firm-level data[J]. Research Policy, 2022, 51(7): 104555.
[16]Babina T, Fedyk A, He A, et al. Artificial intelligence, firm growth, and product innovation[J]. Journal of Financial Economics, 2024, 151: 103745.
[17]Arrow K J. The economic implications of learning by doing[J]. The Review of Economic Studies, 1962, 29(3): 155-173.
[18]Griliches Z. Issues in assessing the contribution of research and development to productivity growth[J]. The Bell Journal of Economics, 1979, 10(1): 92-116.
[19]Bianchini S, Müller M, Pelletier M. Drivers and barriers of AI adoption and use in scientific research[J]. Technological Forecasting and Social Change, 2025, 220: 124303.
[20]Griliches Z. Patent statistics as economic indicators: a survey[J]. Journal of Economic Literature, 1990, 28(4): 1661-1707.
[21]Hall B H, Jaffe A B, Trajtenberg M. The NBER patent citation data file: lessons, insights and methodological tools[Z]. NBER Working Paper No. 8498, 2001.
[22]Freeman C. The economics of industrial innovation[M]. 2nd ed. London: Pinter Publishers, 1982.
[23]Simpson P M, Siguaw J A, Enz C A. Innovation orientation outcomes: the good and the bad[J]. Journal of Business Research, 2006, 59(10/11): 1133-1141.
[24]Haefner N, Wincent J, Parida V, et al. Artificial intelligence and innovation management: a review, framework, and research agenda[J]. Technological Forecasting and Social Change, 2021, 162: 120392.
[25]Rudroff T. Artificial intelligence as a replacement for animal experiments in neurology: potential, progress, and challenges[J]. Neurology International, 2024, 16(4): 805-820.
[26]Spence M. Signaling in retrospect and the informational structure of markets[J]. American Economic Review, 2002, 92(3): 434-459.
[27]Soukhoroukova A, Spann M, Skiera B. Sourcing, filtering, and evaluating new product ideas: an empirical exploration of the performance of idea markets[J]. Journal of Product Innovation Management, 2012, 29(1): 100-112.
[28]Shi Y W, Herniman J. The role of expectation in innovation evolution: exploring hype cycles[J]. Technovation, 2023, 119: 102459.
[29]Feng D L, Zhao L D. Moderating effects of technological innovation and information environment on market response to information disclosure reforms[J]. Heliyon, 2024, 10(20): e39447.
[30]Peres R, Muller E, Mahajan V. Innovation diffusion and new product growth models: a critical review and research directions[J]. International Journal of Research in Marketing, 2010, 27(2): 91-106.
[31]Besiroglu T, Emery-Xu N, Thompson N. Economic impacts of AI-augmented R&D[J]. Research Policy, 2024, 53(7): 105037.
[32]Strubell E, Ganesh A, McCallum A. Energy and policy considerations for deep learning in NLP[C]//Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics, 2019: 3645-3650.
[33]Wang Y L, Yang Z Y, Li Y B, et al. Integrated planning of source-grid-load-storage for regional power grids considering large-scale renewable energy integration[J]. Energy, 2026, 345: 140146.
[34]Abel A B. Optimal investment under uncertainty[J]. The American Economic Review, 1983, 73(1): 228-233.
[35]Greif A, Mokyr J. Cognitive rules, institutions, and economic growth: Douglass North and beyond[J]. Journal of Institutional Economics, 2017, 13(1): 25-52.
[36]Acemoglu D. Directed technical change[J]. The Review of Economic Studies, 2002, 69(4): 781-809.
[37]袁春生,郭振雄. 绩效期望落差与企业 AI 漂洗:基于管理者归因视角[J]. 华东经济管理,2026,40(4):21-30.
[38]汪兵韬,陈金皇,王小龙. “省直管县”改革、资源配置与企业高质量发展[J]. 经济与管理研究,2021,42(4):73-88.

Artificial Intelligence Reshaping Innovation Performance: Mechanism Deconstruction and Practical Exploration

HU Zhaoyang[1], ZHANG Ziran[2]

(1. University of Chinese Academy of Social Sciences, Beijing 102488;
2. Chinese Academy of Social Sciences, Beijing 100836)

Abstract: Against the backdrop of artificial intelligence (AI) being deeply integrated into national innovation systems to drive high-quality economic development, clarifying the micro-level mechanisms and local practical logic through which AI reshapes innovation performance holds significant theoretical and practical importance. This paper aims to open the "black box" of AI-driven innovation and systematically investigate its internal mechanisms, interactive effects, and risk prevention pathways. Methodologically, this paper extends a discrete-time infinite-horizon dynamic optimization model by endogenously embedding the AI empowerment level into knowledge evolution equations, nonlinear cost functions, and market revenue signal generation mechanisms. A unified intertemporal dynamic analytical framework encompassing empowerment, cost reduction, and incentives is constructed, and the existence of these triple mechanisms, along with their interactive impacts, is rigorously verified via mathematical deduction. Building on this theoretical foundation, iFlytek Co., Ltd. is selected as a typical case to analyze the dynamic coupling of these mechanisms in corporate practice and the prevention pathways for "AI washing" risks, thereby achieving cross-validation between theoretical deductions and empirical case findings.

The results are threefold. First, AI enhances knowledge conversion efficiency per unit of effort and innovation output elasticity through the empowerment effect, boosting the full-cycle marginal returns of innovation activities. Second, AI systematically compresses trial-and-error costs and risk exposure through the cost reduction effect, restructuring the marginal cost structure of innovation. Third, AI transforms technology adoption behaviors into credible signals of high technical adaptive capacity through the incentive effect, triggering capital market financing premiums and forming a positive feedback loop of signal recognition and resource reinvestment. More critically, this paper reveals complex interactive relationships among these mechanisms: excessive incentives can easily trigger "AI washing", which in turn weakens the empowerment and cost reduction effects through resource crowding out and allocation distortions, thereby undermining long-term innovation capacity. The case analysis not only validates the synergistic role of the triple mechanisms but also identifies a risk prevention mechanism centered on strategic self-discipline, financial transparency, and ecological constraints.

This paper achieves logical integration and mathematical consistency of the triple mechanisms within a unified framework, revealing the dual attributes of AI as both a factor of production and a vehicle of capability signals. The conclusions provide systematic theoretical explanations and local empirical support for understanding how AI enhances innovation performance, while offering crucial decision-making insights for innovators to avoid false publicity traps, enterprises to build compliance and risk control systems, and policymakers to improve capital market signal screening mechanisms and advance the implementation of the AI Plus initiative.

Keywords: artificial intelligence; innovation performance; empowerment effect; cost reduction effect; incentive effect; AI washing

编校:周　斌;王冬梅