人工智能与产业融合

链主企业 AI 应用对上下游企业创新绩效的溢出效应研究

赵紫萱，杨皎平

（青岛科技大学经济与管理学院，青岛 266061）

摘要：基于 2022—2025 年中国制造业 94 家“链主”上市企业及其上下游企业的样本，实证探究链主企业 AI 技术应用对上下游企业创新绩效的溢出效应及其作用机制。研究发现：链主企业 AI 技术应用对上下游企业创新绩效存在显著正向溢出，但呈现非对称时序特征，上游企业表现为当期及长期持续溢出，下游企业则主要表现为滞后 1 年溢出且效应持续。机制检验表明，知识共享水平在上游路径中发挥部分中介作用（2022 年）并演变为完全中介（2024—2025 年），在下游滞后路径中呈现“完全中介→部分中介”的演变特征，揭示了 AI 技术溢出在供应链不同环节的传导机制差异及动态演变规律。上述发现为“人工智能＋产业链”深度融合、实现全链条创新协同提供了微观证据与实践指引。

关键词：“链主”企业；人工智能；溢出效应；创新绩效

中图分类号：F272.3 **文献标志码：**A **文章编号：**1671－1807(2026)17－0001－09

链主企业不仅主导产业链布局，更身兼创新链核心角色，能够带动上下游中小企业协同开展关键核心技术攻关，巩固提升优势产业的国际地位[1]；中小企业则深耕细分市场，为链主提供关键原材料与零部件，支撑产业链补链、固链、强链[2]。溢出效应理论指出，主体行为会对未直接参与互动的其他主体产生外部性影响，在供应链体系中，这体现为企业行为沿上下游链条传递，间接影响其他企业的能力与绩效[3]。人工智能技术的快速发展正重塑全球产业格局，作为通用技术，人工智能（artificial intelligence，AI）已成为技术创新的关键推动力。2024 年政府工作报告提出“开展‘人工智能＋’行动”，2025 年政府工作报告进一步提出“持续推进‘人工智能＋’行动”，核心在于通过支持大模型广泛应用、发展智能终端与夯实算力底座，推动数字技术与产业优势深度融合[4]。在这一进程中，链主企业作为产业链“火车头”，通过 3 大路径发挥关键带动作用：①推广成熟 AI 技术解决方案至上下游企业，开展链式改造解决中小企业转型难题；②依托工业互联网平台实现协同采购、制造与配送，优化全链条运营成本；③开放场景与数据资源，带动专精特新等中小企业融入 AI 创新生态，形成大中小企业融通发展的集群效应。最终，这种“以点带链、以链织网”的模式，将 AI 能力系统性地注入整条产业链，助力打造具有国际竞争力的数字产业集群[5]。

相关研究表明，链主企业作为行业龙头，在规模、市场、技术等方面享有优势[6]，其行为兼具正负外部性：一方面可通过协同合作整合全产业链资源，带动上下游技术能力提升[7]；另一方面也可能形成行业垄断，对本地企业构成竞争威胁。实践中，链主如何趋利避害、有效赋能上下游创新，已成为重要课题[8]，而人工智能技术的快速发展为此提供了新工具。然而，现有研究对供应链层面的智能化溢出路径及其条件分析尚显不足。基于此，现聚焦制造业，提出核心问题：链主企业 AI 技术应用如何影响上下游创新绩效？其作用机制与边界条件为何？通过构建“技术应用-知识共享-创新溢出”分析框架，并基于中国制造业上市公司数据开展实证检验，旨在揭示链主企业 AI 技术溢出在供应链上下游的时序异质性，厘清知识共享的差异化中介作用，并识别该溢出效应的所有制边界条件，以期为

收稿日期：2026-04-14

基金项目：山东省社会科学规划研究项目（24CGLJ14）

作者简介：赵紫萱（2002—），女，新疆乌鲁木齐人，硕士研究生，研究方向为供应链数字化创新；通信作者杨皎平（1980—），男，山西洪洞人，博士，教授，博士研究生导师，研究方向为创新管理。

推动“人工智能+产业链”深度融合、实现全链条创新协同提供微观证据与实践指引。

1 文献综述

1.1 链主企业

“链主企业”的概念源于20世纪80年代后期的全球价值链理论。Porter[9]提出的“价值链”模型虽未直接命名“链主”,但为企业识别战略环节、掌控价值分配提供了分析基础[10]。真正为其奠定理论基石的是Gereffi等[11]提出并发展的全球价值链治理理论。该理论中,“领导型”价值链由少数核心企业主导,这些“领导企业”通过设定产品规格、工艺流程与认证标准,对上下游企业进行协调与控制。这一机制已精准刻画了“链主”在标准制定与链上治理方面的核心功能。此后,资源依赖理论从关系互动微观层面补充解释“链主”地位的形成与稳固,指出上下游企业为获得关键订单等,会对掌握稀缺资源的“链主”企业产生不对称依赖,“链主”借此施加影响,实现影响力“溢出”,其权力源于对产业基础架构和技术路线的锁定能力[12]。

1.2 AI技术应用

AI技术在链主企业运营中已从试点迈向深度融合。在智能生产层面,链主企业通过机器视觉实现高精度质检,利用深度学习进行设备预测性维护,并借助柔性调度系统优化生产线[13],这不仅提升了自身效率,也为上下游设定了“数字制造”准入门槛。在供应链与客户洞察领域,AI通过时间序列分析与机器学习实现精准需求预测,构建智能供应链平台,将算法能力嵌入上下游运营;同时,利用自然语言处理分析非结构化数据,捕捉市场趋势与消费者偏好,引导上游创新与快速响应。在研发仿真环节,生成式设计算法与数字孪生模型大幅压缩创新周期,向上下游企业开放仿真工具构成高层次知识溢出[14]。综上,链主企业AI应用已进化为贯穿内外的“智能能力体系”,构筑了技术、知识与能力溢出的全新渠道。

1.3 溢出效应

在创新经济学与战略管理领域,“溢出效应”是指某一主体的经济活动对其他主体所产生的、未通过市场契约明确约定的外部影响。现有研究主要聚焦3类核心溢出机制:技术溢出体现为链主企业采用的新技术被上下游通过逆向工程、人才流动等途径模仿采用,降低其技术获取门槛与试错成本[15];知识溢出既包括易于编码的显性知识,更关键的是涉及经验、诀窍等隐性知识通过紧密协作、人员互动等非正式渠道缓慢扩散;网络溢出则指链主企业通过构建数字化生态,提升网络整体连接性与数据流动性,为所有参与者创造更丰富的创新机会与资源组合。

链主企业出于提升全链效率、构建稳固生态等战略目的,会主动向伙伴扩散技术、标准与数据,形成“主动溢出”[16]。因此,所考察的溢出效应,实质上是指链主企业通过AI应用所释放的主动赋能的外部性影响。

2 理论分析与研究假设

在信息化技术推动的现代供应链中,链主企业作为主导核心,具备资源与技术优势,能够协调上下游生产经营[17-18]。其AI技术应用不仅提升自身创新能力,更可能通过供应链溢出效应带动上下游企业创新绩效提升[19]。具体而言,链主企业AI技术应用程度越高,越能有效促进上游专利申请增长,并显著缩短下游新产品开发时间[20]。

2.1 链主企业AI应用与上游企业创新绩效

链主企业通过AI技术整合全链条市场需求与生产数据,精准捕捉前沿技术与潜在需求并传递给上游,显著降低其信息获取成本,加速研发活动,从而提升上游创新绩效[21]。同时,AI技术可延伸至上游创新决策支持:通过模拟环境对研发方案进行多维评估,帮助上游筛选最优方案,减少试错成本,缩短研发周期,促进创新产出[22]。此外,链主企业借助AI技术优化自身资源配置,将技术优势、资金支持及人才储备辐射至上游[23]。综上,链主AI技术应用经验为上游提供了可借鉴的创新模式,上游通过模仿或适配实现生产流程与质量管理的智能化升级,最终体现为创新绩效的提升。据此,提出如下假设。

H1:链主企业AI技术应用能促进上游企业创新绩效。

2.2 链主企业AI应用与下游企业创新绩效

链主企业以AI技术为核心驱动力,搭建起覆盖采购、制造、物流至销售全链路的智能数据网络,实时捕捉市场动态与消费者偏好,进而构建“动态迭代的实时信息共享平台”,助力下游企业精准锚定产品需求,有效缩短开发周期[21]。链主企业的AI技术应用进一步延伸至协同研发环节,借助机器学习与虚拟原型测试技术,为下游企业提供精准研发支持,显著降低设计迭代与沟通成本,大幅加速研发流程[22]。链主企业还运用AI技术打造灵活响应的供应链网络,依据产品开发进度动态调配零部件资源,实时分析市场反馈并精准识别产品缺陷,推动下游企业快速调整设计方案,有效缩短从研发到试产的转换周期[24]。这种动态响应能力不仅整

体压缩了新产品上市周期,更显著提升了下游企业的创新绩效。据此,提出如下假设。

H2:链主企业 AI 技术应用能促进下游企业创新绩效。

2.3 知识共享水平的中介作用

知识共享,即组织内外成员间知识、信息与经验的相互交流与传递过程[25]。在供应链治理场景下,知识共享能够有效打破信息孤岛,推动信息顺畅流通,缓解信息不对称问题,强化合作信任关系,进而提升供应链的整体运营效率与快速响应能力[26]。链主企业应用 AI 技术的核心价值之一,在于对供应链数据进行整合,并将其转化为具有创新价值的信息[21]。当知识共享水平处于较高层次时,上下游企业可更高效地获取链主借助 AI 分析生成的结构化信息,从而缩短创新决策的滞后时间[24]。反之,若知识共享程度不足,AI 技术生成的信息便难以渗透到上下游企业,其对创新的推动作用也会随之削弱。具体而言,上游供应商与链主企业互动紧密,主要依赖技术标准、质量反馈等硬性知识的快速传递;下游客户则需通过持续互动吸收市场洞察、产品趋势等软性知识,其知识转化周期相对较长。据此,提出如下假设。

H3a:知识共享水平在链主企业 AI 技术应用与上游企业创新绩效之间发挥中介作用;

H3b:知识共享水平在链主企业 AI 技术应用与下游企业创新绩效之间发挥中介作用。

3 研究设计

3.1 样本选取与数据来源

以 2022 年中国制造业上市公司为初始样本,从规模实力(营业收入及市场占有率)、创新能力(研发投入强度)和产业带动能力(披露前 5 大供应商及客户)3 个维度综合筛选链主企业。参考现有文献[3,18],以企业营业收入占全行业比重衡量市场占有率,超过行业均值则认定其具备链主地位,最终筛选出 94 家制造业上市公司作为链主企业样本。

需要说明的是,以上市公司作为链主企业研究样本具有充分的数据支撑。据中国证监会披露,实体上市公司利润占规模以上工业企业利润的比重已从 10 年前的 23%增长至超 50%,意味着中国制造业超一半的利润由上市公司创造。制造业 500 强上市公司利润总额占全部上市公司的 93.66%,营业收入占 71.53%。在深市主板,制造业公司数量占比达 65.91%,2022 年上半年实现营业收入5.05 万亿元,同比增长 9.64%。这些数据表明,制造业的龙头企业、利润主体高度集中于上市公司,非上市公司中具备同等链主地位的企业数量极为有限。此外,非上市公司无须强制披露前 5 大供应商及客户信息,无法构建供应链配对数据,不具备纳入研究的可行性。因此,以上市公司中的龙头企业作为链主企业样本,是在数据可得性约束下的合理选择。

依托链主企业年报披露的前 5 大供应商及客户信息,构建“链主-上下游企业”配对关系。由于 AI 技术自 2022 年起进入大规模商业化应用阶段,链主企业的 AI 战略布局与资源投入在该年显著跃升,因此采用 2022 年截面数据测度链主企业 AI 应用程度,以此捕捉技术溢出的关键窗口。被解释变量的观测窗口设定为 2022—2025 年,以此检验 AI 应用的同期效应与滞后效应。上下游企业相关数据的来源包括 3 部分:①供应链配对信息来源于链主企业年报中披露的“前 5 大供应商”及“前 5 大客户”信息,这也是本研究的配对基础;②上下游企业的创新绩效数据分别来自中国研究数据服务平台(CNRDS)及企业年报;③上下游企业的控制变量数据通过企查查、天眼查等第三方企业信息平台手工收集与整理。

样本筛选与处理遵循以下原则:①剔除 ST、*ST 及金融保险行业样本,删除上市不足一年或主要变量缺失的企业;②对每家链主企业保留前 5 大上游供应商及下游客户,剔除无法匹配或信息不全的观测值;③为缓解交互项可能产生的多重共线性问题,对链主企业 AI 应用程度进行中心化处理。最终形成上游与下游各 376 个截面观测值。所有连续变量均进行上下 1%缩尾处理,以减少极端值影响。

3.2 变量定义

3.2.1 被解释变量:企业创新绩效

为检验链主企业 AI 技术应用对上下游企业创新绩效的溢出效应,将被解释变量分为上游与下游两部分。

上游企业创新绩效(Up_Inn)以其专利申请量衡量。专利是衡量上游供应商创新产出的常用的指标之一,能够客观体现技术创新活动的成果[27]。具体测度步骤如下:①依据上市公司年报披露的前 5 大供应商信息,为每个链主企业匹配核心上游合作伙伴;②收集上游企业 2022—2025 年的专利申请数据,以捕捉 AI 大规模商业化应用前后的变化;③参考蒋殿春和鲁大宇[28]的研究,先计算每个链主企业前 5 大上游供应商专利申请量(Patent)的算术平均值,再取自然对数,作为该链主企业在对应年份的上游创新绩效指标,计算公式为

$$\mathrm{Up_Inn}_{i,t}=\frac{1}{5}\sum_{s=1}^{5}\ln(\mathrm{Patent}_{s,t}+1) \quad (1)$$

式中：i 为链主企业；s 为企业；t 为年份。

下游企业创新绩效（Dn_Inn）以新产品开发周期缩短率衡量。该指标能够有效反映下游企业因技术协同或需求拉动而实现的流程创新与效率提升[29]。具体测度步骤如下：①依据上市公司年报披露的前 5 大客户信息，为每个链主企业匹配核心下游客户企业；②收集每家下游企业 2022—2025 年的新产品从立项到量产的平均开发周期（单位：年）[30]，同时收集 2021 年数据用于计算 2022 年缩短率；③计算各下游企业的新产品开发周期缩短率（Development_Cycle），计算公式为

$$\mathrm{Dn_Inn}_{s,t}=\frac{\mathrm{Development_Cycle}_{s,t-1}-\mathrm{Development_Cycle}_{s,t}}{\mathrm{Development_Cycle}_{s,t-1}} \quad (2)$$

Dn_Inn 数值越大，表明开发周期缩短越明显，创新绩效越好。随后，对每个链主企业，计算其 5 家主要下游合作伙伴在各年度的缩短率算术平均值，作为该链主企业在对应年份的下游创新绩效指标。

3.2.2　解释变量：链主企业 AI 应用程度（AI）

为全面测度链主企业 AI 技术应用水平，从“战略披露”与“资源承诺”两个维度构建综合指标体系。具体测度方法如下：①参考李婉红与王帆[31]的关键词表并补充国家人工智能政策术语，对年报“管理层讨论与分析”部分进行文本分析，计算 AI 关键词词频占比（$\mathrm{AI}_{\mathrm{Text}_i}$），得到文本指标；②以总资产标准化链主企业年报中披露的 AI 相关研发投入金额（$\mathrm{AI}_{\mathrm{RD}_i}$），衡量实质性资源投入。对上述两个指标进行标准化处理后，依据样本变异系数确定权重（文本指标 0.36，研发投入 0.64）。最终解释变量计算公式为

$$\mathrm{AI}_i=0.36\times Z(\mathrm{AI}_{\mathrm{Text}_i})+0.64\times Z(\mathrm{AI}_{\mathrm{RD}_i}) \quad (3)$$

式中：Z 为标准化处理，用于消除量纲差异，随后按 0.36 和 0.64 的权重加权合成链主企业 AI 应用程度综合指标。

3.2.3　中介变量：知识共享水平（KS_Up/KS_Down）

以链主企业与上下游企业共同参与的产业技术创新联盟数量衡量知识共享水平。产业技术创新联盟是企业间为协同创新设立的正式合作组织，能够反映成员间制度化知识共享的强度[32]。具体测度时，统计链主企业 i 与合作伙伴 j（上游供应商或下游客户）共同隶属的联盟数量，并按链主分别计算与上游、下游企业的平均值，作为相应样本的中介变量。变量定义见表 1。

3.3　模型构建

采用截面多元线性回归模型，使用普通最小二乘法（OLS）进行估计，并报告异方差稳健标准误。为检验链主企业 AI 技术应用对上下游企业创新绩效的溢出效应及其作用机制，构建如下实证模型。

3.3.1　上游企业截面回归模型

为分别考察链主企业 AI 应用对上游创新绩效的同期效应与滞后效应，采用截面回归模型，基于 2022—2025 年的上游创新绩效数据进行估计，计算公式为

$$\mathrm{Up_Inn}_{i,t}=\alpha_0+\alpha_1\mathrm{AI}_i+\sum\beta_k X_{i,k}+\varepsilon_{i,t},\quad t=2022,2023,2024,2025 \quad (4)$$

式中：$\mathrm{Up_Inn}_{i,t}$ 为链主企业 i 在第 t 年（$t=2022$，2023，2024，2025）的上游企业平均创新绩效；AI_i 为链主企业 AI 应用程度；$X_{i,t}^{k}$ 包括链主企业自身控制变量以及上游企业层面控制变量；$\varepsilon_{i,t}$ 为随机误差项；α_0 为常数项；α_1、β_k 为系数。当 $t=2022$ 时，α_1 反映同期效应；当 $t=2023$，2024，2025 时，α_1 反映滞后效应。

3.3.2　下游企业截面回归模型

为分别考察链主企业 AI 应用对下游创新绩效的同期效应与滞后效应，采用截面回归模型，分别基于 2022—2025 年的下游创新绩效数据进行估计，计算公式为

表 1　变量定义

变量类型	变量名称	变量符号	变量测量
被解释变量	上游企业创新绩效	Up_Inn	专利申请数量增长率
	下游企业创新绩效	Dn_Inn	新产品开发周期缩短率
解释变量	链主企业 AI 应用程度	AI	年报统计词频
中介变量	知识共享水平	KS_Up/KS_Down	产业技术联盟创新关系
控制变量	链主企业性质	Soe	虚拟变量，国有企业为 1，非国有企业为 0
	链主企业年龄	Age	样本年份与企业成立年份差值的自然对数
	研发投入强度	Rd	研发投入占营业收入的比重
	营业收入增长率	RG	（当年的营业收入－上一年的营业收入）÷上一年的营业收入
	上下游企业规模	Size_Up/Size_Down	上游/下游企业注册资本取自然对数，再按链主取 5 家平均值
	上下游企业性质	SOE_Up/SOE_Down	虚拟变量，国有企业为 1，非国有企业为 0

$$\mathrm{Dn_Inn}_{i,t}=\beta_0+\beta_1\mathrm{AI}_i+\sum\gamma_k Z_{i,t}^k+\varepsilon_{i,t},\quad t=2022,2023,2024,2025 \tag{5}$$

式中：$\mathrm{Dn_Inn}_{i,t}$为链主企业 i 在第 t 年的下游企业平均缩短率；$Z_{i,t}^k$ 包括链主企业控制变量以及下游企业层面控制变量；β_0 为常数项；β_1、γ_k 为系数。当 $t=2022$ 时，β_1 反映同期溢出效应；当 $t=2023,2024,2025$ 时，β_1 反映滞后溢出效应。

3.3.3 知识共享水平中介模型

为检验知识共享水平的中介作用，参考 Baron 和 Kenny[33] 的三步法，并结合 Bootstrap 法进行稳健性检验。由于知识共享水平在 2022—2025 年波动较小，且聚焦于 AI 应用当期的制度化合作传导，故上下游中介检验均采用 2022 年截面数据，计算公式如下：

$$\mathrm{KS}_i=\alpha_0+\alpha_1\mathrm{AI}_i+\sum\beta_k C_{i,k}+\varepsilon_{i1}(X\to M) \tag{6}$$

$$Y_i=\gamma_0+\gamma_1\mathrm{AI}_i+\sum\delta_k C_{i,k}+\varepsilon_{i2}(X\to Y\text{ 总效应}) \tag{7}$$

$$Y_i=\gamma_0'+\gamma_1'\mathrm{AI}_i+\theta\mathrm{KS}_i+\sum\eta_k C_{i,k}+\varepsilon_{i3}(X+M\to Y) \tag{8}$$

式中：Y_i 为上下游企业创新绩效；$C_{i,k}$ 为对应控制变量；α_0、γ_0、γ_0'为常数项；α_1、β_k、γ_1、δ_k、γ_1'、θ、η_k 为系数。中介效应成立需满足 α_1、γ_1、θ 均显著，且 γ_1' 较 γ_1 减小（或变得不显著）。采用 Bootstrap 法计算间接效应 $\alpha_1\theta$ 的 95%置信区间。上下游模型结构一致，分别估计。其中，X 为解释变量（链主企业 AI 应用程度），M 为中介变量（知识共享水平），Y 为被解释变量（上下游企业创新绩效）。

4 实证结果与分析

4.1 描述性统计

表 2 的描述性统计结果显示，核心解释变量链主 AI 应用程度经过中心化处理，企业间智能化水平差异明显。上游创新绩效均值为 2.688，标准差为 1.374；下游创新绩效均值为 0.168，标准差为 0.118，二者均存在一定的样本差异。知识共享水平存在一定差异，表明制度化合作程度不均。上游企业以民营企业为主，规模分布集中；下游企业规模更大、国有化程度更高。链主企业自身控制变量均在合理范围内，数据分布无明显异常，为后续回归分析提供了可靠基础。

4.2 基准回归结果

4.2.1 上游企业基准回归结果

表 3 报告了上游企业 2022—2025 年的截面回归结果。列（1）、列（2）检验同期效应，列（3）～列（8）检验滞后效应。结果显示，2022 年 AI 系数在加与不加控制变量时均显著为正，表明上游存在稳健的同期溢出效应。2023—2025 年 AI 系数均显著为正（2025 年最为显著，$P<0.01$），且系数从 2024 年

表 2 变量描述性统计

变量	样本数	均值	标准差	最小值	25%分位数	中位数	75%分位数	最大值
AI	376	−0.044	0.505	−1.058	−0.212	−0.102	0.024	2.725
Up_Inn	376	2.688	1.374	0.000	1.758	2.549	3.497	7.590
Dn Inn	376	0.168	0.118	0.000	0.080	0.170	0.223	0.629
KS_Up	376	0.336	0.200	0.000	0.200	0.300	0.400	1.000
KS_Down	376	0.276	0.255	0.000	0.000	0.200	0.400	1.000
Size_Up	376	10.463	1.213	7.550	9.631	10.484	11.154	14.076
SOE_Up	376	0.214	0.255	0.000	0.000	0.200	0.400	1.000
Size_Down	376	11.814	2.366	4.605	10.244	11.896	12.929	17.127
SOE_Down	376	0.500	0.365	0.000	0.200	0.400	0.800	1.000
Age	376	3.269	0.288	2.480	3.140	3.260	3.400	4.160
Soe	376	0.394	0.489	0.000	0.000	0.000	1.000	1.000
Rd	364	0.053	0.059	0.001	0.018	0.037	0.063	0.346
RG	372	0.100	0.223	−0.397	−0.022	0.074	0.184	1.279

表 3 上游企业基准回归结果

变量	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)
AI	1.535**	1.294**	0.427	0.560*	0.457	0.563*	0.639***	0.750***
	(0.630)	(0.639)	(0.304)	(0.311)	(0.297)	(0.285)	(0.210)	(0.196)
控制变量	No	Yes	No	Yes	No	Yes	No	Yes
样本数	94	90	94	90	94	90	94	90
R^2	0.239	0.237	0.026	0.149	0.031	0.246	0.085	0.168

注：***、**、* 分别表示 1%、5%、10%的显著性水平；括号内为稳健标准误；控制变量包括上游规模、上游国企、链主年限、链主国企、研发投入占比、营业收入增长率。

起持续上升。这表明上游溢出效应不仅具有持续性，还呈现长期增强趋势，验证了 AI 技术赋能的长期价值。

4.2.2　下游企业基准回归结果

表 4 报告了下游企业 2022—2025 年的截面回归结果。列(9)、列(10)检验同期效应，列(11)～列(16)检验滞后效应。结果显示，2022 年 AI 系数边缘显著($P<0.1$)，表明同期效应较弱。2023—2025 年AI 系数均显著为正($P<0.05$ 或 $P<0.01$)，且 2024 年系数达到峰值(0.143，$P<0.01$)，2025 年仍保持高度显著(0.073，$P<0.01$)。这表明下游滞后效应不仅稳健存在，还呈现“滞后显现-持续增强”的特征，验证了链主 AI 赋能下游创新的长期价值。

4.3　知识共享水平中介

表 5 报告了上游企业 2022—2025 年[列(17)～列(20)]和下游企业 2022—2025 年[列(21)～列(24)]的中介效应检验结果。上游企业，2022 年、2024 年、2025 年知识共享均发挥完全中介作用(中介比例分别为 25.0%、43.5%、58.4%)，而 2023 年中介不成立；下游企业，2023 年知识共享发挥完全中介作用(57.1%)，2024 年、2025 年为部分中介(32.2%、39.7%)，2022 年中介不成立。

这表明，知识共享在上下游企业的传导呈现差异化时序特征：上游企业在 AI 应用当年及长期(滞后 2～3 年)均通过正式联盟合作实现创新传导，下游企业则在滞后 1 年完全中介、之后转为部分中介。这揭示了供应链上下游知识吸收节奏的显著差异：上游响应快、长期依赖联盟渠道；下游消化慢、初期完全依赖联盟、后期多元渠道并存。

4.4　稳健性检验

4.4.1　更换被解释变量

为确保研究结论的可靠性，采用更换被解释变量测度的方法进行稳健性检验。上游企业采用专利申请量原始值(未取对数)替代原被解释变量，下游企业采用新产品开发周期原始值(年)替代原被解释变量(缩短率)，分别对上游 2022 年、2024 年和 2025 年，下游 2022—2025 年进行重新回归。

表 6 显示，2022 年、2024 年及 2025 年上游 AI 系数均显著为正($P<0.05$ 或 $P<0.01$)，2023 年上游基准回归结果不显著，故未进行稳健性检验。2022—2025 年下游 AI 系数均显著为负($P<0.05$ 或 $P<0.01$)，表明 AI 应用显著缩短了下游开发周期。更换测度后核心结论未发生实质性改变，基准回归结果具有较好的稳健性。

表 4　下游企业基准回归结果

变量	(9)	(10)	(11)	(12)	(13)	(14)	(15)	(16)
AI	0.060*	0.060*	0.030**	0.035**	0.151***	0.143***	0.057**	0.073***
	(0.031)	(0.031)	(0.012)	(0.014)	(0.027)	(0.030)	(0.023)	(0.027)
控制变量	No	Yes	No	Yes	No	Yes	No	Yes
样本数	94	90	94	90	94	90	94	90
R^2	0.066	0.118	0.050	0.094	0.252	0.256	0.076	0.178

注：***、**、* 分别表示 1%、5%、10%的显著性水平；括号内为稳健标准误；控制变量包括下游规模、下游国企、链主年限、链主国企、研发投入占比、营业收入增长率。

表 5　中介变量回归结果

路径	(17)	(18)	(19)	(20)	(21)	(22)	(23)	(24)
$X\rightarrow M$	0.143**	0.143**	0.143**	0.143**	0.177***	0.177***	0.177***	0.177***
	(0.071)	(0.071)	(0.071)	(0.071)	(0.065)	(0.065)	(0.065)	(0.065)
R^2	0.150	0.150	0.150	0.150	0.250	0.250	0.250	0.250
$X\rightarrow Y$	1.294**	0.560*	0.563*	0.750***	0.060*	0.035**	0.143***	0.073***
	(0.639)	(0.311)	(0.285)	(0.196)	(0.031)	(0.014)	(0.030)	(0.027)
R^2	0.237	0.149	0.246	0.168	0.118	0.094	0.256	0.178
$X\rightarrow Y$	0.971	0.471	0.318	0.312	0.038	0.015	0.097***	0.044*
	(0.563)	(0.365)	(0.354)	(0.288)	(0.028)	(0.018)	(0.025)	(0.024)
$M\rightarrow Y$	2.258**	0.419	1.151*	2.054**	0.126	0.115***	0.260***	0.164**
	(1.063)	(0.659)	(0.630)	(0.852)	(0.083)	(0.036)	(0.077)	(0.064)
R^2	0.308	0.152	0.268	0.269	0.153	0.166	0.339	0.241
控制变量	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes
间接效应	0.323		0.245	0.438		0.020	0.046	0.029
中介比例/%	25.0		43.5	58.4		57.1	32.2	39.7
样本数	90	90	90	90	90	90	90	90

注：***、**、* 分别表示 1%、5%、10%的显著性水平；括号内为标准误。

表 6　稳健性检验结果

变量	(25)	(26)	(27)	(28)	(29)	(30)	(31)
	上游 2022 年	上游 2024 年	上游 2025 年	下游 2022 年	下游 2023 年	下游 2024 年	下游 2025 年
AI	19.071**	21.019**	73.259***	−0.153**	−0.188***	−0.176**	−0.136**
	(8.233)	(10.485)	(20.739)	(0.072)	(0.070)	(0.077)	(0.059)
控制变量	Yes	Yes	Yes	Yes	Yes	Yes	Yes
样本数	90	90	90	90	90	90	90
R^2	0.138	0.224	0.366	0.133	0.182	0.117	0.141

注:***、**、* 分别表示 1%、5%、10%的显著性水平;括号内为标准误。

4.4.2　中介效应的稳健性检验

为确保中介效应的可靠性,采用地理邻近性作为知识共享的替代指标进行稳健性检验。地理邻近性以链主企业与上下游企业是否位于同一省份衡量,取 5 家上游(下游)企业的平均值,取值范围介于 0～1,数值越大表示地理邻近性越强。该指标能够反映企业间的网络嵌入关系,是对原中介变量的有效补充。

采用与主检验相同的三步法,分别对上游企业(2022 年、2024 年、2025 年)及下游企业(2023 年、2024 年、2025 年)进行中介效应检验。据表 7 结果,各路径间接效应均显著,且中介比例与主检验结果基本一致,表明中介效应具有较好的稳健性。

4.5　异质性分析

鉴于企业所有制特征不随时间变化,异质性分析仅报告主窗口(上游企业 2022 年、下游企业 2023 年)结果。进一步将样本按链主企业性质分为国企组和民企组,分别进行分组回归。表 8 显示:民企链主中,上游企业同期效应显著为正($\beta=26.998$,$P<0.01$),下游滞后效应显著($\beta=-0.212$,$P<0.05$),表明 AI 应用显著缩短了下游企业的新产品开发周期;而国企链主中两者均不显著。这表明,链主 AI 的溢出效应主要存在于民营企业,可能源于民企供应链协同更灵活、决策链条更短,而国企受制于较长的决策流程与刚性管理制度,传导效率较低。

5　结论与对策建议

5.1　研究结论

(1)上下游溢出效应呈现显著的时序差异。上游供应商在链主企业 AI 应用当年即获得创新增益,体现“即时响应”特征,且该效应在长期持续增强。下游客户则呈现“持续滞后”特征,其创新增益从 AI 应用次年(2023 年)开始显著,并在 2024—2025 年保持强劲。这源于上游依赖技术标准、质量反馈等硬性知识能够快速传导,响应更为迅速;而下游需将消费者偏好、产品趋势等软性知识,经过研发设计、市场验证等长周期流程才能转化为创新成果,因此呈现持续滞后效应。

(2)知识共享是链主企业 AI 技术溢出的有效传导渠道,但作用时间窗口因上下游而异。上游硬性知识可通过联盟快速传递,知识共享在 AI 应用当期及长期均发挥完全中介作用,且中介比例持续上升;下游软性知识需经联盟持续互动逐步内化,知识共享在 AI 应用一年后发挥完全中介作用,之后转为部分中介,表明长期还存在其他传导渠道。

表 7　中介效应稳健性检验结果

路径	(32)	(33)	(34)	(35)	(36)	(37)
$X\rightarrow M$	0.349***	0.349***	0.349***	0.185***	0.185***	0.185***
	(0.059)	(0.059)	(0.059)	(0.043)	(0.043)	(0.043)
R^2	0.315	0.315	0.315	0.156	0.156	0.156
$X\rightarrow Y$	1.230**	0.563*	0.750***	0.035**	0.143***	0.082**
	(0.612)	(0.285)	(0.196)	(0.014)	(0.030)	(0.032)
R^2	0.215	0.246	0.168	0.094	0.256	0.174
$X\rightarrow Y$	0.888	0.052	0.387	0.019	0.116***	0.061*
	(0.632)	(0.292)	(0.266)	(0.013)	(0.036)	(0.032)
$M\rightarrow Y$	0.980*	1.466***	1.040**	0.088***	0.146*	0.110*
	(0.498)	(0.419)	(0.491)	(0.032)	(0.078)	(0.063)
R^2	0.251	0.336	0.232	0.176	0.307	0.219
控制变量	Yes	Yes	Yes	Yes	Yes	Yes
间接效应	0.342	0.512	0.363	0.016	0.027	0.020
中介比例/%	27.8	90.9	48.4	45.7	18.9	24.4
样本数	90	90	90	90	90	90

注:***、**、* 分别表示 1%、5%、10%的显著性水平;括号内为标准误。

表 8　异质性检验结果

变量	(38)	(39)	(40)	(41)
	上游国企	上游民企	下游国企	下游民企
AI	−14.476	26.998***	−0.040	−0.212**
	(33.868)	(7.358)	(0.127)	(0.090)
控制变量	Yes	Yes	Yes	Yes
样本数	35	55	35	55
R^2	0.134	0.279	0.064	0.324

注：***、**、* 分别表示 1%、5%、10%的显著性水平；括号内为标准误。

(3)溢出效应存在所有制异质性，主要集中于民营企业。民营企业供应链协同灵活、决策链条短，能够更快响应 AI 技术变革；国有企业受制于较长的决策流程和刚性管理制度，传导效率较低，未呈现显著影响。

5.2　研究贡献

(1)拓展了 AI 技术经济后果的研究边界。现有文献多聚焦于 AI 技术对企业内部生产率、管理效率的影响，从产业链生态视角出发，揭示了链主企业 AI 应用对上下游企业创新绩效的溢出效应，并发现上游企业表现为当期及长期持续溢出，下游企业则表现为滞后一年及长期持续溢出的非对称特征，深化了对 AI 技术跨组织传导机制的理解。

(2)揭示了供应链创新溢出的时序异质性与所有制异质性。通过区分同期与滞后效应，发现上游供应商因硬性知识快速传导而即时受益且效应长期持续，下游客户因软性知识吸收周期较长而呈现滞后一年溢出并在后续保持稳定；进一步地，溢出效应主要存在于民营企业，国有企业中未显著显现，这为理解创新溢出的传导节奏与边界条件提供了新的理论视角。

(3)厘清了知识共享在 AI 溢出中的差异化中介作用及其动态演变规律。发现知识共享在上游路径中由部分中介演变为完全中介，在下游滞后路径中则呈现“完全中介→部分中介”的演变特征，表明知识共享的中介作用随时间窗口变化，下游企业在长期还通过其他渠道传导。

5.3　对策建议

(1)链主企业应实施差异化赋能策略。对于上游供应商，着重加强技术标准输出、质量反馈机制，借助数字化采购平台及时传递工艺改进要求，帮助供应商实现长期能力提升；对于下游客户，应依托产业技术创新联盟建立常态化知识共享机制，在 AI 应用初期重点通过联盟渠道传导软性知识，后期则需拓展数据共享平台、联合研发等多元渠道，匹配其从完全中介向部分中介转变的传导特征。

(2)上下游企业应构建适配的知识吸收体系。上游供应商应建立快速响应机制，设立技术对接专员，及时将链主技术标准转化为内部工艺改进方案，并将短期被动适配转化为长期创新能力；下游客户应组建专职分析团队，在 AI 应用初期重点依托联盟渠道吸收软性知识，后期则需拓展内部研发、市场验证等多元转化路径，将滞后创新优势转化为持续竞争力。

(3)政府部门应实施分类引导与数据赋能。对于民营企业，要着重支持其展现灵活协同的优势，借助税收优惠、专项补贴等方式，激励链主企业带动上下游展开创新活动；对于国有企业，则要对决策流程予以优化，建立创新容错机制，以此减少制度刚性给技术溢出造成的阻碍。

(4)着力推动建立“链主引领、多元赋能”的创新生态模式。积极鼓励链主企业与上下游企业共同搭建数据共享平台，借助技术标准、市场洞察、联合研发等多种渠道，分层次有效传导 AI 技术红利；大力推动产业技术创新联盟从“形式联合”向“实质协同”转型，建立知识共享实效评估机制，切实保障联盟合作能真正提升上下游企业的创新能力。

参考文献

[1] 曲永义. 数字经济与产业高质量发展[J]. China Economist，2022，17(6)：2-25.

[2] 张其仔. 产业链供应链现代化新进展、新挑战、新路径[J]. 山东大学学报(哲学社会科学版)，2022(1)：131-140.

[3] 赵晶，刘玉洁，付珂语，等. 大型国企发挥产业链链长职能的路径与机制：基于特高压输电工程的案例研究[J]. 管理世界，2022，38(5)：221-239.

[4] 黄先海，虞柳明. 人工智能与新质生产力：逻辑、现实境遇与政策取向[J]. 东南学术，2025(1)：125-137，248.

[5] 王晓丹，刘达，王淑瑶. 人工智能供应链溢出对企业加成率分布的影响研究[J/OL]. 管理学报，1-10[2026-03-17]. https://link.cnki.net/urlid/42.1725.C.20260519.1426.018.

[6] 姚加权，张锟澎，郭李鹏，等. 人工智能如何提升企业生产效率？基于劳动力技能结构调整的视角[J]. 管理世界，2024，40(2)：101-116.

[7] 罗艳梅，王蕾. 信息协同视角下业财融合对制造业供应链韧性的影响研究[J]. 财会月刊，2025(2)：72-77.

[8] 于苏，于小悦，王竹泉.“链主”企业的供应链治理与链上企业全要素生产率[J]. 商业经济与管理，2023(4)：22-40.

[9] PORTER M E. Competitive advantage：creating and sustaining superior performance[M]. New York：Free

Press, 1985.
[10] 张雨萌, 王静. ESG 信息披露对企业绿色创新绩效的影响研究综述与展望[J]. 时代经贸, 2025(3): 106-112.
[11] GEREFFI G, HUMPHREY J, STURGEON T. The governance of global value chains[J]. Review of International Political Economy, 2005, 12(1): 78-104.
[12] 李强, 王睿, 施征宇. "链主"企业 ESG 表现的溢出效应研究[J]. 中南财经政法大学学报, 2024(5): 138-149.
[13] 杨真真. "链主"企业对链上企业突破性创新的影响:基于专精特新企业的经验证据[J]. 技术经济与管理研究, 2025(1): 23-29.
[14] 施曼. 人工智能、新质生产力与产业链供应链安全[J]. 新疆社会科学, 2024(6): 54-64, 183.
[15] 张誉夫, 谢建国, 孟庆伟. 人工智能应用有助于促进企业专业化分工吗? 基于中国上市企业数据的研究[J]. 山西财经大学学报, 2024, 46(7): 87-98.
[16] 魏娟. 大数据时代基于 SAP 系统的财务共享模式内部控制与信息安全策略研究[J]. 金融文坛, 2025(4): 91-93.
[17] 王丽莎, 庞智强, 邢强. 企业数字化转型的创新溢出效应:基于产业链供应链韧性视角[J]. 软科学, 2025, 39(1): 77-84.
[18] ACEMOGLU D, CARVALHO V M, OZDAGLAR A, et al. The network origins of aggregate fluctuations[J]. Econometrica, 2012, 80(5): 1977-2016.
[19] 盛朝迅. 产业生态主导企业培育的国际经验与中国路径[J]. 改革, 2022(10): 34-44.
[20] 包群, 但佳丽. 网络地位、共享商业关系与大客户占比[J]. 经济研究, 2021, 56(10): 189-205.
[21] SHERWOOD A L, COVIN J G. Knowledgeacquisition in university-industry alliances: an empirical investigation from a learning theory perspective[J]. Journal of Product Innovation Management, 2008, 25(2): 162-179.
[22] 李玉花, 林雨昕, 李丹丹. 人工智能技术应用如何影响企业创新[J]. 中国工业经济, 2024(10): 155-173.
[23] 李果, 白云朴. 人工智能应用如何影响制造企业创新绩效?[J]. 财经论丛, 2024(12): 102-112.
[24] 孙兰兰, 张璐, 祝兵. "链主"企业 CVC 驱动链上企业新质生产力提升: 供应链溢出视角[J]. 现代财经(天津财经大学学报), 2025, 45(5): 95-112.
[25] 李娜娜, 张宝建, 马鹏玉, 等. 企业开放式创新策略对新产品开发绩效的影响: 基于组织学习的中介作用[J]. 科技管理研究, 2025, 45(12): 13-22.
[26] 沈占波, 李昂. 开放式创新平台核心参与者知识共享行为的多重驱动路径研究[J]. 科技进步与对策, 2023, 40(21): 118-128.
[27] 杜小民, 单标安, 闫双慧, 等. 数字经济背景下顾客参与、知识共享对科技型新创企业技术商业化能力的影响[J]. 科技进步与对策, 2023, 40(13): 71-80.
[28] 唐松, 谢雪妍. 企业持股金融机构如何服务实体经济: 基于供应链溢出效应的视角[J]. 中国工业经济, 2021(11): 116-134.
[29] 蒋殿春, 鲁大宇. 供应链关系变动、融资约束与企业创新[J]. 经济管理, 2022(10): 56-74.
[30] 谢恩, 陈昕. 供应商网络与买方企业新产品开发绩效的研究[J]. 科研管理, 2015, 36(6): 20-27.
[31] 李婉红, 王帆. 智能化转型、成本黏性与企业绩效: 基于传统制造企业的实证检验[J]. 科学学研究, 2022, 40(1): 91-102.
[32] MEIXIA W, YUNXIA W, ABBAS M. Empirical analysis of the influencing factors of knowledge sharing in industrial technology innovation strategic alliances[J]. Journal of Business Research, 2023, 157: 113635.
[33] BARON R M, KENNY D A. The moderator-mediator variable distinction in social psychological research: conceptual, strategic, and statistical considerations[J]. Journal of Personality and Social Psychology, 1986, 51(6): 1173-1182.

Research on Spillover Effects of Chain-leading Enterprises' AI Applications on Innovation Performance of Upstream and Downstream Enterprises

ZHAO Zixuan, YANG Jiaoping

(School of Economics and Management, Qingdao University of Science and Technology, Qingdao 266061, China)

Abstract: Based on a sample of 94 chain-leading listed companies in China's manufacturing industry and their upstream and downstream enterprises from 2022 to 2025, an empirical investigation was conducted into the spillover effects and mechanisms of AI technology application by chain-leading enterprises on the innovation performance of upstream and downstream enterprises. It is found that a significant positive spillover effect is exerted by AI technology application of chain-leading enterprises on upstream and downstream innovation performance, but an asymmetric temporal pattern is exhibited. Contemporaneous and sustained long-term spillovers are observed for upstream enterprises, whereas a one-year lagged spillover with sustained effects is primarily identified for downstream enterprises. Through mechanism analysis, it is revealed that a partial mediating role is played by the level of knowledge sharing in the upstream path in 2022, and a full mediating role is played from 2024 to 2025. In the downstream lagged path, a transition from full mediation to partial mediation is observed. Differences in transmission mechanisms and dynamic evolution patterns of AI technology spillovers across different supply chain segments are thereby revealed. Micro-level evidence and practical guidance are provided for the deep integration of "AI + industrial chain" and the realization of full-chain innovation synergy.

Keywords: chain-leading enterprises; artificial intelligence; spillover effects; innovation performance