

企业人工智能技术水平的分层测度及其 创新效应

——基于全球知识网络视角

安同良, 吴致冶

[摘要] 万物智能互联时代,人工智能(AI)作为通用目的技术,加速了全球知识网络的生成。西方主流经济学仅将AI视为生产要素的投入,难以刻画AI技术知识构成的复杂性及其发展的可赶超性。本文基于复杂经济学视域,将AI凝练为复杂嵌套的层级知识系统,构建了AI领域的全球知识共现分层网络,创造性地提出了企业AI技术水平的分层测度方法;根据Jaccard相似度,将AI技术层次划分为通用AI与应用AI两大社区以及底层算法、感知类、平台型、行业应用型技术四大聚类。基于中国制造业上市公司的实证分析发现:通用AI在企业间呈现较强的幂律特征,企业AI技术构成的重心正由平台型技术向底层算法迁移。本文揭示了AI通过知识搜寻的深度与广度对企业创新的传导路径与机制,验证了AI对企业创新的总体影响与行业异质性影响;企业AI技术水平每提高1%,创新水平提高0.65%。本文既破解了AI技术知识构成的“黑箱”,也破解了AI创新效应的“黑箱”,为AI技术分类与测度作出基础性贡献。中国正在迈向强AI时代,以AI底层算法为引领的使命导向型政策将为中国在AI新赛道实现技术赶超提供强大动能。

[关键词] 人工智能; 复杂经济学; 制造业上市公司; 创新; 分层测度

[中图分类号] F124 **[文献标识码]** A **[文章编号]** 1006-480X(2025)06-0081-20

一、引言

万物智能互联时代,嵌入互联网的分布式主体在多边网络下通过目标知识搜寻发生广泛的连接,进而生成新的知识与技术(安同良等,2023)。人工智能(AI)作为通用目的技术,在全球范围内加速发现不同领域知识间的潜在关联(Righi et al., 2020),推动着全球知识网络的创生与扩展。信息与AI技术的发展遵循加速回报定律(Kurzweil, 2005),数字技术领先国家已获得先发锁定优势。以美国为首的西方技术发达国家为垄断数字经济发展的霸权,通过一系列法案、技术投资限制、出

[收稿日期] 2025-01-19

[基金项目] 国家社会科学基金重点项目“中国式创新的综合优势、模式演进及体制机制的经济学研究”(批准号22AZD118)。

[作者简介] 安同良,南京大学商学院教授,博士生导师,管理学博士;吴致冶,南京大学经济学院博士研究生。通讯作者:吴致冶,电子邮箱:602022020018@smail.nju.edu.cn。感谢匿名评审专家和编辑部的宝贵意见,文责自负。

口管制、歧视性关税等持续加码,对中国 AI 等先进技术发展进行知识围堵。世界已被分割成了以中美为首的两大数字阵营,硅幕两侧的数字网络渐行渐远(赫拉利,2024)。中国制造业企业积极拥抱 AI 技术,企业竞争力日新月异,展现出 AI 技术发展的多种路径与可超越性。

目前经济学界对 AI 技术的界定较为模糊,大多数将其等同于工业机器人、自动化技术等(Acemoglu and Restrepo, 2018),其本质是将企业 AI 技术看作企业的要素投入。仅从要素投入角度衡量企业 AI 技术,难以全面衡量 AI 技术知识构成的复杂性。事实上, AI 技术知识构成的复杂性本身需要系统的理论与方法对其进行分层观测与测度,复杂经济学提供了精准界定 AI 技术知识结构的全新视域。复杂经济学强调世界是由多个相互连接、互动的层级系统组成(Simon, 1962)。为此, AI 技术不再仅仅被视为单一的生产要素,而是作为一种嵌套的、跨学科的层级知识系统。

本文认为, AI 技术是多模块复杂的非线性嵌套知识系统。技术创新的本质在于新知识与现有技术的组合进化(Arthur, 2009; 安同良和闻锐, 2024)。当知识可以被无限分割时, 技术可以通过细分后的知识单元进行量化(Agrawal et al., 2018)。同时, 制造业企业本身可以被看作另一个知识系统, 企业 AI 技术水平的测度在于将两个知识系统的交集投射到一维坐标上。基于以上逻辑, 本文从全球知识网络视角提出了全新的制造业上市公司 AI 技术水平的测度方法: 通过 AI 领域的核心专利所蕴含的所有知识信息, 构建 AI 领域的全球知识共现网络, 并计算每个知识在 AI 领域的相对重要性。同时, 逐一解析企业当年所有申请专利中的 AI 知识出现频次。综合考虑企业 AI 相关知识出现频次及其重要性, 从而逐一映射出企业 AI 技术水平。通过知识共现网络中节点的结构相似性算法, 进一步分层测度了企业不同聚类的 AI 技术水平。这一测度框架不仅精准捕捉了 AI 技术水平的发展特征, 使其契合技术的知识本质特征, 更破解了 AI 技术知识构成的“黑箱”。只有通过 AI 技术的分层测度, 才能真正科学估量企业 AI 技术的使用对企业创新驱动发展的贡献, 并且为中国“人工智能+”战略提供政策启示。

二、文献综述

近年来, 学术界围绕 AI 技术水平及其对企业创新绩效的影响开展了较为广泛的研究, 本文在 AI 技术发展的宏观进程下系统梳理相关文献。诺贝尔物理学奖得主彭罗斯将不同学者对 AI 发展的乐观程度由强到弱一共分为 A、B、C、D 四类。强 AI 观点(A 类)认为, 大脑的一切活动都可以被模拟仿真, 意识可以由恰当的计算直接产生。其余三类则为弱 AI 观点: 人脑活动在不同程度上难以被计算机模拟(彭罗斯等, 2023)。而本文认为, 目前人类社会的 AI 技术正在迈向强 AI 的宏观进程, AI 多任务类型的零样本学习正在实现, 这正是智能的核心(库兹韦尔, 2024)。

1. 企业 AI 技术水平的衡量方法

目前, 已有研究大致从以下四个视角衡量企业 AI 技术水平: ①基于西方新古典经济学框架, 学术界的主流方法是将企业 AI 技术看作特定要素投入及其组合, 例如, 用工业机器人数量、密度等代表企业 AI 投入(Acemoglu and Restrepo, 2018), 或者用 AI 相关人力资本投入测度企业 AI 技术水平(Babina et al., 2024)。②将企业 AI 技术当作企业拥有的计算机领域的特定知识(Fujii and Managi, 2018), 该研究未能将企业 AI 与创新紧密联系, 且未能测度企业独立的 AI 技术水平。③基于微观创新调查数据, 考察 AI 在工艺流程、产品服务、客户分析等具体生产过程中的应用情况(Rammer et al., 2022), 调查问卷的方法虽然可以详细判断企业在不同过程中使用不同 AI 技术类型, 但是无法刻画具体应用程度。④从上市公司年报、财务报告等文本中提取和衡量企业 AI 技术综合应用情况(Li

et al., 2023; 姚加权等, 2024), 这些研究对 AI 技术的概括较为笼统。李玉花等(2024)基于 AI 技术特征, 将其分为基于逻辑的 AI 和基于学习的 AI 技术。Dahlke et al.(2024)基于企业网站文本数据分析, 将 AI 分为表层 AI 知识和深层 AI 知识。然而, 文本分析难以克服的问题在于, 种子词的选取依赖经验, 精准性有待检验。

2. 企业 AI 技术创新效应的研究

现有文献认为, AI 技术对企业创新的影响主要通过以下三条路径: 一是创新趋势预测。企业正在借助 AI 预测新趋势并突破人类认知的局限(An and Ahn, 2016)。二是创新决策支持。AI 不仅通过预测作用直接促成创新, 还能够通过增强预测能力, 提高管理层在创新投资和市场趋势分析中的决策效率(Mariani and Nambisan, 2021)。但在决策过程中人类与 AI 技术如何实现互补这一难题仍然存在(Jarrahi, 2018)。三是组织模式优化。Kuzey et al.(2014)研究表明, AI 技术可以提高企业运营效率和供应链效率, 创造新商业模式。

尽管现有研究在企业 AI 技术测度和创新路径分析方面取得了一定进展, 但其分析仍然依赖传统西方新古典经济学框架, 缺乏将 AI 作为复杂知识系统的科学刻画。同时, AI 技术在企业创新中的作用仍未形成明晰的系统性理论支撑, 现有研究忽视了 AI 在知识创新、技术重组和底层创新模式方面的深刻影响。因此, 本文运用全球知识网络重新构建 AI 技术测度框架, 并探讨 AI 如何通过知识搜寻影响企业创新。

三、企业 AI 技术水平分层测度的理论逻辑

1. 复杂系统视域下 AI 技术的网络层级特征与可测度性

科学与技术知识领域是一种具有“模块化—层级化—可重组”的复杂自适应系统(Arthur, 2009; Narayanamurti and Tsao, 2021), AI 技术更是由模块化知识构成的复杂层级知识系统, 其创新效应体现在新知识与现有技术模块的组合进化。①AI 技术由模块化知识构成, 并非一个不可分割的“黑箱”。模块化知识是构建 AI 知识系统的基础, 并且随着技术的不断演化, 呈现出螺旋式的模块化再集成。在维持系统整体性的前提下, 不同层次与尺度的现象能够被独立研究(Simon, 2002), 这意味着 AI 知识系统的各模块在理论上具备独立分析与测度的可行性。②作为嵌套的知识系统, AI 技术的模块化并不意味着知识的松散堆积, 相反, AI 知识体系呈现出高度关联与分层嵌套的结构特征, 子结构之间通过耦合与协同演化, 最终形成一个自我强化的“无缝网络”(Anderson, 2001)。该网络呈现出“小世界”特征: 少数枢纽节点高度互联, 形成紧密簇群, 并通过“弱连接”与外围节点保持整体联通。③作为通用目的技术, AI 推动知识组合式创新。创新不是无限制地自由发生, 而是在既有知识结构的边界上生成新的知识组合, 这种知识组合的广度越高, 越容易发现创造性的结论。但人脑思维的局限性会导致知识创新出现“广度对抗深度”的挑战(Avina et al., 2018)。AI 在这一过程中扮演着关键的“加速器”角色: 其高维计算能力与语义识别机制, 能够在庞大知识空间中识别潜在的关联路径, 提升跨模块知识的匹配效率与重组能力。在拓展知识广度的同时, AI 重塑了深度组合的可能性, 突破了人脑思维在结构复杂性处理上的天然瓶颈。

2. 复杂经济学视域下企业 AI 技术水平的测度逻辑

在复杂经济学视域下, 企业 AI 技术水平的测度基于非线性系统方法与多主体互联式创新框架(安同良等, 2023)。不同于新古典经济学依赖要素投入产出关系的测度方式, 复杂经济学强

调 AI 在互联式创新网络中的嵌套性与演化特征^①。AI 技术对企业创新的驱动作用主要通过知识的组合式扩张,而非单一市场需求驱动下的探索试错。因此,其测度不应局限于企业层面的投资与财务指标,而应立足全球知识网络,关注知识的流动与演化。在生产函数层面,AI 不再仅仅是某种具体的生产要素,而是多学科的智能知识系统的耦合,其产出取决于创新主体的智能度和连接度。因此,在复杂经济学视域下,运用复杂网络分析的图算法和结构算法,通过挖掘全球知识网络中的知识节点信息,建立更符合 AI 技术本质的测度框架,方能更精准地评估 AI 对企业创新的影响。

3. AI 领域全球知识网络的构建

依据知识的组合式创新理论(Agrawal et al., 2018),知识创新被理解为“现有知识储量”的潜在组合,并由此催生出“新知识”,而新知识一经生成,又作为知识单元被纳入知识网络。这一机制建立在“知识可分性”的理论假设之上,然而现实中知识边界较为模糊,难以被直接识别与结构化观测。为在实证中捕捉知识的动态演化特征,本文以专利作为知识组合的载体,其形成过程即多个知识单元的重组过程,最终成果体现为新的知识组合。进一步地,本文引入专利所携带的 IPC 分类号以实现知识单元化处理,将抽象的技术知识具象为可分类、可识别的符号表达。基于这一逻辑,本文构建了 AI 领域的知识共现网络,并据此测度企业知识结构与 AI 知识系统之间的结构性耦合程度。

具体而言,在 Incopat 全球专利数据库中,将“Artificial Intelligence”作为关键词进行模糊搜索,得到全球 2014 年至 2025 年 2 月所有涉及 AI 领域的专利,并按照被引用次数从高到低进行排序。选取被引用量前 1000 的专利数据,并解析这些专利涉及的所有 IPC 分类号信息。根据 IPC 分类号的共同出现次数,构建 AI 领域的全球知识网络:网络中知识以节点的形式存在,为其后续量化提供了可能性。网络中的连边为两种知识的“共现关系”:如果同一专利中同时出现两个不同的 IPC 分类号,视为这两个知识单元发生一次共现,由此构建知识共现网络中的连边关系。

具体的 IPC 号虽然更精细,然而其粒度过小,难以全面反映专利之间在技术方向上的关联。在实际专利数据中,存在大量专利虽然未使用完全相同的 IPC 号,但其所属的知识领域高度相近。为了更全面反映 AI 领域知识之间的潜在知识关联性,本文同时考虑了 IPC 小类的共现关系。表 1 分别统计了根据 IPC 小类和具体 IPC 号构建的知识共现网络特征。从表 1 可以发现,知识节点被浓缩为约 1/10 个知识方向。将原先分散在不同 IPC 号的共现次数叠加到小类上,虽然网络整体变得稀疏,集聚效应下降,但是在局部反而表现出更强的集聚效应(最大共现次数上升)。

表 1 AI 全球知识共现网络特征信息

	知识节点个数	共现次数	最大共现次数	集聚系数
IPC 号	1067	8473	216	0.795
IPC 小类	106	568	380	0.679

为了进一步区分知识单元在网络中的重要性程度,本文用计算加权 PageRank 值衡量节点的重要性程度,其计算公式为:

^① 具体测度逻辑表格参见《中国工业经济》网站(ciejournal.ajcass.com)附件。

$$PR(i) = (1 - \alpha) + \alpha \sum_{j \in N(i)} \frac{w_{ij} \cdot PR(j)}{\sum_{k \in N(j)} w_{jk}} \quad (1)$$

其中, $PR(i)$ 为第 i 个节点的加权 PageRank 值, 衡量知识的重要性程度, α 为阻尼因子, 按照惯例设定为 0.85, 表示每个节点跳转的概率; $N(i)$ 为节点 i 邻居节点 j 的集合; w_{ij} 表示节点 i 和 j 之间边的权重, 以知识节点之间的共现频次衡量, $\sum_{k \in N(j)} w_{jk}$ 表示节点 j 的加权重。通过迭代计算每个节点的加权 PageRank 值, 并直至收敛。为突出不同知识节点在网络结构中的相对重要性, 本文采用以 PageRank 得分为基础的分层布局方式构图, 使得核心知识模块在图中自然沉降于底部。节点的大小即为其加权 PageRank 值大小的直观表示。其中, 底层为加权 PageRank 值前 10% 的知识节点, 包含 AI 知识领域中最重要五个枢纽节点: 机器学习方法 (G06N20/00)、神经网络学习方法 (G06N3/08)、神经网络结构 (G06N3/04)、图像识别 (G06K9/00) 和图像聚类方法 (G06K9/62); 中间层为加权 PageRank 值排名前 20% 的知识节点; 上层为其余节点。在 AI 知识网络中, 底层节点簇与其他知识模块之间形成放射状连接结构, 尤其是五个枢纽节点构成了 AI 知识网络底层的源头性核心放射源, 这表明 AI 知识系统不仅具备中心辐射能力, 也具有较强的知识扩散性与兼容性。为此, 本文聚焦底层枢纽节点集, 进一步分析 AI 知识共现网络的底层逻辑与结构, 以揭示 AI 知识网络的核心结构特征。

4. 基于 Jaccard 相似度的企业 AI 技术层级聚类

为深入揭示 AI 知识网络底层结构的细粒度特征, 需要引入更具针对性的聚类算法, 对底层枢纽节点集进行系统性的归类与结构分析^①。具体而言, 本文采用基于网络拓扑结构的 Jaccard 相似度算法对知识节点进行更精确的聚类分析, 计算知识节点之间的相似性。与其他相似度算法相比, Jaccard 相似度更强调邻接结构对称性, 符合知识共现网络的对称性特征。对于节点 i 和节点 j , Jaccard 相似度 $J(i, j)$ 的计算公式为:

$$J(i, j) = \frac{|N(i) \cap N(j)|}{|N(i) \cup N(j)|} \quad (2)$$

其中, $N(i)$ 和 $N(j)$ 表示任意一组节点 i, j 的邻居集合, $|N(i) \cap N(j)|$ 表示两个节点的共同邻居数量; $|N(i) \cup N(j)|$ 表示两个节点邻居的联合集合大小。通过计算每对节点的 Jaccard 相似度, 得到节点之间的相似度矩阵。在此基础上, 本文进一步采用 Ward 方法进行聚类。Ward 方法通过最小化类内方差来进行节点的合并, 确保每个聚类内的节点尽可能相似。最终呈现底层枢纽知识节点集的聚类情况。聚类结果的树状图如图 1 所示, 其中, 纵轴表示 AI 知识网络中所有底层枢纽知识节点, 横轴表示基于 Jaccard 相似度计算的聚类偏差值。偏差值越大, 代表被归入同一聚类的大类之间内部异质性越强, 即知识节点间在邻接结构上的差异越显著。

聚类结果表明, 底层 AI 枢纽知识节点被分为两大社区: 通用 AI 技术和应用 AI 技术; 具体又可细分为四大聚类: 底层算法、感知类技术、平台型技术、行业应用型技术。其中, 通用 AI 技术涵盖了现代 AI 的核心技术: 机器学习、自然语言处理技术等, 该部分技术通常构成知识网络源头性的枢纽节点, 决定了整个 AI 技术体系的发展方向。从相似度偏差数值看, 通用 AI 技术内部差异度较小, 结构更加紧密, 说明不同通用 AI 技术之间存在强关联性, 即它们共享相似的技术原理, 并可能在多

① 底层枢纽节点可视化结果参见《中国工业经济》网站(ciejournal.ajcass.com)附件。




图1 基于Jaccard相似度的AI技术层次聚类

个应用场景中协同使用。应用AI知识节点之间结构差异相对较大,说明AI技术在不同行业的知识应用特征存在较大差异。平台型技术聚类是应用AI技术的行业共性技术,包括智能检索、数据管理、图像处理、网络协议等。行业应用型技术聚类表明AI在医疗领域的应用最深入,同时广泛应用于智能交通、电视监控、医疗设备、运动设备等领域。

四、中国制造业上市公司AI技术水平的测度^①

1. 中国制造业上市公司AI技术水平的分层测度方法

企业AI技术水平的测度逻辑在于识别企业知识结构与AI知识系统之间的结构性耦合程度。为此,本文提取中国制造业上市公司累积专利形成的知识库与AI知识系统的耦合关系,并通过加权求和的方式,将该耦合关系在一维坐标系中进行投影与量化,从而构建出反映企业AI技术嵌入深度的动态指标。

AI知识网络中底层枢纽知识节点不仅在网络中具有领先的加权PageRank值,而且向其他层辐射扩散。因此,本文立足底层枢纽知识节点,将其作为衡量企业AI技术水平的得分来源。受文本分析的词频统计启发,本文提取了企业所有专利中AI领域底层枢纽知识节点的出现频次。同时,逐一解析上市企业所涉年份的所有申请或授权的发明IPC分类号的小组信息,并按照枢纽知识节点的加权

^① AI技术水平测度方法及特征性结果图参见《中国工业经济》网站(ciejournal.ajcass.com)附件。

PageRank 值计算上市公司 AI 技术水平得分。例如,上市公司申请的专利 A 的 IPC 分类号中出现了 G06N20/00 知识,则该企业的 AI 水平得分增加其对应的加权 PageRank 值,即得分增加 0.028。最后,将上市公司特定年份所有发明专利的 AI 相关技术得分进行汇总,得到其相关年份的 AI 技术水平。进一步地,本文依据 Jaccard 相似度对 AI 技术网络进行四类聚类划分,并分别计算每个聚类中企业的 AI 得分,从而实现企业 AI 技术水平的分层测度。在处理时,综合考虑三个方面:①知识时效性。AI 技术迭代快,旧知识价值随时间降低,衰减前一年得分能突出当年新获取知识的重要性。②知识存续性。企业过往积累的 AI 知识仍有价值,保留前一年得分一定比例可体现技术发展连贯性。③平滑数据波动。企业 AI 技术发展受多种因素影响易产生数据波动,此种处理能减少偶然因素干扰,使测度结果更稳定可靠。因而,在处理时将前一年得分经衰减 30% 处理后加上当年的得分值,得到企业当年 AI 技术水平。

2. 中国制造业上市公司 AI 技术水平分层测度结果

为了将 AI 技术聚类的结果与企业 AI 技术水平相连接,本文进一步将四类 AI 聚类依次映射至企业层面,构建反映企业 AI 技术水平与结构的分层测度体系,系统揭示中国制造业上市公司 AI 技术水平与结构的分布特征与动态演进路径。

(1) 中国制造业上市公司 AI 技术水平的分布特征。AI 四个聚类维度在中国制造业上市公司层面的分布均符合典型的幂律特征:大多数企业聚类得分较低,仅少数企业得分显著偏高。这意味着 AI 技术在企业间存在明显的差异性,且具有技术回报递增特性。其中,应用 AI 聚类的两个子图曲线头部下降趋势平缓,说明这两类以应用为导向的 AI 技术在企业间的扩散相对广泛,具备一定程度的共享性和可复制性,企业间的技术能力差距不显著。相比之下,通用 AI 聚类子图的曲线头部明显更加陡峭,说明通用 AI 技术具有更强的技术门槛与集中性。

(2) 中国制造业上市公司 AI 技术水平的行业特征。本文按照《上市公司行业分类指引》中的行业代码对企业进行分类,然后计算每个行业在四个聚类维度的平均得分,并根据得分在全行业进行百分位排名。其中,专用设备制造业在行业应用型技术聚类排名第一,这与该行业本身面向不同工业场景进行设备定制的特征密切相关,体现出其对行业特定 AI 技术的高度依赖。家具制造业因个性化需求,在行业应用型技术聚类中同样表现突出。汽车制造业和黑色金属冶炼与压延加工业则在底层算法聚类表现突出,说明这类行业在工艺优化、智能控制与参数调整等方面更依赖于算法优化,而对感知类技术的依赖相对较弱。相比之下,电气机械与电子设备制造业则在感知类技术聚类中具有显著优势,说明其产品更强调音频、视觉识别等功能的集成。汽车制造业在四个聚类维度中的排名均较为靠前,反映出该行业对 AI 的整体吸收能力和高度融合趋势。而计算机、通信和电子设备制造业在全部聚类维度中均排名第一,体现出其作为天然的 AI 强相关行业,既是 AI 底层算法的研发者,又是平台型技术的提供者。

(3) 中国制造业上市公司 AI 技术部署的动态特征。AI 技术部署的动态过程同样值得关注,为此,图 2 进一步描绘了不同聚类维度 AI 技术的年度占比变化,以刻画制造业企业在 AI 战略重心上的结构性调整。行业应用型技术与感知类技术的占比基本平稳,而底层算法在 2016 年进入拐点之后,占比逐年上升,同时平台型技术占比逐年下降。这一现象说明,平台型技术早期是 AI 技术进入制造业的主要载体,但随着 AI 整体技术的成熟与通用 AI 技术的不断涌现,企业对平台型 AI 技术的依赖程度降低,更倾向于在平台型技术的基础上进一步发展底层算法能力。这一趋势揭示出企业 AI 技术能力由中间环节的技术整合向底层算法研发的结构演化,表明企业 AI 战略正从系统整合走向底层模型创新。这一结构性演化不仅拓展了企业 AI 技术的创新边界,也意味着中国制造业正逐步迈入以底层算法创新为核心驱动力的强 AI 时代。




图2 中国制造业上市公司不同聚类AI技术占比变化趋势

五、人工智能影响企业创新的路径

在AI推动的知识组合式创新模式下,知识创新被视为知识的组合进化。AI通过提升知识搜寻的广度与深度,加速了知识潜在组合的识别与重构过程,从而有效推动知识组合式创新的发生与演化。

1. 知识组合式创新

Agrawal et al. (2018)构建了AI时代知识的组合创新理论及组合式知识生产函数:创新并非从现有知识中发现新知识的线性过程,而是来源于从知识的潜在组合中发现新知识组合的非线性过程。知识组合创新模型中的决定性参数暗含了AI对创新的影响路径,但Agrawal et al.(2018)并未明确定义这些参数,且仅通过数值模拟方法进行分析。本文对Agrawal et al. (2018)组合创新理论进行扩展,将其决定性参数经济含义明确定义为知识搜寻广度与知识搜寻深度,并对其进行定量实证。知识组合创新理论的基本假定是:现有知识可以无限分割成独立的单元。假设现有知识有 A 个,创新主体可获得的知识为 A^φ ,其中, $0 < \varphi < 1$ 。本文将参数 φ 定义为知识的搜寻广度,即研究者从现有知识库中获取知识的范围和效率。已有知识的潜在组合数量 $g(A^\varphi)$ 的表达式为:

$$g(A^\varphi) = \sum_{a=0}^{A^\varphi} \binom{A^\varphi}{a} - A^\varphi - 1 = 2^{A^\varphi} - A^\varphi - 1 \quad (3)$$

假定 t 时期新知识的发现函数 $\dot{A}(t)$ 为知识潜在组合的不变弹性函数:

$$\dot{A}(t) = \beta \left[\frac{g(A(t)^\varphi)^\theta - 1}{\theta} \right] = \beta \left[\frac{(2^{A(t)^\varphi} - A(t)^\varphi - 1)^\theta - 1}{\theta} \right] \quad (4)$$

其中,参数 $\beta(>0)$ 表示知识组合效率系数;弹性系数 θ 满足 $0 < \theta < 1$,本文将其定义为知识的搜寻深度,即研究者如何深入挖掘已有知识潜在组合的能力。深度搜寻能力越强,企业越容易从已有知识组合中迸发出新知识组合灵感。

在此基础上,本文考虑AI技术对企业新知识发现效率的非线性影响,将参数 φ 和 θ 均设定为AI的隐函数,即 $\varphi = \varphi(AI(t))$, $\theta = \theta(AI(t))$ 。这意味着AI技术能够动态地影响企业知识搜寻的广度和深度。在此基础上定义新知识的发现效率 $\gamma_A(t)$ 的表达式为:

$$\gamma_A(t) = \frac{\dot{A}(t)}{A(t)} = \frac{\beta}{A(t)} \left[\frac{g\left(A(t)^{\varphi(AI(t))}\right)^{\theta(AI(t))} - 1}{\theta(AI(t))} \right] \quad (5)$$

AI影响新知识发现效率 $\gamma_A(t)$ 的传导路径遵循如下链式法则:

$$\frac{\partial \gamma_A(t)}{\partial AI(t)} = \frac{\partial \gamma_A(t)}{\partial \varphi} \cdot \frac{\partial \varphi(AI(t))}{\partial AI(t)} + \frac{\partial \gamma_A(t)}{\partial \theta} \cdot \frac{\partial \theta(AI(t))}{\partial AI(t)} \quad (6)$$

其中, $\frac{\partial \varphi}{\partial AI(t)}$ 表示AI对知识获取范围,即知识搜寻广度的影响; $\frac{\partial \theta}{\partial AI(t)}$ 表示AI对现有知识组合的深入挖掘能力,即知识搜寻深度的影响。将式(4)、式(5)代入式(6)可以得到:

$$\begin{aligned} \frac{\partial \gamma_A(t)}{\partial AI(t)} &= \frac{\beta}{A(t)} \cdot \left(2^{A(t)^{\varphi}} - A(t)^{\varphi} - 1\right)^{\theta-1} \cdot A(t)^{\varphi} \ln A(t) (\ln 2 \cdot 2^{A(t)^{\varphi}} - 1) \frac{\partial \varphi(AI(t))}{\partial AI(t)} + \\ &\quad \frac{\beta}{A(t)\theta^2} \cdot \left[\left(2^{A(t)^{\varphi}} - A(t)^{\varphi} - 1\right)^{\theta} (\theta \ln(2^{A(t)^{\varphi}} - A(t)^{\varphi} - 1) - 1) + 1\right] \frac{\partial \theta(AI(t))}{\partial AI(t)} \end{aligned} \quad (7)$$

现实中,知识单元数量较大。因此,当条件 $\frac{\partial \varphi(AI(t))}{\partial AI(t)} > 0$ 且 $\frac{\partial \theta(AI(t))}{\partial AI(t)} > 0$ 满足时, $\frac{\partial \gamma_A(t)}{\partial AI(t)} > 0$ 始终

成立。这表明,通过知识搜寻广度和深度这两条路径,AI技术在知识创新过程中起到了双重促进作用:一方面,知识搜寻范围和覆盖领域的增加,拓展了创新主体在技术空间中的搜索半径,增强了其在多领域中识别潜在组合的能力;另一方面,对知识深度挖掘能力的增加,有助于识别潜藏于复杂知识组合中的潜在关联,从而激发新的知识组合与创新。

2. AI对企业创新的影响路径:知识搜寻广度路径与知识搜寻深度路径

(1) AI以平台型技术形态集成于企业技术创新活动中,显著增加了知识搜寻的广度。①AI的大规模数据处理与自动化学习能力,改变了传统技术搜索与人工搜索的局限性。AI技术能够自动化地从行业报告、研究文献等文本中提取有价值的知识。同时,快速提取相关信息并发现技术间的关联,从不同领域的技术中找到潜在的交叉点(Righi et al., 2020),这使得企业能够在广泛的技术空间内进行高效搜索和发现创新点。②AI能够将全球范围的技术知识进行整合,提升跨国、跨行业的知识搜寻能力。通过大数据分析、自然语言处理和推荐系统,AI能够从不同国家、地区和行业的技术文献、专利信息、市场趋势等多来源数据中提取并融合有价值的信息。在制造业上市公司中,这一技术使得企业能够捕捉到全球技术发展动向,拓展其技术搜索的视野。③AI能够利用自动化的数据抓取与实时分析技术,监测并捕捉最新的技术进展、科研发现以及行业变化。此种技术让制造业上市公司能够在快速变化的市场环境中保持技术发展的敏捷性。

(2) AI主要通过底层算法的不断优化增加知识搜寻的深度。①AI利用深度学习技术,增加了知识搜寻的深度。通过自然语言处理和神经网络等技术结合,AI可以从复杂的专利文献、科研论文和技术报告中提取更加细致和深刻的信息。同时,AI能够通过不断学习和自我优化帮助制造业上市公司深入挖掘技术文献中的复杂信息和隐藏的创新路径。②AI通过智能体的强化学习技术,提升了知识搜寻的精准度与深度。传统搜索方法可能局限于关键词匹配,无法深入挖掘文本的潜在信息。而AI的强化学习能力能够探索真实世界(罗素和诺维格, 2023),并处理文本中的隐含信息,深入分析技术文献中的概念、趋势和应用场景,为制造业上市公司提供更加精准的技术搜索,推动制造业上市公司对技术创新的深入洞察与反馈,从而促进技术深度发展。AI对企业创新的具体传导机制见图3。




图3 人工智能影响企业创新的传导机制

六、中国制造业上市公司 AI 技术创新效应的实证检验

1. 研究设计

(1)被解释变量:企业的创新水平(*Innovation*),采用企业当年申请的发明专利数量作为衡量指标。其中,包括独立申请的发明专利数量和联合申请的发明专利数量,两者之和用于全面反映企业的整体创新能力。具体而言,独立申请的发明专利数量反映了企业自主创新的能力,而联合申请的发明专利数量则体现了企业与外部合作的创新水平。因此,本文的创新水平变量定义为上述两个指标的总和。这一指标能够较为全面地衡量企业在不同创新模式下的综合表现。

(2)核心解释变量:企业 AI 技术水平(*AI*)。由前文计算得到。

(3)控制变量。资产负债率(*Asset-Liability Ratio*),以负债合计与资产总计之比表示;无形资产比率(*Intangible Asset Ratio*),以无形资产净额与资产总计之比表示;总资产净利润率(*Return on Assets, ROA*),计算方法为净利润与总资产平均余额之比,其中,总资产平均余额为资产合计期末余额与资产合计期初余额的平均值;企业规模(*Company Size*),用总资产的自然对数表示;流动比率(*Current Ratio*),计算方法为流动资产与流动负债之比;企业年龄(*Enterprise Age*),衡量方法为统计截止日期所在年度与公司成立年度的差值;研发强度(*R&D Intensity*),即研发投入占营业收入的比例,用于衡量企业在创新方面的资金投入强度;主营收入增长率(*Revenue Growth Rate*),用主营业务收入变化量与上年主营业务收入之比衡量,反映企业主营业务收入的增长水平。

(4)计量模型设定。本文采用中国制造业上市公司面板数据,研究 AI 技术应用对企业创新的影响。本文选择固定效应模型进行回归,计量方程设定如下:

$$\ln_Innov_{i,t} = \beta_0 + \beta_1 \ln_AI_{i,t} + \beta X + \gamma_i + \delta_t + \varepsilon_{i,t} \tag{8}$$

其中, $\ln_AI$ 表示上市公司 AI 技术水平的自然对数。 $\ln_Innov$ 表示上市公司创新水平的自然对数。下标 i, t 分别代表企业和年份。向量 X 是控制变量。 γ_i 和 δ_t 分别代表企业固定效应和年份固定效应。 $\varepsilon_{i,t}$ 为随机扰动项,标准误聚类到行业—年份层面。

(5)数据来源。选取中国证券监督管理委员会 2012 年分类为制造业的非 ST 上市公司作为研究对象,样本时间为 2014—2024 年。专利数据信息来源于 Incopat 数据库,企业基本信息和财务信息数据来源于 CSMAR 和 CNRDS 数据库。

2. 基准回归结果

表 2 汇报了基准回归结果。第(1)列未加入任何控制变量和固定效应,结果显示,企业 AI 技术水平每提高 1%,创新水平提升 2.63%。在第(2)列中引入控制变量后,AI 对创新指数的影响系数略有下降。第(3)、(4)列分别加入年份和企业固定效应,系数仍然在 1% 水平下显著为正。综合考虑固定效应和控制变量后,企业 AI 技术水平每提高 1%,创新水平提高 0.65%。

表 2 基准回归结果

变量	(1)	(2)	(3)	(4)
	<i>ln_Innov</i>	<i>ln_Innov</i>	<i>ln_Innov</i>	<i>ln_Innov</i>
<i>ln_AI</i>	2.6339*** (0.2316)	1.9666*** (0.1679)	1.9731*** (0.1662)	0.6529*** (0.1073)
控制变量	否	是	是	是
年份固定效应	否	否	是	是
企业固定效应	否	否	否	是
N	15000	10693	10693	10603
R ² _adjusted	0.1168	0.2392	0.2483	0.7471

注:***、**和*分别表示 1%、5% 和 10% 的显著性水平,括号内的数值为聚类到行业一年份层面的标准误,以下各表同。

3. 不同 AI 技术对企业创新的影响

根据前文分析,按照 Jaccard 相似度矩阵和 Ward 方差最小化方法,将人工智能技术分为四个聚类:底层算法、感知类技术、平台型技术、行业应用型技术。分组回归结果表明^①:除第一个聚类代表的行业应用型技术之外,其余各聚类 AI 技术均显著促进了企业创新水平。同时,基于底层算法的 AI 技术对于创新的表现不如感知类技术和平台型技术。可能的解释是:AI 行业应用型技术主要被企业用于直接创造经济利润,对创新的促进作用较为间接。并且,人工智能主要用于常规决策和模仿性决策(Felin and Holweg, 2024),因而 AI 技术最广泛应用的医疗系统中,其替代人类判断更加困难。

4. 内生性处理

(1) 遗漏变量偏误检验。影响企业创新的因素复杂多样,可能导致遗漏变量引起的内生性问题。为评估这一问题,本文对遗漏变量偏误进行了检验,并据此推断遗漏变量可能在多大程度上对基准结果产生影响。利用有限观测变量与不可观测变量的偏误程度,通过控制有限观测变量的集合,计算解释变量系数的差异比率,以此评估遗漏变量对基准结果产生偏误的可能性。^②

根据检验结果,当不引入任何控制变量和固定效应时,差异比率为 0.33,反映了遗漏变量带来的偏误较大,这在一定程度上表明仅依赖于未经调整的模型可能导致基准估计的偏误;进一步发现,当引入企业和年份固定效应时,差异比率增加至 11.53,说明固定效应的纳入能够显著降低遗漏变量的影响;当进一步加入控制变量并结合企业固定效应时,差异比率达到 18.83,综合表明遗漏不可观测变量造成估计结果偏误的可能性较小。

① 回归结果参见《中国工业经济》网站(ciejournal.ajcass.com)附件。

② 检验结果参见《中国工业经济》网站(ciejournal.ajcass.com)附件。

(2)样本选择偏误处理。企业AI技术水平可能受到企业规模、行业特性、地区经济发展水平等因素影响。因此,本文用倾向得分匹配(PSM)方法来处理选择性偏误问题。根据AI技术得分计算结果是否为正,将企业分为对照组和处理组。本文通过倾向得分执行1:1最近邻匹配,卡尺宽度设定为0.01,限制匹配对的倾向得分差异不超过该阈值,以确保匹配质量。在样本匹配完成后,大部分协变量的标准化偏误均小于5%。匹配后样本的检验结果如表3第(1)列所示, $\ln_AI$ 的回归系数仍然在1%水平下显著为正,说明本文研究结果稳健。

(3)反向因果问题处理。创新水平较高的企业通常掌握更多的知识单元,从而也更可能具备较强的AI技术能力。因此,表3第(2)一(5)列使用Shift-share工具变量方法,以缓解估计中可能存在的反向因果问题。Shift-share方法结合了AI技术的初始份额与行业冲击的交乘项,构造具有外生性的工具变量。本文选取上市公司初始年份的AI技术得分作为初始份额变量,并以每年所有上市公司AI关联技术(仅IPC小类相同)得分的平均增长率作为行业层面的外生冲击。AI的关联知识与特定AI知识在专利中经常共同出现,因此,可以侧面反映企业对AI相关知识的掌握程度,满足工具变量所需的相关性假设。并且,这些关联知识多属于外观、硬件等辅助性内容,通常构成专利中的非核心部分,具有较强的偶发性与个体差异性,不易持续稳定地影响企业的创新行为。同时,本文采用的是该类知识在全体行业层面的增长率作为工具变量,而非企业自身的具体技术指标,进一步弱化了其与被解释变量之间可能存在的直接联系,从而较好地满足排他性假设。

表3第(2)、(3)列使用2014年数据作为初始份额构建的工具变量进行两阶段最小二乘法(2SLS)估计,其中,第一阶段的Kleibergen-Paap rk LM统计量和rk Wald F值分别为8.499和19.863,表明工具变量具备一定识别力。本文采用对异方差稳健的Kleibergen-Paap rk Wald F统计量,替代传统的Cragg-Donald F值,更适用于聚类稳健标准误下的识别检验。第(3)列显示,工具变量的估计系数为正,在10%水平边缘显著。考虑到2014年数据中存在较多初始份额为零的情况,而2015

表3 内生性检验

变量	(1)	(2)	(3)	(4)	(5)	(6)
	$\ln_Innov$	$\ln_AI$	$\ln_Innov$	$\ln_AI$	$\ln_Innov$	$\ln_Innov$
$\ln_AI$	0.4576*** (0.0659)		0.3648* (0.2171)		0.6013*** (0.1962)	1.5984*** (0.1293)
$IV1$		2.8185*** (0.6324)				
$IV2$				2.8794*** (0.4148)		
Kleibergen-Paap rk LM		8.499***		10.051***		12.597***
Kleibergen-Paap rk Wald F		19.863		48.194		91.675
控制变量	是	是	是	是	是	是
年份固定效应	是	是	是	是	是	是
企业固定效应	是	是	是	是	是	是
N	4824	10608	10602	9944	9938	10027
$R^2_adjusted$	0.7925	0.8444		0.8950		

年的数据质量相对更加良好,并且也能说明初始份额,因此,本文在第(4)、(5)列进一步使用2015年数据重新构造工具变量。相应的识别检验结果进一步增强,第一阶段rk LM统计量和rk Wald F值分别上升至10.051和48.194。第(5)列的估计系数为正,且在1%水平上显著,表明2015年数据作为初始份额识别力更强、估计更为稳健。为进一步提高估计效率与稳健性,表3第(6)列基于IV2采用两阶段广义矩估计法(GMM),其在存在异方差背景下更具估计效率。GMM结果显示,AI水平的估计系数依旧显著为正,且均通过可识别和相关性检验。

5. 稳健性检验^①

为进一步保证结论的可靠性,本文还从替换核心解释变量、替换被解释变量以及考虑前置效应等三个方面,进行稳健性检验。

(1)替换核心解释变量。首先使用与AI紧密关联的技术指标,即IPC分类号中的小类计算上市公司AI技术水平,以替换基准回归中的AI变量。结果显示,以IPC小类测算的企业AI技术显著提高了其创新水平。进一步,提取IPC号的大组信息代替小组信息计算相关企业AI技术水平,结果依旧稳健。

(2)替换被解释变量。将被解释变量替换为企业独立申请的发明专利($\ln_Indep$),独立申请的发明专利反映了企业自主创新和自主研发的能力。估计结果表明,系数仍然在1%水平上显著为正,这进一步证实了AI技术促进企业自主创新的关键作用。

(3)专利技术的前置性。由于企业在专利申请或授权之前就已经掌握了相关技术,因此,与滞后效应的处理不同,本文对被解释变量滞后一期,使用滞后一期的创新指数(L_ln_Innov)进行回归。这一分析考虑了企业掌握技术到形成可申请专利的时间延迟,结果依旧稳健。

七、中国制造业上市公司AI技术影响企业创新的作用机制检验

本文基于组合式知识创新理论,将企业的知识搜寻能力区分为广度与深度两个维度:广度侧重于企业在更大范围内识别、吸收异质知识的能力;深度则强调在既有知识结构基础上进行精细化理解与再组合的能力。通过知识搜寻广度与深度两个维度,进一步揭示人工智能技术对企业创新行为的具体影响路径。为此,本文构建以下模型对作用机制进行检验:

$$\ln_Knowledge_{i,t} = \beta_2 + \beta_3 \ln_AI_{i,t} + \beta X + \gamma_i + \delta_t + \varepsilon_{i,t} \quad (9)$$

其中, $\ln_Knowledge$ 为机制变量的自然对数,其他设定与基准回归(8)式一致。

1. 作用机制检验 I: 知识搜寻广度

本文用专利的平均IPC广度作为知识搜寻广度变量。IPC广度不仅体现企业是否涉足多个技术领域,更反映其在复杂异质性知识空间进行系统性探索与组合的潜力。企业若在技术发现过程中展现出更高的多样性,其专利组合在构建创新拼图时拥有更多单元,则有助于发现跨域连接点,推动组合式创新。

为量化企业的专利平均IPC广度,本文引入信息论中的香农熵(Shannon Entropy)指标。熵值常用来评估企业所拥有专利中IPC分类号的多样性与均匀性。Kim et al.(2016)基于熵值方法构建了总技术多元化(TTD)、相关多元化(RTD)与非相关多元化(UTD)等指标体系,用以描述企业专利技术结构的多样性特征,徐欣等(2019)在此基础上进一步发展了用于刻画创新突破性的指标体系。

^① 稳健性检验结果参见《中国工业经济》网站(ciejournal.ajcass.com)附件。

与 Kim et al.(2016)侧重于 IPC 小类的做法不同,本文在测度企业知识搜寻广度时,采用完整的 IPC 分类号(包括大组/小组),以获得更细粒度的技术识别结果,从而更精准地刻画企业在 AI 知识系统中的搜寻能力。

香农熵具体的计算公式为:

$$H(X)=-\sum_{i=1}^n p(i)\ln p(i) \tag{10}$$

其中, $H(X)$ 表示 IPC 分类号的香农熵, $p(i)$ 是第 i 类 IPC 分类号出现的频率, n 代表 IPC 分类号的总数。香农熵反映了企业知识与技术的多样性,因此,可以表示企业知识搜寻广度。熵值越高,表明企业在技术搜索中覆盖的领域越广,具有的知识组合能力更强。

回归结果见表 4。首先考察 AI 总体技术水平对企业知识搜寻广度的影响,如第(1)列所示, $\ln_AI$ 的回归系数为正,表明 AI 总体技术水平显著促进了企业知识搜寻广度。该结果初步印证了 AI 技术能够增强企业链接多元知识来源、拓宽知识边界的能力。

进一步地,本文将 AI 技术的平台型、底层算法与感知类三类技术,分别纳入模型进行机制拆分析。如表 4 第(2)—(4)列所示,三类 AI 技术对知识搜寻广度的影响均为正且显著,表明其均能在一定程度上提升企业知识搜寻广度。其中,平台型 AI 技术的系数最大,感知类技术次之,底层算法相对较小。这说明虽然三类 AI 技术均有积极作用,但其影响程度存在明显差异。

表 4 作用机制检验 I:知识搜寻广度

变量	(1)	(2)	(3)	(4)	(5)
	$\ln_Kscope$	$\ln_Kscope$	$\ln_Kscope$	$\ln_Kscope$	$\ln_Kscope$
$\ln_AI$	0.1691*** (0.0272)				
Platform		0.2716*** (0.0547)			0.2094*** (0.0522)
Algorithm			0.1392*** (0.0278)		0.0619* (0.0337)
Perception				0.2589*** (0.0522)	-0.1093 (0.0671)
控制变量	是	是	是	是	是
年份固定效应	是	是	是	是	是
企业固定效应	是	是	是	是	是
N	10609	10609	10609	10609	10609
R ² _adjusted	0.5961	0.5959	0.5958	0.5955	0.5958

随后,本文将三类 AI 技术同时纳入统一模型以检验其相对边际效应。在将三类 AI 技术同时纳入统一模型之前,本文对模型中主要解释变量之间的多重共线性问题进行了检验。采用方差膨胀因子(Variance Inflation Factor, VIF)作为衡量标准,结果显示,所有解释变量的 VIF 值均小于 5,低于规定临界值表明不存在显著多重共线性问题,模型设定较为稳健。回归结果见表 4 第(5)列,平台型技术依然保持显著正向影响,且系数在三类中最高;底层算法类技术仍显著,但影

响边际下降;感知类技术不显著,说明在控制其他技术路径影响后,其对知识搜寻广度的边际贡献被弱化。表4结果系统揭示了AI技术在扩展知识搜寻广度方面的总体正向作用及其分层机制,特别是平台型AI技术通过增强技术链接能力与资源整合能力,成为企业提升知识搜寻广度的关键驱动力。

2.作用机制检验 II:知识搜寻深度

本文用专利的平均IPC深度测算知识搜寻深度。该指标用于衡量企业专利中所涉及技术分类的细化程度,反映其在特定技术领域内的专业化探索水平。在组合式知识创新理论视角下,企业技术创新不仅依赖于广泛的知识搜寻能力,还依赖于对现有技术路径的深入掌握与系统重构,知识搜寻深度更强调在已有知识结构中的纵向延伸与专业化重组能力。IPC分类体系本身具有层级结构,其深度反映了技术标注的精细化程度。较深的IPC分类代表企业聚焦更具体的技术环节,表明其在某一领域内开展了更系统、深入的知识钻研。

本文依据专利IPC分类号的层级结构构建IPC深度指标。如果专利的IPC信息统计到小类,即IPC只精确到4位,IPC深度记为1;如果统计到大组,深度为2;如果IPC包含具体小组信息,深度为3;如果包含进一步细分小组的信息,则深度为4。例如,如果A专利中的IPC号仅出现C09D11/00时,根据其只精确到大组信息,则认为该专利的IPC深度为2;如果B专利中的IPC号同时包含了C09D11/03和C09D11/037,则认为其IPC深度同时出现了3和4,平均IPC深度为3.5。通过计算企业所有发明专利的平均IPC深度,识别其在既有知识系统中深化理解与重构创新的总体水平。

知识搜寻深度的机制检验结果见表5。如第(1)列所示,AI总体技术水平对知识搜寻深度的回归系数为正且显著,表明AI技术不仅拓展了企业的知识边界,也加深了其在关键技术领域的专业积累,增强了对复杂知识的深度整合能力。为进一步识别不同类型AI技术的具体作用路径,本文将平台型、底层算法类与感知类AI技术分别纳入模型。第(2)―(4)列显示,三类AI技术在单独纳入时均对知识搜寻深度产生显著正向影响,说明它们均有助于推动企业在特定知识结构中的深入探索与专业深化。

表 5 作用机制检验 II:知识搜寻深度

变量	(1)	(2)	(3)	(4)	(5)
	<i>ln_Kdepth</i>	<i>ln_Kdepth</i>	<i>ln_Kdepth</i>	<i>ln_Kdepth</i>	<i>ln_Kdepth</i>
<i>ln_AI</i>	0.0795*** (0.0195)				
<i>Platform</i>		0.0859** (0.0338)			-0.0453 (0.0386)
<i>Algorithm</i>			0.0802*** (0.0220)		0.1030*** (0.0302)
<i>Perception</i>				0.1765*** (0.0373)	-0.0220 (0.0545)
控制变量	是	是	是	是	是
年份固定效应	是	是	是	是	是
企业固定效应	是	是	是	是	是
N	10609	10609	10609	10609	10609
R ² _adjusted	0.4066	0.4065	0.4066	0.4065	0.4064

进一步,如表5第(5)列所示,当三类AI技术同时纳入统一模型后,仅底层算法类技术的回归系数仍为正且在1%水平上显著,而平台型和感知类技术的影响不再显著。这表明,在控制其他路径影响后,底层算法是推动企业加深技术专精、提升知识搜寻深度的主要驱动力。相较于平台型技术对广度的主导作用,底层算法类技术在深化企业知识能力方面发挥了关键作用,体现了AI不同技术在赋能企业多维度知识搜寻能力方面的功能异质性。

3.AI对不同行业创新的异质性影响^①

将企业按照行业性质分为以下五类:医药与化学、交通与汽车、信息与通信、金属制品、消费品与其他传统制造业。实证结果表明,除了金属相关制造业不显著之外,其他分类的回归结果均说明了AI技术对创新的正向影响。其中,AI在医药与化学领域的创新作用最为明显。可能的解释是,金属行业的创新模式主要依赖材料工程和工艺改进,同时由于生产流程较为成熟,因此,AI的应用更多体现在生产效率的优化而非知识的创新上。医药与化学行业本质上属于人工智能密集型行业,其智能药物研发及生物技术的创新对AI技术高度依赖。相比之下,高度数字化的信息与通信行业,AI技术已内嵌于行业自身,其创新的影响难以分离,故而影响相对较弱。

在消费品和传统制造业领域内,AI技术对创新仍有较强的促进作用。本文认为其主要原因有二:一是个性化需求推动了AI技术在消费品领域的创新应用,AI在市场洞察、消费者偏好分析和智能推荐方面发挥了关键作用;二是AI技术进一步模糊了生产者与消费者之间的界限,促进了用户深度参与产品设计和制造环节,推动传统消费品制造业的智能化升级,真正推动了生产者与消费者合一(安同良和魏婕,2023)。

八、结论与启示

AI作为通用技术,在全球知识网络中通过分布式主体的互动学习与演化,加速了知识边界的扩展与全球创新生态系统的重构,并成为互联式创新的核心力量。西方主流新古典经济学将AI技术仅当作一种要素投入,难以展现其知识构成的复杂性与发展的可赶超性。为此,本文基于复杂经济学视域,将AI技术凝练为嵌套知识系统,并通过知识的加权共现网络及节点的加权PageRank值将其分层可视化。在此基础上,结合知识节点聚类方法与企业知识结构耦合性识别方法,本文提出了以中国制造业上市公司为主体的AI技术水平的分层测度方法,并进行了实证观测。本文揭示了AI通过知识搜寻的深度与广度对企业创新的传导路径与机制,并将AI促进创新的机制转化为可度量的知识搜寻过程。基于此,本文既破解了AI技术知识构成的“黑箱”,也破解了AI创新效应的“黑箱”,对企业AI技术的识别与结构性测度作出基础性贡献。

1.研究发现

(1)AI技术是一个嵌套的复杂知识系统,底层的枢纽知识节点对其余知识模块具有显著的源头辐射带动特性。本文通过深入分析知识网络的底部核心层结构,利用Jaccard相似度算法,将AI技术聚类为通用AI与应用AI技术两大社区以及底层算法、感知类技术、平台型技术、行业应用型技术四大聚类。节点的聚类分析表明,通用AI技术相关节点的相似性较强,体现了基础知识的共同性;而应用AI技术相关节点则表现出较强的相似度偏差,体现了跨领域技术的差异性。这种基于

^① 异质性影响检验结果参见《中国工业经济》网站(ciejournal.ajcass.com)附件。

全球知识共现网络的分层测度,能够有效反映企业AI技术知识构成的复杂性与结构特征,更精准地捕捉不同层级的AI技术在企业创新中的真实贡献。

(2)基于AI聚类维度构建的分层测度结果显示,中国制造业上市公司AI技术的四个聚类均存在一定的幂律分布特征。其中,通用AI聚类(底层算法与感知类技术)的企业得分分布呈现出更强的幂律特征,头部企业聚集度高;而应用AI聚类(平台型与行业应用型技术)分布相对平缓,具备更强的可扩散性与共享性。不同行业在AI能力结构上也展现出显著的比较优势:专用设备制造业、家具制造业在行业应用型技术上排名靠前;汽车制造业在四类聚类中均有较强表现;而计算机与电子制造业则在通用AI技术上全面领先,反映了其在AI基础研发上的综合主导地位。从时间维度看,中国制造业企业的AI技术重心由平台型技术向底层算法偏移,表明企业AI战略正从以平台部署为核心转向以底层算法开发为导向的发展路径。

(3)AI技术整体上显著提升了中国制造业上市公司的创新水平,企业AI技术水平每提高1%,企业的创新水平平均提高0.65%。分组分析表明,平台型技术、感知类以及底层算法AI技术对企业创新有明显的正向促进作用,其中,平台型技术和感知类技术对创新的推动效果更为直接和显著,底层算法对创新的推动效果较为间接,而行业应用型技术未表现出显著的创新效应。原因在于,现阶段AI技术多用于常规决策,对涉及复杂、非程序化的决策场景难以有效替代人类。此外,行业异质性分析显示,AI对医药、化学等知识密集型以及传统消费品行业的创新效果较强,对金属制品等传统制造业创新作用不显著。

(4)AI技术主要通过增加企业知识搜寻的广度与深度两条路径来促进企业创新,AI创新效应的“黑箱”真正被破解。所有类型的AI技术均显著提升了知识搜寻广度。其中,平台型技术是提升搜寻广度的主要驱动力,在增强企业技术整合效率与知识网络联通性方面表现最为突出。与此同时,底层算法是促进知识搜寻深度的核心路径。其通过深度学习与强化学习等能力,帮助企业识别嵌套在复杂知识结构中的语义逻辑与潜在关联,从已有技术组合中挖掘新颖的重组路径,推动企业在特定领域内实现深层次的知识理解与突破。相比之下,感知类技术与平台型技术对知识深化的贡献更多依赖于底层算法的支撑。

2. 政策启示

(1)以基础研究突破引领AI技术发展。AI知识网络的结构表明,通用AI枢纽知识节点之间形成高度关联的强耦合核心集群,体现出基础知识的共性与通用性。因此,基础研究突破是支撑AI技术发展的关键举措。从跟跑到并跑领跑、进入科技的“无人区”后,更加需要从基础研究中找到创新方向和出路。正如2025年国务院《政府工作报告》提出的,应推动科技支出向基础研究倾斜,政策上应加大对数学、计算机科学、神经科学等基础领域的资金投入,强化基础研究组织化建设。重点培育一批国家级基础学科研究基地和顶尖青年创新团队,以高质量的基础研究推动AI技术深度演化,确保国家在全球未来人工智能竞争中掌握主动权。

(2)分类引导、优化通用AI与应用AI的创新效应。AI在不同技术类型与不同行业创新效应的差异表明,通用AI的创新活力需要进一步被激发,与其他AI技术融合,从间接推动企业创新转变为直接推动创新。针对当前主要用于创造市场价值的行业应用型AI技术,政策上应引导企业将此类技术应用的重心逐步向知识创造转变,加强此类技术在复杂、非程序化决策场景中的运用。同时,针对企业通用AI技术水平的幂律分布特征,应强化对通用AI技术的研发引导,通过完善算法基础设施、推动模型开源共享,降低企业进入门槛。此外,应鼓励企业立足个性化消费需求和“产销者”模式,推动AI技术在传统消费品行业的广泛应用,鼓励消费者深度参与产品创新设计与制造,助推

传统消费品产业智能化升级,释放更大创新潜力。

(3)以互联式创新生态的培育,助推AI技术的应用和演进。鼓励政府、企业、高校、科研机构及行业联盟等分布式创新主体协同AI创新,推动AI技术在全社会扩散与落地应用,助推AI技术知识搜寻广度与深度的促进效应。例如,阿里云的推理服务,实现了从模型研发到应用落地的全链路覆盖;华为专注于特定领域模型,并提供智能化服务,在通信和智能终端领域展现出AI平台型技术优势。这些企业不仅推动了AI技术的协同创新,也促进了AI知识在分布式主体中的扩散和演进。为此,政策上应进一步推动AI技术共享与开放合作,深化“人工智能+”行动,打造具有国际竞争力的数字产业集群,构建中国主导的全球“AI技术共享平台”,形成更加高效的互联式创新生态。

(4)重构AI技术底层算法,冲破技术先进国家的知识围剿。底层算法是推动中国制造业上市公司知识深度搜寻的主驱动力,同时底层算法在AI技术中的比重正不断上升,而中国制造业企业对底层算法突破的不懈追求正助推着中国迈向强AI时代。强AI技术为中国在未来科技赛道突破技术围堵、实现技术赶超带来了新的希望。Deep Seek-V3通过底层算法的突破,形成了中国自主可控的低成本高性能大模型。其成功不仅展示了AI技术在知识搜寻与组合中的巨大潜力,也为中国企业在迈向强AI时代的技术突破提供了典范,进一步推动了中国在全球AI竞争中的差异化领先地位。2025年初,中国多家实验室集中发布前沿推理模型,显示出中国AI产业在全球范围内的强大竞争力。因此,推动向强AI迈进的使命导向政策与前瞻性布局,可以为中国在强AI新赛道实现全球技术引领提供强大动力。通过AI技术底层算法的重构与优化,实现知识更深层次、更高质量的新组合,中国企业能够占据全球知识网络更多的枢纽节点。政策上应鼓励AI技术向强AI推进,引导AI技术从数据驱动的优化智能向更具类人认知能力的泛化智能加速跃进。

〔参考文献〕

- 〔1〕安同良,魏婕. 中国经济学走向何处:复杂经济学视域的新经济发展重构中国经济学[J]. 中国工业经济,2023,(12): 5-23.
- 〔2〕安同良,魏婕,姜舸. 基于复杂网络的中国企业互联式创新[J]. 中国社会科学,2023,(10):24-43.
- 〔3〕安同良,闻锐. 以互联式创新网络枢纽节点为靶向的中国创新激励政策——基于组合式知识生产函数的探讨[J]. 经济研究,2024,(10):94-112.
- 〔4〕李玉花,林雨昕,李丹丹. AI技术应用如何影响企业创新[J]. 中国工业经济,2024,(10):155-173.
- 〔5〕〔美〕雷·库兹韦尔. 奇点更近[M]. 芦义译. 北京:中国财政经济出版社,2024.
- 〔6〕〔美〕斯图尔特·罗素,〔美〕彼得·诺维格. 人工智能:现代方法[M]. 张志华等译. 北京:人民邮电出版社,2023.
- 〔7〕徐欣,郑国坚,张腾涛. 研发联盟与中国企业创新[J]. 管理科学学报,2019,(11):33-53.
- 〔8〕姚加权,张锟澎,郭李鹏,冯绪. AI如何提升企业生产效率? ——基于劳动力技能结构调整的视角[J]. 管理世界,2024,(2):101-116.
- 〔9〕〔以〕尤瓦尔·赫拉利. 智人之上:从石器时代到AI时代的信息网络简史[M]. 林俊宏译. 北京:中信出版集团,2024.
- 〔10〕〔英〕罗杰·彭罗斯,〔美〕艾伯纳·西蒙尼,〔英〕南希·卡特莱特,〔英〕史蒂芬·霍金. 宇宙、量子 and 人类心灵[M]. 阳曦译. 上海:东方出版中心,2023.
- 〔11〕Acemoglu, D., and P. Restrepo. Artificial Intelligence, Automation, and Work [A]. Economics of Artificial Intelligence: An Agenda[C]. Chicago: University of Chicago Press, 2018.
- 〔12〕Agrawal, A., J. S. Gans, and A. Goldfarb. Prediction Machines: The Simple Economics of Artificial Intelligence[M].

- Boston: Harvard Business Review Press, 2018.
- [13] An, H. J., and S. J. Ahn. Emerging Technologies—Beyond the Chasm: Assessing Technological Forecasting and Its Implication for Innovation Management in Korea[J]. *Technological Forecasting and Social Change*, 2016, 102:132–142.
- [14] Anderson, P. W. Science: A ‘Dappled World’ or a ‘Seamless Web’ [J]. *Studies in the History and Philosophy of Modern Physics*, 2001, 32(3): 487–94.
- [15] Arthur, W. B. *The Nature of Technology: What It Is and How It Evolves*[M]. London: Free Press, 2009.
- [16] Avina, J., A. Montoya, and M. Garcia. Balancing Knowledge Breadth and Depth in Innovation Systems: A Cognitive Challenge[J]. *Journal of Knowledge Management*, 2018, 22(4):645–664.
- [17] Babina, T., A. Fedyk, A. He, and J. Hodson. Artificial Intelligence, Firm Growth, and Product Innovation[J]. *Journal of Financial Economics*, 2024, 151:103745.
- [18] Dahlke, J., M. Beck, J. Kinne, D. Lenz, R. Dehghan, M. Wörter, and B. Ebersberger. Epidemic Effects in the Diffusion of Emerging Digital Technologies: Evidence from Artificial Intelligence Adoption[J]. *Research Policy*, 2024, 53(2):104917.
- [19] Felin, T., and M. Holweg. Theory Is All You Need: AI, Human Cognition, and Causal Reasoning[J]. *Strategy Science*, 2024, 9(1):65–79.
- [20] Fujii, H., and S. Managi. Trends and Priority Shifts in Artificial Intelligence Technology Invention: A Global Patent Analysis[J]. *Economic Analysis and Policy*, 2018, 58:60–69.
- [21] Jarrahi, M. H. Artificial Intelligence and the Future of Work: Human–AI Symbiosis in Organizational Decision Making[J]. *Business Horizons*, 2018, 61(4):577–586.
- [22] Kim, J., C. Y. Lee, and Y. Cho. Technological Diversification, Core–Technology Competence, and Firm Growth[J]. *Research Policy*, 2016, 45(1): 113–124.
- [23] Kurzweil, R. *The Singularity Is Near: When Humans Transcend Biology* [M]. New York: Penguin Books, 2005.
- [24] Kuzey, C., A. Uyar, and D. Delen. The Impact of Multinationality on Firm Value: A Comparative Analysis of Machine Learning Techniques[J]. *Decision Support Systems*, 2014, 59:127–142.
- [25] Li, C., Y. Xu, H. Zheng, Z. Wang, H. Han, and L. Zeng. Artificial Intelligence, Resource Reallocation, and Corporate Innovation Efficiency: Evidence from China’s Listed Companies[J]. *Resources Policy*, 2023, 81:103324.
- [26] Mariani, M. M., and S. Nambisan. Innovation Analytics and Digital Innovation Experimentation: The Rise of Research–Driven Online Review Platforms[J]. *Technological Forecasting and Social Change*, 2021, 172:121009.
- [27] Narayanamurti, V., and J. Y. Tsao. *The Genesis of Technoscientific Revolutions: Rethinking the Nature and Nurture of Research*[M]. Cambridge: Harvard University Press, 2021.
- [28] Rammer, C., G. P. Fernández, and D. Czarnitzki. Artificial Intelligence and Industrial Innovation: Evidence from German Firm–Level Data[J]. *Research Policy*, 2022, 51(7):104555.
- [29] Righi, R., S. Samoli, M. López Cobo, M. Vázquez–Prada Baillet, M. Cardona, and G. De Prato. The AI Techno–Economic Complex System: Worldwide Landscape, Thematic Subdomains and Technological Collaborations [J]. *Telecommunications Policy*, 2020, 44(6):101943.
- [30] Simon, H. A. Science Seeks Parsimony, Not Simplicity: Searching for Pattern in Phenomena [A]. Zellner A., Keuzenkamp H.A., and McAleer M. *Simplicity, Inference and Modelling: Keeping It Sophisticatedly Simple* [C]. Cambridge: Cambridge University Press, 2002.
- [31] Simon, H. A. The Architecture of Complexity[J]. *Proceedings of the American Philosophical Society*, 1962, 106(6): 467–482.

Hierarchical Measurement of AI Technology Levels in Enterprises and Their Innovation Effects: From a Perspective of the Global Knowledge Network

AN Tong-liang¹, WU Zhi-ye²

(1. Business School, Nanjing University;

2. School of Economics, Nanjing University)

Abstract: In the era of the Intelligent Internet of Everything (IIoE), artificial intelligence (AI), as a general purpose technology (GPT), is accelerating the formation of global knowledge networks and fostering the emergence of interconnected innovation ecosystems. However, mainstream Western economic theories tend to view AI merely as a production input, failing to fully capture the complexity of its technological knowledge structure and the potential for technological leapfrogging in its development. From the perspective of complexity economics, this paper conceptualizes AI as a nested and complex knowledge system. This paper constructs a global knowledge co-occurrence network in the AI domain and proposes an innovative hierarchical method to measure the AI technology levels of listed manufacturing firms in China. Based on Jaccard similarity, this paper classifies AI technologies into two major communities—General AI and Applied AI, and further clusters them into four groups—foundational algorithms, perception technologies, platform-based technologies, and industry-specific applications.

The analysis of Chinese manufacturing listed companies reveals that General AI exhibits a pronounced power-law distribution, with core technologies shifting from platform-based to foundational algorithm-based. Empirical results show that for every 1% increase in a firm's AI technology level, its innovation output increases by 0.65%. The key mechanism through which AI promotes innovation lies in enhancing both the breadth and depth of firms' knowledge search. Among them, platform-based AI technologies serve as the primary driver for expanding the breadth of knowledge search, while foundational algorithms play a central role in enhancing its depth.

By abstracting AI technology into a nested knowledge system and translating the mechanism by which AI fosters innovation into a measurable knowledge search process, this paper demystifies the black box of AI's technological knowledge composition and that of its innovation effects. Then, this paper evaluates the overall impact of AI on innovation, as well as its heterogeneous effects across sectors. As China advances toward the era of strong AI, mission-oriented policies led by foundational algorithm development will accelerate the transition from data-driven, optimization-based intelligence to more generalized intelligence with human-like cognitive capabilities, facilitating technological leapfrogging in the global AI race. By optimizing foundational AI algorithms to enable deeper knowledge search, Chinese enterprises will be better equipped to identify more critical nodes in global knowledge networks, discover novel combinations of knowledge, and ultimately overcome knowledge blockades.

Keywords: artificial intelligence; complexity economics; listed manufacturing companies; innovation; hierarchical measurement

JEL Classification: O32 L60 O38

[责任编辑:王燕梅]