

# 人工智能技术创新与企业全要素生产率

何小钢 郭晓斌

**摘要:**人工智能技术是培育新质生产力的关键,对于推动企业高质量发展具有重要意义。本文结合人工智能(AI)领域前沿的谷歌公司开发的大语言模型(BERT)模型和专利摘要,较为精准地识别人工智能技术创新,考察了人工智能技术创新对企业全要素生产率的影响。研究发现,企业人工智能技术创新水平提高10%时,其全要素生产率提高约8.2%。机制分析表明,人工智能技术创新通过培育新质生产力,提升企业全要素生产率。异质性分析发现,在知识产权保护体系完善的地区、劳动密集型企业以及技术吸收能力较强的企业中,人工智能技术创新的生产率效应更加明显。此外,不同类型人工智能技术创新对企业全要素生产率的影响存在差异。本文的研究结论为中国制定人工智能技术创新政策和推动企业智能化转型提供了重要参考。

**关键词:**人工智能技术创新 全要素生产率 新质生产力 BERT模型 专利文本

**中图分类号:**F062.5;F272.5

**文献标识码:**A

**文章编号:**1000-7636(2026)03-0144-17

## 一、问题提出与相关研究

当前,中国的人工智能创新水平已跻身世界前列。根据国家工业信息发展研究中心与工业和信息化部电子知识产权中心的数据,截至2021年,中国人工智能技术创新申请量已达到909 401项,位居世界第一。作为引领第四次科技革命的核心驱动力,人工智能正以远超传统技术的速度不断推进创新应用,覆盖广泛领域,并对各行各业产生了深远的影响<sup>[1]</sup>。企业作为重要的微观经济主体,是人工智能技术创新的“主力军”<sup>[2]</sup>。随着越来越多企业投入人工智能技术研发,深入研究人工智能技术创新对企业全要素生产率的影响,将为中国在智能化时代推动经济高质量发展提供重要的政策参考。

近年来,越来越多的学者开始关注人工智能技术对企业的影响。大多数文献探讨了人工智能技术对企业人力资本结构升级<sup>[3]</sup>、创新<sup>[4]</sup>、韧性<sup>[5]</sup>以及绿色转型<sup>[6]</sup>等影响。也有少部分文献关注人工智能技术对企业全要素生产率的影响。一些研究认为,人工智能技术能够提升企业生产率<sup>[7-8]</sup>。然而,也有学者指出,数字经济时代可能仍面临“索洛悖论”的挑战<sup>[9-10]</sup>,导致人工智能技术在初期对生产率的提升效果有限。这主

收稿日期:2025-07-21;修回日期:2026-02-01

基金项目:国家社会科学基金重大项目“人工智能对劳动力市场结构性变迁的影响趋势及政策应对研究”(25&ZD148);国家社会科学基金重点项目“人工智能对制造业转型升级的影响研究”(23AZD085);国家自然科学基金面上项目“机器人应用的就业极化与收入极化效应研究:理论机制、实证识别与政策设计”(72373057)

作者简介:何小钢 江西财经大学数字经济学院教授、博士生导师,南昌,330013;

郭晓斌 江西财经大学数字经济学院博士研究生。

作者感谢匿名审稿人的评审意见。

要是因为人工智能技术在研发和创新阶段需要大量投入,而这些投入在短期内难以转化为显著的经济收益<sup>[11]</sup>。

虽然现有文献对人工智能技术的经济效应做了一些探索性研究,但仍存在不足。第一,尚未建立一个统一的框架来研究人工智能技术如何赋能企业全要素生产率。新质生产力是由技术革命性突破、生产要素创新性配置和产业深度转型升级而催生的先进生产力,它以劳动者、劳动资料、劳动对象及其优化组合的质变为基本内涵,是推动全要素生产率的内在要求和重要着力点。然而,现有研究较少从新质生产力的视角深入探讨人工智能技术在促进企业全要素生产率中的作用。第二,现有研究多集中于人工智能技术的应用与引进,而对其技术创新关注较少。大多数研究基于企业年报来刻画企业的人工智能技术的应用情况,但这在概念上与创新截然不同<sup>[12]</sup>。也有一些研究采用词典法识别人工智能技术创新<sup>[13-14]</sup>,但此方法存在两方面局限:一是词典中的人工智能关键词不够全面,导致一些真实的人工智能技术创新未被识别;二是语义处理能力上存在不足,难以捕捉上下文信息,易出现术语切分不准或语义理解偏误,进而将非人工智能技术创新错误识别为相关创新活动<sup>[15]</sup>。因此,学术界亟须构建更精准的人工智能技术创新指标,以开展实证研究,特别是探讨人工智能技术创新对企业全要素生产率的影响。这样才能廓清迷雾、减少分歧,进而为当前中国企业在智能化过程中面临的“不愿创新”和“不敢创新”难题提供理论指导。

结合上述研究背景,本文采用 BERT 模型识别了人工智能技术创新的直接度量指标。BERT 模型是人工智能领域的一大突破,能够将文本语义信息转换为计算机可处理的向量表示。在多项权威阅读理解测试中,BERT 的表现已超过人类平均水平,因此在学术界获得了广泛应用和认可。例如,阿齐卡林等(Acikalin et al.)利用 BERT 预测企业专利是否会受到美国某判例的影响<sup>[16]</sup>。刘青和肖柏高基于专利摘要文本,采用 BERT 模型识别了劳动节约型技术相关的专利<sup>[17]</sup>。与这些研究类似,本文从人工智能核心领域出发,利用 BERT 对专利摘要进行文本提取与分类,构建了人工智能技术创新的直接度量指标。具体而言,本文首先从专利样本中随机抽取一定数量的专利,通过人工识别的方式对这些专利的摘要文本进行分类,接下来利用 BERT 大语言模型对人工标注的专利进行学习,最后使用训练好的 BERT 大语言模型对所有专利进行分类。测试结果显示,模型预测准确率可达 92%~95%。进一步检验表明,该指标与现实高度吻合,充分证明了本文识别方法的可靠性。

在准确测算人工智能技术创新的基础上,本文采用 2010—2022 年上市公司与专利匹配数据,从新质生产力的视角考察人工智能技术创新对企业全要素生产率的影响。本文可能的贡献有三点。第一,本文利用 BERT 大语言模型构建了上市公司人工智能技术创新数据库,能够更合理、更精准地识别企业的人工智能技术创新水平,弥补了现有文献在识别新兴技术方面的不足。鉴于人工智能技术快速迭代,传统词典法在识别相关术语时存在覆盖不足和语义理解能力有限等问题,易导致技术创新识别偏误<sup>[15]</sup>。为克服上述局限,本文以人工智能核心领域为基础,引入 BERT 大语言模型对专利文本进行识别。该方法无需依赖预设词表,而是通过语义建模对文本进行自动理解与判断,从而提高识别过程的准确性与全面性,显著增强人工智能技术创新识别的可靠性。第二,本文积极回应了数字经济时代关于“索洛悖论”可能依然存在的担忧,并验证了人工智能技术创新的生产率效应。既有研究多聚焦于人工智能技术的具体应用,而对其技术创新本身关注相对不足,且人工智能技术的经济效应在现有文献中尚未形成一致结论<sup>[7,9]</sup>。基于 BERT 大语言模型对人工智能技术创新的准确识别,本文发现人工智能技术创新能够提升企业全要素生产率,为制定相关创新政策和推动企业智能化转型提供了重要参考。第三,本文从培育新质生产力的视角,丰富了人工智能技术创新影响企业全要素生产率的传导机制理论,为人工智能技术创新赋能高质量发展提供了新的理论解

释。与以往文献主要从技能结构升级、资本-技能互补和产业链等视角考察人工智能技术影响企业全要素生产率的传导机制不同<sup>[7,18]</sup>,本文聚焦于生产要素的创新性配置,分别从新型劳动者、新型劳动资料和新型劳动对象三个方面衡量新质生产力,系统分析了人工智能技术创新通过培育新质生产力提高企业全要素生产率的作用路径,为相关领域研究提供了新的理论视角和实践启示。

## 二、理论分析和研究假设

### (一) 人工智能技术创新对企业全要素生产率的影响

人工智能技术创新反映了企业在人工智能领域的技术知识积累与研发成果,构成了其将相关技术嵌入生产经营活动的能力基础与资源储备。企业的人工智能技术创新主要通过驱动和赋能关键业务环节的技术应用,进而提升全要素生产率。具体而言,这些创新成果为企业在投资决策、内部管控和资产营运等领域部署高效的人工智能解决方案提供了技术条件与能力支撑,进而通过提高决策质量、降低管控成本与优化资产利用效率等路径,实现资源配置效率与生产率的持续提升。

首先,在投资决策方面,人工智能技术通过深度学习与数据分析,显著提升企业决策的科学性与前瞻性,从而促进全要素生产率的提高。与传统决策依赖有限信息和经验判断不同,人工智能技术能够快速处理海量多维数据,帮助企业精准预测行业趋势、市场需求和投资回报率<sup>[4]</sup>。以风险投资为例,人工智能算法能够通过分析历史数据与市场动态,提供多维度的风险评估,降低投资的不确定性。与此同时,模拟分析和情景预测还可以帮助企业识别潜在的战略性投资机会,从而优化资本配置,提高投资效率。其次,在内部管控方面,人工智能技术可通过自动化流程、智能化监控和实时数据分析,显著降低企业的管理成本。具体而言,基于人工智能技术的企业资源计划系统与客户关系管理系统,能够实现高效的信息整合与动态监测,从而减少人工操作错误与时间浪费<sup>[18]</sup>。与此同时,利用自然语言处理与图像识别等技术的智能审计系统,能实时识别财务异常和合规风险,进一步降低内部管控成本,提高运营透明度与管理效率。最后,在资产营运效率方面,人工智能技术通过优化资源分配与流程管理,有效提升了资产的边际产出率和整体利用效率。智能化的生产调度系统依托实时数据调整设备运行状态,降低资产闲置率,减少资源浪费。同时,在资产管理领域,利用人工智能技术进行预测性维护可提前监测设备运行情况,及时发现潜在故障,减少维护成本与停机损失。此外,人工智能技术还可优化库存管理与供应链调度,提高库存周转率和物流效率<sup>[19]</sup>。综上所述,人工智能技术创新通过推动技术在企业经营活动中的应用与深化,能够改善投资决策质量、降低内部管控成本、提升资产营运效率,从而显著提高企业的全要素生产率。

基于此,本文提出假设1:人工智能技术创新能够提升企业全要素生产率。

### (二) 人工智能技术创新对全要素生产率的影响机制

人工智能技术创新不仅是一种技术进步形式,更代表了以数据、算法与算力为核心的新生产要素重组过程。随着人工智能技术在企业研发、生产和管理环节的深入应用,企业生产函数正从以传统资本与劳动为主导的要素投入模式,向以知识与智能为驱动的新型生产力结构转变。这一变革正是新质生产力的典型体现。新质生产力是近年来中央经济工作会议提出的重要理论概念,是由技术革命性突破、生产要素创新性配置和产业深度转型升级而催生的先进生产力,它以劳动者、劳动资料、劳动对象及其优化组合的质变为基本内涵<sup>[20-22]</sup>。三者共同构成了人工智能驱动下生产力演化的新形态,为企业提升全要素生产率提供了新的实现路径。

第一,人工智能技术创新能够催生高素质的新型劳动者。马克思主义政治经济学强调,劳动者是生产

过程中的核心要素。人工智能技术提升了企业在解决复杂问题、数据分析和跨学科协作等方面的高阶能力,并通过重塑流程和组织模式,强化了知识与技术密集型岗位的重要性<sup>[23]</sup>。因此,企业在调整劳动力结构时,倾向于优先吸纳新型劳动者——即那些能够掌握并应用新兴技术、具备持续学习和创新意识的高素质人才,如数据分析师、区块链应用操作员等<sup>[24]</sup>。这些新型劳动者的涌现为新质生产力的形成奠定了人力资源基础。

第二,人工智能技术创新可以拓展更广范围的新型劳动对象。新型劳动对象是新质生产力的重要物质基础。人工智能技术催生了大量智能化、低碳且安全的新型生产工具,例如自动化生产线、智能机器人、无人机、3D 打印技术以及智能传感器等。这些新型生产工具不仅进一步解放了劳动者的生产力,还减少了自然条件对生产活动的制约,极大拓宽了生产空间,为新型生产力的形成提供了坚实的物质基础<sup>[25]</sup>。特别是智能制造系统等非实体形态的生产工具的广泛应用,丰富了生产工具的表现形式,推动了制造流程的智能化转型,从而提升了生产活动的效率和灵活性,为新质生产力的发展提供了强大支撑。

第三,人工智能技术创新能够创造更高技术含量的新型劳动资料。新型劳动资料是新质生产力的动力源泉。人工智能通过催生智能生产工具,实现劳动资料从物质形态向虚拟形态的转变,根本性地重塑了劳动资料的性质与功能<sup>[26]</sup>。智能机器人、自动化系统和虚拟协作平台的广泛应用,使生产过程更加智能化和灵活化。同时,人工智能催生了新的数据资源和信息系统,如大数据平台、云计算基础设施和物联网设备,成为现代生产不可或缺的核心劳动资料,使数据正式成为新质生产力的重要生产要素。

新质生产力在提升企业全要素生产率方面发挥着重要作用。首先,它通过提高生产要素的质量,培育高端要素,从而推动企业全要素生产率的提升。一方面,新质生产力促进了人工智能等技术与传统生产要素(如资本和劳动力)的深度融合,使这些要素具备智能化特征,并提升其功能。这不仅优化了要素的投入比例,还推动了企业生产结构的升级,进一步提高了全要素生产率。另一方面,新质生产力突破了规模报酬递减的限制,使传统要素如资本、劳动力和土地不再受时间和空间的束缚,从而大幅提高了产出效率,进一步提升了全要素生产率<sup>[27]</sup>。其次,新质生产力通过催生新型生产组织形式,优化资源配置,推动了企业全要素生产率的增长。随着新质生产力的发展,生产方式逐渐从传统的机械化、流水线模式转变为依托数字技术的智能化、平台化生产方式<sup>[28]</sup>。这一转变不仅提高了要素流动效率,减少了资源损耗,还促进了供需双方的高效对接,显著优化了资源配置效率,从而进一步提升了全要素生产率。最后,新质生产力通过赋能技术创新,推动企业全要素生产率的提升。新质生产力改变了企业在技术创新中的角色,重新定义了企业的规模、层级和边界,进而改变了企业间的合作模式,企业的外部边界逐渐模糊,形成了以企业为核心的创新网络。这种网络打破了地理空间的限制,使创新要素得以在更广泛的范围内配置,优化了创新资源的结构,提升了资源配置效率,持续激发创新动力,进一步提高了全要素生产率。

基于以上分析,本文提出假设 2:人工智能技术创新能够催生新型劳动者、开发新型劳动对象和创造新型劳动资料,从而培育新质生产力,提升企业全要素生产率。

### 三、人工智能技术创新的定义和识别

#### (一) 人工智能技术创新的定义与识别

本文尝试利用先进的大语言模型对专利摘要进行识别与分类。具体技术过程如下:首先,从专利样本中随机抽取一定数量的专利,并通过人工识别对这些专利摘要进行分类;其次,利用 BERT 大语言模型对人工标注的专利进行学习,最终使用训练好的模型对所有专利进行分类。在这一过程中,最关键的一步是确保人工识别时能够正确标注专利摘要,因此,制定一个完善且可执行的人工智能技术创新定义尤

为重要。

本文将“人工智能”定义为由人类制造的机器所展现的智能,通常是指通过计算机程序实现的类人智能技术。由于人工智能涵盖的范围广泛,单一的定义难以明确区分人工智能技术创新,因此本文从人工智能的相关领域出发,对专利进行划分。根据工业和信息化部2024年发布的《国家人工智能产业综合标准化体系建设指南》,人工智能的关键技术可分为以下核心领域:知识图谱、群体智能、自然语言处理、计算机视觉、大模型、智能体、智能语音、机器学习、跨媒体智能、人机混合增强智能、具身智能、生物特征识别等。

本文列举了多个典型示例(见表1),以说明本文识别人工智能技术创新的方法及一些原有方法的不足之处。从1号到6号专利,本文依据专利是否属于人工智能的子领域进行判别,涵盖了图像识别、生物特征识别、机器学习、具身智能、大模型等领域。这些专利中存在一些值得关注的细节。1号和2号专利的关键词分别为“检测人脸图像”和“采集并处理被鉴定者的虹膜图像”。这种关键词难以通过常规的文本分析方法进行字典匹配,因此传统的文本分析方法在此情境下并不适用。7号专利的国际专利分类(IPC)主分类号并不属于人工智能相关技术领域,且经过人工判别后确认其不属于人工智能技术创新。然而,传统文本分析方法通过匹配到“机器人”这一关键词,错误地将其归类为人工智能技术创新。8号专利的IPC主分类号可归属于多个技术领域,其中包括人工智能技术。因此,按照IPC主分类号判断,该专利会被归入人工智能技术创新。然而,人工判别显示该专利实际为关于缓存实现的方法,并不涉及人工智能技术。

表1 人工智能技术专利示例

| 编号 | IPC 主分类号  | 专利摘要                                                                                                                           | 类别     | 是否为 AI 专利 |
|----|-----------|--------------------------------------------------------------------------------------------------------------------------------|--------|-----------|
| 1  | G01B11/02 | 本发明公开了一种身高测量方法及其测量装置,其中,所述方法包括:检测人体位置,判断所述人体位置是否进入预定范围;判断为是则采集人体视频图像;从所述人体视频图像中检测人脸图像并获取最佳人脸图像;由所述最佳人脸图像确定人体身高。……,方便准确地计算人体的身高 | 计算机视觉  | 是         |
| 2  | H04L9/32  | 本发明公开了一种提高智能密钥安全性的方法,包括以下步骤:1. 采集并处理被鉴定者的虹膜图像。……,提高智能密钥装置的可靠性和安全性                                                              | 生物特征识别 | 是         |
| 3  | G06K9/62  | 本发明公开了一种基于深度神经网络的票据数量识别方法及系统,……,同时帮助系统进行后续的票据目标检测与内容识别任务,实现系统的实时工作                                                             | 机器学习   | 是         |
| 4  | G05D1/02  | 本发明公开了一种用于双足步行机器人的动态步行控制方法,……,对双足步行机器人的步态进行实时修正,实现在未知、非平整地面上的稳定行走                                                              | 具身智能   | 是         |
| 5  | G06F40/30 | 本申请公开了有害短信分析方法、装置和存储介质,……。本申请通过盘古大模型和迁移学习技术,减少所需的有标签的有害短信数据量,训练所需要的时间和计算资源也大大减少,具有更好的适应性,能在短时间内生成可靠的有害短信检测分析模型,提高了通信网有害短信的分析效率 | 大模型    | 是         |
| 6  | G06K9/34  | 本发明的图像分割方法不但适用于不同的图像场景、具有广泛适用性,而且具有可以接受的时间复杂度和空间复杂度                                                                            | 计算机视觉  | 是         |
| 7  | E21B41/08 | 一种水下隔离阀的海底管线终端,包括防沉板、安装在防沉板上的支撑结构、水下隔离阀及其执行机构、工艺管线、膨胀弯接口,以及阀门防护结构,……,以保证其不会因水中落物及水下机器人的撞击和渔网拖带而造成损坏                            |        | 否         |

表1(续)

| 编号 | IPC 主分类号  | 专利摘要                                                                                                          | 类别 | 是否为 AI 专利 |
|----|-----------|---------------------------------------------------------------------------------------------------------------|----|-----------|
| 8  | G06F17/30 | 本发明提出了一种基于闪存(Flash)存储介质的文件分配表缓存实现方法。该缓存机制以单个文件为单位,当创建或打开文件时,系统将创建与之对应的文件对象结构,……。本发明所需 RAM 资源较少,简化了文件系统的掉电保护工作 |    | 否         |

(二)大语言模型的文本分类方法

BERT 模型是谷歌公司于 2018 年推出的基于 Transformer 架构的预训练语言模型。BERT 的训练过程分为两个阶段:一是预训练阶段,在大规模无监督语料上进行,目的是学习语言的通用模式,通过上下文的双向学习理解词汇和句子的深层含义;二是微调阶段,针对特定任务进行调整,在此阶段,BERT 已经掌握了通用的语言基础,只需少量标注数据对模型进行微调,以适应新任务需求。举个例子,如果拥有大量图书数字资源,可以训练一个知识渊博的模型(相当于一个通晓多领域的人)。当需要在专利分类等特定场景下使用时,只需修改输出层,并用标注的专利数据对模型进行增量训练(相当于让这个知识渊博的人成为行业专家)。通过这种方式,BERT 能够有效地将通用语言能力转化为具体任务的专业能力。

第一步的预训练过程已由谷歌公司完成,本文采用的 BERT 模型版本为基于中文语料库预训练的 bert-base-chinese 模型。该模型在预训练阶段基于维基百科的全部中文内容,参数量约为 1 亿个。第二步是微调和训练分类器。对于 BERT 在文本分类任务中的应用,微调阶段通过特定语料的训练来提升模型在特定任务上的准确率。然而,由于 bert-base-chinese 模型体量较大,微调过程对计算资源要求较高,而且该模型已基于维基百科语料库进行预训练,且该语料与专利摘要较为接近,因此本文未对模型进行微调。本文的核心任务是利用人工标注的训练集和测试集训练一个基于 BERT 输出的分类模型。具体技术细节如下。

第一步,专利文本的人工标注。本文从 2002—2022 年的专利数据中随机抽取了 10 000 条,并基于前文对人工智能技术创新的定义和分类标准对其进行了人工标注。对于一些模糊的专利,为确保标注的严谨性,本文使用了 ChatGPT-4 大语言模型进行辅助识别。具体操作是:首先将人工智能技术创新的定义输入 ChatGPT-4,再将模糊专利的摘要输入模型,由其判断是否属于人工智能技术创新。最终结合 ChatGPT-4 的判别结果和人工评判结果,对模糊专利进行最终标注。第二步,模型训练。标注完成后,从 10 000 条人工标注的专利中随机抽取 9 000 条作为训练集,1 000 条作为测试集<sup>①</sup>。训练集用于对分类器进行训练,使其满足人工智能技术创新分类的需求。测试集在训练完成后用于评估模型的泛化能力和分类精度。第三步,参数调整。在训练过程中,本文不断调整学习率(lr)、训练周期(epoch)、单次训练样本数(batch size)等参数。经过训练,模型的预测准确率达到 92%~95%<sup>②</sup>。最终,基于已训练好的模型对上市公司的全部专利进行分类。

(三)人工智能技术创新指标有效性检验

图 1 展示了 2002—2022 年期间中国人工智能技术创新数量和人工智能技术创新企业数量的变化趋势。可以看出,人工智能技术创新数量和技术创新企业数量都呈现持续增长的态势。尤其是在 2013 年之后,两

① 模型训练样本数量的设定主要参考了阿齐卡林等<sup>[16]</sup>的研究经验,并结合模型性能测试结果综合确定。验证结果表明,当训练样本量超过 10 000 条时,模型准确率趋于稳定,进一步扩大模型训练样本对模型精度提升的边际效应较为有限。

② 作为对照,本文同样使用 10 000 条人工标注的专利文本应用词典法进行识别,结果显示其识别准确率约为 85%,明显低于 BERT 模型的识别表现。

条曲线的增长速度明显加快,这表明2013年之后,人工智能技术的研发进入了快速发展阶段。这种趋势符合预期,也与国内外人工智能技术扩散的整体规律相一致。在实际发展中,2013年,脸书(Facebook)创建了人工智能实验室,百度设立了深度学习研究院。2015年,谷歌公司发布了开源的机器学习平台TensorFlow,这一年被视为人工智能技术取得重要突破的节点。这些事实充分证明了本文所构建的指标具有较高的可靠性。




图1 中国人工智能技术创新趋势

## 四、实证设计

### (一) 样本选取与数据来源

本文的研究数据主要包括2010—2022年中国沪深A股上市公司数据及其对应的专利数据。其中,上市公司相关财务与运营数据来源于深圳希施玛数据科技有限公司CSMAR中国经济金融研究数据库,具有较高的覆盖度与可信度。人工智能相关专利数据则来自国家知识产权局公开发布的专利数据库。为实现企业层面的专利匹配,本文依据上市公司的现用名称及曾用名称与专利数据中的申请人字段进行识别与匹配,从而构建上市公司人工智能技术创新的专利样本。为确保研究结论的可靠性与稳健性,样本选择标准如下:(1)剔除了金融业及信息传输、软件和信息技术服务业企业,主要原因在于其经营模式、资产结构及创新特征与实体企业差异明显,难以直接比较;(2)剔除了ST及\*ST公司,以避免财务异常和经营不稳定等因素对回归结果造成干扰;(3)为减少异常值影响,对连续变量的上下进行1%的缩尾处理,最终得到30379个有效观测样本。

### (二) 模型设定

本文设定如下双向固定效应回归模型实证检验人工智能技术创新对企业全要素生产率的影响:

$$TFP_{it} = \alpha_0 + \alpha_1 \ln AI_{it} + X'_{it} \beta + \theta_i + \varphi_p + \gamma_j + \mu_t + \varepsilon_{it} \quad (1)$$

其中,下标*i*为企业,*j*为行业,*p*为省份,*t*为年份。 $TFP_{it}$ 为*i*企业*t*年的全要素生产率, $\ln AI_{it}$ 为*i*企业*t*年人工智能技术创新, $X'_{it}$ 为控制变量向量, $\theta_i$ 、 $\varphi_p$ 、 $\gamma_j$ 、 $\mu_t$ 分别为企业、省份、行业和时间固定效应, $\varepsilon_{it}$ 为误差项。

为检验新质生产力是否为人工智能技术创新对企业全要素生产率的作用机制,本文设定如下回归模型:

$$NQP_{it} = \beta_0 + \beta_1 \ln AI_{it} + X'_{it} \beta + \theta_i + \varphi_p + \gamma_j + \mu_t + \varepsilon_{it} \quad (2)$$

其中, $NQP_{it}$ 为*i*企业*t*年的新质生产力,其他变量定义同模型(1)。

### (三) 变量说明

#### 1. 被解释变量

考虑到企业可能根据生产效率的变化调整要素投入,导致按普通最小二乘(OLS)法和固定效应(FE)法估计的企业层面全要素生产率与要素投入之间存在较强的内生性关系,得到的全要素生产率结果通常存在

同时性偏差,且这两种方法涵盖的信息也不够全面;相比之下,虽然广义矩估计(GMM)方法能够解决 OLS 和 FE 方法面临的内生性问题,但需要较长的样本时间跨度,使样本损失严重<sup>[29]</sup>。为此,借鉴黄勃等<sup>[12]</sup>的做法,本文采用 LP 法和 OP 法计算的全要素生产率(分别记为  $TFP_{LP}$  和  $TFP_{OP}$ )作为本文的被解释变量。

2. 解释变量

本文基于 BERT 模型对专利摘要进行识别,获取人工智能技术创新数量并与上市公司进行匹配,然后将专利数量加 1 后取自然对数,用于衡量企业人工智能技术创新( $\ln AI$ )指标。

3. 机制变量

新质生产力以新型劳动者、新型劳动对象和新型劳动资料及其优化组合的质变为核心内涵。因此,参考梁孝成等<sup>[30]</sup>的方法,本文构建了企业新质生产力( $NQP$ )的指标体系,并运用熵值法合理确定各项指标的权重<sup>①</sup>。第一,新型劳动者。该维度从员工与管理层两个层面刻画企业新型劳动者特征,因为新型劳动者既依赖一线劳动者的知识技能结构,也取决于管理层对技术应用和组织转型的引导能力。员工层面以高素质员工比例和研发人员占比反映劳动者的知识技能结构;管理层层面则通过管理团队的数字化背景和首席执行官(CEO)职能经历多样性体现其能力特征。其中,高管数字化背景利用高管教育背景数据识别其专业领域,并根据是否具有与“信息、智能、软件、电子、通信、系统、网络、自动化、计算机”等相关的专业经历构建虚拟变量,以反映其数字素养。CEO 职能经历依据 CSMAR 数据库提供的职能分类体系将 CEO 经历划分为九类,并以出现的类别数量进行计数,数值越高表示其职业经历越多元化。

第二,新型劳动资料。该维度从生态环境和未来发展两个方面刻画企业所依赖的基础性生产资源,因为新型劳动资料既包含绿色友好型生产环境的外部条件,也涉及支持生产体系升级的长期物质投入。生态环境指标通过华证环境、社会和治理(ESG)体系中的环境得分衡量企业的绿色治理与环境绩效,以反映企业在绿色发展方面的关注程度;未来发展指标采用固定资产占比来刻画企业对长期资源投入和产能升级的重视程度。

第三,新型劳动对象。该维度旨在衡量企业在科技创新、绿色技术和数字化能力方面的资源配置。科技劳动资料以  $\ln(\text{申请专利数}+1)$  等指标反映企业的创新水平及知识创造能力;绿色劳动资料通过绿色技术水平和绿色专利占比衡量企业绿色创新活动;数字劳动资料通过企业智能化水平与数字资产占比反映数字技术渗透程度。上述指标体现了企业在研发投入、绿色创新与数字化发展方面的资源配置状况和能力积累。具体衡量方式见表 2。

表 2 企业新质生产力指标体系

| 构成要素   | 一级指标   | 指标          | 衡量方式                    | 方向 | 权重      |
|--------|--------|-------------|-------------------------|----|---------|
| 新型劳动者  | 员工素质   | 高素质员工       | 研究生以上学历占比               | +  | 0.120 1 |
|        |        | 研发人员占比      | 研发人员占总员工的比例             | +  | 0.092 1 |
|        | 管理层素质  | 管理层数字化背景    | 高管团队是否具有数字化背景           | +  | 0.121 9 |
|        |        | CEO 职能经历丰富度 | CEO 职能经历计数              | +  | 0.060 2 |
| 新型劳动对象 | 生态环境   | 环境绩效        | 华证 ESG 评分体系中的环境得分       | +  | 0.057 0 |
|        | 未来发展   | 固定资产占比      | 固定资产/资产总额               | +  | 0.065 4 |
| 新型劳动资料 | 科技劳动资料 | 企业创新水平      | $\ln(\text{申请专利数}+1)$   | +  | 0.150 9 |
|        | 绿色劳动资料 | 绿色技术水平      | $\ln(\text{申请绿色专利数}+1)$ | +  | 0.090 8 |

① 本文进一步采用主成分分析法重新赋权构建替代性  $NQP$  指数进行稳健性检验,结果显示回归结论未发生实质性变化,验证了研究结果的稳健性。限于篇幅未在文中报告,留存备索。

表2(续)

| 构成要素 | 一级指标 | 指标             | 衡量方式            | 方向 | 权重      |
|------|------|----------------|-----------------|----|---------|
|      |      | 数字劳动资料中的绿色专利占比 | 申请绿色专利数/企业申请专利数 | +  | 0.085 6 |
|      |      | 智能化水平          | ln(智能化水平词频+1)   | +  | 0.130 4 |
|      |      | 数字资产占比         | 数字化相关资产/无形资产总额  | +  | 0.025 6 |

4. 控制变量

本文选取可能影响人工智能技术创新和全要素生产率的控制变量,包括:(1)企业年龄(*lnAge*),为企业成立年限的对数;(2)企业规模(*lnSize*),为员工人数的对数;(3)流动比率(*Liquid*),为流动资产与总资产的比值;(4)董事会规模(*lnBoard*),为董事人数的对数;(5)产权性质(*Soe*),国有企业取1,其他取0;(6)现金流水平(*Cflow*),为经营活动产生现金流量净额与总资产的比值;(7)企业相对价值(*Tobin*),为市值与总资产的比值;(8)企业成长性(*Growth*),为营业收入增长率;(9)资产负债率(*Lev*),为总负债与总资产的比值。

(四) 变量描述性统计

主要变量的描述性统计结果见表3。由表可知,*TFP\_OP*和*TFP\_LP*的均值分别为6.724和8.371,与现有文献<sup>[34]</sup>的结果相近。*lnAI*的均值为2.403 4,标准差为29.977 2,表明企业间人工智能技术创新水平存在差异。

表3 描述性统计结果

| 变量类型  | 变量            | 观测值    | 均值          | 标准差          | 最小值       | 最大值          |
|-------|---------------|--------|-------------|--------------|-----------|--------------|
| 被解释变量 | <i>TFP_OP</i> | 30 379 | 6.723 5     | 0.920 7      | 2.138 2   | 11.446 8     |
|       | <i>TFP_LP</i> | 30 379 | 8.370 9     | 1.092 2      | 3.981 6   | 13.106 4     |
| 解释变量  | <i>AI</i>     | 30 379 | 2.4034      | 29.977 2     | 0         | 1 726        |
| 机制变量  | <i>NQP</i>    | 30 379 | 4.972 1     | 2.418 2      | 0.060 1   | 32.475 3     |
| 控制变量  | <i>Age</i>    | 30 379 | 10.838 2    | 7.507 1      | 0         | 32           |
|       | <i>Size</i>   | 30 379 | 6 136.799 1 | 20 663.613 4 | 500.000 0 | 570 060.00 0 |
|       | <i>Liquid</i> | 30 379 | 0.568 4     | 0.193 7      | 0.111 2   | 0.944 5      |
|       | <i>Board</i>  | 30 379 | 10.1583     | 2.666 2      | 4         | 30           |
|       | <i>Soe</i>    | 30 379 | 0.345 9     | 0.475 7      | 0         | 1            |
|       | <i>Cflow</i>  | 30 379 | 0.047 0     | 0.069 0      | -0.162 2  | 0.245 8      |
|       | <i>Tobin</i>  | 30 379 | 2.057 9     | 1.352 6      | 0.849 1   | 8.791 6      |
|       | <i>Growth</i> | 30 379 | 0.180 9     | 0.451 6      | -0.576 3  | 3.030 0      |
|       | <i>Lev</i>    | 30 379 | 0.436 6     | 0.205 2      | 0.058 6   | 0.903 1      |

五、实证结果与分析

(一) 基准回归

本文分析了人工智能技术创新对全要素生产率的影响,回归结果见表4。无论采用OP法还是LP法计算全要素生产率,*lnAI*的回归系数均在1%水平下显著为正,表明人工智能技术创新能够提升企业全要素生产率。以OP法回归结果为例,当企业人工智能技术创新提高10%时,全要素生产率提高约8.2%<sup>①</sup>。这些发现表明,人工智能技术创新能够提高企业全要素生产率,该实证结果支持了假设1。

① 具体计算方式为:(0.054 9×10/6.723 5)×100%=8.2%

表 4 基准回归结果

| 变量             | TFP_OP                 | TFP_LP                 |
|----------------|------------------------|------------------------|
| lnAI           | 0.0549***<br>(0.0073)  | 0.0511***<br>(0.0072)  |
| lnAge          | 0.1929***<br>(0.0212)  | 0.1689***<br>(0.0208)  |
| lnSize         | 0.0540***<br>(0.0165)  | 0.3575***<br>(0.0155)  |
| Liquid         | 1.1145***<br>(0.0589)  | 1.3010***<br>(0.0581)  |
| lnBoard        | -0.0004<br>(0.0148)    | 0.0004<br>(0.0147)     |
| Soe            | -0.0326*<br>(0.0194)   | -0.0327*<br>(0.0190)   |
| Cflow          | 0.8052***<br>(0.0578)  | 0.7703***<br>(0.0572)  |
| Tobin          | -0.0323***<br>(0.0055) | -0.0257***<br>(0.0054) |
| Growth         | 0.2521***<br>(0.0085)  | 0.2486***<br>(0.0083)  |
| Lev            | 0.3364<br>(0.3511)     | 0.2906<br>(0.3503)     |
| 常数项            | 5.0817***<br>(0.1354)  | 4.3466***<br>(0.1288)  |
| 年份固定效应         | 控制                     | 控制                     |
| 企业固定效应         | 控制                     | 控制                     |
| 行业固定效应         | 控制                     | 控制                     |
| 省份固定效应         | 控制                     | 控制                     |
| 样本量            | 30379                  | 30379                  |
| R <sup>2</sup> | 0.8775                 | 0.9140                 |

注：\*\*\*、\*\*和\*分别表示在1%、5%和10%水平下显著,括号内为在企业层面聚类的稳健标准误。后表同。

与人工智能技术创新高度正相关,符合预期。第一阶段F值均大于10,且Kleibergen-Paap rk Wald F统计量也大于临界值,拒绝了弱工具变量假设,表明本文选择的工具变量有效。第二阶段所有回归系数均在1%水平下显著为正,这表明在考虑内生性问题后,结论依然稳健。

表 5 工具变量回归结果

| 变量     | 第一阶段                  | 第二阶段                 |                      |
|--------|-----------------------|----------------------|----------------------|
|        |                       | TFP_OP               | TFP_LP               |
| IV     | 1.4987***<br>(0.1525) |                      |                      |
| lnAI   |                       | 0.0456**<br>(0.0200) | 0.0422**<br>(0.0200) |
| 控制变量   | 控制                    | 控制                   | 控制                   |
| 基准固定效应 | 控制                    | 控制                   | 控制                   |

(二) 内生性分析

本文可能面临两类内生性问题。一是遗漏变量问题。尽管模型已纳入多种控制变量,但仍可能存在一些难以量化的因素(如企业文化)同时影响人工智能技术创新与全要素生产率。二是反向因果关系。生产率较高的企业往往具备更多的资金和人才,能够更好地进行人工智能技术的研发。为缓解内生性问题,本文采用移动份额法构建巴蒂克(Bartik)工具变量。具体而言,该方法通过初始变量份额与总体增长率的乘积来预测当年的估计值,并结合两阶段最小二乘法回归,有效减少因遗漏变量和反向因果引起的内生性问题。巴蒂克工具变量的构建公式如下:

$$IV_{it} = \ln AI_{it-1} \times (1 + \ln AI Growth_t) \quad (3)$$

其中,IV<sub>it</sub>为巴蒂克工具变量,即t年企业i的人工智能创新水平预测值,lnAI<sub>it-1</sub>为企业i在t年期初的人工智能技术创新水平,lnAIGrowth<sub>t</sub>为t年所有企业的人工智能技术创新水平的年增长率。基于初始变量的预测值与实际值强相关,但与残差项不相关,因此工具变量满足相关性与排他性。工具变量回归结果见表5,第一阶段回归显示,本文选取的工具变量

表5(续)

| 变量                        | 第一阶段    | 第二阶段              |                   |
|---------------------------|---------|-------------------|-------------------|
|                           |         | TFP <sub>OP</sub> | TFP <sub>LP</sub> |
| 样本量                       | 29 123  | 29 123            | 29 123            |
| R <sup>2</sup>            | 0.061 5 | 0.343 6           | 0.205 1           |
| Kleibergen-Paap rk LM     |         | 87.866 2          | 96.614 4          |
| Kleibergen-Paap rk Wald F |         | 36.114 2          | 35.054 6          |
|                           |         | [0.000 0]         | [0.000 0]         |

注:基准固定效应包括企业、省份、行业和时间固定效应,后表同。方括号内数值为P值。

(三) 稳健性检验<sup>①</sup>

1. 替换变量

为检验被解释变量不同测度方式对结果稳健性的影响,本文分别采用OLS、FE和GMM方法测算的企业全要素生产率替代被解释变量。此外,本文还更替了解释变量,借鉴姚加权等<sup>[7]</sup>的方法,通过人工智能关键词识别人工智能技术创新,并将其作为人工智能技术创新的替代指标。结果表明,在替换变量后,结论依然与前文一致。

2. 倾向得分匹配法

企业进行人工智能技术创新并非完全随机,而是受到多个因素的影响,诸如企业生产率、知识产权保护、市场竞争力及技术吸收能力等。这些因素可能导致企业在是否进行人工智能技术创新上的选择具有一定差异,进而引发样本自选择偏差问题。为解决该问题,本文采用倾向得分匹配法。具体而言,根据企业是否进行人工智能技术创新,将样本分为实验组和对照组,并以式(1)的控制变量作为匹配标准,采用1:1有放回的最邻近匹配方法进行匹配。匹配后的回归结果显示,核心解释变量的回归系数在1%水平下显著为正,结论依然稳健。

3. 考虑滞后效应

由于人工智能技术创新通常需要一定时间来完成从技术突破到实际生产率提升的转化,其对全要素生产率的影响通常具有滞后效应。这种滞后性主要源于技术创新从实验室阶段到产业化的周期,以及新技术在企业内部从试验性应用到全面推广所需的学习与适应过程。为此,本文将人工智能技术创新的滞后一期进行稳健性检验。回归结果表明,人工智能技术创新的回归系数均为正,且在1%的水平下显著,说明本文的基本结论是稳健的。

4. 智能制造政策冲击

智能制造政策以推动人工智能技术创新为重要目标,通过税收优惠等措施为企业的人工智能技术研发提供了关键资源,降低了技术开发成本,并激发企业技术创新的积极性。同时,政策推动了企业、高校和科研机构间的协同创新,促进了人工智能技术及相关知识的流动、转移与共享,加速了技术的研发。因此,智能制造政策的实施可以被视为对企业人工智能技术创新的外部冲击。由于该政策较少受到企业自身生产率的影响,因此面临的内生性问题相对较小。基于此,本文将智能制造政策视为对人工智能技术创新的外部冲击,检验其对企业生产率的影响。本文参考沈坤荣等<sup>[31]</sup>的做法构建如下双重差分模型:

$$TFP_{i,t} = \tau_0 + \tau_1 Treat \times Post_{it} + X'_{it}\beta + \theta_i + \varphi_p + \gamma_j + \mu_t + \varepsilon_{it} \tag{4}$$

其中,*Treat* 为企业所属行业是否属于十大重点领域对应的制造业行业<sup>②</sup>,若属于则 *Treat* 等于 1,否则为

① 限于篇幅,稳健性检验结果未在文中报告,留存备案。  
② 十大重点领域包括:新一代信息技术、高档数控机床与机器人、航空航天装备、海洋工程装备与高技术船舶、先进轨道交通装备、节能与新能源汽车、电力装备、农机装备、新材料,以及生物医药与高性能医疗器械。

0;*Post* 表示年份是否大于或等于 2015 年,若是则 *Post* 等于 1,否则为 0。其余变量定义与基准模型相同。回归结果显示,*Treat*×*Post* 的回归系数在 1%水平下显著为正,表明研究结论是稳健的。

(四) 机制检验

本文的理论分析表明,人工智能技术创新能够催生新型劳动者、创造新型劳动资料和开发新型劳动对象,从而培育新质生产力,提升企业全要素生产率。为了检验这一作用机制,本文采用机制分析方法进行实证分析,回归结果如表 6 所示<sup>①</sup>。被解释变量分别为新型劳动者(*NQP1*)、新型劳动资料(*NQP2*)、新型劳动对象(*NQP3*)和新质生产力。可以看出,人工智能技术创新的回归系数均在 1%水平下显著为正,这表明人工智能技术创新能够催生新型劳动者、创造新型劳动资料和开发新型劳动对象,从而培育新质生产力,提升企业全要素生产率。该实证结果支持了假设 2。

表 6 机制检验回归结果

| 变量                    | <i>NQP1</i>              | <i>NQP2</i>              | <i>NQP3</i>              | <i>NQP</i>              |
|-----------------------|--------------------------|--------------------------|--------------------------|-------------------------|
| <i>lnAI</i>           | 0.103 7 ***<br>(0.023 1) | 0.096 5 ***<br>(0.010 9) | 0.033 4 ***<br>(0.007 5) | 0.2309 ***<br>(0.031 7) |
| 控制变量                  | 控制                       | 控制                       | 控制                       | 控制                      |
| 基准固定效应                | 控制                       | 控制                       | 控制                       | 控制                      |
| 样本量                   | 30 379                   | 30 379                   | 30 379                   | 30 379                  |
| <i>R</i> <sup>2</sup> | 0.760 5                  | 0.770 0                  | 0.830 6                  | 0.795 7                 |

六、进一步研究

(一) 异质性分析

1. 知识产权保护异质性

知识产权是重要的民事权利之一,完善知识产权保护不仅能够保障企业专利权益,还能促进专利成果的转化与应用。现有研究表明,知识产权保护是企业技术创新中获取合法利益的关键,尤其在易模仿、易复制的人工智能技术创新领域具有重要意义<sup>[32]</sup>。完善知识产权保护能够通过人工智能技术创新,推动企业更高效地将这些创新成果转化为实际应用,从而提升全要素生产率。为此,本文依据国家知识产权局发布的各省知识产权保护指数,将样本按中位数划分为知识产权保护程度较强和较弱两组。分组回归结果见表 7。在知识产权保护较强的样本中,人工智能技术创新对全要素生产率的促进作用更大,且组间系数差异通过了显著性检验。这表明,完善知识产权保护能够增强人工智能技术创新对企业全要素生产率的提升效果。

表 7 知识产权保护异质性分析回归结果

| 变量          | <i>TFP_OP</i>            |                          | <i>TFP_LP</i>            |                          |
|-------------|--------------------------|--------------------------|--------------------------|--------------------------|
|             | 知识产权保护较强                 | 知识产权保护较弱                 | 知识产权保护较强                 | 知识产权保护较弱                 |
| <i>lnAI</i> | 0.073 2 ***<br>(0.010 1) | 0.046 4 ***<br>(0.010 3) | 0.070 1 ***<br>(0.010 2) | 0.040 4 ***<br>(0.010 3) |
| 控制变量        | 控制                       | 控制                       | 控制                       | 控制                       |

① 鉴于人工智能技术创新在内涵上与新质生产力指标体系中的“智能化水平”和“数字劳动资料”分项高度相关,为避免机制变量与解释变量在指标构成上的重合,本文在机制分析中剔除了上述两项,仅保留其余维度进行机制检验,相关实证结论依然成立。

表7(续)

| 变量             | TFP_OP    |          | TFP_LP    |          |
|----------------|-----------|----------|-----------|----------|
|                | 知识产权保护较强  | 知识产权保护较弱 | 知识产权保护较强  | 知识产权保护较弱 |
| 基准固定效应         | 控制        | 控制       | 控制        | 控制       |
| 样本量            | 15 066    | 15 306   | 15 066    | 15 306   |
| R <sup>2</sup> | 0.876 3   | 0.883 3  | 0.911 8   | 0.918 7  |
| 组间系数差异         | 0.027 9** |          | 0.030 9** |          |

2. 劳动密集程度异质性

由于劳动密集型企业可自动化、标准化任务较多,人工智能技术创新更易提升劳动效率、降低管理成本并优化资源配置;而资本密集型企业生产率主要依赖资本深化,人工智能创新的边际效应相对有限<sup>[31]</sup>。本文预测,劳动密集型企业人工智能技术创新推动下,其全要素生产率提升幅度更大。为此,本文参考沈坤荣等<sup>[31]</sup>的做法,采用企业员工总数与固定资产总额的比值衡量劳动密集程度,并根据中位数将样本分为劳动密集程度较高和较低两组。分组回归结果见表8。人工智能技术创新对全要素生产率的促进作用在劳动密集程度较高的样本中更大,且组间系数差异通过了显著性检验。这一结果验证了本文的理论预期,说明人工智能技术创新在以劳动要素为主导的企业中更能释放生产率红利,推动企业实现更高质量的发展。

表8 劳动密集程度异质性分析回归结果

| 变量             | TFP_OP                  |                         | TFP_LP                  |                         |
|----------------|-------------------------|-------------------------|-------------------------|-------------------------|
|                | 劳动密集程度较高                | 劳动密集程度较低                | 劳动密集程度较高                | 劳动密集程度较低                |
| lnAI           | 0.060 3***<br>(0.012 1) | 0.038 7***<br>(0.008 3) | 0.057 5***<br>(0.012 2) | 0.035 8***<br>(0.007 4) |
| 控制变量           | 控制                      | 控制                      | 控制                      | 控制                      |
| 基准固定效应         | 控制                      | 控制                      | 控制                      | 控制                      |
| 样本量            | 15 028                  | 14 993                  | 15 028                  | 14 993                  |
| R <sup>2</sup> | 0.881 3                 | 0.905 5                 | 0.920 1                 | 0.943 3                 |
| 组间系数差异         | 0.021 2*                |                         | 0.018 2*                |                         |

3. 吸收能力异质性

企业在吸收人工智能技术创新方面的能力存在差异,这种差异可能导致人工智能技术对企业全要素生产率提升效果的不同。吸收能力较强的企业通常具备较高水平的人力资本、技术储备与管理实践,能够更迅速地将人工智能技术创新成果转化为实际生产力,从而实现更明显的生产率提升;而吸收能力较弱的企业则可能面临技术适配性不足、资源配置效率低下等问题,限制了人工智能技术的应用效果。

为系统刻画企业吸收能力,本文综合采用产学研合作情况、研发强度及高学历人才占比三类指标,以全面反映企业在知识识别、转化与利用人工智能技术创新成果方面的能力。产学研合作情况用于衡量企业的外部知识识别能力。产学研合作是指企业与高校或科研机构的联合创新活动,有助于企业在知识交流与成果转化过程中获取外部创新资源,提升知识识别与合作吸收潜力。本文通过专利联合申请方式测度,若企业当年存在产学研合作专利,赋值为1,否则为0。研发强度用于衡量企业的知识转化能力,计算方式为年度研发支出占营业收入的比重。较高的研发投入反映企业较强的技术积累与再创新潜能,有助于促进外部知识的吸收与知识的整合。高学历人才占比用于衡量企业的知识利用能力,用本科及以上学历员工占总员工比例衡量。高学历人才具备较强的学习、理解与知识整合能力,能够促进人工智能技术成果的内化与再利

用。为综合反映企业在知识识别、转化与利用三个环节的整体吸收能力,本文采用主成分分析法对上述三类指标进行降维处理,提取第一主成分作为吸收能力的综合指标。在此基础上,根据综合指标的中位数将样本划分为吸收能力较强组和较弱组。分组回归结果见表 9。人工智能技术创新对全要素生产率的促进作用在吸收能力较强的企业中更为明显,且组间系数差异通过了显著性检验。该结果表明,提升技术吸收能力能够提高人工智能技术创新的转化效率,从而有效推动企业全要素生产率的提高。

表 9 吸收能力异质性分析回归结果

| 变量             | TFP_OP                   |                         | TFP_LP                   |                         |
|----------------|--------------------------|-------------------------|--------------------------|-------------------------|
|                | 吸收能力较强                   | 吸收能力较弱                  | 吸收能力较强                   | 吸收能力较弱                  |
| lnAI           | 0.084 9 ***<br>(0.015 2) | 0.032 4 **<br>(0.015 2) | 0.075 8 ***<br>(0.013 3) | 0.027 8 **<br>(0.014 1) |
| 控制变量           | 控制                       | 控制                      | 控制                       | 控制                      |
| 基准固定效应         | 控制                       | 控制                      | 控制                       | 控制                      |
| 样本量            | 15 005                   | 15 015                  | 15 005                   | 15 015                  |
| R <sup>2</sup> | 0.942 1                  | 0.919 3                 | 0.905 1                  | 0.880 5                 |
| 组间系数差异         | 0.053 1 ***              |                         | 0.048 2 ***              |                         |

(二) 不同类型人工智能技术创新的生产率效应

不同类型的技术创新在促进技术进步、优化生产流程以及提高企业生产率方面可能发挥着不同的作用。为此,本文将人工智能技术创新分为发明、实用新型和外观设计三类人工智能技术创新,分别考察其对全要素生产率的影响。回归结果见表 10。发明、实用新型人工智能技术创新能够有效提升企业全要素生产率,但外观设计人工智能技术创新难以有效提升企业全要素生产率。可能的原因在于,发明和实用新型人工智能技术创新通常涉及技术创新和实用功能的提升,这些创新能够优化生产流程、提高效率,从而有效提升企业的全要素生产率。相比之下,外观设计人工智能技术创新主要关注产品的美观和外观设计,虽然有助于产品在市场上实现差异化并提升竞争力,但对内部生产过程和效率的直接影响较小,因此在提升企业全要素生产率方面的作用有限。

表 10 不同类型人工智能技术创新的生产率效应回归结果

| 变量             | TFP_OP                   |                          |                      | TFP_LP                  |                          |                      |
|----------------|--------------------------|--------------------------|----------------------|-------------------------|--------------------------|----------------------|
|                | (1)                      | (2)                      | (3)                  | (4)                     | (5)                      | (6)                  |
| 发明             | 0.042 7 ***<br>(0.007 1) |                          |                      | 0.0387 ***<br>(0.007 2) |                          |                      |
| 实用新型           |                          | 0.046 2 ***<br>(0.013 3) |                      |                         | 0.041 8 ***<br>(0.013 1) |                      |
| 外观设计           |                          |                          | 0.044 1<br>(0.029 4) |                         |                          | 0.047 4<br>(0.030 2) |
| 控制变量           | 控制                       | 控制                       | 控制                   | 控制                      | 控制                       | 控制                   |
| 基准固定效应         | 控制                       | 控制                       | 控制                   | 控制                      | 控制                       | 控制                   |
| 样本量            | 30 379                   | 30 379                   | 30 379               | 30 379                  | 30 379                   | 30 379               |
| R <sup>2</sup> | 0.877 1                  | 0.877 2                  | 0.877 2              | 0.914 1                 | 0.914 5                  | 0.914 7              |

## 七、结论与建议

随着人工智能技术的飞速发展,人工智能创新已成为推动高质量发展的重要动力。近年来,国家政策的支持、技术的突破以及市场需求的多元化,都为企业人工智能技术创新提供了前所未有的机遇。本文结合人工智能领域前沿的 BERT 语言模型和专利摘要,精准识别人工智能技术创新,并实证检验其对中国企业全要素生产率的影响及作用机制。研究发现,人工智能技术创新能够提高企业全要素生产率。机制分析表明,人工智能技术创新能够催生新型劳动者、创造新型劳动资料和开发新型劳动对象,从而培育新质生产力,提升企业全要素生产率。异质性分析发现,在知识产权保护体系较为完善的地区、劳动密集型企业及具备较强吸收能力的企业中,人工智能技术创新的生产率效应更加明显。进一步分析表明,发明专利和实用新型类人工智能技术创新能有效提升企业全要素生产率,而外观设计类人工智能技术创新则未能有效提升生产率。

本文的结论具有如下政策含义:

第一,加大对企业人工智能技术创新的支持力度,构筑中国企业智能化竞争新优势。政府应加大财政支持与税收优惠力度,设立专项资金鼓励企业加大对人工智能技术研发的投入,并通过减税降费降低企业创新成本。夯实数字基础设施建设,系统优化算力基础设施布局,促进东西部算力高效互补和协同联动。同时要畅通数据资源大循环,构建国家数据管理体制机制,推动公共数据汇聚利用,释放商业数据价值潜能。优化人工智能创新环境,通过完善政策体系、打造创新产业园区和提供配套服务,营造适宜的创新生态。同时,加大对中小企业和初创企业的支持力度,通过融资服务、技术支持和政策扶持,激发更多企业参与人工智能技术创新的积极性。

第二,加强企业新质生产力的培育,提升企业综合竞争力。政府应通过税收减免、人才补贴、技能培训等方式激励企业引进高学历人才、培养复合型和技能型人才。同时支持高校与企业开展协同育人,构建面向人工智能领域的人才培养体系,提升企业人力资本质量。政府应通过财政补助、设备更新补贴等政策,降低企业数字化设备引进成本,加快智能制造装备、工业互联网与信息基础设施的导入进程。推动新型劳动资料与传统生产要素融合,提升生产系统的智能化与灵活性。推动数据基础设施的建设与完善,促进大数据、云计算等新型生产要素的广泛应用,增强生产系统的灵活性和适应性。

第三,加强知识产权保护体系建设,提升人工智能技术创新的保障水平。政府应进一步完善知识产权法律法规,加快人工智能相关专利的审批流程,提高知识产权保护的力度,对算法、模型架构、训练数据处理等关键技术领域建立更具针对性的保护规则,加大对侵权行为的处罚力度,提高企业侵权成本,增强创新主体的安全感与投入意愿,确保企业的创新成果得到有效保护。同时,推动省际执法协作和信息共享机制建设,减少地区间保护水平差异引发的制度套利问题,提高创新成果跨区域流动与扩散的安全性,形成统一、高效的创新保护环境。

第四,加强企业吸收能力建设,提升人工智能技术创新效能。政府应推动企业与高校、科研机构建立紧密合作关系,促进知识交流与技术转移,提升企业的知识获取和整合能力,提升企业的吸收能力。同时,政府可支持企业通过产学研合作、产业联盟、技术共享平台等方式接触更多外部技术知识资源。通过开放式创新模式,促进企业与供应商、客户及科研机构之间的知识交流和技术协同,从而提升技术吸收与再创新能力。构建开放的创新生态系统,支持中小企业获取先进技术资源,减少技术壁垒,促进广泛的技术应用与创新。企业应加快推进数据平台、信息系统与智能化基础设施建设,以增强数据获取、分析和应用能力,为吸收外部人工智能技术与实现技术融合提供基础条件。

## 参考文献:

- [1] 王文涛,修博文. 人工智能如何重塑劳动力市场:创造还是替代? [J]. 首都经济贸易大学学报,2025,27(6):67-81.
- [2] 戚聿东,杜博,温馨. 国有企业数字化战略变革:使命嵌入与模式选择——基于3家中央企业数字化典型实践的案例研究[J]. 管理世界, 2021,37(11):137-158.
- [3] 韩颖,许薛璐. 人工智能技术与人力资本结构升级:内在机理与经验检验[J]. 江西财经大学学报,2024(2):13-26.
- [4] BABINA T, FEDYK A, HE A, et al. Artificial intelligence, firm growth, and product innovation[J]. Journal of Financial Economics, 2024, 151: 103745.
- [5] 成琼文,朱婧丽. 人工智能应用如何提升制造企业韧性? [J]. 经济与管理研究,2025,46(8):56-75.
- [6] 吕越,马明会,陈泳昌,等. 人工智能赋能绿色发展[J]. 中国人口·资源与环境,2023,33(10):100-111.
- [7] 姚加权,张银澎,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.
- [8] 高杰英,周圣杰,周渡洋. 以智促效:人工智能赋能上游企业全要素生产率提升——基于供应链溢出视角的分析[J]. 北京工商大学学报(社会科学版),2025,40(6):16-28.
- [9] BRYNJOLFSSON E, COLLIS A. How should we measure the digital economy[J]. Harvard Business Review, 2019, 97(6): 140-148.
- [10] 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.
- [11] 陈楠,蔡跃洲. 人工智能、承接能力与中国经济增长——新“索洛悖论”和基于AI专利的实证分析[J]. 经济学动态,2022(11):39-57.
- [12] 黄勃,李海彤,刘俊岐,等. 数字技术创新与中国企业高质量发展——来自企业数字专利的证据[J]. 经济研究,2023,58(3):97-115.
- [13] 董直庆,姜昊,王林辉. “头部化”抑或“均等化”:人工智能技术会改变企业规模分布吗? [J]. 数量经济技术经济研究,2023,40(2):113-135.
- [14] 尹志锋,曹爱家,郭家宝,等. 基于专利数据的人工智能就业效应研究——来自中关村企业的微观证据[J]. 中国工业经济,2023(5):137-154.
- [15] 金星晔,左从江,方明月,等. 企业数字化转型的测度难题:基于大语言模型的新方法与新发现[J]. 经济研究,2024,59(3):34-53.
- [16] ACIKALIN U U, CASKURLU T, HOBERG G, et al. Intellectual property protection lost and competition: an examination using machine learning[Z]. NBER Working Paper No. 30671, 2022.
- [17] 刘青,肖柏高. 劳动力成本与劳动节约型技术创新——来自AI语言模型和专利文本的证据[J]. 经济研究,2023,58(2):74-90.
- [18] 张龙鹏,钟易霖. 价值链视角下人工智能应用对全要素生产率的影响——基于中国A股上市公司的实证研究[J]. 经济体制改革,2023(4):106-113.
- [19] HELO P, HAO Y. Artificial intelligence in operations management and supply chain management: an exploratory case study[J]. Production Planning & Control, 2022, 33(16): 1573-1590.
- [20] 杨仁发,李婷. 政府数据开放与企业新质生产力——来自政府数据公开平台上线的证据[J]. 首都经济贸易大学学报,2025,27(5):52-66.
- [21] 刘伟. 科学认识与切实发展新质生产力[J]. 经济研究,2024,59(3):4-11.
- [22] 韩文龙,张瑞生,赵峰. 新质生产力水平测算与中国经济增长新动能[J]. 数量经济技术经济研究,2024,41(6):5-25.
- [23] 张丹丹,于航,李力行,等. 中国人工智能技术暴露度的测算及其对劳动需求的影响——基于大语言模型的新证据[J]. 管理世界,2025,41(7):59-75.
- [24] ACEMOGLU D, AUTOR D, HAZELL J, et al. Artificial intelligence and jobs: evidence from online vacancies[J]. Journal of Labor Economics, 2022, 40(S1): S293- S340.
- [25] 张秀娥,王卫,于泳波. 数智化转型对企业新质生产力的影响研究[J]. 科学学研究,2025,43(5):943-954.
- [26] 徐浩,肖毅,祝志勇,等. 人工智能赋能新质生产力的机制与效用研究——基于生产力要素新质化的视角[J]. 当代财经,2025(4):84-96.
- [27] 贾若祥,王继源,窦红涛. 以新质生产力推动区域高质量发展[J]. 改革,2024(3):38-47.
- [28] 杜传忠,疏爽,李泽浩. 新质生产力促进经济高质量发展的机制分析与实现路径[J]. 经济纵横,2023(12):20-28.
- [29] 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.
- [30] 梁孝成,吕康银,陈思. 数据要素市场化对企业新质生产力水平的影响研究[J]. 科研管理,2025,46(2):12-21.
- [31] 沈坤荣,乔刚,林剑威. 智能制造政策与中国企业高质量发展[J]. 数量经济技术经济研究,2024,41(2):5-25.
- [32] LIU Y, DONG J Y, MEI L, et al. Digital innovation and performance of manufacturing firms: an affordance perspective[J]. Technovation, 2023, 119: 102-158.

## AI Technological Innovation and Corporate Total Factor Productivity

HE Xiaogang, GUO Xiaobin

(Jiangxi University of Finance and Economics, Nanchang 330013)

**Abstract:** As the core driver of Industry 4.0, artificial intelligence (AI) is advancing innovative applications at a pace far exceeding traditional technologies. It spans diverse fields and exerts a profound influence on various industries. Firms, as vital microeconomic entities, serve as the main force in AI technological innovation. As more firms invest in AI research and development, in-depth research on the impact of AI technological innovation on corporate total factor productivity (TFP) will yield crucial policy implications in fostering high-quality economic development in the era of intelligent transformation. This paper combines the cutting-edge Bidirectional Encoder Representations from Transformers (BERT) model in the AI field with patent abstracts to accurately identify AI technological innovation and examines its impact on corporate TFP.

The findings indicate that a 10% increase in AI technological innovation levels correlates with an approximate 8.2% rise in corporate TFP. Mechanism analysis reveals that AI technological innovation fosters new types of workers, creates novel means of production, and develops new objects of labor, thereby cultivating new quality productive forces and enhancing corporate TFP. Heterogeneity analysis further shows that the productivity effects of AI technological innovation are more pronounced in regions with robust intellectual property protection systems, labor-intensive firms, and firms with stronger absorption capabilities. Further analysis indicates that AI technological innovation in the form of invention and utility model patents effectively boosts corporate TFP, whereas that registered as design patents fails to yield significant productivity gains.

This paper makes three marginal contributions. First, it employs the BERT model to construct an AI technological innovation database for listed companies, enabling more rational and precise identification of firms' AI technological innovation levels and addressing existing literature gaps in recognizing emerging technologies. Second, it actively addresses concerns about the potential persistence of the Solow Paradox in the digital economy era and validates the productivity effects of AI technological innovation. Third, from the perspective of cultivating new quality productive forces, it enriches the transmission mechanisms through which AI technological innovation impacts corporate TFP, offering new theoretical insights into how AI technological innovation can empower high-quality development.

Based on these findings, this paper proposes the following policy recommendations: first, increase support for AI technological innovation to build new competitive advantages for firms in intelligent transformation; second, strengthen the cultivation of new quality productive forces within firms to enhance their overall competitiveness; third, reinforce the intellectual property protection system to enhance the safeguards for AI technological innovation; fourth, enhance firms' absorptive capacity to improve the effectiveness of AI technological innovation.

**Keywords:** AI technological innovation; total factor productivity; new quality productive forces; BERT model; patent text

编校:姜 菜