

人工智能与企业资产结构配置

许志勇^{1,2}, 甘 敏¹, 陈家威¹, 张 呈¹, 杨成宇¹

(1. 湖北经济学院 会计学院, 湖北 武汉 430205; 2. 湖北会计发展研究中心, 湖北 武汉 430205)

摘 要:在全球产业链智能化重组与产业数字化融合的双重变革背景下,人工智能正通过技术赋能和效率变革重塑企业的资产结构配置逻辑,成为企业资源配置的核心技术引擎。文章以 2009—2024 年 A 股上市公司为样本,探究了人工智能对企业资产结构配置的影响机制。研究发现,人工智能有助于抑制企业资产结构错配,推动资产结构合理配置。机制分析表明,人工智能通过抑制战略偏差、降低代理成本以及提升数字技术应用水平,抑制企业资产结构错配。异质性分析显示,对于所在地区产业转型升级程度和金融科技水平较高的企业,以及非“多言少行”、数字基础设施建设水平较高、数据资产较多或分析师关注度较高的企业,人工智能对资产结构错配的抑制作用更加明显。文章的研究为深入理解人工智能对资产结构配置的影响机制、提升人工智能应用效能、优化企业资产结构配置、助力企业高质量发展提供了经验证据和政策启示。

关键词:人工智能;资产结构配置;战略偏差;数字技术应用

中图分类号:F275;F830.9 **文献标识码:**A **文章编号:**1001-9952(2026)08-0079-16

DOI:10.16538/j.cnki.jfe.20260414.101

一、引 言

党的二十届四中全会明确提出“坚持把发展经济的着力点放在实体经济上,坚持智能化、绿色化、融合化方向”,并强调“加快高水平科技自立自强,引领发展新质生产力”。作为引领新一轮科技革命和产业变革的战略性技术,人工智能正深刻改变人类生产生活方式,其核心价值在于通过智能算法和海量数据分析,重塑生产要素的识别、匹配与利用模式,从而提升全要素生产率(师博, 2020)。人工智能凭借原创性、颠覆性的技术创新以及数据要素的赋能作用,推动传统生产力在技术形态、要素配置与产业格局层面发生根本性变革(张轩铭等, 2025)。作为革命性通用技术,人工智能已广泛渗透至工业及其他领域,重构企业资产结构配置的底层逻辑,逐步成为驱动技术创新的核心引擎。在此背景下,探究人工智能应用的经济后果对于塑造经济发展新动能、推动新质生产力发展具有重要意义。

企业资产结构配置的本质是持续的价值重构过程。从资源配置视角来看,资产结构配置既是企业资源配置的核心载体和主要体现,也是其战略方向的直接映射。有效的资产结构配置能

收稿日期:2025-08-27

基金项目:国家社会科学基金一般项目(22BGL032)

作者简介:许志勇(1971—),男,湖北武汉人,湖北经济学院会计学院教授,湖北会计发展研究中心主任;

甘 敏(2001—),女,广西贺州人,湖北经济学院会计学院硕士研究生;

陈家威(2001—),男,湖北黄冈人,湖北经济学院会计学院硕士研究生;

张 呈(1987—)(通讯作者),女,湖北襄阳人,湖北经济学院会计学院讲师;

杨成宇(2003—),男,湖北荆州人,湖北经济学院会计学院硕士研究生。

让有限资产创造最大产出,而资产结构错配则是对这一目标的偏离。企业高质量发展需要合理、高效的资产结构配置,优化资产结构已成为企业顺应政策导向、实现长远发展的必然选择。而当前企业普遍存在金融资产占比过高、原创性投资不足、迎合性创新投入偏高、战略偏离等资产结构错配问题,严重制约企业高质量发展。随着企业数字化转型的持续深化,人工智能应用已从生产环节逐步延伸至决策环节。凭借快速获取新知识、突破传统操作模式局限的能力,人工智能已成为优化企业资产结构配置的关键引擎。不过,人工智能的应用场景与模式仍较为传统,应用边界相对有限,尚未实现深度突破和全域赋能。因此,深入探究人工智能对企业资产结构配置的影响及其作用机制,不仅关乎企业数字化转型的成败,更是释放新质生产力潜能、推动经济高质量发展的核心议题。

现有研究主要聚焦于人工智能对宏观经济增长、产业结构升级、劳动力结构以及收入分配等方面的影响(柴正猛等, 2024; 赵儒煜和高明宇, 2024)。随着企业智能化转型的推进,相关研究逐步拓展至微观视角。在企业经营和金融资产配置领域,智能制造政策可显著提升企业研发效率(Li 和 Branstetter, 2024),这种提升作用通过信息化、人力资本和资金等多重路径实现(沈坤荣等, 2024)。此外,人工智能通过融资效应和技能升级效应推动企业进口扩张(辛大楞和邱悦, 2023),国家人工智能先导区政策也被证实对企业金融资产配置具有重要影响(冯婉昕, 2024)。在市场要素赋能方面,人工智能可显著提升企业新质生产力(陈凯鸣等, 2025)。随着企业数字化转型的深化,人工智能应用正从生产环节向研发环节扩展,在推动产业智能化发展的同时深刻影响企业创新行为(Damioli 等, 2021)。其底层逻辑在于,人工智能具有较强的知识溢出效应,能在多领域催生新技术和解决方案(王磊等, 2023)。在供应链优化管理方面,企业借助人工智能可实现智能化生产和供应链优化管理,为创新营造良好环境(张夏恒和肖林, 2024)。人工智能在实时数据处理中的应用还能帮助企业实时收集、处理和分析数据,为供应链运营提供智能化决策支持(武宪云等, 2024)。这推动了生产模式的智能化转变和精细化管理(Wan 等, 2021),促进了“全链路”各参与者的协同合作和资源共享(吴群和陈倩, 2024)。

现有文献从宏观层面探讨了人工智能的经济社会影响,并逐步深入至企业生产效率、进口扩张、金融资产配置以及创新行为等具体效应,但尚未系统揭示人工智能与企业资产结构配置的内在关联,仍存在进一步研究的空间。第一,现有实证研究虽表明人工智能能够提升企业效能,但缺乏对其优化资产结构配置的机制阐释及直接证据;第二,关于人工智能影响机制的现有研究尚未打开其作用于代理成本、战略偏差和数字技术应用的“黑箱”;第三,在人工智能驱动资产结构配置优化方面,现有研究缺乏对企业多维异质性特征的深入剖析。鉴于此,本文选取 2009—2024 年 A 股上市公司作为研究样本,探究人工智能应用对企业资产结构配置的影响,为深入理解人工智能赋能本质提供理论支撑和经验证据。

本文的研究贡献主要体现在:第一,拓展了人工智能经济后果的微观研究视角。现有相关文献多集中在宏观层面,或聚焦于企业生产效率、进口规模等单一绩效指标;即使涉及微观层面,也多局限于人工智能对企业效能的提升作用。本文以资产结构配置为关键切入点,提供了人工智能驱动企业优化资产结构配置的直接证据,为理解人工智能如何重塑企业运营提供了新视角。第二,本文丰富了人工智能赋能资产结构配置的机制研究。现有研究对人工智能影响资产结构配置的机制分析较为匮乏,尤其缺乏从企业战略决策与执行偏差层面的深入剖析。本文通过检验战略偏差、代理成本和数字技术应用的中介作用,打开了人工智能优化企业资产结构配置的“黑箱”,为深入理解人工智能重塑企业运营的深层机理提供了理论洞见。第三,本文揭示了人工智能赋能效应的异质性特征,为精准施策提供了依据。现有研究多关注人工智能的宏

观影响，微观层面鲜有文献探讨其在不同内外部环境下的差异化表现。本文考察了地区产业转型升级水平、企业数字基础设施建设水平、企业“多言少行”的人工智能应用特征、金融科技水平、数据资产规模以及分析师关注度等因素在人工智能影响资产结构配置过程中的差异化作用，这有助于精准识别政策与管理的着力点，更有效地推动企业资产结构合理配置，助力企业高质量发展。

二、理论分析与研究假设

（一）人工智能与企业资产结构配置

人工智能能够优化企业资产结构配置。人工智能是通过算法模拟人类智能的技术体系，能够实现数据驱动的自主决策和优化；企业资产结构配置则是对内部资金、技术、人力等要素的分配和调度过程，其核心目标在于实现资源的最优配置和价值最大化。两者的核心关联在于，人工智能通过对资源流动数据的深度分析和智能处理，为资产结构配置提供精准的决策依据和优化方案。内生增长理论表明，持续的技术革新是长期增长的核心动力。人工智能依托机器学习，通过算法迭代构建智能决策体系，推动管理决策、产品研发、制造和库存等流程的全面智能化，从而提升企业决策速度、降低成本并提高劳动生产率（姚加权等，2024）。劳动生产率的提升会释放冗余要素，并在人工智能的精准匹配下流向高效环节，从而实现资源的最优配置。

人工智能主要通过以下四个渠道发挥作用：第一，依托机器学习和逻辑推理能力，人工智能可解析历史数据，研判市场前景，指导企业合理规划产销节奏，从而降低库存水平，加速资产周转（师博，2020）。这一过程能盘活沉淀资金，推动资本从低效存货领域流向高回报的研发活动和轻资产运营环节，提升企业资产结构配置效率。第二，人工智能能够识别产业链中的投资信号，在逻辑推理支撑下优化战略布局和投资决策，提高投资效率和决策质量（张永坤和张萌，2025）。这有助于引导资本精准流向高附加值、轻资产环节，削减重资产冗余，从而提升资产结构配置效率。第三，人工智能技术可助力企业建立资产配置动态调整机制，提升监测效率。人工智能的可视化和智能识别系统能够实现对企业安全生产、仓储物流等环节的实时监测，快速捕捉生产环节动态信息，帮助企业快速响应市场变化，提升经营效率（刘鑫鑫和韩先锋，2023）。第四，人工智能能够使企业实时感知组织运行状态，敏捷应对内外部环境变动，从而优化资源配置并提升管理效率（沈坤荣和林剑威，2025）。经营效率和管理效率的提升能使企业动态优化资产组合，降低无效资产占比，并通过提高固定资产周转率和流动资产配置精准度，实现资产结构的最优配置。基于上述分析，本文提出以下假设：

假设 1：人工智能有助于优化企业的资产结构配置。

（二）战略偏差、代理成本与数字技术应用的中介作用

人工智能对企业资产结构配置的作用机制需要深入探究。从战略层面看，人工智能可通过抑制战略偏差来优化资产结构配置；从治理层面看，人工智能能通过强化监督等途径降低代理成本，推动管理者做出以企业价值最大化为目标的资产配置决策；从技术层面看，人工智能可驱动数字技术升级和应用场景深化，实现资产的精细化管理。基于此，本文选取战略偏差、代理成本和数字技术应用作为中介机制展开分析。

1. 战略偏差的中介效应。凭借大数据的实时感知能力、算法驱动的决策一致性特征以及闭环反馈下的自适应学习属性，人工智能能够有效抑制企业的战略偏差。一方面，基于组织学习理论，人工智能可通过系统的错误诊断和策略修正来抑制战略偏差。当管理层制定的战略出现偏差时，企业能够借助人工智能的组织学习与改进系统，以数智化手段为决策赋能（蔡思航和翁

翕, 2024)。该系统通过自动归因分析, 精准识别并纠正战略方案中的不合理环节。这一过程依托客观数据分析实现战略的动态优化, 推动企业决策向行业主流模式趋近, 从而有效抑制战略偏差。另一方面, 战略偏差源于管理层对行业外部环境的认知偏差(窦超等, 2023)。基于动态能力理论, 人工智能通过实时数据分析和自适应机制, 高效整合内外部多源信息, 缓解信息不对称问题。在此基础上, 结合客观全面的数据智能分析, 人工智能可有效弥合战略意图与执行行为之间的鸿沟, 为战略执行提供精准、情境化的支持, 从而抑制企业的战略偏差。

战略偏差会对资产结构配置产生影响。资产结构配置本质上是企业基于内外部环境对资产存量和增量投向进行动态决策的过程; 而战略偏差是指企业战略偏离行业常规路径的现象, 具有高度的不确定性。一方面, 战略偏差可能导致企业投入大量成本却无法达成生产经营目标, 造成资源浪费并最终影响企业绩效(陈雨欣和杨安, 2019)。这不仅会降低管理效率, 还会加剧资产结构错配。在实际生产经营中, 战略偏差会干扰企业对资源投入的精准判断, 导致局部领域过度投资和关键环节投入不足, 从而加剧资产结构错配。另一方面, 在战略执行过程中, 组织结构与战略类型不匹配、管理能力不足等现实因素容易导致战略执行偏离目标, 影响企业长期发展。这类执行偏差会使企业在资源配置时做出不符合战略目标的错误决策, 从而加剧资产结构错配。基于上述分析, 本文提出以下假设:

假设 2: 战略偏差在人工智能与资产结构配置之间发挥部分中介作用。

2. 代理成本的中介效应。根据委托代理理论, 委托人与代理人的目标分歧及信息不对称是代理成本的根源, 而人工智能可有效降低代理成本。一方面, 基于信息不对称理论, 人工智能凭借强大的数据挖掘与分析能力, 能够打破委托人与代理人之间的信息壁垒; 同时, 其通过为管理者提供决策支持、助力制定合理规划, 降低经营失误所导致的机会成本, 避免非理性行为(祁怀锦等, 2020), 并提升信息透明度, 从而降低代理成本。另一方面, 从委托代理目标冲突的视角来看, 人工智能通过自动化与标准化作业, 约束代理人因私利而偏离委托人目标的行为; 此外, 人工智能的应用能够提高信息披露、公司治理和监督制衡的科学性和精准度, 各治理环节借助数据挖掘分析提升管理效能, 从而降低代理成本(文雯等, 2025)。

代理成本会对资产结构配置产生影响。一方面, 根据经理效用模型, 经理人以个人效用最大化为首要目标, 代理成本可能诱使其倾向于选择高风险、高收益的项目, 偏离企业利益最大化目标。从投资视角来看, 代理问题可能引发管理层的权力寻租和过度投资行为。缓解代理问题有助于避免短视决策, 并通过合理研判市场投资状况分散经营与财务风险, 实现合理的资产结构配置。另一方面, 代理成本上升会加剧大股东与中小股东之间的利益冲突, 尤其当大股东“一股独大”或所有权与控制权高度分离时, 控股股东更有动机侵占公司资源(文雯和冯晓晴, 2024)。具体而言, 其一, 控股股东可能操纵资产配置以实现利益输送, 如低价转让优质资产、高价回购低质资产, 造成核心资产流失和资产质量下降; 其二, 控股股东可能引导企业将大量资金沉淀于与主营业务无关的股权投资或金融衍生品交易, 套取短期收益, 却忽视研发设备更新、核心技术迭代等长期投入(杜立和孙梦茹, 2025)。这会降低资产周转率和盈利能力, 加剧现金流波动, 导致资产结构错配。基于上述分析, 本文提出以下假设:

假设 3: 代理成本在人工智能与资产结构配置之间发挥部分中介作用。

3. 数字技术应用的中介效应。人工智能重塑了企业数字技术的应用模式, 推动其从被动工具升级为具有主动感知、决策与行动能力的智能数字中枢。一方面, 根据有限理性决策理论, 决策者受信息获取与认知能力的限制, 往往遵循“满意原则”而非“最优原则”。人工智能凭借多源数据抓取功能, 可实时整合宏观经济和行业竞争数据, 突破信息获取的时空局限(袁帅和于

翔, 2026)。这有助于缓解传统数字技术信息不全、响应滞后等问题, 弥补企业各层级在信息获取和认知方面的短板, 从而打破管理层和执行层的经验盲区, 推动企业认知和决策模式的数字化转型, 为数字技术应用筑牢基础。另一方面, 人工智能通过对海量实时数据的深度学习和动态优化(欧阳嘉文等, 2026), 将数字技术与生产运营、风险管控、资源配置等核心业务场景深度融合, 拓展其应用边界。这不仅能促进数字技术的普及与使用, 更能使其从辅助性工具转变为贯穿企业全流程的核心运营能力。

数字技术应用会对资产结构配置产生影响。一方面, 企业经营过程中的资产结构处于动态变化之中, 数字技术应用有助于构建数据驱动的内控体系, 及时识别人为操作失误和舞弊行为, 从而提升信息透明度(王欣然和朱国悦, 2026)。数字技术应用通过缓解信息不对称、约束管理层机会主义行为和非理性投资, 能够减少企业在低效资产、冗余产能以及高风险项目上的错配投入。另一方面, 数字技术作为企业转型的重要推动力, 可实现组织多维度升级(Hanelt 等, 2021), 引导企业加大对数据资产、知识产权、技术研发等轻资产、高知识密度领域的配置力度。在数字技术应用的信息治理和技术赋能双重作用下, 企业资产结构配置得以实现动态优化。基于上述分析, 本文提出以下假设:

假设 4: 数字技术应用在人工智能与资产结构配置之间发挥部分中介作用。

三、研究设计

(一) 样本选择与数据来源

本文以 2009—2024 年 A 股上市公司数据为研究样本, 考察人工智能对资产结构配置的影响。为确保研究结果的准确性和样本的客观性, 本文对数据进行如下处理: (1) 剔除金融类上市公司样本; (2) 删除变量缺失较多或主要变量存在缺失值的样本; (3) 剔除 ST 类公司及主要变量异常的样本; (4) 为避免异常值的干扰, 对主要连续变量进行上下 1% 的缩尾处理。本文最终得到 32 453 个观测值, 数据来自 CSMAR、Wind 和 EPS 等数据库。

(二) 模型构建

1. 基准回归模型。本文构建如下基准回归模型:

$$Misszc_{it} = \alpha_0 + \alpha_1 AI_{it} + \alpha_2 Controls_{it} + \sum Year + \sum Firm + \sum Ind + \varepsilon_{it} \quad (1)$$

其中, 被解释变量 $Misszc_{it}$ 表示资产结构错配, 解释变量 AI_{it} 表示人工智能应用水平, $Controls_{it}$ 表示控制变量。此外, 本文还控制了年份($Year$)、企业($Firm$)和行业(Ind)固定效应, 以排除不可观测因素的干扰。

2. 中介效应模型。较多研究指出, 传统三段式中介效应检验存在一定缺陷。为此, 本文参考牛志伟等(2023)的研究, 构建了四段式中介效应模型。在机制检验过程中, 本文通过引入被解释变量与中介变量的直接关系完善实证链条, 并采用 Bootstrap 方法检验间接效应的显著性; 同时, 考察解释变量通过中介变量对被解释变量的影响, 并参考许志勇和韩炳(2023)的研究, 依据 $\beta_1 \times \varphi_2$ 与 φ_1 相关系数符号来判断效应类型为中介效应或遮掩效应。

本文旨在构建一个既契合理论逻辑又具有实证严谨性的中介效应检验模型。基于这一目标, 本文在模型(1)的基础上构建如下模型:

$$Mediator_{it} = \beta_0 + \beta_1 AI_{it} + \beta_2 Controls_{it} + \sum Year + \sum Firm + \sum Ind + \varepsilon_{it} \quad (2)$$

$$Misszc_{it} = \theta_0 + \theta_1 Mediator_{it} + \theta_2 Controls_{it} + \sum Year + \sum Firm + \sum Ind + \varepsilon_{it} \quad (3)$$

$$Misszc_{it} = \varphi_0 + \varphi_1 AI_{it} + \varphi_2 Mediator_{it} + \varphi_3 Controls_{it} + \sum Year + \sum Firm + \sum Ind + \varepsilon_{it} \quad (4)$$

其中,解释变量和控制变量的定义及测度方式与基准回归模型一致,中介变量 $Mediator_{it}$ 具体包括代理成本(AC)、战略偏差($Strategy$)和数字技术应用($LNDTA$)。

(三)变量定义

1. 被解释变量。资产结构错配($Misszc$)反映企业资产配置结构与合理状态的偏离程度。本文采用资本边际产出法、行业偏差法和投资残差法三种测度方法,其中基准回归采用资本边际产出法,稳健性检验则采用行业偏差法和投资残差法。资本边际产出法借鉴 Hsieh 和 Klenow (2009)的资源配置效率分析框架,通过测算各企业资本边际产出相对于行业基准的离散程度来判断错配程度。在有效市场中,同行业内不同企业的同种资本边际产出应较为相近,若差异较大则表明存在错配。本文基于 Cobb-Douglas 生产函数构建指标。

$$Y_{it} = A_{it} L_{it}^{\alpha} \prod_K K_{kit}^{\beta_k} \quad (5)$$

其中, Y_{it} 表示营业收入, L_{it} 表示员工人数, K_{kit} 表示金融资产、固定资产、无形资产、应收账款和存货五类关键资产(许志勇等, 2024)。其中,金融资产包括交易性金融资产、衍生金融资产、债权投资、其他债权投资、其他权益工具投资、长期股权投资、其他非流动金融资产、投资性房地产、可供出售金融资产以及持有至到期投资。对式(5)取自然对数后,可得到线性回归模型。

$$\ln Y_{it} = \ln A_{it} + \alpha \ln L_{it} + \sum_k \beta_k \ln K_{kit} + \varepsilon_{it} \quad (6)$$

为避免零值问题,所有变量在取自然对数前均加 1,随后分行业、分年度进行 OLS 回归以估计产出弹性 $\hat{\beta}_k$,再据此计算各类资本的边际产出。

$$MRP_{kit} = \hat{\beta}_k \times \frac{Y_{it}}{K_{kit}} \quad (7)$$

以同行业同年度各类资本边际产出的中位数为基准,计算企业边际产出与基准之差的绝对值,再取五类资本偏离程度的均值,得到资产结构错配指标。其数值越大,表明错配越严重。

行业偏差法参考 Tang 等(2011)以及叶康涛等(2014)的研究,将企业金融资产、固定资产、无形资产、应收账款以及存货占总资产的比值,分别减去当年本行业该指标的均值,再除以标准差并取绝对值,最后对五个维度资产偏离度取均值,得到资产结构错配指标。理论上,以同年度行业均值作为单项资产基准,可避免极端资产结构配置的影响;同行业企业面临相似的条件和环境,有效资产配置存在趋同的合理区间,行业年度均值反映了多数企业的均衡配置状态。因此,以此为参照能有效捕捉单个企业因战略误判、管理低效等问题而导致的资产结构错配。该指标可全面刻画微观层面的资产结构错配,且控制了行业和年度特征,具有跨企业可比性。

投资残差法参考 Richardson(2006)通过实际投资率偏离最优投资率来识别企业过度投资的思路,并结合叶德珠等(2012)对异常消费率的研究,采用主要资产投资残差法衡量资产结构错配程度。具体步骤如下:第一步,选取资产规模、资产负债率、总资产报酬率、主营业务收入增长率、上市年份以及经营活动现金流量比率等变量,针对应收账款、存货、金融资产、固定资产、无形资产这五类资产进行线性拟合,以确定其最优或正常的配置占比;第二步,通过五个 OLS 回归分别估计各类资产占总资产比例的拟合值,计算实际占比与拟合值之间的残差;第三步,将所有残差相加取均值后取绝对值,得到整体的资产错配程度。

2. 解释变量。基于微观视角测度人工智能应用水平的主流方法可分为三类:一是专利法,通过人工智能相关专利的申请或授权数量和质量进行衡量(尹志锋等, 2023)。该方法虽能直接反映人工智能领域的应用深度,但无法完全反映技术的实际落地程度,也难以覆盖未申请专利

的人工智能技术应用场景。二是机器人投入法，以工业机器人、服务机器人等硬件设备的数量和密度为衡量依据(Babina 等, 2024)。但该方法无法涵盖算法、软件等无形层面的投入和应用情况。三是文本法，通过统计上市公司年报等公开信息中“人工智能”等关键词词频进行衡量(姚加权等, 2024)。李玉花等(2024)进一步将其划分为基于逻辑和基于学习的人工智能技术。本文借鉴姚加权等(2024)的思路，采用文本法，以“人工智能”等 73 个关键词匹配企业年报，据此衡量人工智能应用水平(*AI*)，数据来自 CSMAR 数据库。此外，考虑到专利法能较好地体现技术积累和应用深度，本文在稳健性检验中分别采用专利法和细分型词频法构建替代指标。

3. 中介变量。本文的中介变量包括战略偏差(*Strategy*)、代理成本(*AC*)和数字技术应用(*LNDTA*)。战略偏差指标的构建借鉴 Tang 等(2011)以及叶康涛等(2014)的研究，从广告强度、研发强度、资本密集度、固定资产更新程度、管理费用、财务杠杆六个维度展开，其中广告与研发支出分别以销售费用和无形资产替代。计算步骤如下：首先按行业年度均值对各维度指标进行调整，再除以行业标准差并取绝对值得到单维度偏离程度，最后对六个维度的偏离程度取均值，得到战略偏差指标。代理成本的衡量参考李文贵和余明桂(2015)的研究，采用管理费用与销售费用之和与营业收入的比值来衡量。数字技术应用则以 CSMAR 数据库中数字技术应用相关关键词的词频加 1 后取自然对数来衡量。

4. 控制变量。本文控制了企业财务、公司治理以及地区层面的特征，并控制了年份、企业与行业固定效应。本文主要变量定义见表 1。

表 1 主要变量定义

变量名称	变量符号	变量定义
资产结构错配	<i>Misszc</i>	采用资本边际产出法计算的偏离程度
人工智能应用水平	<i>AI</i>	人工智能词频数
代理成本	<i>AC</i>	经营费用率
战略偏差	<i>Strategy</i>	对六个指标处理后得到的战略偏差度指标
数字技术应用	<i>LNDTA</i>	$\ln(\text{数字技术应用词频数}+1)$
企业规模	<i>Size</i>	$\ln(\text{年末总资产})$
资产负债率	<i>LEV</i>	总负债/总资产
总资产净利率	<i>ROA</i>	净利润/总资产
上市年龄	<i>Listage</i>	$\ln(\text{观测年度}-\text{上市年度}+1)$
经营活动现金流量比率	<i>Cfo</i>	经营活动现金流量净额/总资产
固定资产比率	<i>Fixed</i>	固定资产净额/总资产
存货资产比率	<i>INV</i>	存货净额/总资产
应收账款占比	<i>REC</i>	应收账款净额/总资产
无形资产占比	<i>Intang</i>	无形资产净额/总资产
股权集中度	<i>TOP1</i>	第一大股东持股比例
股权制衡	<i>Balance</i>	第二至第五大股东持股/第一大股东持股
管理层持股比例	<i>Mshare</i>	管理层持股数/总股本
董事会规模	<i>Board</i>	$\ln(\text{董事会人数})$
董事会独立性	<i>Indep</i>	独立董事人数/董事会总人数
两职合一	<i>Dual</i>	董事长兼任总经理时取值为 1，否则为 0
经济发展水平	<i>LNAGDP</i>	$\ln(\text{地区人均生产总值})$
金融发展水平	<i>FDL</i>	地区金融机构存款余额/地区生产总值
一般公共预算收入	<i>GBRP</i>	一般公共预算收入/地区生产总值

四、实证结果分析

(一)描述性统计

主要变量的描述性统计结果显示,资产结构错配(*Misszc*)的最大值为 2.9448,最小值为 0.1410,均值为 0.8710,表明我国企业的资产结构错配程度存在较大差异。人工智能应用水平(*AI*)的最大值为 2.1357,最小值为 0,反映了不同企业的应用程度差异显著;其均值为 0.1018,处于中等偏低水平,中位数为 0 则表明人工智能应用水平的分布不均衡。控制变量的统计特征与已有研究结果相近。此外,本文在回归分析前通过方差膨胀因子(*VIF*)对各解释变量进行了多重共线性检验,结果显示所有变量的 *VIF* 值均小于 10,因此不存在多重共线性问题。

(二)基准回归分析

表 2 报告了基准回归结果。列(1)仅纳入了解释变量和被解释变量,并控制了企业固定效应;列(2)在列(1)的基础上加入了年度固定效应;列(3)在列(2)的基础上加入了控制变量;列(4)则在列(3)的基础上进一步控制了行业固定效应。结果显示,人工智能应用水平(*AI*)的回归系数在 1% 的水平上显著为负,表明人工智能能够有效优化企业资产结构配置,从而验证了假设 1。其内在逻辑在于:一方面,人工智能可通过数据分析实时捕捉企业资产流动状态,精准识别闲置或低效资产,推动资源向高产出领域转移;另一方面,其能优化供应链管理和生产计划,减少库存积压和过度投资,降低资产结构错配的发生概率。此外,人工智能辅助的风险评估模型可提升投资决策的科学性,避免因盲目扩张而导致的资产结构失衡,从而提升企业资产结构配置效率。

表 2 基准回归分析

	(1) <i>Misszc</i>	(2) <i>Misszc</i>	(3) <i>Misszc</i>	(4) <i>Misszc</i>
<i>AI</i>	-0.0604*** (-4.2092)	-0.0601*** (-4.0015)	-0.0497*** (-3.2904)	-0.0556*** (-3.6608)
<i>_cons</i>	0.8772*** (353.9589)	0.8772*** (352.5580)	2.4379*** (7.4687)	2.4553*** (7.5794)
<i>Controls</i>	未控制	未控制	控制	控制
<i>Firm</i>	控制	控制	控制	控制
<i>Year</i>	未控制	控制	控制	控制
<i>Ind</i>	未控制	未控制	未控制	控制
<i>N</i>	32453	32453	32453	32453
<i>adj. R²</i>	0.5275	0.5285	0.5324	0.5377

注:*,**和***分别表示10%、5%和1%的显著性水平,下同。

(三)内生性处理

1. 工具变量法。为解决逆向因果及遗漏变量问题,本文选取了两个工具变量:一个是同年度、同行业、同规模下除本企业外其他企业的人工智能应用水平均值(*IV1*);另一个是同年度、同省份、同行业下除本企业外其他企业的人工智能应用水平均值(*IV2*)。这两个变量受技术扩散与模仿效应影响,主要反映宏观趋势和行业共性,不会干预企业自身的资产结构调整,因而满足工具变量的相关性和外生性要求。检验结果显示,人工智能应用水平(*AI*)的回归系数显著为负,表明基准回归结论具有稳健性。

2. Heckman 两阶段模型。除了反向因果、遗漏变量所导致的内生性问题外,模型还可能存在自选择偏误。企业是否采纳人工智能技术并披露相关信息并非完全随机。为此,本文采用 Heckman 两阶段模型来解决样本自选择问题。在第一阶段,以同年度同行业人工智能应用水平的中位数为分组标准设定虚拟变量,将其作为被解释变量,并将同年度同省份内其他企业的人工智能应用水平均值(工具变量)作为外生解释变量纳入回归,计算逆米尔斯比(*IMR*);在第二阶段,将 *IMR* 纳入主回归。检验结果显示,人工智能应用水平(*AI*)的回归系数显著为负,基准结论依然成立。

3. 系统 GMM 模型。为缓解动态面板模型的内生性问题并降低弱工具变量风险,本文采用系统 GMM 方法检验上文结论的稳健性。检验结果显示,人工智能应用水平(*AI*)的系数显著为负,表明基准回归结论具有稳健性。

4. DID、PSM 和 PSM-DID 检验。为缓解遗漏变量偏误、政策作为解释变量所导致的内生性问题以及样本自选择偏误，本文采用双重差分法(DID)、倾向得分匹配法(PSM)以及 PSM-DID 模型展开分析。2019 年科技部发布的《国家新一代人工智能开放创新平台建设指引》为解决上述问题提供了准自然实验场景。本文以 2019 年为时间节点划分政策实施前后的阶段，使用双重差分法(DID)检验该政策对资产结构错配的影响。结果显示，政策交互项系数显著为负，表明该政策强化了人工智能对资产结构错配的抑制作用。为缓解样本自选择偏误等问题，本文进一步采用倾向得分匹配法(PSM)。参考张永坤等(2021)的研究，本文以人工智能应用水平的行业年度中位数为依据划分实验组和对照组，将高于中位数的样本赋值为 1，否则赋值为 0；同时，将基准回归的所有控制变量作为协变量，进行 1:4 近邻匹配。平衡性检验结果显示，匹配后各协变量的标准化偏差均低于 10%，t 检验未拒绝“处理组与控制组无系统差异”的原假设；与匹配前相比，各变量的标准化偏差显著缩小，表明协变量通过平衡性检验。平均处理效应(ATT)值为-6.72，表明在控制其他干扰因素后，人工智能应用水平对被解释变量的净效应具有统计显著性。此外，人工智能应用水平(AI)的系数显著为负，验证了研究结论的可靠性。PSM-DID 检验结果显示，政策交互项系数显著为负，进一步表明上述结论具有稳健性。

双重差分法需满足平行趋势假设，即政策实施前处理组与控制组的人工智能应用水平的变化趋势应保持一致。为此，本文参考王璐等(2020)的经典事件分析法，以政策颁布当年为基期，引入年份虚拟变量($time_t$)并与处理组虚拟变量($treat_i$)进行交互处理，具体模型设定如下：

$$AI_{it} = \alpha_0 + \sum_{t=-5}^5 \beta_t \times treat_i \times time_t + \alpha_1 Controls_{it} + \sum Year + \sum Firm + \sum Ind + \xi_t \quad (8)$$

检验结果显示，2019 年政策颁布前各回归系数均不显著，表明处理组与控制组的人工智能应用水平的变化趋势无显著差异；在政策颁布后，系数显著下降，这表明通过了平行趋势检验。

5. 模型调整。考虑到各省经济水平等因素的差异可能干扰估计结果，本文对回归模型的控制方式进行了调整。在基准回归的基础上，本文进一步引入省份固定效应、“年度×行业”固定效应以及“企业×省份”固定效应。检验结果显示，人工智能应用水平(AI)的系数始终显著为负，表明基准回归结果具有稳健性。

6. 聚类稳健标准误调整。本文在基准回归及其他回归模型中均采用稳健标准误，但同行业或同省份的企业可能受到共同冲击的影响。为此，本文将稳健标准误替换为不同维度的聚类稳健标准误进行检验。首先，在基准回归的基础上增加企业与行业层面的聚类；其次，在上述基础上进一步增加省份层面的聚类；再次，在基准回归的基础上分别增加“企业×省份”和“企业×行业”层面的聚类；最后，在基准回归的基础上增加“企业×行业×省份”层面的聚类。检验结果显示，人工智能应用水平(AI)的系数始终显著为负，表明基准回归结果具有稳健性。

(四)稳健性检验

1. 替换解释变量。为验证结论的稳健性，本文通过替换解释变量进行稳健性检验，具体如下：第一，将人工智能关键词在年报中的总出现次数加 1 后取自然对数，作为人工智能应用水平的衡量指标(AI1)；第二，参考姚加权等(2024)的研究，利用 Word2vec 技术和 Skip-gram 模型确定“人工智能”等 73 个关键词，通过文本分析方法将上市公司年报“管理层讨论与分析”部分的人工智能技术关键词数量作为替代变量(AI2)；第三，借鉴李玉花等(2024)的方法，以“机器学习”等为种子词，通过 Word2vec 技术和 Skip-gram 模型构建 AI 技术应用词库，将年报中 AI 技术关键词数量加 1 后取自然对数作为替代变量(AI3)；第四，借鉴许志勇和符佳歆(2026)的研究，以专利号分类为依据，将上市公司当年独立申请的人工智能发明与实用新型专利数量之和加 1

后取自然对数作为衡量指标(*AI4*)；第五，采用相同方法，将上市公司当年独立申请的人工智能发明专利数量加 1 后取自然对数作为衡量指标(*AI5*)；第六，采用相同方法，将上市公司及其子公司当年独立申请的人工智能发明与实用新型专利数量之和加 1 后取自然对数作为衡量指标(*AI6*)；第七，参考斯丽娟等(2025)的研究，以关键词分类为依据，将上市公司当年独立获得的人工智能发明、实用新型以及外观设计专利数量之和加 1 后取自然对数作为衡量指标(*AI7*)；第八，以关键词分类为依据，将上市公司及其子公司当年独立获得的人工智能发明、实用新型以及外观设计专利数量之和加 1 后取自然对数作为衡量指标(*AI8*)。检验结果显示，解释变量的系数均显著为负，表明基准回归结果具有稳健性。

2. 替换被解释变量。为控制核心变量的测量误差，本文通过替换被解释变量进行稳健性检验，具体如下：第一，在资本边际产出法的基础上，将金融资产类别从 10 类扩充至 15 类，形成新的资产结构错配衡量指标(*Misszc1*)。第二，采用偏差法衡量。参考 Tang 等(2011)以及叶康涛等(2014)的研究，本文先分别计算企业金融资产、固定资产、无形资产、应收账款以及存货与总资产的比值，再将各比值减去当年本行业该指标的均值，随后除以本行业各资产占比的标准差进行标准化处理并取绝对值，接着对各资产偏离程度取均值，最后除以 100 得到替代变量(*Misszc2*)，其中金融资产共 10 类。第三，在 *Misszc2* 的基础上，将金融资产类别从 10 类扩充至 15 类，得到新的衡量指标(*Misszc3*)。第四，采用残差法衡量。参考许志勇和韩炳(2023)的研究，本文通过 OLS 方法估计应收账款、存货、金融资产、固定资产和无形资产的占比，再计算残差，将所有残差相加并取均值，最后取绝对值得到替代指标(*Misszc4*)，其中金融资产共 15 类。检验结果显示，解释变量的系数均显著为负，基准回归结论保持稳健。

3. 删除特定样本。第一，剔除 2015 年股灾期间的样本，以尽可能排除相关干扰因素。第二，鉴于 2020 年新冠疫情全球暴发对中国各行业造成强烈冲击，删除 2020 年的样本。第三，同时剔除 2015 年和 2020 年的样本。第四，考虑到我国四个直辖市在经济、政治以及社会结构等方面与其他地区存在差异，进一步剔除直辖市样本，并删除 2015 年和 2020 年数据。检验结果显示，人工智能应用水平的回归系数依然显著为负，表明上述结论具有稳健性。

4. 排除其他竞争性解释因素。为排除其他竞争性解释因素的干扰，本文在模型中纳入企业数字化转型(*DAT*)、科技金融(*TF*)以及 ESG 表现(*ESG*)作为竞争性解释变量。具体测度方法如下：企业数字化转型水平的衡量参考赵宸宇等(2021)的研究，通过统计数字技术应用、互联网商业模式、智能制造、现代信息系统四个维度下 99 个数字化相关词频进行衡量；科技金融指标则借鉴倪宣明等(2025)的方法，从资源、经费、融资、产出四个维度选取指标后，采用熵值法测度并加权求和得到；ESG 表现的衡量参考周泽将和雷玲(2023)的研究，以华证 ESG 评级为依据，将上市公司由低到高划分为 C 至 AAA 九个等级并相应赋值 1 至 9，取四个季度评级均值作为年度 ESG 得分。检验结果显示，人工智能应用水平的系数依然显著为负，表明核心结论保持稳健。

(五)中介效应检验

1. 战略偏差。人工智能通过大数据分析和机器学习动态校准企业战略与市场环境的匹配度，有效规避信息滞后或认知偏差所导致的战略偏差，从而推动企业配置标准化资产，提升资产流动性，优化债务和股权比例，最终改善资产结构配置。表 3 列(1)显示，人工智能应用水平的回归系数显著为负；列(2)和(3)中战略偏差对资产结构错配的回归系数显著为正，模型间接效应乘积为-0.0088，与直接效应符号一致，表明战略偏差在人工智能影响资产结构配置的过程中发挥部分中介作用。Sobel Z 值为-2.679(在 1% 的水平上显著)，Bootstrap 抽样检验(500 次，下同)的置信区间为[-0.0156, -0.0012]且不包含 0。因此，假设 2 得到验证。

表 3 中介效应检验

	(1)Strategy	(2)Misszc	(3)Misszc	(4)AC	(5)Misszc	(6)Misszc	(7)LNDTA	(8)Misszc	(9)Misszc
AI	-0.0248** (-2.4002)		-0.0468*** (-3.2086)	-0.0211*** (-6.6590)		-0.0436*** (-2.8918)	0.9352*** (23.8722)		-0.0482*** (-3.1233)
Strategy		0.3554*** (31.7110)	0.3549*** (31.6522)						
AC					0.5702*** (12.3453)	0.5659*** (12.2266)			
LNDTA								-0.0100*** (-3.0954)	-0.0079** (-2.3804)
_cons	1.7692*** (7.5184)	1.8629*** (6.0297)	1.8274*** (5.9098)	0.7738*** (10.6933)	2.0479*** (6.3555)	2.0174*** (6.2552)	-1.9664*** (-3.9879)	2.4715*** (7.6457)	2.4399*** (7.5384)
Controls	控制	控制	控制	控制	控制	控制	控制	控制	控制
Firm、Year和Ind	控制	控制	控制	控制	控制	控制	控制	控制	控制
Sobel Z值	-2.679***			-7.139***			-2.422**		
Bootstrap检验置信区间	[-0.0156, -0.0012]			[-0.0158, -0.0078]			[-0.0131, -0.0012]		
N	32453	32453	32453	32453	32453	32453	32453	32453	32453
adj. R ²	0.5147	0.5616	0.5618	0.7698	0.5429	0.5430	0.6367	0.5376	0.5378

2. 代理成本。人工智能通过实时监控和数据分析缓解信息不对称,抑制管理层的机会主义行为以降低代理成本,从而推动企业优化资产结构配置。表 3 列(4)显示,人工智能应用水平的回归系数显著为负;列(5)和列(6)中代理成本对资产结构错配的回归系数显著为正,模型间接效应乘积为-0.0119,与直接效应符号一致,表明代理成本在人工智能影响资产结构配置的过程中发挥部分中介作用。Sobel Z 值为-7.139(在 1% 的水平上显著),Bootstrap 抽样检验的置信区间为[-0.0158, -0.0078]且不包含 0。因此,假设 3 得到验证。

3. 数字技术应用。人工智能通过深化数字技术应用优化企业资产结构配置,依托信息平台重构数字技术流程,提升技术运用效能;随着数字技术应用的持续深化,其通用性和赋能性渗透至企业资产运营全流程,推动存量资产盘活与增量资产优化之间形成良性循环。表 3 列(7)显示,人工智能应用水平的回归系数显著为正;列(8)和列(9)中数字技术应用对资产结构错配的回归系数显著为负,模型间接效应乘积为-0.0074,与直接效应符号一致,表明数字技术应用在人工智能影响资产结构配置的过程中发挥部分中介作用。Sobel Z 值为-2.422(在 5% 的水平上显著),Bootstrap 抽样检验的置信区间为[-0.0131, -0.0012]且不包含 0。因此,假设 4 得到验证。

(六)异质性分析

1. 地区产业转型升级。在产业转型升级程度较高的地区,企业能够依托完善的数字基建和政策体系,降低人工智能应用的成本,从而精准识别资产结构错配问题。借鉴陈焕等(2025)的研究,本文采用空间向量夹角法计算地区产业结构升级程度(*ISOU_S1*),并以中位数为界进行分组,将高于中位数的样本归为产业转型升级程度较高组。表 4 列(1)结果显示,人工智能对资产结构错配的抑制作用在产业转型升级程度较高地区的企业中更加明显。

2. 数字基础设施。作为人工智能的物理和算力载体,数字基础设施会影响其应用成本和协同效率,从而导致人工智能优化资产结构配置的效果存在差异。参考谢知非(2025)的研究,本文使用企业数字基础设施建设相关词频之和加 1 后取自然对数来衡量数字基础设施建设水平(*LNDIC*),并按行业—年度中位数进行分组,将高于中位数的样本归为数字基础设施建设水平较

高组。表 4 列(2)结果显示,人工智能对资产结构错配的抑制作用在数字基础设施建设水平较高的企业中更加明显。

3. 是否“多言少行”的企业。非“多言少行”的企业将资源实质性投入技术、设备和人才等领域,能够有效优化资产结构;而“多言少行”的企业仅依赖信息披露,实际投入不足,技术无法融入经营环节发挥正向作用,反而加剧资产结构错配。本文首先将人工智能相关资产与总资产的比值乘以 100,按行业-年度中位数进行分组,将大于中位数的样本归为人工智能应用较多组;其次,将年报中人工智能关键词数量加 1 后取自然对数,按行业-年度中位数进行分组,将大于中位数的样本归为人工智能披露较多组;最后,以“披露多”但“应用少”作为“多言少行”的衡量指标(*SAI*)。表 4 列(3)结果显示,人工智能对资产结构错配的抑制作用在非“多言少行”的企业中更加明显。

表 4 异质性分析

	(1) <i>Misszc</i>	(2) <i>Misszc</i>	(3) <i>Misszc</i>	(4) <i>Misszc</i>	(5) <i>Misszc</i>	(6) <i>Misszc</i>
<i>AI</i>	-0.0046 (-0.1784)	-0.0228 (-1.1107)	-0.0882*** (-5.2657)	-0.0162 (-0.6647)	-0.0231 (-0.9637)	-0.0356** (-2.0747)
<i>d_ISOU_S1</i>	-0.0123 (-1.4336)					
<i>d_ISOU_S1</i> × <i>AI</i>	-0.0646** (-2.3724)					
<i>d_LNDIC</i>		-0.0049 (-0.6314)				
<i>d_LNDIC</i> × <i>AI</i>		-0.0419** (-2.0192)				
<i>SAI</i>			0.0091 (1.1988)			
<i>SAI</i> × <i>AI</i>			0.0724*** (3.2548)			
<i>d_Fintech</i>				-0.0044 (-0.5678)		
<i>d_Fintech</i> × <i>AI</i>				-0.0477** (-2.1252)		
<i>d_DAS</i>					0.0037 (0.6536)	
<i>d_DAS</i> × <i>AI</i>					-0.0418* (-1.7764)	
<i>d_LNReport</i>						-0.0167*** (-2.7081)
<i>d_LNReport</i> × <i>AI</i>						-0.0425** (-2.4417)
<i>_cons</i>	2.3990*** (7.3860)	2.4527*** (7.5702)	2.4657*** (7.6100)	2.4431*** (7.5353)	2.4586*** (7.5868)	2.3693*** (7.2881)
<i>Controls</i>	控制	控制	控制	控制	控制	控制
<i>Firm</i> 、 <i>Year</i> 和 <i>Ind</i>	控制	控制	控制	控制	控制	控制
<i>N</i>	32453	32453	32453	32453	32453	32453
<i>adj. R²</i>	0.5378	0.5378	0.5380	0.5377	0.5377	0.5380

4. 金融科技水平。金融科技水平较高的省份，其数字信贷与智能风控体系更加完善，可有效缓解企业融资约束和信息不对称问题，为人工智能技术落地提供资金支持，助力企业通过智能化手段纠正资产结构错配。参考宋敏等(2021)的方法，本文从天眼查平台获取金融科技相关企业信息，剔除经营异常及存续期不足一年的样本；同时，通过正则表达式匹配企业经营范围中的金融业务，并排除含否定字段的企业，最终以各省每年新增金融科技数量加1后取自然对数来衡量省级金融科技水平(*Fintech*)，并按中位数进行分组。表4列(4)结果显示，人工智能对资产结构错配的抑制作用在金融科技水平较高省份的企业中更加明显。

5. 数据资产。数据资产较多的企业拥有高质量的数据基础，能为人工智能提供充足的训练样本和实时反馈数据，使模型得以精准识别资产冗余与资产结构错配问题。参考许志勇等(2025)的方法，本文以“数据”为种子词构建相似词集，以总词频衡量企业数据资产水平(*DAS*)，并按年度一行业中位数进行分组，将大于中位数的样本归为数据资产较多组。表4列(5)结果显示，人工智能对资产结构错配的抑制作用在数据资产较多的企业中更加明显。

6. 分析师关注。分析师关注度较高的企业信息透明度更高、外部监督较强，有助于市场充分解读人工智能的价值，缓解信息不对称，确保人工智能在资源配置中发挥实际效能；而分析师关注度较低的企业信息透明度不足、外部监督较弱，技术优化的效能难以充分释放。参考潘越等(2011)的研究，本文使用同一家上市公司的分析师研报数量加1后取自然对数来衡量分析师关注度(*LNReport*)，并按中位数进行分组，将大于中位数的样本归为分析师关注度较高组。表4列(6)结果显示，人工智能对资产结构错配的抑制作用在分析师关注度较高的企业中更加明显。

五、结论与政策建议

人工智能正深度重塑企业资产结构配置逻辑，成为推动产业智能化升级和高质量发展的关键驱动力。本文以2009—2024年中国A股上市公司为样本，考察了人工智能对资产结构配置的影响及作用机制。研究发现：第一，人工智能有助于抑制企业资产结构错配，促进资产结构合理配置；第二，人工智能可通过抑制企业战略偏差、降低代理成本以及提升数字技术应用水平，优化企业资产结构配置；第三，人工智能对企业资产结构配置的优化作用在产业转型升级程度较高、金融科技水平较高地区的企业，以及非“多言少行”、数字基础设施建设水平较高、数据资产较多、分析师关注度较高的企业中更加明显。基于上述结论，本文就如何借助人工智能优化企业资产结构配置提出以下建议：

第一，精准布局人工智能应用，构建智能化管理体系。政府应加大知识资源共享力度，搭建人工智能技术应用推广平台，助力企业快速吸收前沿知识，提升技术转化能力；同时，制定长期支持政策，整合产学研资源，为中小企业提供低成本人工智能解决方案，降低应用门槛，推动全行业资产结构配置优化。企业需主动加大人工智能投入，引入专业系统和人才，实现对各类资产的动态梳理和配置效率评估，实时优化资产配置状态，助力企业实现高质量发展。

第二，优化内在驱动机制，提升资产结构配置精度。企业可从以下维度着力：首先，借助人工智能精准研判行业趋势和自身核心竞争力，减小战略偏差，确保资产配置方向合理。其次，引入智能监控系统并优化治理结构，实现决策全流程可追溯，减少管理层的机会主义行为，降低代理成本。最后，加快数字技术与资产运营全流程的深度融合，搭建智能化运营平台，通过人工智能拓展技术应用场景，提升数字技术赋能资产结构配置的效率。

第三，聚焦主体差异导向，释放资产结构配置综合价值。结合人工智能赋能的差异化特征，实施精准化策略。首先，针对产业转型升级程度较高、金融科技水平较高的地区，政府应重点布

局人工智能基础设施,出台专项政策推动产业链协同,借助人工智能优化资产配置,形成集聚效应。其次,强化人工智能领域“多言少行”企业的执行力,聚焦数字基建水平较高、数据资产丰富的企业,鼓励其发挥示范作用,打造标杆案例,提炼可复制经验并向全行业推广。最后,对于分析师关注度较高的企业,引导其完善治理结构、提升信息披露质量,强化人工智能应用优势;对于分析师关注度较低的企业,则建议先夯实内部治理与数据基础,逐步引入人工智能,优化治理结构,提升经营透明度和市场信心,为人工智能技术应用创造良好环境。

参考文献:

- [1]蔡思航,翁翕.一个数据要素的经济学新理论框架[J].财经问题研究,2024,(5):33-48.
- [2]柴正猛,张培铎,韩先锋.工业智能化能成为产业结构升级的新动能吗[J].科技进步与对策,2024,(19):56-66.
- [3]陈焕,梁沐晗,尤欣赏,等.新质生产力与产业链韧性:基于因果森林算法的处理效应分析[J].中国软科学,2025,(S1):38-48.
- [4]陈凯鸣,黄庆华,时培豪.人工智能应用驱动企业新质生产力涌现——来自中国上市公司的微观证据[J].科研管理,2025,(4):34-43.
- [5]陈雨欣,杨安.战略的偏差及其矫正策略研究[J].中国市场,2019,(28):74-75.
- [6]窦超,杨雪,原亚男.冲动是魔鬼?高管情绪化与企业过度投资[J].中国会计评论,2023,(3):479-522.
- [7]杜立,孙梦茹.地方政府债务管理体制改革的与实体经济影子银行活动[J].经济学动态,2025,(10):95-114.
- [8]冯婉昕.人工智能与企业金融资产配置——来自国家人工智能创新应用先导区的经验证据[J].当代财经,2024,(4):141-152.
- [9]李文贵,余明桂.民营化企业的股权结构与企业创新[J].管理世界,2015,(4):112-125.
- [10]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.
- [11]刘鑫鑫,韩先锋.人工智能与制造业韧性:内在机制与实证检验[J].经济管理,2023,(11):48-67.
- [12]倪宣明,周祖强,姜淼,等.科技金融对技术创新的空间溢出效应研究[J].系统工程理论与实践,2025,(6):1729-1744.
- [13]牛志伟,许晨曦,武瑛.营商环境优化、人力资本效应与企业劳动生产率[J].管理世界,2023,(2):83-100.
- [14]欧阳嘉文,梅国平,何珏,等.人工智能赋能企业高质量发展[J].当代财经,2026,(5):19-31.
- [15]潘越,戴亦一,林超群.信息不透明、分析师关注与个股暴跌风险[J].金融研究,2011,(9):138-151.
- [16]祁怀锦,曹修琴,刘艳霞.数字经济对公司治理的影响——基于信息不对称和管理者非理性行为视角[J].改革,2020,(4):50-64.
- [17]沈坤荣,林剑威.人工智能赋能产业变革的机制与推进路径[J].经济纵横,2025,(1):55-65.
- [18]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,(2):5-25.
- [19]师博.人工智能助推经济高质量发展的机理诠释[J].改革,2020,(1):30-38.
- [20]斯丽娟,辛雅儒,王超群.人工智能发展对劳动力职业选择的影响研究——基于政府与企业部门的视角[J].上海经济研究,2025,(7):51-66.
- [21]宋敏,周鹏,司海涛.金融科技与企业全要素生产率——“赋能”和信贷配给的视角[J].中国工业经济,2021,(4):138-155.
- [22]王磊,肖倩,邓芳芳.人工智能对中国制造业创新的影响研究——来自工业机器人应用的证据[J].财经论丛,2023,(9):14-24.
- [23]王璐,吴群峰,罗頔.市场壁垒、行政审批与企业价格加成[J].中国工业经济,2020,(6):100-117.
- [24]王欣然,朱国悦.同行数字化转型、信息溢出和企业生产率增长[J].经济学报,2026,(1):123-137.

- [25]文雯,冯晓晴.多个大股东并存与股票异常停牌[J].会计研究,2024,(3):65-79.
- [26]文雯,肖瑶,牛煜皓.人工智能技术水平与企业投资效率[J].经济管理,2025,(6):103-122.
- [27]吴群,陈倩.基于智能制造的新质生产力形成逻辑与跃迁路径研究[J].当代财经,2024,(9):3-12.
- [28]武宪云,苏敬勤,杨道虹,等.数字技术可供性实现下的数字化转型企业组织惯性构建机制研究[J].科研管理,2024,(5):34-42.
- [29]谢知非.外生冲击力度、政府帮扶与盈余管理[J].会计研究,2025,(2):49-62.
- [30]辛大楞,邱悦.人工智能对进口扩张的影响研究:来自中国微观企业层面的证据[J].世界经济研究,2023,(11):11-25.
- [31]许志勇,艾万谋,甘敏,等.数据资产与企业风险承担:促进还是抑制?[J].系统工程理论与实践,2025,(11):3641-3670.
- [32]许志勇,符佳歆.科技金融与企业资产配置:资产结构错配视角[J].财会月刊,2026,(17):47-53.
- [33]许志勇,韩炳.资产结构错配与企业高质量发展——技术创新与融资约束的中介效应[J].系统工程理论与实践,2023,(10):2881-2907.
- [34]许志勇,王瑾,张娜,等.资产结构错配、激励机制与企业二元创新[J].南开管理评论,2024,(3):106-119.
- [35]姚加权,张锬澎,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,(2):101-116,133.
- [36]叶德珠,连玉君,黄有光,等.消费文化、认知偏差与消费行为偏差[J].经济研究,2012,(2):80-92.
- [37]叶康涛,张姗姗,张艺馨.企业战略差异与会计信息的价值相关性[J].会计研究,2014,(5):44-51.
- [38]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.
- [39]袁帅,于翔.相得益彰:人智协同如何影响企业投资效率?[J].外国经济与管理,2026,(8):21-38.
- [40]张夏恒,肖林.数字化转型赋能新质生产力涌现:逻辑框架、现存问题与优化策略[J].学术界,2024,(1):73-85.
- [41]张轩铭,陆彬,王振华,等.企业人工智能战略退出是否抑制了新质生产力?——基于PSM-多时点DID的实证研究[J].财经论丛,2025,(1):92-105.
- [42]张永坤,李小波,邢铭强.企业数字化转型与审计定价[J].审计研究,2021,(3):62-71.
- [43]张永坤,张萌.人工智能如何影响企业劳动收入份额?——基于人力资本结构调整和资源配置效率视角[J].经济经纬,2025,(3):106-119.
- [44]赵宸宇,王文春,李雪松.数字化转型如何影响企业全要素生产率[J].财贸经济,2021,(7):114-129.
- [45]赵儒煜,高明宇.工业智能化如何影响劳动力技能结构[J].财经科学,2024,(2):107-118.
- [46]周泽将,雷玲.营商环境优化与企业ESG表现[J].厦门大学学报(哲学社会科学版),2023,(5):43-56.
- [47]Babina T, Fedyk A, He A, et al. Artificial intelligence, firm growth, and product innovation[J]. Journal of Financial Economics, 2024, 151: 103745.
- [48]Damioli G, Van Roy V, Vertesy D. The impact of artificial intelligence on labor productivity[J]. Eurasian Business Review, 2021, 11(1): 1-25.
- [49]Hanelt A, Bohnsack R, Marz D, et al. A systematic review of the literature on digital transformation: Insights and implications for strategy and organizational change[J]. Journal of Management Studies, 2021, 58(5): 1159-1197.
- [50]Hsieh C T, Klenow P J. Misallocation and manufacturing TFP in China and India[J]. The Quarterly Journal of Economics, 2009, 124(4): 1403-1448.
- [51]Li G W, Branstetter L G. Does “Made in China 2025” work for China? Evidence from Chinese listed firms[J]. Research Policy, 2024, 53(6): 105009.

- [52]Richardson S. Over-investment of free cash flow[J]. *Review of Accounting Studies*, 2006, 11(2-3): 159-189.
- [53]Tang J Y, Crossan M, Rowe W G. Dominant CEO, deviant strategy, and extreme performance: The moderating role of a powerful board[J]. *Journal of Management Studies*, 2011, 48(7): 1479-1503.
- [54]Wan J F, Li X M, Dai H N, et al. Artificial-intelligence-driven customized manufacturing factory: Key technologies, applications, and challenges[J]. *Proceedings of the IEEE*, 2021, 109(4): 377-398.

Artificial Intelligence and Firms' Asset Structure Allocation

Xu Zhiyong^{1,2}, Gan Min¹, Chen Jiawei¹, Zhang Cheng¹, Yang Chengyu¹

(1. *School of Accounting, Hubei University of Economics, Wuhan 430205, China;*

2. *Hubei Accounting Development Research Center, Wuhan 430205, China)*

Summary: Under the dual background of global industrial chain intelligent restructuring and industrial-digital integration, artificial intelligence (AI) is reshaping the logic of corporate asset structure allocation and has become a core engine driving micro-level resource allocation. However, existing literature lacks systematic evidence on how AI affects corporate asset structure misallocation, especially the internal transmission mechanisms and heterogeneous conditions.

Using a sample of China's A-share listed companies from 2009 to 2024, this paper empirically examines the impact of AI on corporate asset structure allocation. The core explanatory variable is the AI application level measured by text analysis of annual reports, and the dependent variable is asset structure misallocation measured by the marginal product of capital deviation method. The results show that AI significantly reduces corporate asset structure misallocation, with an economic magnitude of 6.38% of the sample mean, indicating that AI helps firms allocate assets more reasonably. Mechanism testing shows that AI alleviates asset structure misallocation through three pathways: suppressing strategic deviation, lowering agency costs, and enhancing digital technology application. Heterogeneity analysis reveals that the mitigating effect of AI on asset structure misallocation is more pronounced in firms located in regions with higher levels of industrial transformation and Fintech development, as well as in firms with higher digital infrastructure, more data assets, and higher analyst attention, and those characterized by "less talk but more action" in AI adoption.

The marginal contributions of this paper are as follows: First, it enriches the micro-level research on the economic consequences of AI by directly linking AI to corporate asset structure optimization. Second, it opens the black box of internal mechanisms from the perspectives of strategic deviation, agency costs, and digital technology application. Third, it offers nuanced heterogeneous evidence to guide targeted policies. Based on these findings, policy recommendations include that governments should build AI application promotion platforms and provide low-cost solutions for SMEs, that firms should proactively integrate AI into asset management and reduce strategic bias, and that policies should prioritize regions and firms with favorable conditions while helping laggards strengthen digital foundations.

Key words: AI; asset structure allocation; strategic deviation; digital technology application

(责任编辑 康 健)