

引用格式:王玉燕,唐辰新.智能制造如何提升企业碳全要素生产率?——基于要素投入成本与结构的视角[J].技术经济,2025,44(7):76-92.

Wang Yuyan, Tang Chenxin. How can intelligent manufacturing improve the carbon total factor productivity of enterprises: From the perspective of factor input cost and structure[J]. Journal of Technology Economics, 2025, 44(7): 76-92.

智能制造如何提升企业碳全要素生产率?

——基于要素投入成本与结构的视角

王玉燕,唐辰新

(安徽大学经济学院,合肥 230601)

摘要:党的二十大报告强调要推动制造业高端化、智能化、绿色化发展。本文基于 GML-SBM 模型和 SBM-DDF 模型测算了 2012—2022 年制造业 A 股上市公司的碳全要素生产率,从投入和应用两个方面探究智能制造提升企业碳全要素生产率的效应和渠道。结果发现,智能制造能显著提高企业碳全要素生产率,且技术效率变动是主要驱动力;智能制造主要通过要素成本和要素结构渠道,即降低资本、劳动使用成本和促进资本深化、提高资本产出效率四条路径提升企业碳全要素生产率;对年轻企业和非国有企业、处在竞争程度较高行业和技术密集型行业的企业、处在知识产权保护程度较高地区及工业基地的企业,智能制造的作用效果更强。研究结果为智能制造战略的实施和“双碳”目标的实现提供了政策启示,对制造业企业的智能化转型具有重要参考意义。

关键词:智能制造;碳全要素生产率;要素投入;要素成本;要素结构

中图分类号: F424.6 **文献标志码:** A **文章编号:** 1002-980X(2025)07-0076-17

DOI: 10.12404/j.issn.1002-980X.J24061401

一、引言

随着工业化与城镇化进程的加快,二氧化碳等温室气体排放量急剧增长,温室效应、气候变化已经成为全球性问题。《碳达峰碳中和标准体系建设指南(2023)版》中提出到 2025 年,基本建立工业领域碳达峰碳中和标准体系,推动工业领域深度减碳,引导相关产业低碳高质量发展,为“双碳”目标的攻坚确立了重点方向。当前,中国正处在“双碳”目标的攻坚期、产业技术革命追赶期及制造业绿色转型关键期,碳排放的主要来源是能源消耗和工业生产活动,制造业是能源消耗和工业生产活动的重要主体,因此,制造业企业节能减排效果直接影响着“双碳”目标的实现。然而,以牺牲经济效益为代价换取的减排成果并不会带来绿色技术创新,也无益于生产效率的提升^[1]。基于此,同时考虑期望产出和非期望产出的碳全要素生产率指标能够较为准确地衡量企业减排增效的水平,对研究制造业绿色转型发展具有重要参考价值。

从 20 世纪末开始,智能制造作为一种全新的制造业战略发展模式开始在全球范围内孕育和兴起。智能制造是指以工业机器人为典型代表的具有信息深度自感知、智慧优化自决策、精准控制自执行等功能的先进制造过程、系统与模式的总称,其贯穿于企业管理、生产、服务等制造活动的各个环节。中国智能制造战略实施起步相对较晚,但有奋起直追的趋势,如《智能制造发展规划(2016—2020 年)》和《智能制造发展规划(2021—2025 年)》分别于 2016 年和 2020 年发布。作为一种全新的产业数字化驱动要素,智能制造的应用必然会引起企业内部生产经营模式的变革,进而对企业的生产效率、经济效益和节能减排等产生影响,推动企业实现绿色转型。因而,研究智能制造与制造业绿色转型的关系对于中国实现“双碳”目标至关重要,有助于推动工业领域深度减碳,促进产业低碳高质量发展。

收稿日期:2024-06-14

基金项目:国家社会科学基金“‘双循环’新格局下制造业高质量发展的驱动机制、效果测度及提升策略研究”(21CJY050)

作者简介:王玉燕(1988—),博士,安徽大学经济学院副教授,博士研究生导师,研究方向:产业升级与产业政策;唐辰新(1999—),安徽大学经济学院硕士研究生,研究方向:数字经济与制造业高质量发展。

二、文献综述

已有相关研究主要从以下几个方面探讨“双碳”目标下智能制造如何影响制造业企业碳全要素生产率。一方面,对于智能制造影响效果的研究,主要集中在经济增长^[2]、劳动力就业结构的转变^[3]和制造业价值链分工的优化^[4]等方面,如人工智能通过促进技术创新、优化资源配置等提升制造业价值链参与程度和分工地位,其中对劳动力配置效率的促进作用更为明显^[4]。也有研究表明智能制造能够显著提升企业全要素生产率^[5],降低企业碳排放强度、减少排放量^[6],为智能制造助力制造业高质量发展提供了经验证据。另一方面,关于碳全要素生产率的影响因素研究,主要包括环境政策不确定性^[7]、价值嵌入^[8]和低碳技术创新^[9]等。也有文献证实了人工智能在地区层面^[10]对绿色全要素生产率的提升作用;发现了智能制造行业的绿色全要素生产率存在正向的时空演变规律^[11],为智能制造助力企业绿色转型发展提供了间接经验支撑。在智能制造对企业绿色全要素生产率的影响研究中,有学者利用上市公司年报文本分析刻画智能制造实施意愿,发现智能制造通过促进绿色技术进步和提高绿色技术效率提升企业绿色全要素生产率^[12]。也有学者以智能制造试点政策为准自然实验,发现了智能制造提升企业碳全要素生产率的人力资本结构优化路径^[13]。此外,还有研究认为智能制造的推广能有效抑制企业成本黏性,提高资本要素使用效率^[14];工业智能化重塑了劳动力就业结构^[3],使其出现“两极化”特征。同时,要素投入结构的转变和效率的优化提高了产业创新绩效^[15],推动了绿色低碳技术创新,从而显著提升企业绿色全要素生产率。综上,现有文献虽然为智能制造提升企业碳全要素生产率提供了间接和直接的经验证据,但缺乏基于要素投入视角的机制探讨,也没有将对智能制造的衡量落在投入力度和应用效果维度上。

鉴于此,本文基于要素投入的视角,探究智能制造对制造业企业碳全要素生产率的影响。可能的边际贡献包括:第一,以制造业 A 股上市公司为样本,实证探究智能制造对企业碳全要素生产率的影响效果及作用机制,为智能制造促进制造业高质量发展提供了直接经验证据;第二,在能源消耗和碳排放两个指标中采用微观企业数据,利用全局参比的超效率松弛变量模型(global Malmquist Luenberger-super slack-based measure, GML-SBM)和基于松弛变量的方向距离函数模型(slack-based measure-directional distance function, SBM-DDF)测算了制造业 A 股上市公司的碳全要素生产率,丰富了企业绿色全要素生产率研究的数据体系;第三,研究结论对“智能制造试点示范项目”的实施和推广,以及制造业企业的绿色转型发展提供重要启示。

三、理论机制与研究假设

(一) 影响效应

1. 智能制造对碳全要素生产率的影响

传统制造模式中,高资本和高能源投入是企业生产经营的主要特征,这种粗放型的增长方式通过资本投入的转移机制引发了制造业的“资源诅咒”^[16],既不利于经济增长,也造成了资源浪费和环境破坏。作为一种以人、机、网高度融合为突出表现的全新生产经营模式,智能制造深刻影响了企业的投入产出管理,通过生产、研发和营销体系的数据联通,赋能制造业企业技术创新^[17];通过资源趋同和资源共享实现了生产率的追赶与超越^[18];通过赋能产业升级降低碳排放^[19],促进了资本、技术、人才等要素资源的充分流动流,重塑了价值链的运作模式,从而提升企业碳全要素生产率。

2. 智能制造对技术效率变动和技术进步变动的影响

碳全要素生产率可被分解为技术效率变动和技术进步变动两种效应。其中,前者是指在技术水平不变的情况下,通过优化要素投入组合发挥出更大的效率潜力;后者是指在要素投入数量和组合不变的情况下,提高单位要素投入的产出,扩张生产函数的外沿。智能制造本身是一种技术效率和技术进步的体现,但在作用于中国传统制造业发展模式时,还存在着“重效率”而“轻技术”的困境;随着制造业服务化的发展,企业往往采用整体外包的形式进行智能化改造,由于专业人才的缺乏和技术积累的局限,智能系统与生产线的结合并不充分,智能化改造的效果往往没有直接作用于生产要素,而是通过流程控制和人员管理等渠道间接影响生产要素的使用,因此,对生产效率的优化还停留在前沿追赶而不是外延扩张。一方面,由于智能制

造影响企业生产经营的主要着力点在于对生产管理过程的优化而非技术或工艺的改进^[20],因而,能够通过产销合一提升企业产能利用率,优化生产要素的使用效率^[21]。同时通过加强资源掌控提升企业韧性,增强应对重大生产经营调整的能力^[22],从而有效驱动技术效率变动。另一方面,中国智能制造起步相对较晚,企业进行智能化改造会挤占原料能源替代、核心工艺改造、产品迭代升级等技术创新活动所需的资金、人力等资源;国产智能制造产品和系统存在关键零部件受制于人、高端市场面临外资围困等瓶颈^[23],且重“高端设备”轻“软件支持”的改造模式也使智能工厂成为“信息孤岛”,阻碍技术与管理的深度融合^[24],从而对技术进步产生一定抑制作用。

(二) 作用机制

1. 要素成本渠道

智能制造通过改变资产利用方式,提高资产利用效率,降低了资本要素使用成本。智能设备投入是制造业智能化的基础。一方面,在传统制造模式中,企业建成的厂房及生产设备一旦完工并投入使用,就成为专用性资产,很难挪作他用,直接增加成本黏性^[25]。而在智能制造模式中,生产线经过智能评估并扩大兼容性,只需简单调整便可适应新产品的生产需求,使企业既可以利用现有成熟生产线进行大规模生产,又可以及时按需进行调整,满足客户个性化定制需求^[26],从而大大降低了资产专用性,有效抑制成本黏性。另一方面,在传统制造模式中,生产设备和生产线维护与维修成本较高,机器单元的运行效率较低。而智能制造能够将自动化生产与人类专家的智慧 and 能动性高度结合,让机器设备自动形成最佳的组织结构^[27],提高生产线效率。随着资本要素使用成本的降低,企业在面临能源价格波动和环境规制政策的约束时将更有动力选择以节能、高效的生产设备及工艺替代高耗能、高污染的落后产能。同时,更有余力加强对污染排放末端治理设施的投资力度,最终表现为以增加资本投资的方式节约能源使用和降低污染排放水平^[28],从而形成对能源要素的替代,提升碳全要素生产率。

智能制造能够激发新的运营模式及简化管理流程,从而有效降低劳动要素使用成本。软件技术开发与应用是制造业智能化提升的关键,软件智能化升级能够优化企业运营管理模式。在传统运营管理模式中,人员协作形式往往呈“金字塔”型分布,这种高度依赖于“人治”的管理模式因为信息不对称而产生了如盈余管理^[29]和激励扭曲^[30]等问题,容易造成企业内部管理冲突,难以形成发展合力。由于智能制造模式下自动化和信息化高度结合,机器和生产线能够自动地实现最优的策略组合,不需要过度人为干预,大大减少了管理突发事件发生的次数和频率^[31]。同时,智能化贯穿于人员招聘、培训、管理、考核的全过程,企业加快实现从“垂直管理”向“扁平管理”的转变,人员结构不断优化。因此,智能制造通过改变企业管理模式,显著提升了企业数字化管理的先发优势^[32]。随着劳动要素使用成本的降低、能源价格的上涨及环境规制政策的压力,企业将更倾向于引进高技术劳动力以开展绿色技术创新活动,同时加大产业一线劳动要素的投入力度,以满足产出规模扩张的需要^[33],最终表现为以增加劳动投入的方式节约能源和降污减排,形成对能源要素的有效替代,从而提高碳全要素生产率。

2. 要素结构渠道

企业绿色转型过程中,资本要素对能源要素的替代性远远强于劳动要素对能源要素的替代性^[34]。智能制造能够通过优化资本和劳动要素的投入结构,进一步加强对能源要素的替代,从而提升企业碳全要素生产率。

第一,智能制造能够改变投入要素使用比例,提高资本-劳动比,从而引发资本深化。装备智能化和生产方式智能化是智能制造的核心特征和重要体现,这离不开大量机器设备的引进和生产线的搭建,不仅需要大量的前期资本投入以支撑生产线和人工智能系统的建设^[35],而且还会对劳动力形成“低级大量替代,高级少量需求”的两极化特征,从而改变制造业就业结构^[3]。一方面,当资本深化与技术进步呈现协同关系时,对生产率具有促进作用^[36],这种协同关系被称为“资本偏向型技术进步”;另一方面,资本深化带来的生产效率的提升亦会使企业的碳排放产生规模扩大效应。最终,资本深化能否提升企业碳全要素生产率,取决于生产效率的提升能否弥补碳排放规模的扩大。近年来,中国制造业的技术进步偏向于资本,资本深化程度和技术进步偏向性得到了匹配,整体上推动了全要素生产率的增长^[37];且资本深化与碳排放之间存在倒

U型关系,随着资本深化程度的加深,中国碳排放量将达到峰值并逐年递减^[38]。因此,资本深化将有利于促进减排提效,提升制造业企业碳全要素生产率。

第二,智能制造能够强化资本要素比较优势,提高资本产出效率,促进“机器换人”。企业作为效益最大化目标的追求者,会自发地根据要素使用成本调整生产要素的合理用量,追加高效率要素投入,减少低效率要素投入。智能制造对资本要素成本的降低作用往往强于对劳动要素成本的降低作用^[20],能够发挥出资本要素投入的比较优势,有效提高资本产出效率。资本产出效率的提升使资本要素对劳动要素形成替代,从而使技术进步偏向资本与要素结构偏向资本相适宜,提高制造业产能利用率^[39]。而强化资本要素的优势地位,能够反哺工业智能化转型^[40],并在提高劳动者工作质量^[41]的同时引发劳动“降级”^[42],从而促进资本要素“增量”与劳动要素“提质”,形成对能源要素的进一步替代,提高碳全要素生产率。

为此,本文提出如下基本假设:

智能制造能够显著提高制造业企业碳全要素生产率,并且能够驱动技术效率变动,但对技术进步变动具有一定的抑制作用(H1);

智能制造可通过降低要素成本,即降低资本要素成本和劳动要素成本,提高制造业企业碳全要素生产率(H2);

智能制造可通过优化要素结构,即促进资本深化和提高资本产出效率,提高制造业企业碳全要素生产率(H3)。

智能制造影响制造业企业碳全要素生产率的影响效应和作用机制如图1所示。

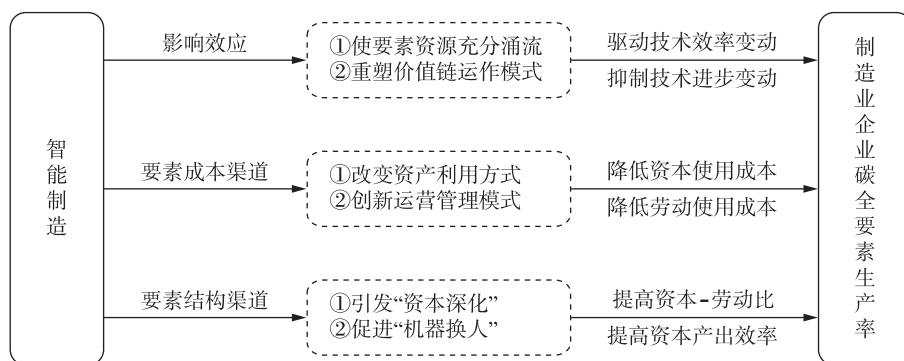


图1 智能制造影响制造业企业碳全要素生产率的影响效应和作用机制

四、研究设计

(一) 模型构建与变量说明

本文试图从企业层面实证检验智能制造水平对制造业企业碳全要素生产率的影响。碳全要素生产率用于衡量企业的绿色高质量发展水平,该指标又可被分解为技术效率变动(EC)和技术进步变动(TC)^[43]。本文选择这三种指标作为被解释变量,建立双向固定效应模型,如式(1)所示。

$$GTFP_{it} = \alpha_0 + \alpha_1 IM_{it} + \alpha_2 CONTROLS_{it} + \varphi_i + \gamma_t + \varepsilon_{it} \quad (1)$$

其中: i 、 t 分别为企业、年份; $GTFP_{it}$ 为被解释变量,包括碳全要素生产率($CTFP_{it}$)、技术效率变动指数(EC_{it})和技术进步变动指数(TC_{it}); IM_{it} 为核心解释变量智能制造水平,包括智能制造投入力度($AIAL_{it}$)和智能制造应用效果($Exposure_{it}$); $Controls_{it}$ 为一系列企业层面的控制变量; φ_i 为个体固定效应; γ_t 为年份固定效应; ε_{it} 为随机扰动项。

1. 碳全要素生产率

借鉴张宁^[9]的研究并充分考虑制造业企业间的同质属性,以资本、劳动和能源为投入要素,以主营业务收入为期望产出,以总碳排放量为非期望产出测算碳全要素生产率。借鉴 Tone^[44]的方法,利用规模报酬可变的基于松弛变量的超效率模型,在考虑非期望产出的情形下计算 GML 指数(global Malmquist-

Luenberger 指数, GML 指数可被视为碳全要素生产率的增长率), 将 2011 年设定为基年, 连年累乘得到企业每年的碳全要素生产率。具体测算指标有: ①资本要素投入, 参考李小平和朱钟棣^[45]的研究, 采用固定资产净额的对数表示; ②劳动要素投入, 借鉴李颖和许月朦^[46]的研究, 用企业员工人数的对数表示; ③能源要素投入, 借鉴王慧等^[7]的研究, 用企业能源消耗总量(折算成万吨标准煤)的对数表示; ④期望产出, 借鉴大多数研究的做法, 采用主营业务收入的对数表示; ⑤非期望产出, 采用企业碳排放总量的对数表示, 主要包含化石燃料燃烧排放、生物质燃料燃烧排放和原料开采逃逸排放等。

2. 技术效率变动指数与技术进步变动指数

作为一种采用共同前沿面的 GML 指数, GML 指数在计算时可被分解为纯技术效率变动(PEC)与纯技术进步变动(PTC)(以下简称 EC 和 TC), 三者之间的关系为: $CTFP_{it}^{t+1} = EC_{it}^{t+1} TC_{it}^{t+1}$ 。EC 和 TC 均为通过将 GML 指数分解后连年累乘得到, 表示企业碳全要素生产率中的技术效率变动部分和技术进步变动部分。

3. 智能制造投入

人工智能技术是智能制造发展的重要基础, “机器换人”是人工智能技术的重要体现。借鉴何勤等^[47]及孙文远和刘于山^[48]的研究, 本文采用人工智能的采纳程度指标衡量企业智能制造投入力度, 用企业人均机器账面价值表示, 具体计算公式如式(2)所示。

$$AIAL_{it} = \frac{MAVALUE_{it}}{EMPLOYEE_{it}} \quad (2)$$

其中: $AIAL_{it}$ 为企业 i 在 t 年的人工智能采纳程度; $MAVALUE_{it}$ 为企业 i 在 t 年固定资产报表中公布的机器账面价值; $EMPLOYEE_{it}$ 为企业 i 在 t 年的员工总人数。为消除数据的量纲影响, 对计算结果进行了标准化处理。

4. 智能制造应用

借鉴 Acemoglu 和 Restrepo^[49]及王永钦和董雯^[50]的测算方法, 本文采用企业层面的机器人渗透度指标衡量企业智能制造的应用情况。具体测度方法如下:

第一步, 计算行业层面工业机器人渗透度指标, 记为 PR_{jt}^{CH} 。

$$PR_{jt}^{CH} = \frac{MR_{jt}^{CH}}{L_{j,t=2010}^{CH}} \quad (3)$$

其中: MR_{jt}^{CH} 为 j 行业 t 年的工业机器人存量; $L_{j,t=2010}^{CH}$ 为 j 行业 2010 年(基期)的就业人数; PR_{jt}^{CH} 为 j 行业 t 年的工业机器人渗透度。

第二步, 构造企业层面工业机器人渗透度指标, 该指标衡量了 j 行业 i 企业在 t 年的工业机器人渗透度。

$$Exposure_{ijt} = \frac{PWP_{ijt=2011}}{ManuPWP_{t=2011}} \frac{MR_{jt}^{CH}}{L_{j,t=2010}^{CH}} \quad (4)$$

其中: $\frac{PWP_{ijt=2011}}{ManuPWP_{t=2011}}$ 为制造业中 j 行业 i 企业 2011 年(基期)生产部门员工占比与制造业所有企业 2011 年生产部门员工占比中位数的比值。为便于结果的展示, 将测算结果除以 100。智能制造作为一种数字化效率提升模式, 对制造业生产经营的赋能作用主要通过企业对机器人、人工智能系统和自动化生产线的整体引进来实现^[51]。因而, 反映本国行业技术特征变化的工业机器人渗透度指标能够在控制企业本身特征因素的情况下更准确反映企业智能制造应用效果。

5. 控制变量

为了增强模型的解释力, 参考李洪英和李闯^[52]的研究, 加入其他可能影响企业碳全要素生产率的因素: $Size_{it}$ 为企业规模, 用资产总计的对数表示; Age_{it} 为企业年龄, 用观察期所在年份减去企业上市年份表示; LEV_{it} 为企业 i 在 t 年的资产负债率; ROA_{it} 为企业 i 在 t 年的资产收益率; $TobinQ_{it}$ 为企业 i 在 t 年的托宾 Q 值; $Cashflow_{it}$ 为企业 i 在 t 年的经营现金流; $Growth_{it}$ 为企业 i 在 t 年的成长性, 用总资产增长率表示; $\ln Fanv_{it}$ 为企业 i 在 t 年固定资产净额的对数。

(二) 样本选择与数据来源

1. 样本选择与数据处理

本文参考《上市公司行业分类指引》(2012 年修订),以制造业 A 股上市公司为研究对象。考虑到 2016 年是中国智能制造元年,本文将研究样本区间设定为 2012—2022 年。本文对原始数据作了如下处理:由于碳全要素生产率的计算需要平衡面板数据,本文对所用到的由资本、劳动和能源投入指标及期望产出和非期望产出指标组成的非平衡面板数据进行平衡化处理,删除在年份上不连续的个体,得到 2012—2022 年的平衡面板数据;考虑到企业异常状态可能造成的样本数据异常值问题,本文剔除了 ST(special treatment)、*ST 及被处以退市警告的企业;考虑到数据可得性,本文利用线性插值法对核心解释变量及控制变量指标中数据轻微缺失的个体进行补齐,对于数据严重缺失的个体予以剔除;为了减少异常值的影响,对连续变量在 1%和 99%水平上进行缩尾处理;对于可能受到通货膨胀影响的指标,用相应的价格指数进行了平减。

2. 数据来源

本文使用的企业固定资产净额、员工人数、主营业务收入、控制变量和企业人均机器账面价值数据均来自国泰安(CSMAR)数据库;企业层面工业机器人渗透度计算所用机器人存量数据来自国际机器人联合会(IFR),其余指标来自 CSMAR 数据库和 WIND 数据库。企业碳排放数据参考王浩等^[53]研究,从企业每年披露的环境报告和社会责任报告中收集;企业能源消耗量数据参考覃风展^[54]研究,通过对每家上市公司的能源消耗情况进行数据挖掘,提取上市公司年报、社会责任报告、投资者关系活动中的能源消耗信息,结合企业及其子公司所在地环保部门的微观能源消耗数据库,进行综合统计,最终汇总形成上市公司的能源消耗数据。本文构造了 2011—2022 年企业投入产出的平衡面板数据,基于 MATLAB 软件的 GML-SBM 模型运行脚本完成碳全要素生产率数据的计算,其他指标均以上市公司股票代码+年份的方式进行匹配。主要变量的描述性统计结果如表 1 所示。其中,碳全要素生产率指标在转化为平衡面板的过程中删除了部分个体,其观测值较少,其余企业层面核心解释变量和控制变量指标均为非平衡面板,其观测值数量也不尽相同。

表 1 主要变量描述性统计

变量	观测值	均值	标准差	最小值	最大值
CTFP	19074	0.9610	0.0919	0.2231	1.9476
EC	19074	1.3078	0.1738	0.2840	2.5988
TC	19074	0.7419	0.0798	0.5198	0.9409
AIALStd	24883	-0.0280	0.0260	-0.0730	0.1150
Exposure	24019	0.2770	0.6657	0.0000	4.2459
Size	23646	21.8354	1.2069	19.2962	25.2170
Age	20075	9.8954	7.3653	0.0000	32.0000
LEV	23450	0.3513	0.2139	-0.3453	0.9403
TobinQ	20647	2.1164	1.3329	0.2438	9.5402
ROA	23400	0.0695	0.0876	-0.2532	0.4726
Cashflow	23450	0.0567	0.1014	-0.3906	0.4656
Growth	22013	0.1287	0.5195	-2.2584	2.5045
lnFanv	23758	20.0025	1.5008	15.1687	23.9585

五、实证分析与结果

(一) 基准回归结果

表 2 考察了智能制造投入及应用对碳全要素生产率的影响。由于采用非平衡面板数据且不同指标的缺失情况并不一致,实际参与回归的观测值数量小于描述性统计中展示的结果,后文的分析中亦是如此。本文在豪斯曼检验的基础上选择个体和年份双固定效应模型进行回归。结果表明,在其他条件一定的情况下,智能制造能够显著提升制造业企业碳全要素生产率,并且主要通过提高技术效率来实现,而对技术进步变动具有一定的抑制作用。至此,假设 H1 初步得到验证。

表2 基准回归结果

变量	(1)	(2)	(3)	(4)	(5)	(6)
	<i>CTFP</i>	<i>EC</i>	<i>TC</i>	<i>CTFP</i>	<i>EC</i>	<i>TC</i>
<i>AIALStd</i>	0.3774 *** (0.0292)	0.6899 *** (0.0908)	-0.0978 *** (0.0371)			
<i>Exposure</i>				0.0022 *** (0.0007)	0.0094 *** (0.0030)	-0.0033 ** (0.0013)
<i>Constant</i>	1.4765 *** (0.0250)	1.2149 *** (0.0842)	1.2070 *** (0.0309)	1.4565 *** (0.0251)	1.1839 *** (0.0834)	1.2080 *** (0.0306)
<i>Controls</i>	Yes	Yes	Yes	Yes	Yes	Yes
<i>Company FE</i>	Yes	Yes	Yes	Yes	Yes	Yes
<i>Year FE</i>	Yes	Yes	Yes	Yes	Yes	Yes
<i>N</i>	14221	14221	14221	14320	14320	14320
<i>R</i> ²	0.5141	0.6811	0.8519	0.4837	0.6800	0.8534

注:***、**、* 分别表示在 1%、5%、10%水平下显著;括号内为考虑异方差情况下企业层面的聚类稳健标准误。

(二) 核心解释变量的滞后处理

智能制造系统从建成到发挥作用需要一定时间的测试和磨合且智能化改造具有明显的阶段性,前一阶段的智能制造应用将显著提升生产经营效率,为后期智能制造建设提供持续支持。为此参考温素彬等^[55]的研究,分别采用智能制造投入力度和应用效果的一至三阶滞后项对式(1)重新进行回归。结果显示,智能制造投入对碳全要素生产率的提升作用效果随时间的推移逐步减弱,难以产生长期的影响。但随着机器设备

表3 智能制造水平滞后项与碳全要素生产率回归结果

变量	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)
	<i>CTFP</i>	<i>EC</i>	<i>TC</i>	<i>CTFP</i>	<i>EC</i>	<i>TC</i>	<i>CTFP</i>	<i>EC</i>	<i>TC</i>
Panel A									
<i>L. AIALStd</i>	0.2821 *** (0.0282)	0.5875 *** (0.0938)	-0.1120 *** (0.0408)						
<i>L2. AIALStd</i>				0.1479 *** (0.0272)	0.3969 *** (0.0943)	-0.1033 ** (0.0402)			
<i>L3. AIALStd</i>							0.0203 (0.0260)	0.2815 *** (0.0923)	-0.1297 *** (0.0397)
<i>Constant</i>	1.4684 *** (0.0244)	1.2770 *** (0.0834)	1.1424 *** (0.0320)	1.4437 *** (0.0257)	1.3094 *** (0.0839)	1.0923 *** (0.0318)	1.4292 *** (0.0290)	1.3466 *** (0.0911)	1.0570 *** (0.0331)
<i>Controls</i>	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes
<i>Company FE</i>	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes
<i>Year FE</i>	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes
<i>N</i>	13311	13311	13311	12356	12356	12356	11276	11276	11276
<i>R</i> ²	0.4440	0.5588	0.7461	0.3737	0.4136	0.5904	0.3176	0.2783	0.4040
Panel B									
<i>L. Exposure</i>	0.0023 *** (0.0007)	0.0099 *** (0.0030)	-0.0036 *** (0.0013)						
<i>L2. Exposure</i>				0.0022 *** (0.0008)	0.0098 *** (0.0030)	-0.0038 *** (0.0013)			
<i>L3. Exposure</i>							0.0024 *** (0.0009)	0.0096 *** (0.0031)	-0.0038 *** (0.0012)
<i>Constant</i>	1.4595 *** (0.0250)	1.2636 *** (0.0838)	1.1420 *** (0.0317)	1.4448 *** (0.0259)	1.3160 *** (0.0840)	1.0885 *** (0.0317)	1.4264 *** (0.0288)	1.3415 *** (0.0902)	1.0584 *** (0.0327)
<i>Controls</i>	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes
<i>Company FE</i>	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes
<i>Year FE</i>	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes
<i>N</i>	13393	13393	13393	12432	12432	12432	11359	11359	11359
<i>R</i> ²	0.4266	0.5581	0.7483	0.3709	0.4141	0.5928	0.3201	0.2803	0.4062

注:***、**、* 分别表示在 1%、5%、10%水平下显著;括号内为考虑异方差情况下企业层面的聚类稳健标准误。*L.* 表示滞后项。

的购进、人工智能系统的搭建及人工智能人才的引进,智能制造应用效果一旦显现将在短期内维持基本稳定。

(三) 内生性问题的处理

1. 工具变量法

本文采取工具变量法来缓解可能存在的双向因果问题。一方面,借鉴 Lewbel^[56] 和杨金玉等^[57] 构建工具变量的思路,采用智能制造投入力度和应用效果分别与其按两位数行业分类的行业均值之差的三次方 ($IV_AIALStd_Lewbel$ 和 $IV_Exposure_Lewbel$) 作为智能制造水平指标的第一个工具变量。该工具变量用离差的形式反映了变量围绕均值的变动情况,对智能制造水平有显著正向作用,满足相关性要求,但不会对企业碳全要素生产率产生直接影响,满足外生性要求。另一方面,在实际型工具变量的构造中,现有研究多采用邮局数量和电话数量^[58]。由于非时变数据无法作为面板数据的工具变量,本文在此基础上采用企业所在地级市 1984 年每百人固定电话安装数量的对数与滞后一期开通微博企业数量对数的交互项 ($IV_lnTel \times lnWeibo$) 作为智能制造投入指标的第二个工具变量;采用企业所在地级市 1984 年每百万人邮局数量的对数与滞后一期信息传输、计算机服务和软件业城镇从业人员占比的交互项 ($IV_lnPost \times Alper$) 作为智能制造应用指标的第二个工具变量^[59]。数字经济与互联网的发展相辅相成,开通微博企业数量和相关从业人员占比反映了地区经济发展与互联网技术结合的紧密程度,对企业智能制造有显著正向作用,但不会对企业碳全要素生产率产生直接影响,满足相关性和外生性要求。

本文采用以上两类工具变量作为联合工具变量,分别对智能制造投入和应用指标进行两阶段最小乘法 (2SLS) 回归,结果如表 4 所示,所选取的工具变量均对智能制造水平有显著正影响,满足相关性要求,核心解释变量的回归系数与基准回归一致。此外,相关工具变量通过不可识别检验和过度识别检验,且不存在弱工具变量问题,说明本文基准回归结果依然稳健。

表 4 工具变量处理结果

变量	第一阶段		第二阶段					
	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)
	$AIALStd$	$Exposure$	$CTFP$	EC	TC	$CTFP$	EC	TC
$IV_AIALStd_Lewbel$	60.7240*** (3.7606)							
$IV_lnPost \times lnWeibo$	0.0008** (0.0004)							
$IV_Exposure_Lewbel$		0.1686*** (0.0047)						
$IV_lnPost \times Alper$		0.3185*** (0.0777)						
$AIALStd$			0.2489*** (0.0434)	0.3779*** (0.1440)	-0.0293 (0.0633)			
$Exposure$						0.0026*** (0.0009)	0.0091*** (0.0035)	-0.0029** (0.0015)
KP-rk LM Statistic (P-Value)			49.5030*** (0.0000)			99.9220*** (0.0000)		
C-D Wald F Statistic (10% Maximal Size)			4306.7440 (19.9300)			8408.044 (19.9300)		
Hansen J Statistic (P-Value)			0.0090 (0.9250)	0.3740 (0.5409)	0.7340 (0.3887)	0.3940 (0.5300)	0.7550 (0.3849)	0.6080 (0.4356)
Controls	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes
Company FE	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes
Year FE	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes
N	11350	12392	11350	11350	11350	12392	12392	12392
R ²	—	—	0.4613	0.5606	0.7490	0.4892	0.6803	0.8545

注:***、**、* 分别表示在 1%、5%、10% 水平下显著;括号内为考虑异方差情况下企业层面的聚类稳健标准误;“—”代表在该模型中此统计量无法得到。

2. Heckman 两阶段法

上市公司的规模、资金、技术等方面的实力本身较强,实施智能制造的难度较低、渠道更广,因而可能存在样本选择偏误问题。本文参考张吉昌等^[60]的思路,按照智能制造投入力度和应用效果是否大于行业内中位数将样本分为高智能制造水平组($AIALStd_Dum = Exposure_Dum = 1$)和低智能制造水平组($AIALStd_Dum = Exposure_Dum = 0$),采用 Heckman 两阶段法进行处理。在第一阶段中,以上述分组的虚拟变量为被解释变量,以一系列控制变量、外生变量为解释变量,采用面板 Probit 模型进行回归,并计算出逆米尔斯比率($IMR_AIALStd, IMR_Exposure$)。在第二阶段中,将逆米尔斯比率纳入式(1)重新进行回归。参考黄群慧等^[58]及温素彬等^[55]的研究思路,本文采用的两个外生变量分别为 1984 年各地级市每百万人邮局数量与滞后一期的互联网上网人数的交互项、1984 年各地级市每百人固定电话数量与滞后一期的互联网上网人数的交互项。Heckman 两阶段回归结果,如表 5 所示,本文基准回归结果依然稳健。

表 5 Heckman 两阶段回归结果

变量	(1)	(2)	(3)	(4)	(5)	(6)
	CTFP	EC	TC	CTFP	EC	TC
<i>AIALStd</i>	0.4104 *** (0.0353)	0.7463 *** (0.1117)	-0.1054 *** (0.0459)			
<i>IMR_AIALStd</i>	0.0179 *** (0.0064)	0.0408 ** (0.0209)	-0.0030 (0.0082)			
<i>Exposure</i>				0.0020 *** (0.0008)	0.0076 ** (0.0033)	-0.0024 * (0.0014)
<i>IMR_Exposure</i>				-0.0186 ** (0.0080)	-0.2223 *** (0.0292)	0.1018 *** (0.0131)
<i>Constant</i>	1.4547 *** (0.0291)	1.2054 *** (0.1029)	1.1543 *** (0.0406)	1.4962 *** (0.0297)	1.6107 *** (0.1066)	0.9855 *** (0.0426)
<i>Controls</i>	Yes	Yes	Yes	Yes	Yes	Yes
<i>Company FE</i>	Yes	Yes	Yes	Yes	Yes	Yes
<i>Year FE</i>	Yes	Yes	Yes	Yes	Yes	Yes
<i>N</i>	11505	11505	11505	11565	11565	11565
<i>R²</i>	0.4696	0.5634	0.7492	0.4295	0.5651	0.7540

注:***、**、* 分别表示在 1%、5%、10%水平下显著;括号内为考虑异方差情况下企业层面的聚类稳健标准误。

3. 考虑遗漏变量

考虑到不可观测因素的影响,本文在基准回归结果基础上加入更为严格的固定效应。参考温素彬等^[55],本文采用年份×城市固定效应,控制城市层面随时间变化的特征的影响,采用年份×行业固定效应控制行业层面随时间变化的特征的影响,并在此基础上同时控制年份×城市固定效应,以及年份×行业固定效应。智能制造投入和应用回归结果分别为表 6 中 Panel A 和 Panel B,可以看出本文基准回归结果保持稳健。

表 6 考虑遗漏变量的回归结果

变量	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)
	CTFP	EC	TC	CTFP	EC	TC	CTFP	EC	TC
Panel A									
<i>AIALStd</i>	0.3766 *** (0.0292)	0.6895 *** (0.0910)	-0.0983 *** (0.0371)	0.3787 *** (0.0293)	0.6841 *** (0.0908)	-0.0935 ** (0.0370)	0.3780 *** (0.0293)	0.6839 *** (0.0909)	-0.0940 ** (0.0370)
<i>Constant</i>	1.4804 *** (0.0259)	1.2048 *** (0.0870)	1.2150 *** (0.0318)	1.4835 *** (0.0265)	1.1987 *** (0.0896)	1.2232 *** (0.0336)	1.4882 *** (0.0275)	1.1879 *** (0.0921)	1.2322 *** (0.0343)
<i>Controls</i>	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes
<i>Company FE</i>	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes
<i>Year FE</i>	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes
<i>City×Year FE</i>	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes
<i>Industry×Year FE</i>	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes
<i>N</i>	14221	14221	14221	14221	14221	14221	14221	14221	14221
<i>R²</i>	0.5146	0.6812	0.8520	0.5146	0.6816	0.8523	0.5151	0.6817	0.8524

续表

变量	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)
	<i>CTFP</i>	<i>EC</i>	<i>TC</i>	<i>CTFP</i>	<i>EC</i>	<i>TC</i>	<i>CTFP</i>	<i>EC</i>	<i>TC</i>
Panel B									
<i>Exposure</i>	0.0022 *** (0.0007)	0.0093 *** (0.0030)	- 0.0033 ** (0.0013)	0.0029 *** (0.0008)	0.0155 *** (0.0035)	- 0.0061 *** (0.0015)	0.0029 *** (0.0008)	0.0155 *** (0.0035)	- 0.0061 *** (0.0015)
<i>Constant</i>	1.4613 *** (0.0258)	1.1750 *** (0.0861)	1.2161 *** (0.0314)	1.4425 *** (0.0269)	1.0937 *** (0.0907)	1.2484 *** (0.0340)	1.4476 *** (0.0276)	1.0824 *** (0.0928)	1.2580 *** (0.0346)
<i>Controls</i>	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes
<i>Company FE</i>	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes
<i>Year FE</i>	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes
<i>City×Year FE</i>	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes
<i>Industry×Year FE</i>	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes
<i>N</i>	14320	14320	14320	14320	14320	14320	14320	14320	14320
<i>R</i> ²	0.4842	0.6800	0.8534	0.4846	0.6815	0.8542	0.4851	0.6816	0.8543

注：***、**、* 分别表示在 1%、5%、10% 水平下显著；括号内为考虑异方差情况下企业层面的聚类稳健标准误。

(四) 其他稳健性检验

1. 替换被解释变量

基准回归中所使用的碳全要素生产率是基于 Tone^[61] 构建的 GML-SBM 模型计算得到的, 该模型只能同比例增加或减少期望产出与非期望产出。为此本文进一步基于 SBM-DDF 模型, 重新测算碳全要素生产率 *CTFP_DDF*、*EC_DDF* 及 *TC_DDF*, 如表 7 所示, 与基准回归结果一致。

2. 替换核心解释变量

参考宋德勇等^[62] 的做法, 构建智能化投资指标来衡量企业智能制造水平。先基于上市公司财务报告附注中固定资产和无形资产的科目名称和每项资产额度, 手工整理出与智能制造相关的固定资产和无形资产投资额度, 分别表示智能化硬件和软件投资额度; 然后考虑到行业规模差异, 分别用智能化硬件投资和软件投资额与按所属行业均值的比值衡量智能化硬件投资水平 (*Hard_std*) 和软件投资水平 (*Soft_std*)。借鉴 Ho 等^[63]、祁怀锦等^[64] 的研究, 与企业智能化相关的固定资产为科目名称中包含“电子设备”“计算机”“数据设备”等词语的固定资产项目, 相应的无形资产为科目名称中包含“智能”“软件”“系统”“信息平台”“数据”等关键词的无形资产项目。智能化硬件投资和软件投资水平的回归结果如表 8 所示, 与基准回归结果一致。

表 7 替换被解释变量的回归结果

变量	(1)	(2)	(3)	(4)	(5)	(6)
	<i>CTFP_DDF</i>	<i>EC_DDF</i>	<i>TC_DDF</i>	<i>CTFP_DDF</i>	<i>EC_DDF</i>	<i>TC_DDF</i>
<i>AIALStd</i>	0.0990 *** (0.0098)	0.2132 *** (0.0278)	- 0.0820 *** (0.0174)			
<i>Exposure</i>				0.0005 ** (0.0002)	0.0026 *** (0.0009)	- 0.0016 ** (0.0006)
<i>Constant</i>	1.1596 *** (0.0077)	1.0706 *** (0.0254)	1.0814 *** (0.0157)	1.1547 *** (0.0077)	1.0603 *** (0.0253)	1.0851 *** (0.0156)
<i>Controls</i>	Yes	Yes	Yes	Yes	Yes	Yes
<i>Company FE</i>	Yes	Yes	Yes	Yes	Yes	Yes
<i>Year FE</i>	Yes	Yes	Yes	Yes	Yes	Yes
<i>N</i>	14221	14221	14221	14320	14320	14320
<i>R</i> ²	0.4875	0.7167	0.8375	0.4728	0.7155	0.8383

注：***、**、* 分别表示在 1%、5%、10% 水平下显著；括号内为考虑异方差情况下企业层面的聚类稳健标准误。

3. 改变样本观察期

2016 年, 作为第一份智能制造发展规划, 《智能制造发展规划 (2016—2020)》开始实施, 该规划体现了信息技术与制造技术的深度融合, 为智能制造的发展提供了良好的政策环境。另外, 2020 年新冠肺炎疫情的爆发对智能制造发展形成了一定的冲击。为此, 本文将样本期缩短到 2015—2019 年, 结果如表 9 所示。

由表9可知,基准结果依然稳健。

4. 缩小样本范围

由于直辖市的特殊行政和经济地位,位于其范围内的企业可能受到更多的政策优待或享有更好的发展环境,并且样本中分布在直辖市的企业占比为14.35%。基于此,本文进一步将样本范围限定为注册地为非直辖市的企业,从表10可以看出,基准回归结果仍保持稳健。

表8 替换核心解释变量的回归结果

变量	(1)	(2)	(3)	(4)	(5)	(6)
	<i>CTFP</i>	<i>EC</i>	<i>TC</i>	<i>CTFP</i>	<i>EC</i>	<i>TC</i>
<i>Hard_std</i>	0.0010 ** (0.0005)	0.0158 *** (0.0029)	-0.0074 *** (0.0013)			
<i>Soft_std</i>				0.0008 ** (0.0004)	0.0052 *** (0.0016)	-0.0021 *** (0.0006)
<i>Constant</i>	1.4479 *** (0.0230)	1.2824 *** (0.0779)	1.1512 *** (0.0308)	1.4495 *** (0.0227)	1.2160 *** (0.0777)	1.1874 *** (0.0308)
<i>Controls</i>	Yes	Yes	Yes	Yes	Yes	Yes
<i>Company FE</i>	Yes	Yes	Yes	Yes	Yes	Yes
<i>Year FE</i>	Yes	Yes	Yes	Yes	Yes	Yes
<i>N</i>	14345	14345	14345	14345	14345	14345
<i>R</i> ²	0.4817	0.6823	0.8553	0.4826	0.6802	0.8537

注:***、**、*分别表示在1%、5%、10%水平下显著;括号内为考虑异方差情况下企业层面的聚类稳健标准误。

表9 改变样本期的回归结果(2015—2019年)

变量	(1)	(2)	(3)	(4)	(5)	(6)
	<i>CTFP</i>	<i>EC</i>	<i>TC</i>	<i>CTFP</i>	<i>EC</i>	<i>TC</i>
<i>AIALStd</i>	0.5469 *** (0.0534)	1.2926 *** (0.1763)	-0.2779 *** (0.0710)			
<i>Exposure</i>				0.0029 *** (0.0009)	0.0276 *** (0.0045)	-0.0119 *** (0.0019)
<i>Constant</i>	1.4989 *** (0.0370)	1.2724 *** (0.1363)	1.1367 *** (0.0517)	1.4505 *** (0.0376)	1.1753 *** (0.1309)	1.1528 *** (0.0487)
<i>Controls</i>	Yes	Yes	Yes	Yes	Yes	Yes
<i>Company FE</i>	Yes	Yes	Yes	Yes	Yes	Yes
<i>Year FE</i>	Yes	Yes	Yes	Yes	Yes	Yes
<i>N</i>	6900	6900	6900	6929	6929	6929
<i>R</i> ²	0.3768	0.4331	0.5642	0.3449	0.4305	0.5682

注:***、**、*分别表示在1%、5%、10%水平下显著;括号内为考虑异方差情况下企业层面的聚类稳健标准误。

表10 改变样本范围的回归结果(删除直辖市)

变量	(1)	(2)	(3)	(4)	(5)	(6)
	<i>CTFP</i>	<i>EC</i>	<i>TC</i>	<i>CTFP</i>	<i>EC</i>	<i>TC</i>
<i>AIALStd</i>	0.3600 *** (0.0311)	0.6595 *** (0.0982)	-0.0931 ** (0.0403)			
<i>Exposure</i>				0.0017 ** (0.0008)	0.0075 ** (0.0033)	-0.0027 * (0.0014)
<i>Constant</i>	1.4629 *** (0.0272)	1.1740 *** (0.0900)	1.2186 *** (0.0325)	1.4458 *** (0.0273)	1.1481 *** (0.0895)	1.2187 *** (0.0322)
<i>Controls</i>	Yes	Yes	Yes	Yes	Yes	Yes
<i>Company FE</i>	Yes	Yes	Yes	Yes	Yes	Yes
<i>Year FE</i>	Yes	Yes	Yes	Yes	Yes	Yes
<i>N</i>	12407	12407	12407	12494	12494	12494
<i>R</i> ²	0.5066	0.6867	0.8551	0.4768	0.6850	0.8565

注:***、**、*分别表示在1%、5%、10%水平下显著;括号内为考虑异方差情况下企业层面的聚类稳健标准误。

六、进一步分析

(一) 机制检验

参考董必荣等^[65]及米瑞华等^[66]的做法并充分考虑江艇^[67]对中介效应模型的探讨,本文采用中介效应两步法,从要素成本和要素结构两个渠道检验智能制造对企业碳全要素生产率的作用机制。其中,核心解释变量对被解释变量的影响已在基准回归中得到证实,下面实证检验核心解释变量对中介变量的影响,具体模型设定如式(5)所示。

$$MID_{it} = \alpha_0 + \alpha_1 IM_{it} + \alpha_2 Controls_{it} + \gamma_t + \varepsilon_{it} \quad (5)$$

其中: MID_{it} 为机制变量,包括资本要素成本(DCC_{it})、劳动要素成本($Maeff_{it}$)、资本深化程度($Capdeep_{it}$)和资本产出效率($Capeff_{it}$)4个变量。具体而言,使用债务资本成本作为资本要素成本(DCC_{it})的代理变量,用滞后一期的财务费用与期末总负债的比值表示^[68];使用管理费用率,即管理成本与主营业务收入比值的对数表示劳动要素成本($Maeff_{it}$);使用资本-劳动比即固定资产净额与员工人数比值的对数表示资本深化程度($Capdeep_{it}$);采用固定资产净利润率即净利润与固定资产平均余额比值的对数表示资本产出效率($Capeff_{it}$)。

1. 降低要素成本渠道

智能制造降低资本要素成本的机制检验结果见表11的(1)列和(2)列,降低劳动要素成本的机制检验结果见(3)列和(4)列。表2基准结果已证实智能制造投入与应用显著提升了企业碳全要素生产率。表11的(1)列和(2)列表明,智能制造投入与应用显著降低了企业资本要素成本。(3)列显示,智能制造投入与劳动要素成本存在显著的倒U型关系,即投入力度较低时会提高劳动要素成本,但随着投入力度的加大,最终会不断降低企业劳动要素成本。(4)列表明,智能制造应用显著降低了企业劳动要素成本。对于资本要素和劳动要素成本的降低对企业碳全要素生产率的提升作用,学界并无直接的经验证据,但从理论逻辑上看是显而易见的:资本要素成本的降低,使企业更有余力和动力进行设备更新换代、淘汰落后产能和加强末端治理,从而降低能源要素使用的比例、减少污染排放,从而提升其碳全要素生产率;劳动要素成本的降低,使企业更倾向于突破原有的粗放型经营模式,引进高端技术和人才资源以开展绿色技术创新,提高能源要素的使用效率、减少污染排放,从而提升其碳全要素生产率。至此,假设H2得到验证。

2. 优化要素结构渠道

智能制造提高资本-劳动比渠道的机制检验结果见表12的(1)列和(2)列,提升资本产出效率渠道的机制检验结果见(3)列和(4)列。(1)列和(2)列表明,智能制造投入与应用显著提高了资本-劳动比;(3)列和(4)列显示,智能制造投入与应用显著提升了资本产出效率。中国的资本深化与资本偏向型技术进步相匹配,提升了生产效率,且随着程度的加深,会抑制碳排放的增长,从而有利于碳全要素生产率的提升;而资本产出效率的提升使资本偏向型技术进步和资本偏向型要素结构相适应,提升了产能利用率,且能够推动资本要素“增量”与劳动要素“提质”,从而有利于碳全要素生产率的提升。至此,假设H3得到验证。

表11 降低要素成本渠道的机制检验

变量	降低资本要素成本		降低劳动要素成本		变量	降低资本要素成本		降低劳动要素成本	
	(1)	(2)	(3)	(4)		(1)	(2)	(3)	(4)
	<i>DCC</i>	<i>DCC</i>	<i>Maeff</i>	<i>Maeff</i>		<i>DCC</i>	<i>DCC</i>	<i>Maeff</i>	<i>Maeff</i>
<i>AIALStd</i>	-0.1096*** (0.0327)		0.1726*** (0.0412)		<i>Controls</i>	Yes	Yes	Yes	Yes
<i>AIALStd</i> ²			-1.3027** (0.5679)		<i>Company FE</i>	Yes	Yes	Yes	Yes
<i>Exposure</i>		-0.0022*** (0.0009)		-0.0031** (0.0013)	<i>Year FE</i>	Yes	Yes	Yes	Yes
<i>Constant</i>	-0.0367* (0.0220)	-0.0273 (0.0218)	0.4087*** (0.0338)	0.4078*** (0.0372)	<i>N</i>	15436	15584	17114	17286
					<i>R</i> ²	0.1924	0.1933	0.3195	0.3099

注:***、**、*分别表示在1%、5%、10%水平下显著;括号内为考虑异方差情况下企业层面的聚类稳健标准误。

表 12 优化要素结构渠道的机制检验

变量	提高资本-劳动比		提升资本产出效率	
	(1)	(2)	(3)	(4)
	<i>Capdeep</i>	<i>Capdeep</i>	<i>Capeff</i>	<i>Capeff</i>
<i>AIALStd</i>	8.9981 *** (0.4425)		0.8379 *** (0.1880)	
<i>Exposure</i>	0.0379 *** (0.0122)		0.0116 ** (0.0053)	
Constant	9.0980 *** (0.3254)	8.3189 *** (0.3796)	0.6805 *** (0.1983)	0.6972 *** (0.1997)
<i>Controls</i>	Yes	Yes	Yes	Yes
<i>Company FE</i>	Yes	Yes	Yes	Yes
<i>Year FE</i>	Yes	Yes	Yes	Yes
<i>N</i>	17112	17283	15385	15529
<i>R</i> ²	0.5618	0.4680	0.4131	0.4113

注：***、**、* 分别表示在 1%、5%、10% 水平下显著；括号内为考虑异方差情况下企业层面的聚类稳健标准误。

(二) 异质性分析

1. 企业特征

本文从企业年龄和所有制性质维度考察企业特征层面的异质性影响。一是,随着年龄的增长,企业组织结构愈发僵化,人员安排和经营模式相对固定,受新技术的影响较小^[69-70],而更有动机采用新技术的年轻企业要素调整的成本与难度相对较低,智能制造效果可能更好。二是,国有企业承担着一定的政治与社会责任,加之体制机制约束较为严格,在要素结构优化过程中容易“瞻前顾后”。而非国有企业受体制约束较少,生产经营较为灵活^[71],因此,智能制造效果可能更优。分组检验结果如表 13 所示,智能制造投入和应用回归结果分别为 Panel A 和 Panel B。可以看出,年轻企业及非国有企业中智能制造对碳全要素生产率的提升作用更为明显。

2. 行业特征

本文从行业竞争程度和要素密集度维度考察行业特征层面的异质性影响。一是,在竞争度较高的行业,企业为了创造竞争优势,会采用新技术,对智能制造的接受程度较高,智能化改造动机较强。二是,技术密集型行业中的企业通常具有较高的员工知识水平及较强的研发创新能力,能以更高效率和质量实施智能化改造,从而提升碳全要素生产率的作用更为明显。按行业特征分类的异质性分析回归结果表 14 所示,智能制造投入和应用回归结果分别为 Panel A 和 Panel B。可以看出在竞争程度高及技术密集型行业中智能制造对企业碳全要素生产率的提升作用更为明显。

表 13 按企业特征分类的异质性分析结果

变量	CTFP			
	企业年龄		企业所有制性质	
	年老企业	年轻企业	国有企业	非国有企业
Panel A				
<i>AIALStd</i>	0.2481 *** (0.0617)	0.4508 *** (0.0344)	0.2827 *** (0.0710)	0.4481 *** (0.0323)
<i>Constant</i>	1.3854 *** (0.0624)	1.4923 *** (0.0237)	1.4050 *** (0.0653)	1.5243 *** (0.0283)
<i>N</i>	5123	9098	2838	8550
<i>R</i> ²	0.3434	0.5907	0.4729	0.6212
Panel B				
<i>Exposure</i>	0.0003 (0.0012)	0.0021 ** (0.0011)	0.0012 (0.0013)	0.0032 *** (0.0009)
<i>Constant</i>	1.3679 *** (0.0601)	1.4689 *** (0.0253)	1.3898 *** (0.0629)	1.4989 *** (0.0303)
<i>N</i>	5183	9137	2868	8593
<i>R</i> ²	0.3311	0.5565	0.4643	0.5803

注：***、**、* 分别表示在 1%、5%、10% 水平下显著；括号内为考虑异方差情况下企业层面的聚类稳健标准误。

表 14 按行业特征分类的异质性分析回归结果

变量	CTFP			
	行业竞争程度		要素密集度维度	
	高	低	技术密集	非技术密集
Panel A				
<i>AIALStd</i>	0.4013 *** (0.0407)	0.3350 *** (0.0371)	0.4048 *** (0.0453)	0.3671 *** (0.0399)
<i>Constant</i>	1.4837 *** (0.0316)	1.4858 *** (0.0431)	1.4322 *** (0.0288)	1.5775 *** (0.0432)
<i>N</i>	7959	6262	8040	5236
<i>R</i> ²	0.5583	0.4595	0.5645	0.5450
Panel B				
<i>Exposure</i>	0.0023 * (0.0013)	0.0016 * (0.0009)	0.0031 *** (0.0008)	0.0044 (0.0032)
<i>Constant</i>	1.4641 *** (0.0320)	1.4709 *** (0.0426)	1.4098 *** (0.0294)	1.5528 *** (0.0431)
<i>N</i>	8022	6298	8079	5288
<i>R</i> ²	0.5250	0.4348	0.5416	0.5057

注：***、**、* 分别表示在 1%、5%、10% 水平下显著；括号内为考虑异方差情况下企业层面的聚类稳健标准误。

3. 地区特征

本文从知识产权保护程度和工业基地属性维度考察地区层面特征的异质性影响。一是,知识产权保护降低了知识和技术受到剽窃的风险,为技术创新提供了激励^[72],因而,在知识产权保护程度较高的地区,企业更有动力引进新技术进行智能化改造。二是,工业基地的生产制造体系较为发达,技术基础较为雄厚,因而,实施智能制造的时间更早、进程更快。按地区特征分类的异质性分析结果见表 15,智能制造投入和应用回归结果分别为 Panel A 和 Panel B。可以看出,在知识产权保护程度高的地区及工业基地尤其是重工业基地中智能制造对企业碳全要素生产率的提升作用更为明显。

表 15 按地区特征分类的异质性分析结果

变量	CTFP				
	知识产权保护程度		工业基地属性		
	高	低	重工业基地	轻工业基地	工业基地非
Panel A					
<i>AIALStd</i>	0.4382 *** (0.0506)	0.3341 *** (0.0386)	0.4245 *** (0.0984)	0.4103 *** (0.0418)	0.3242 *** (0.0416)
<i>Constant</i>	1.4581 *** (0.0337)	1.5178 *** (0.0386)	1.5280 *** (0.0530)	1.4316 *** (0.0320)	1.4992 *** (0.0421)
<i>N</i>	4982	6283	1660	6979	5582
<i>R</i> ²	0.5200	0.5078	0.5019	0.5334	0.5040
Panel B					
<i>Exposure</i>	0.0040 *** (0.0011)	0.0017 (0.0011)	0.0044 *** (0.0016)	0.0024 ** (0.0011)	0.0014 (0.0010)
<i>Constant</i>	1.4235 *** (0.0340)	1.4907 *** (0.0394)	1.5338 *** (0.0615)	1.4140 *** (0.0331)	1.4735 *** (0.0418)
<i>N</i>	5021	6327	1675	7031	5614
<i>R</i> ²	0.4863	0.4756	0.4742	0.4966	0.4807

注：***、**、* 分别表示在 1%、5%、10% 水平下显著；括号内为考虑异方差情况下企业层面的聚类稳健标准误。

七、结论与政策建议

随着数字经济时代的到来,强化智能制造支撑作用,赋能企业碳全要素生产率,对于推动制造业企业高质量发展及实现“双碳”目标具有重要意义。本文以 2012—2022 年制造业 A 股上市公司为样本,考察智能制造发展对企业碳全要素生产率的影响,并探究具体作用渠道及异质性影响。研究结果显示,智能制造能

够显著提升制造业企业碳全要素生产率,并且主要通过提升技术效率来实现,而对技术进步变动具有一定抑制作用。机制检验结果表明,智能制造通过降低资本要素成本、降低劳动要素成本、促进资本深化及提高资本产出效率等渠道,提升企业碳全要素生产率,实现绿色高质量发展。异质性结果显示,对年轻企业和非国有企业、处在竞争程度较高行业和技术密集型行业的企业,以及处在知识产权保护程度较高地区以及工业基地尤其是重工业基地的企业,智能制造提升企业碳全要素生产率的作用更为明显。

基于以上研究结论,本文得到以下政策启示:

第一,政府应将智能制造战略作为当前“双碳”工作的重要着力点和主要抓手,积极引导制造业企业开展智能化转型。应在国家层面将“智能制造”战略的实施放在关键位置,大力推动企业进行智能化建设,加快产业智能化升级;同时,在企业层面从资金奖补、税收优惠、人才引进等方面出台相关支持政策,加大智能制造技术研发投入,激励企业开展基础性研究。

第二,企业进行智能化改造时,应将实现要素投入的最优配置作为主攻方向。一方面,应主要将智能化改造成果应用于改变资产利用方式、提高管理效率和推进“机器换人”等方面,实现要素投入的最佳配置;另一方面,应强化关键绿色技术攻关,搭建协同创新平台,加大绿色技术财税金融支持,建立完善市场导向的企业绿色技术创新体系,逐步打通绿色技术创新促进企业碳全要素生产率提升的作用渠道。与此同时,应贯彻落实党中央、国务院关于“降低实体经济成本”的精神,围绕企业用工、融资、用房、用地等需求,多措并举、全方位降低制造业企业生产运营成本,不断优化要素供给结构,加强核心装备制造和装配、关键技术引进与应用,增强技术、人才、数据等高端要素供给,提高资本产出效率。

第三,智能制造战略的实施应做到因事制宜、因企制宜、因地制宜。一方面,年轻企业往往具有较强的创新活力,智能化发展空间较大,但规模、资金、技术等实力较弱,亟需智能化转型的政策倾斜;高竞争度的行业容易形成智能化转型示范和带动的“鲶鱼效应”,是减排增效的“角斗场”;技术密集型行业具有得天独厚的效率优势,是减排增效的“主战场”。政府应加强对以上企业的政策倾斜和资金扶持力度,优化营商环境,助力其在实施智能化改造的过程中“爬坡过坎”。另一方面,政府应加强地区知识产权保护力度,营造良好的技术创新氛围,为智能化新知识、新技术的引进“保驾护航”。政府还应加强工业基地建设,着力建设一批具有较高智能制造水平的龙头示范企业,发挥其对产业链上中下游的辐射带动作用。同时,加快推进产业转移,并辅以相应的配套设施建设和政策支持,为有发展潜力的智能制造企业提供良好的区位条件,助力“绿苗”成长为“大树”。

参考文献

- [1] 邵帅,张曦,赵兴荣.中国制造业碳排放的经验分解与达峰路径——广义迪氏指数分解和动态情景分析[J].中国工业经济,2017(3): 44-63.
- [2] GRAETZ G, MICHAELS G. Robots at work: The impact on productivity and jobs[R]. London: Technical Report, Centre for Economic Performance, LSE, 2015.
- [3] 孙早,侯玉琳.工业智能化如何重塑劳动力就业结构[J].中国工业经济,2019(5): 61-79.
- [4] 刘斌,潘彤.人工智能对制造业价值链分工的影响效应研究[J].数量经济技术经济研究,2020,37(10): 24-44.
- [5] 温湖炜,钟启明.智能化发展对企业全要素生产率的影响——来自制造业上市公司的证据[J].中国科技论坛,2021,297(1): 84-94.
- [6] 林熙,刘启仁,冯桂媚.智能制造与绿色发展:基于工业机器人进口视角[J].世界经济,2023,46(8): 3-31.
- [7] 王慧,孙慧,肖涵月,等.环境政策不确定性、双向FDI与低碳全要素生产率的关系[J].中国人口·资源与环境,2020,30(11): 75-86.
- [8] 许冬兰,于发辉,张敏.全球价值链嵌入能否提升中国工业的低碳全要素生产率?[J].世界经济研究,2019(8): 60-72, 135.
- [9] 张宁.碳全要素生产率、低碳技术创新和节能减排效率追赶——来自中国火力发电企业的证据[J].经济研究,2022(2): 158-174.
- [10] 孙文远,周浩平.人工智能、技术外溢与绿色全要素生产率[J].当代经济,2023,40(2): 3-10.
- [11] 周杰.中国智能制造绿色全要素生产率增长的时空演变[J].技术经济与管理研究,2022,314(9): 100-105.
- [12] 陈俊龙,何瑞宇,刘佳丽.智能制造对制造企业绿色全要素生产率的影响研究[J].软科学,2024,38(8): 1-6, 13.
- [13] 颜逢,赵秀云.智能制造推动了企业绿色全要素生产率提升吗?——基于智能制造示范企业的研究[J].商业研究,2024(3): 41-49.
- [14] 权小锋,李闯.智能制造与成本粘性——来自中国智能制造示范项目的准自然实验[J].经济研究,2022(4): 68-84.
- [15] 李培楠,赵兰香,万劲波.创新要素对产业创新绩效的影响——基于中国制造业和高技术产业数据的实证分析[J].科学学研究,2014,32(4): 604-612.

- [16] 徐康宁, 王剑. 自然资源丰裕程度与经济发展水平关系的研究[J]. 经济研究, 2006(1): 78-89.
- [17] 甄美荣, 刘蕊. 数字赋能制造企业技术创新的实现机制——基于数据生命周期理论的研究[J]. 技术经济, 2024, 43(3): 64-76.
- [18] 郑飞, 刘梦欣, 贺翔, 等. 智能制造对企业间生产率差距的影响研究——基于管理者时间导向的调节效应[J]. 管理学报, 2024, 37(3): 78-94.
- [19] 仲崇阳, 张雨朦, 马新啸. 智能制造对中国城市低碳发展的赋能效应——基于工业机器人应用视角[J]. 资源科学, 2024, 46(4): 728-743.
- [20] 张曙. 工业 4.0 和智能制造[J]. 机械设计与制造工程, 2014, 43(8): 1-5.
- [21] 黄卓, 陶云清, 刘兆达, 等. 智能制造如何提升企业产能利用率——基于产消合一的视角[J]. 管理世界, 2024, 40(5): 40-59.
- [22] 侯德帅, 熊健, 杜松桦. 智能制造与企业韧性——基于工业机器人视角[J]. 中南财经政法大学学报, 2024(4): 120-134.
- [23] 吕铁, 韩娜. 智能制造: 全球趋势与中国战略[J]. 人民论坛·学术前沿, 2015(11): 6-17.
- [24] 刘建丽, 李娇. 智能制造: 概念演化、体系解构与高质量发展[J]. 改革, 2024(2): 75-88.
- [25] ANDERSON M C, BANKER R D, JANAKIRAMAN S N. Are selling, general, and administrative cost 'sticky'?[J]. Journal of Accounting Research, 2003, 41(1): 47-63.
- [26] 吕文晶, 陈劲, 刘进. 工业互联网的智能制造模式与企业平台建设——基于海尔集团的案例研究[J]. 中国软科学, 2019(7): 1-13.
- [27] 滕修攀, 魏云飞, 程德俊, 等. 产业互联网背景下传统制造业的转型路径探索: 商业模式创新案例分析[J]. 管理现代化, 2020, 40(4): 19-22.
- [28] 杨冕, 徐江川, 杨福霞. 能源价格波动、高能效资本动态累积与资本-能源替代关系[J]. 系统工程理论与实践, 2021, 41(9): 2284-2299.
- [29] 何威风. 高管团队垂直对特征与企业盈余管理行为研究[J]. 南开管理评论, 2015, 18(1): 141-151.
- [30] 尹振东. 垂直管理与属地管理: 行政管理体制的选择[J]. 经济研究, 2011(4): 41-54.
- [31] 沈志锋, 许桂泽, 焦媛媛, 等. 数字环境下企业项目管理效率提升机理[J]. 科技管理研究, 2019, 39(17): 188-198.
- [32] 刘淑春, 闫津臣, 张思雪, 等. 企业管理数字化变革能提升投入产出效率吗[J]. 管理世界, 2021, 37(5): 170-190, 13.
- [33] 鲁成军, 周端明. 中国工业部门的能源替代研究——基于对 ALLEN 替代弹性模型的修正[J]. 数量经济技术经济研究, 2008, 25(5): 30-42.
- [34] 郑照宁, 刘德顺. 考虑资本-能源-劳动投入的中国超越对数生产函数[J]. 系统工程理论与实践, 2004(5): 51-54, 115.
- [35] 肖静华, 吴小龙, 谢康, 等. 信息技术驱动中国制造转型升级——美的智能制造跨越式战略变革纵向案例研究[J]. 管理世界, 2021, 37(3): 161-179, 225, 11.
- [36] 杨文举. 技术效率、技术进步、资本深化与经济增长: 基于 DEA 的经验分析[J]. 世界经济, 2006(5): 73-83, 96.
- [37] 余东华, 张鑫宇, 孙婷. 资本深化、有偏技术进步与全要素生产率增长[J]. 世界经济, 2019, 42(8): 50-71.
- [38] 徐大丰. 资本深化、技术进步与中国碳排放 EKC 的形成[J]. 系统工程理论与实践, 2022, 42(6): 1632-1643.
- [39] 陈汝影, 余东华. 资本深化、技术进步偏向与中国制造业产能利用率[J]. 经济评论, 2019(3): 3-17.
- [40] 时省, 李蓉, 彭飞. 资本偏向型税收激励是否促进了工业智能化转型升级? ——基于“机器换人”视角的分析[J]. 财政研究, 2023(10): 115-129.
- [41] 侯俊军, 张莉, 窦钱斌. “机器换人”对劳动者工作质量的影响——基于广东省制造企业与员工的匹配调查[J]. 中国人口科学, 2020(4): 113-125, 128.
- [42] 许怡, 叶欣. 技术升级劳动降级? ——基于三家“机器换人”工厂的社会学考察[J]. 社会学研究, 2020, 35(3): 23-46, 242.
- [43] 颜鹏飞, 王兵. 技术效率、技术进步与生产率增长: 基于 DEA 的实证分析[J]. 经济研究, 2004(12): 55-65.
- [44] TONE K. A slacks-based measure of super-efficiency in data envelopment analysis[J]. European Journal of Operational Research, 2002, 143(1): 32-41.
- [45] 李小平, 朱钟棣. 中国工业行业的全要素生产率测算——基于分行业面板数据的研究[J]. 管理世界, 2005, 21(4): 56-64.
- [46] 李颖, 许月朦. 营改增背景下制造业服务化对企业绿色全要素生产率的影响[J]. 软科学, 2021, 35(9): 117-123.
- [47] 何勤, 李雅宁, 程雅馨, 等. 人工智能技术应用对就业的影响及作用机制研究——来自制造业企业的微观证据[J]. 中国软科学, 2020(S1): 213-222.
- [48] 孙文远, 刘于山. 人工智能对劳动力市场的影响机制研究[J]. 华东经济管理, 2023, 37(3): 1-9.
- [49] ACEMOGLU D, RESTREPO P. Robots and jobs: Evidence from US labor markets[J]. Journal of Political Economy, 2020, 128(6): 2188-2244.
- [50] 王永钦, 董雯. 机器人的兴起如何影响中国劳动力市场? ——来自制造业上市公司的证据[J]. 经济研究, 2020, 55(10): 159-175.
- [51] 周济, 李培根, 周艳红, 等. 走向新一代智能制造[J]. Engineering, 2018, 4(1): 28-47.
- [52] 尹洪英, 李闯. 智能制造赋能企业创新了吗? ——基于中国智能制造试点项目的准自然试验[J]. 金融研究, 2022(10): 98-116.
- [53] 王浩, 刘敬哲, 张丽宏. 碳排放与资产定价——来自中国上市公司的证据[J]. 经济学报, 2022, 9(2): 28-75.
- [54] 覃凤展. 双碳背景下缫丝企业能源消耗及碳减排潜力——以河池市宜州区缫丝企业为例[J]. 应用能源技术, 2022(12): 39-42.

- [55] 温素彬, 张金泉, 焦然. 智能制造、市场化程度与企业运营效率——基于 A 股制造业上市公司年报的文本分析[J]. 会计研究, 2022(11): 102-117.
- [56] LEWBEL A. Constructing instruments for regressions with measurement error when no additional data are available[J]. *Econometrica*, 1997, 65(5): 1201-1213.
- [57] 杨金玉, 彭秋萍, 葛震霆. 数字化转型的客户传染效应——供应商创新视角[J]. 中国工业经济, 2022(8): 156-174.
- [58] 黄群慧, 余泳泽, 张松林. 互联网发展与制造业生产率提升: 内在机制与中国经验[J]. 中国工业经济, 2019(8): 5-23.
- [59] 杨刚强, 王海森, 范恒山, 等. 数字经济的碳减排效应: 理论分析与经验证据[J]. 中国工业经济, 2023(5): 80-98.
- [60] 张吉昌, 龙静, 王泽民. 智能化转型如何赋能制造企业高质量发展? [J]. 经济与管理研究, 2023, 44(4): 3-20.
- [61] TONE K. Dealing with undesirable outputs in DEA: A slacks-based measure (SBM) approach [C]//NAPW III, Toronto: The Operations Research Society of Japan, 2004: 44-45.
- [62] 宋德勇, 朱文博, 丁海. 企业数字化能否促进绿色技术创新? ——基于重污染行业上市公司的考察[J]. 财经研究, 2022, 48(4): 34-48.
- [63] HO J L Y, WU A, XU S X. Corporate governance and returns on information technology investment: Evidence from an emerging market[J]. *Strategic Management Journal*, 2011, 32(6): 595-623.
- [64] 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.
- [65] 董必荣, 徐怀宁, 王菁华. 企业数字化战略承诺与股价崩盘风险[J]. 会计研究, 2022(9): 112-126.
- [66] 米瑞华, 倪世龙, 刘书敏. 数字技术、经济效率与城市产业结构升级[J]. 技术经济, 2024, 43(5): 107-116.
- [67] 江艇. 因果推断经验研究中的中介效应与调节效应[J]. 中国工业经济, 2022(5): 100-120.
- [68] 郑军, 林钟高, 彭琳. 货币政策、内部控制质量与债务融资成本[J]. 当代财经, 2013(9): 118-129.
- [69] LODERER C, STULZ R, WAELCHLI U. Firm rigidities and the decline in growth opportunities[J]. *Management Science*, 2017, 63(9): 3000-3020.
- [70] 田高良, 施诺, 刘晓丰. 智能制造与劳动力成本粘性——基于工业机器人应用的视角[J]. 经济管理, 2023, 45(9): 28-49.
- [71] 陈勇兵, 李辉, 林雄立. 劳动保护与企业智能制造转型——来自机器人进口的证据[J]. 数量经济技术经济研究, 2023, 40(6): 133-152.
- [72] 周鹏, 王卓, 谭常春, 等. 数字技术创新的价值——基于并购视角和机器学习方法的分析[J]. 中国工业经济, 2024(2): 137-154.

How Can Intelligent Manufacturing Improve the Carbon Total Factor Productivity of Enterprises: From the Perspective of Factor Input Cost and Structure

Wang Yuyan, Tang Chenxin

(School of Economics, Anhui University, Hefei 230601, China)

Abstract: The report of the 20th National Congress of the Communist Party of China emphasizes the promotion of high-end, intelligent, and green development in the manufacturing industry. Based on the GML-SBM and SBM-DDF models, the carbon total factor productivity (CTFP) of manufacturing A-share listed companies from 2012 to 2022 was calculated. The impact and channels of intelligent manufacturing on enhancing enterprise CTFP were explored from both input and application perspectives. It is found that intelligent manufacturing significantly improves enterprise CTFP, with technological efficiency change being the main driving force. Intelligent manufacturing primarily enhances enterprise CTFP through four pathways: reducing capital and labor usage costs, promoting capital deepening, and improving capital output efficiency. The impact and channels are stronger for young enterprises and non-state-owned enterprises, enterprises in highly competitive industries and technology-intensive industries, enterprises in regions with high levels of intellectual property protection, and enterprises in industrial bases. The findings provide policy insights for the implementation of intelligent manufacturing strategies and the achievement of “dual carbon” targets, and have significant reference value for the intelligent transformation of manufacturing enterprises.

Keywords: intelligent manufacturing; total factor productivity of carbon; element input; element cost; element structure