

人工智能背景下制造业企业全要素生产率的研究

王雷, 陈杭肖

东华大学旭日工商管理学院, 上海

收稿日期: 2024年8月5日; 录用日期: 2024年8月20日; 发布日期: 2024年9月10日

摘要

我国人工智能技术的发展主要是从2006年深度学习网络兴起后开始的, 由此不断向前推进。从经验上看, 自2006年深度学习网络出现后, 制造业企业全要素生产率随着其对人工智能技术应用的增加而有所提高。目前, 在新一轮科技革命发展下人工智能技术的应用更是直接对制造业企业的全要素生产率产生了重要作用。本文主要通过双重固定效应模型考察人工智能技术对制造业企业全要素生产率的影响, 研究结果表明: 1) 人工智能技术对制造业企业的全要素生产率存在正向且显著的影响; 2) 从地理位置角度来看, 在东部地区, 人工智能技术对制造业企业的全要素生产率的影响更大。

关键词

人工智能, 制造业企业, 全要素生产率

Research on Total Factor Productivity of Manufacturing Enterprises under the Background of Artificial Intelligence

Lei Wang, Hangxiao Chen

Glorious Sun School of Business and Management, Donghua University, Shanghai

Received: Aug. 5th, 2024; accepted: Aug. 20th, 2024; published: Sep. 10th, 2024

Abstract

The development of artificial intelligence technology in China primarily commenced following the emergence of deep learning networks in 2006 and has since been consistently advanced. Empirically, the total factor productivity of manufacturing enterprises has shown an increase concomitant

with the growing application of artificial intelligence technology subsequent to the advent of deep learning networks in 2006. Currently, amidst a new wave of scientific and technological revolution, the direct impact of artificial intelligence technology on the total factor productivity of manufacturing enterprises is substantial. This study predominantly investigates the influence of artificial intelligence technology on the total factor productivity of manufacturing enterprises through a dual fixed effect model. The research findings indicate that: 1) Artificial intelligence technology exerts a positive and significant influence on the total factor productivity of manufacturing enterprises; 2) Geographically, within the eastern region, AI technology demonstrates a more pronounced impact on the total factor productivity of manufacturing enterprises.

Keywords

Artificial Intelligence, Manufacturing Enterprises, Total Factor Productivity

Copyright © 2024 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

改革开放后, 中国制造业发展迅速。我国制造业占全球的比重从 1990 年的 2.7% (居世界第九位) 上升到 2007 年的 13.2% (居世界第二); 2010 年我国制造业占全球的比重进一步提高到 19.8%, 跃居世界第一。之后, 我国更是稳居世界第一制造大国的地位。与此同时, 我国制造业增加值也从 2012 年的 16.98 万亿元增加到 2021 年的 31.4 万亿元; 截至 2022 年, 我国全部工业增加值已经突破了 40 万亿元大关, 占 GDP 比重达到了 33.2%, 其中制造业增加值占 GDP 比重为 27.7%。中国制造业规模在高端制造业领域不断突破, 例如: 新能源汽车、高铁、超级计算机、载人航天等, 为促进我国制造企业转型升级, 推动我国经济高质量发展, 提高我国综合势力和国际竞争力做出了巨大贡献[1]。

然而, 随着社会和科技的发展, 制造业的发展弊端逐渐显现出来, 主要集中在劳动力优势逐渐消失、关键技术能力不强、国际竞争日渐加剧等方面。在劳动力优势方面, 由于经济持续增长而导致劳动力需求更加旺盛以及人们生活水平提高后对工资的要求增加, 劳动力不断成本上涨, 这使得许多低端劳动密集型企业逐渐转向劳动力成本更低的国家, 所以随着我国的劳动力优势逐渐消失[2] [3]。在关键技术方面, 由于中国制造业起步较晚, 基础设备相对来说较落后, 仍需国外提供在生产过程中所需要的关键技术, 所以我国制造业还处于全球价值链的中低端[4]。此外, 再加上中美贸易摩擦、地区冲突等外在因素, 也进一步加剧了国际之间的竞争[5]。目前, 我国虽然制造业在全球范围内具备一定的规模优势, 但是从高质量发展角度来看, 中国制造业与美国、德国等发达国家的差距依然明显[6]。

在上述背景下, 我国制造企业要想实现发展, 必须突破现有的瓶颈。而人工智能作为第四次工业革命的产物, 具有基础性和外溢性特征, 不仅可以帮助我国制造企业提高运营智能化水平和劳动生产率, 降低运营成本, 还可以改变制造业的生产和决策模式, 有助于企业及时应对变化的外部环境, 提高自身的市场竞争能力; 甚至人工智能技术可以推动中国制造由价值链低端向高附加值两端延伸, 提高我国的国际竞争力[7]。在此背景下, 中国政府应积极抓住人工智能发展带来的优势, 加快创新步伐的决心。回顾已有研究内容, 目前关于人工智能对制造业企业全要素生产率影响的实证研究较少, 因此, 本文试图运用双重固定效应模型, 从经验上检验人工智能对我国制造业企业全要素生产率的影响并得出结论, 以期弥补现有研究的不足。

2. 模型构建与变量说明

本文采用双重固定效应模型来进一步探究分析人工智能对制造业企业全要素生产率的影响, 该模型的基准回归设定如下所示:

$$OP_{it} = \beta_1 AI_{it} + \alpha_j \text{control}_{it} + \sum \text{Year} + \sum \text{ID} + \varepsilon_{it} \quad (1)$$

在基准回归式(1)中, i 表示制造业企业编号, t 表示年份; OP_{it} 为被解释变量, 表示 i 企业在 t 年的全要素生产率水平; AI_{it} 为核心解释变量, 表示 i 企业在 t 年的人工智能应用情。而其估计系数 β_1 也是本文的重点关注对象, 反映了人工智能对制造业企业全要素生产率的实际影响, 若该值正向显著, 则表明人工智能在一定程度上促进制造业企业全要素生产率的提高, 若该值负向显著, 则表明人工智能在一定程度上抑制制造业企业全要素生产率的提高, 若该值不显著, 则表明人工智能对制造业企业全要素生产率无明显影响。 j 表示控制变量的数量, 在本文中主要包括企业年龄、企业规模、资产负债率、董事会规模、营业收入增长率、第一大股东投资占比、投资机会以及总资产增长率; U_{it} 则表示误差项。

本文将 2010~2020 年在中国沪深正常上市的 A 股制造业企业数据作为样本数据, 使用的数据主要来源于上市公司年报、马克数据网以及国泰安数据库等。在参考当下学术界对全要素生产率研究的基础上, 本文根据自己的研究目的和制造业企业自身的特点, 确定了被解释变量(OP)、核心解释变量(AI)以及相关的控制变量, 各变量的具体说明可见表 1。

Table 1. All variable descriptions and descriptive statistics in this article

表 1. 本文所有变量说明与描述性统计

变量类型	变量	定义	说明
被解释变量	OP	全要素生产率	采用 OP 法计算的全要素生产率
核心解释变量	AI	人工智能	Log(人工智能相关词频数 + 1)
	Ln_age	企业年龄	取(当年年份 - 成立年份 + 1)的对数值
	Ln_reg	企业规模	取企业总资产的对数值
	Lev	资产负债率	期末总负债期末/总资产
	Growth	企业成长性	(本期末总资产 - 上年期末总资产)/ 上年期末总资产)
控制变量	Rate	营业收入增长率	本年营业收入增长额/上年营业收入总额
	Top1	第一大股东持股比例	第一大股东持股数量/总股数
	Board	董事会规模	取董事会总人数的对数值
	Tq	投资机会	托宾 Q 值: (流通股市值 + 非流通股股份数 每股净资产 + 负债账面值)/资产账面值

3. 实证分析

3.1. 描述性分析

本文对被解释变量(OP)、核心解释变量(AI)以及所有控制变量进行了描述性统计, 具体可见下表 2。结果表明, 每个变量的观测值都是 15918, 数据不存在缺失的情况, 且没有有存在特别极端的异常值, 符合基准回归的要求。但是我们观察到, 第一大股东持股比例(Top1)和投资机会(Tq)这两个控制变量的标准差都大于 1, 分别为 14.243 和 1.298; 并且企业规模(Ln_reg)和营业收入增长率(Rate)这两个控制变量的标准差接近于 0.5, 分别为 0.484 和 0.478, 这说明当下我国制造业的发展在企业规模、企业投资机会和企业自身竞争力等方面存在差异。

Table 2. Describe the statistical table
表 2. 描述统计表

变量名称	观察值	平均值	标准差	最小值	最大值
被解释变量(OP)	15918	6.710	0.787	4.964	8.812
核心解释变量(AI)	15918	0.614	0.979	0	3.989
企业年龄(Ln_age)	15918	1.267	0.147	0.477	1.748
企业规模(Ln_reg)	15918	3.466	0.484	2.307	4.781
资产负债率(Lev)	15918	0.423	0.188	0.066	0.899
企业成长性(Growth)	15918	0.149	0.288	-0.264	2.084
营业收入增长率(Rate)	15918	0.191	0.478	-0.667	2.951
第一大股东持股比例(Top1)	15918	34.217	14.243	9.032	73.186
董事会规模(Board)	15918	2.132	0.187	1.609	2.639
投资机会(Tq)	15918	2.025	1.298	0	8.587

3.2. 基准回归

Table 3. Benchmark regression analysis results
表 3. 基准回归分析结果

变量	模型 1 (OP)	模型 2 (OP)
AI	0.055*** (6.02)	0.047*** (5.49)
Ln_age	-	0.637*** (3.19)
Ln_size	-	0.138** (2.46)
Lev	-	0.156*** (8.83)
Growth	-	-0.020 (-1.63)
Rate	-	0.181** (2.50)
Top1	-	0.126*** (2.72)
Board	-	0.003*** (2.60)
Tq	-	0.004 (0.74)
常数项	6.347*** (407.68)	4.684*** (17.00)
企业固定效应	是	是
行业固定效应	是	是
PseudoR2	0.0505	0.1943
观测值	15918	15918

注：括号里的值为 t 统计量；***表示估计系数在 1% 水平上显著，**表示估计系数在 5% 水平上显著，*表示估计系数在 10% 水平上显著。

表3的模型1为不加控制变量的基础双重固定效应模型, 而模型2则为加入控制变量之后的双重固定效应模型。实证结果表明, 不加入控制变量时, 人工智能(AI)的系数在1%的水平上正向且显著, 初步证明了在新一轮科技革命的背景下, 人工智能确实会对我国制造业企业的全要素生产率的提高存在一定的正面影响。在加入控制变量后, 人工智能(AI)系数符号依旧为正向, 并且还是在1%的显著性水平上通过了检验, 这说明控制变量的加入并没有改变核心解释变量(AI)参数估计值的符号和显著性水平, 侧面说明本文的研究结果是稳健的。

3.3. 稳健性检验

为确保回归结果的可靠性, 本文将对实证结果进行稳健性检验。本文的稳健性检验主要分为重新度量关键性指标和修正计量模型两大部分。

3.3.1. 全要素生产率变量的再度量

Table 4. Replace the dependent variable—total factor productivity of the enterprise

表 4. 替换被解释变量——企业的全要素生产率

变量	模型 1 (LP)	模型 2 (LP)	模型 3 (OLS)	模型 4 (OLS)	模型 5 (FE)	模型 6 (FE)	模型 7 (GMM)	模型 8 (GMM)
AI	0.078*** (7.42)	0.047*** (5.54)	0.088*** (7.62)	0.043*** (4.96)	0.094*** (7.86)	0.043*** (4.83)	0.050*** (5.89)	0.047*** (5.73)
Ln_age	-	0.543*** (2.77)	-	0.704*** (3.05)	-	0.720*** (3.07)	-	0.571*** (2.65)
Ln_size	-	0.806*** (15.04)	-	1.165*** (19.17)	-	1.317*** (21.33)	-	0.073 (1.35)
Lev	-	0.163*** (9.17)	-	0.153*** (7.49)	-	0.152*** (7.33)	-	0.155*** (8.85)
Growth	-	-0.021* (-1.76)	-	-0.019 (-1.54)	-	-0.019 (-1.51)	-	-0.022* (-1.89)
Rate	-	0.116 (1.62)	-	0.241*** (3.14)	-	0.263*** (3.38)	-	0.067 (0.95)
Top1	-	0.113** (2.47)	-	0.131*** (2.80)	-	0.136*** (2.87)	-	0.102** (2.36)
Board	-	0.003* (2.73)	-	0.003** (2.17)	-	0.003** (2.07)	-	0.003*** (2.80)
Tq	-	0.008 (1.35)	-	0.005 (0.79)	-	0.004 (0.58)	-	0.014*** (2.51)
常数项	8.024*** (479.40)	4.265*** (15.73)	10.358** (604.87)	5.150*** (16.56)	11.038*** (612.68)	5.287*** (16.78)	5.387*** (409.70)	4.087*** (14.13)
企业固定效应	是	是	是	是	是	是	是	是
行业固定效应	是	是	是	是	是	是	是	是
PseudoR2	0.0371	0.5404	0.032	0.6412	0.0302	0.6742	0.0505	0.1293
观测值	15918	15918	15160	15160	15160	15160	15160	15160

注: 括号里的值为 t 统计量; ***表示估计系数在 1% 水平上显著, **表示估计系数在 5% 水平上显著, *表示估计系数在 10% 水平上显著。

目前, 企业全要素生产率的计算方式有多种, 为了确保实证结果的可靠性, 本文将参照鲁晓东和连

玉君的做法, 采用 LP 法、GMM 法、OSL 法以及 FE 法重新测算企业全要素生产率这个指标并进行稳健性检验[8]。若在被解释变量被替换的情况下, 人工智能对制造业企业全要素生产率的影响还是正向且显著的, 那就说明之前的回归结果可靠, 检验通过, 否则反之。

表 4 的模型 1、模型 3、模型 5 和模型 7 分别汇报了未加入控制变量时的回归结果, 模型 2、模型 4、模型 6 和模型 8 则汇报了加入控制变量后的回归结果。结果显示, 无论是否加入控制变量, 无论用哪种方法测量企业的全要素生产率, 核心解释变量人工智能水平(AI)的估计系数在统计上均显著, 并且还是在 1%的水平上显著, 因此可以进一步证明基准回归结果的可靠性。

3.3.2. 人工智能变量的再度量

目前学术界对于人工智能的定义并没有完全达成共识, 部分学者认为人工智能对于制造业企业而言最大的应用就是工业机器人, 工业机器人可以通过替代部分劳动力来提高企业的生产效率。因此, 本文也将从工业机器人角度出发, 参考王永钦和董雯的测量方法[9], 构造出中国制造业上市企业的工业机器人渗透率(AI_1), 以此来重新度量制造业企业的人工智能水平。具体的计算公式(2)如下:

$$AI_1 = \ln \left(\frac{L_{ij}}{Industry_i} + \frac{R_{it}}{L_i} \right) \tag{2}$$

其中, i 表示制造业下的具体行业, j 表示该制造业的企业人数; AI_1 用于衡量制造业企业的工业机器人渗透度, Industry_i 表在基期年份(2010 年)在 i 行业企业员工数量的中位数; R_{it} 表示 i 行业在 t 年的企业员工数量; L_i 表示在基期年份(2010 年) i 行业的企业员工数量。

Table 5. Replace the dependent variable 1—robot penetration

表 5. 替换被解释变量 1——机器人渗透度

变量	模型 1 (OP)	模型 2 (OP)
AI_1	0.001** (2.09)	0.001** (1.96)
Ln_age	-	0.615*** (3.04)
Ln_size	-	0.153*** (2.71)
Lev	-	0.156*** (8.78)
Growth	-	-0.019 (-1.56)
Rate	-	0.194*** (2.65)
Top1	-	0.135*** (2.90)
Board	-	0.003** (2.37)
Tq	-	0.004 (0.77)
常数项	6.345*** (398.57)	4.640*** (16.57)
企业固定效应	是	是
行业固定效应	是	是
PseudoR2	0.0467	0.2015
观测值	15918	15918

注: 括号里的值为 t 统计量; ***表示估计系数在 1%水平上显著, **表示估计系数在 5%水平上显著, *表示估计系数在 10%水平上显著。

表 5 展示了人工智能指标重新度量后的回归结果。结果表明, 无论是否加入控制变量, 核心解释变量(AI_1)估计系数都在 5% 的水平上显著为正, 这说明制人工智能的应用确实会进一步提高制造业企业的全要素生产率, 证明了基准回归结果的可靠性。

此外, 部分学者认为制造业企业的数字化程度也可以体现人工智能的应用程度, 因为一般能够应该人工智能的企业, 其数字化程度都不低。因此, 数字化这一指标在一定程度上也可以用于衡量制造业企业的人工只能应用情况。目前, 数字化的衡量指标有很多, 为了确保结果的可靠性, 本文主要是参考了两位学者的测算方法, 首先是根据《管理世界》中吴非等的测算方法[10], 对五大维度(具体包括: 大数据技术、云计算技术、区块链技术、人工智能技术和数字技术运用)76 个有关“数字化”的词频进行统计, 计算出制造业企业第一个数字化程度(AI_2)的指标; 其次, 本文根据《财贸经济》中赵宸宇的测算方法, 对四大维度(互联网商业模式、现代信息系统、数字技术应用和智能制造)99 个有关“数字化”的词频进行统计[11], 计算出制造业企业第二个数字化程度(AI_3)的指标; 最后, 将这两个数字化程度指标作为本文核心解释变量的替代变量重新进行回归分析, 具体的回归结果见表列(3)和列(4)。

Table 6. Replace the dependent variable 2—degree of digitization
表 6. 替换被解释变量 2——数字化程度

变量	模型 1 (OP)	模型 2 (OP)	模型 3 (OP)	模型 4 (OP)
AI_2	0.002*** (3.65)	0.002*** (3.20)	-	-
AI_3	-	-	0.001*** (4.48)	0.001*** (3.58)
Ln_age	-	0.627*** (3.12)	-	0.634*** (3.14)
Ln_size	-	0.145*** (2.58)	-	0.139** (2.45)
Lev	-	0.156*** (8.81)	-	0.155*** (8.79)
Growth	-	-0.019 (-1.58)	-	-0.019 (-1.58)
Rate	-	0.187*** (2.56)	-	0.188*** (2.59)
Top1	-	0.126*** (2.73)	-	0.126*** (2.72)
Board	-	0.003** (2.46)	-	0.003** (2.48)
Tq	-	0.004 (0.76)	-	0.004 (0.76)
常数项	6.351*** (408.58)	4.677*** (16.80)	6.342*** (399.16)	4.682*** (16.68)
企业固定效应	是	是	是	是
行业固定效应	是	是	是	是
PseudoR2	0.0517	0.2020	0.0514	0.1972
观测值	15918	15918	15918	15918

注: 括号里的值为 t 统计量; ***表示估计系数在 1% 水平上显著, **表示估计系数在 5% 水平上显著, *表示估计系数在 10% 水平上显著。

上表 6 说明, 将数字化作为人工智能的代理变量时, 加入控制变量前后, 核心解释变量(AI_1 和 AI_2) 的系数都在 1% 水平上显著为正, 即随制造业企业数字化程度的增加, 其全要素生产率也会随之提高, 这从侧面说明了应用了人工智能的制造企业, 其数字化程度也相对较高, 从而对该制造业企业全要素生产率的提高有一定的促进作用, 进一步证明了人工智能对制造业企业全要素生产率的正面影响和基准回归结果的稳健性。

3.4. 内生性检验

在基准回归的过程中, 可能存在把重要变量遗漏或者逆向因果关系等情况, 这将导致本文的回归结果出现内生性问题。因此, 本文打算使用工具变量法来缓解内生性情况。通过文献阅读, 本文参考了罗润东和郭怡笛, 将人工智能专利数量作为工具变量, 并用两阶段最小二乘法(2SLS)来试着解决计量估计模型可能存在的内生性问题[12]。人工智能专利数量能够直接表现出制造企业的研发实力和企业的自主创新能力。一般来说, 自主创新能力和研发实力强的企业往往更有能力从“制造”向“智造”转型, 因此我们可以将制造业企业的人工智能专利数作为工具变量, 为了减小误差, 我们还将专利数量加 1 后取对数。

由表 7 可知, 核心解释变量和工具变量之间的关系均在 1% 的水平上显著为正, 说明两者存在相关性, 并且结果都通过了不可识别检验、弱工具变量检验和豪斯曼检验等, 再一次证明了本文基准回归的可靠性。

Table 7. Instrumental variable test table

表 7. 工具变量检验表

变量	模型 1	模型 2
	AI	IV
	工具变量模型第一阶段	
lnin	0.059*** (6.38)	-
	工具变量模型第二阶段	
AI	-	0.239*** (2.67)
不可识别检验	通过	通过
过度识别检验	通过	通过
弱工具变量检验	通过	通过
豪斯曼检验	通过	通过
控制变量	是	是
企业固定效应	是	是
行业固定效应	是	是
观测值	13773	13773

注: 括号里的值为 t 统计量; ***表示估计系数在 1% 水平上显著, **表示估计系数在 5% 水平上显著, *表示估计系数在 10% 水平上显著。

4. 进一步研究

接着, 本文从地理位置展开异质性分析, 本文根据我国最新地理位置的划分, 将样本数据分为东部、

中西部和东北三大区域, 具体结果如下表 8。模型 1 和模型 2 显示了在东部地区和中西部地区的制造业企业样本回归结果, 而模型 3 则显示了在东北地区的制造业企业样本回归结果。结果显示, 当制造业企业在东部地区和中西部地区时, 核心解释变量(AI)的系数均为正向且在 1% 的水平上显著, 而当制造业企业在东北地区时, 核心解释变量(AI)的系数不显著。从整体上而言, 东部和中西部地区的人工智能应用均正向作用于制造业企业全要素生产率的提高, 而东北地区人工智能应用对制造业企业全要素生产率提升的影响是不显著的。但从影响程度上来看, 人工智能对于制造业企业的影响在东部地区要远大于中西部地区, 这主要是东部地区凭借其便利的交通、更深的对外交流以及更强的技术引进能力等优势, 更多资金、人才和技术。

Table 8. Regression analysis from the perspective of geographical location

表 8. 从地理位置角度出发的回归分析

变量	模型 1 (OP)	模型 2 (OP)	模型 3 (OP)
AI	0.048*** (4.86)	0.039** (2.15)	0.064 (1.07)
常数项	4.457*** (13.51)	5.410*** (9.16)	3.866* (1.74)
控制变量	是	是	是
固定效应	是	是	是
调整的 R2	0.1983	0.1768	0.1359
观测值	10409	4789	720

注: 括号里的值为 t 统计量; ***表示估计系数在 1% 水平上显著, **表示估计系数在 5% 水平上显著, *表示估计系数在 10% 水平上显著。

5. 研究结论与不足

本文收集了 2010 年至 2022 年中国上市公司的数据, 从企业的角度考察人工智能如何影响制造业企业的全要素生产率。本文的研究结果报告如下: 第一, 本文发现人工智能对制造业企业的全要素生产率有显著的正向影响, 并且这个影响通过了多方面的稳健型检验。这说明制造业企业应用人工智能技术后不仅可以合理优化生产线, 提高员工的知识技能, 还可以及时响应市场的变化, 确保可持续增长的增长和核心竞争能力。第二, 本文从地理位置角度出发。结果表明, 人工智能对制造业企业全要素生产率的提升作用, 东部地区和中西部地区显著为正, 东北地区不显著, 并且东部地区的影响大于中西部地区, 这一差异主要还是由地区间的经济发展水平、人才数量以及政策支持等因素形成的。因此, 政府应该加大对人工智能技术研发的投资, 支持初创企业和研究机构, 推动技术创新和产业升级。

本文可能存在以下几个方面的不足: 第一, 本文所需的数据主要来源于国泰安、马克数据网等, 因为目前没有 2023 年的数据, 所以本文主要收集了 2010 年至 2022 年中国上市公司的数据。而且年报数据会存在部分的缺失, 所以样本量会有一定的减少, 这可能使本文无法得出最精准的结果。第二, 本文的异质性分析主要是从地理位置角度出发, 事实上, 影响人工智能对制造业企业全要素生产率的因素很多, 这将在未来的研究中进一步解决。第三, 本文考虑了人工智能对制造业企业全要素生产率的直接影响, 未来可以通过加入中介变量或者调节变量来进一步研究这一过程的影响机制。

参考文献

- [1] 王姝楠. 数字经济背景下中国制造业转型升级研究[D]: [博士学位论文]. 北京: 中共中央党校, 2022.

- [2] 王兰. 关于中国成为“世界工厂”的思考[J]. 现代营销(下旬刊), 2019(5): 16-17.
- [3] 范保群, 郑世林, 黄晴. 中国制造业外迁: 现状和启示[J]. 浙江工商大学学报, 2022(6): 85-99.
- [4] 张崇杰. “一带一路”背景下中国制造业转型升级路径研究[D]. [博士学位论文]. 西安: 西北大学, 2022.
- [5] 郭鑫, 张婧婧, 池康伟, 等. 中国与美国、日本、德国制造业国际竞争优势比较研究及相关政策建议[J]. 中国科学院院刊, 2023, 38(8): 1130-1153.
- [6] 吕铁, 刘丹. 制造业高质量发展: 差距、问题与举措[J]. 学习与探索, 2019(1): 111-117.
- [7] 闫晓杰, 孔祥栋. 加快人工智能与制造业深度融合, 构筑国际竞争新优势[J]. 中国信息化, 2023(9): 110-112.
- [8] 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.
- [9] 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.
- [10] 吴非, 胡慧芷, 林慧妍, 等. 企业数字化转型与资本市场表现——来自股票流动性的经验证据[J]. 管理世界, 2021, 37(7): 130-144.
- [11] 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, 42(7): 114-129.
- [12] 罗润东, 郭怡笛. 人工智能技术进步会促进企业员工共同富裕吗? [J]. 广东社会科学, 2022(1): 54-63.