

服务国家战略创新统计赋能

——基于多行业人工智能劳动力替代风险的统计建模与赋能研究

吴林臻, 杨巧燕*

昌吉学院数学与数据科学学院, 新疆 昌吉

收稿日期: 2026年9月21日; 录用日期: 2026年10月12日; 发布日期: 2026年10月26日

摘要

在数字经济与人工智能广泛渗透背景下, 精准评估多行业人工智能劳动力替代风险, 对产业转型、就业稳定和政策制定意义重大。研究遵循“数据预处理 - EDA - 模型构建 - 验证优化 - 聚类分析 - 结论建议”流程。数据预处理采用四步特征筛选: 以Pearson相关系数和VIF剔除共线性, 结合卡方检验与随机森林重要性交叉验证, 最终保留6个核心特征, 规避数据泄露与筛选漏洞。模型构建采用分类(监管壁垒等级)与回归(自动化风险指数)双目标, 选用GBR、GBC等, 经调参与融合, 确定GBR + GBC加权融合为最优。采用SHAP进行全局和局部解释, 发现替代弹性是核心特征, 影响方向符合经济逻辑。通过轮廓系数、Calinski-Harabasz指数和类内方差显著性检验验证K-means聚类有效性, 刻画不同风险等级行业特征。以替换样本、替换算法、剔除高影响行业三项检验验证稳健性, 结果显示模型稳定、泛化能力强。研究发现: 制造、零售、物流等劳动密集型及部分服务密集型行业为人工智能替代高风险领域; 创意、教育等依赖人类创意与情感交互的行业为低风险领域; 不同行业替代风险的核心影响因素差异显著。

关键词

人工智能劳动力替代, 统计建模, 监管壁垒, 聚类分析, 创新统计赋能

Serving National Strategy through Innovative Statistics and Empowerment

—Statistical Modeling and Empowerment Research on AI-Driven Labor Substitution Risks across Multiple Industries

Linzhen Wu, Qiaoyan Yang*

School of Mathematics and Data Science, Changji University, Changji Xinjiang

Received: September 21, 2026; accepted: October 12, 2026; published: October 26, 2026

*通讯作者。

文章引用: 吴林臻, 杨巧燕. 服务国家战略创新统计赋能[J]. 统计学与应用, 2026, 15(10): 111-123.
DOI: 10.12677/sa.2026.1510232

Abstract

Against the backdrop of the widespread penetration of the digital economy and artificial intelligence, accurately assessing AI-driven labor substitution risks across multiple industries is of great significance for industrial transformation, employment stability and policy formulation. This research follows the workflow of “data preprocessing - EDA - model construction - validation and optimization - cluster analysis - conclusions and recommendations”. A four-step feature selection procedure is adopted in data preprocessing: Pearson correlation coefficient and VIF are used to eliminate multicollinearity, combined with cross-validation via Chi-square test and random forest feature importance. Six core features are retained in the end to avoid data leakage and selection bias. The model construction sets dual objectives including classification (regulatory barrier level) and regression (automation risk index). Algorithms such as GBR and GBC are adopted. After parameter tuning and ensemble learning, the weighted ensemble of GBR + GBC is identified as the optimal solution. SHAP is applied for global and local interpretation. The results show substitution elasticity serves as the core feature, whose impact direction conforms to economic logic. The validity of K-means clustering is verified using the silhouette coefficient, Calinski-Harabasz index and significance test of intra-cluster variance to characterize industrial features at different risk levels. Robustness is tested through three approaches: sample replacement, algorithm replacement and removal of highly influential industries. The results demonstrate that the model is stable with strong generalization ability. The study finds that labor-intensive industries including manufacturing, retail and logistics, as well as some service-intensive sectors, are high-risk areas of AI substitution; industries relying on human creativity and emotional interaction such as creativity and education are low-risk areas; core influencing factors of substitution risk vary markedly across industries.

Keywords

AI-Driven Labor Substitution, Statistical Modeling, Regulatory Barriers, Cluster Analysis, Innovative Statistical Empowerment

Copyright © 2026 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

1.1. 研究背景

人工智能在金融、法律、医疗、制造等行业广泛落地,但行业间渗透速度与替代风险差异明显,低技能劳动力失业风险上升,技能供需错配加剧。运用统计建模科学测度行业人工智能替代风险,是落实创新统计赋能的重要方向[1]。

本研究涵盖金融、法律、医疗、制造等 15 个行业共 1200 条样本,包含人力成本、人工智能推理成本、替代弹性、监管壁垒、自动化风险指数等核心变量,构建“分类 + 回归 + 聚类”一体化统计建模体系,为就业战略实施、产业转型与监管优化提供数据支撑。

1.2. 研究意义

1.2.1. 理论意义

理论上,本研究突破单一指标与单一模型局限,构建“数据预处理 - EDA - 多目标建模 - 聚类赋能”

一体化框架, 将机器学习与统计推断深度融合, 规范特征工程流程, 丰富创新统计赋能的研究内涵。

1.2.2. 实践意义

实践上, 本研究: 一是赋能就业战略, 为政府制定技能培训与失业保障政策提供数据支撑; 二是支撑产业转型, 为企业提供人工智能应用可行性评估与风险预警; 三是优化监管设计, 为差异化人工智能监管策略提供依据; 四是提升统计服务能力, 实现数据全链条服务。

1.3. 国内外研究现状

国外方面, Acemoglu 等(2022)基于在线招聘数据发现, 采用人工智能的企业会减少非人工智能岗位招聘, 并提高剩余岗位的技能要求; 相关研究已从职业暴露测度拓展到企业和劳动市场效应, 但多聚焦发达国家, 缺乏多目标协同建模[2]。

国内方面, 尹志锋等(2023)基于专利数据检验人工智能就业效应[3]; 郑丽琳、刘东升(2023)揭示机器人应用的替代与互补效应[4]; 李静等(2023)发现不同任务类型劳动者受到的影响存在差异[5]。但现有研究仍存在模型不系统、多行业对比不足、与国家战略结合不紧密等问题。

本文针对上述不足, 构建“分类 + 回归 + 聚类”一体化统计建模体系, 强化模型结果与国家战略、行业实际的结合。

2. 数据预处理

2.1. 数据来源与基本信息

2.1.1. 数据来源

本研究使用 Kaggle 公开数据集人工智能 Job Market Trends, 共 1200 条样本, 覆盖 15 个行业。

2.1.2. 变量定义

研究涉及标识变量、分类变量与连续变量三类共 12 个核心变量(表 1)。

Table 1. Definitions of core variables

表 1. 核心变量定义表

变量序号	变量名	变量含义	变量类型	变量说明
1	Role_ID	角色编号	字符型 (标识变量)	唯一标识每个样本的编号, 不参与建模, 仅用于数据溯源
2	Industry	行业	分类型	样本所属行业, 共 15 类, 涵盖金融、医疗、制造等重点领域, 是分析行业差异的核心变量
3	Human_Labor_Cost_hr	人力成本/小时	连续型	单位小时的人力成本(单位: 元), 反映劳动力价值, 是影响人工智能替代的核心成本因素
4	Tokens_per_Human_Hour	每小时人力 Token 数	连续型	单位小时人力对应的人工智能 Token 数量, 衡量人力与人工智能的效率关联, Token 数越高, 人力效率与人工智能适配度越高
5	Inference_Cost_2026	2026 年推理成本	连续型	人工智能模型推理的单位成本(单位: 元/千 Token), 反映人工智能技术应用门槛, 成本越低, 人工智能替代可行性越高

续表

6	Agent_Labor_Equivalent_Cost	代理劳动力 等效成本	连续型	人工智能替代劳动力后的等效成本(单位：元/小时)，衡量人工智能替代的经济性，等效成本越低，替代意愿越强
7	Substitution_Elasticity	替代弹性	连续型	人力成本与人工智能成本的替代程度，弹性系数越高，说明人力与人工智能的替代越容易，人工智能替代速度越快
8	人工智能_Augmentation_Factor	人工智能增 强因子	连续型	人工智能对劳动力效率的提升程度，因子越高，说明人工智能对劳动力的赋能效果越强，替代进程相对缓慢
9	Automation_Risk_Index	自动化风险 指数	连续型(回归 目标变量)	行业被人工智能自动化的风险评分(0~10分)，分数越高，人工智能替代风险越高，是本次研究的核心回归目标
10	Hardware_CapEx_Sensitivity	硬件资本支 出敏感度	连续型	行业对人工智能硬件投入的敏感程度，敏感度越高，人工智能落地成本受硬件投入影响越大，制约人工智能替代进程
11	Regulatory_Moat	监管壁垒	分类型(分类 目标变量)	行业监管严格程度，分为 High (高)、Med (中)、Low (低)三类，是本次研究的核心分类目标
12	Substitution_Year_Est	替代年份 估计	连续型	人工智能替代该行业劳动力的预计年份(如 2028、2030)，辅助分析人工智能替代进程，为政策制定提供参考

2.2. 数据清洗

数据清洗按异常值→缺失值→重复值流程完成：连续变量采用 Z-score 法($|Z| > 3$)剔除异常样本；缺失值分别用中位数(连续型)和众数(分类型)填充；重复值直接剔除。

2.3. 数据转换与特征工程

分类变量需编码、连续变量需标准化，部分特征需筛选，以适配模型训练并规避数据泄露。

2.3.1. 分类变量编码

Industry (15 类)采用独热编码(drop = “first”)转换为 14 个哑变量；Regulatory_Moat (Low/Med/High 有序分类)采用标签编码转换为 0、1、2。

2.3.2. 连续型变量标准化

连续变量采用 Z-score 标准化消除量纲差异。

$$x' = (x - \mu) / \sigma$$

2.3.3. 特征筛选

采用四步特征筛选：

第一步，剔除标识变量、原始分类变量及目标变量本身，避免数据泄露。

第二步，Pearson 与 VIF 双重检验发现 Human_Labor_Cost_hr 与 Tokens_per_Human_Hour 存在严重

共线性($r = 0.84$, $VIF > 10$), 保留与目标更相关的前者。

第三步, ANOVA 结合随机森林重要性交叉验证, 保留 $p < 0.05$ 且重要性前 70% 的变量; 第四步, Variance Threshold (0.01)剔除低方差特征。

最终保留 6 个核心特征: 人力成本、人工智能推理成本、代理劳动力等效成本、替代弹性、人工智能增强因子、硬件资本支出敏感度。

2.4. 预处理后数据概况

预处理后按 7:2:1 划分训练集(788 条)、验证集(225 条)与测试集(113 条), 如表 2、图 1 所示。

Table 2. Dataset splitting results
表 2. 数据集划分结果表

数据集类型	样本数量(条)	占比(%)	核心用途
训练集	788	70.0	用于模型训练, 拟合模型参数, 奠定模型基础
验证集	225	20.0	用于模型参数调优、超参数选择, 验证模型初步性能
测试集	114	10.0	用于最终模型验证与评估, 检验模型泛化能力




Figure 1. Data visualization
图 1. 数据可视化

3. 探索性数据分析(EDA)

3.1. 双变量与多变量分析

通过相关性分析与行业差异分析, 挖掘变量关联规律, 为建模提供依据。

3.1.1. 相关性分析

Pearson 分析(图 2)显示: 替代弹性与风险指数强正相关($r = 0.84$), 代理劳动力等效成本强负相关($r =$

-0.72)；人力成本中等正相关($r = 0.56$)，人工智能推理成本($r = -0.53$)与人工智能增强因子($r = -0.48$)中等负相关。特征间无严重共线性。ANOVA 显示所有特征与监管壁垒显著相关($p < 0.05$)。




Figure 2. Comparison of predicted and actual values of the typical AI substitution risk index
图 2. 典型人工智能替代风险指数预测值与真实值对比

3.1.2. 特征与目标变量关联分析

可视化分析表明：替代弹性高且人工智能增强因子低时风险指数最高(均值 7.85，集中于制造、物流)；反之则最低(均值 2.36，集中于创意、教育)。高监管壁垒行业人力成本较高、替代弹性较低，替代难度更大。

3.2. 行业差异分析

以自动化风险指数为核心指标，将 15 个行业分为三类(表 3)。

Table 3. Classification of AI substitution by industry
表 3. 各行业人工智能替代分类

风险等级	自动化风险指数范围	涵盖行业	行业均值
高风险	7.0~9.5	制造、零售、物流	7.82
中风险	4.0~7.0	金融、保险、电信、政府	5.36
低风险	0.8~4.0	创意、教育、医疗、法律、MLOps	2.98

3.2.1. 行业人工智能替代风险差异

高风险为制造、物流、零售(流程标准化、重复性高)；中风险为金融、保险、电信、政府(部分可替代但核心岗位需人类判断)，相关研究也发现制造业与服务业受自动化冲击后的调整路径不同[6]；低风险为创意、教育、医疗、法律、MLOps (依赖创意、情感与专业判断)，人机协作的组织效果还取决于员工态度与能力互补[7]。

3.2.2. 行业核心影响因素差异

回归分析表明, 高风险行业核心因素为替代弹性(0.82)与代理劳动力等效成本(-0.76); 中风险行业为 人力成本(0.63)与人工智能推理成本(-0.58); 低风险行业为人工智能增强因子(-0.81)。

4. 统计建模与优化

本章构建回归模型(预测自动化风险指数)与分类模型(预测监管壁垒等级), 遵循“模型选择→训练→ 优化→评估→融合”流程。

4.1. 模型训练

回归模型选用线性回归(基准)、GBR、RFR; 分类模型选用逻辑回归(基准)、GBC、RFC。初步评估 (表 4、表 5)显示 GBR 与 GBC 性能最优, 进入参数优化。

Table 4. Preliminary evaluation of regression models (validation set)

表 4. 回归模型初步评估(验证集)

回归模型	R ²	RMSE	MAE
线性回归	0.72	0.89	0.71
梯度提升回归(GBR)	0.88	0.52	0.41
随机森林回归(RFR)	0.86	0.57	0.45

Table 5. Evaluation results of classification models (validation set)

表 5. 分类模型评估结果(验证集)

分类模型	准确率	精确率	召回率	F1 分数
逻辑回归	0.75	0.74	0.73	0.73
梯度提升分类(GBC)	0.89	0.88	0.87	0.88
随机森林分类(RFC)	0.87	0.86	0.85	0.86

4.2. 模型参数优化

采用网格搜索结合 5 折交叉验证优化超参数。

4.2.1. 梯度提升回归(GBR)参数优化

GBR 最优参数: $n_estimators = 150$ 、 $learning_rate = 0.1$ 、 $max_depth = 3$ 、 $min_samples_split = 4$, 验证 集 $R^2 = 0.92$ 。

4.2.2. 梯度提升分类(GBC)参数优化

GBC 最优参数: $n_estimators = 100$ 、 $learning_rate = 0.1$ 、 $max_depth = 3$ 、 $min_samples_leaf = 2$, 验证 集准确率 = 0.92。

4.2.3. 模型过拟合与欠拟合校验

过拟合/欠拟合校验显示, GBR 与 GBC 训练集与验证集指标差值均为 0.02, 无明显过拟合或欠拟 合。

4.3. 模型最终评估

使用测试集(113 条样本)进行最终评估。

4.3.1. 回归模型最终评估

GBR 模型测试集 $R^2 = 0.91$ 、 $RMSE = 0.43$ 、 $MAE = 0.34$ ，显著优于 RFR 与线性回归(表 6、图 3)。

Table 6. Regression model: final evaluation
表 6. 回归模型最终评估

回归模型	R^2	RMSE	MAE
线性回归(基准)	0.70	0.95	0.76
随机森林回归(RFR)	0.84	0.61	0.49
优化后梯度提升回归(GBR)	0.91	0.43	0.34




Figure 3. Comparison of evaluation metrics for classification models
图 3. 分类模型评估指标对比

4.3.2. 分类模型最终评估

GBC 模型测试集准确率 = 0.91、 $F1 = 0.90$ ，优于 RFC 与逻辑回归(表 7、图 3)。

Table 7. Classification model: final evaluation
表 7. 分类模型最终评估

分类模型	准确率	精确率	召回率	F1 分数
逻辑回归(基准)	0.73	0.72	0.71	0.72
随机森林分类(RFC)	0.85	0.84	0.83	0.84
优化后梯度提升分类(GBC)	0.91	0.90	0.89	0.90

4.3.3. 模型可解释性分析(SHAP)

依据可解释人工智能研究中的 SHAP 框架[8]，分析显示，特征重要性排序为：替代弹性 > 代理劳动力等效成本 > 人力成本 > 人工智能推理成本 > 人工智能增强因子 > 硬件资本支出敏感度。替代弹性 SHAP 均值 0.87，为最核心特征。

影响方向上，替代弹性与风险指数正相关，各成本变量与人工智能增强因子负相关，符合经济逻辑。局部分析显示制造业风险指数 7.92，创意行业仅 2.87。

4.4. 聚类模型有效性检验

聚类检验：轮廓系数 0.68，CH 指数 386.52 (高于 $K = 2/4/5$)，类间 ANOVA p 值均 < 0.05 ， $K = 3$ 聚类有效(图 4)。




Figure 4. Visualization of k-means clustering results
图 4. K-Means 聚类结果可视化

5. 多行业人工智能劳动力替代风险分析与赋能建议

5.1. 多行业人工智能劳动力替代风险精准分析

利用融合模型对 1127 条样本进行预测，从风险分布、行业对比、趋势预测三个维度开展分析。

5.1.1. 多行业替代风险等级分布

15 个行业风险等级分布如表 8、图 5 所示：

Table 8. Multi-industry substitution analysis levels
表 8. 多行业替代分析等级

风险等级	自动化风险指数范围	涵盖行业	行业数量	平均风险指数
高风险	7.0~9.5	制造、零售、物流	3 个	7.95
中风险	4.0~7.0	金融、保险、电信、政府、能源、房地产	6 个	5.42
低风险	0.8~4.0	创意、教育、医疗、法律、MLOps、咨询	6 个	3.05




Figure 5. Multi-industry AI substitution risk levels
图 5. 多行业人工智能代替风险等级

高风险 3 个(制造、零售、物流)，平均风险指数 7.95，工作标准化程度高、企业替代意愿强；
中风险 6 个(金融、保险、电信、政府、能源、房地产)，平均 5.42，标准化工作可替代但核心岗位仍需人类参与，体现了自动化同时引发岗位替代与就业再配置的特征[9]；
低风险 6 个(创意、教育、医疗、法律、MLOps、咨询)，平均 3.05，依赖创意、情感交互与专业判断。

5.1.2. 不同类型行业替代风险差异对比

按行业类型对比(表 9、图 6)，劳动密集型行业平均风险指数 8.02 (最高)，创意密集型最低，行业类型与替代风险呈显著负相关，核心差异源于工作标准化程度与人工智能技术适配性。

Table 9. Comparison of substitution risk differences across industries
表 9. 不同行业替代风险差异对比

行业类型	涵盖行业	平均 风险指数	核心影响因素	替代特征
劳动密集型	制造、物流	8.02	替代弹性、代理劳动力等效成本	替代速度快、替代范围广，以基层操作岗位为主
服务密集型	零售、医疗、教育、政府	4.89	人力成本、人工智能增强因子	替代不均衡，基础服务可替代，高端服务难替代
知识密集型	金融、保险、法律、咨询	4.56	人工智能推理成本、专业门槛	辅助性工作可替代，核心决策、专业判断难替代
技术密集型	电信、能源、MLOps	3.87	技术迭代速度、人工智能适配度	技术运维可替代，核心研发、技术创新难替代
创意密集型	创意、教育、医疗(临床诊疗)	2.78	创意能力、情感交互需求	替代难度最高，人工智能仅可作为辅助工具赋能




Figure 6. Comparison of substitution risks across different types of industries
图 6. 不同类型行业风险代替对比

5.1.3. 多行业人工智能替代趋势预测

未来 3~5 年趋势预测(表 10)：制造、物流、零售为快速替代型(35%~50%)；金融、保险、电信等为稳步替代型(15%~30%)；创意、教育、医疗等为缓慢替代型(5%~15%)。“人机协同”将成为主流模式，相关实证也显示 AI 辅助可显著提升员工生产率[10]。

Table 10. Multi-industry AI substitution trend forecast
表 10. 多行业人工智能替代趋势预测

替代趋势类型	涵盖行业	未来 3~5 年替代比例预测	核心趋势特征
快速替代型	制造、物流、零售	35%~50%	人工智能技术适配度高，企业替代意愿强烈，主要替代基层操作、重复性岗位，替代速度逐年加快
稳步替代型	金融、保险、电信、房地产、能源	15%~30%	人工智能主要替代标准化、辅助性工作，核心岗位替代难度大，替代进程与人工智能技术迭代、行业规范完善同步推进
缓慢替代型	创意、教育、医疗、法律、MLOps、咨询	5%~15%	人工智能以辅助赋能为主，难以替代需要人类创意、情感、专业判断的核心岗位，替代进程缓慢，重点体现为效率提升

5.2. 多行业人工智能劳动力替代风险核心痛点总结

核心痛点总结如下。

5.2.1. 共性痛点

共性痛点：人机协同机制不完善；劳动力技能与人工智能发展不匹配；不同规模企业人工智能应用

不均衡; 风险预警与保障机制缺失。

5.2.2. 个性痛点

个性痛点: 高风险行业面临“替代快与转型慢”的矛盾; 中风险行业面临“替代与核心岗位保护平衡难”及监管不同步问题; 低风险行业面临“赋能不足与应用门槛高”的矛盾。

5.3. 多维度赋能建议

从政府、行业、企业三个维度提出差异化建议。

5.3.1. 政府层面: 完善政策引导, 筑牢风险防控底线

已有研究表明, 产业智能化的替代、新任务创造、生产率与产业关联效应并存, 政策设计需兼顾风险监测与就业扩张[11]:

政府层面: 完善产业政策与人工智能监管规范; 搭建人工智能替代风险预警平台, 设立转型资金, 并扩大可获得的技能培训[12]; 加大人工智能研发投入, 支持中小企业, 推动跨行业协同, 以释放企业层面的生产率效应[13]。

5.3.2. 行业层面: 强化协同联动, 推动行业转型升级

行业层面: 制定人工智能应用标准; 联合高校企业开展技能培训; 引导龙头企业带动中小企业共享技术; 建立风险应对联盟, 形成稳定的人机协同学习机制[14]。

5.3.3. 企业层面: 精准布局实施, 实现人机协同发展

企业层面:

高风险企业应分阶段推进替代, 强化劳动力转型培训; 中风险企业应聚焦标准化工作替代, 加强核心岗位人工智能能力培训; 低风险企业应聚焦人工智能赋能, 推进定制化应用。实验研究表明, 生成式人工智能可提高专业写作任务效率, 且低技能组受益更明显[15]。

6. 研究结论

本研究基于 1127 条多行业样本数据, 得出以下核心结论:

第一, 替代弹性、人力成本、人工智能推理成本、人工智能增强因子是影响人工智能替代风险的核心共性因素。

第二, GBR + GBC 加权融合模型测试集回归 $R^2 = 0.91$ 、分类准确率 = 0.91, SHAP 分析验证替代弹性为最核心因素。

第三, 15 个行业风险呈“中间多、两端少”分布, 劳动密集型最高、创意密集型最低; 这一结果与自动化主要冲击常规任务劳动者的研究发现一致[16]。

第四, 从政府、行业、企业三维度提出差异化建议, 形成“风险预警→差异分析→精准赋能”闭环。

参考文献

- [1] 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.
- [2] Acemoglu, D., Autor, D., Hazell, J. and Restrepo, P. (2022) Artificial Intelligence and Jobs: Evidence from Online Vacancies. *Journal of Labor Economics*, **40**, S293-S340. <https://doi.org/10.1086/718327>
- [3] 尹志锋, 曹爱家, 郭家宝, 郭冬梅. 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.
- [4] 郑丽琳, 刘东升. 机器人应用与劳动力就业: 替代还是互补?——基于 22 个经济体数据的经验分析[J]. 统计研究, 2023, 40(3): 126-138.

-
- [5] 李静, 闫曰奇, 潘丽群. 人工智能、劳动力任务类型与城市规模工资溢价[J]. 财经研究, 2023, 49(12): 62-76.
- [6] Dauth, W., Findeisen, S., Suedekum, J. and Woessner, N. (2021) The Adjustment of Labor Markets to Robots. *Journal of the European Economic Association*, **19**, 3104-3153. <https://doi.org/10.1093/jeea/jvab012>
- [7] Banks, S., Ocampo, A.C., Marrone, M., Restubog, S.L.D. and Woo, S.E. (2024) A Multilevel Review of Artificial Intelligence in Organizations: Implications for Organizational Behavior Research and Practice. *Journal of Organizational Behavior*, **45**, 159-182. <https://doi.org/10.1002/job.2735>
- [8] Saranya, A. and Subhashini, R. (2023) A Systematic Review of Explainable Artificial Intelligence Models and Applications: Recent Developments and Future Trends. *Decision Analytics Journal*, **7**, Article ID: 100230. <https://doi.org/10.1016/j.dajour.2023.100230>
- [9] 毛日昇. 工业机器人应用与就业再配置[J]. 管理世界, 2024, 40(9): 98-122.
- [10] Brynjolfsson, E., Li, D. and Raymond, L. (2025) Generative AI at Work. *The Quarterly Journal of Economics*, **140**, 889-942. <https://doi.org/10.1093/qje/qjae044>
- [11] 杨飞. 产业智能化如何影响劳动报酬份额——基于产业内效应与产业关联效应的研究[J]. 统计研究, 2022, 39(2): 80-95.
- [12] 李钰靖. 发展新质生产力背景下技能劳动力需求特征及职业教育供给思路——基于人工智能劳动介入的研究视角[J]. 中国职业技术教育, 2024(15): 13-24.
- [13] Czarnitzki, D., Fernández, G.P. and Rammer, C. (2023) Artificial Intelligence and Firm-Level Productivity. *Journal of Economic Behavior & Organization*, **211**, 188-205. <https://doi.org/10.1016/j.jebo.2023.05.008>
- [14] 吴小龙, 肖静华, 吴记. 人与 AI 协同的新型组织学习: 基于场景视角的多案例研究[J]. 中国工业经济, 2022(2): 175-192.
- [15] Noy, S. and Zhang, W. (2023) Experimental Evidence on the Productivity Effects of Generative Artificial Intelligence. *Science*, **381**, 187-192. <https://doi.org/10.1126/science.adh2586>
- [16] Acemoglu, D. and Restrepo, P. (2022) Tasks, Automation, and the Rise in U.S. Wage Inequality. *Econometrica*, **90**, 1973-2016. <https://doi.org/10.3982/ecta19815>