

# 企業の AI・IoT 導入による生産性への因果効果に関する実証分析

伊藤 万里<sup>a</sup> 松浦寿幸<sup>b</sup>

2025 年 7 月

## 要旨

本稿は、日本企業における AI および IoT 導入が企業の実生産性に対する因果的影響を、企業レベルのミクロデータを用いて実証的に検証するものである。分析には、総務省「通信利用動向調査（企業編）」と経済産業省「企業活動基本調査」を接合したパネルデータを用い、全要素生産性（TFP）および労働生産性（Y/L）を指標として、デジタル技術の導入がもたらす生産性上昇効果を評価した。内生性の問題に配慮するため、処置効果推定法として IPWRA および AIPW といった二重にロバストな推定手法を適用した結果、AI・IoT を導入した企業は、非導入企業と比べて平均して約 6% 高い全要素生産性および労働生産性を有することが示された。この結果は AI・IoT 導入が企業のパフォーマンス向上に寄与していることを実証的に示すとともに、デジタル技術の普及を促進する政策の設計に対しても実務的な含意を与えるものである。

JEL Classification: O33, L25, C21

Keywords: AI（人工知能），IoT（モノのインターネット），生産性，因果推論

---

\* 本稿は、青山学院大学経済研究所による研究助成（課題番号 24203）の支援を受けて得られた研究成果である。また、執筆にあたっては、OECD デジタル経済政策委員会（CDEP）傘下のデジタル経済計測分析作業部会（Working Party on Measurement and Analysis of the Digital Economy）における「AI と生産性」プロジェクトの一環として、総務省「通信利用動向調査（企業編）」および経済産業省「企業活動基本調査」の個票データを利用させていただいた。関係機関のご支援と貴重なデータの提供に対し、ここに深く感謝の意を表する。なお、本稿に残された不備や誤りはすべて筆者に帰するものである。

<sup>a</sup> 青山学院大学経済学部 E-mail: bito@aoyamagakuin.jp

<sup>b</sup> 慶應義塾大学産業研究所

## 1. はじめに

近年、人工知能（AI）やIoTをはじめとするデジタル技術の進展は、ビッグデータの解析を通じたデータ駆動型ビジネスを加速させ、企業活動の様態を根本的に変化させつつある。その経済的帰結としてデジタル技術の導入が企業の生産性に与える影響に注目が集まっている。とりわけ、企業がAI・IoTを導入することによって生産性が上昇するのか、それとも生産性の高い企業が先行してAIを導入しているのかといった、導入と生産性との間の因果関係を明らかにすることは、実証研究において大きな課題となっている。

近年、人工知能（AI）やIoT（Internet of Things）といった先端デジタル技術は、企業の生産活動において急速に導入が進んでおり、生産性を飛躍的に向上させる手段として注目されている。実際の企業事例として、トヨタ自動車は工場内の生産設備をIoT化し、稼働状況や異常値を中央でリアルタイムに監視することで、生産ラインの稼働率や保守効率の改善を実現している。また、ソフトバンクや楽天といった通信・IT企業では、AIを活用したカスタマーサポートの自動化や広告配信の最適化により、業務の効率化と労働生産性の向上を達成している。これらの事例は、AIやIoTが製造業からサービス業まで幅広い業種において、プロセス革新やサービス高度化を通じた生産性向上の手段となり得ることを示唆している。

一方で、AIが企業の生産性に与える影響に関する既存研究は、データ制約の問題からロボット導入を代理変数としてマクロ的視点からその効果を分析してきた（Graetz & Michaels, 2018 ; Acemoglu & Restrepo, 2020）。しかし、近年では、企業レベルのデータを用いてAIの導入とパフォーマンスの関連を直接分析する研究が現れ始めている。例えば Czarnitzki et al. (2023) は、ドイツの企業を対象にAI導入の労働生産性への効果を分析し、導入企業が非導入企業よりも平均で約5%高い生産性を示すことを実証している。また、こうした効果はAI単体ではなく、補完的な組織改革や人的資本投資との相互作用を通じて実現される点が強調されている。Cathles et al. (2020) は、欧州投資銀行による企業調査（EIBIS）のデータを用

い、AI およびビッグデータ活用と労働生産性および雇用成長との間に正の関連があることを示した。Lee et al. (2022) は韓国の高テク・ベンチャー企業を対象に、AI 導入の「強度」が企業の収益性に及ぼす影響を検証しており、AI 投資が一定水準に達して初めて収益改善が観察されること、さらにクラウドやデータベースといった補完的技術の導入や独自の R&D 戦略の存在が AI 導入の効果を強化することを示している。その一方で、日本企業における AI・IoT の導入実態やその効果については、産業横断的かつ定量的な証拠が未だ十分に蓄積されているとは言い難い。例外的に、日本企業における AI 技術の導入状況と経済的影響を把握する試みとして、Morikawa (2024) は企業へのアンケート調査によって収集したデータを用いて、AI 導入と労働生産性・業績指標との関連を分析している。同研究は、日本において AI 技術の導入が限定的であり、主に大企業や情報通信業に偏在している現状を明らかにするとともに、AI 導入企業の方が労働生産性が高い傾向にあることを示した点で意義深い。しかしながら、同研究は観察データに基づく通常の回帰分析にとどまり、AI 導入と生産性向上との因果関係を特定するための処置効果推定などの手法は用いられていない。

本研究は、日本企業の実態に即した企業レベルのミクロデータを用いて、AI・IoT の導入が企業の生産性に与える因果的影響を実証的に検証する点に主たる貢献がある。具体的には、総務省「通信利用動向調査（企業編）」と経済産業省「企業活動基本調査」を接合し、AI・IoT 導入の有無と企業の全要素生産性（TFP）、労働生産性（Y/L）との関係を明らかにするとともに、企業の国際化（輸出入、海外進出）の状況を制御変数として取り入れることで、デジタル化と国際化が同時進行するなかで AI・IoT 導入が果たす生産性への役割をより精緻に捉えることを試みる。

最後に、本論文の構成について述べておく。次節では、利用するデータの説明と分析の枠組みを提示する。第 3 節では、AI・IoT 導入と生産性の関係を記述統計的に示した後、因果関係の特定を検証する。最後に第 4 節において結論と今後の課題を整理する。

## 2. データと分析枠組み

### 2.1 ミクロデータ

本研究は、総務省「通信利用動向調査（企業編）」と経済産業省「企業活動基本調査」の個票データを接合して構築した、企業レベルのミクロデータを用いている。「通信利用動向調査（企業編）」は、国内企業における情報通信技術の導入状況を把握することを目的として総務省が毎年実施している常用雇用者 100 人以上の企業を対象とする抽出調査であり、本分析で AI・IoT の導入有無に関する情報を含む平成 29 年（2017 年調査）から令和 2 年（2020 年調査）までの 4 年分のデータを利用している<sup>1</sup>。一方、「企業活動基本調査」は、従業員 50 人以上かつ資本金又は出資金 3,000 万円以上の企業を対象とした調査であり、企業の財務情報など基本的なデータが所収されている。

両調査の個票データの接合は、名簿情報の利用に制約があったため、両調査に共通して利用可能な企業の本社所在都道府県、売上高、資本金の情報をもとに接合を試みた。その結果、接合が成功した企業数は、2017 年調査（2016 年実績）で 948 社、2018 年調査（2017 年実績）で 671 社、2019 年調査（2018 年実績）で 632 社、2020 年調査（2019 年実績）で 783 社である。ただし、「通信利用動向調査」が抽出方式であることから、接合後のデータはパネルデータとはならず、観測期間中に 2 回以上観測された企業は全体の 5%未満にとどまり、95%の企業は 1 期のみ観測されている。したがって、本分析では 4 期間のデータをプールしたクロスセクション分析を用いている。

生産性指標としては、全要素生産性（TFP）および労働生産性（Y/L）を用いている。TFP については、投入要素に資本と労働を用いた生産関数を仮定し、中間投入を制御変数として用いることで投入選択の内生性を補正する Levinsohn and Petrin（2003）の手法を適用して推定している。労働生産性は、付加価値額を従業員数で除することで計測しており、いずれも

---

<sup>1</sup> AI・IoT の導入については、2017 年調査では AI 導入と IoT 導入とが区別されているが、以降の調査では区別されていない。本分析では分析の一貫性を保つため両者を区別せず AI あるいは IoT の導入に焦点を当てている。

企業活動基本調査に含まれる財務情報をもとに算出している<sup>2</sup>。

AI・IoT の導入が生産性に与える影響を検証するうえで交絡要因の考慮が不可欠となる。ここでは企業の国際化や無形資産への投資を取り上げ、企業活動基本調査から関連する変数データを得ている。国際化については、輸出の有無と直接投資の有無について取り上げ、輸出は直接輸出額が計上されているかどうかによって判断し、直接投資の有無に関しては、各企業の子会社・関連会社の保有状況から、海外子会社・関連会社を少なくとも1社保有している場合には海外直接投資企業であると判断した。無形資産への投資については、研究開発集中度として、研究開発投資額の対売上高比を、人への投資として能力開発費の対売上高比をそれぞれ利用した。

## 2.2 実証分析の枠組み

本研究の主たる目的は、企業による AI 導入が生産性に与える平均処置効果（Average Treatment Effect: ATE）を、観察データに基づいて識別・推定することである。AI 導入は企業の戦略的意思決定の一環であり、外生的に割り当てられるものではない。したがって、AI を導入している企業と導入していない企業との間には、事前に存在するさまざまな企業属性、例えば企業規模（売上高・従業員数）や、研究開発投資、属する産業や国際展開の有無などに起因する選択バイアス（selection bias）が生じる可能性がある。たとえば、知識資本や人材などの経営資源が豊富な大企業は、AI 導入に伴う初期投資や学習コストを吸収しやすく、結果として導入確率が高くなると考えられる。また、技術革新への感度が高い情報通信業や製造業においては、産業構造的に AI 導入の経済的インセンティブが大きい。さらに、輸出や外国直接投資など海外展開を行っている企業では、グローバル市場での競争優位性

---

<sup>2</sup> 中間投入については、（売上原価＋販売費・一般管理費）－（給与総額＋派遣従業者給与総額＋賃貸料＋減価償却費＋租税公課）によって算出し、付加価値額は売上高から中間投入を差し引いたものとして算出した。いずれも実質化には JIP データベースの産出デフレーターおよび中間デフレーターを用いた。

確保のために AI の活用が戦略的に重視されるものと考えられる。このように、AI 導入の有無は企業の特徴に内在する要因によって系統的に決定されている可能性があり、導入企業と非導入企業の単純な比較では AI 導入による生産性への真の因果効果を過大または過小に推定してしまう懸念がある。

こうした実証上の課題を踏まえ、本研究では、AI 導入の有無が企業の属性によって左右される可能性を考慮し、導入企業と非導入企業の違いを統計的に調整する手法を用いる。具体的には、企業規模、輸出や外国直接投資の有無、研究開発集中度、能力開発集中度、AI・IoT 導入に付随するデジタル化としてクラウドコンピューティングの導入有無などの観察可能な企業特性を考慮した処置効果推定の枠組みを採用することで、AI 導入の選択に伴う企業間の構造的な差異を補正し、そのうえで生産性への因果効果を推計する。本研究では処置効果推定の枠組みに則り、未観測の交絡因子の影響を最小限に抑えるための二重にロバスト (doubly robust) な手法として Inverse-Probability-Weighted Regression Adjustment (IPWRA) と Augmented Inverse-Probability Weights (AIPW) の二つを用いる。二重ロバスト推定法とは、処置割当モデル (treatment model) とアウトカムモデル (outcome model) のいずれか一方が正しく特定されていれば、一貫した因果効果の推定が可能となる手法であり、いずれの手法も、処置の選択メカニズムとアウトカムの両方を同時にモデル化し、相補的に活用する点が共通する。

IPWRA は、推定の 2 段階アプローチに基づく。まず、処置割当モデルとして、AI 導入の確率 (傾向スコア) を共変量  $X_i$  に基づきロジット回帰などで推定する。次に、アウトカムモデルとして、導入／非導入別にアウトカム (本研究では  $\ln TFP$  および  $\ln Y/L$ ) を回帰モデルで推定し、予測値を得る。最後に、これらの情報を統合して次式で示される ATE を算出する。

$$\widehat{ATE}_{IPWRA} = \frac{1}{N} \sum_{i=1}^N \left[ \left( \frac{D_i}{\hat{p}(X_i)} - \frac{(1-D_i)}{1-\hat{p}(X_i)} \right) (Y_i - \hat{m}(D_i, X_i)) + \hat{m}(1, X_i) - \hat{m}(0, X_i) \right] \quad (1)$$

ここで、 $D_i \in \{0,1\}$ は処置変数である AI・IoT 導入の有無を、 $\hat{p}(X_i)$ は処置割当確率（傾向スコア）を、 $\hat{m}(D_i, X_i) = E[Y_i|D_i, X_i]$ はアウトカムモデル（回帰モデル）によって予測された生産性の値をそれぞれ示している。この式から、実測値と予測値の誤差に基づく補正項と予測値の差を組み合わせることで、二重のロバスト性を確保している。したがって、傾向スコアが誤って推定されていてもアウトカムモデルが正しく定式化されていれば、あるいはまたその逆でも ATE の推定が可能である。

一方 AIPW は、主に「傾向スコア重み付け法（IPW）」を拡張し、予測値ベースの補正項（augmentation）を加えた形で次式のように定式化される。

$$\widehat{ATE}_{AIPW} = \frac{1}{N} \sum_{i=1}^N \left[ \frac{D_i(Y_i - \hat{m}(1, X_i))}{\hat{p}(X_i)} - \frac{(1-D_i)(Y_i - \hat{m}(0, X_i))}{1-\hat{p}(X_i)} + \hat{m}(1, X_i) - \hat{m}(0, X_i) \right] \quad (2)$$

AIPW では、回帰モデルを用いずとも、共変量に基づいて傾向スコアと予測値を用いた効率的な ATE 推定が可能な形となっており、観察データに対して重み付けを行った残差部分（重み付き IPW）」を補正し、さらに「予測された期待値の差分」を加味することで、未観測の反実仮想の値を補っている。本研究では、企業の AI 導入が企業属性に基づいて内生的に決定されるという前提に立ち、企業規模、産業ダミー（大分類）、研究開発集中度（研究開発費／売上高）、能力開発集中度（能力開発費／売上高）、輸出ダミー、外国直接投資ダミー、クラウドコンピューティングの導入ダミー変数を共変量として含めた処置割当モデルを推定する。両推定法（IPWRA および AIPW）に基づいて、AI・IoT 導入が全要素生産性（lnTFP）および労働生産性（lnY/L）に及ぼす平均的な因果効果（ATE）を推定する。

### 3. AI・IoT 導入と生産性との関係性

#### 3.1 産業別の分布と AI・IoT 実装による生産性プレミアム

図1および図2は、それぞれ全要素生産性 ( $\ln TFP$ ) および労働生産性 ( $\ln(Y/L)$ ) に関して、AI・IoT 導入企業（実線）と非導入企業（破線）の分布をカーネル密度推定により比較したものである。いずれの指標においても、導入企業の分布は非導入企業と比べて右側にシフトしており、AI・IoT の導入が平均的に企業の生産性向上と関連している可能性を示唆している。図1の  $\ln TFP$  に関する分布では、AI・IoT 導入企業がやや右に分布しているとともに、右側の裾が若干厚く、一部企業において高い生産性の実現が確認される。これは、全要素的な技術効率性や資源配分の改善を通じた AI・IoT のポテンシャルを反映していると考えられる。一方、図2の  $\ln(Y/L)$  では、両群ともにほぼ類似の中心値を持ちながらも、非導入企業の分布のピークがやや高く、狭い分布となっているのに対し、導入企業は分布の幅が広く、より高い労働生産性を実現している企業が一定数存在することがわかる。この点から、AI・IoT の導入効果が必ずしも均一ではなく、業種・企業規模・補完的資源の保有といった条件に依存して効果の非均質性（heterogeneity）が存在している可能性が示唆される。




図1．AI・IoT 導入企業と非導入企業における全要素生産性（lnTFP）の分布比較




図2．AI・IoT 導入企業と非導入企業における労働生産性（ln(Y/L)）の分布比較

図1 および図2 で示した AI・IoT 導入企業と非導入企業の生産性分布の違いが統計的に有意か否かを検証するため、Kolmogorov-Smirnov 検定（2 標本 K-S 検定）を実施した。検定

対象は、(1) 全要素生産性 ( $\ln TFP$ )、(2) 労働生産性 ( $\ln(Y/L)$ ) の 2 指標である。その結果、 $\ln TFP$  については、両群間の累積分布に 0.1098 の最大差が観察され、 $p$  値は 0.000 と統計的に有意であった (5%有意水準)。これは、AI・IoT 導入の有無によって全要素生産性の分布に有意な差が存在することを示しており、図 1 で観察された右シフトを統計的にも裏付ける結果となった。労働生産性 ( $\ln(Y/L)$ ) に関しても、両群間の最大分布差は 0.1107 であり、 $p$  値は 0.000 と同様に統計的に有意であった。導入群の分布の広がりが高生産性裾野の存在が、分布全体としての違いにつながっていると考えられる。

これらの結果は、AI・IoT 導入と生産性指標との間に分布レベルで有意な差異が存在することを示唆しており、導入企業が平均的にも、また一部企業において極端に高い生産性を示していることを示す。

次に産業別に違いが見られるか否か検証する。表 1 は、産業大分類別に AI・IoT 導入企業と非導入企業のおよび生産性プレミアム（導入企業と非導入企業の平均生産性（対数値）の差）を算出した。全体として、AI・IoT の導入率は 14.2%にとどまる一方で、産業間で導入の広がりには大きなばらつきが見られる。例えば、製造業（15.9%）、情報通信業（16.0%）において比較的高い導入率が確認される一方で、農業・林業・鉱業・建設業（8.0%）や運輸・郵便業（10.9%）では導入が限定的である。また、電気・ガス・熱供給業のようなインフラ系産業においては導入率こそ 38.5%と高いが、企業数が限られており、解釈には注意を要する。

AI・IoT 導入の経済的効果を示すものとして、生産性の対数値に基づくプレミアムを導出した結果、全体平均では TFP（全要素生産性）において 0.08、労働生産性（ $Y/L$ ）において 0.09 と、導入企業が非導入企業に対してそれぞれ約 8~9%高い生産性水準にあることが示唆された。

ただし、これらのプレミアムは産業ごとに大きく異なる。たとえば、情報通信業においては TFP プレミアムが 0.13、労働生産性プレミアムが 0.16 と顕著に高く、AI・IoT 導入が生

生産性に与える効果が大きい可能性が示唆される。一方、農業・林業・鉱業・建設業、電気・ガス・熱供給業では TFP プレミアムと労働生産性プレミアムが大幅にマイナスであり、導入企業の方が非導入企業よりも生産性が低い傾向が見られた。これは、当該分野における AI 導入がまだ定着しておらず、実効性に乏しい段階にあるか、導入企業が新興事業者に偏っている可能性が示唆されるが、観測数や導入企業が少数であることに留意が必要である。

もっとも、本分析で用いている生産性プレミアムは、生産性の対数値の単純な平均差分として計測しており、AI・IoT 導入の効果を因果的に識別したものではない点には留意が必要である。すなわち、生産性の高い企業ほど AI・IoT を導入しやすいという選択バイアスの存在が排除できないため、「導入によって生産性が高まった」のか、「もともと生産性の高い企業が導入している」のかは、本表の集計値からは判断できない。因果的な効果を厳密に検証するには、導入の内生性を考慮した計量経済的手法を用いる必要があり、次節ではこの課題へ対処する形で検証を進める。

表 1. 産業分類別 AI・IoT 導入分布と生産性プレミアム

|             | 非導入   | 導入  | Total | 導入比率  | TFPプレミアム | Y/Lプレミアム |
|-------------|-------|-----|-------|-------|----------|----------|
| 農業・林業・鉱業・建設 | 81    | 7   | 88    | 8.0%  | -0.22    | -0.16    |
| 製造業         | 801   | 151 | 952   | 15.9% | 0.05     | 0.07     |
| 電気・ガス・熱供給   | 8     | 5   | 13    | 38.5% | -0.27    | -0.34    |
| 情報通信業       | 542   | 103 | 645   | 16.0% | 0.13     | 0.16     |
| 運輸業・郵便業     | 123   | 15  | 138   | 10.9% | 0.02     | 0.00     |
| 卸売・小売業      | 292   | 38  | 330   | 11.5% | 0.08     | 0.06     |
| 金融・保険業      | 271   | 38  | 309   | 12.3% | 0.04     | 0.07     |
| 不動産・物品賃貸業   | 5     | 1   | 6     | 16.7% | 0.19     | 0.04     |
| サービス業・その他   | 443   | 66  | 509   | 13.0% | 0.04     | 0.08     |
| Total       | 2,564 | 426 | 2,990 | 14.2% | 0.08     | 0.09     |

注：2016 年実績～2019 年実績データについて通信利用動向調査と企業活動基本調査が接続できた 2990 観測数をクロスセクションデータとして用いた結果を示している。

### 3.2 AI・IoT 導入による生産性上昇効果

本研究では、AI・IoT 導入の因果効果推定にあたり、処置群（導入企業）と対照群（非導入企業）との間で共変量の分布が適切にバランスされているかを確認するため、共変量のバランステストを実施した。具体的には、導入の有無に応じた処置割り当ての傾向スコアに基づき、Inverse Probability Weighting (IPW) を適用した後、共変量の標準化差分 (standardized mean differences) および分散比 (variance ratio) を比較した。

表 2 に示す通り、IPW 重み付けの前後で多くの共変量においてバランスの改善が確認された。たとえば、「FDI 企業ダミー」については、重み付け前の標準化差分が 0.179 とやや高かったが、重み付け後は-0.001 と事実上ゼロに収束しており、処置群と対照群の分布が一致していることを示している。同様に、「クラウド全社的導入」の標準化差分も 0.447 から 0.000 へと改善されている。また、分散比に関しても、一般に 0.5～2.0 の範囲内に収まっていれば十分なバランスが取れているとされるが (Rubin, 2001)、全ての変数において重み付け後の分散比はこの基準を満たしており (例: R&D 集中度の分散比は 1.789 から 0.597 へ改善)、共変量の分布の類似性が確保されている。

表 2. AI・IoT 導入の傾向スコア重み付けによる共変量バランステスト結果

|           | 標準化差分  |          | 分散比   |          |
|-----------|--------|----------|-------|----------|
|           | Raw    | Weighted | Raw   | Weighted |
| クラウド導入ダミー |        |          |       |          |
| —全社的に導入   | 0.447  | 0.000    | 0.963 | 1.000    |
| —一部で導入    | -0.104 | 0.004    | 0.888 | 1.005    |
| —今後導入予定   | -0.132 | -0.011   | 0.704 | 0.972    |
| FDI企業ダミー  | 0.179  | -0.001   | 1.395 | 0.998    |
| 輸出企業ダミー   | 0.095  | -0.032   | 1.164 | 0.946    |
| R&D集中度    | 0.110  | 0.000    | 1.789 | 0.597    |
| 能力開発費集中度  | -0.019 | -0.034   | 0.538 | 0.515    |

このように、バランステストの結果から、IPW 重み付けにより導入群と非導入群の観察

可能な属性が統計的に同等の水準まで調整されていることが確認された。よって、続く IPWRA および AIPW の因果効果推定は、交絡バイアスのリスクが低減された信頼性の高い推定と評価できる。

表 3 は、AI・IoT 導入が企業の生産性に与える因果的影響を推定した結果を示している。推定には、二重にロバストな処置効果推定手法である IPWR と AIPW を用いた。いずれの手法においても、全要素生産性 ( $\ln TFP$ ) および労働生産性 ( $\ln(Y/L)$ ) に対して、AI・IoT 導入の正の平均処置効果 (ATE) が確認された。具体的には、AI 導入の  $\ln TFP$  に対する ATE は、IPWRA で 0.061 (標準誤差 0.029)、AIPW で 0.060 (標準誤差 0.029) と推定されており、いずれも 5%水準で統計的に有意である。これは、AI を導入した企業が、観察される企業属性を同じくする非導入企業と比べて、平均して約 6%高い全要素生産性を有することを示している。生産性が高い企業が AI を導入するという自己選抜の関係性もあることから、表 1 の結果は 2%程度過大評価されていたといえる。同様に、 $\ln(Y/L)$  に対する ATE も IPWRA および AIPW とともに 0.068 (標準誤差 0.031) と一貫しており、労働生産性についても AI 導入企業が約 6.8%高い水準にあることが確認された。これらの結果は、AI 技術の導入が企業の生産性向上に資する可能性を示唆しており、デジタル技術と企業パフォーマンスとの正の関連を裏づける実証的証拠と位置づけられる。

表 3. AI・IoT 導入による生産性への平均処置効果の推定結果

|            | IPWRA            | AIPW             |
|------------|------------------|------------------|
| $\ln TFP$  | 0.061<br>(0.029) | 0.060<br>(0.029) |
| $\ln(Y/L)$ | 0.068<br>(0.031) | 0.068<br>(0.031) |

注：カッコ内は頑健標準誤差を示しており、ATE はいずれも 5%有意水準で統計的に有意である。

#### 4. おわりに

本稿では、日本企業における AI・IoT 技術の導入が企業の生産性に与える因果的影響を、企業レベルのマイクロデータを用いて実証的に検証した。総務省「通信利用動向調査（企業編）」と経済産業省「企業活動基本調査」を接合することにより、AI・IoT の導入状況と全要素生産性（TFP）、および労働生産性（Y/L）との関係性を明らかにした。

因果推定には、処置の選択に伴う内生性の問題に配慮するため、二重にロバストな推定手法である IPWRA よび AIPW を適用した。その結果、いずれの手法においても、AI・IoT 導入が全要素生産性および労働生産性の双方に対して統計的に有意な正の効果をもたらしていることが確認された。具体的には、AI 導入企業は非導入企業に比べて平均して 6%前後高い生産性水準を有している。

これらの知見は、AI・IoT の導入が企業の競争力強化や生産性向上に寄与することを示唆しており、デジタル技術の普及と企業パフォーマンスとの間に正の関連が存在するという実証的エビデンスを提供するものである。

#### 参考文献

- Acemoglu, D., & Restrepo, P. (2020). Robots and jobs: Evidence from US labor markets. *Journal of Political Economy*, 128(6), 2188–2244.
- Brynjolfsson, E., & McAfee, A. (2014). *The second machine age: Work, progress, and prosperity in a time of brilliant technologies*. W. W. Norton & Company.
- Cathles, A., Nayyar, G., Rückert, D., 2020. Digital technologies and Firm performance: Evidence from Europe. EIB Working Papers No. 2020/06. European Investment Bank.
- Czarnitzki, D., Fernández, S., & Rammer, C. (2023). Artificial intelligence adoption and firm productivity. *Journal of Economic Behavior & Organization*, 211, 502–528.
- Graetz, G., & Michaels, G. (2018). Robots at work. *The Review of Economics and Statistics*, 100(5),

753–768.

- Lee, J. D., Bae, J., & Kim, J. (2022). AI adoption and firm performance: Evidence from Korean manufacturing. *Industrial and Corporate Change*, 31(1), 1–30.
- Levinsohn, J., & Petrin, A. (2003). Estimating production functions using inputs to control for unobservables. *The Review of Economic Studies*, 70(2), 317–341.
- Morikawa, M. (2024). Use of artificial intelligence and productivity: Evidence from firm and worker surveys. RIETI Discussion Paper Series 24-E-074.
- Rubin DB. (2001). Using propensity scores to help design observational studies: application to the tobacco litigation. *Health Services & Outcomes Research Methodology*, 2, 169–188.