

「AI の経済学」に関する文献レビュー

畠山 喜充 *

2023 年 9 月 26 日

1 イントロダクション

近年急速に普及している AI (Artificial Intelligence, 人工知能) であるが、人間の知能に関連する認知機能を模倣することを目的として設計されたそれらの技術は、これまで機械化、自動化することができなかった領域においても活用が進んでいる。例えば、翻訳、病気の診断、問い合わせ対応、自動運転、EC サイトにおけるダイナミックプライシングなどが挙げられる。こうした AI の活用は現実経済においては進展しているものの、その影響については十分な分析がなされているとはいえない。そこで本稿では、経済学分野における現在までの AI に関連する研究の潮流を調査するとともに、そのうち筆者が特に興味深いと感じたアルゴリズム入札に関する論文を取り上げ、その概観を紹介する。

2 AI に関する経済学的研究の動向

経済学分野における現在までの AI に関連する研究の潮流を調査するために、主要な雑誌及び学会等から AI に関する既存研究を抽出し、それらを内容に応じて分析した。

2.1 論文の抽出方法

論文は、次の雑誌、学会の web ページから、“AI”、“Artificial Intelligence”、“Machine Learning”の 3 つの単語で検索を行い、それらに該当する論文を抜き出した。ただし、学会については 2020 年以降の各学会の定期カンファレンスにおいて報告された論文から該当する論文を検索し抽出した。

学会：NBER, Digital Economics Conference in Toulouse, American Economic Association, European Economic Association (EEA), EARIE, EC22, Workshop on the Economics of Advertising and Marketing (以上、6 学会)

雑誌：American Economic Journal: Macroeconomics, American Economic Journal: Microeconomics, American Economic Review, American Economic Review: Insights, Annual Review of Eco-

* 京都大学大学院経済学研究科 修士 1 回

nomics, Econometrica, Journal of Economic Literature, Journal of Economic Perspectives, Journal of Financial Economics, Journal of International Economics, Journal of Labour Economics, Journal of Political Economy, Journal of Political Economy Macroeconomics, Journal of Political Economy Microeconomics, Management Information Systems Quarterly, Management Science, Marketing Science, Quantitative Economics, Quarterly Journal of Economics, RAND Journal of Economics, Research Policy, Review of Economic Studies, Strategic Management Journal (以上、24 誌)

その結果、302 本の論文が該当した。

抽出された AI 関連論文について、“Method”、“Using ML”、“Pricing”、“Antitrust”、“Advertisement”、“Productivity”、“Innovation”、“Labor”、“Decision Making”、“Ethics”、“Policy”、“Finance”という 12 のタグを用いてタグ付けを行った。各タグの詳細については、後に詳細を説明する。

2.2 既存研究の動向

抽出された論文を確認したところ、経済学分野における AI に関する研究は、次の 3 つに大別されることが分かった。

1. AI 関連手法の性質を計量経済学的観点から分析した研究 (Tag: Method)
2. AI 関連手法を分析に利用した研究 (Tag: Using ML)
3. 経済における AI 関連技術の役割を分析した研究

このうち、本稿で特に注目するのは 3. 経済における AI の役割を分析した研究、であるため、これに該当する論文については AI が役割を果たしている文脈に応じてさらに上記のタグに対応する形で分類した。

図 1 左図は、各分類に分類された論文数を円グラフを用いて表したものである。抽出された論文の中では、AI 関連手法を分析に利用した論文 (Using ML) が 157 本と最も多く、AI 関連技術の経済学研究への応用が進んでいることがわかる。AI に関して分析した論文 (Analysis of AI) は 114 本であり、こちらに関する研究も相応に進んでいる。分析されている内容として特に多いのは、タグ“Productivity”や“Labor”がついた論文であり、AI の導入が生産性にもたらす影響や労働者との代替可能性について関心が高まっていることが反映されている。他には、AI が直接起こしうる社会問題への関心も強く、タグ“Ethics”や“Antitrust”に分類される論文も各々 10 本以上となっている。

図 1 右図は抽出された論文のうち、雑誌に掲載された論文の本数を掲載時期によって時系列に並べたグラフである。2019 年以降徐々に論文数が増加し、特に 2021 年以降は急増している。2018 年には、強化学習に関する技術の発展などをきっかけとして、Google 社が新しい言語理解モデルや糖尿病性網膜症の診断を助ける AI モデルに関する発表を行う、自動運転車の開発やテストが盛んに行われるなどの出来事があった。2019 年には、OpenAI による Chat GPT-2 の公開があり、2020 年にはその改良版である Chat GPT-3 の発表があるなど、汎用 AI の開発及び普及も進んでいる。グラフは、このような世界的な AI の普及とそれに伴う社会の関心を反映していると考えられる。




図 1. (左) 今回抽出した論文全体の内訳、(右) 雑誌に掲載された論文数の推移
出所) 各学会及び雑誌の web ページより筆者作成

2.3 既存研究の方向性

前述の通り、抽出した論文のうち、AI が持つ社会経済への影響について分析した論文について、その分析対象を基に 10 のタグ付けを行い分類した。基本的には排他的にタグ付けを行ったが、“Innovation”及び“Antitrust”は、それぞれ“Productivity”及び“Pricing”に内包される概念である。分類された論文をいくつか例示しつつ、それぞれの具体的な内容を説明する。

2.3.1 生産性：Productivity (Innovation)

AI の導入は様々な分野で進んでいるが、AI の導入によってどのように生産性が上昇しているかに関しては、導入される環境や目的等によって異なることが予想され、AI と生産性の関係についての研究は特に盛んに行われている。Brynjolfsson et al. (2019) は、デジタルプラットフォームからのデータを使用して、AI の主要な応用である機械翻訳の導入によって、このプラットフォームでの国際貿易が大幅に増加し、輸出が 10.9% 増加したことを発見した。Choudhury et al. (2020) は、知識経済における生産性を高めるために機械学習を使用するには、機械学習の予測から生じる可能性のある重要なバイアスを考慮する必要があることを指摘し、ユーザーのドメイン専門知識がこのバイアスを軽減することで機械学習を補完できると理論付けしている。

また、特に AI がイノベーション創出に与える影響について着目した研究も行われている。Lou and Wu (2021) は、創薬分野における AI の役割を分析することを目的として、イノベーションのために AI リソースを開発、管理、利用する企業の能力を評価する AI イノベーション能力を概念化した。彼らの研究は、創薬における AI の使用の利点と限界の両方、そして創薬のための AI リソースを効果的に管理する方法を明らかにしている。Rammer et al. (2022) は、ドイツの企業レベ

ルのデータを用いて、イノベーションにおけるさまざまな AI 手法と応用分野の役割を調査し、イノベーションにおける AI の利用が、世界初の製品イノベーションによる売上高の増加やビジネス部門のコストの削減などのポジティブな役割を果たしていると述べている。

2.3.2 雇用：Labor

AI による自動化が、これまで自動化による脅威に曝されていなかったホワイトカラーを中心とした労働者に代替する可能性が世界中で指摘されている。しかしながら、実際に AI の導入がどのように雇用に影響を与えるのかについては、いまだ研究の余地がある。Babina et al. (2022) は、従業員の履歴書と求人情報のデータセットを独自に組み合わせて、企業レベルの AI 投資と、学歴、専門分野、階層などの従業員構成変数を測定した。その結果、企業が AI に投資するにつれてより教育を受けた労働力に移行する傾向があることや、AI への投資が若手レベルの従業員の割合を大幅に増加させ、中間管理職や上級職の従業員の割合を減少させることなどを発見した。Acemoglu et al. (2022) は、2010 年以降の米国のほぼ全世界のオンライン求人に関する事業所レベルのデータを使用して、AI が労働市場に与える影響を研究し、AI による労働代替が事業所レベルでは目に見えているものの、より危険にさらされている職業や産業における雇用と賃金の伸びに対する総合的な影響は、現時点では小さすぎて検出できないと結論付けた。

2.3.3 政策：Policy

このタグには政策当局や公的機関による AI の利用や、AI を推進する産業政策の実施等についての分析が含まれる。Kleinberg et al. (2015) は、重要な種類の政策問題には因果推論^{*1}は必要なく代わりに予測推論^{*2}が必要であると主張し、医療政策の例を使用して、機械学習による予測の改善が潜在的な社会福祉を大きく改善することを説明した。Beraja et al. (2023) は、中国における AI 企業や政府調達契約、さらには 2010 年代初頭以降の中国全土の社会不安に関する包括的なデータを収集し、独裁体制が政治統制の新技术としての顔認識 AI の恩恵を受けていることを示した。

2.3.4 倫理：Ethics

AI の活用は、学習データの制約等から、様々な倫理的問題を引き起こす可能性が指摘されており、こうした可能性に関する研究も盛んである。Arnold et al. (2021) は、公判前の保釈決定の設定におけるアルゴリズムによる差別を測定する新しい準実験ツールを開発し、ニューヨーク市のデータを用いて、洗練された機械学習アルゴリズムが黒人被告を差別していること示した。Avery et al. (2023) は、AI の使用が人材採用においてむしろ長年の偏見を永続させるという指摘に対し、男性と白人が多数を占める業界でのポジションの採用に関するフィールド実験^{*3}から得られた結果を報告した。その内容は、人間ではなく AI によって評価されることを潜在的な応募者が知ること、過小評価されている少数派が増加し非少数派の申請率が減少しているというものである。

^{*1} ある事象や行動が別の事象の原因となるかどうかを統計的または実験的手法を用いて推定すること。

^{*2} 既知の情報やデータに基づいて未来の事象や結果を推測・予想すること。

^{*3} 実際の経済環境において行われる実験のこと。実験室の中で行われる「ラボ実験」と対比される。

2.3.5 価格：Pricing (Antitrust)

AI の、パーソナライズされた価格設定やダイナミックプライシング、オークションへの自動入札への応用が進んでおり、それが価格に及ぼす影響に関する研究をここに分類する。Brunnermeier et al. (2020) は、保険会社が AI を用いることで、情報の優位性が被保険者から保険会社に逆転することを指摘し、保険会社に統計情報の開示を強制することが福祉の向上につながる可能性があることや、顧客が情報を完全に推測できない場合に価格差別^{*4}が保険会社の利益を大幅に押し上げることを示した。Dubé and Misra (2023) は、ランダム化された制御価格設定のフィールド実験からのデータを使用し、パーソナライズされた価格について検証した。その結果、パーソナライズされた価格設定では消費者余剰は減少するが、60 %以上の消費者がパーソナライズによって利益を得ることや、不公平回避的な厚生関数の下では消費者の厚生が増加することさえあることを示した。

また、このような価格に関する研究のうち、AI がオークションに参加することが、共謀^{*5}を引き起こす可能性が指摘されている。Calvano et al. (2020) は、価格競争を繰り返す寡占モデルにおける AI(Q 学習) を活用したアルゴリズムの動作を実験的に研究し、アルゴリズムが相互に通信することなく、競争の水準を上回る価格を請求することを一貫して学習していることを発見した。Calvano et al. (2023) は、製品市場の競争に対するアルゴリズムレコメンドの潜在的な反競争効果に関して学界と政策界の両方で提起されている懸念に対し、アルゴリズムによるレコメンドが利用できず、消費者が個別の検索のみに依存しているシナリオと比較して、レコメンドシステムの利用が市場集中と価格の上昇につながることを実証した。ただし彼らは、レコメンドシステムは製品と消費者の一致を改善し、高価な検索プロセスの必要性を減らすことで、消費者余剰を増加させる可能性が高いことも主張している。

2.3.6 意思決定：Decision Making

AI は人間の意思決定を助け、時にそれを代替するが、その意思決定のパフォーマンスについては研究が必要である。Kleinberg et al. (2018) は、機械学習が人間の意思決定を改善できるかを確認するため、裁判官の保釈決定に着目した。彼らは、機械学習を利用することで潜在的に大きな厚生^{の改善が見られると結論付けたが、この価値を実現するには、これらのツールを経済的枠組みに統合する必要があるとも述べている。Wang et al. (2020) は、意思決定に機械学習アルゴリズムを適用する企業は影響を受けるユーザーに対してアルゴリズムを透明にすべきかという問題を分析し、企業がアルゴリズムを透明化すれば、場合によってはアルゴリズムの予測力さえも向上する可能性がある一方で、ユーザーはアルゴリズムの透明性の下で常に有利になるとは限らないことを示した。}

^{*4} 同じ商品やサービスを顧客ごとに異なる価格で販売すること。

^{*5} 競合企業間で秘密裏に協力し、競争的な場合よりも各企業の利潤が増加するように価格や生産量などの市場に関する変数を不正に調整すること。

2.3.7 金融：Finance

金融分野は先進的に AI を活用している分野の一つである。AI アナリスト、AI トレーダーは一般的な存在となり、彼らの登場が市場に与える影響や、彼らのパフォーマンスについて研究が進んでいる。Avramov et al. (2020) は、ディープラーニング信号に基づく投資が、裁定取引が困難な株式や裁定取引の制限が高い市場状態から収益性を引き出すことを示した。彼らによれば、その不透明な性質にもかかわらず、機械学習手法はほとんどのアノマリーと一致するミsprayis 銘柄の特定に成功している。Cao et al. (2021) は、AI アナリストと人間のパフォーマンスを比較し、重要な情報が制度的情報 (institutional knowledge) を必要とする場合は人間の方が強く、情報が透明だが膨大な場合は AI の方が強いと結論付けた。よって、AI のパワーと人間の知恵は、正確な予測を生み出す上で補完的であり、金融分析、そしておそらく他の高スキル職業においても、「人間+機械」の未来が予想される。

2.3.8 広告：Advertise

AI の活用が特に進む分野の一つに、広告分野が挙げられる。Luo et al. (2019) は、チャットボットまたは人間の従業員からランダムに営業の電話を受ける顧客に関するフィールド実験データを活用し、未公開のチャットボットが顧客の購入を誘発する上で、熟練した従業員と同じくらい効果的で、経験の浅い従業員よりも 4 倍効果的であることを示した。ただし、マシンと顧客の会話の前にチャットボットの身元を開示すると、購入率が低下するということも述べられている。Rafieian and Yoganarasimhan (2021) は、モバイルアプリ内広告のユーザー追跡特性に対するプライバシー擁護の問題に 대응するため、新たなターゲティングフレームワークを構築してシミュレーションを行い、ターゲティングがより詳細に設定されると総余剰は増加するものの、最も効率的なターゲティングによって広告ネットワークの収益が最大化されるわけではなく、むしろ、広告ネットワークが広告主に行動ターゲティングを許可していない場合に最大化されることを示した。この結果は、広告ネットワークが外部規制なしでユーザーのプライバシーを保護する経済的インセンティブを持っている可能性があることを示唆している。

3 論文紹介：Banchio and Skrzypacz (2022)

抽出した既存研究の中から、筆者が特に興味深いと感じた論文として、Banchio and Skrzypacz (2022) を取り上げる。この論文では、入札者が（ナッシュ均衡^{*6}パラダイムを使用せずに）単純な人工知能アルゴリズムを使用して入札を決定するオークションを分析することで、オークションの設計が収益と入札者の行動にどのような影響を与えるかという古典的な疑問を再検討している。

彼らは 2 つの理由から、オークションの設計が AI アルゴリズムによるプレイにどのような影響

^{*6} ゲーム理論において、各プレイヤーが自分の最適な戦略を取った場合、他のプレイヤーも自分の戦略を変えるインセンティブがなくなる状態のこと。

を与えるかを研究することに興味を持っている。まず、この分析はオンライン広告オークションに
応用できると考えられる。オンライン広告オークションでは、ある種のインプレッション/クリッ
クの入札者が1日に何千件ものオークションで競い合う。オンライン広告オークションは、通常、
数秒以内に行われ、入札者はオークション開催者が提供する入札ツール、社内またはサードパー
ティが開発した入札ツールを利用するのが一般的である。このようなアルゴリズムの人気の高まる
につれ、複数の競合他社が同様のツールを使用し、それぞれが所有者に代わって最適化を行った場
合、そのようなオークションでのプレイがどのように進化するのかという疑問は当然のことだ。

第二に、アルゴリズム・プライシングに関する最近の研究は、プライシングに使用されるアルゴ
リズムが（暗黙の）談合を助長しかねないという懸念を表明している。一般的なテーマは、洗練さ
れたアルゴリズムが動的戦略を学習し、暗黙の談合に対しては競合他社に報酬を提供し、競争的行
動に対しては競合他社を罰する、つまり静的ゲームの高収益均衡ではなく、無限に繰り返される
ゲームの低収益均衡を演じることができるというものだ。アルゴリズムによるこのような行動は、
互いを継続的に監視し、人間よりもはるかに速いスピードで（罰を与えて）反応する能力によって
促進される。繰り返しゲームに関する彼らの理論は、監視と反応速度の向上により、暗黙の共謀^{*7}
均衡がより安定することを示唆している。この論文は、繰り返されるゲームの直感が単純な AI ア
ルゴリズムにどの程度適用されるのか、またオークション設計の選択がそれらの力に影響を与える
可能性があるのかを理解することに興味がある。

3.1 関連文献

アルゴリズムによる共謀は、最近、経済学コミュニティでの関心を引き起こしている。Calvano
et al. (2020) の先駆的な研究では、価格設定寡占における共謀を調査し、過去の価格を追跡するアル
ゴリズムが暗黙のカルテルに典型的な共謀戦略を採用していることを示唆している。彼らもまた、
主力の人工知能アルゴリズムとして Q 学習を研究している。Klein (2021) も価格設定ゲームにおけ
る共謀と Q 学習を研究しているが、その設定では価格オファーが交互に表示される。Asker et al.
(2022) は、同様の価格設定モデルでアルゴリズム設計が共謀に及ぼす影響を研究しており、同期
アルゴリズムは共謀的な結果に収束する可能性が低いことを発見した。Brown and MacKay (2021)
は、オンライン小売業者間の競争に対する高頻度の価格調整の影響を研究している。彼らは、頻度
が高くなると価格の分散が生じ、全体的な価格レベルが上昇する可能性があることを発見した。特
に関連性があるのは、Banchio and Mantegazza (2022) の最近の研究で、彼らはアルゴリズム・シス
テムのための連続時間近似技法を提案し、均衡の特徴付けを可能にした。Hansen et al. (2021) は、
バンディットの文献とは異なるアルゴリズムをシミュレートし、その誤った仕様の実装が同様にど
のように共謀を引き起こすかを示している。

アルゴリズムによる価格設定に関する実証研究も盛んに行われている。Musolff (2022) は、自動
価格設定の導入によって生じる価格競争と、価格再設定者による、取引量の少ない夜間などに定期

^{*7} 競合企業間での明確なコミュニケーションや合意なしに、共謀が行われること。

的に価格を引き上げる（価格を「リセットする」）戦略を通じて、オンライン小売業者の価格がエッジワースのサイクル行動に従っていることを発見した。Assad et al. (2020) では、著者らは自動価格設定アルゴリズムの採用によるガソリン小売業者の利益の増加を文書化している。最近の研究の中にはオークションでの学習を分析したものもあるが、Nedelec et al. (2019) を除き、Milgrom and Tadelis (2018) などほとんどの文献は競売人側に関するものだ。彼らは戦略的入札者の目的を分析し、勾配降下法を通じて学習にアプローチしている。最近では、Kolumbus and Nisan (2022) は、本質的に最小限の入札から落札までのフィードバックを必要とするリグレット最小化アルゴリズム^{*8}を使用した自動入札エージェントを研究している。他に、Alcobendas and Zeithammer (2021) は、オンラインプラットフォームでの二位価格オークション^{*9}から一位価格オークション^{*10}への切り替えに対する入札者の短期的な反応を分析している。

Watkins (1989) および Watkins and Dayan (1992) による Q 学習に関する先駆的な研究は、経済学でも簡単に調査された強化学習に関する文献を復活させ、Erev and Roth (1998) や Erev et al. (1999) などの研究に至った。マルチエージェント学習を取り巻く理論は、実際の応用において大きな成功を収めているが、主要なパラダイムについてはコンピュータ科学者の間でコンセンサスが得られていない。最近の概要については、Zhang et al. (2021) を参照のこと。マルチエージェント強化学習に関する理論的研究は、主に特定のアルゴリズムとルールに関して、進化的ゲーム理論の文献 (Bloembergen et al. (2015) を参照) との関連に至っている。

ゲームでの学習に関する文献では、さまざまな角度から学習者のシステムが分析されている。Brown (1951) による架空劇の主力モデルは徹底的に研究され、その特性の理解は進んできた (詳細なレビューについては Fudenberg and Levine (1998) を参照) が、その実際の採用は長らく敬遠されてきた。Erev and Roth (1998) および Börgers and Sarin (1997) の簡単な強化学習モデルは、単純なアルゴリズムで興味深い予測を生成する。しかし、ほとんどの文献は、ナッシュ均衡と全体としての平衡概念の基礎としての学習に関係している。

最後に、オークションにおける共謀に関する理論文献を取り上げる。McAfee and McMillan (1992) は、サイドペイメント^{*11}を使用するカルテルと使用しないカルテルとして定義される、強いカルテルと弱いカルテルによる共謀スキームについて分析している。彼らは、入札ローテーション方式の特性と、どのような条件下で入札者がその方式から利益を得られるかについて議論した。Skrzypacz and Hopenhayn (2004) は、入札者が勝者の身元のみを公に観察する繰り返しゲームにおける暗黙の共謀を研究している (繰り返しオークションにおける入札ローテーションのさらなる分析については、Aoyagi (2003) を参照)。Athey and Bagwell (2001) は、プレイヤーがすべての入札を観察した場合の暗黙の共謀を研究している。Marshall and Marx (2009) は、広範な形式のオークション形式がどのように暗黙の共謀を阻害または促進するかを示している。

^{*8} 実際の利得と最も良い可能性のある利得との間の差 (リグレット) を時間の経過とともに最小化するアルゴリズムのこと。異なる行動の結果についての不確実性がある状況で、繰り返し意思決定が行われる場面で利用される。

^{*9} 最も高い金額を入札した者が商品を落札するが、支払う金額は第二に高い入札額となるオークションのこと。

^{*10} 最も高い金額を入札した者が商品を落札し、その入札した金額を支払うオークションのこと。

^{*11} 取引や合意の一部として、主要な取引の一部ではない追加の支払いや特典のこと。交渉や合意形成の過程で、参加者間の利益を平準化したり、合意を円滑に進めたりするための調整手段として使用される。

3.2 モデル

2 人の入札者が連続するオークションに参加する状況を考える。各期 $t \in \{1, \dots, \infty\}$ において、競売人はオークションを実行し、単一の分割不可能な商品を入札者の一人に割り当てる。どちらの入札者もオブジェクトを $v_i = 1$ で評価し、その値は時間が経っても一定であるとする。

一連のオークションは $\alpha \in [1, 2]$ によってパラメータ化されている。 α -オークションでは、最高額入札者が落札し、当該オークションの敗者の提示価格の加重を $\alpha - 1$ 、勝者の提示価格の加重を $2 - \alpha$ として、その加重平均を落札価格とする。彼らは、一位価格オークション (First Price Auction, FPA, $\alpha = 1$) と二位価格オークション (Second Price Auction, SPA, $\alpha = 2$) という 2 つの極端なケースに焦点を当てている。

期間 t のオークションの勝者の利益は、 $\pi_t = 1 - p_t$ であり、 p_t は、オークション参加者が選択したメカニズムによって決定される価格である。負けた入札者は 0 のペイオフを受け取る。入札者は、割引係数 $\gamma \in (0, 1)$ を使用して、割引された期間ごとのペイオフの期待合計を最大化する。

オークションにおいて、入札者は有限の価格グリッドから入札額を選択する。各入札者は、等距離の入札のセット $[b_1, \dots, b_m]$ にアクセスできる。したがって、 $b_i = \frac{i}{m+1}$ である。この仮定により、より単純な学習アルゴリズムを使用できるようになる。これは、通常、入札者がドルとセントで表される入札を提出できるオークションの代表でもある。

割引率が十分に高い場合、繰り返しゲームには複数のナッシュ均衡が存在しうる。一連の均衡は、オークションのたびに入札者に提供される情報によって異なる。繰り返しゲームに関するリテラチャーから得られる教訓は、落札額といった完全な情報があれば、対称性の強い談合均衡は SPA よりも FPA の方が維持しやすいということであるが、その差はわずかである。その代わり、プレイヤーが勝者の身元を観察するだけであれば、単純な公開完全均衡であっても、ビッドローテーション方式によって暗黙の談合結果を維持することが可能である。さらに、このような均衡は、FPA よりも SPA の方が維持しやすいことが示唆される。この結果から得られる主なことは、単純なアルゴリズムが暗黙の談合結果に到達する傾向は、繰り返しゲームの分析から得られる直感を越えた経済的な力に依存するということである。

シミュレーションでは、まずプレイヤーが勝者の身元のみを観察できる設定から出発し、次に入札額についても観察できる設定に拡張した場合にどのような変化が起こるかを確認する。

3.3 Q 学習アルゴリズム

上記のように設定されたオークションの入札価格設定に、強化学習の基礎となる Q 学習アルゴリズムを導入する。Q 学習アルゴリズムを活用して、各期に 2 人のエージェントは入札ビット $b_t^i \in B = \{b_1, \dots, b_m\}$ を選択するとする。そして、エージェントは $F(r_t | b_t^i, b_t^{-i})$ に従って分布する確率的報酬 r_t を獲得する。

それぞれのエージェントは、割引された報酬の合計 $\mathbb{E}[\sum_t \gamma^t r_t]$ を最大化する。ここで、 $\gamma < 1$ は

割引率である。Q 学習では、DP 問題の価値を考える代わりに、次の行動価値関数を推定する。

$$Q(a) = \mathbb{E}[r | b^i, b^{-i}] + \gamma \mathbb{E} \left[\max_{b'} Q(b') \right]$$

ここで、最適値は単純に $V = \max_b Q(b)$ である。エージェントが Q 関数を学習すると、最適な戦略を実行できるようになる。アルゴリズムは単純で、任意の初期アクション値関数から開始し、アクションを選択した後、次のように Q 関数を更新する。

$$Q_{t+1}(b_t) = (1 - \alpha)Q_t(b_t) + \alpha \left[r_t + \gamma \max_b Q_t(b) \right]$$

この特定の学習形式は非同期である。特定の期間に訪れた状態と行動のペアのみが更新され、残りの Q 関数は一定のまま。ハイパーパラメータ α は学習率と呼ばれる。その課題は、学習の速度を制御することだけでなく、今日の行動価値の推定において過去の経験がどのくらいの期間保持されるかについても制御することだ。更新手順は長期平均であり、この意味でパラメーター α は割引係数に相当する。 γ は将来に与えられる重要性を決定し、 α はアルゴリズムが過去をどれだけ早く忘れるかを指定している。

Q 学習の手順では、実行されるすべての行動の更新ポリシーを指定するが、行動の選択を直接指定するわけではない。最初の探索期間の後には、一貫して優れたパフォーマンスを示している行動から利益を得るのが合理的である。ここでは、 ϵ -greedy として知られるルールに焦点を当てる。エージェントは、Q 関数を最大化する行動を確率 $1 - \epsilon$ で実行し、一様にランダムに確率 ϵ で行動を実行する。探索確率は $\epsilon_t = \epsilon_0 e^{-\beta t}$ の形式になり、 β は時間の経過に応じて探索と活用のトレードオフをさらに調整する。

3.4 結果

オークションで入札する 2 つの独立した Q 学習アルゴリズムのシミュレーションを行った。許可入札のグリッドには、0.05 ~ 0.95 の 19 の入札レベルが含まれる。特に明記されていない限り、各実験は 1,000 回繰り返され、100 万周期後に各実験を終了する。戦略が最後の 1,000 回繰り返して変更されない場合、つまり、各プレイヤーの $\arg\max Q_i(a)$ が一定のままであれば、アルゴリズムは収束している。収束しないシミュレーションは破棄した。

最初の主要な発見は図 2 に示されており、各々 1,000,000 回のオークションを含む 1,000 回の実験における、値 $v = 1$ の入札エージェントの長期的行動の分布を表している。SPA の繰り返しては、入札者は静的ナッシュ均衡の予測に従った入札に収束し、競売人の収益は高い。これとは対照的に、FPA では、入札者は時間の経過とともに低く入札価格に収束する (平均入札価格は 0.24)。これは暗黙の談合を彷彿とさせる。この結果の背後にある経済学的な力を理解するために、FPA と SPA のオークション形式には、結果の違いに寄与する可能性のある複数の違いがあることに着目した。特に、以下の点を指摘する：




図 2. 収束時の各戦略のペアの頻度を示すヒートマップ
出所) Banchio and Skrzypacz (2022), Figure 1

1. 入札が 1 回だけ行われる SPA には支配的な入札戦略があるが、FPA にはなく、アルゴリズムは支配的な戦略を見つけるのが得意である。
2. 入札者が低入札で調整しようとする場合、SPA ではすべての高入札が（短期的には）利益を生む逸脱となるが、FPA では現在の入札に近い入札のみが利益を生む逸脱となる。例えば、入札者が $(0.2, 0.2)$ の入札で調整する場合、SPA では 0.2 から 1 の間のどの入札も利益を増加させるが、FPA では 0.2 から 0.6 の間の入札のみが利益を生む逸脱となる。この論文のアルゴリズムがランダムな実験によって利益となる逸脱を発見しているため、FPA ではそれらが発見することが難しく、より高い入札（例えば 0.8 ）へのトライは現在の暗黙の談合入札よりも低い利益をもたらす可能性があり、したがって入札者は実験を停止する可能性がある。
3. 利益を生む可能性のある逸脱が非常に多く存在するため、アルゴリズムにとって、FPA よりも SPA の方が、暗黙の共謀の結果を調整/達成するのが難しい可能性がある（低入札で初期化すれば、長期的な行動は 2 つのフォーマットで同じになる可能性がある）。
4. 入札者 1 が入札者 2 を競り落とした場合、FPA と SPA、どちらの形式でも入札者 2 は現在の戦略が利益を生まないことを知り、他の入札を模索し始める。この 2 つの形式で異なるのは、入札者 1（高入札者）がどのように行動するかである。SPA では、その入札者のペイオフは現在の入札額に依存しないので、入札者を高入札や低入札に押しやる一次的な力は存在しない。一方、FPA では、落札者は少しでも安く落札するインセンティブを持つ。そのため、入札者が $(0.2, 0.2)$ の入札でスタートした場合、逸脱アルゴリズムは、一定の相手入札に対して、最適な逸脱は 1 入札増分（シミュレーションでは 0.05 増分）だけであることを学習することになる。その結果、入札者が再び同価格の入札を行った場合、平均して FPA の方が SPA よりも低い価格で落札することになる。

これらの可能性のある説明を区別するために、さらなる一連の実験／シミュレーションを計画した。その結果、違いの主な理由は最後の 1 つであることが判明した。この力が、FPA と SPA の根本的な違いである。また、暗黙の談合がなぜオークションごとの平均収益 0.24 をもたらし、それ以下にはならないのかを理解する助けにもなる。入札者が非常に低い入札額で協調しようとする場合、実験によって入札者は押し上げられるだけで、押し下げられることはない。

2 番目の主な発見は図 3 に示されている。FPA で、入札者は落札したかどうかだけでなく、落札を保証する最低の入札がいくらであったかも観察することで、現在の入札だけでなく、すべての反実仮想入札について Q ベクトルを更新することができる（いわゆる同期更新）。このような追加的な情報があれば、FPA でも入札者は時間の経過とともに競争力の高い入札に収束していくことがわかる。場合によっては、両方の入札者がより低い入札で調整することがあるが、その場合には図 3(b) が示すように、すぐに両方の入札者が徐々に 1 入札増分ずつお互いを上回って入札し、入札の競争ベクトルに戻る。




図 3. 同期更新がある場合のシミュレーション結果
出所) Banchio and Skrzypacz (2022), Figure 6

この結果の背後にある力を理解するためには、より低い入札額で再調整するインセンティブについて考えることが役に立つ。両入札者が 0.3 の入札で調整し、一方の入札者が 0.4 に乖離したとする。入札者 1 は新しい入札の価値を即座に見積もり、入札者 2 は 0.3 がもはや良い入札ではないことに気づくだろう。いくつかの実験の後、2 人が 0.4 で調整したとする。もし 2 人の入札者が現在の入札の Q エントリしか更新できなければ、入札 0.3 の見積もりは偏ったままである。やがて入札者は、0.4 で調整することが 0.3 で調整するよりも悪いことを発見し、0.3 に戻ろうとする。

その代わりに、入札者が他の入札からの反実仮想リターンを使って同期的に更新した場合、入札 0.4 に移行すると、戦略 0.3 の価値の推定値は劇的に低下する。ある意味で同期性は近視眼的である。使用される反実仮想的尺度は将来の再調整を考慮に入れていない。

また、彼らはいくつかの拡張を検討している。まず、留保価格^{*12}が入札者の行動に与える影響を分析した。留保価格が正の場合、アルゴリズムは FPA において、留保なしで到達したのと同じ分布で調整するが、留保価格で切り捨てる。SPA では、留保価格がない場合と同様にアルゴリズムは静的ナッシュ均衡に収束する。次に、3 人の AI 入札者、あるいは 2 人の AI 入札者と競争的フリンジというように、競争が激化した場合のゲームを分析した。予想通り、競争激化は FPA の収益を増加させる。しかし、暗黙の共謀を排除することはできない。最後に、FPA と SPA の差は価値観の非対称性に頑健であることがわかった。

参考文献

- ACEMOGLU, D., D. AUTOR, J. HAZELL, AND P. RESTREPO (2022): “Artificial intelligence and jobs: evidence from online vacancies,” Journal of Labor Economics, 40, S293–S340, publisher: The University of Chicago Press Chicago, IL.
- ALCOBENDAS, M. AND R. ZEITHAMMER (2021): “Adjustment of bidding strategies after a switch to first-price rules,” Available at SSRN 4036006.
- AOYAGI, M. (2003): “Bid rotation and collusion in repeated auctions,” Journal of economic Theory, 112, 79–105, publisher: Elsevier.
- ARNOLD, D., W. DOBBIE, AND P. HULL (2021): “Measuring racial discrimination in algorithms,” in AEA Papers and Proceedings, American Economic Association 2014 Broadway, Suite 305, Nashville, TN 37203, vol. 111, 49–54.
- ASKER, J., C. FERSHTMAN, AND A. PAKES (2022): “Artificial intelligence, algorithm design, and pricing,” in AEA Papers and Proceedings, vol. 112, 452–56.
- ASSAD, S., R. CLARK, D. ERSHOV, AND L. XU (2020): “Algorithmic pricing and competition: Empirical evidence from the German retail gasoline market,” Publisher: CESifo Working Paper.
- ATHEY, S. AND K. BAGWELL (2001): “Optimal collusion with private information,” RAND Journal of Economics, 428–465, publisher: JSTOR.
- AVERY, M., A. LEIBBRANDT, AND J. VECCI (2023): “Does Artificial Intelligence Help or Hurt Gender Diversity? Evidence from Two Field Experiments on Recruitment in Tech,” Evidence from Two Field Experiments on Recruitment in Tech (February 14, 2023).
- AVRAMOV, D., S. CHENG, AND L. METZKER (2020): “Machine Learning versus Economic Restrictions: Evidence from Stock Return Predictability, SSRN Scholarly Paper ID 3450322,” Social Science Research Network, Rochester, NY.
- BABINA, T., A. FEDYK, A. X. HE, AND J. HODSON (2022): “Firm investments in artificial intelligence technologies and changes in workforce composition,” Available at SSRN 4060233.

^{*12} オークションなどの販売手段における、商品やサービスの最低売却価格のこと。この価格が入札者による入札金額に達しない場合、商品は売却されないことが多い。

- BANCHIO, M. AND G. MANTEGAZZA (2022): “Adaptive algorithms, tacit collusion, and design for competition,” SSRN Electronic Journal.
- BANCHIO, M. AND A. SKRZYPACZ (2022): “Artificial Intelligence and Auction Design,” ArXiv:2202.05947 [cs, econ].
- BÖRGERS, T. AND R. SARIN (1997): “Learning through reinforcement and replicator dynamics,” Journal of economic theory, 77, 1–14, publisher: Elsevier.
- BERAJA, M., A. KAO, D. Y. YANG, AND N. YUCHTMAN (2023): “AI-tocracy,” The Quarterly Journal of Economics, 138, 1349–1402, publisher: Oxford University Press.
- BLOEMBERGEN, D., K. TUYLS, D. HENNES, AND M. KAISERS (2015): “Evolutionary dynamics of multi-agent learning: A survey,” Journal of Artificial Intelligence Research, 53, 659–697.
- BROWN, G. W. (1951): “Iterative solution of games by fictitious play,” Act. Anal. Prod Allocation, 13, 374.
- BROWN, Z. Y. AND A. MACKAY (2021): “Competition in pricing algorithms,” Tech. rep., National Bureau of Economic Research.
- BRUNNERMEIER, M. K., R. LAMBA, AND C. SEGURA-RODRIGUEZ (2020): “Inverse Selection,” SSRN Electronic Journal.
- BRYNJOLFSSON, E., X. HUI, AND M. LIU (2019): “Does machine translation affect international trade? Evidence from a large digital platform,” Management Science, 65, 5449–5460, publisher: INFORMS.
- CALVANO, E., G. CALZOLARI, V. DENICOLO, AND S. PASTORELLO (2020): “Artificial intelligence, algorithmic pricing, and collusion,” American Economic Review, 110, 3267–3297, publisher: American Economic Association 2014 Broadway, Suite 305, Nashville, TN 37203.
- CALVANO, E., G. CALZOLARI, V. DENICOLÒ, AND S. PASTORELLO (2023): “Artificial Intelligence, Algorithmic Recommendations and Competition,” Algorithmic Recommendations and Competition (May 14, 2023).
- CAO, S., W. JIANG, J. L. WANG, AND B. YANG (2021): “From man vs. machine to man+ machine: The art and AI of stock analyses,” Tech. rep., National Bureau of Economic Research.
- CHOUDHURY, P., E. STARR, AND R. AGARWAL (2020): “Machine learning and human capital complementarities: Experimental evidence on bias mitigation,” Strategic Management Journal, 41, 1381–1411, publisher: Wiley Online Library.
- DUBÉ, J.-P. AND S. MISRA (2023): “Personalized pricing and consumer welfare,” Journal of Political Economy, 131, 131–189, publisher: The University of Chicago Press Chicago, IL.
- EREV, I., Y. BEREBY-MEYER, AND A. E. ROTH (1999): “The effect of adding a constant to all payoffs: experimental investigation, and implications for reinforcement learning models,” Journal of Economic Behavior & Organization, 39, 111–128, publisher: Elsevier.
- EREV, I. AND A. E. ROTH (1998): “Predicting how people play games: Reinforcement learning in experimental games with unique, mixed strategy equilibria,” American economic review, 848–881,

- publisher: JSTOR.
- FUDENBERG, D. AND D. K. LEVINE (1998): The theory of learning in games, vol. 2, MIT press.
- HANSEN, K. T., K. MISRA, AND M. M. PAI (2021): “Frontiers: Algorithmic collusion: Supra-competitive prices via independent algorithms,” Marketing Science, 40, 1–12, publisher: INFORMS.
- KLEIN, T. (2021): “Autonomous algorithmic collusion: Q-learning under sequential pricing,” The RAND Journal of Economics, 52, 538–558, publisher: Wiley Online Library.
- KLEINBERG, J., H. LAKKARAJU, J. LESKOVEC, J. LUDWIG, AND S. MULLAINATHAN (2018): “Human decisions and machine predictions,” The quarterly journal of economics, 133, 237–293, publisher: Oxford University Press.
- KLEINBERG, J., J. LUDWIG, S. MULLAINATHAN, AND Z. OBERMEYER (2015): “Prediction policy problems,” American Economic Review, 105, 491–495.
- KOLUMBUS, Y. AND N. NISAN (2022): “Auctions between regret-minimizing agents,” in Proceedings of the ACM Web Conference 2022, 100–111.
- LOU, B. AND L. WU (2021): “AI on drugs: Can artificial intelligence accelerate drug development? Evidence from a large-scale examination of bio-pharma firms,” Evidence from a Large-scale Examination of Bio-pharma Firms, (March 15, 2021). MISQ Forthcoming.
- LUO, X., S. TONG, Z. FANG, AND Z. QU (2019): “Frontiers: Machines vs. humans: The impact of artificial intelligence chatbot disclosure on customer purchases,” Marketing Science, 38, 937–947.
- MARSHALL, R. C. AND L. M. MARX (2009): “The vulnerability of auctions to bidder collusion,” The Quarterly Journal of Economics, 124, 883–910, publisher: MIT Press.
- MCAFEE, R. P. AND J. MCMILLAN (1992): “Bidding rings,” The American Economic Review, 579–599, publisher: JSTOR.
- MILGROM, P. R. AND S. TADELIS (2018): “How artificial intelligence and machine learning can impact market design,” in The economics of artificial intelligence: An agenda, University of Chicago Press, 567–585.
- MUSOLFF, L. (2022): “Algorithmic pricing facilitates tacit collusion: Evidence from e-commerce,” in Proceedings of the 23rd ACM Conference on Economics and Computation, 32–33.
- NEDELEC, T., N. EL KAROUI, AND V. PERCHET (2019): “Learning to bid in revenue-maximizing auctions,” in International Conference on Machine Learning, PMLR, 4781–4789.
- RAFIEIAN, O. AND H. YOGANARASIMHAN (2021): “Targeting and privacy in mobile advertising,” Marketing Science, 40, 193–218, publisher: INFORMS.
- RAMMER, C., G. P. FERNÁNDEZ, AND D. CZARNITZKI (2022): “Artificial intelligence and industrial innovation: Evidence from German firm-level data,” Research Policy, 51, 104555, publisher: Elsevier.
- SKRZYPACZ, A. AND H. HOPENHAYN (2004): “Tacit collusion in repeated auctions,” Journal of Economic Theory, 114, 153–169, publisher: Elsevier.

- WANG, Q., Y. HUANG, S. JASIN, AND P. V. SINGH (2020): “Algorithmic Transparency with Strategic Users,” ArXiv:2008.09283 [cs].
- WATKINS, C. J. C. H. (1989): “Learning from delayed rewards,” Publisher: King’s College, Cambridge United Kingdom.
- WATKINS, C. J. C. H. AND P. DAYAN (1992): “Q-learning,” Machine Learning, 8, 279–292.
- ZHANG, K., Z. YANG, AND T. BAŞAR (2021): “Multi-agent reinforcement learning: A selective overview of theories and algorithms,” Handbook of reinforcement learning and control, 321–384, publisher: Springer.