

博士論文 令和5年度（2023）

レビューの不正操作についての実証研究

慶應義塾大学 大学院 経済学研究科

坂口 洋英

はしがき

近年、フェイクレビューと呼ばれる、“ヤラセ”や“サクラ”にあたる偽レビューにより、レビューやレーティングが不正に操作されることが社会問題化している。本稿は、こうしたレビューの不正操作の問題について、筆者が2021年から現在までに行った研究成果をまとめたものである。

本稿の執筆にあたり、多くの方々のご指導とご支援をいただいた。この場において、深く感謝の意を申し上げます。指導教官である田中辰雄先生には、学部生時代から熱心にご指導いただいただけでなく、様々な面で、長年にわたるご支援と助言をいただいた。学内では、石橋孝次先生、河井啓希先生、中嶋亮先生、中妻照雄先生には、研究内容について有意義な指摘をいただいただけでなく、公私の両面でお世話になった。

学外では、7章の共著者である、依田高典先生(京都大学大学院)、大磯一氏(京都大学大学院)、黒田敏史先生(東京経済大学)には、彼らの広範な知識と深い洞察から大変多くのものを学ばせていただいた。

さらに、学会ならびに、各種ワークショップにて、様々な有益なコメントを頂いた。北野泰樹先生(青山学院大学)、土居直史先生(小樽商科大学)、遠山祐太先生(早稲田大学)、中林純先生(京都大学)、西脇雅人先生(大阪大学)、原泰史先生(神戸大学)、松木佑介先生(長崎大学)、安井佑太先生(高知工科大学)、若森直樹先生(一橋大学)、その他多くの先生から建設的なアドバイスをいただいた。

最後に、生活面で支えてくれた家族に心より感謝したい。

目次

第 1 章	イントロダクション	4
第 2 章	先行研究のサーベイ	10
2.1	はじめに	10
2.2	理論研究	10
2.3	観察データを用いた実証研究	12
2.3.1	Mayzlin et al. (2014)	13
2.3.2	Luca and Zervas (2016)	16
2.3.3	He et al. (2022b)	20
2.4	実験データを用いた実証研究	26
2.4.1	Akesson et al. (2023)	26
2.5	その他の関連研究	29
2.6	先行研究の課題と本研究の位置づけ	30
第 3 章	Amazon.co.jp とデータ	33
3.1	はじめに	33
3.2	Amazon のシステム	33
3.3	レビューの不正操作	35
3.4	データの取得	39
3.5	記述統計	41
第 4 章	どんなレビューがフェイクなのか?: レビューレベルの実証分析	44
4.1	はじめに	44
4.2	データ	44
4.3	メソドロジーと結果	46
4.3.1	モデル	46
4.3.2	推定結果	48
4.3.3	セラーの交差項の導入	51
4.4	おわりに	54
第 5 章	どんな売り手や商品が不正に関与しているのか? プロダクトレベルの分析	56

5.1	はじめに	56
5.2	データ	56
5.3	メソドロジーと結果	58
5.3.1	モデル	58
5.3.2	推定結果	61
5.4	おわりに	63
第 6 章	いつフェイクレビューは投稿されるのか?: パネルデータによる分析	64
6.1	はじめに	64
6.2	データ	64
6.2.1	記述統計	64
6.2.2	レビューの不正操作の時系列上での動向	65
6.3	メソドロジーと結果	78
6.3.1	モデル	78
6.3.2	推定結果	79
6.4	おわりに	83
第 7 章	実験データを用いたフェイクレビューの影響の調査	86
7.1	はじめに	86
7.2	実験設計	87
7.2.1	実験の概要	87
7.2.2	実験サイトの基本設計	88
7.2.3	介入	89
7.2.4	使用データ	93
7.2.5	メソドロジー	96
7.3	実験結果	96
7.3.1	記述統計	96
7.3.2	フェイクレビューと商品表示順の効果	100
7.3.3	トリートメントの交互作用	103
7.4	おわりに	103
第 8 章	総括と今後の展望	106

Appendix A. 異なる特定化によるパネルデータ分析	109
Appendix B. 実験サイトと質問	109
参考文献	117

第 1 章 イントロダクション

口コミ (Word of Mouth: WoM) は消費者が日常で財を選択するにあたり、大きな役割を果たす。特に近年では、高速インターネット回線とスマートデバイスの浸透を背景に様々なオンラインサービスが生まれ、インターネット上の口コミ (e-WoM)、その中でも消費者レビューが存在感を増している。例えば、Amazon や楽天のような EC サイトでは、レビューシステムやレーティングシステムが導入されており、販売される財への消費者からの評価が分かるようになっている。また、「食べログ」のような、特定の分野に特化した、レビューやレーティングを主目的とするようなサイトも、人々の日常生活を大きく支えている。

こうした消費者レビューが、財の需要にも大きく影響を与えていることは、様々な調査や実証研究にも支持されている。消費者庁 (2020) では、半数以上の消費者がレビューを参照し、その 7 割以上がレビューを信頼していることが示されている。また、Chevalier and Mayzlin (2006) や Chintagunta et al. (2010)、Hollenbeck (2018) のように、経済学や経営学における様々な実証研究において、レビューが消費者の需要に正の影響をもたらす結果が導かれている。

一方で、レビューや口コミを悪用する企業も出現するようになった。国内では、2010 年代前半から、「食べログやらせ事件」¹や「ペニーオークション詐欺事件」²などをきっかけに、レビューや口コミを不正に操作することが、ステルスマーケティングの一種として、問題視されるようになった。

特に近年では、Amazon におけるレビューの不正操作が社会問題として注目を集めている。このレビューの不正操作においては、「フェイクレビュー」と呼ばれる偽のレビューが投稿される³。これは、商品の売り手が、消費者に金銭などと引き換えに投稿させたレビューとなる。所謂“サクラ”や“ヤラセ”といった行為に該当するものであり、本来利害関係にない消費者が投稿することが期待される“本物”のレビューではない“偽物”という点で、フェイクといえるレビューとなる。このようなフェイクレビューにより、高評価のレビュー数を水増しすることで、商品のレーティングを上げるなど、レビューに基づくレーティ

¹ レストランレビューサイトである食べログにおいて、ステルスマーケティングを行う業者の存在が明らかになった事件。 https://www.nikkei.com/article/DGXNASDG0403M_U2A100C1CR8000/?dg=1 などを参照された。

² ペニーオークションという、入札に手数料がかかるものの、安価で落札可能なオークション形式をうたうオークションサイトが、自動入札用の Bot を用い、実際には落札できないように妨害することで手数料を騙し取った事件。多くの芸能人がブログで当該サイトを紹介するなど、ステルスマーケティングへの関与が発覚した。詳細は <https://www.shiroyama-tower.com/books/yomiuri/20130313.html> などを参照された。

³ 本稿では、一連の不正について、Mayzlin et al. (2014) にちなみ、レビューの不正操作と呼称する。

ングシステムに対して不正な介入を行うことが可能となる⁴。

米国においては、コロナ禍による Amazon の利用増加もあって増加傾向にあり、2020 年には全体のレビューのうち 40% ものレビューがフェイクである疑いもたれている。国内においても、多くのメディアで取り上げられているほか、Amazon のレビューについての検索エンジンの検索結果⁵上位は、こうしたフェイクレビュー関連の記事が上位を占め、レビューの不正操作が横行していることが伺える。

こうしたレビューの不正操作は、ステルスマーケティングにあたり、競争上の不当な行為といえる。さらに、消費者や、他の売り手やプラットフォーム自体にも被害を及ぼす可能性がある。具体的には、まず、消費者が欺かれ、望まない消費を行うという直接的な被害が想定される。加えて、消費者のレビューという仕組み自体への信頼を失わせる可能性がある。これは、財の選択に係るサーチコストを増大させ、間接的に消費者だけでなく商品販売者やプラットフォーム全体に被害をもたらすことが懸念される。

こうした背景からか、米国では強く問題視されており、FTC(連邦取引委員会)は、金銭を受け取り公平な第三者と偽ってレビューを執筆することを明確に違法行為と定め、高額を罰金を科している⁶。

一方、我が国では、長らく 2012 年に景品表示法のガイドラインが改訂されたに留まっていた。これは、フェイクレビューが景品表示法の不当表示にあたる可能性について示したものにすぎず、法曹界からは規制強化を求める声もあった(日本弁護士連合会, 2017)。近年では、ステルスマーケティングの規制強化への動きが進み、2023 年の 10 月から、フェイクレビューが不当表示にあたることが明文化されたものの、依然として諸外国と比較して規制の有効性・強制性が弱いことが指摘されている(カライスコス, 2023)。

以上から、現状の我が国は、更なる規制・施策など、レビューの不正操作に対し有効な対策を検討する段階にあるといえる。これらを策定するにあたり肝要なのは、何を対象に、どのような介入を行えば、レビューの不正操作の被害をどれだけ抑制できるのかという点である。加えて、トレードオフを考慮しなくてはならない。フェイクレビューを抑制するための規制や施策は、同時に、フェイクでない真のレビューの投稿をも減らすことが懸念される。例えば、レビューの投稿に現在よりも厳しい条件⁷を課す場合、フェイクレビュー

⁴フェイクレビューがフェイクとされるのは、消費者と売り手の利害関係によるものであり、必ずしも商品の実態と乖離している必要はない。仮に、高品質な財の売り手が金銭と引き換えに高評価であるレビューの執筆を依頼した場合でも、それはフェイクレビューとなる。

⁵2023 年 10 月確認

⁶<https://www.ftc.gov/news-events/news/press-releases/2021/10/ftc-puts-hundreds-businesses-notice-about-fake-reviews-other-misleading-endorsements>

⁷Amazon では、アカウントがレビューを投稿可能になるまで一定の条件を課している。詳細は 3 章にて述

と真のレビューの両方が減少することになる。

さらに、レビューの不正操作は害をもたらさない可能性もある。高品質な財の売り手が不正を行っているケースでは、被害が生じにくい。むしろ、フェイクレビューは、商品の質のシグナルとして、有益な可能性もある。このようなケースは、直観的ではないものの、フェイクレビューを一種のマーケティング手段として考える場合、Nelson (1970) や Milgrom and Roberts (1986) の結果は、質の高い財の売り手が不正を行う均衡が存在しうることを示している。また、フェイクレビュー自体について理論モデルによる分析を行った例では、Dellarocas (2006) は、高品質な財を供給する企業ほど不正を行うという均衡が起りうることを示し、Yasui (2020) は均衡では質の高い企業ほどフェイクレビューを募集することを示している。

したがって、まず、現状におけるレビューの不正操作がもたらす被害を把握することが求められる。さらに、考えられうる介入がどれだけこの被害を抑制し、どれだけレビューの減少とそれに伴う社会厚生¹の減少をもたらすかについて評価する必要があるといえる。そのためには、レビューの不正操作に関する実態を把握し、様々なトピックについて広範なエビデンスを獲得せねばならない。これらのリサーチクエッションは、三つに大分される

課題 1 不正行為の詳細はどんなものか？

第一に、不正行為の詳細なパターンを明らかにすることである。具体的には、どのレビューがフェイクであるか、またどの売り手や製品が不正操作に関与しているか、さらに、これらの行為がどのような動機やインセンティブの下で行われているのかを理解することが求められる。これらの知見は、不正と被害の抑制のために、どのような介入が効果的か、何に焦点を当てるべきなど、規制・施策の勘案にあたり不可欠である。また、政府やプラットフォームだけでなく、消費者や一般の企業がフェイクレビューを識別するうえでも役立つ。

特に、売り手の属性や扱う商品の質は、消費者の被害に大きく影響を与える。不正操作により被害が生じるのは、低品質な財の売り手が、あたかも高品質なものに見せかけるようフェイクレビューを用いているケースである。この場合は、消費者が欺かれて粗悪品を購入してしまうという形で被害が生じる。逆に、高品質な財の売り手がフェイクレビューにより自社製品のステルスマーケティングを行うようなケースでは、高品質な財に対して、財が高く評価されているようなフェイクレビューが投稿されることになる。この場合、実態と乖離していない以上、消費者がレビューに欺かれて想定以下の品質の財を購入してし

まうような事態は起こりにくい。倫理や競争上の公正の面では明らかに問題とはいえるものの、先述したように、消費者被害にはつながりにくいと考えられる。⁸

課題 2 消費者はフェイクレビューにどのような影響を受けるのか？

第二に、消費者がフェイクレビューにどのような影響を受けるのかを明らかにしなくてはならない。具体的には、フェイクレビューの下で提示される情報をもとにどのような判断を下し、どのように選択するのかといった、消費者の行動の変容について、詳細なレベルで把握することが求められる。これらの知見は、効果的な介入の策定にあたり、不正行為が消費者の行動にどのような歪みをもたらし、その結果どのような被害が生じるかというメカニズムを解明するために必要とされる。

消費者が受ける影響の中でも、消費者がフェイクレビューにどれだけ欺かれるかは、レビューの不正操作がもたらす被害を左右する関係上、特に重要になる。フェイクレビューを見分けられずに欺かれるような消費者が大半であるならば、害は大きい。一方で、消費者の多くがフェイクレビューを見分けられたり、フェイクレビューの存在を考慮して商品選択が歪まないならば、害は小さくなる。実際に、理論研究においても、消費者のフェイクレビューの判別などについてのタイプとその分布が、不正操作がもたらす厚生の変化に対し大きな影響を与える、鍵となる変数として扱われている。さらに、公平性を重視する立場からは、消費者の属性とフェイクレビューから受ける影響の関係が政策決定において大きなファクターとなる。例えば、学歴や所得の低い消費者ほどフェイクレビューに欺かれやすい場合、仮にレビューの不正操作が総余剰に与える影響が正であっても、規制は正当化され得る。

課題 3 レビューの不正操作に対して有効な施策や制度設計はどんなものか？

第三に、どのような介入やレビューシステム・レーティングシステムが、レビューの不正操作の被害をどれだけ抑制できるか明らかにする必要がある。現在は、有効な施策を勘案する段階であるが、少数ながらも既に行われている介入は存在する。また、現在のレビューやレーティング、商品表示に関連するシステムは、レビューの不正操作の被害についても影響をもたらしている可能性がある。さらに、既存の施策や現状のレビューシステム

⁸理論研究により支持されるものの、想像し難いケースであるが、市場に参入して間もないために知名度が低いものの、高品質な財を供給するような企業が、安価なプロモーション手段としてフェイクレビューを使うケースは十分に考えられうる。このケースに該当する可能性が高い例として、ノキア社は2020年頃に日本でイヤホンの販売を開始したが、ある商品については多くのレビューが削除されている。ただし、この商品については、質が低いとの指摘をイギリスの消費者団体 Which? から受けている。

の設計について効果を検証することは、今後の施策の方向性を決定づける点に関しても有益である。

フェイクレビューが消費者を利するシグナルとなる可能性を考慮すると、規制やフィルタリングの強化のようにフェイクレビューを直接減らすような介入ではなく、フェイクレビューに消費者が欺かれるのを防ぐような間接的なものは、穏当な手段として望ましい。そのため、特に、教育的な介入や、Yelp で行われているようなフィルタリングされたレビューを別個で表示されるようなシステムについては、効果を検証する意義が大きい。また、商品表示やランキングのシステムは、時にレビューの不正操作の被害を増大させる恐れがある。例えば、レーティングの高さに基づいた商品の表示順は、不正が行われた商品が上位に表示されやすくなってしまふことが懸念される。この点から、レビューシステムに関連する、EC サイトの制度設計についても、フェイクレビューの下でどのように機能するか評価する必要がある。

これらのリサーチクエッションに対し、蓄積されたエビデンスは十分な水準にあるとはいえず、レビューの不正操作の実態については未だ不明な点が多いというのが現状である。米国の産業について観察データを用いた研究 (Mayzlin et al., 2014; Luca and Zervas, 2016; He et al., 2022b) や、実験データを用いた研究 (Ananthakrishnan et al., 2020; Akesson et al., 2023) が行われてはいるものの、先行研究の蓄積は限定的である。特に、国内においては、取材レベルの調査が行われるのに留まっている。

そこで、本稿は、Amazon.co.jp の観察データの分析と、実験データの分析を通じ、こうしたレビューの不正操作の実態について明らかにするものである。本稿の構成は以下の通りである。

2 章では、レビューの不正操作に関する研究のサーベイを行い、先行研究の課題と限界について整理し、そのうえで本稿がどのように差別化されるかについて位置づける。3 章では、分析対象となる Amazon.co.jp について、そのシステムについて概説し、データの取得方法と仕様について述べる。

4 章から 6 章においては、Amazon.co.jp から取得したデータを用いた分析を行う。これらの章は、主に、本章で述べた第一のリサーチクエッションに対応するものである。4 章では、レビューレベルの分析により、どのようなレビューがフェイクかについて検証する。分析の結果、フェイクレビューは、一見、真実のレビューのような特徴をもち、消費者がうまく判別できていない可能性が示された。

5 章は、プロダクトレベルの分析により、どのような売り手や商品が不正に関わっている

かについて明らかにするものである。低品質な財や、非ブランドの製品の売り手ほど、不正を行いやすいことが示され、消費者被害が大きくなるようなパターンに該当する結果となった。

6章においては、パネルデータ分析により、フェイクレビューの時系列上の動向を把握し、不正の背景にあるインセンティブについて明らかにする。フェイクレビューは販売初期に集中し、その後減少することと、フェイクレビューが投稿されて以後、低評価のレビューが増加することが示された。所謂“売り逃げ”のを目的で不正が行われ、消費者被害が生じていることも示唆された。

7章は、第二、第三のリサーチクエッションに答えるものである。Amazonを模したwebサイトでの実験を用いた分析により、消費者がレビューの不正操作に対しどのような影響を受け、教育的介入やAmazonの商品表示システムがどのような効果をもたらすかを明らかにする。分析の結果、フェイクレビューは消費者を低品質な財に誘導し、教育的介入はフェイクレビューの被害を抑制できなかった。また、レーティング順での商品表示システムは、フェイクレビューの下でもおおよそ頑健なものの、時にフェイクレビューの被害を増幅させる懸念があることが示された。

最後に、8章では、4章から7章までの分析結果を総括したうえで考察を行い、政策的含意や、今後の展望について述べる。

本稿の各章は、筆者が従事してきた研究プロジェクトに依拠する。第二章は、筆者が経済産業省のプラットフォーム研究会に依頼されて執筆したサーベイ論文(坂口, 2022)に大幅な加筆修正を加えたものである。第三章から六章までは、筆者の単著プロジェクト⁹の分析結果を述べたものである。第七章については、筆者が参加している、京都大学大学院の依田高典氏と大磯一氏、東京経済大学の黒田敏史氏による、共著プロジェクト(Oiso et al., 2023)に依拠するものである¹⁰。

⁹未公開。

¹⁰論文としてはワーキングペーパーの段階かつ未公開であり、学会やワークショップでの発表を行う段階である。

第 2 章 先行研究のサーベイ

2.1 はじめに

本章では、レビューの不正操作に関わる研究について、実証研究を中心にサーベイを行う。まず、理論研究について概説したのちに、観察データを用いた実証研究について整理し、代表的な実証研究である Mayzlin et al. (2014) と Luca and Zervas (2016)、He et al. (2022b) について紹介する。さらに、近年に例がある、実験データを用いた実証分析について述べたうえで、Akersson et al. (2023) を紹介する。そのうえで、既存研究のギャップを明らかにし、本稿を位置づける。

2.2 理論研究

レビューの不正操作に関連する理論研究は、Nelson (1970) や Milgrom and Roberts (1986) のシグナリングモデルの文脈に置かれる。彼らは、シグナリングモデルによる広告の分析において、高品質商品を供給する企業だけが広告を行い、低品質な商品を供給する企業は広告を行わない分離均衡が存在し得ることを示している。

レビューの不正行為の問題がモデル化される際には、ステルスマーケティングの一環として、こうしたシグナリングモデルが拡張される。ここで、フェイクレビューやそれに類するものは、企業による広告とは別のプロモーションの手段として行われる。更に、これらとは別に、他の消費者による真のレビューが存在する。消費者は、レビューをシグナルとして受けとって行動するものの、消費者はフェイクレビューと、真のレビューなどの正しい情報を判別することができず、どちらのレビューがどれだけの量存在するかを観察できない。消費者は、真のレビューとフェイクレビューの両方が存在することについては理解しており、後者の存在を考慮し割り引いて財の選択を行う。企業はこうした消費者を想定して、フェイクレビューの量などを調整する。既存の理論研究はこのようなモデルを用い、均衡においてどのような主体がフェイクを行い、どのような結果をもたらすか、その結果はどのような要因に影響されるのかについて分析している。

Mayzlin (2006) は、企業のステルスマーケティングと純粋な消費者口コミによって消費者の需要がどのように影響されるかを理論モデルで構築し分析している。このモデルにおいては、二企業 A と B が、互いに自社の財が他社の財より優秀だという口コミを流す。同時に、財の品質を見分けられる消費者 D が、どちらの財が優れているかについて正しい口コミを流す。その後、財の品質の判別ができない消費者 C が、ステルスマーケティングも

含めた風評に依存して選択を行う。この際、消費者 C は企業による口コミの操作を考慮し、これらを割り引いて口コミから品質を推測する。企業は、消費者 C の選択を想定して¹¹、どれだけの量の口コミを流すかを決定する。均衡では、低品質な商品を供給する企業の方が、多くの口コミを流すことが示された。また、ステルスマーケティングによる厚生損失は二つの財の品質の差や財の価格が大きいほど増加し、消費者 D の数が大きくなるほど減少することが示されている。

一方で、Dellarocas (2006) は、高品質な財を供給する企業ほどより多く不正を行う均衡が存在しうることを、別の理論モデルにより示している。このモデルでは、質 q の財を供給する独占企業の質が、フェイクレビューを投稿することで、質についてのシグナル y を操作する。消費者は、 $\theta = E[q|y]$ をもとに商品の質を判断し、需要は消費者の効用関数における質についてのコンポーネント $f(\theta)$ で決定される。均衡については、 q が高い高品質な財を供給する企業ほどより多く不正を行う均衡と、逆に q が低い低品質な財を供給する企業ほど多く不正を行う均衡の両方が存在しうることを示されており、前者のパターンはレビューの不正操作が消費者に有益であることを示唆する。二つの均衡のうちどちらが成立するかは、予想された質を評価する消費者の効用関数である $f(\theta)$ に依存する。

近年では、Yasui (2020) が、レビューシステムの特徴を反映し、より現実のレビューの不正操作の問題に対応した理論モデルによる分析を行っている。ここでは、独占企業が、財を q 個販売する。このとき、企業は時間経過により変化する財の質 θ_t や、商品のレーティング Y_t に応じて、その都度ダイナミックにフェイクレビューの量 F_t を調整する。レーティング Y_t は、 θ_t に応じた本物のレビューの投稿のほか、 F_t により変化する。消費者は、フェイクレビューの存在を考慮できる合理的なタイプと、フェイクレビューの存在を知らないナイーブなタイプが考慮され、前者をベースラインに、後者が混じるケースについて検討している。消費者が合理的なタイプのみの場合、均衡では、財の質 θ_t が高いほど、フェイクレビューの投入量が増加し、レーティング Y_t が高いほどフェイクレビューが減少する。これは、高品質な企業のシグナルとなるため、フェイクレビューのフィルタリングの強化はレーティングの情報量を下げる可能性が指摘されている。ナイーブな消費者が混じるケースでも、均衡における財の品質・レーティングとフェイクレビューの関係は変化しない。ただし、フィルタリングの強化はナイーブな消費者を利する結果となっており、消費者保護とレーティングシステムの情報量はトレードオフといえる。

これらの理論研究は、レビューの不正操作とその影響に関して、重要な知見を提供する。

¹¹ D の選択は企業の利潤に含まれず、口コミを介してのみ利潤に影響を与える。

第一に、必ずしも低品質な財を供給する企業が不正を行うのではなく、Dellarocas (2006) や Yasui (2020) が支持するように、高品質な財を供給する企業が不正を行うような均衡が存在しうることである。こうしたケースでは、レビューの不正操作は有害とは限らず、消費者にとって有益なシグナルとなる可能性がある。消費者余剰に対する影響を、実証研究により定量的に評価することが求められる。

第二に、消費者の異質性や効用関数が、レビューの不正操作の被害に影響を与える点がいえる。Mayzlin (2006) では、財の品質を正しく見分けられる消費者が多いほど被害が減少し、Dellarocas (2006) では、消費者の商品の質への効用関数によって不正を行う企業のタイプが変化した。さらに、Yasui (2020) の結果は、ナイーブな消費者が多い場合、消費者保護の観点から規制が好ましい可能性を示している。消費者が実際にどれだけ騙されやすいのか、騙されやすい消費者はどの程度の割合なのかなど、フェイクレビューに対する消費者の反応と、異質性について明らかにすることが必要となる。

2.3 観察データを用いた実証研究

レビューの不正操作に関わる、観察データを用いた実証研究は、米国ホテルレビューサイトにおける不正操作対象とした Mayzlin et al. (2014) を嚆矢として、ボストンのレストランのレビューを分析した Luca and Zervas (2016)、米 Amazon のフェイクレビューを対象とした He et al. (2022b) が存在する。近年では、ホテル産業を扱った Nie et al. (2022) やレストランを扱った Li et al. (2023) なども存在する。これらは、レビューの不正操作の主体がどのようなもので、どのようなインセンティブに基づいて不正操作を行っているかについて、実証分析を通じ調査している。主要な研究について¹²、対象としたウェブサイトや分析の対象について、簡易にまとめたものが以下の表 1 となる。

表 1: レビューの不正操作に関する実証研究

	Mayzlin et al. (2014)	Luca and Zervas (2016)	He et al. (2022b)
対象サイト	Tripadvisor&Expedia	Yelp	Amazon
産業	ホテル	レストラン	特定産業でない
データの種類	クロスセクション	パネル	パネル
フェイクの把握	プロキシ	プロキシ	製品レベルで把握
自社高評価偽装	扱う	扱う	扱う
他社攻撃	扱う	扱う	扱わない
研究の範囲	不正の主体	不正の主体	不正の主体・不正の影響

¹²Nie et al. (2022) と Li et al. (2023) は、前者が Mayzlin et al. (2014) と類似した分析であり、後者は Li et al. (2023) と同様の分析を行っている関係上、省略する。

レビューの不正操作に関して、実証面で常に付きまとう課題として、レビューがフェイクか否かが判別できないという問題がある。こうしたフェイクの識別について、Mayzlin et al. (2014) と Luca and Zervas (2016) は、フェイクレビューを直接観察することはできず、プロキシを用いるアプローチをとっている。一方で、He et al. (2022b) は、Facebook のフェイクレビュー依頼コミュニティの調査を通じ、不正操作が行われている製品をある程度把握することに成功している。

分析対象としては、He et al. (2022b) は、自社製品を高く装うようなレビューの不正操作のみ扱っている。対し、Mayzlin et al. (2014) と Luca and Zervas (2016) は、競合相手から投稿されていると思われる、フェイクレビューによる攻撃についても扱っている。これは、後者の2つが対象とするのが、ホテルやレストランといった、競合相手が同じ地域に限定されやすいことに起因する。一方で、前者は Amazon を対象としているため、潜在的に多くの競合相手が存在するうえ、どの商品が競合関係にあるか定かではない¹³。

これらの研究は、レビューの不正操作の主体とそのインセンティブに焦点を当てており、不正操作がもたらす被害を定量的に評価するまでには至っていない。ただし、He et al. (2022b) は、フェイクレビューの投稿が開始されてからセールスランクが上昇することや、欺かれて望まぬ購入をしたと思わしき低評価レビューが増加することを示しており、限定的ではあるものの、レビューの不正操作がもたらす影響について推定している。

2.3.1 Mayzlin et al. (2014)

Mayzlin et al. (2014) は、Tripadvisor と Expedia における 2011 年 10 月時点での米国ホテルのレビューを対象に、どのような経営形態やオーナーシップのホテルがレビューの不正操作を行っているかについて分析している。両サイト上でも、レビューがフェイクか否かは判別できない。そこで、彼ら¹⁴は二つのレビューシステムの違いを利用している。

プロキシ

当時、Tripadvisor と Expedia は同じ経営母体であったものの、異なるレビューシステムを有していた。Expedia では同サイトを通じて予約した消費者のみがレビューを行うことができたのに対し、Tripadvisor ではどんな消費者でもレビューを行うことができた。その

¹³He et al. (2022b) は Amazon において、競合相手を攻撃するレビューはコストが大きく、効果が限定的であることも示している。ただし、フェイクレビューによる攻撃を受けた事例は存在し、例えば、Anker はフェイクレビューによる攻撃についてプレスリリースを出している (現在は削除。以下で確認は可能。https://news.infoseek.co.jp/article/prtimes_000000227_000016775/)。

¹⁴以後、論文の複数の筆者は全て彼らで統一する。

ため、Tripadvisor におけるフェイクレビューの投稿のコストは相対的に低く、ホテル経営者がレビューの不正操作を行う場合、Expedia にフェイクレビューを投稿するよりも、Tripadvisor にフェイクレビューを投稿する可能性が高い。

このような背景から、Mayzlin et al. (2014) は、Tripadvisor と Expedia におけるレビューの分布の差を、どれだけ不正行為が行われているかについてのプロキシとして扱っている。これは以下の (1) で表される。

$$Y_{ij}^N = \frac{NstarReviews_{ij}^{TA}}{TotalReviews_{ij}^{TA}} - \frac{NstarReviews_{ij}^{Exp}}{TotalReviews_{ij}^{Exp}} \quad (1)$$

ここで、 i はホテルを、 j は地域を意味する。 TA は Tripadvisor、 Exp は Expedia を示す。 $NstarReviews$ は星 N のレビューの数を、 $TotalReviews$ はレビューの合計本数となる。そのため、右辺第一項は Tripadvisor における N 点レビューの割合であり、第二項は Expedia における N 点レビューの割合となる。

自社を高評価に装うなら、Tripadvisor に対して高評価のフェイクレビューを相対的に多く投稿する。この場合、 N が 4 や 5 の時に右辺の第一項が、第二項と比べて大きくなり、 Y_{ij}^N は大きくなる。一方、競合他社から攻撃が行われる場合、Tripadvisor において低評価のレビューが相対的に多く投稿されることになる。この場合、 N が 1 や 2 の時に Y_{ij}^N が大きくなる。

モデル

彼らは、Tripadvisor と Expedia のレビューとホテルの属性に関するクロスセクションデータを用い、(1) のプロキシ Y_{ij}^N を、ホテルの属性に回帰することで¹⁵、不正操作を行いやすい属性を調査している。モデルは以下の (2) で表現される。

$$Y_{ij}^N = X_{ij}B_1 + OwnAF_{ij}B_2 + Nei_{ij}B_3 + NeiOwnAF_{ij}B_4 + \sum \gamma_j + \epsilon_{ij} \quad (2)$$

ここで、 X_{ij} はレーティング¹⁶や施設の有無などのホテルの属性である。 $OwnAF_{ij}$ には、ホテルの保有と所属に関する変数を含まれ、ホテルが独立系 (非チェーン) であることを示すダミー変数と、ホテルが複数のホテルを所有するオーナー (マルチユニットオーナー) に所有されているか否かを示すダミー変数である¹⁷。 Nei_{ij} は近隣にホテルがあるか否かを意

¹⁵論文中では差分の差分法 (DID) を用いていると主張されているが、一般的な DID とは異なり、クロスセクションデータを用い得点分布の差をホテルの属性に回帰している。

¹⁶レビューとは異なる、所謂“星”にあたる公式のレーティング。

¹⁷これらは排他的ではない。非チェーン系ホテルだがマルチユニットオーナーに所有されるケースも、チェーン系だが他にホテルを所有しないオーナーに所有されるケースもある。

味するダミー変数、 $NeiOwnAf_{ij}$ は近隣のホテルについてのホテルの保有と所属に関する変数であり、非チェーンか否か、マルチユニットオーナーに所有されている否かを示すダミー変数である。 γ_j は地域の固定効果であり、 ϵ_{ij} は誤差項である。

主な関心の対象は、 $OwnAF_{ij}$ や $NeiOwnAf_{ij}$ といった変数であり、これらはレビューの不正のインセンティブに関わってくる。例えば、マルチユニットオーナーが所有するホテルの場合、不正操作が露呈した場合の風評へのダメージは、他に所有するホテルに波及するため、フェイクレビューのコストが大きい。一方で、非チェーン系のホテルは、ブランドイメージの棄損を恐れる必要がないために、フェイクレビューのコストが小さい。また、競合他社が同じ地域に存在するホテルは、競合他社フェイクレビューでその競合相手を攻撃することで、自社の需要を増大させることができる。

推定結果

低評価のフェイクレビューによる攻撃のプロキシとして、1点と2点の低評価のレビューの割合の差を被説明変数とした場合 ($Y_{ij}^N |_{N=\{1,2\}}$) の推定の結果、近隣に他のホテルがあるホテルは有意に Y_{ij}^N が約 3% ポイント分増加する。この近隣ホテルが非チェーンの独立系ホテルである場合、さらに有意に 1.7% ポイント分大きくなる。ただし、近隣ホテルがマルチユニットオーナーにより所有される場合、2.5% ポイント分少なくなる。これは、近隣地域に競合相手がいる場合、攻撃的なフェイクレビューを投稿しやすい可能性を意味する。加えて、競合相手が非チェーンの独立系ホテルだと攻撃が激化するが、競合ホテルがマルチユニットオーナー所有のものだと攻撃が緩和される。

次にフェイクレビューによる高評価の偽装について、5点の高評価レビューの割合の差 ($Y_{ij}^N |_{N=5}$) を被説明変数とすると、ホテルが独立系の場合、 Y_{ij}^N が有意に 2.4% ポイント分増加する。マルチユニットオーナーにより所有されるホテルの場合は、有意に 3.1% ポイント分少なくなる。これは、独立系ホテルほどフェイクレビューにより自社の評価を高く装う傾向を示している。逆にマルチユニットオーナーは自社のレビューについて不正に操作しにくい傾向がみられる。他方で、低評価のケースとは対照的に近隣のホテルの存在は有意な影響を与えているとは言えない結果になった。自社への正のフェイクレビューは、競合他社の存在に関係なく行われている可能性がいえる。

以上の結果からは、ホテルを一つしか持たない非チェーンのホテルほど、フェイクレビューにより、他社を攻撃しやすく、自社の評価を高く装うことが伺える。他にホテルを保有しておらず、チェーンに所属していないため、ブランドイメージを棄損しにくく、フェ

イクレビューのコストが低い。これは、経済的インセンティブと整合的であるといえる。

Mayzlin et al. (2014) の結果は、レビューの不正操作がもたらす被害に関して肝要となる企業が供給する財の品質¹⁸については直接的なエビデンスを示さない。ただし、非チェーンかつ個人経営のホテルは、必ずしも質が低いとはいえないものの、非ブランドのホテルと解釈可能である。このことは、近年の Amazon におけるレビューの不正操作について、非ブランド系や、マーケットプレイスで販売される商品に対しフェイクレビューが投稿される可能性が高いことを示唆する。

2.3.2 Luca and Zervas (2016)

Luca and Zervas (2016) は、米国のレストランレビューサイト Yelp に 2004 年から 2012 年にかけて投稿されたレビューを対象に、パネルデータを構築し、レビューの不正操作がどのような背景で行われているかについて分析している。パネルデータを用いることで、Mayzlin et al. (2014) と比べ、レビューの時系列に沿った変化を観察することができているといえる。しかしながら、同様に、レビューがフェイクか否かを判別できない問題を抱えている。彼らは異なるアプローチでこの問題に対処しており、レビューが Yelp にフィルタリングされたか否かをフェイクのプロキシに利用する。

プロキシ

Yelp がフィルタリングしたレビューを、フェイクレビューのプロキシとして扱う場合、フィルタリングアルゴリズムを分析しているという懸念が指摘できる。ただし、Yelp によるおとり捜査を用いた調査結果は、実際にフェイクレビューを利用している企業のレビューは高い確率でフィルタリングされていることを示す。具体的には、不正操作を行っていると判断された企業のレビューのフィルタリングされる割合は 79% であり、ボストンのレストランの平均である 19% と比べて極めて大きい。そのため、フィルタリングされたか否かをフェイクのプロキシとして用いる妥当性は担保されているといえる。

まず、フィルタリングの傾向を把握するために、線形確率モデルにより推定を行って

¹⁸ホテルのレーティングはコントロール変数として用いられているものの、レーティングが高いほど 5 点の高評価レビューの割合の差は有意に低くなる。また、レストランやコンベンションセンターのような施設があるほど、同じく高評価の割合の差を減少させる。レーティングが、得点分布の差に影響を与える観察されない要素と相関しない場合、質の高いホテルほど、自社を高く評価されているように装うレビューの不正操作を行っていく傾向がいえる。

る。これは以下 (3) のようなモデルとなる。

$$Fliterd_{ik} = b_i + z'_{ik}\beta + \epsilon_{ik} \quad (3)$$

ここで、 i はレストラン、 k はレビューを示す。 z_{ik} はレビューの属性、 b_i はレストランの固定効果となる。 $Fliterd_{ik}$ はレビューが削除された場合 1 となるダミー変数である。

推定の結果、*5 や *1 のレビューは *3 のレビューと比べ有意に約 3% ポイント分フィルタリングされやすい傾向が示された。レーティングを操作するには中程度の評価を行う意味が薄いことと整合的である。また、長いレビューや、他に多くのレビューを投稿しているユーザーによるレビューは有意に削除されにくい傾向がみられた。

モデル

メインの分析にあたっては、フィルタリングされた高評価レビューや低評価レビューの投稿数をプロキシとして用いる。これを被説明変数として、レビューの不正操作を行うインセンティブに関わる変数に対して、どのように反応するかを、パネルデータを用いた固定効果モデルにより推定している。この際、フィルタリングのプロセスをモデル化し、そこから誘導型モデルを導くことで、プロキシを用いた分析を可能としている。これは以下のようなになる。

t 期のレストラン i に対して投稿されるフェイクレビューの本数 f_{it}^* を以下のように仮定する。

$$f_{it}^* = x'_{ij}\beta + b_i + \mu_t + \epsilon_{it} \quad (4)$$

x'_{ij} は時間で変動するレビューの不正操作のインセンティブに関わる変数であり、 $t-1$ 期の得点分布等や、競合レストランの出現といった変数が用いられる。 i はレストランの固定効果であり、 μ_t は t 期の固定効果、 ϵ_{it} は誤差項となる。 f_{it}^* は観察できない潜在変数となり、観察できるのは各レビュー k のフィルタリングの有無となる。これは (5) となる。

$$f_{ikt} = \alpha_0(1 - f_{ikt}^*) + (\alpha_0 + \alpha_1)f_{ikt}^* + u_{itk} \quad (5)$$

f_{ikt} はレビュー k がフィルタリングされた場合 1 となる変数であり、 f_{ikt}^* はレビュー k がフェイクの場合 1 となる観察できない潜在変数である。 u_{itk} は誤差項となる。ここで、 α_0 はレビューがフェイクでないのにフィルタリングしてしまう偽陽性率、 $\alpha_0 + \alpha_1$ はレビューがフェイクであり実際にフィルタリングする真陽性率となる。これらについて、 $\alpha_0 \in [0, 1]$

と、 $\alpha_1 \in (0, 1 - \alpha_0]$ を仮定する。これは、真陽性率が偽陽性より大きいことを意味する。この仮定は、先述した Yelp の調査結果と整合的である。

f_{ikt} の和をとることで、フィルタリングされたレビューの数 f_{it} となる。これは以下の (6) となる。

$$\begin{aligned} f_{it} &\equiv \sum_k f_{itk} = \sum_k [\alpha_0(1 - f_{itk}^*) + (\alpha_0 + \alpha_1)f_{itk}^* + u_{itk}] \\ &= \alpha_0 n_{it} + \alpha_1 f_{it}^* + u_{it} \end{aligned} \quad (6)$$

ここで、 n_{it} は i の t 期のレビュー投稿数、 $u_{it} = \sum_k u_{ikt}$ 、 $f_{it}^* = \sum_k f_{ikt}^*$ となる。(4) を代入することで、以下の (7) が得られる。

$$f_{it} = \alpha_0 n_{it} + \alpha_1 (x'_{it} \beta + b_i + \mu_t + \epsilon_{it}) + u_{it} \quad (7)$$

焦点となるのは、レビューの不正操作のインセンティブに関わる変数である x'_{it} である。(7) から、インセンティブに関わる 4 のパラメータ β は直接推定できないものの、誘導系パラメータ $\alpha_1 \beta$ を推定することができる。 α_1 は正のため、 β の符号については把握することが可能となる。

推定にあたっては、想定される内生性が 2 点残る。第一に、フェイクレビューの投稿に係る誤差項である ϵ_{it} と x_{it} の相関である。これについては、レストラン i と時期 t の固定効果 b_i と μ_t を説明変数に含めることで、レストランや時期に特有なショックをコントロールすることができる。

第二の内生性として、フィルタリングプロセスの誤差項である u_{it} と x_{it} の相関が考えられる。これは、レビューのフィルタリングのされやすさに関する観察されない属性と、 x_{it} の相関となる。これに対処すべく、 u_{itk} を以下の (8) ように定式化する。

$$u_{itk} = z'_{ikt} \gamma + \tilde{u}_{ikt} \quad (8)$$

ここで、 z'_{ikt} はレビューのフィルタリングされやすさに係る属性であり、 \tilde{u}_{ikt} は独立な誤差項である。(8) を代入して、以下の (9) が得られる。

$$f_{it} = \alpha_0 n_{it} + \alpha_1 (x'_{it} \beta + b_i + \mu_t + \epsilon_{it}) + \sum_k z'_{ikt} \gamma + u_{it} \quad (9)$$

(9) は、(7) にフィルタリングに係るレビューの属性の和を加えた形となる。 z'_{ikt} に用いる具体的な変数は、(3) の推定結果から、レビューの長さや、レビュアーの他のレビューの数などを用いる。

対象としては Mayzlin et al. (2014) と同様に、自社の評価を高く装うための高評価のフェイクレビューと、他社を攻撃するための低評価のフェイクレビューの両方を扱う。前者については、フィルタリングされた星 5 レビューの投稿数を被説明変数として設定し、後者については、フィルタリングされた星 1 レビューの投稿数を被説明変数とする。

推定結果

フィルタリングされた *5 レビューの投稿数を被説明変数とした場合、前期の *1 や 2 の低評価のレビューの投稿数は、有意に正の影響を与える。逆に、前期の星 4 や 5 の低評価のレビューの投稿数は、有意に負の影響を与える。この結果は、フェイクレビューと思わしき高評価のレビューが、レストランの評価が低くなると増加し、高くなると減少することを意味する。自社の評価を上げるというインセンティブに沿ってレビューの不正操作が行われていることがうかがえる。

また、前期までに投稿された合計レビュー数は、有意に負の影響を与えている。これは、レビュー数が増えるほど、フィルタリングされた高評価レビューが減少することを意味する。これも、レビューの全体数が増加すると、レーティングを操作するのに必要なフェイクレビューの数が増加し、追加的なフェイクレビューの効果が薄れることから、経済的インセンティブと整合的な結果といえる。

Mayzlin et al. (2014) と同様、レストランがチェーン店¹⁹の場合、有意にフィルタリングされた高評価レビューが減少する。チェーン店はフェイクのコストが大きいことと整合的である。加えて、同じ地域の競合レストランの存在は、有意な影響をあたえているとはいえない結果になっており、この点についても同様である。自社の高評価を装うようなフェイクレビューは、競合他社と関係なく行われている可能性が示されている。

フィルタリングされた *1 レビューの投稿数を被説明変数とする場合は、前期のレビューの投稿数は、いずれの点についても有意な影響を与えているとはいえない結果になっている。時系列に沿った点数の変化は、攻撃的なフェイクレビューにインセンティブを与えない傾向がうかがえる。一方で、前期のレビューの総数は有意に負の影響をもたらす。高評価のフィルタリングされたレビューを被説明変数としたケースと同様に、レビューの全体数が増加すると追加的なフェイクレビューの効果が薄れることから、経済的インセンティブと整合的な結果といえる。

¹⁹これはチェーン店を示すダミーを用いて推定を行っている。店舗の固定効果をモデルに組み込んでいた下では、多重共線性が発生し推定が行えないため、チェーン店の効果を計る際には、店舗の固定効果を外したランダムエフェクトモデルにより推定を行っている。

他方、近隣の競合店は有意な影響を与える。近隣に同じ種類の料理を出す独立系のレストランが存在する場合、有意にフィルタリングされた低評価レビューが増加する。逆に、同じ料理を出すレストランでも、チェーン店の存在は、フィルタリングされた低評価レビューを減少させる。これらは、高評価レビューを被説明変数とする場合とは対照的ではあるものの、Mayzlin et al. (2014) と同様に、独立系の競合他社からの攻撃がなされていることが伺える結果になっている。また、フェイクレビューのコストが高いチェーンの場合は攻撃的なレビューが減少する点も共通している。

以上の Luca and Zervas (2016) の導いた結果からは、Mayzlin et al. (2014) と共通した結果がみてとれる。独立系の競合店舗ほどレビューの不正行為を行いやすく、これらが近隣に存在する場合は低評価のフェイクレビューにより攻撃を受けやすい。これらの点に関しては、Mayzlin et al. (2014) と同様に、企業が供給する財の品質に関連したエビデンスが直接的には示されていない。一方で、特に正のフェイクレビューについて、時系列に沿った得点分布の変化に、自社の評価を高くするインセンティブに沿う形で反応する。このことから、質の低い財を供給する企業ほどレビューの不正行為に関わりやすいことが示唆される。

2.3.3 He et al. (2022b)

He et al. (2022b) は、近年問題となっている Amazon におけるレビューの不正操作を対象とする。彼らは、米 Amazon(Ammazon.com) から取得したパネルデータの分析を通じ、レビューの不正操作について、その主体だけでなく被害についてもある程度のレベルで明らかにしている。最大の特徴は、Mayzlin et al. (2014) や Luca and Zervas (2016) とは異なり、フェイクレビューについてある程度判別を可能としている点である。

フェイクの判別

Amazon.com におけるフェイクレビューは、Facebook におけるフェイクレビューを募集するコミュニティで行われる。この Facebook のコミュニティにおいて、レビューの不正行為を行う商品の販売者は、商品代金のキャッシュバックや金銭と引き換えに、消費者に自社製品を購入し高評価のレビューを書くように依頼する。He et al. (2022b) は、リサーチアシスタントを用い、この Facebook におけるフェイクレビューを依頼するコミュニティへの投稿を調査することで、フェイクレビューの募集が行われている商品と、フェイクレビューの募集が開始された時期を把握している²⁰。

²⁰フェイクレビューの募集を行っている商品と時期は把握しているが、その商品に投稿される個別のレビューがフェイクか否かは判別できていない。

この商品レベルでのフェイクレビューの把握により、レビューの不正操作を行う企業の特徴のより正確な推定が可能となっているだけでなく、フェイクレビューの募集前後の時系列に沿った商品の売上などの変化をみることができる。

データ

まず、2019年10月から2020年6月にかけて Facebook からデータを収集し、おおよそ1500のフェイクレビューを募集した商品(フェイクレビュー商品²¹)を特定している。さらに、同期間に、Amazonの同じカテゴリにおける商品検索ページにおいて、フェイクレビュー商品と同じページにある商品について、レーティングや価格などの属性を日次で取得する。加えて、2020年8月から2021年1月にかけて、競合商品の中から選ばれた約2700商品とフェイクレビュー商品について、レーティング等を日次で、詳細なレビューデータを月に二回のペースで取得する

フェイクレビュー商品の特徴

こうしたフェイクレビュー商品について、そうでない通常の競合商品と比べ、どのような傾向があるか、記述統計を示している。競合商品の商品年齢²²は約758日なのに対し、フェイクレビュー商品の商品年齢は、平均約230日であり、かなり若い商品となっている。投稿されているレビューの数についても、こうした商品年齢の差に応じて、前者が平均約450件であるのに対し、後者は平均約183件となっている。また、価格は競合商品が平均約45ドルであるのに対し、フェイクレビュー商品は33.4ドルと安い。フェイクレビュー商品は相対的に新しく参入した、安価な商品である傾向がうかがえる。ただし、新商品とは言い難い水準であり、フェイクレビューを販売から1か月以内に行っている商品は全体の1割に満たない。

レビューのレーティングや、セールスランク、検索順位などについては、フェイクレビュー商品が競合少雨品を上回る傾向にある。平均的なレーティングは、競合商品が4.2点であるのに対し、フェイクレビュー商品は4.4点となっている。セールスランクは、前者が約73292位なのに対し、後者は約90000位となっている。検索順位についても、前者が約21位、後者が約28位となっており、全体的にフェイクレビュー商品が売上や評価の面では相対的に高い成績を残している。

このような商品の属性に加え、フェイクレビュー商品の販売者について²³も、記述統計が

²¹論文中では、focal product とされる。

²²発売からの経過週数となる。

²³これは競合商品の販売者と比較されず、フェイクレビュー商品の販売者だけに絞られている。

示されており、これらの 84% が中国企業となっている。これは、後述する、本稿における調査結果と整合的である。また、他に販売する商品の価格やレビューの数などは、フェイクレビュー商品と近い値となっている。

Amazon 側の対応

He et al. (2022b) は、フェイクレビューの削除状況についても、貴重な知見を提供している。Amazon は不正と思わしきレビューの削除を行うが、通常の商品のレビューは 23% 程度しか削除されないのに対し、フェイクレビュー商品のレビューが後に削除される確率は 43% と高い削除率を示した。これは、Amazon のフェイクレビュー検知がある程度効果的に働いていることを意味する。

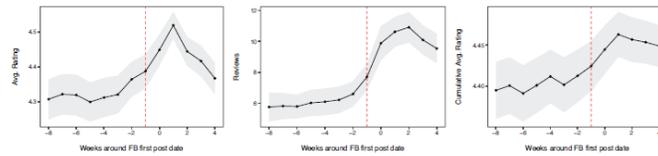
こうして削除されたレビューは、削除されていないレビューと比べ、平均的に高い評価をもつ。これは、削除されたレビューのほとんどが $\star 5$ のレビューであることによる。また、文章が長く、タイトルが短く、写真が添付されている傾向にある。Luca and Zervas (2016) における Yelp のフィルタリングでは、文章が長いレビューほど削除されやすいことが示されており、対照的な結果といえる。直観的には文章が長いレビューや写真つきのレビューはフェイクである可能性が低いと考えられ、フェイクレビューが巧妙化しており、それに Amazon 側も対応している可能性が示唆される。

一方で、削除されるタイミングからは、Amazon の対処が後手に回っていることが分かる。削除されたレビューが削除されるまでの日数は、投稿されてから平均 100 日、中央値 53 日となっている。

フェイクレビュー募集後の変化

レビューの不正操作の影響を推定するにあたり、まず、前後比較による大まかな把握を行っている。具体的には、フェイクレビュー商品について、フェイクレビューの募集の前と後の商品のセールスランクやレーティングの変化をみる。まず、レビューとレーティングについて、これを図示したのが、図 (1) である。横軸がフェイクレビューの募集開始した週を 0 とした週であり、左図は縦軸が期間中に投稿されたレビューの平均点としたもの、中央図は投稿されたレビュー数を縦軸としたもの、右図は縦軸をレーティングとしたものである。当初、平均して $\star 4.3$ だったレビューの評価が、フェイクレビューの少し前から上昇傾向を示し、最大で平均 $\star 4.5$ になる。投稿されたレビューの数も、同様の傾向を示し、レビューの数は、平均約 6 から、最大で約 12 になっている。レーティングは相対的にゆるやかに上昇する。

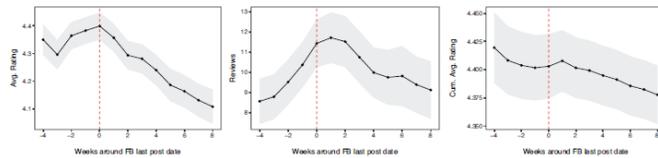
Figure 4. (Color online) Seven-Day Average Ratings, Seven-Day Average Number of Reviews, and Cumulative Average Ratings Before and After Fake Reviews Recruiting Begins



Note. The red dashed line indicates the last week of data before we observe Facebook fake review recruiting.

図 1: フェイクレビュー募集開始前後のレビューの変化 (He et al. (2022b), Figure 4.)

Figure 8. (Color online) Seven-Day Average of Average Ratings, Number of Reviews, and Average Share of One-Star Reviews Before and After Fake Review Recruiting Stops



Note. The red dashed line indicates the last week of data in which we observe Facebook fake review recruiting.

図 2: フェイクレビュー募集終了前後のレビューの変化 (He et al. (2022b), Figure 8.)

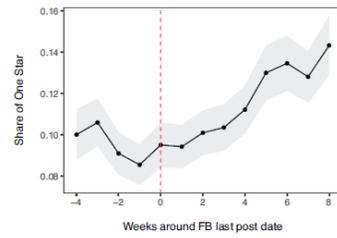
図 (2) は、フェイクレビュー募集後について、横軸をフェイクレビューの募集終了した週を 0 とした週を表す。縦軸については、図 (1) と同様である。いずれも、フェイクレビューの募集が終わると急激に減少する。フェイクレビューにより一時的に高評価に装われていたものが、実態が明らかになるにつれ評価を落としていることが示唆される。

特に、レビュー募集終了後に、レーティングやレビューの平均点が減少することから、低評価のレビューが増加していることが伺える。低評価のレビューは、望まぬ購入をした消費者と想定されるため、被害のプロキシとして用いることができる。 $\star 1$ のレビューの割合を縦軸にして図示したものが、以下の図 3 となる。フェイクレビューの募集が終わってから、 $\star 1$ レビューの割合は、最低で約 8% 程度だったものが最大で約 14% と、大きく増加する。このことから、少なくない数の消費者が実際にフェイクレビューに欺かれ、被害が生じていることが伺える。

セールスランクや推定された売上などについて、同様の動向を図示したのが、図 (4) と図 (5) である。左図は、縦軸がセールスランクの対数、中央の図の縦軸が売上量²⁴、右図の縦軸が検索順位となっている。フェイクレビューの募集が始まるのは、セールスランクや検索順位が落ちているタイミングとなり、募集により大幅に順位を改善させ、売上を伸ばしている。しかしながらフェイクレビューの募集が終わると、セールスランクと売上は大幅

²⁴厳密な売上ではなく、Amazon.com における在庫の変動から推定されたものとなる。

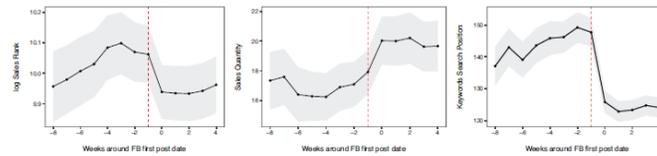
Figure 14. (Color online) Seven-Day Average Share of One-Star Reviews Before and After Fake Review Recruiting Stops



Note. The red dashed line indicates the last time we observe Facebook fake review recruiting.

図 3: フェイクレビュー募集終了前後の★1 レビュー割合の変化 He et al. (2022b), Figure 14.)

Figure 5. (Color online) Seven-Day Average Sales Rank Before and After Fake Review Recruiting Begins (Left), Sales in Units (Center), and Keyword Search Position (Right) Before and After Fake Review Recruiting Begins



Note. The red dashed line indicates the last week of data before we observe Facebook fake review recruiting.

図 4: フェイクレビュー募集開始前後の売上の変化 (He et al. (2022b), Figure 5.)

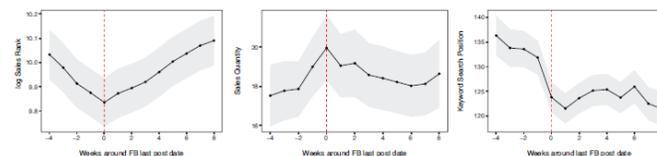
に悪化する。検索順位は大きく反転せず、セールスランクほど大きく変化しない。フェイクレビュー自体が売上を伸ばす働きを持つ²⁵ため、レビューが操作された影響と識別できないものの、フェイクレビューにより、一時的に売上が上昇していることが分かる。

フェイクレビューの因果効果

フェイクレビューの投稿される時期は、商品の固定効果をコントロールしたうえで、他の観察されないショックと相関する可能性が高い。また、その期間に価格が低下したり、

²⁵消費者に商品を購入させたうえでレビューを投稿させるプロセスを踏む。

Figure 9. (Color online) Seven-Day Average Sales Rank, Sales in Units, and Keyword Rank Before and After Fake Review Recruiting Stops



Note. The red dashed line indicates the last week of data in which we observe Facebook fake review recruiting.

図 5: フェイクレビュー募集終了前後の売上の変化 (He et al. (2022b), Figure 9.)

プロモーションが行われる可能性もある。

こうした内生性の問題に対処すべく、He et al. (2022b) は自然実験的な状況を利用している。Amazon.com はフェイクレビューと思わしきレビューの削除を行うが、分析期間中のある一時期において削除されたレビューが極端に多い。この大量削除が予想されていなかった場合、この時期にフェイクレビューを募集した商品は、フェイクレビューにより高評価を水増ししにくい。

そこで、大量削除の時期にフェイクレビューを募集した商品をコントロールグループとして扱い、他の時期にフェイクレビューを募集した商品をトリートメントとして扱う。これらのアウトカムの変化を比較することで、差分の差分法 (DID) を用いることができる。モデルは以下の (10) となる。

$$y_{it} = Treated_i + \beta_1 After_{it} + \beta_2 Treated_i \times After_i + \alpha_i + \tau_t + X'_{it}\gamma + \epsilon_{it} \quad (10)$$

ここで、 t 期の商品 i に対し、 y_{it} がアウトカム、 $After_{it}$ はフェイクレビューの募集開始後を示す。 α_i と τ_t は i と t の固定効果を示す。 X_{it} は時間で変動する商品の属性となる。

関心の対象は $After_{it}$ の係数である β_1 と $Treated_i \times After_i + \alpha_i$ の係数である β_2 である。 β_1 はフェイクレビューを募集することによる効果で、 β_2 は DID 推定量にフェイクレビューによりレビューが操作されたことによる効果といえる。

まず、累積レビュー数の対数を被説明変数とした推定では、 β_2 は有意に正、 β_1 は 0 に近く有意とはいえない結果となり、トリートメントでのみ有意にレビューが増加しているといえる。フェイクレビューの大量削除により、コントロールではレビューが増加していない一方で、トリートメントではフェイクレビューが投稿されていることが伺える。

セールスランクの対数を被説明変数とした場合、 β_1 は有意に正、 β_2 は有意に負となっており、 $\beta_1 + \beta_2$ は負となる。フェイクレビューの募集によりコントロールはセールスランクを落とすものの、トリートメントはセールスランクを上昇させていることがわかる。また、DID 推定量である β_2 が有意に負であることから、フェイクレビューの募集が全体としてセールスランクを改善する因果効果が伺える。

He et al. (2022b) が示した結果は、レビューの不正行為を行う企業がどんなものかについて、Mayzlin et al. (2014) や Luca and Zervas (2016) と比べ、より詳細で直接的な結果を示している。特に、フェイクレビューの募集が終わったのちに、フェイクレビュー商品が評価を落とし低評価のレビューが増加していることから、低品質な商品が高く評価されているように装うことが目的であると考えられる。さらに、フェイクレビューがもたらす影響

について限定的ながらもエビデンスを示している点でも差別化され、フェイクレビューが実際に被害を生じさせていること、売上を増加させていることを示している。

2.4 実験データを用いた実証研究

近年では、フェイクレビューについての実験を行い、その影響や頑健なレビューシステムを模索する例 (Ananthakrishnan et al., 2020; Azimi et al., 2022; Akesson et al., 2023) がある。

Ananthakrishnan et al. (2020) は、レストランのレビューサイトを模した実験サイトで、5つのレビューシステムのパフォーマンスについて検証している。彼らは、フェイクだと判断されたレビューを削除するよりも、それが怪しいレビューであることを提示した上で残すようなシステムの方が、消費者のプラットフォームへの信頼を高めることができることを示している。Azimi et al. (2022) は、既存のフェイクレビュー²⁶を被験者に見せ、レビューがフェイクか否かを答えさせる実験を通じ、消費者がどんなレビューの特徴からフェイクと判断するかを分析している。Akesson et al. (2023) は、ECサイトを模した web ページを用いた実験により、フェイクレビューがもたらす厚生損失が消費額の約 10% に及ぶことや、プラットフォーム側の教育的介入がこの厚生損失を約半数に減少させることを示している。

2.4.1 Akesson et al. (2023)

Akesson et al. (2023) は、Amazon を模した実験サイトで実際に商品を選択させる実験を行い、フェイクレビューの下での被験者の選択行動を観察することで、レビューの不正操作が消費者に与える影響について分析している。さらに、教育的介入を行った場合に、被害をどれだけ抑制できるのかについて検証している。これらは観察データを用いる場合、分析が困難な対象であり、彼らの研究はこのギャップを埋めるものといえる。

実験設計

彼らは、英国で 10000 人の成人を被験者として募集し、Amazon を模した実験サイトにおいて実際に商品を選択させる実験を行った。ここでは、ヘッドホン、車載カメラ、コードレス掃除機の 3 つの商品カテゴリのうちからいずれかを選び、さらにその商品カテゴリの中で 5 つの商品から 1 つを選択する。彼らは抽選に当選した場合、その選択した商品を受け取ることができる。これらの商品は、1 つが外部機関 Which?²⁷によって認定された優秀な

²⁶(Ott et al., 2011, 2013) のデータセットから選ばれたレビュー。

²⁷イギリスの消費者団体である、Consumers' Association により運営されるブランドであり、消費者保護のために、商品をテストする。

商品 (Best Buy)、1 つが買うべきではないと認定された商品 (Don't Buy) となる。実験サイトでは、商品の価格²⁸と説明のほかに、商品についてのテキスト付きレビューが表示され、レーティングとレビュー得点の分布が表示される。

被験者は、商品の選択において、真のレビューのみが表示されるコントロールグループ (グループ 1) と、フェイクレビューについての介入を受ける 5 つのトリートメントグループ (グループ 25)、合計 6 のグループにランダムに振り分けられる。これらのグループと介入の関係を示したものが表 2 である

表 2: Akesson et al. (2023) での介入^a

	G1	G2	G3	G4	G5	G6
インフレしたレーティング分布		✓	✓	✓	✓	✓
フェイクレビューのテキスト			✓		✓	✓
より疑わしいフェイクレビューテキスト				✓		
プラットフォームの推奨マーク					✓	✓
警告バナー						✓

^a Akesson et al. (2023) より筆者が作成

グループ 1 では、Amazon に実際に投稿された本物と思われるレビューと、実際のレーティングが表示される。グループ 2 からグループ 5 までは、フェイクレビューの存在を再現した介入が行われ、どのグループにおいても、Don't Buy 商品に、フェイクレビューで操作されたレーティングを模した、高得点のレーティングと *5 が多い極端な分布が表示される。このとき Don't Buy 商品のレーティングは平均して 1.46 ポイント分上昇する。

さらに、グループ 3 と 4 では、グループ 2 の処置に加え、レーティングだけでなくレビューについてもフェイクと疑わしいものが表示される。グループ 3 では Don't Buy 商品における否定的なレビューを、反復的なフレーズや誇張的な表現が用いられたテキストなど、フェイクレビューの特徴をもつ高評価のレビューに置き換える。グループ 4 では、金銭を提供されたことを認める内容など、更にフェイクとして疑わしい特徴があるテキストのレビューが表示される。

グループ 5 と 6 では、グループ 3 の処置に加え、フェイクレビューの下での教育的介入が行われる。グループ 5 では Amazon における推奨商品のマークである Amazon's choice を再現したマークが特定の商品に表示され、グループ 6 ではこの推奨マークに加え、実験サイトのページ上部に、フェイクレビューの存在を警告するメッセージが表示される。ポイ

²⁸価格はカテゴリごとに固定となっている。

WTP 推定のための付随実験

この主実験に追加で、1000人の成人を被験者として募集し、商品へのWTPを申請させる付随実験についても行っている。この実験の結果を利用することで、商品へのWTPを推定し、分析のアウトカムとして用いる。これは、主実験で提示された商品について、商品の属性やレーティング、Whichでの評価を見せたうえで、各商品に対して支払い意思額(WTP)を尋ねるものである。

この実験は、被験者がWTPを正直に申告するように、BDM法(Becker et al., 1964)を用いる。この際、BDM法での商品の贈呈は被験者全員に行われるわけではなく、抽選の当選者に対してのみ、300ポンドの贈呈のうえで行われる。これは以下のようなプロセスである。まず、当選した被験者がWTPを申請した商品から1つの商品がランダムに選ばれ、ランダムな価格が設定される。当選者の申請したWTPがこの価格以上である場合、その商品が贈呈され、更に300ポンドと価格の差額が賞金として贈呈される。申請したWTPがこの価格未満であるときは、300ポンドの賞金のみが贈呈される。実験の事前にこのBDM法のプロセスと、WTPを正直に申告することが合理的であることを伝えている。

この方法で申告されたWTPは、フェイクレビューがなく、正しい情報が提示された下でのWTPといえる。このWTPと、付随実験で申請した被験者の属性、さらに主実験の被験者の属性を用いることで、主実験での被験者についても商品のWTP²⁹を予測することが可能となる。この予測されたWTPがアウトカムとして用いられる。

フェイクレビューの影響

各種アウトカムをトリートメントグループのダミーに回帰することで、フェイクレビューの下において被験者がどのような影響を受けるか明らかにする。ここで、Don't BuyやBest Buy商品を選ぶか否かが商品の質についてのアウトカム³⁰となり、選択した商品へのWTPが厚生についてのアウトカムとなる。

コントロールにおけるDon't Buy商品を選ぶ確率は、約10%ポイント、WTPは約57.1ポンドとなっている。一方、グループ2はDon't Buy商品を選ぶ確率が有意に約5.8%ポイント増加し、選択した商品のWTPが有意に2.9ポンド減少する。Best Buy商品を選ぶ確率は有意な影響を受けているとはいえない。レーティングの操作の下では、質が低く、本来低いWTPしかもたないの商品に誘導され、消費者余剰が減少していることを示す結果

²⁹WTPは予測に用いる変数により2種類の予測値があり、本稿では被験者の年齢から予測されたWTPについての結果を紹介する。どちらのWTPについても結果については大きく変化しない。

³⁰線形確率モデルとなる。

といえ、トリートメントと比べて、約 5.1% の厚生損失が生じている。

更に、グループ 3 については、Don't Buy 商品を選ぶ確率が有意に約 12.6% ポイント増加し、Best Buy 商品を選ぶ確率が有意に約 5.2% ポイント減少する。さらに選択した商品の WTP が有意に 6.6 ポンド減少する。レーティングだけでなく、レビューにフェイクが混在する状況下では、より質の商品に誘導され、より大きい被害が生じている結果となっている。ここでは、トリートメントと比べ、約 11.7% の厚生損失が生じている。

グループ 4 についても、同様の結果となっており、Don't Buy 商品を選ぶ確率が有意に約 11.0% ポイント増加し、Best Buy 商品を選ぶ確率が有意に約 4.3% ポイント減少する。さらに選択した商品の WTP が有意に 6.6 ポンド減少する。Don't Buy 商品の選択確率や厚生損失について、グループ 3 と比較被害は少ないものの、その差は非常に小さい。顕著な特徴があったとしても、消費者はフェイクレビューをあまり見抜くことができないことが伺える。

グループ 5 については、Don't Buy 商品を選ぶ確率が有意に約 14.3% ポイント増加し、Best Buy 商品を選ぶ確率が有意に約 3.6% ポイント減少する。さらに選択した商品の WTP が有意に 7.2 ポンド減少する。プラットフォームの推奨マークの導入は、むしろ Don't Buy 商品の選択確率を上げ、WTP を減少させる効果となっている。ただし、Best Buy 商品を選ぶ確率については、被害が緩和されている。ここでは、トリートメントと比べ 12.7% の厚生損失が生じている。

教育的介入の効果

グループ 5 と、同様の処置に加えてフェイクレビューについての警告表示を受けたグループ 6 のアウトカムを比較することで、教育的介入の効果がどれだけあるのかを明らかにしている。グループ 6 は、グループ 5 と比べ、Don't Buy 商品を選ぶ確率が有意に約 5.8% ポイント減少し、選択した商品の WTP が有意に 3.0 ポンド増加する。Best Buy 商品を選ぶ確率は有意な影響を受けているとはいえない。質が低い商品に誘導されにくくなり、消費者余剰が増加するといえる結果であり、教育的介入はフェイクレビューの被害を緩和できていると判断できる。これは、フェイクレビューの下で生じる厚生損失について、42.2% 分の被害が減少している。

2.5 その他の関連研究

機械学習の文脈においては、Ott et al. (2011, 2013) など、機械学習モデルによりレビューが否かを判別する研究が数多く行われている。Ott et al. (2011, 2013) はクラウドソーシ

ングを用い執筆させたフェイクレビュー³¹と、レビューサイトにおけるレビューを用いデータセット³²を作成し、レビューがフェイクか否かを判別する機械学習モデルを構築している。近年においては、He et al. (2022a) は、不正を行っている商品を判別したうえで、レビューアのネットワークを把握し、そのネットワークの特徴を用いた機械学習モデルを提案している。これはテキスト情報等からフェイクの判別を行う既存のモデルよりも高い精度を示している。

直接フェイクレビューを扱うわけではないものの、関連性が高い実証研究については、Anderson and Simester (2014) は、アパレル産業のレビューを対象に、実際に商品を購入していない消費者によるレビューについて分析している。これらが、平均的に評価が低く、商品のフィット感や素材感について言及することが少ないいうえに、嘘だと思わしき文章上の特徴を含みやすいことを示されている。Park et al. (2023) はインセンティブレビュー³³がもたらす影響について調査している。彼らは、インセンティブレビューが一般のレビューと比較して商品を高く評価し売上を増加させる傾向を明らかにし、商品の売り手に依頼されるインセンティブレビューよりも、Vine プログラムのようなプラットフォームがレビューアのインセンティブを与えるような仕組みが好ましいことを示している。

2.6 先行研究の課題と本研究の位置づけ

第 1 章で整理した第一のリサーチクエッションにあたる、不正の詳細に関しては、既存の観察データを用いた実証研究がある程度のエビデンスを提供している。しかし、Mayzlin et al. (2014); Luca and Zervas (2016) は、分析対象が 2010 年代前半に集中しており、主にホテルやレストランのような地理的要因が影響する産業に焦点を当てているため、現代のレビューの不正操作の問題に対して適用できるかという外的妥当性に疑問が残る。

近年における、米 Amazon を対象とした He et al. (2022b) は、外的妥当については問題なく、フェイクレビュー商品を判別することに成功している。しかしながら、個別のレビューレベルでフェイクか否かを判別できているわけではない。また、把握されたフェイクレビュー商品は、約 1500 個であり、競合商品 20 万個と比べるとかなり小さい割合となっている。不正を行っているかなりの数の商品が、見落とされている可能性がある。更に、一

³¹ フェイクレビューを書く業務を命じられたことを想定して執筆するよう依頼している。

³² このデータセットは the gold standard dataset として、現在でも様々な研究で利用されている。

³³ かつて Amazon は、ユーザーが利害関係を明示することを条件に、商品の割引や無償提供と引き換えにレビューを投稿することを許可していた。これをインセンティブレビューという。現在では禁止されているものの、Vine プログラムとして、Amazon がレビューアにインセンティブを与えレビューを執筆させるシステムがある。

部のデータについては、フェイクレビュー商品を把握してから取得している関係上、セレクションバイアスが生じている可能性がある。

第二と第三のリサーチクエッションである、レビューの不正操作の影響や、施策や制度設計の評価については、He et al. (2022b) が間接的なエビデンスを示しているものの、観察データを用いた研究には限界がある。この点におけるギャップを埋めるのが、実験データを用いた研究であり、特に Akesson et al. (2023) はフェイクレビューがどれだけ消費者を欺き、どれだけの厚生損失をもたらすかを明らかにしている。

しかしながら、Akesson et al. (2023) は実験設計の面で、いくつかの問題がある。第一に、Akesson et al. (2023) が再現したフェイクレビューの特徴は、現実に即していない可能性がある。彼らがフェイクレビューの特徴として用いるもののいくつかは、He et al. (2022b) や本稿の結果と異なる。第二に、純粋な教育的介入の効果とはいえない結果となっている。彼らは、教育的介入を、フェイクレビューの再現に加えプラットフォームの推奨商品を表示した状況でのみ行っている。第三に、厚生損失の計算に用いた、被験者の商品への WTP が、被験者本人が誘引両立的な選択で行ったものではない。付随実験で得た WTP を用いた推定値となっており、この WTP も表明選好に基づくものであり、厚生損失の値については信頼性に疑問が残る。

現状において、レビューの不正操作に関する実証研究は少数に留まり、三つのリサーチクエスチョンに対するエビデンスの蓄積は十分でない。本稿はこのような研究のギャップを埋め、エビデンスの充実に寄与するものである。

まず、4章から6章については、2021年から2022年の Amazon.co.jp から取得したデータを用い、国内におけるレビューの不正操作についての分析を行う。これは、観察データを用いたフェイクレビューについての実証研究の文脈に置かれる。Mayzlin et al. (2014) と Luca and Zervas (2016) とは異なり、昨今の EC サイトにおける社会問題化したレビューの不正操作を扱っているといえる。一方で、He et al. (2022b) とは、対象としている産業が同じであり、分析対象の期間も近い。

ただし、本研究が対象とするのは日本国内であり、この点で大きく差別化される。対象とした 2021 年から 2022 年における我が国においては、フェイクレビューによるレビューの不正操作は、米国と異なり明確に違法とされていない。また、中国系企業が不正に大きく関与していることが疑われているが、我が国は米国と比べ中国と物理的に距離が近い。これらの違いから、米国とは大きく異なる状況下における、不正操作についての知見を提示する。

また、本稿の手法は、削除されたレビューをフェイクレビューのプロキシとして扱う、

Luca and Zervas (2016) を踏襲したものとなっている。He et al. (2022b) は、不正を行った商品を Facebook において把握しており、本研究はプロキシーを使う点で、不正の把握についての精度では劣っている。しかしながら、He et al. (2022b) の手法は非常にコストが大きく、また、フェイクレビュー募集グループが SNS などで観察可能な国でない限り適用することはできず、不正に関与した商品のカバレッジが十分である保証もない。本研究は、実現可能性の大きい手法を発展させ、用いた例として差別化される。

加えて、本稿では、データの収集方法において He et al. (2022b) と差別化される。He et al. (2022b) では、Facebook でフェイクレビューを募集している商品を特定したのち、Amazon からレビュー等のデータを取得している。データ取得にタイムラグが存在するため、既に削除の対象となったものは取得できていない、サバイバルバイアスが生じている可能性がある。一方、本研究は、1年以上にわたりデータの取得を続け、可能な限りリアルタイムの観測を行っており、ある程度サバイバルバイアスの問題に対処することができている。

次に、7章については、Akesson et al. (2023) と並び、フェイクレビューの影響について実験により明らかにする数少ない研究であり、その点において貢献する。特に、本実験は、商品の表示順や、レビューの両面表示などの、Amazon の各種仕様がフェイクレビューの下でどのように働くかを検証しており、この点でも貴重な知見を提供する。

また、本実験では、Akesson et al. (2023) での実験設計上の問題を解消すべく、実際に Amazon から削除されたレビューを用い、より実際のフェイクレビューの下での状況を再現している。更に、被験者の WTP が誘引両立的な状況で、顕示選好として推定可能な設計になっている³⁴。

³⁴本稿では、WTP の推定は行わない。

第 3 章 Amazon.co.jp とデータ

3.1 はじめに

本稿は、4 章から 7 章のいずれの章についても、Amazon.co.jp におけるレビューの不正操作についての実証分析を扱う。これらはいずれも Amazon から取得したデータを用いる。そこで、本章では、Amazon の仕様とデータ取得の方法について解説を行う。

3.2 Amazon のシステム

マーケットプレイス

Amazon では Amazon 自身が販売を行うだけでなく、他の企業が Amazon において中古も含む商品を販売することのできるマーケットプレイスという仕組みがある。これにより、Amazon は電子商取引のプラットフォームとしても機能している。マーケットプレイスの利用には月額料金ならびに Amazon への手数料がかかるものの、自社で専用のショッピングサイト等を作成・運用する手間を省けるうえ、Amazon を利用する膨大な消費者を活用できる可能性がある。

マーケットプレイスの商品の購入は Amazon のシステム上で行われ、Amazon が販売する商品と同様に行うことができる。ただし、販売は他の企業によって行われるため、返品やクレーム等はそれらの販売者に対して行うことが求められる³⁵。これらの販売者についての消費者からの評価は集計され、他の消費者が参考にできるようになっているほか、住所や問い合わせ電話番号などの情報も公開されている。

ASIN

Amazon においては、商品は ASIN と呼ばれる ID で管理される³⁶。ASIN には、親 ASIN と子 ASIN の二種類が存在する。子 ASIN は、個別の商品単位で割り振られる ID であり、一つの商品に対し一つの子 ASIN が割り当てられる。消費者が実際に選択する商品の単位が子 ASIN といえる。

この際、根本的には同じ商品でもあっても、商品のバリエーションごとに、異なる子 ASIN が割り当てられる。具体的にはサイズや内部仕様、色などの違いに応じて、別の商品として扱われ、別個の子 ASIN をもつことになる。例えば、同じ第四世代の iPad Pro であ

³⁵ これらの一部を Amazon が担うサービスもある。

³⁶ 細かい仕様については、Amazon の API のドキュメントに記載されている。詳細は以下を参照されたい。
<https://webservices.amazon.com/paapi5/documentation/parent-asin.html>

っても、商品カラーや、内部ストレージの容量が異なる場合、異なる子 ASIN が割り振られる。こうした子 ASIN は、消費者側からも商品 URL から確認可能である。

親 ASIN は、抽象的な「商品」に割り振られる。先の ipad の例だと、「第四世代の ipad Pro」に親 ASIN が割り振られる。この親 ASIN は、類似の商品をひとまとめに扱うために用いられ、子 ASIN は、親 ASIN の商品の具体的なバリエーションとして、親 ASIN に紐づけられる。

親 ASIN に紐づけられた商品同士は、商品ページで他のバリエーションがオプションとして表示され、そのオプションについてスムーズに³⁷商品ページに移動できるようになる。具体的には、第四世代の ipad Pro の場合、ストレージが 256GB のバリエーションのページから、1TB や 2TB のバリエーションがオプションとして表示される。

レビュー

これらの商品について、原則³⁸として、カスタマーレビューと呼ばれる、ユーザーからの五段階の評価からなる商品レビューを掲載するシステムが設けられている。これらのレビューは、このレビューは、文章付きのレビューが基本となるが、評価点のみを投稿することも可能となっている。本研究では、Amazon におけるレビューについて、単にレビューと記述する場合、この文章付きのレビューのことを指す。これらのレビューと評価点のみの投稿は集計され、点数の分布と総合的な評価（レーティング）が表示される。レーティングの計算方法は公開されていないが、単純な平均点ではなく、レビューの新しさや、購入の有無を考慮したものとなっている。

レビューには、Amazon における購入の有無やレビューが投稿された日付のほか、他のユーザーからの得票数（「参考になった」数）やレビュアーの名前が記載されている。レビュアーの名前欄をクリックすることで、レビュアーの個別ページにアクセス可能であり、レビュアーのレビューの投稿数や、合計得票数などを知ることが可能である。レビューは個別のレビュー ID が割り当てられ、管理される。また、レビュー ID で構成した URL にアクセスすることで、レビュー単体を閲覧することも可能となっている。

投稿されたレビューは、商品ページで 15 件表示され、「レビューをすべて見る」のクリックにより、レビューページに遷移する。ここでは、1 ページあたり 10 件、最大 10 ページ 100 件³⁹のレビューが表示される。同時に、ページ上部に代表的な肯定的なレビューと代表

³⁷ブラウザ (Google Chrome で確認) 上で表示される URL は変化するものの、履歴ではページの遷移が記録に残らない。

³⁸医薬品は薬事法の関係上レビューが設定されていない。

³⁹2024 年 1 月時点の仕様。本稿の分析期間中は最大 5000 件が閲覧可能だった。

的な否定的な否定的レビューが、別枠で常に表示される (両面表示)。

評価点のみが投稿される場合には、単に点数の分布に集計されるのみとなっている。それゆえ、個々の評価を識別して把握することはできず、他の情報についても得られない。どの時点で評価されたかや、評価者が購入しているか否かを区別することもできない。複数時点での得点分布を観測していれば、差分から評価の時系列に沿った推移を把握することは可能であるものの、購入の有無の分布などについては知りえない仕組みとなっている。

ASIN とレビュー

Amazon におけるレビューは、個別の商品レベルで行われ、子 ASIN に紐づけられる。そして、異なる子 ASIN でも、共通の親 ASIN に属する場合、表示・集計されるレビューを共有する。具体的には、仮に「第四世代の iPad Pro」の親 ASIN に、256GB の内部ストレージのモデルの子 ASIN と 512GB の内部ストレージのモデルの子 ASIN が賦しているとする。この場合、256GB モデルに投稿されたレビューは 512GB モデルのページにも表示され、512GB モデルに投稿されたレビューは 256GB モデルのページにも表示される。レーティングや得点分布についてはレビューと得点のみの投稿の両方を共有し、同じ得点分布とレーティングが表示される。

この親子 ASIN のシステムにより、Amazon は細かい単位で商品を扱いながら、それらの区分に左右されることなく、本質的に同じ商品が同様の評価をされるようなレビューシステムを実現している。ただし、ASIN のシステムが機能するには、親 ASIN に属する商品同士が本質的に同一であることが前提となる。そのため、Amazon はマーケットプレイス出品者に、親 ASIN に異なる複数の商品を登録することを禁止している。

3.3 レビューの不正操作

不正対策

カスタマーレビューは利害関係にない一般消費者の実際の使用感を伝えることが目的であるため、フェイクレビューや、嫌がらせが攻撃が目的であるようなレビューは規約で禁止されており、削除の対象となる。レビューには通報欄があり、消費者の側からの疑わしいレビューに対するフィードバックを受けられるような仕組みになっている。

レビューは削除されると商品ページのレビュー欄から消え、総合点の計算や得点分布から排除される。また、個別のレビューページは消滅⁴⁰する。ただし、Amazon では、レビュ

⁴⁰ステータスコードは 404 となる。

ーを削除しても、特にアナウンスを行わず、削除されたレビューを別個に表示することはしない。そのため、消費者が疑わしいレビューが削除された商品のページを見ても、その商品に投稿されたレビューが削除された過去があるか否かなどについて知ることはできない。

他にも、レビューの投稿にはある程度の制約は課されており、安易な不正行為は行いにくくなっている。例えば、レビューの投稿には、アカウントに一年間で累計 5 千円の購入履歴が必要となっており、大量のアカウントを作成しレビューを投稿するといった不正行為は行いにくくなっている。また、購入していない商品へのレビューは、先述したように購入の有無がレビューに記載されるとともに、投稿数の制限がある。

不正操作の現状

このように、Amazon 側でも対策をある程度行っているものの、未だフェイクレビューの氾濫が社会問題化しており、SNS での募集も続いている。

日本においては、2018 年ごろ⁴¹からフェイクレビューの問題が表面化し始め、2019 年頃には NHK で特集が組まれるようになった。しかしながら、フェイクレビューの実態は未だ不明瞭であり、米国のようにフェイクレビューの投稿に従事する企業が明らかになったわけではなく、メディアによる当事者への取材が行われるレベルに留まっている。

現状、レビューの不正操作については、主に 3 つの類型が確認されている。第一に、最も代表的な、社会問題化しているフェイクレビューによる高評価の水増しがあげられる。これは、ステルスマーケティングの一種であり、商品があたかも高く評価されているように装うものである。本研究では、このタイプのレビューの不正操作について扱う。

これらのフェイクレビューは SNS 上のコミュニティを通じ募集される。SNS 運営や Amazon に対する発覚を防ぐためか、商品 URL などを直接指定せず、画像と検索ワードのみ表示することで間接的に商品を指示し、ユーザーからのレビューの投稿が確認できたら報酬を支払う仕組みになっている。報酬は、商品代の一部のキャッシュバックが行われるケースや、商品代を返金したうえでの報奨金が支払われるケースもある。

第二に、ASIN を悪用した不正操作がある。前述したように、親 ASIN に登録される子 ASIN は、本質的に同一の商品の子 ASIN であることが前提となっている。しかしながら、関係ない商品同士を紐づけることで、実際の評価とは乖離した評価に見せかけることが可

⁴¹Google 検索で期間を年単位で指定し、フェイクレビューの単語で検索を行うと、2017 年に限定した場合は、フェイクレビューに関連するページがヒットしないものの、2018 年に限定すると急にヒット数が増加する(2022 年 10 月確認)。このことから、日本における社会問題としてのフェイクレビューは 2018 年以降の現象と判断できる。



(a) Line におけるフェイクレビュー募集コミュニティ



(b) Facebook における募集の例

図 6: SNS におけるフェイクレビュー募集

能である。例として、レビュー数が多く高評価のモバイルバッテリーと、レビュー数が少なく低評価のシャワーヘッドを同じ親 ASIN に登録するケースを考える。この場合、本来低評価のはずのシャワーヘッドは、モバイルバッテリーのレビューを共有するために、表示されるレビューは高評価なものが多くなり、レーティングや得点分布もシャワーヘッドだけのレビューと比べ高い値を示す。

図 7は、実際に親 ASIN に全く別の商品が共有されている例であり、双眼鏡のレビューページにシャワーヘッドのものが表示されている。こうした類型の不正操作は、既存の研究でとりあげられた例はなく、フェイクレビューに関する消費者のナレッジとして取り上げられることも少ない⁴²。しかしながら、先に挙げた例が実際に観察されており、こうしたレビューシステムの悪用という形でも、レビューの不正操作が行われていることがいえる。

第三に、他の商品を攻撃するためにフェイクレビューが用いられるケースがあげられる。これは Mayzlin et al. (2014) で観察されたケースであり、競合他社の商品に実態と異なる低評価のレビューを投稿することで風評被害を与えるようなものであり、いわゆる「低評価爆撃」に相当する。ただし、この類の不正操作は、競合関係にある商品が多かったり、競合商品へのレビューの投稿数が多い場合、フェイクレビューのコストが非常に大きくなる。

⁴²図 7は、自社製品同士で、レビューの紐づけを悪用したパターンであるが、他社の高評価の商品と ASIN を紐づける不正についても例があり、FTC は多額の罰金を課している。これは、レビューハイジャックと呼称されている。https://www.ftc.gov/news-events/news/press-releases/2023/04/ftc-approves-final-order-against-bountiful-company-first-case-alleging-hijacking-online-product



図 7: 親 ASIN を用いた不正の例

Amazon においては、多くの商品が複数の商品と競合関係にあるため、コスト面で非現実的であり、He et al. (2022b) でも発見されていない。しかしながら、実際にこのタイプのフェイクレビューの攻撃の被害を受けた出品者の例も報告されており、著名な企業が被害を受けた例もある。

不正操作と Amazon の仕様

Amazon の仕様は、時にレビューの不正操作の被害を増幅させる恐れがある。例えば、Amazon の商品検索画面では商品の表示順が「おすすめ」がデフォルトに設定され、レーティングを用いた「標準的なカスタマーレビュー」をオプションとして用いることが可能である。これらの表示順のアルゴリズムは公表されていないものの、高評価なものを上位に表示する場合、フェイクレビューにより高評価に操作された商品も上位に表示されてしまう。

一方で、他の仕様は、不正操作の被害を抑制する可能性がある。代表的な否定的なレビューをとりあげるレビューの両面表示は、フェイクレビューの存在を消費者に認知しやすくしている可能性がある。さらに、レビューの表示順も影響を与える可能性がある。レビューはデフォルトでは「トップレビュー」の順に並んでおり、アルゴリズムは未公表なもの、得票数が多いものが優先して表示されやすいと考えられ、フェイクレビューが投稿されている商品でも真のレビューが多くの投票を集めていれば優先して表示されやすい可能性がある⁴³。

⁴³逆に、不正を行う売り手側が、フェイクレビューの得票数についても操作している場合は、フェイクレビ

3.4 データの取得

本研究では、Amazon から取得したレビューデータや商品のデータを用いる。特に重要になるのは、レビューがフェイクか否かの判別である。根源的な問題として、仮に疑わしいレビューがあったとしても、それがフェイクレビューか否かを判別することができない。

先行研究においては、実際にフェイクレビューを募集した商品を調査した He et al. (2022b) が存するものの、リサーチアシスタントを雇用し、SNS におけるフェイクレビューの募集を調査することは、時間的・金銭的な制約から実現可能性が低い。特に、日本においては、Facebook 以外の SNS の存在感も強く、より多くのコストが予想される⁴⁴。また、仮に SNS の調査を行ったとしても、レビュー単位でフェイクレビューか否かを判別することはできず、フェイクレビューの募集を網羅的に把握できる保証はない。

一方で、プロキシを用いているものの、Luca and Zervas (2016) の手法については、現実的な範囲で我が国においても適用可能であり、Amazon が事後的に削除したレビューは、フェイクレビューである可能性が高いと判断できる。さらに、He et al. (2022b) においては、Amazon.com でフェイクレビューを用いている商品のレビューは削除されやすい調査結果が示されている。そのため、事後的に削除されたレビューは、フェイクレビューのプロキシとしての妥当性が担保されているといえる。

そこで、本稿では、削除されたレビューをフェイクレビューのプロキシとして、プロキシによる分析を行うアプローチをとる。ただし、Luca and Zervas (2016) が分析対象とした Yelp では運営によりフィルタリングされたレビューについて確認することが可能なものの、Amazon においては削除されたレビューが観察できなくなる。そのため、データの取得間隔が長期間に渡る場合、レビューが観察されないまま削除されてしまう可能性がある。具体的には、データを観察していない期間において、レビューが投稿され、その期間中に削除が行われた場合、そのレビューと削除を観察できない。故に、高頻度で商品データを取得する必要がある。

取得プロセス

高頻度でレビューを取得することを前提とした場合、あまりにも多くの商品を取得対象ユーザの影響を受けやすくなるともいえる。

⁴⁴米国では圧倒的に Facebook の利用が多いものの、日本においては Line や Twitter の存在感が強く複数の SNS を調査する必要がある。加えて、特に Line については仕様上データの取得のコストが大きい。SNS の利用状況については以下を参照されたい。<https://www.soumu.go.jp/johotsusintokei/whitepaper/ja/h30/html/nd142210.html>

とすることは、時間的制約から困難である。そこで、本研究では、Amazon の売上上位と考えられる商品を対象とする。具体的には 11 カテゴリにおける、Amazon の売れ筋ランキングに掲載されている商品に加え、検索順位が上位なものを対象とした。

取得プロセスは、以下のように行われる。まず日次で Amazon の売れ筋ランキングならびに検索順位 20 ページ分の商品をチェックし、これらに一度でも入った商品をデータ取得対象⁴⁵に加える。並行して、データ取得対象に含まれている商品のレビューページを随時取得する⁴⁶。

本稿では、2021 年 1 月から 2022 年 4 月⁴⁷までこれらのプロセスを繰り返し、レビューデータとプロダクトデータ⁴⁸を取得した。加えて、2022 年 5 月からセラーのデータを随時取得し、2022 年 12 月に個別のレビューの削除状況⁴⁹を一括で取得した。最終的に、約 3 万 7 千 ASIN コード分の商品に対し、約 160 万のユニークなレビューを取得した。

取得したデータは二つに大分される。第一に、個別のレビューに紐づけられた情報である。これは、先述したような、テキスト付レビューから得られるデータであり、レビューの点数や投稿日時、購入ステータスと得票数に加え、レビューテキストやタイトルといったテキスト情報、ならびに写真の枚数や有無となる。加えて、投稿したユーザーについての得票数や投稿数も含まれる。また、テキストなしの、星のみを合算した評価や、Amazon 側でのレーティングについても取得している。第二に、商品に関するデータである。これは、商品価格や商品の説明文のほか、製造している企業やブランド、ならびに販売を担っているセラーの評価や住所ならびに電話番号といった情報となる。

ASIN の処理上の留意点

ASIN コードの仕様を考慮すると、以下の二点について対処する必要がある。第一に、サンプル内における商品の重複である。商品を ASIN コード単位で扱うと、実質的に同じ商品が複数分析対象として加わることになる。

第二に、ASIN コードの仕組みの悪用に対する懸念がある。フェイクレビューによる不正

⁴⁵ ASIN コード単位。

⁴⁶ ランキングや検索順位については日次で取得するのに対し、レビューは随時取得している。これは具体的にはすべての取得対象商品のレビューを順に取得次第、また取得対象の商品のデータを取得することを繰り返す。

⁴⁷ データの取得プロセス自体は、2022 年 12 月まで行っている。レビューの削除まではタイムラグがあるため、分析で使用するデータはある一時点までに取得したものに限る。

⁴⁸ 一部のデータの取得は 2021 年 9 月からとなっている。

⁴⁹ 本稿ではレビューの取得を製品ページレベルで取得している。時にレビューは削除されていないにもかかわらずレビューページから消える場合がある。そのため、別個に削除状況を取得している。この際、レビューの個別ページが 404 ステータスコードを返した場合に削除とみなす。

と、先述した親 ASIN との紐づけを用いた不正を併用している場合、不正が行われる対象は、ASIN が紐づけられる商品全体であり、個別の ASIN 単位での商品ではない。

それゆえ、分析データを構築するにあたり、商品を ASIN コード単位で扱うのではなく、その紐づけられたバリエーションについても考慮する必要がある。そこで、本研究ではレビューの参照のネットワークを用い、ASIN が紐づけられた商品のグループを作成する。

これは、以下のようなプロセスによる。まず、データ取得期間中に商品 A と商品 B に共通したレビューがある場合、商品 A と商品 B を同じグループとして扱う。さらに、商品 B と C に同じレビューがあった場合 B と C を同じグループとして扱う。B を介して A と B は同じグループだと判断できるため、A と B と C を同じグループとして扱う。このように、レビューが共通する商品同士を同じグループにまとめる処理を繰り返すことで、商品グループを特定する。最終的に約 17600 の商品グループが得られた。本稿では、4 章から 6 章において、商品の単位として ASIN ではなく、この商品グループを用いる。

3.5 記述統計

取得状況

取得対象とした各カテゴリと、カテゴリごとのレビューの取得状況を示したものが、表 3 である。レビューの削除率が最も高いのは、Switch 周辺機器で約 28%、スマートウォッチで約 26% と次ぐ。削除率が低いカテゴリは、デジタルカメラが元も低く 4%、無線 LAN・ネットワーク機器が 6% となっている。広く需要されるデジタルデバイスで削除率が高く、専門性の高いカテゴリで削除率が低い傾向が確認される。

レビューの投稿数の推移

レビュー投稿数の推移を示したものが図 8 となる。左図 (a) は 2010 年以降の各年におけるレビュー投稿数を示したもので、横軸が投稿された年であり、左縦軸は投稿数、右縦軸は削除率となっている。全てのレビューの投稿数が青いバーで、そのうち削除されたものの数がオレンジのバーより示してあり、折れ線は削除率の推移を示す。右図 (b) は、データ取得期間について、月次レベルで同様のグラフを描いたものである。データ取得期間の関係上、投稿されたレビューは 2021 年や 2020 年に集中する。

古い時期に投稿されたレビューは相対的に少ないだけでなく、削除されたレビューの割合が顕著に少ない。古い商品については、疑わしいレビューが投稿されたうえで、観察される前に削除されている可能性が高い。全てのレビューや商品を用いた分析には、サバイバルバイアスが生じる懸念がある。

表 3: カテゴリごとの取得状況

	商品数	レビュー数	削除レビュー数	削除率
スマートウォッチ	4291	90757	24202	0.26
モバイルバッテリー	2892	141616	22772	0.16
マウス	3384	147563	16335	0.11
シェーバー	2960	168833	26500	0.16
swicth 周辺機器	1480	127938	36536	0.28
PS4 周辺機器	1403	75593	13155	0.17
デジタルカメラ	3727	56166	2314	0.04
ディスプレイ	3001	100374	8282	0.08
イヤホン・ヘッドホン	6016	483900	89431	0.18
無線 LAN・ネットワーク機器	2294	141945	9177	0.06
ウェブカメラ	2317	82701	13481	0.16

さらに、一定以上古いレビューについては、レビュー自体が近年とそれと比べ定性的に異なる可能性が指摘できる。Amazon におけるフェイクレビューが問題になり始めた時期は 2018 年頃であるため、過去のレビューについてはそもそもフェイクレビューが少なく、レビューの削除は Amazon の誤検知や、ユーザーによる削除などが主たる原因と考えられる。それゆえ、古い削除されたレビューは、フェイクレビューのプロキシとして働かない可能性が高い。

削除の状況

事後的に削除されたレビューが、削除されるまでどれだけ残っているかについて示したものが、以下の表 9 である。左図 (a) 削除までの週数を横軸にとり、縦軸は度数を意味する。削除されたレビューが最も多く削除されるのは投稿から 1 週間後であり、0 週 (投稿週) がそれに次ぐが、長い期間削除されずに残っているレビューも相当数存在する。右図 (b) は、横軸は同じく削除までの週数をとり、縦軸に、相対度数の累積値をとったものである。5 週間以内に削除されるレビューは 3 割程度に過ぎず、フェイクレビューの検知と削除が、後手に回ってしまっていることがわかる。

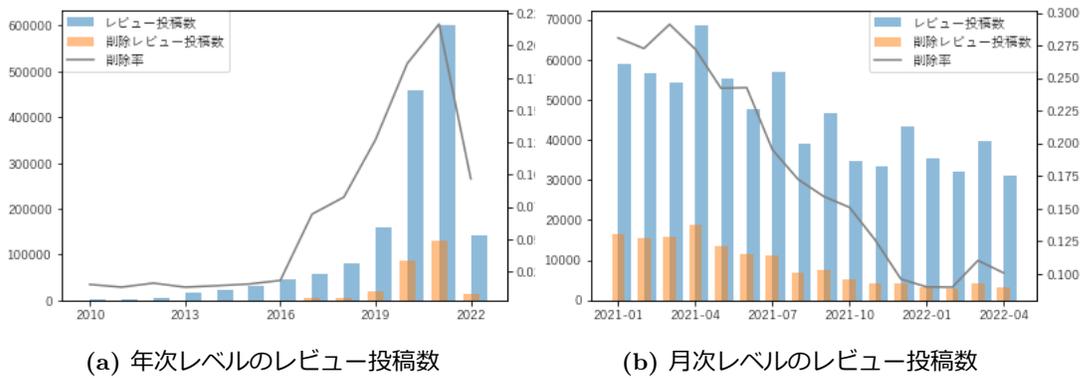


図 8: レビュー投稿数の推移

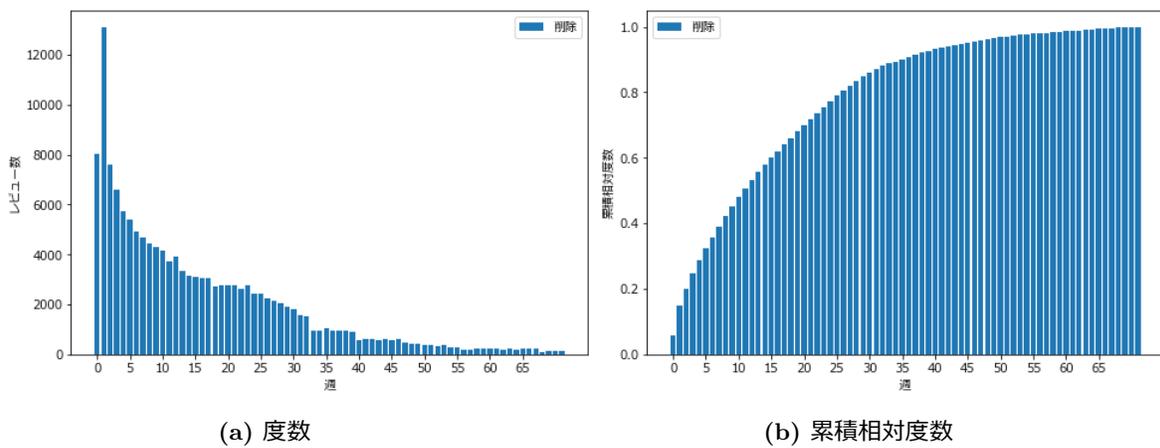


図 9: 削除レビュー生存週数

第4章 どんなレビューがフェイクなのか?: レビューレベルの実証分析

4.1 はじめに

1章と2章で整理した通り、将来の施策や規制を検討するにあたり、レビューの不正操作の詳細について理解することが必要となる。具体的には、どのレビューがフェイクであり、どの販売者や製品が不正に関与しているか、またこれらの行為がどのような動機やインセンティブの下で行われているのかを明らかにする必要がある。これらの知見は、不正と被害の抑制のための効果的な介入や、焦点を当てるべき点を規制・施策の勘案にあたり不可欠となる。しかしながら、レビューの不正操作に関する実証研究は蓄積が不十分で、その実態は多く不明瞭である。特に、国内における実証研究の例はなく、メディアによる調査に留まっている。

本稿は、削除されたレビューをフェイクレビューのプロキシとして分析を行う。ゆえに、まず、どのようなレビューが削除され、どのようなレビューがフェイクと疑わしいのかについて特定することが、他の詳細の分析にあたり前提となる。

そこで本章では、まず、レビューレベルでの分析を通じ、どんなレビューがフェイクなのか、フェイクレビューがどのような属性をもつかのかについて明らかにする。

特に、フェイクレビューの得点に焦点を当てる。高得点のフェイクレビューが主流なら、不正操作は、自社のプロモーションが目的であると判断できる。逆に、低得点のフェイクレビューが多ければ、他社に対しての攻撃のために行われているといえる。

また、フェイクレビューが巧妙化しているか否かについて注目する。先述したように、消費者の欺かれやすさが、不正操作の被害に影響する。これはフェイクレビューがどれだけ本物らしく見えるかにも影響される。フェイクレビューが真のレビューと判断されるような特徴を持つ場合、消費者被害は大きくなることが想定される。

4.2 データ

三章で述べたように、本稿で扱うレビューのデータは高頻度で取得されており、パネルデータとして扱うことが可能である。しかしながら、レビューの属性の大半は、基本的に、時系列に対して変動しない Time-Invariant な属性となっている。レビューの得点や、テキストやタイトルといったものは、レビューの執筆時点で固定されることが大半であると考

えられる⁵⁰。パネルデータを用いて固定効果を導入すると、多くのレビューの属性は、固定効果と完全な多重共線性を引き起こし、説明変数として用いることができない。これは、フェイクレビューとレビューの属性の関係を明らかにするという本章の目的からは望ましくない。

そこで、本章ではレビューレベルのクロスセクションデータを利用する。個々のレビューの最新の観測時点を用いたものであり、レビューの削除状況とレビューの属性により構成される。具体的には、レビューが事後的に削除されたか否かのダミー変数と、レビューの点数や文章などの変数となる。レビューの削除状況と投稿時期別に、点数の分布を示したものが、表4となる。

全期間に投稿されたレビューと、観測期間中に投稿されたレビューでは、削除されたレビューの割合や得点分布に大きく違いがある。全期間に投稿されたレビューのうち削除されたものが占める割合は16%ほどだが、観測期間中のものに限定すると、約20%のレビューが削除対象となっている。この結果からは、節で述べたように、観測期間以前に投稿されたレビューは、既にAmazon側による削除が行われて観測できなくなっていることが伺われ、サバイバルバイアスが生じていると判断できる。

レビューの削除状況については、いずれの期間のレビューでも、削除されたレビューの分布は、削除されていないレビューと比べて高得点に偏っている。特に、観測期間中に投稿された削除されたレビューの約3/4を★5が占めており、Amazonは高得点のものを集中的に削除しているといえる。あくまでAmazonによる削除はフェイクレビューのプロキシではあるものの、Amazonがフェイクレビューを高精度で把握できているという仮定が成立する場合、フェイクレビューは高得点なものが主流であり、他社を攻撃するのではなく、自社のプロモーションに用いられている可能性が高いといえる。

さらに、削除されたレビューと削除されていないレビューの間には、いくつかの他の変数においても違いが見られる。まず、発売からの経過週数⁵¹が大きく異なる。削除されたレビューは発売から平均して40週後に投稿されている一方で、削除されていないものは約80週後に投稿されている。比較的若いレビューが削除されていることがわかる。

また、タイトルやテキストについては、削除されたレビューの方が相対的に短い傾向が

⁵⁰ レビュー執筆後に商品が故障するなどして、当該ユーザーの商品への評価が変わり、レビューを低評価に書きなおすことなどの例は考えられるが、多くの場合レビューは最初に投稿された後に、そのまま放置される。例外は得票数や投稿からの経過日数のみで、分析上の焦点となるレビューの属性は変化しないといえる。

⁵¹ レビュー投稿時の販売からの経過週数。商品の発売日を得られないこともあるため、欠損値となるケースがある。

表 4: 得点分布

	全レビュー				観測期間中に投稿されたレビュー			
	非削除		削除		非削除		削除	
	度数	相対度数	度数	相対度数	度数	相対度数	度数	相対度数
*1	147261	0.11	20739	0.08	71792	0.12	10619	0.07
*2	71508	0.05	9010	0.03	31834	0.05	4251	0.03
*3	124417	0.09	14332	0.05	52051	0.09	6384	0.04
*4	306790	0.23	37037	0.14	120997	0.21	15980	0.11
*5	697042	0.52	180991	0.69	313052	0.53	106644	0.74
N	1347018		262109		589726		143878	

みられる。Azimi et al. (2022) が示したように⁵²、レビューが短いほど消費者はレビューをフェイクだと判別しやすい傾向にあり、消費者が想定する一般的なフェイクレビューの特徴に沿った削除の傾向であることがわかる。

一方で、デフォルトアイコンやデフォルトネームの使用は、削除されたレビューが相対的に多い。写真についても、削除されたレビューの方が使用している割合が大きく、購入者の比率も削除されているレビューの方が高い。一般論として、アイコンやユーザー名が設定された、購入者の写真付きのレビューはむしろ真の消費者のレビューの特徴と認識されているだろう。実際に、Akesson et al. (2023) は非購入者やデフォルトネームをフェイクレビューの特徴として扱っている。この削除の傾向からは、フェイクレビューが巧妙化しており、さらに Amazon がそれに対応してフィルタリングを行えていることが伺える。

4.3 メソッドロジーと結果

4.3.1 モデル

本節では、(Luca and Zervas, 2016) に倣い、レビューの不正操作とレビューの属性の関係を調査するモデルを構築する。商品 i のレビュー k について、がフェイクの場合 1 となり、真のレビューの場合 0 となる f_{ik} は以下のような回帰モデルで表せられる。

$$f_{ik} = x'_{ik}\beta + \gamma_k + \epsilon_{ik} \quad (11)$$

⁵²ただし、ネガティブなレビューについては短いほど真のレビューだと判断されやすい。

表 5: レビューレベル記述統計

		count	mean	std	
全レビュー	点数	734140	4.06	1.36	
	*1	734140	0.11	0.32	
	*2	734140	0.05	0.22	
	*3	734140	0.08	0.27	
	*4	734140	0.19	0.39	
	*5	734140	0.57	0.49	
	画像あり	703307	0.11	0.32	
	販売からの経過週数	679322	76.51	111.89	
	タイトル長さ	734140	10.28	7.18	
	タイトルに中国漢字使用	734140	0.00	0.03	
	テキスト長さ	734140	121.13	163.32	
	ひらがな率	734140	0.43	0.27	
	テキストに中国漢字使用	734140	0.00	0.04	
	デフォルトネーム	734140	0.12	0.33	
	ユーザー名に中国漢字使用	734140	0.00	0.05	
	デフォルトアイコン	734140	0.89	0.32	
	得票数	728023	235.63	1440.96	
	購入者	734140	0.91	0.28	
	非削除	点数	589726	3.97	1.39
		*1	589726	0.12	0.33
*2		589726	0.05	0.23	
*3		589726	0.09	0.28	
*4		589726	0.21	0.40	
*5		589726	0.53	0.50	
画像あり		581446	0.10	0.30	
販売からの経過週数		547633	84.56	117.51	
タイトル長さ		589726	10.37	7.32	
タイトルに中国漢字使用		589726	0.00	0.02	
テキスト長さ		589726	122.26	170.21	
ひらがな率		589726	0.43	0.27	
テキストに中国漢字使用		589726	0.00	0.04	
デフォルトネーム		589726	0.13	0.34	
ユーザー名に中国漢字使用		589726	0.00	0.04	
デフォルトアイコン		589726	0.89	0.31	
得票数		585382	270.12	1529.74	
購入者		589726	0.91	0.29	
削除		点数	143878	4.42	1.18
		*1	143878	0.07	0.26
	*2	143878	0.03	0.17	
	*3	143878	0.04	0.21	
	*4	143878	0.11	0.31	
	*5	143878	0.74	0.44	
	画像あり	121347	0.19	0.39	
	販売からの経過週数	131221	42.61	75.36	
	タイトル長さ	143878	9.90	6.55	
	タイトルに中国漢字使用	143878	0.00	0.03	
	テキスト長さ	143878	116.58	131.34	
	ひらがな率	143878	0.43	0.27	
	テキストに中国漢字使用	143878	0.00	0.04	
	デフォルトネーム	143878	0.09	0.28	
	ユーザー名に中国漢字使用	143878	0.01	0.08	
	デフォルトアイコン	143878	0.85	0.35	
	得票数	142125	94.16	986.02	
	購入者	143878	0.94	0.23	

右辺の x'_{ik} はレビューの属性のベクトルである。 γ_k は k の固定効果を示し、 ϵ_{ik} は誤差項となる。

しかしながら、レビューがフェイクか否かを観察することはできない。観察可能なのは、プロキシーである、レビューが削除されたか否かである。これは、フェイクレビューでないのに Amazon のアルゴリズムの誤検知や他の規約違反などで削除される偽陽性のケースが考えられるため、測定誤差の問題が生じる。

測定誤差について、以下のように仮定する。レビューを削除された場合に 1 となるダミー変数を d_{ik} とする。真のレビューであるのに削除されてしまう偽陽性の確率を α_0 、実際にフェイクレビューが削除される真陽性の確率を $\alpha_0 + \alpha_1$ とする。ここで、 $\alpha_0 \geq 0$ かつ $\alpha_1 > 0$ と $\alpha_0 + \alpha_1 \leq 1$ を仮定する。これは、真陽性の確率は偽陽性の確率より厳密に大きいこと仮定している。先述したように、He et al. (2022b) は、Amazon はフェイクレビューをよく判別できていることを示しており、妥当な仮定といえる。これらを用い、 d_{ik} は (12) のように書ける。

$$\begin{aligned} d_{ik} &= \alpha_0(1 - f_{ik}) + (\alpha_0 + \alpha_1)f_{ik} + u_{ik} \\ &= \alpha_0 + \alpha_1 f_{ik} + u_{ik} \end{aligned} \quad (12)$$

ここで、 u_{ik} は平均 0 の独立な誤差項である。これに (11) を代入することで、以下が得られる。

$$\begin{aligned} d_{ik} &= \alpha_0 + \alpha_1(x'_{ik}\beta + \gamma_k + \epsilon_{ik}) + u_{ik} \\ &= \alpha_0 + \underbrace{x'_{ik}\tilde{\beta}}_{\alpha_1\beta} + \underbrace{\tilde{\gamma}_k}_{\alpha_1\gamma_k} + \underbrace{\tilde{\epsilon}}_{\alpha_1\epsilon_{ik}+u_{ik}} \end{aligned} \quad (13)$$

パラメータ β は推定できないものの、誘導系パラメータ $\tilde{\beta}$ は推定することが可能となっている。 α_1 は正の値であるため、パラメータの符号は等しくなる。シンプルな線形確率モデルであり、レビューの属性が、削除されるか否に影響を与えるか否かという定式化となっている。

懸念されるのは、 x'_{ik} とレビューがフェイクか否かに影響するが観測されない属性である ϵ_{ik} の相関である。これは、商品レベルの固定効果の導入により対処する。

4.3.2 推定結果

(11) の推定結果を示したものが、表 6 である。推定にあたっては、先述したセレクションバイアスを考慮し、観測期間中に投稿されたレビューのみを用いている。モデルには商品固

定効果が含まれるが、表には記載されていない。また、固定効果には ASIN ではなく、商品グループレベルとなっている。

まず、点数⁵³について、*1 と *4、*5 は有意に正となっている。*5 については係数も *1 や *4 と比べ大きく、約 6% ポイント削除されやすい。高評価のレビューほど顕著に削除されやすいことから、自社のプロモーション目的のフェイクレビューが主だったものであると考えられる。また、*1 についても、有意に削除されやすい結果が示されており、低評価による攻撃が行われている可能性が示唆される。さらに、販売からの経過週数が短いほど、レビューは削除されやすい。販売初期に集中してフェイクレビューが投稿されていることが伺える。

タイトルの長さについては有意とはいえないものの、テキストの長さは有意に正となっており、長いテキストほど削除されやすい。写真の使用は有意に正であり、写真を掲載しているレビューの方が削除されやすい。デフォルトアイコンやデフォルトネームの使用は有意に負となっており、アイコンやユーザー名を初期状態から変えている方が削除されやすい。これらの有意に削除されやすいとされる特徴は、先述したように、一般的に本物のレビューにある特徴とされるものであり、実際の消費者によるレビューだと誤認させるように、巧妙化したフェイクレビューが投稿されていることがいえる。一方で、そうしたレビューが削除されていることから、Amazon 側が巧妙化したフェイクレビューを把握できていることもいえる。

購入者については、非購入者と比べ有意に 3.6% ポイント削除されやすい。レーティングの計算で購入者のレビューを重く評価する Amazon の仕様上、フェイクレビューにより不正操作を行うためには、購入者によるレビューである必要性が高い。購入者もむしろフェイクと思われるにくい特徴である。

ユーザー名における中国語の使用は有意に約 13.7% ポイント削除されやすくなる。また、ひらがな率も有意に正となっている。中国系と思わしきユーザー名や稚拙な日本語は削除の対象となりやすいことがいえる。レビューの不正操作には中国系セラーの関与している疑惑が各種メディアの取材や先行研究で指摘されてきたが、こうした疑惑を裏付ける結果となっている。

回帰分析の結果は、記述統計からみられた傾向を支持するものである。これらは He et al. (2022b) のデータと近い傾向を示している。He et al. (2022b) では、本研究と同様、削除されたレビューの方が、購入者の比率が大きく、写真の使用数が多く、評価が高い。

⁵³各変数は *3 を基準としたダミー変数となる。

表 6: レビューレベル推定結果

	ベースモデル
1	0.006 (0.002)
*2	0.003 (0.002)
4	0.003 (0.001)
*5	0.060*** (0.003)
購入者	0.036*** (0.003)
販売からの経過週数	-0.001*** (0.000)
画像あり	0.043*** (0.003)
テキスト長さ	0.000*** (0.000)
タイトル長さ	0.000 (0.000)
テキストに中国漢字使用	0.009 (0.013)
タイトルに中国漢字使用	0.040 (0.021)
ひらがな率	0.003* (0.001)
ユーザー名に中国漢字使用	0.137*** (0.012)
Num.Obs.	652988
R2	0.469
R2 Adj.	0.458

Signif. codes: *** 0.001 **0.01 *0.05

括弧内は標準誤差を示す

標準誤差は商品グループをクラスターとしたクラスターロバスト標準誤差から計算されている

一方で、Luca and Zervas (2016) とは異なる傾向を示している。Luca and Zervas (2016) では、短いレビューほど削除されやすく、写真付きのレビューほど削除されにくい。レストラン産業と EC サイトではフェイクレビューの特徴は異なる可能性もあるが、Luca and Zervas (2016) が扱うのは 2012 年までのレビューデータであり、当時と比べてフェイクレビューが巧妙化している可能性が指摘できる。

4.3.3 セラーの交差項の導入

本章では、レビューの削除をフェイクレビューであることのプロキシとして用いている。そのため、フェイクレビューについての分析ではなく、Amazon 側のアルゴリズムを分析しているという懸念がある。具体的には、 u_{ik} とレビュー属性の相関による推定されたパラメータへのバイアスという形となる。

(12) で u_{ik} は独立な誤差項と仮定している。これは、レビューが削除されるか否かに影響する観察されない属性が、観察されるレビューの属性と相関しないことを仮定している。しかしながら、商品固定効果をコントロールしたうえで、特定の属性をもつレビューが、アルゴリズム上削除されやすいことは十分考えられ、 u_{ik} とレビューの属性は相関してしまう恐れがある。そこで、本節ではセラーの違いを用い、このコントロールを行う。

3 章で述べたように、Amazon においては、Amazon 自身が販売する商品と、マーケットプレイスで Amazon 以外に販売される商品に分けられる。Amazon が販売する商品は、Amazon 上でレビューの不正操作を行うインセンティブが小さい。入荷元や製造元が著名な企業やブランドの製品であることが多く、レビューの不正操作が露呈した場合のブランドイメージの棄損が大きい。また、Amazon 以外の出荷先も多く存在し、一つの販売チャンネルでしかない Amazon でのレビューの操作は、プロモーションとしても対費用効果が弱い。

一方で、マーケットプレイスで商品を販売するセラーは、不正のインセンティブが大きい。無名のブランドや企業が中心であり、不正が露呈した場合のダメージは小さい。また Amazon が販売チャンネルとして大きい可能性も高い。実際に、Mayzlin et al. (2014) や Luca and Zervas (2016) は、チェーン系のホテルやレストランは不正を行いにくいことを示している。

こうしたセラーの性質から、Amazon で販売される商品については、フェイクレビューが投稿されにくい。それゆえ、Amazon で販売される商品のレビューが削除される場合、アルゴリズムの誤検知や、ユーザーのアカウント停止、その他の規約違反など、フェイクレビューとは無関係に削除されている可能性が大きい。

表 7: セラー別の点数分布

		Amazon 販売		マーケットプレイス	
		mean	std	mean	std
全レビュー	点数	3.88	1.39	4.10	1.35
	*1	0.12	0.33	0.11	0.31
	*2	0.06	0.24	0.05	0.21
	*3	0.10	0.30	0.07	0.26
	*4	0.23	0.42	0.18	0.38
	*5	0.48	0.50	0.60	0.49
	N	156421		577719	
削除されていないレビュー	点数	3.89	1.38	4.00	1.39
	*1	0.12	0.33	0.12	0.33
	*2	0.06	0.24	0.05	0.22
	*3	0.10	0.30	0.08	0.28
	*4	0.23	0.42	0.20	0.40
	*5	0.48	0.50	0.55	0.50
	N	149525		440201	
削除されたレビュー	点数	3.72	1.55	4.45	1.15
	*1	0.18	0.38	0.07	0.25
	*2	0.07	0.26	0.03	0.16
	*3	0.10	0.29	0.04	0.20
	*4	0.15	0.36	0.11	0.31
	*5	0.50	0.50	0.75	0.43
	N	6713		137165	

セラー別のレビューの点数の分布を示したものが表 7 である。仮に、削除されているレビューがフェイクレビューならば、得点は大きく偏る可能性が高い。しかしながら、Amazon で販売される商品においては、削除されたレビューでは約 4% と少なく、削除状況によってレビューの分布が大きく変化しない。一方で、マーケットプレイスが販売する商品は、約 23% のレビューが削除の対象となっており、削除されたレビューでは、高得点のレビューに強く偏っている。この事実からも、Amazon が販売する商品でレビューが削除される場合、レビューがフェイクと判断されたのではなく、他の原因で削除されている可能性が高いと判断できる。

こうしたセラーの違いを用いることで、Amazon 側の削除ポリシーをコントロールすることが可能といえる。しかしながら、セラーの固定効果と商品固定効果の併用は、多重共線性により不可能である。そこで、マーケットプレイス商品であることを示すダミーとレビュー属性の交差項を用いる。

推定結果が表 8 となる。まず、記述統計で確認した通り、レビューの点数について大きな違いがみられる。Amazon で販売される商品については、*1 と 4 が有意となっているものの、どの得点も係数が小さい。一方、マーケットプレイスの商品は、*4 と *5 点が有意に正かつ係数も大きく、高得点のものが顕著に削除されやすい。他社の攻撃というよりは、高評価のフェイクレビューによる自社についてプロモーションという図式がより支持される結果といえる。

発売からの経過週数は、Amazon 販売商品については有意に正な一方で、マーケットプレイス商品は有意に負となっている。Amazon 販売商品では、販売から時間が経過してから投稿されるレビューが削除されやすいのに対し、マーケットプレイス商品では、販売から間もないレビューほど削除されやすい。初期に集中して投入されていることが伺える。

テキストの長さは、Amazon 販売商品については有意とはいえない一方で、マーケットプレイス商品については有意に正になっている。写真の添付や中国漢字のユーザー名への使用は両者が有意に正、デフォルトアイコンやデフォルトネームの使用は両者で有意に負となっている。これらは、フィルタリングアルゴリズムをコントロールしてもなお削除されやすいとされる特徴といえ、フェイクレビューの特徴であることの頑健性が確認できる。

購入者については、Amazon 販売商品において有意に負である一方、マーケットプレイス商品では有意に正かつ係数が大きい。レーティングは購入者のレビューの比重が高い仕様から、購入者のレビューを水増しすることで、目的である可能性がより支持される結果といえる。

いずれの属性についても、マーケットプレイス商品に関しては、前節の推定結果と整合的であり、フェイクレビューとしての特徴の頑健性が確認されたといえる。

4.4 おわりに

本章では、レビューレベルのデータを用い、削除されやすいレビューの属性について分析を行った。推定の結果、主に3つの知見が得られた。第一に、高得点のレビューや販売から間もないレビューほど有意に削除されやすい。自社の商品について、高評価のフェイクレビューを販売初期に集中することで、レーティングを歪めていることが示唆される。

第二に、写真があるレビュー、テキストの長いレビュー、購入者によるレビューは有意に削除されやすい。一方で、デフォルトアイコンや、デフォルトネームを用いているレビューは削除されにくい。前者は一般に真のレビューの特徴と考えられるものであり、後者はフェイクレビューの特徴として考えられるものである。フェイクレビューは巧妙化していると判断でき、消費者がうまく判別できていない可能性が指摘できる。

第三に、ユーザー名に中国漢字が用いられていると有意に削除されやすい。中国系セラーが不正に関与していることが報道されているが、この関与を裏付ける結果といえる。

本章の結果は、フェイクレビューがどんな特徴をもつかを示し、判別と対策に貢献するが、いくつかの限界がある。第一に、フェイクレビュー自体を観察できず、Amazonに削除されたレビューを用いているため、Amazonのアルゴリズムについて分析しているという懸念が残る。推定にあたり固定効果の導入や、マーケットプレイス交差項の導入など、対処は行っているものの、より高精度でのフェイクレビューの把握が求められる。

第二に、現在におけるフェイクレビューの特徴は、将来では有用にならず、所謂“いたちごっこ”の状況が発生してしまう懸念がある。仮に、これらの特徴を用い、フェイクレビューへの対策を行ったとしても、不正を行う売り手側がそれを考慮し、異なる特徴をもつフェイクレビューを依頼するようになる可能性が指摘できる。継続的な分析を行うことや、より本質的で、変化しない特徴について明らかにすることが必要となる。

表 8: レビューレベル推定結果 (交差項使用)

	マーケットブレイス交差項導入
*1	0.016** (0.005)
*2	0.006 (0.004)
4	-0.009 * * (0.002)
*5	0.002 (0.002)
購入者	-0.006* (0.003)
商品年齢	0.000** (0.000)
画像あり	0.014* * * (0.003)
テキスト長さ	0.000 (0.000)
タイトル長さ	-0.000 (0.000)
テキストに中国漢字使用	0.031 (0.026)
タイトルに中国漢字使用	0.065 (0.036)
ひらがな率	0.001 (0.002)
ユーザー名に中国漢字使用	0.065** (0.021)
*1(マーケットブレイス)	-0.011 (0.006)
*2(マーケットブレイス)	-0.003 (0.005)
4(マーケットブレイス)	0.017 * * (0.003)
5(マーケットブレイス)	0.075 * * (0.004)
購入者 (マーケットブレイス)	0.055* * * (0.005)
商品年齢 (マーケットブレイス)	-0.002* * * (0.000)
画像あり (マーケットブレイス)	0.028* * * (0.004)
テキスト長さ (マーケットブレイス)	0.000* * * (0.000)
タイトル長さ (マーケットブレイス)	0.000 (0.000)
タイトルに中国漢字使用 (マーケットブレイス)	-0.028 (0.044)
ひらがな率 (マーケットブレイス)	0.003 (0.003)
デフォルトアイコン (マーケットブレイス)	-0.020* * * (0.003)
ユーザー名に中国漢字使用 (マーケットブレイス)	0.081** (0.025)
Num.Obs.	652988
R2	0.472
R2 Adj.	0.461

Signif. codes: *** 0.001 **0.01 *0.05

括弧内は標準誤差を示す

標準誤差は商品グループをクラスターとしたクラスターロバスト標準誤差から計算されている

第 5 章 どんな売り手や商品が不正に関与しているのか？プロダクトレベルの分析

5.1 はじめに

本章では、前章に続き、不正の詳細について、製品レベルで明らかにする。具体的には、プロダクトレベルに集計したクロスセクションデータを用い、どのような売り手や商品がレビューの不正操作を行っているか調査を行う。

特に、不正を行っている売り手や製品の質について明らかにする。1 章や 2 章で整理したように、不正操作がもたらす害は、売り手のタイプに依存する。一般的に懸念されているような、低品質な商品の売り手が、実際とは乖離したような高評価のレビューを水増しするようなケースでは、消費者の被害は大きくなる。一方で、知名度が低いが高品質な商品を供給するような売り手がフェイクレビューを投稿するようなケースでは、被害は大きくない。後者のケースは直観的ではないものの、いくつかの理論研究は、このような均衡が実現する可能性を指摘しており、実証上の課題といえる。

また、不正を行っている売り手の販売形態についても明らかにする。Mayzlin et al. (2014) や Luca and Zervas (2016) では、企業の経営形態が不正の有無に影響を与えていることが示されている。不正の経済的インセンティブが大きいような売り手が、産業の性質が異なる Amazon においても、実際に不正に関与しやすいか否かを検証する必要がある。

5.2 データ

本節で扱うのは、前章で扱った個別のレビューデータの削除状況や得点について、プロダクトレベルで集計し、セラーや商品の属性をマージしたクロスセクションデータである。この際、プロダクトの単位は、前節と同様に、レビューが紐づけられている商品グループ同士を一つの商品として扱う。

セラーおよびその属性については、レビューと取得タイミングが異なるため、いくつかの商品については商品が削除されているケースや、在庫切れの場合もあり、売り手のデータが欠損する。中古のみが販売されている商品についても、欠損扱いとしている⁵⁴。

また、Amazon で販売される商品は、Amazon も含めた複数のセラーが存在する場合があり、セラーと個別の商品ならびに商品グループを 1 対 1 で対応することができない。そ

⁵⁴新品を販売するセラーの情報は得られないものの、中古を販売しているセラーのデータ自体は取得可能である。

ここで、より同じグループの商品を一つでも Amazon が販売しているグループについては、Amazon が販売しているものとして扱い、どの商品もマーケットプレイスで販売されているなら、マーケットプレイスで販売されている商品として扱う。セラーの国籍 (中国系か否か) は、同じグループの商品を全てが中国系のセラーの場合に中国系とする。ストアの有無については、グループ内の商品に一つでもストアがある場合に、専用ストアありとする。セラーの評価については、グループ内で最高の評価のセラーの点を用いる

こうしたセラーの分布を示したのが表 9 である。セラーが特定できるものは、全体の約 6 割であり、そのうちの約 75% がマーケットプレイスでのみ販売される商品となっている。セラーの国籍については、約半数が中国系となっている。セラーが特定できない約 4 割については、そのうちの約半数が中古のみの扱い、約 35% が在庫切れ、残り約 15% は商品ページが削除されたものとなっている。中古や在庫切れの判定については、ある一時点での観測ではなく、2022 年 5 月から 12 月までの期間、当該項目が観測されなかったものを用いており、長期間にわたって中古のみや在庫切れの商品となっている。

セラーが特定できない商品は、不正に関与している可能性が高い商品ともいえる。Amazon から削除された商品には何らかの規約違反があったと判断できる。長期間にわたって在庫切れの商品や中古しかない商品も、データの取得対象と時期から、単に古い商品や在庫が一時的に切れている商品とは考えにくく、“売り逃げ” のようなケースに該当し得る。

表 9: セラー分布

全商品	15879
セラーあり	9439
Amazon 販売	2308
マーケットプレイス商品	7131
中国系セラー	3478
セラーなし & 中古のみ	6440
在庫切れ	2163
商品削除	999
中古のみ	3188

こうしたセラーごとの記述統計が表 10 である。まず、フェイクレビューの可能性が大きい、削除された *4-5 の高評価のレビューの投稿数については、Amazon の販売する商品は平均約 1.90 本に過ぎない。一方で、マーケットプレイスが販売する商品で約 3 倍の平均約

5.81 本と、相対的にかなり多く投稿されている。マーケットプレイスの中でも中国系セラーが扱う商品だと傾向はより顕著になり、平均して 4 倍近い約 7.74 本投稿されている。

新品を販売するセラーが得られない商品については、更に多くの疑わしいレビューが投稿されており、在庫切れの商品については平均して約 8.3 本、削除された商品については約 13.34 本、中古のみの扱いの商品は約 14.28 本投稿されている。

一方で、これらの商品への削除されていない高評価レビューの投稿数については、Amazon の商品と比べ少ない。疑わしいレビューがより高い比率で投稿されていると判断でき、レビューの投稿状況からも、不正を行っている可能性が高い商品だといえる。

商品の質については、低評価の削除されていないレビューの数についても Amazon の商品より少なく、レビューの投稿数自体が少ないことから、平均評価について一概に低いと判断することはできない。ただし、Amazon 販売の商品約 8 割がメーカー専用のストアを持つのに対し、他の商品はストアを持たないケースが大多数であり、大手メーカーの製品ではないと判断できる。セラーの数も Amazon が販売する商品で際立って多く、Amazon 以外の多くの小売が扱うような人気商品であることが伺える。

中国語の使用については、中国系企業の関与が疑われるほか、日本の消費者を販売対象としながらも日本語のスキルが乏しい企業の商品といえる。これは、一種の品質についてのプロキシとなる。Amazon で扱う商品では中国語の使用が稀な一方で、マーケットプレイスの商品では約 5% の商品で使用されている。中国系セラーの商品は更に多く、約 8% となっている。セラーの情報を得られない商品では、いずれも、中国系セラーの商品と同水準の約 8% となっている。

セラー自体については、Amazon が販売する商品については、セラーの数が多く評価も高い。一方、マーケットプレイスの商品やセラーの情報を得られない商品については、セラーの数と評価の両方が相対的に小さい。特に、これらの商品については、単一のセラーのみが販売しているケースが半数以上を占める。

5.3 メソドロジーと結果

5.3.1 モデル

本節では、どのような商品がフェイクレビューによる不正操作を行っているかを明らかにするモデルを構築する。この際、フェイクレビューと商品の質の関係が焦点となる。ここでの商品の質を示す変数としては様々なものが考えられるが、客観的な指標としてまず考えられるのは、フェイクではない真のレビューについての変数だろう。具体的には真の

表 10: セラー別記述統計

		mean	std	
Amazon 販売	*4~5(削除)	1.90	5.09	
	*4~5(非削除)	46.18	111.94	
	*1~3(削除)	1.01	4.79	
	*1~3(非削除)	18.61	42.45	
	商品ページに中国漢字使用	0.00	0.06	
	専用ストアあり	0.80	0.40	
	セラー評価	4.92	0.30	
	セラー数	50.95	87.94	
	単一セラー	0.04	0.19	
	マーケットプレイス	*4~5(削除)	5.81	27.77
		*4~5(非削除)	28.23	91.21
*1~3(削除)		0.78	3.88	
*1~3(非削除)		9.13	25.79	
商品ページに中国漢字使用		0.05	0.22	
専用ストアあり		0.41	0.49	
セラー評価		4.67	0.54	
セラー数		12.57	31.32	
単一セラー		0.50	0.50	
中国系セラー		*4~5(削除)	7.74	26.79
		*4~5(非削除)	32.36	82.64
	*1~3(削除)	0.91	3.70	
	*1~3(非削除)	10.43	25.64	
	商品ページに中国漢字使用	0.08	0.27	
	専用ストアあり	0.29	0.46	
	セラー評価	4.53	0.65	
	セラー数	1.55	1.82	
	単一セラー	0.76	0.43	
	在庫切れ	*4~5(削除)	8.30	30.58
		*4~5(非削除)	16.33	56.30
*1~3(削除)		1.46	7.23	
*1~3(非削除)		6.95	17.72	
商品ページに中国漢字使用		0.08	0.27	
専用ストアあり		0.27	0.44	
商品削除		*4~5(削除)	13.34	116.88
	*4~5(非削除)	10.98	41.61	
	*1~3(削除)	1.85	15.15	
	*1~3(非削除)	4.92	11.25	
	商品ページに中国漢字使用	0.08	0.28	
	専用ストアあり	0.17	0.37	
	中古のみ	*4~5(削除)	14.28	57.95
*4~5(非削除)		25.05	106.31	
*1~3(削除)		2.62	13.46	
*1~3(非削除)		8.68	27.02	
商品ページに中国漢字使用		0.08	0.27	
専用ストアあり		0.24	0.43	

レビューの平均点や、得点別のレビューの投稿数や比率などが考えられる。しかしながら、レビューがフェイクか否かを判別することはできず、事後的なレビューの削除のみ観察可能である。フェイクレビューだけでなく、商品の質を示す真のレビューについても観察することができない。両者のプロキシを用い分析する必要がある。

ただし、フィルタリングが完全でなく、いくつかの点を考慮する必要がある。第一に、真のレビューが削除されてしまうことがあるために、削除されたレビューが多くとも、不正操作を行っているとは限らない。不正を行っている可能性が低い有名ブランドの人気商品でも、真のレビューが多い分、削除されたレビューは多くなり得る。このようなケースでは削除されたレビューの数や平均点などは不正操作のプロキシとしては好ましくない。

第二に、逆に、フェイクレビューが削除されずに残る可能性があるため、フェイクレビューが多いほど、削除されていないレビューにもフェイクレビューが混ざることになる。高評価のフェイクレビューと比べ、低評価の真のレビューがあまり投稿されていないようなケースでは、削除されずに残ったフェイクレビューのせいで、削除されていないレビューは高得点のものが多くなってしまふ可能性がある。削除されていないレビューは、真のレビューのプロキシとして信頼できないものとなってしまう。

そこで、レビューの得点分布に着目する。フェイクレビューは、真のレビューと比較して、その目的から高得点に強く偏ることが考えられる⁵⁵。逆に、低評価のレビューにはフェイクレビューが混ざりにくい。

こうした得点分布の傾向から、本節では、不正操作のプロキシとして、削除されたレビューにおける高得点率を用い、削除されていない低評価のレビューの数を質のプロキシとして用いる。フェイクレビューが高得点に偏るならば、フェイクレビューが多いほど削除されたレビューにおける高得点率は高くなりやすい。また、低評価レビューにフェイクレビューが混ざりにくいことから、これを質の低さの指標として捉えることが可能となる。モデルは以下のように表すことができる。

$$\frac{D_k^h}{1 + D_k} = \alpha + \beta R_k^l + \gamma X_k + \epsilon_k \quad (14)$$

ここで、 D_k^h は、削除された *4 と *5 のレビューの数で、 D_k は削除されたレビューの数となる。 R_k^l は削除されていない低評価の数 s であり、 X_k は売り手の属性に関する変数、 ϵ_k は誤差項である。

左辺 $\frac{D_k^h}{1 + D_k}$ は、不正操作削除されたレビューにおける高得率であり、商品 k のフェイクレビューの割合についてのプロキシとなる。ゼロ除算を避けるために分母を調整してい

⁵⁵レビューを低くなるよう操作するインセンティブは考えにくい。

る。これに、商品 k の質のプロキシである削除されていない低評価レビューの数である R_k^l や、売り手の性質を表す X_k がどのように影響を与えるかを推定することで、どのような売り手や商品が不正にかかわっているかを調査する。

5.3.2 推定結果

(14) の推定結果を示したものが表 11 である。集計対象のレビュー自体は観測期間中に投稿されたものであっても、レビューの削除が初期に集中する場合にはサバイバルバイアスが生じる可能性が考えられるため、サンプルの全商品を使用した推定結果と、観測期間中に発売した商品のみ対象とした推定結果を併記してある。係数は凡そ同じ傾向を示すが、観測期間限定の商品を対象とするケースでは、マーケットプレイスが有意に正かつ、係数も大幅に大きくなる。サバイバルバイアスが生じていると判断できる。

まず、商品の質について、*1-3 の削除されていないレビューは有意に正となっており、低評価のレビューが増えるほど、フェイクレビューのプロキシである、削除されたレビューにおける高評価の割合が増加する。低評価のレビューが多い商品ほど、不正操作が行われやすいことがいえる。

Amazon の販売する商品と比較して、マーケットプレイスで販売される商品は削除レビューにおける高得点率が有意に高く、約 10.7% ポイント高くなっている。Amazon 以外の販売する商品については、不正が行われている可能性が大きい。また、専用ストアがある場合、有意に不正が減少する。専用ストアがあるような企業の商品は、ブランド力を保持していることが多く、そのような商品については不正を行うインセンティブが小さいと考えられる。

Amazon から削除されている商品や、在庫がない商品、中古のみの商品についても、有意に正となっており、係数もマーケットプレイスより大きい。特に、在庫切れの商品と中古のみの商品は、削除レビューにおける高得点率が顕著に高く、マーケットプレイス販売の商品と比較しても不正に関与している疑いが強い。

セラーの数は、有意に負となっており、セラーが多いほど、削除レビューにおける高得点率が低くなる。仮にセラーが不正を行っても、他のセラーで購入される可能性があり、不正の恩恵が小さいため、インセンティブに整合的な結果といえる。

中国系セラーに関する属性については、中国語の使用も、中国系セラーも有意に正となっている。中国製の商品や中国系のセラーほど疑わしいレビューの分布をしており、4 章と同様に、中国系企業の関与が支持されている結果となっている。

表 11: プロダクトレベル推定結果

	(1)	(2)
	全商品	観測期間発売
切片	0.190*** (0.008)	0.172*** (0.018)
非削除 *1~3	0.004*** (0.000)	0.005*** (0.000)
マーケットプレイス	0.001 (0.009)	0.107*** (0.020)
専用ストアあり	-0.027*** (0.006)	-0.041*** (0.012)
セラー数	-0.000 (0.000)	-0.001* (0.000)
商品削除	0.097*** (0.013)	0.142*** (0.022)
在庫切れ	0.116*** (0.010)	0.194*** (0.021)
中古のみ	0.135*** (0.010)	0.308*** (0.022)
中国系セラー	0.144*** (0.008)	0.119*** (0.015)
商品ページに中国漢字使用	0.109*** (0.012)	0.090*** (0.018)
Num.Obs.	15789	5327
R2	0.134	0.162
R2 Adj.	0.133	0.161

括弧内は標準誤差を示す

標準誤差は商品グループをクラスターとしたクラスターロバスト標準誤差から計算されている

5.4 おわりに

本章では、どのような売り手や商品がレビューの不正操作に関与しているかを明らかにすべく、削除されたレビューの高得点率をプロキシとして用い、プロダクトレベルの分析を行った。推定の結果、主に4つの知見が得られた。第一に、低評価の削除されていないレビューが多い商品ほど、削除されたレビューの高得点率が有意に高くなり、分布が疑わしいものになる。低品質な財の売り手が高得点を装う目的で不正を行っているという構図が示唆され、消費者被害が大きくなるパターンに該当しているといえる。

第二に、マーケットプレイスで販売されるような商品では、削除されたレビューの分布が有意に高得点率に偏る。逆に、専用ストアがあるようなブランド商品や扱うセラー数の多い商品では、高得点率が有意に低くなる。Amazonでの売上が収益につながりやすいマーケットプレイスでの販売を行う売り手や、ブランドイメージ棄損のダメージが小さい非ブランド商品の売り手は、不正操作の利得が大きくなりやすい。同様に、セラーの数が多い場合は、仮に不正操作を行っても自社から購入されると限られないため、不正操作の利得は小さくなると考えられる。売り手の不正への関与が経済的インセンティブに一貫した形だといえる結果となっている。また、Mayzlin et al. (2014) や、Luca and Zervas (2016) とは産業が異なるものの、独立系のホテルやレストランほど不正を行い易いという結果と整合的である。

第三に、販売ページが削除されている商品や、長期間在庫切れや中古のみの商品は、削除されたレビューにおいて、高得点の割合が有意に高くなり、より不正への関与が疑われる結果となっている。削除された商品については、Amazonが削除を行ったタイミングが早期なら不正操作による被害は小さいものの、長期間にわたり、在庫切れの商品や中古のみの商品については、所謂“売り逃げ”に成功した商品であり、Amazonが後手に回っていることの証左といえ、消費者被害が生じていることが懸念される。

第四に、中国系のセラーや、商品の説明文に中国漢字が用いられると、削除されたレビュー一点数分布が有意に疑わしいものとなる。中国系セラーによる不正への関与を裏付ける結果といえる。

ただし、本章の分析は4章と同じく、不正を行っている売り手や商品を直接把握できていない。He et al. (2022b) と異なるアプローチをとる場合、より精度の高い不正の把握や、別のプロキシを用いた異なる角度での分析が求められる。

第 6 章 いつフェイクレビューは投稿されるのか?: パネルデータによる分析

6.1 はじめに

前章では、どのような商品やセラーが不正に関わっているか調査を行った。しかしながら、あくまでクロスセクションデータの分析であり、時間経過に伴うフェイクレビューの不正操作の動向についてはまだ考慮されていない。フェイクレビューが特定の時期や状況に応じて投稿される傾向がある場合、被害抑制にはこれを把握することが肝要となる。

また、フェイクレビュー時系列上での動向は、消費者被害の大きさにも関連する。例えば、フェイクレビューが一定の期間に集中して投稿されると、レビューが実態から大きく乖離し、欺かれる消費者が多くなる可能性がある。特に、販売初期にフェイクレビューが集まる場合は、消費者からは判別が困難になり、被害は大きくなると考えられる。このように、フェイクレビューの影響を評価するにあたっては、時間経過に伴うトレンドを把握することが必要となる。

加えて、不正の背景にあるインセンティブや、売り手や商品の属性が反映される可能性がある。フェイクレビューが蓄積したのちに低評価のレビューが増加した場合、それはフェイクレビューにより操作されたレビューの下での購入した消費者による、商品の実態への低い評価と解釈でき、低評価な商品の売り手による不正だと判断できる。

そこで、本章では、商品ごとに週単位で集計したパネルデータを用い、フェイクレビューがどのようなタイミングで増加し、同時に真のレビューがどのような動向を見せるかについて明らかにする。特に、フェイクレビューが初期に集中するか、フェイクレビューの投入後に低評価の真のレビューは増加するか否かに注目する。

6.2 データ

6.2.1 記述統計

本章で用いるのは、商品ごとに週次レベルで集計したパネルデータである。4 章と 5 章と同様に、ASIN ではなく、商品グループ単位で扱っており、その分類は 5 章に準ずる。時系列上でのレビューの動向を調査するという目的から、観測期間中に発売された商品のみ扱う。これは、商品ごとに出現数が異なる、アンバランスドパネルとなっている。

表 12 は、このパネルデータの記述統計を示したものである。平均して 40 から 50 週程度サンプルに出現する。ただし、Amazon から削除された商品は、その性質上出現週数は約

34.6 と少なくなっている。

フェイクレビューと疑わしい高評価の★4-5の削除されたレビューについては、Amazonが販売する商品では平均0.01と非常に少ない。一方で、Amazon以外が販売する商品⁵⁶においては、平均0.25と比較して顕著に多い。更に、中古のみの商品や、商品が削除された商品ではより多く、特に疑わしい商品で多くなっているといえる。Amazon以外が販売する商品においては分散についても大きいため、特定の商品と時期に集中している可能性が伺える。

高評価の削除されていないレビューについては、Amazonが販売するか否かで大きな違いはない。ただし、Amazonが販売しない商品のなかでは、マーケットプレイスや商品が削除された商品で平均約1と多く、在庫切れと中古のみの商品ではいずれも0.5以下と相対的に少ない。この二つの商品については、削除された高評価のレビューの数が、削除されていないレビューの数と比べ相対的に大きい。

6.2.2 レビューの不正操作の時系列上での動向

フェイクレビューのトレンド

各商品に投稿されるレビューの数が、時系列上でどのようなトレンドを示すか確認する。図(10)は、横軸に発売からの経過週数(30週まで)、縦軸に★4と★5のレビューの投稿数の商品間の平均値をとった棒グラフである。販売開始からの時系列上において、平均的に高評価レビューがどのように投稿されるかを示したものと見える。

青が★4-5が削除されていないレビューの数、オレンジが削除された★4-5のレビューの数を示す。(a)がAmazonが販売する商品、(b)Amazonでないセラーが販売する商品となっている。

amazon以外が販売する商品について、(c)はマーケットプレイスで販売される商品のものに限定したもので、(d)は在庫切れでセラーが特定できなかったもの、(e)は中古のみが扱われているもの、(f)は商品全体が削除されているものにそれぞれ限定している。Amazon以外が扱う商品において、単にマーケットプレイスで販売される(c)と比べ、(e)から(f)までは通常でない状況にある、疑わしい商品となっている。

(a)と(b)を比較すると、明らかに異なる傾向を示しており、Amazon以外が販売する商品は、Amazonが販売する商品に比べ、高評価のレビューが初期に強く偏っている。削除された高評価のレビューについてはより顕著であり、Amazonが販売する商品では、削除された高評価レビュー自体が稀かつコンスタントに投稿されているのに対し、Amazon以外

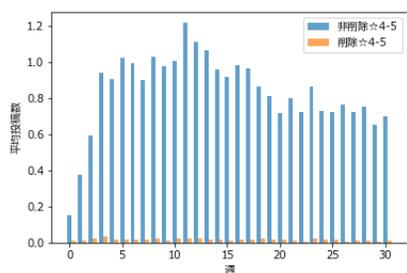
⁵⁶商品の削除や在庫切れ、中古のみ等でセラーが特定できないケースも含む。

表 12: パネルデータ記述統計

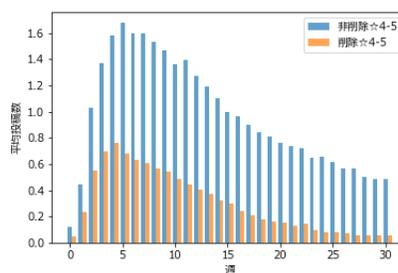
		mean	std
Amazon	★4~5(削除)	0.01	0.13
	★4~5(非削除)	0.79	2.39
	★1~3(削除)	0.01	0.09
	★1~3(非削除)	0.27	0.84
	出現週数	47.18	15.91
非 Amazon	★4~5(削除)	0.25	2.24
	★4~5(非削除)	0.83	3.42
	★1~3(削除)	0.03	0.28
	★1~3(非削除)	0.25	0.87
	出現週数	44.54	16.41
マーケットプレイス	★4~5(削除)	0.18	1.59
	★4~5(非削除)	0.99	3.81
	★1~3(削除)	0.02	0.18
	★1~3(非削除)	0.27	0.94
	出現週数	44.65	16.00
在庫切れ	★4~5(削除)	0.21	1.66
	★4~5(非削除)	0.43	2.44
	★1~3(削除)	0.02	0.20
	★1~3(非削除)	0.16	0.69
	出現週数	50.22	13.78
商品削除	★4~5(削除)	0.36	4.58
	★4~5(非削除)	0.49	2.77
	★1~3(削除)	0.04	0.46
	★1~3(非削除)	0.20	0.71
	出現週数	34.62	15.35
中古のみ	★4~5(削除)	0.56	2.74
	★4~5(非削除)	1.00	3.22
	★1~3(削除)	0.08	0.48
	★1~3(非削除)	0.33	0.91
	出現週数	42.54	18.76

の商品では、削除されたレビューは初期に集中している。これらのことから、フェイクレビューが初期に集中していることが疑われる。

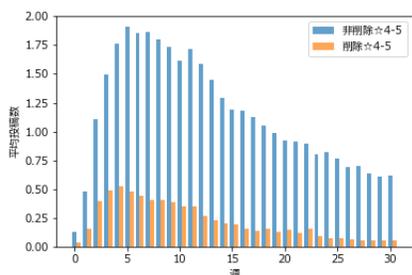
更に、(c) と比べ (d) から (f) までは更に初期に高評価のレビューが集中する傾向が強まり、高評価レビューにおける削除されたレビュー割合も大きくなる。特に疑わしい商品において、高評価のレビューが更に初期に集中しており、フェイクレビューが初期に集中することを指示する傾向を示している⁵⁷。



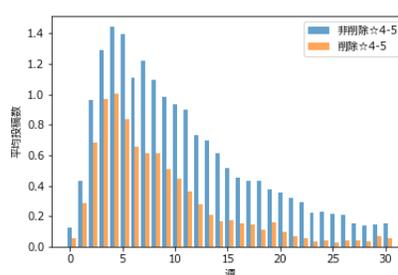
(a) Amzon 販売



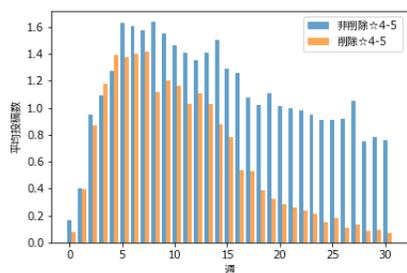
(b) 非 Amzon 販売



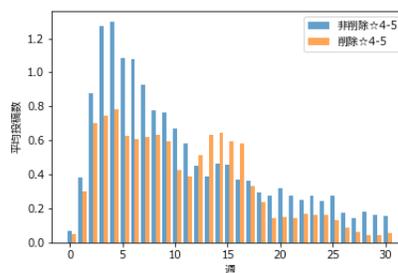
(c) マーケットプレイス



(d) 在庫切れ



(e) 中古のみ



(f) 商品削除

図 10: 高評価レビューのトレンド

⁵⁷単に高く評価しやすい消費者が初期に購入しやすいという傾向がある可能性については、Amazon が販売する商品において、高評価レビューがコンスタントに投稿されていることから考えにくい。

販売初期のフェイクレビューのトレンド

初期に疑わしいレビューが集中することから、フェイクレビューが投稿され始めた時期と、フェイクレビューが集中する時期が、いずれも販売初期になることが予想される。そこで、商品ごとの、削除された高評価レビューが最も多い週や、削除された高評価レビューが最初に投稿された週を示したのが図 11である。販売からの経過週数を横軸に、商品数を縦軸にとった棒グラフであり、青いバーが削除された高評価レビューが最も多い週、オレンジのバーが削除された高評価レビューが最初に投稿された週となっている。

削除された高評価レビューが最も多い週は、最初にそれらのレビューが投稿される週とかなり似た分布を示している。削除された高評価レビューのピークは投稿され始めて間もないタイミングであるケースが多いことがいえる。Amazon 販売の商品と比べ、Amazon 以外が販売する商品では、いずれの週も相対的に販売初期に集中し、(d) から (f) までの特に疑わしい商品についてはより顕著な傾向を示している。ただし、Amazon が削除を開始する週は、他二つの週と比べて、ピークが販売からより経過している。

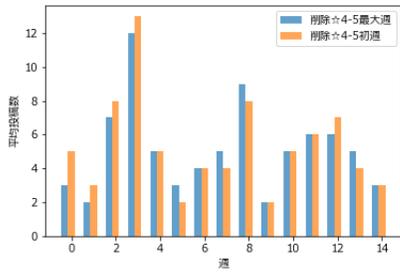
次に Amazon 側の対処のタイミングを確認する。フェイクレビューが初期に大量に集中する場合、消費者被害が大きくなることが懸念されるものの、Amazon が早期にフェイクレビューを削除できていれば、被害を抑制することが可能だと考えられる。商品ごとの、削除された高評価レビューの投稿が始まった週と、レビューの削除が始まった週についてヒストグラムを描いたのが図 12である。販売からの経過週数を横軸に、商品数を縦軸にとった棒グラフであり、青いバーが削除された高評価レビューの投稿が始まった週、オレンジのバーがレビューの削除が開始された週を示す。

高評価レビューの投稿が始まった週の分布と比べ、レビューの削除が開始された週は右寄りの分布となっており、ピークがより遅い週となっている。フェイクレビューへの対処は、後手に回っており、フェイクレビューが蓄積してから行われていると考えられる。

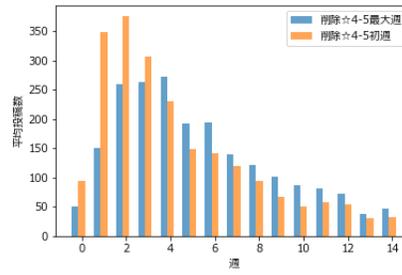
図 (13) は、各商品について、これらの週の差の分布を示したものである。青いバーが削除された高評価レビューが最も多い週と、削除された高評価レビューが最初に投稿された週の差を示し、オレンジのバーがレビューの削除が開始した週と、削除された高評価レビューが最初に投稿された週の差⁵⁸を示す。

削除された高評価レビューが最も多い週と削除された高評価レビューの差については、いずれも差が 0 の商品が大半であり、他の商品の大多数でも差が小さい。殆どの商品において、これらの週は重複するか近いことが分かる。一方で、レビューの削除が開始した週

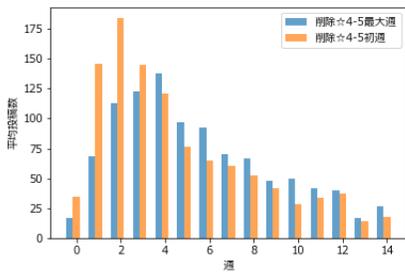
⁵⁸一部商品については、低評価レビューが、高評価レビューに先んじて削除される関係上、週の差はマイナスのものもある。ただし、これは 57 商品とごく一部であり、図からは省略している。



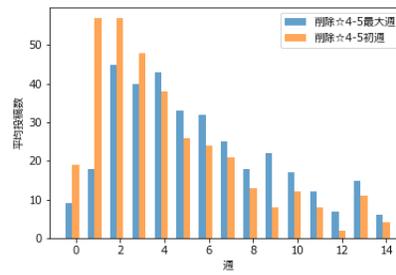
(a) Amzon 販売



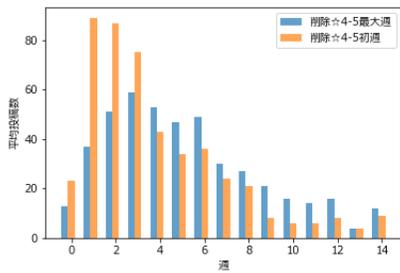
(b) 非 Amzon 販売



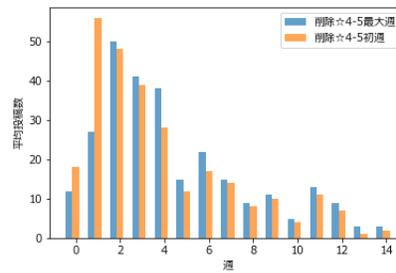
(c) マーケットプレイス



(d) 在庫切れ

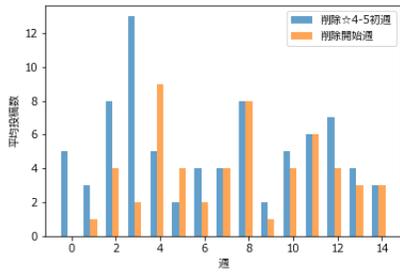


(e) 中古のみ

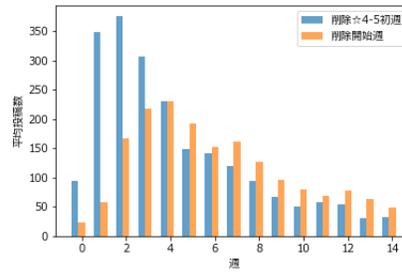


(f) 商品削除

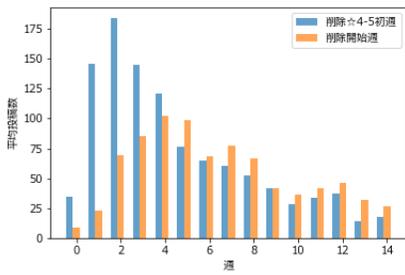
図 11: 削除された高評価レビューの投稿開始週と、最も多い週の分布



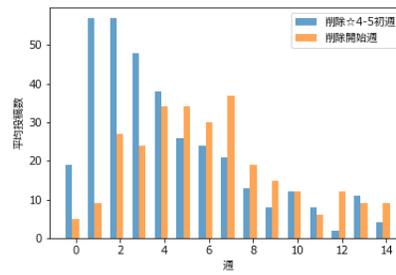
(a) Amzon 販売



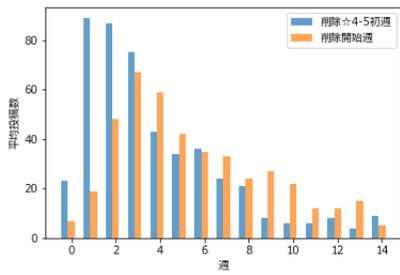
(b) 非 Amzon 販売



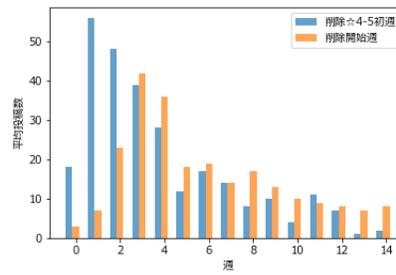
(c) マーケットプレイス



(d) 在庫切れ



(e) 中古のみ

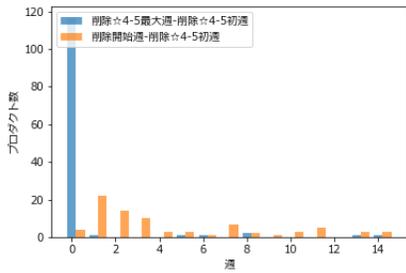


(f) 商品削除

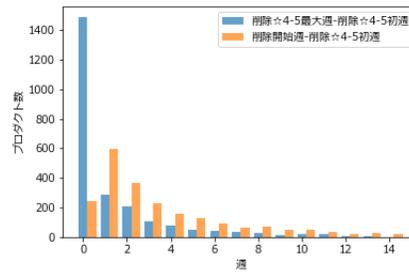
図 12: 削除された高評価レビュー投稿開始週と Amazon によるレビュー削除開始週の分布

と削除された高評価レビューの差は、1週をピークとして、なだらかに分布しており、疑わしいレビューが投稿されてから実際に削除が始まるまでは、タイムラグがあることと、削除開始までの時間にばらつきがあるといえる。実際に、3章でも、削除されたレビューについて、投稿から削除までの間隔が5週以下であるものは3割程度に過ぎなかった。

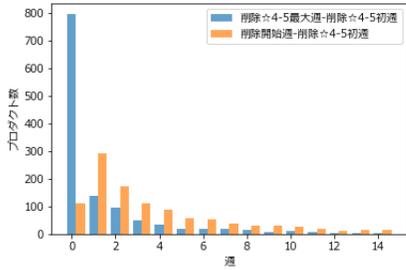
販売初期に疑わしいレビューの投稿が開始され、なおかつその量も商品の販売時系列の中で最上位に位置する傾向があり、更に Amazon の対策は後手に回っているといえる。販売初期にフェイクレビューが大量に投稿し、評価を歪めている可能性と、その歪んだ評価が正されるまでにある程度時間がかかることが支持される。



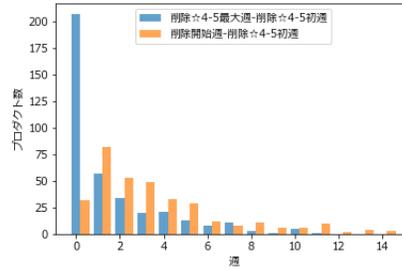
(a) Amzon 販売



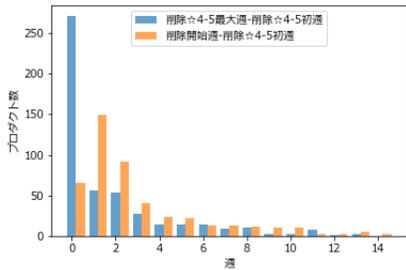
(b) 非 Amzon 販売



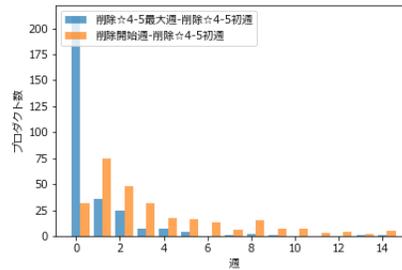
(c) マーケットプライス



(d) 在庫切れ



(e) 中古のみ



(f) 商品削除

図 13: 削除された高評価レビューの投稿開始週との差分の分布

低評価レビューのトレンド

次に低評価のレビューが時系列上においてどのように投稿されるかを、図 10 同様にして示したものが、以下の図 14 である。青のバーが削除されていない *1 から *3 のレビューの数を示し、オレンジのバーが削除された *1 から *3 のレビューの数を示す。

Amazon が販売する商品においては、削除状況に関わらず、低評価レビューはコンスタントに投稿されている。一方で、Amazon 以外が販売する商品については、商品の分類に関わらず、ピークとなる週まで急激に増加し、その後緩やかに減少していく傾向がみられる。削除された低評価のレビューについてもおおよそ同様の傾向をみせる。

販売初期に少ない低評価レビューが、販売からしばらく経過してから増加している。これらは、高評価の削除されたレビューが集中する時期より後となっている。このことから、初期に集中するフェイクレビューに欺かれた被害者が、販売からしばらく経過してから増加している可能性が考えられる⁵⁹。

フェイクレビュー投入開始前後のトレンド

次に、フェイクレビューのプロキシである、削除された高得点の疑わしいレビューについて、投稿され始める週の前後のレビューや得点の推移をみる。これによって、販売初期に投稿されるフェイクレビューの投稿がどれだけ集中するか、どのような影響をもたらしたか確認することができる。

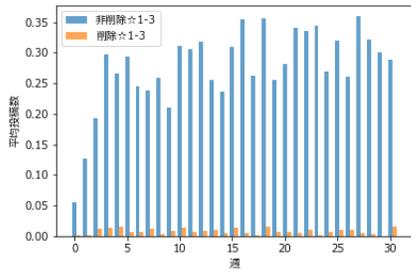
各商品について、削除された高評価レビューが最初に投稿される週を基準週として⁶⁰、その前 10 週後 20 週についての投稿数の平均やレビューの平均点を示したものが図 16 である。これは、左縦軸にレビューの、それらの週における投稿数の商品間の平均値をとり、右縦軸にレーティングをとった折れ線グラフである。

削除状況に関わらず、高評価レビューは基準週もしくはそのすぐ近くの週で最も多く投稿されている。ただし、削除されたものはより顕著に基準週に集中する傾向がみられる。また、Amazon が販売する商品については、削除されたレビューの数自体が非常に少ない

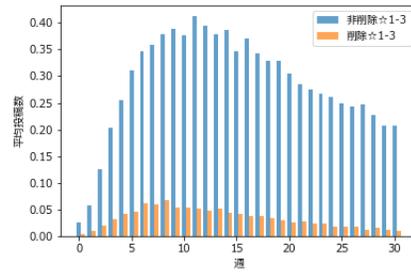
(c) から (f) のどのセラーの商品についても、基準週に削除状況に関わらずレビューが集中する傾向は変化しない。しかしながら、疑わしいセラーの商品については、削除された高評価レビューの数が、削除されていないレビューと比べ相対的に大きくなっている。

⁵⁹単に低く評価しやすい消費者は販売からしばらく経ってから購入しやすいという傾向がある可能性については、Amazon が販売する商品において、低評価レビューの投稿がコンスタントに行われていることから考えにくい。

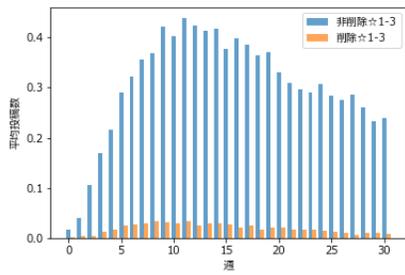
⁶⁰高評価レビューが削除されなかった商品については対象外としている。



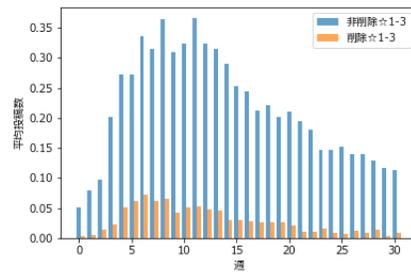
(a) Amzon 販売



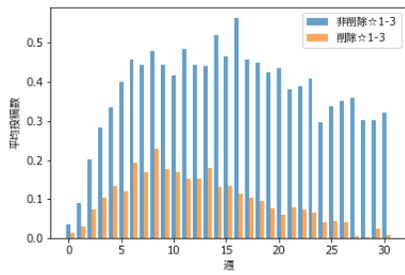
(b) 非 Amzon 販売



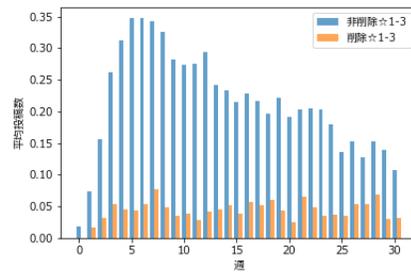
(c) マーケットプレイス



(d) 在庫切れ



(e) 中古のみ



(f) 商品削除

図 14: 低評価レビューのトレンド

削除されていない低評価レビューについては、商品間で明らかな違いはなく、基準週以後増加する。一方で、総合点については、基準週で評価が大きく伸びるのは共通しているが、Amazon 販売の商品では基準週以降も評価を維持するのに対し、Amazon 以外が販売する商品については、評価が低下する傾向にある。疑わしいレビューが集中する週の評価は高いものの、それ以降評価が落ちているといえ、フェイクレビューに欺かれて購入し、低評価レビューを投稿している消費者の存在が伺える。

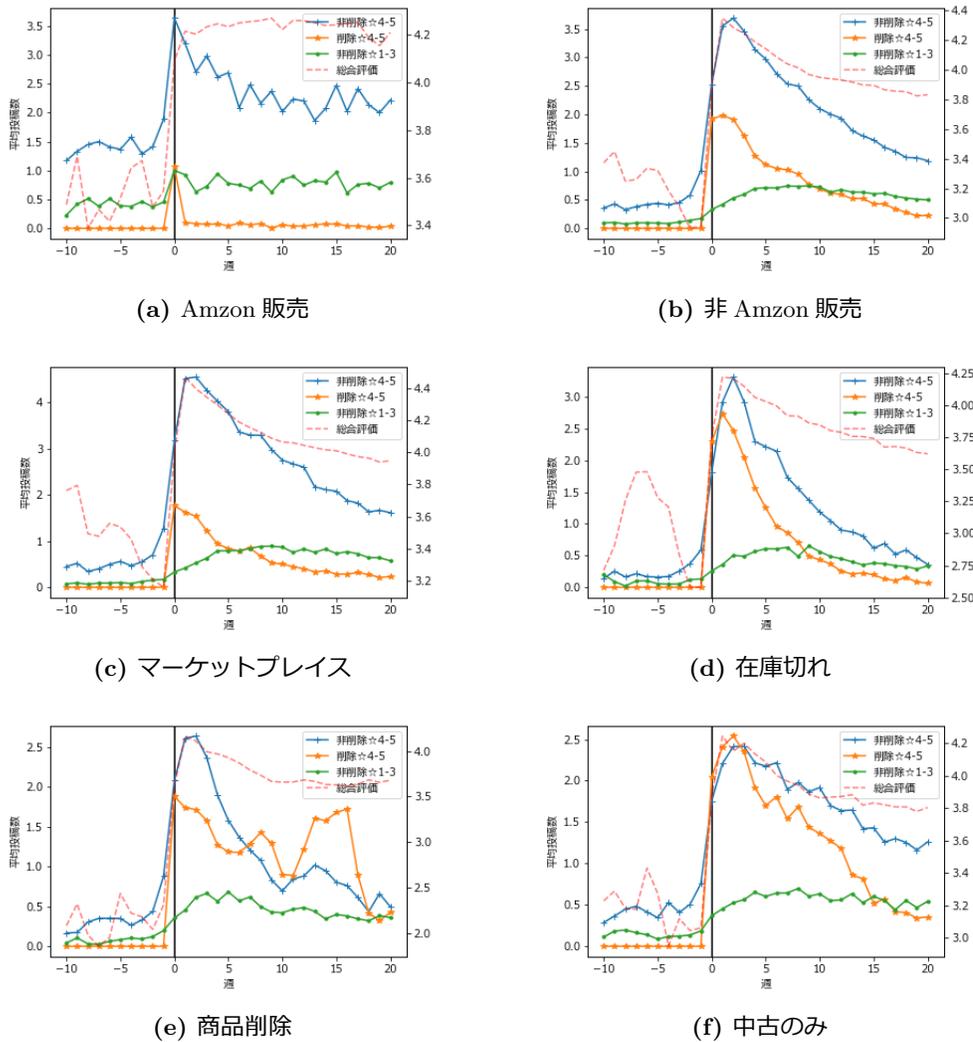


図 15: 削除された高評価レビュー投稿開始後のレビューのトレンド

フェイクレビューの集中

次に、どれほど疑わしいレビューが集中して投稿されるかについて確認する。レビューが短期間に集中して投稿される場合、最も多く投稿された週と、その近くの週に多く投稿されることが予想される。

そこで、各商品について、最も削除された高評価レビューの投稿が多い週を基準⁶¹に、その前後 10 週についての投稿数の平均を示したものが図 16 である。これは、縦軸に *4 と *5 のレビューの、それらの週における投稿数の商品間の平均値をとった折れ線グラフである。

削除状況に関わらず、高評価レビューは基準週で最も多く投稿されている。ただし、削除されたものはより顕著に基準週に集中する傾向がみられる。また、Amazon が販売する商品については、削除されたレビューの数自体が非常に少ない

(c) から (f) のどのセラーの商品についても基準週に削除状況に関わらずレビューが集中する傾向は変化しない。しかしながら、疑わしいセラーの商品については、削除された高評価レビューの数が、削除されていないレビューと比べ相対的に大きくなっている。

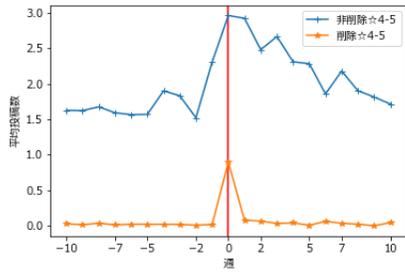
同様のグラフについて、縦軸に投稿数ではなく、商品内における相対度数をとったものが以下の図 17 である。オレンジの線が、各商品についての、*4 と *5 の削除されたレビューの総数に対する各週での投稿数の割合を、青の線が削除されていない *4 と *5 のレビューの同様の割合の平均となる。

(a) から (f) のいずれの商品の分類においても、基準週に投稿された高評価の削除されたレビューの数の相対度数は、平均して 0.5 以上となっている。一方で、基準週以外での相対度数は、おおよそ 0.1 以下の水準にとどまる。削除されていない高評価のレビューの相対度数は、基準週で最大となるものの、その数値は 0.1 から 0.2 程度と大きくない。基準週以外での相対度数とも大きく変化しない。

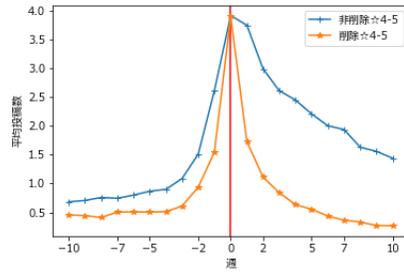
コンスタントに投稿され、相対度数が平坦な傾向を見せる削除されていない高評価レビューと比べ、削除された高評価レビューは極端に基準週に集中しているといえる。疑わしいレビューの過半数が基準週に顕著に集中しており、フェイクレビューが短期間に集中して投稿され、商品の評価を歪めている可能性が伺える⁶²。

⁶¹ レビューが削除されなかった商品については対象外としている。

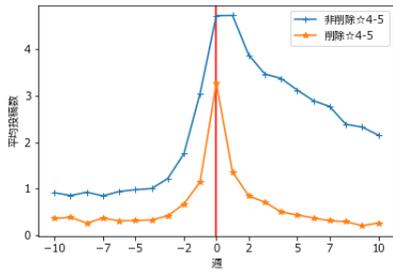
⁶² フェイクレビューである可能性が低い、Amazon が販売する商品についても、削除された高評価レビューが基準週に集中している。これは、削除されたレビュー自体が少ない関係で、基準週に全ての削除された高評価レビューが投稿されることが多いゆえである。商品を削除されたレビューの数が一定数のものに限定する場合、Amazon が販売する商品については、他の分類の商品と比べて基準週に集中しない傾向がある。また、他の分類の商品についても、基準週における相対度数の平均は 0.25 程度に減少する。



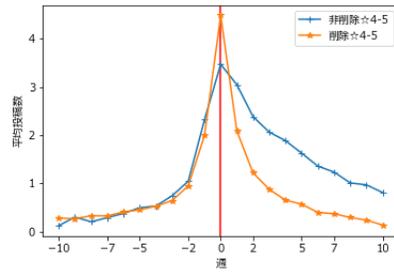
(a) Amzon 販売



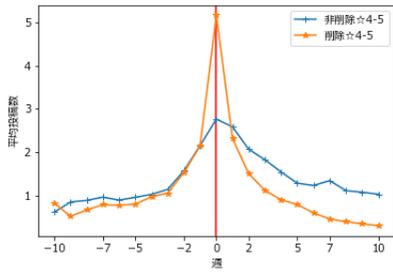
(b) 非 Amzon 販売



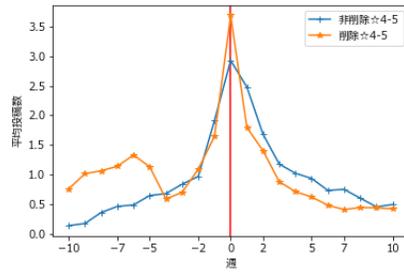
(c) マーケットプレイス



(d) 在庫切れ

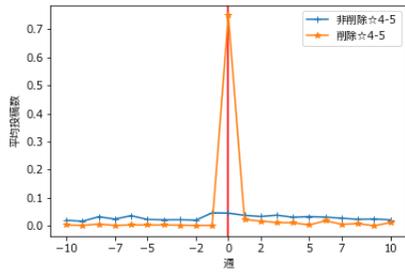


(e) 中古のみ

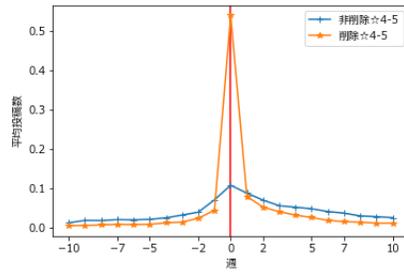


(f) 商品削除

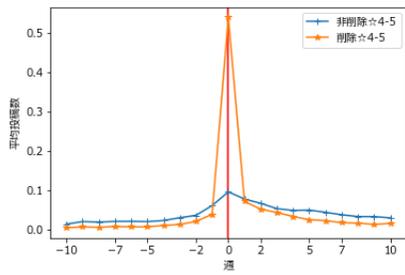
図 16: 削除された高評価レビューが最大となる週近辺におけるレビューのトレンド



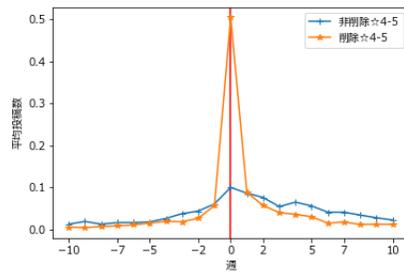
(a) Amzon 販売



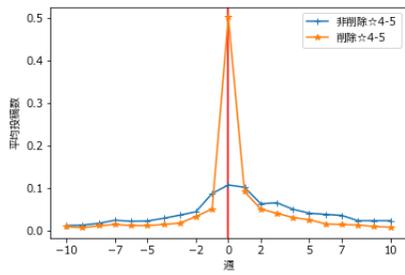
(b) 非 Amzon 販売



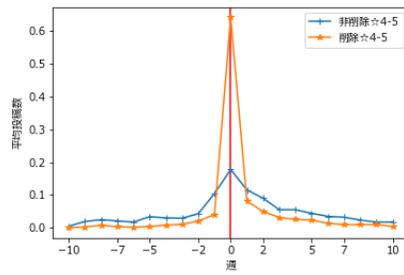
(c) マーケットプレイス



(d) 在庫切れ



(e) 中古のみ



(f) 商品削除

図 17: 削除された高評価レビューが最大となる週近辺のレビューのトレンド (相対度数)

6.3 メソドロジーと結果

6.3.1 モデル

本節では、Luca and Zervas (2016) を参考に、レビューが時系列上においてどのように投稿されるか、どのような経済的インセンティブに反応して投稿されるかについて、これらを明らかにするためのモデルを構築する。

t 期の商品 k について、フェイクレビューの投稿量を f_{kt} とし、時系列や経済的インセンティブに関わる変数ベクトルを x_{kt} とする。これらの関係を (15) で表す。

$$f_{kt} = x'_{kt}\beta + \mu_t + b_k + \epsilon_{kt} \quad (15)$$

ここで、 b_k は商品 k の固定効果であり、 μ_t は t の固定効果となる。 ϵ_{kt} は独立な誤差項である。主な関心の対象は、 x_{kt} の係数 β である。

しかしながら、このモデルは F_{kt} が観察できないことから、実際には推定することができない。観察可能なのは、個別のレビューが削除されたか否かである。4章で述べたように、Amazon のアルゴリズムの誤検知や他の規約違反などで、真のレビューが削除される偽陽性のケースが考えられるため、測定誤差の問題が生じる。そこで、同様に、測定誤差について、以下のように仮定する。 t 期の商品 k のレビュー i が削除された場合に 1 となるダミー変数を d_{ikt} とする。真のレビューであるのに削除されてしまう偽陽性の確率を α_0 、実際にフェイクレビューが削除される真陽性の確率を $\alpha_0 + \alpha_1$ とする。ここで、 α_0 と α_1 について、 $\alpha_0 \geq 0$ かつ $\alpha_1 > 0$ と $\alpha_0 + \alpha_1 \leq 1$ を仮定する。 d_{ikt} は (16) のように書ける。

$$\begin{aligned} d_{ikt} &= \alpha_0(1 - f_{ikt}) + (\alpha_0 + \alpha_1)f_{ikt} + u_{ikt} \\ &= \alpha_0 + \alpha_1 f_{ikt} + u_{ikt} \end{aligned} \quad (16)$$

ここで、 f_{ikt} は個別のレビューがフェイクである場合 1 となるダミー変数である。 d_{ikt} の和をとることで、 t 期の商品 k において削除されたレビューの数は、(17) で表せる。

$$\begin{aligned} d_{kt} &= \sum_{i \in \mathcal{K}_t} d_{ikt} \\ &= \sum_{i \in \mathcal{K}_t} (\alpha_0 + \alpha_1 f_{ikt} + u_{ikt}) \\ &= \alpha_0 n_{kt} + \alpha_1 f_{kt} + u_{kt} \end{aligned} \quad (17)$$

ここで、 \mathcal{K}_t は t 期の k のレビューの集合、 n_{kt} は \mathcal{K}_t の濃度を示す。また、 $f_{kt} = \sum_{i \in \mathcal{K}_t} f_{ikt}$

かつ $u_{kt} = \sum_{i \in \mathcal{K}_t} u_{ikt}$ である。これに (15) を代入して、

$$\begin{aligned} d_{kt} &= \alpha_0 n_{kt} + \alpha_1 (x'_{kt} \beta + \mu_t + b_k + \epsilon_{kt}) + \epsilon_{kt} \\ &= \alpha_0 n_{kt} + x'_{kt} \tilde{\beta} + \tilde{\mu}_t + \tilde{b}_k + \tilde{\epsilon}_{kt} + u_{kt} \end{aligned} \quad (18)$$

ここで、 $\tilde{\beta} = \alpha_1 \beta$ 、 $\tilde{\mu}_t = \alpha_1 \mu_t$ 、 $\tilde{b}_k = \alpha_1 b_k$ 、 $\tilde{\epsilon}_{kt} = \alpha_1 \epsilon_{kt} + u_{kt}$ となる。 d_{kt} は観察できるため、(18) の推定は可能である。これにより、構造パラメータ β 自体は得られないものの、誘導系パラメータ $\tilde{\beta} = \alpha_1 \beta$ を得ることができる。また、 α_1 は正であるため、 β の符号は、 $\tilde{\beta}$ は β と等しくなる。

識別

固定効果の導入により、商品ごとの時間不変なショックや、時期に共通なショックはコントロールされている。懸念されるのは、説明変数 X_{kt} と誤差項である u_{kt} との相関についてである。 u_{kt} は削除プロセスの誤差項からなり、観察されない削除されやすさに影響を与える属性といえる。

この内生性の問題に対処すべく、レビューの削除プロセスをコントロールする。 u_{ikt} について、以下のようなモデルを仮定する。ここで、 η_{ikt} は独立な誤差項である

$$u_{ikt} = Z'_{ikt} \gamma + \eta_{ikt} \quad (19)$$

これを (18) に代入し、

$$d_{kt} = \tilde{\beta} + \tilde{\mu}_t + \tilde{b}_k + \tilde{\epsilon}_{kt} + \gamma \sum_{i \in \mathcal{K}_t} Z'_{ikt} + \eta_{kt} \quad (20)$$

が得られる。ここで、 $\eta_{kt} = \sum_{i \in \mathcal{K}_t} \eta_{ikt}$ である。レビューの削除に影響を与える変数 Z'_{ikt} の和を加えることにより、レビューの削除のされやすさをコントロールする形になる。

6.3.2 推定結果

フェイクレビューのトレンド

★4 から 5 の削除されたレビューを被説明変数に (20) を推定した結果を示したものが、表 13 である。比較のため、削除されていない高得点のレビューについても併記している。また、時系列上のフェイクレビューの変化を確認するという目的から、削除されたプロダクトは分析対象から除外している。

推定にあたって、時系列や経済的インセンティブに関わる変数に関する変数として用いたのは、発売 5 週以内を示すダミー⁶³、販売からの経過週数、Amazon からの削除が始まって以後を示すダミー、非削除レビューの得点の移動平均の差分が負か否か⁶⁴を示すダミー変数の 1 期ラグである。これらに疑わしいレビューがどのように反応するかについて調査する。

更に、マーケットプレイスで販売される商品は、フェイクレビューを用いるインセンティブが相対的に強く、より疑わしい商品といえる。これらの商品については、Amazon 以外のセラーが販売する商品を示すダミー変数⁶⁵との交差項を導入している。

まず、時期に関する変数について、カラム (1) をみると、発売開始 5 週以内で有意に削除された高得点のレビューが約 0.056 増加する。交差項も有意に正となっており、マーケットプレイスで販売される商品では、削除された高得点のレビューが追加的に約 0.056、合計で約 0.11 増加する。一方で、販売からの経過週数は有意な影響を与えているとは言えない結果といえる。

カラム (2) では、発売開始 5 週以内では削除されない高得点レビューが有意に約 0.062 減少する。交差項は有意に正であり、マーケットプレイスで販売される商品では、削除されない高得点のレビューが追加的に約 0.056 増加するものの、合計では約 -0.002 と係数が 0 に近い。販売からの経過週数についても、有意に影響をおよぼすものの、同様に影響力は小さい。

レビューが評価に反応しているかについては、非削除レビューの移動平均が減少傾向にあるタイミングは、(1) と (2) の両方で有意に負となっており、係数の大きさも近い値となっている。交差項についても有意とはいえず、セラーが Amazon か否かで反応に有意な違いがあるとはいえない。レビュー自体がこのタイミングで減少することが伺える。

疑わしいレビューは初期に集中する結果となっている。レビュー自体が初期に集中する可能性については、削除されていない高評価レビューが初期に特に増加しないことから否定される。一方で、疑わしいレビューは、非削除レビューの得点が減少したタイミングに反応して投稿されず、むしろ減少タイミングで同時に減少する。フェイクレビューは初期に集中して投稿されることを支持する結果となっている。

次に、削除の開始にどのように反応するか確認する。(1) では、削除開始以後は有意に削

⁶³5 週以外のダミーを用いた結果については、Appendix を参照。

⁶⁴5 週移動平均を用いている。販売から 5 週に満たないものは、計算可能な最大の週数を用いる。例えば、発売から 4 週目なら 4 週移動平均となる

⁶⁵これ自体は商品の固定効果と完全なマルチコを起こす関係上用いられない。

除された高評価レビューが変化するとはいえない。しかしながら、交差項については有意に負となっており、非 Amazon の商品については、約-0.173 減少する。他方、(2) では、削除の開始は、削除されない高得点レビューの投稿数に有意な影響をもたらしているとはいえず、係数も正である。

レビューの削除は、疑わしいレビューの投稿を減少させることが可能といえる結果となっている。単にレビューの削除開始時期が、投稿の減少する時期と被っているという懸念については、削除されない高評価レビューの変化が有意とはいえない水準であるものの正であり、レビュー自体が減少する時期にあたるとは考えにくい。Amazon 側からの対処がフェイクレビューを抑制することが伺える結果といえる。

被害の推定

フェイクレビューに欺かれた被害を、直接推定することは、実現可能性が極めて低い。どれほどの消費者が欺かれて商品を購入し、それらの商品の実態についても把握することが必要だが、これらのデータの取得は不可能に近い。

一方、先述したように、フェイクレビューが蓄積されたのちに投稿されるレビューは、商品の実態についての消費者の評価といえる。そこで、He et al. (2022b) にならい、削除されていない低評価レビューを用い、間接的に被害について推定する。削除されていない低評価のレビューは、低評価の真のレビューのプロキシであり、商品が期待と異なるものであった結果ととらえることができる。これが仮にフェイクレビューの投稿開始後に増加していた場合、それはフェイクレビューによる被害と解釈できる。

ただし、本研究においては、He et al. (2022b) と異なり、フェイクレビューの投稿開始タイミングを把握することはできない。代わりに、疑わしいレビューの集中を考慮し、プロキシを用いて分析を行う。本節で示したように、*4-5 の削除されたレビューは、販売初期に増加する。また、図 17 で確認したように、この疑わしいレビューが最も多い週を基準週とすると、その基準週に疑わしいレビューの大半が投稿されており、極端に集中する傾向がある。そのため、この基準週の周辺でフェイクレビューの投稿が開始された可能性が大きい。

本研究はこの基準週⁶⁶をフェイクレビューの投稿が開始された時期プロキシとして扱い、基準週から一定期間以降に疑わしいレビューが増加するか否かを推定することを通じ、フェイクレビューの被害について検証する。

基準週から 3 週間以降のダミーを追加し、*1 から 3 の削除されていないレビューを被説

⁶⁶削除された高評価のレビューが最初に投稿された時期を基準週とした推定結果など、本章の異なる特定化については Appendix A に記載している。

表 13: 高評価レビューについての推定結果

	(1) 削除 ★4-5	(2) 非削除 ★4-5
販売開始 5 週以内	0.056* (0.024)	-0.062** (0.024)
販売開始 5 週以内 * 非 Amazon 販売	0.058* (0.027)	0.060* (0.027)
販売からの経過週数	0.000 (0.001)	-0.001* (0.001)
販売からの経過週数 * 非 Amazon 販売	-0.001 (0.001)	0.004*** (0.001)
削除開始以後	-0.048 (0.043)	0.032 (0.042)
削除開始以後 * 非 Amazon 販売	-0.173*** (0.051)	0.071 (0.050)
1 期ラグ非削除レビュー移動平均低下	-0.014 (0.014)	-0.045** (0.017)
1 期ラグ非削除レビュー移動平均低下 * 非 Amazon 販売	-0.044 (0.026)	-0.015 (0.028)
レビュー数	0.146*** (0.035)	0.653*** (0.035)
切片	0.043 (0.042)	-0.125** (0.041)
<i>N</i>	163903	163903

Standard errors in parentheses

* $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$

コントロールに用いるレビューの属性や固定効果については省略している。

明変数に推定した結果を示したものが、表 14である。削除されていない低評価のレビューを被説明変数とした主たる推定結果はカラム (1) であり、比較のため、削除されていない高得点のレビューと、削除されていない低評価レビューの低評価高評価のレビューに対する比⁶⁷も併記している

(1) は、基準週から三週以後は、有意に削除されていない低評価のレビューが有意に約 0.169 増加する結果を示している。ただし、Amazon 以外のセラーとの交差項については有意とはいえず、セラー間で顕著な差がみられない。ただし、Amazon 以外のセラーが販売する商品においては、5 週以内では、削除されていない低評価レビューが有意に減少しており、販売から 5 週以降に低評価レビューが増加していることがわかる。

(2) では、削除されていない高評価レビューは有意とはいええない水準であるものの、交差項は有意に正となっており、Amazon 以外が販売する商品においては、削除されていない高評価レビューが追加で約 0.58 増加し、合計で 0.49 増加する。ただし、低評価レビューの割合については、(3) において、基準週から三週以後に有意に約 0.06 増加しており、低評価のレビューの方が相対的に多く増加していることが分かる。

これらの結果からは、フェイクレビューの蓄積後に、真の低評価レビューが増加していることが支持される結果となっている。間接的ではあるものの、消費者被害が生じていることが示唆される。

6.4 おわりに

本章では、レビューの不正操作の時系列上のトレンドを明らかにすべく、削除された高評価のレビューの数をフェイクレビューのプロキシとして用い、パネルデータ分析を行った。推定の結果、主に 3 つの知見が得られた。第一に、削除された高評価レビューは、販売から 5 週以内に有意に増加し、不正のインセンティブが高い Amazon 以外のセラーだと更に有意に増加する。一方で、削除されていない高評価のレビューは、Amazon が販売する商品で有意に減少し、Amazon 以外のセラーでは、ほとんど影響を受けない。発売から間もない時期に疑わしいレビューのみが顕著に集中している結果であり、販売初期にフェイクレビューを集中投入することにより評価を歪める、所謂“売り逃げ”が目的であると判断できる。また、フェイクレビューの判別が困難であり、被害が大きくなるパターンに該当する。

第二に、Amazon からの削除が開始されると、削除されていない高評価レビューの投稿数は有意といえる影響を受けない一方で、Amazon 以外のセラーが発売する商品でのみ、有

⁶⁷削除されていない低評価レビューの投稿数を、高評価のレビューの投稿数 +1 で除したもの。+1 をしたもので割るのは、ゼロ除算回避のため。

表 14: 低評価レビューについての推定結果

	(1) 非削除 *1-3	(2) 非削除 *4-5	(3) 非削除 *1-3 率
基準週 3 週以後	0.169** (0.060)	-0.095 (0.051)	0.057** (0.021)
基準週 3 週以後 * 非 Amazon 販売	0.035 (0.063)	0.583*** (0.073)	0.009 (0.022)
販売開始 5 週以内	0.004 (0.018)	-0.067** (0.023)	-0.018* (0.008)
販売開始 5 週以内 * 非 Amazon 販売	-0.078*** (0.020)	0.120*** (0.029)	-0.033*** (0.009)
販売からの経過週数	0.000 (0.000)	-0.001* (0.001)	0.000 (0.000)
販売からの経過週数 * 非 Amazon 販売	-0.003*** (0.001)	0.003** (0.001)	-0.001*** (0.000)
削除開始以後	-0.036 (0.041)	0.078 (0.049)	0.013 (0.018)
削除開始以後 * 非 Amazon 販売	0.039 (0.044)	-0.245*** (0.065)	-0.019 (0.019)
1 期ラグ非削除レビュー移動平均低下	0.054** (0.017)	-0.041* (0.016)	0.016* (0.008)
1 期ラグ非削除レビュー移動平均低下 * 非 Amazon 販売	0.052** (0.019)	-0.054* (0.027)	0.047*** (0.009)
レビュー数	0.185*** (0.016)	0.661*** (0.035)	0.024*** (0.003)
切片	0.099*** (0.014)	-0.064 (0.042)	0.096*** (0.005)
<i>N</i>	163903	163903	163903

Standard errors in parentheses

* $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$

意に高評価の削除されたレビューが減少する。フェイクレビューが Amazon に検知されて以降は数を減らしており、不正を行う売り手がフェイクレビューの募集を停止するなど、Amazon 側の対処に反応していると考えられる。Amazon が早期にフェイクレビューに対処できるようになるほど、フェイクレビューが抑制され得ることが示唆される。

第三に、削除された高評価レビューが集中するタイミングの後に、削除されていない低評価レビューが有意に増加する。不正が行われた商品においてフェイクレビューが初期に集中したのちに、低評価の真のレビューが投稿されていることが示唆される結果となっている。こうした低評価のレビューは、商品の実態を低く評価するものであると解釈可能であり、商品の実態が低品質なもので、実際に消費者が欺かれて購入する被害が生じていることがいえる。

本章には、いくつかの課題がある。まず、4 章と 5 章と同じく、フェイクレビューや不正に関与している商品や売り手を直接観察できていない点があげられる。フェイクレビューが実際に投入される時期も特定できておらず、分析においては、全てプロキシを用いている。共通する課題として、より高精度の把握が求められる。

また、フェイクレビューの影響について分析しているものの、低評価のレビューが増加していることを示しているに過ぎず、He et al. (2022b) と同様に、間接的なエビデンスに留まる。消費者余剰の減少についての定量的な評価など、レビューの不正操作の影響をより直接的に推定することが求められる。

第 7 章 実験データを用いたフェイクレビューの影響の調査

7.1 はじめに

6 章までは、観察データを用いて、どのような売り手が不正を行っているのかなど、レビューの不正操作の詳細について明らかにしてきた。主にどのような売り手が不正を行っているかについての分析であり、レビューの不正操作がもたらす影響については間接的なエビデンスを提供したに過ぎない。

1 章と 2 章で整理したように、今後の施策や規制を検討するうえでは、フェイクレビューの下で消費者がどのような影響をも受けるのかについても明らかにする必要がある。しかしながら、商品レベルの観察データの分析では、これらの点を明らかにするには限界がある。先行研究においても He et al. (2022b) が、フェイクレビューが売上を増加させ、欺かれる消費者が存在することを示唆する結果に留まる。個人レベルでの実際の選択行動を把握する必要があり、そのためには、実験によるアプローチが適している⁶⁸。

また、現状考えられ得る施策や、EC サイトの仕様についても評価を行う必要がある。しかしながら、現状のところ、近年において Amazon での大規模なシステムの変更は行われていない。観察データ上でデータバリエーションがそもそも存在せず、効果の検証は不可能である。これらの介入等を制御したデータを獲得することができるという点でも、実験による分析が求められている。

実験を用い、レビューの不正操作について分析した研究の例は少なく、Akesson et al. (2023) が存在するものの、再現できる状況や介入が限定される実験の性質から、また外的妥当性の担保のため、様々な角度からの実証分析が蓄積されることが必要となる。

そこで、本章では、Amazon を模した web サイトでのオンライン実験により、消費者がレビューの不正操作から受ける影響について明らかにする。被験者は、デジタルカメラ・ヘッドフォン・スマートウォッチの 3 カテゴリーの商品を対象に、実験サイト上で実際に商品の選択を行う。

実験を通じ、特に以下の 3 点について分析を行う。第一に、フェイクレビューのプロキシとして削除されたレビューを表示する介入を行い、消費者がどのような影響を受けるかを明らかにする。特に、フェイクレビューがどれだけ消費者を欺き、消費者の選択がどのように歪むのかについて明らかにする。

⁶⁸同意を得た消費者にトラッキングを行うなどの方法も考えられるが、コストやプライバシー保護の面で現実的ではない。

第二に、商品表示順を変更する介入により、フェイクレビューの下での商品表示システムについて評価する。Amazonの商品表示のオプションは、先述したように、時にフェイクレビューの効果を悪化させる恐れがある。具体的には、レーティングの評価順で商品を表示する場合、フェイクレビューによるレビュー操作の下で、不正が行われた商品を上位に表示しやすくなってしまふ。

第三に、実験サイトにフェイクレビューを警告する文章を表示することで、教育的介入がフェイクレビューの被害を減少させるかについて検証する。教育的介入はフィルタリングの強化などの施策と異なり、フェイクレビューや、フェイクレビューと誤認された真のレビューを直接減少させるものではない。仮にフェイクレビューがそこまで有害でなくレビュー自体が減少するトレードオフの方が大きい場合や、フェイクレビューがむしろ消費者にとって有益なシグナルとなっている場合には、穏当な介入として好ましい。

7.2 実験設計

7.2.1 実験の概要

本実験は、マイボイス社を通じ、2023年3月にオンライン上の実験サイトで行われた。実施にあたっては、同社のモニターを対象に、約5000人の被験者を募集した。この際には、同社からモニターへのメールに調査期間の詳細が記載され、この調査が学術研究者による実施であることも伝えられた。参加者には250円相当のポイントが付与され、ごく一部の被験者には実験で選択した商品が贈られることも伝えた。募集は、性別・年齢別に、回答者数が日本のネットユーザーの分布に応じた目標数に達するまで行われ、最終的に6000人のモニターが実験に参加した。

実験では、被験者にネット通販の利用経験など現在の状況を尋ねた。その後、被験者にオンラインショップを模したページを提示し、実際に商品を選択させる。商品の選択は二段階に分かれており、第一段階では、Amazonを模した実験サイトでの商品選択が行われる、被験者は、最も欲しい商品を選択するか、全ての商品が不要かを回答する。第二段階では、いずれかの商品が欲しいと回答した被験者に対し、実験の報酬である商品の抽選について、第一段階で選択した商品をそのまま抽選の対象とするか、マイボイス社のポイントを同じ確率で代わりに抽選の対象とするかを選択させる。この選択を、デジタルカメラ・ヘッドフォン・スマートウォッチの3つのカテゴリに全て対して行わせのち⁶⁹、最後に

⁶⁹ロバストネスチェックのために、罫となる設問を、二番目と三番目のカテゴリの選択での終了後に設けている。これは、Bottan and Perez-Truglia (2022) を参考に設定を行った。

感想等を質問して実験終了となる。

7.2.2 実験サイトの基本設計

被験者は、Amazon を模した実験用のウェブサイトで第一段階の商品の選択を行う。第一段階でいずれかの商品を選択した場合、抽選の対象を選択する画面に推移する。第一段階を行う実験サイトは、商品一覧ページと商品詳細ページ、レビューページの3つのページで構成され、被験者はこの3つのページを自由に行き来して商品を探索・選択する。図19は、各ページを抜粋したものの⁷⁰である。

商品一覧ページ

商品一覧ページは、Amazon の商品一覧ページを模したものである。ここでは、商品の画像・総合評価・評価数が表示される。縦長の画面であり、スクロールしない限りは全ての商品を把握することはできないようになっている。この商品一覧ページで、「商品の詳細を見る」ボタンをクリックすることで、第二のページである、商品詳細ページに遷移する。

総合評価や評価数は Amazon 上におけるレーティングや、テキストがない*のみの評価を含んだ評価数ではなく、投稿された文章つきレビューの平均点と、その本数を用いている。さらに、介入によって計上に用いるレビューが変化する(後述)。

商品詳細ページ

Amazon の商品ページを模したもので、商品一覧ページと同様の評価やレビュー数のほか、商品のスペックと、実際に投稿されたレビューから抜粋・修正された文章付きのレビューが表示される。レビューは点数や投稿日、得票数が付帯し、5件表示される。「レビューをもっと読む」ボタンをクリックすることで、レビュー詳細ページに遷移する。商品の選択は、「この商品を選ぶ」ボタンか「どの商品も欲しくない」ボタンのクリックにより、この画面で行うことになっている。

レビュー詳細ページ

Amazon のレビューページを模したページである。商品詳細ページと同等の内容に加え、追加で5件、合計10件のレビューが表示される。さらに、ページ上部でレビューの両面表示が行われ、肯定的なレビューと否定的なレビューの代表的なものが表示される。

⁷⁰商品や、商品の特定に用いることのできる単語についてはマスキング処理を行ってある。

抽選対象選択画面

被験者が第一段階で、いずれかの商品について、「この商品を選ぶ」ボタンをクリックした場合この画面に遷移する。ここでは、第二段階の選択として、報酬として事前にアナウンスしてある抽選の対象を選ばせる。抽選に当選した場合に第一段階で選んだ商品を得るか、商品ごとに4段階にランダムに設定されたポイントを得るか、この二択のどちらかを選択させる。この際、商品とポイントの選択で抽選確率が変わることはなく、当選した場合に得られる商品の対象を選択させていることがアナウンスされる。

7.2.3 介入

本実験では警告表示の有無（二種）、レビューソースの種別（二種）、商品表示順（三種）、レビュー表示順（三種）、両面提示の有無（二種）の介入を行う。5つの介入のうち、警告表示の有無については擬似乱数生成（PRNG）アルゴリズムであるSHA1PRNGを使用して介入を割り付けた。残りの4つの介入については、Rosenberger (2002) が提案する適合的ランダム化アルゴリズムを用いて被験者を介入の組みあわせからなる36のグループに割り付けた。また、抽選対象の選択における金額と、3つの商品カテゴリが表示される順序についてもランダムに割り当てた。

削除レビューの表示

フェイクレビューが消費者にもたらす影響を調査するために、表示されるレビューと、レビューに基づく総合評価や評価数に対し介入を行う。Amazon から削除されたレビューは、フェイクである可能性が高く、フェイクレビューのプロキシとして利用できる。逆に、削除されていないレビューは消費者の実際のレビューである可能性が大きく、真のレビューのプロキシとして扱える。

レビューについては、トリートメントグループには、フェイクの可能性が大きい、削除されたレビューのみを表示し、コントロールグループに対しては、Amazon 側から削除されずに残ったレビューのみを表示する。総合評価と評価数については、トリートメントグループには、消されなかったレビューと消されたレビューの全てを対象として集計したものを提示する。コントロールグループに対しては、消されなかったレビューのみを対象として集計したものを提示する。

商品表示順



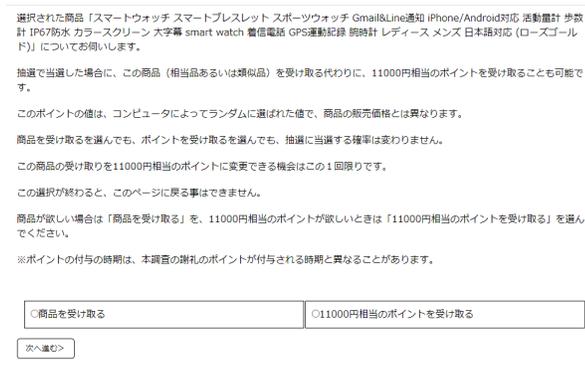
(a) 商品一覧ページ



(b) 商品詳細ページ



(c) レビュー詳細ページ



(d) 抽選対象選択ページ

図 18: 実験サイト抜粋

フェイクレビューの下で、商品の表示順が消費者にどのような影響を与えるかを明らかにするため、商品一覧ページにおける商品の表示順に対し介入する。コントロールグループに対しては、ランダムな順で商品を表示し、一つ目のトリートメントグループに対しては、商品の総合評価の降順に並べる。もう一つのトリートメントグループにはレビューの数の降順に商品を並べる。

特に、レーティング順で商品を並べる場合、フェイクレビューの下では、本来の総合評価が低く、フェイクレビューの投稿により高評価を水増しされているような商品が上位に並びやすくなる。

警告表示

フェイクレビューの下で、教育的介入が消費者に影響をもたらすかについて検証するため、警告文を商品一覧ページに表示する介入を行う。これは、フェイクレビューの存在を警告し、フェイクレビューに欺かれないようにするために、レビューの点数だけでなく、本文をよく読むことなどを推奨するものである。トリートメントグループに対してはこの警告文が表示され、コントロールグループには表示されない。

レビューの表示順

フェイクレビューの下で、レビューの表示順が消費者にどのような影響をもたらすかを明らかにするために、商品詳細ページならびにレビュー詳細ページにおいて、レビューの表示順に対し介入を行う。コントロールグループに対しては、ランダムな順番でレビューを表示する。一つ目のトリートメントグループに対しては、レビューの投稿日付が新しい順に表示し、二つ目のトリートメントグループに対してはレビューの役に立った数の降順に表示する。

両面表示

フェイクレビューの下で、レビューの両面表示が消費者にどのような影響をもたらすかを明らかにするため、商品詳細ページにおいてポジティブなレビューとネガティブなレビューの代表的なものをそれぞれとりあげる両面表示を行う。トリートメントグループに対して表示され、コントロールグループには表示されない。介入が行われるのは、商品詳細ページにおける表示のみで、レビュー詳細ページでは介入に限らず両面表示が行われる。

ISO STORE スマートウォッチ
ISO STORE スマートウォッチ

商品画像	<p>スマートウォッチ 2023 新登場 1.70インチ大画面 100種類運動モード 女性の生理周期リマインダー iPhone&Android対応 Smart Watch 活動量計 腕時計 心拍数 睡眠モニター 着信通知 スマートウォッチ レディース メンズ 誕生日 敬老の日 クリスマス 新年プレゼント</p> <p style="font-size: small;">総合評価★★★★★4.9 (評価数75)</p>	この商品の詳細を見る	<p>各商品の「詳細を見る」ボタンを押すと、商品詳細ページが表示され、そこではユーザーの皆様から投稿されたレビュー（レビュー）をご覧いただけます。商品をお選びいただけます。</p> <p>本サイトでは、ユーザーの皆様から投稿された内容を原則としてそのままレビューとして掲載しています。そのため、事実と必ずしも適合しない投稿や誹謗中傷などが含まれている場合があります。</p> <p>商品についてより正確な情報を得るには、次のことが効果的です。</p> <p>「商品の数」や「評価数」だけでなく、レビューの本文も参照すること 評価が高いレビューと評価が低いレビューの両方を参照すること 不自然な表現が含まれるレビューを避けること</p>
商品画像	<p>IMFRCHCS AMOLEDカラーディスプレイ 活動量計 25種類運動モード SATMの防水機能 LINE・メッセージ・着信・座りすぎ通知 iOS Androidスマートウォッチ 2023最新 歩数計 腕時計 メンズ レディース プレゼントギフト</p> <p style="font-size: small;">総合評価★★★★★4.7 (評価数139)</p>	この商品の詳細を見る	<p>スマートウォッチ 2023 新登場 1.70インチ大画面 100種類運動モード 女性の生理周期リマインダー iPhone&Android対応 Smart Watch 活動量計 腕時計 心拍数 睡眠モニター 着信通知 スマートウォッチ レディース メンズ 誕生日 敬老の日 クリスマス 新年プレゼント</p> <p style="font-size: small;">総合評価★★★★★4.9 (評価数75)</p>
商品画像	<p>スマートウォッチ 1.69インチ大画面 音楽再生コントロール 20種類運動モード おやすみモードメッセージ通知 iPhone&Android対応 レディース 2023新モデル Smart Watch 活動量計 万歩計 腕時計 文字盤自由設定 長持ちバッテリー 明度調整 着信通知/拒否 タイマー スマートウォッチ 懐中電灯 IP68防水 日本語アプリ 技術認証取得済</p> <p style="font-size: small;">総合評価★★★★★4.7 (評価数127)</p>	この商品の詳細を見る	<p>IMFRCHCS AMOLEDカラーディスプレイ 活動量計 25種類運動モード SATMの防水機能 LINE・メッセージ・着信・座りすぎ通知 iOS Androidスマートウォッチ 2023最新 歩数計 腕時計 メンズ レディース プレゼントギフト</p> <p style="font-size: small;">総合評価★★★★★4.7 (評価数139)</p>
商品画像	<p>スマートウォッチ 【Bluetooth5.3&1.57インチ大画面】 smart watch 腕時計 多種類運動モード カラーモニタリング iPhone/Android対応 歩数計 音楽制御 180mAh 着信通知 スマートウォッチ IP68防水 メッセージ通知 LINE通知 天気予報 遠隔撮影 多言語サポート タイマー 短期出張 日本語説明書付き プレゼント/スポーツ/誕生日/母の日/父の日</p> <p style="font-size: small;">総合評価★★★★★4.6 (評価数43)</p>	この商品の詳細を見る	<p>スマートウォッチ 1.69インチ大画面 音楽再生コントロール 20種類運動モード おやすみモードメッセージ通知 iPhone&Android対応 レディース 2023新モデル Smart Watch 活動量計 万歩計 腕時計 文字盤自由設定 長持ちバッテリー 明度調整 着信通知/拒否 タイマー スマートウォッチ 懐中電灯 IP68防水 日本語アプリ 技術認証取得済</p> <p style="font-size: small;">総合評価★★★★★4.7 (評価数127)</p>
商品画像	<p>スマートウォッチ 1.85インチ Bluetooth5.0 24種類運動モード iPhone Android対応 大画面 測定機能 2色ベルト 多機能 スマートウォッチ 活動量計 smart watch 着信通知 メッセージ通知 IP68防水 天気予報 マナーモード メンズ レディース 日本語説明書付き</p> <p style="font-size: small;">総合評価★★★★★4.5 (評価数52)</p>	この商品の詳細を見る	<p>スマートウォッチ 【Bluetooth5.3&1.57インチ大画面】 smart watch 腕時計 多種類運動モード カラーモニタリング iPhone/Android対応 歩数計 音楽制御 180mAh 着信通知 スマートウォッチ IP68防水 メッセージ通知 LINE通知 天気予報 遠隔撮影 多言語サポート タイマー 短期出張 日本語説明書付き プレゼント/スポーツ/誕生日/母の日/父の日</p> <p style="font-size: small;">総合評価★★★★★4.6 (評価数43)</p>

(a) 警告表示なし

この商品を選ぶ

この商品も似しくない

商品説明

ブランド Briskyp

色 ローズゴールド

特徴 活動量, カロリトラッカー, GPS

対象年齢 大人

対応デバイス スマートフォン

この商品のレビュー

評価★★★★★5
2020/11/02

大型化しているスマートフォンと合わせて使用すると楽！

必要な通知がスマートウォッチに届くため、スマホを手に取らなくても平気。

0人が役に立ったと言っています

このレビューは役に立ちました

評価★★★★★4
2020/09/01

普通ではあるけど、防水で便利！

が欲だったので、このスマートウォッチを購入しました。初めはベルトが特殊でつづいきましたが、慣れるとこのタイプは便利だと感じました。バッテリーの持ちも普通程度です。防水なので料理しながら外す必要がなくなりました。お風呂に入る際もつけています。また、音楽制御機能が充実していたのですが、時々入る間はずれていました。個人的に煩雑であり方がないことだと思います。

0人が役に立ったと言っています

このレビューは役に立ちました

評価★★★★★3
2020/06/22

トレーニングにはちょっと不便？

トレーニング機に買ったのですが、スマートウォッチだけで操作できると思っていたので、スマホと連動させる必要があることが少し不便です。ただ、通知や万歩計の機能は備わっているため、コストパフォーマンスは良いと思います。価格が安かったこともあって、この程度の機能で満足しています。

0人が役に立ったと言っています

このレビューは役に立ちました

評価★★★★★1
2020/09/06

品質に不満がありました。

商品を取り取り、時計を誤って使用した後、裏蓋が外れてしまいました。使用不可能になってしまい、とても残念です。

0人が役に立ったと言っています

このレビューは役に立ちました

(c) 両面表示なし

(b) 警告表示あり

この商品を選ぶ

この商品も似しくない

商品説明

ブランド Briskyp

色 ローズゴールド

特徴 活動量, カロリトラッカー, GPS

対象年齢 大人

対応デバイス スマートフォン

この商品のレビュー

評価★★★★★3.3 (評価数380)

この商品のレビュー

評価★★★★★4
2020/04/13

シンプル

必要な機能に絞り込まれていて、非常に使いやすいです。

0人が役に立ったと言っています

このレビューは役に立ちました

評価★★★★★4
2020/09/27

LINE通知が届かないのが残念

スマートウォッチを使い始めてから、LINEの通知が届かないことがあります。色々設定を変えてみたのですが、改善されないので残念です。他のアプリや機能は煩雑なく使えるので、それ以外は満足しています。

0人が役に立ったと言っています

このレビューは役に立ちました

評価★★★★★4
2020/02/15

良い感じですが

腕を揺らすと電圧が上がるので、電圧が計測しにくくなるようです。最初には推奨設定で使っていたのですが、2日で充電が切れてしまいました。現在は感度を下げているため、4日経過後で使えるようになりました。特に不都合はなく、快適に使っています。つけ心地も良いです。

7人が役に立ったと言っています

このレビューは役に立ちました

(d) 両面表示あり

図 19: 介入の抜粋

7.2.4 使用データ

本実験では、より現実的な状況の下での選択を行わせるため、Amazon の実際のデータを用いて実験サイトを構築する。このデータは、3 章で述べた、Amazon からの高頻度で取得したデータとなっており、その中でデジタルカメラ・ヘッドホン・スマートウォッチの3カテゴリ⁷¹についてのものになっている。レビューに関するデータは、2021 年から、2022 年 9 月まで取得したもので、価格をはじめとした商品の属性については、2022 年 12 月に取得したものをを用いる。レビューの削除状況の確認についても、2022 年 12 月に行っている。

最終的に、約 1 万 8 千のユニークな ASIN⁷²と約 218 万のレビューのデータを収集した。これらの商品についての記述統計量を示したのが表 15 である。いずれのカテゴリにおいても、削除されたレビューは、削除されなかったレビューと比べ、平均的にレビューの点が大きい。ただし、デジタルカメラについては、差が小さく、レビューの削除率も低い。

表 15: 取得データ記述統計

	ヘッドホン		スマートウォッチ		デジタルカメラ	
	Mean	Std	Mean	Std	Mean	Std
レビュー平均点	3.95	0.72	3.61	1.02	4.14	0.59
レビュー平均点 (削除)	4.26	0.83	4.31	0.98	4.12	1.01
レビュー平均点 (非削除)	3.90	0.77	3.51	1.04	4.11	0.62
レビュー数	196.95	412.28	51.08	141.74	58.35	74.54
削除率	0.11	0.20	0.14	0.26	0.06	0.14
市場価格 (千円)	5.68	10.11	12.93	19.29	58.71	87.70
マーケットプレイスの割合	0.60	0.49	0.47	0.50	0.35	0.48
商品数	8536		5183		4073	

実験にあたっては、レビューと商品について、これらの属性が偏らないよう候補を抽出したのち、実験で使用するものを選択する。

最終的に、取得した商品の中から、デジタルカメラ 10 件、ヘッドホン 30 件、スマートウォッチ 30 件を実験で用いる。レビューについては、削除されていないレビューからランダ

⁷¹実験で商品をプレゼントする関係上、広く需要されるものが望ましく、この 3 カテゴリを選択した。

⁷²本章では、特定の商品を実験で用いる関係上、商品をグループで扱う処理は行っていない。

ムに選ばれたうえで修正された 10 件のレビューと、削除されたレビューについて同様に選抜・修正された 10 件のレビューが用いられる。

商品の抽出

実験に使用する商品は、2022 年 12 月の時点において利用可能であり、価格が高すぎず (5 万円以下)、レビュー数が十分あることを条件に、評価とレビュー削除率の分布が偏らないように選択する。

まず、削除されたレビューが 15 件以上、削除されていないレビューが 15 件以上ある商品を各カテゴリで抽出する。この 15 件のレビューから、日本語以外の言語で書かれているものや、後述する書き直し処理が行えないもの、他の商品のレビューと思われるものが混じっているものを取り除く。この処理で、最低 10 件以上のレビューがある商品あるものを候補とする。

残った候補から、カテゴリごとに、消費者評価について 5 タイル、レビュー削除率について 3 タイル、合計 15 のタイルに分割する。各タイルからヘッドホンとスマートウォッチ 3 製品、条件を満たす商品が少ないデジタルカメラについては 1 製品をランダムに抽出し、実験で使用する商品の候補とする。

レビューの選択と処理

各製品のレビューを、レビュー属性が偏らないように選択する。スマートウォッチとヘッドホンについては、評価について 2 タイル、レビュー投票について 2 タイル、レビューの日付について 2 タイル、合計 8 タイルにレビューを分割する。レビュー数が限られる、デジタルカメラについては、評価を基準に 3 つのタイルに分割する。各タイルからランダムに選択されたレビューを実験で使用する候補とする。

さらに、著作権侵害を回避するため、レビューとタイトルの原文をそのまま用いず、GPT アルゴリズムを使って変換を行う。その後、アルゴリズムの出力を確認し、ハルシネーションを削除した。さらに、原文にある誤字脱字等の表現を再現するよう書き換えた。この作業ののち、実験に使用できないものを取り除き、レビューの属性が偏らないよう、各商品について 10 件のレビューを手作業で選択した。

最終的な商品選定

ヘッドホンやスマートウォッチといったカテゴリは、データ取得時の Amazon 上の分類に依存する。そのため、これらの中には、各カテゴリの関連商品も含まれており、実験で提

示するには適切でないものも含まれている。例えば、ヘッドホンのカテゴリには、ヘッドホン用の充電器やケーブルが含まれている。これらの商品と最終的な商品選定時である23年2月の時点では在庫がない商品を候補から取り除く。

こうした商品の選抜を行った後でも、更に目標数より多くの商品が残ったため、評価や削除率、レビューの情報が幅広く含まれるように、デジタルカメラは10商品、ヘッドホンとスマートウォッチは30商品を手動で抽出した。

最終的に実験に用いられた商品とレビューについての記述統計を示したものが以下の表16である。総合評価や評価数は、実験で提示されるものと同じく、各商品におけるレビューの平均をとったものであり、削除レビューを表示するケースに対応したすべてのレビューから計算されたものと、削除されていないレビューを表示するケースに対応した削除されていないレビューのみ対象に計算したものの両方を記している。

表 16: 商品記述統計

カテゴリ		Mean	SD	Min	Median	Max
デジタルカメラ	総合評価	3.996	0.289	3.548	4.042	4.369
	総合評価 (非削除)	3.613	0.665	2.111	3.687	4.444
	評価数	180.900	144.130	27.000	146.000	401.000
	評価数 (非削除)	125.800	130.884	7.000	94.500	351.000
	市場価格	18.212	14.924	4.290	13.160	44.579
	削除率	0.186	0.176	0.029	0.135	0.519
ヘッドホン	総合評価	4.361	0.332	3.800	4.357	4.900
	総合評価 (非削除)	4.224	0.492	2.765	4.279	4.867
	評価数	527.467	475.013	71.000	287.500	1596.000
	評価数 (非削除)	349.333	352.849	17.000	185.000	1381.000
	市場価格	4.986	5.599	0.980	3.749	30.113
	削除率	0.212	0.171	0.036	0.177	0.732
スマートウォッチ	総合評価	4.162	0.405	3.340	4.206	4.939
	総合評価 (非削除)	3.880	0.557	2.786	3.871	4.933
	評価数	236.567	260.107	41.000	117.000	977.000
	評価数 (非削除)	141.200	161.776	19.000	73.000	663.000
	市場価格	4.066	1.040	1.999	4.189	5.999
	削除率	0.276	0.175	0.036	0.255	0.733

7.2.5 メソッドロジー

関心の対象は、消費者がレビューの不正操作から受ける影響であり、特にどれだけの消費者被害が生じているかである。被害が生じるのは、粗悪な商品が高く評価されているように操作され、消費者が偽装に気づかずに購入してしまうようなケースとなる。したがって、フェイクレビューの存在が、消費者に選ばれた商品の品質をどのように変化させるか、消費者がどれだけ低品質な商品に誘導されるかが肝要となる。

商品の品質に係る変数は、売り上げや商品の属性、Amazon 内外の評価など、いくつかの候補が考えられる。例えば、Akesson et al. (2023) は消費者団体 Which? の判定を用いている。本実験では、削除されていないテキストつきレビューの平均点を主なアウトカムとして分析を行う。削除されていないレビューは、消費者による真のレビューである可能性が高いため、これは実際の消費者により判断された品質として扱うことができる。

7.3 実験結果

7.3.1 記述統計

実験の第一段階において、最初に閲覧した商品と、最終的に選択された商品について、商品の表示順との関係を示した折れ線グラフが、図 20 である。図の左側 (a) は、最初に閲覧された商品について、横軸は商品が上からの何番目にあるか、縦軸は閲覧回数を示す。図の右側 (b) は、最終的に選択された商品について、横軸は同様の商品の順番、縦軸は商品が選ばれた回数を示している。

(a) は、消費者がどの商品を最初にクリックするかと、商品の順番の関係を示すもので、どのカテゴリでも、上位商品に閲覧が偏る形となっており、上位の商品が最初にチェックされやすいことを示している。一方、(b) は、最終的な選択と商品の表示順の関係を示したものであり、(a) と比べ平坦となっている。最終的な商品の選択については、探索行動と比べて相対的に、表示順に関係なく商品が選択されていることが伺える。

次に、図 21 は、カテゴリごとに、表示するレビューや商品表示順への介入の下での最終的に選択された商品と、表示順との関係を示したものである。青線が削除されていないレビューのみ表示されたグループを示し、赤線が削除されたレビューのみ表示されたグループを示す。横軸は商品の表示順であり、縦軸は商品が選ばれた回数を示している。

各カテゴリにおける、左の折れ線グラフは、商品の順番を各個人にランダムに割り当てた場合に、その順番の商品を最も欲しい商品として選択した参加者の数を示している。これは、消費者が商品の属性に関係なく、リストの一番上の商品をクリックする傾向を示して

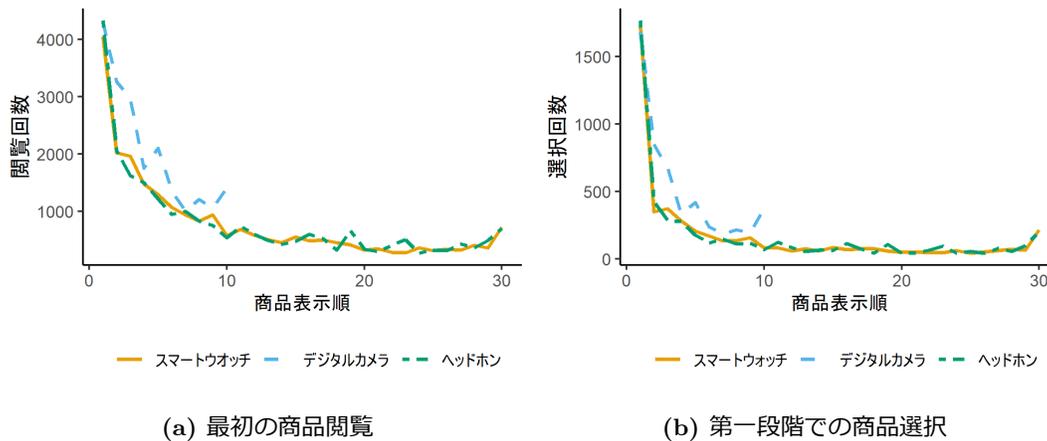
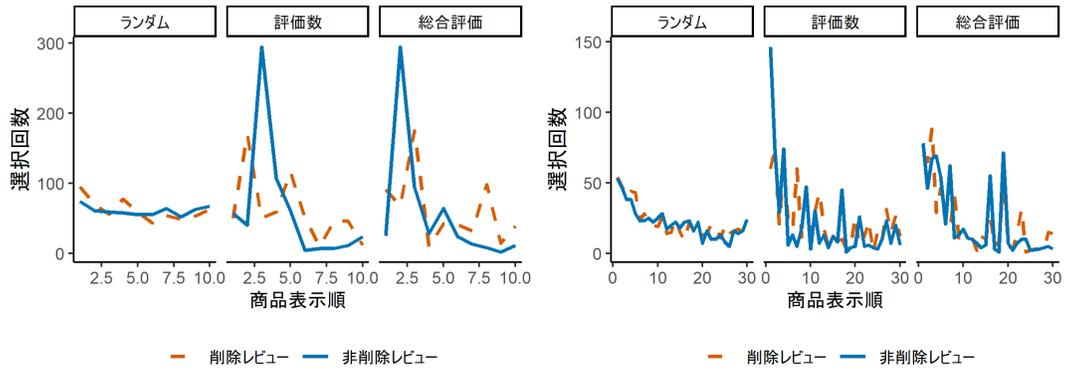


図 20: 商品の選択と商品表示順

いる。また、この傾向は削除されたレビューを表示するか否かで変化しない。デジタルカメラ (a) は他 2 カテゴリと異なり 10 商品しかないため、単純に比較できないものの、ほぼ平坦に選択される。ヘッドホン (b) やスマートウォッチ (c) では上位に表示される商品が選ばれやすい傾向はあり、上位の商品は下位の商品の 2 倍以上の頻度で選ばれているが、被験者の選択が顕著に偏るわけではなく、下位の商品についても一定の比率で選択している。また、上位の商品を選び、早期に実験を終了しているとは考えにくい結果といえる。

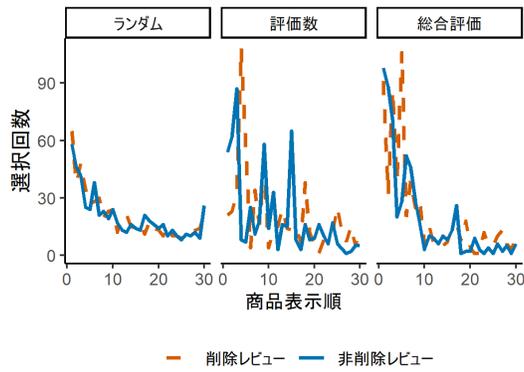
中央と右の折れ線グラフは、評価数の降順に商品を表示するケースと、総合評価の降順に商品を表示するケースを示す。順番が各個人にランダムに割り当てられている場合 (左) とは異なり、商品の並び順に介入を受けるグループでは、トリートメントの組み合わせごとに、特定の商品が置かれる位置は固定される。これらのケースでは、表示されるレビューの種類に関わらず、いずれも左上上がりの折れ線を描いており、レビュー数順や総合評価順で並べる場合、削除されたレビューが表示されるか否かに関係なく、消費者は上位に表示される商品を選ぶ傾向があるといえる。ただし、選択に与える影響にはカテゴリごとに異なる。表示順と選択の関係は、デジタルカメラで最も弱く、ヘッドホンがそれに続き、スマートウォッチで最も強い。また、折れ線が特定の表示順で大きくジャンプすることから、一部の商品は他の商品よりも魅力的であることが伺える。

図 22 は、カテゴリごとに、商品評価やレビュー数と被験者の選択の関係を示したものである。左図 (a) は、横軸に商品の総合評価、縦軸に選択数をプロットしたものである。右図 (b) は、商品の評価数を横軸に、選択数を縦軸にプロットしたものである。赤のバーが最初に詳細を閲覧した商品について、青のバーが最終的な選択を意味する。被験者は、最初の



(a) デジタルカメラ

(b) ヘッドホン



(c) スマートウォッチ

図 21: 介入ごとの商品の選択と商品表示順

閲覧でも商品の選択においても、総合評価の高い商品を選ぶ傾向があることがわかる。レビュー数については、初回選択と最終選択の両方で、明確な傾向はみられない。レビュー数が高い商品が、必ずしも消費者に魅力的ではないことが示唆される。

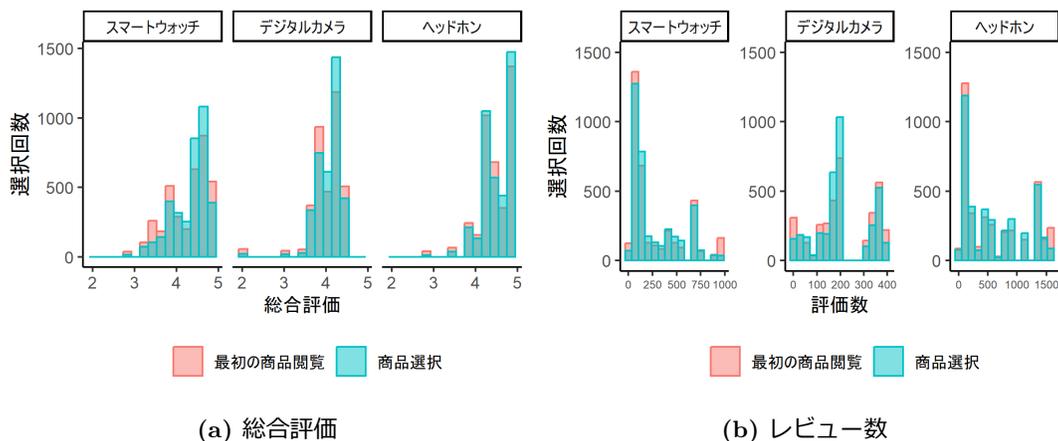


図 22: 商品の選択とレビュー

図 23は、各カテゴリについて、縦軸に消費者に提示したポイントの額、横軸に二段階目の選択においてポイントではなく商品を選んだ被験者の割合をとり、実験で観察されたポイントと商品選択率の組について、散布図を描画し、回帰直線を引いたものである。いずれのカテゴリにおいても右下がりの形を示しており、より高額なポイントを提示された被験者は、抽選の対象として商品を選ぶ割合が減少する傾向がみられており、経済的なインセンティブと一貫した行動をとっている判断できる。

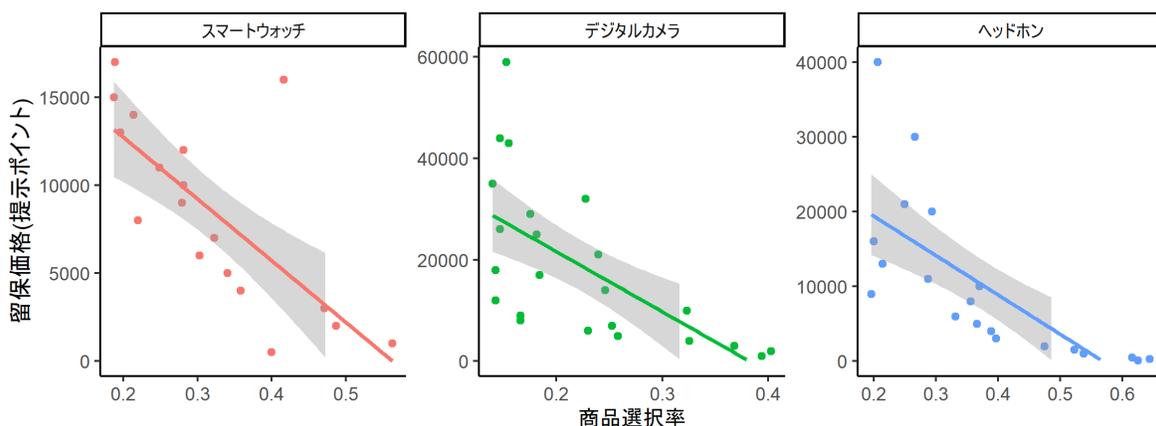


図 23: 留保価格と商品選択率

7.3.2 フェイクレビューと商品表示順の効果

トリートメントの効果は、各種アウトカムを、トリートメントを示すダミーとコントロール変数に回帰することで推定される。商品の品質として、削除されなかったレビューの平均点⁷³を主たるアウトカムとして用いるほか、選ばれた商品の価格などへの影響についても調査する。

まず、交差項を考えない各介入の効果について明らかにする。具体的には、フェイクレビューの再現にあたる削除されたレビューの表示がどのような影響をもたらしているか、商品表示順などの Amazon のシステムを再現した介入がどのように被験者の選択を変化させるかを検証する。

これらの結果は、表 17から表 19に示されている。各カラムについては、(1)の商品を選択は、実験の第一段階でいずれかの商品を選んだか否かをアウトカムとしたものである。(2)の表示順は選ばれた商品の表示順をアウトカムとしたものであり、(3)の市場価格は選ばれた商品の市場価格をアウトカムとして用いた結果を示す。(4)の品質は、削除されなかったレビューの平均点をアウトカムとしたメインの結果であり、(5)の評価数は削除されなかったレビューの数をアウトカムとしたものである。モデルには個人の属性や他のトリートメントが含まれるが、表からは省略している⁷⁴。

デジタルカメラ

デジタルカメラについての推定結果を示したものが、表 17である。削除されたレビューが表示される場合、有意に低品質な商品に誘導され、品質が \star 約 0.265 個分減少する。これは、コントロールと比較して、約 6.8% の \star の減少に値する。これは、品質が同様に 6.8% 分減少しているとはいえないものの、消費者がフェイクレビューに欺かれて、本来購入しないはずの低品質な財を選択してしまうようなケースといえる。選択された市場価格も有意に約 8200 円安くなり、これはコントロールと比較して約 24.6% の大幅な減少となる。単に価格の減少から品質の減少を導くことはできないものの、機能等で劣る商品に誘導されていることが伺える。評価数もコントロールの 12.7% 分に相当する約 21 本分有意に減少し、本来は評価があまりなされないような商品に誘導されているといえる。ただし、評価数が少ない商品が、低品質と判断することはできない。表示順も有意に負であり、上位に表示

⁷³実験に使用するレビューを選択する前の削除されなかったレビュー平均点であり、コントロールグループに表示される総合評価である。

⁷⁴マイボイス社のモニターを対象に被験者に募集しているため、学歴や年収などについては、同社から提供を受けている。他の個人属性については、実験サイト上で質問を行っている。この詳細は Appendix B にて示す。レビューの表示順の変更も省略しているが、これは有意といえる結果をもたらしていない。

される商品が選ばれやすくなるが、これも品質との関係は断じることができない。抽選における選択は、係数は正であるものの、有意といえるほどの影響を受けたとはいえない。

評価順での商品表示は、有意に上位の商品が選ばれやすくする。ただし、選択された商品の品質には有意といえる影響を与えていない。評価数順での商品表示は、有意に上位の商品が選ばれやすくなるのは同様であるが、選択された商品の評価数も有意に増加する。両面表示は、評価数のみに有意な影響を与え、評価数が高い商品を選ばれやすくする。

表 17: トリートメント効果 (デジタルカメラ)

	(1) 商品を選択	(2) 表示順	(3) 市場価格	(4) 品質	(5) 評価数
切片	0.792*** (0.042)	5.038*** (0.285)	33.232*** (1.551)	3.898*** (0.055)	165.538*** (10.265)
削除レビュー表示	0.033 (0.028)	-0.399* (0.191)	-8.196*** (1.038)	-0.265*** (0.037)	-21.003** (6.873)
総合評価順	-0.002 (0.022)	-2.323*** (0.150)	0.358 (0.817)	0.024 (0.029)	-2.493 (5.407)
評価数順	0.021 (0.021)	-1.819*** (0.147)	-0.241 (0.800)	0.016 (0.028)	10.555* (5.293)
両面表示	0.019 (0.018)	0.038 (0.122)	0.141 (0.663)	0.038 (0.023)	9.109* (4.386)
Num.Obs.	5192	3618	3618	3618	3618
R2	0.041	0.092	0.107	0.120	0.062
R2 Adj.	0.037	0.086	0.102	0.115	0.056

Standard errors are in parentheses.

* $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$

ヘッドホン

ヘッドホンについての推定結果を示したものが、表 18である。削除されたレビューの表示は、選択された商品の品質に有意な影響を与えているとはいえない。ヘッドホンについては、フェイクレビューを見分けられる可能性がいくる。選択された商品の市場価格は有意な影響を受け、約 960 円安くなる。これはコントロールと比較して約 16.7% の減少となる。減少幅の絶対値も、コントロールと比較した割合もヘッドホンと比べ小さい。評価数についてもコントロールの 13.8% 分に相当する約 90 件分減少する。抽選における選択や選択された商品の表示順は、有意といえるほどの影響を受けていない。

評価順での商品表示は、有意に上位の商品が選ばれやすくなり、選ばれた商品の品質も上昇する。更に有意に安価な商品に誘導される。評価数順での商品表示は、有意に上位の

商品が選ばれやすくなるのは同様であるが、市場価格は高くなり、選ばれた商品の品質は有意に減少する。選択された商品の評価数も有意に増加する。両面表示は、どのアウトカムにも有意な影響を与えているとはいえない。

表 18: トリートメント効果 (ヘッドホン)

	(1) 商品を選択	(2) 表示順	(3) 市場価格	(4) 品質	(5) 評価数
切片	0.812*** (0.038)	11.572*** (0.922)	5.764*** (0.527)	4.374*** (0.040)	649.603*** (46.283)
削除レビュー表示	0.031 (0.025)	0.414 (0.619)	-0.956** (0.354)	-0.019 (0.027)	-90.097** (31.050)
総合評価順	0.016 (0.020)	-3.321*** (0.486)	-0.869** (0.278)	0.108*** (0.021)	-35.308 (24.363)
評価数順	0.011 (0.020)	-2.792*** (0.485)	1.086*** (0.277)	-0.062** (0.021)	181.532*** (24.344)
両面表示	-0.012 (0.016)	-0.016 (0.395)	0.125 (0.226)	0.014 (0.017)	1.479 (19.841)
Num.Obs.	5086	3926	3926	3926	3926
R2	0.081	0.030	0.052	0.049	0.094
R2 Adj.	0.077	0.024	0.046	0.043	0.089

Standard errors are in parentheses.

* $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$

スマートウォッチ

スマートウォッチについての推定結果を示したものが、表 19である。削除されたレビューの表示は、選択された商品の品質を有意に $\ast 0.143$ 個分減少させる。これは、コントロールと比較して約 3.4% の減少にあたる。選択された市場価格も有意に約 175 円減少する。ただし、これはコントロールと比較して約 3.7% の減少にとどまり、他 2 カテゴリと比べ減少幅がかなり小さくなっている。評価数についてはコントロールの 10.8% 分に相当する約 27 件分減少している。抽選における選択や選択された商品の表示順は、有意といえるほどの影響を受けていない。

評価順での商品表示は、有意に上位の商品が選ばれやすくなり、選ばれた商品の品質も上昇する。評価数順での商品表示は、有意に上位の商品が選ばれやすくなり、商品の評価数も有意に増加する。両面表示は、どのアウトカムにも有意な影響を与えているとはいえない。

表 19: トリートメント効果 (スマートウォッチ)

	(1) 商品を選択	(2) 表示順	(3) 市場価格	(4) 品質	(5) 評価数
切片	0.758*** (0.041)	12.018*** (0.893)	4.453*** (0.108)	4.196*** (0.054)	251.637*** (20.125)
削除レビュー表示	0.044 (0.028)	-0.432 (0.607)	-0.175* (0.073)	-0.143*** (0.037)	-27.838* (13.692)
総合評価順	-0.010 (0.022)	-4.856*** (0.475)	0.056 (0.057)	0.175*** (0.029)	-12.581 (10.701)
評価数順	-0.010 (0.021)	-2.058*** (0.472)	-0.015 (0.057)	0.019 (0.029)	41.948*** (10.641)
両面表示	-0.002 (0.018)	0.213 (0.388)	0.016 (0.047)	-0.036 (0.024)	-10.157 (8.742)
Num.Obs.	5076	3622	3622	3622	3622
R2	0.041	0.055	0.035	0.065	0.057
R2 Adj.	0.036	0.049	0.028	0.059	0.051

Standard errors are in parentheses.

* $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$

7.3.3 トリートメントの交互作用

次に、フェイクレビューの下での商品表示のシステムや、教育的介入についての効果を検証する。以下の表 20は、削除されたレビューを表示されたサブサンプルを用い、各カテゴリについて、選択された商品の品質に対し、トリートメントを回帰した推定結果である。

警告表示は有意な影響を与えているとはいえない。教育的介入はレビューの不正操作の被害を抑制することが期待され、Akesson et al. (2023) では大きな効果が出ているものの、本実験で行った教育的介入については効果が認められない結果となった。

商品の表示順については、総合評価の順に商品を並べると、ヘッドホンとスマートウォッチでは選択される商品の品質が有意に向上し、デジタルカメラでは有意に減少する。前者二つのカテゴリについては、総合評価による表示順はより高品質の商品に消費者を誘導しており、フェイクレビューの下でも頑健であると判断できる。一方で、デジタルカメラについては、フェイクレビューの被害を増幅させる可能性がいえる。評価数順での商品表示やレビューの両面表示は、有意といえるような影響を与えていない。

7.4 おわりに

本章は、Amazon を模した web サイトでの実験により、レビューの不正操作が消費者にあたえる影響を調査し、フェイクレビューの下で、教育的介入や商品表示システムがどのよ

表 20: トリートメント効果の交互作用

	(1)	(2)	(3)
	デジタルカメラ	ヘッドホン	スマートウォッチ
切片	3.673*** (0.093)	4.402*** (0.058)	4.054*** (0.073)
警告表示	-0.031 (0.029)	-0.009 (0.019)	-0.006 (0.024)
総合評価順	-0.107** (0.035)	0.121*** (0.023)	0.218*** (0.029)
評価数順	0.030 (0.035)	-0.030 (0.022)	0.043 (0.029)
両面表示	0.025 (0.029)	0.003 (0.018)	0.002 (0.024)
Num.Obs.	1834	1969	1860
R2	0.029	0.036	0.053
R2 Adj.	0.018	0.027	0.043

Standard errors are in parentheses.

* $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$

うに働くかについて評価するものである。

実験では、デジタルカメラ・ヘッドホン・スマートウォッチの3カテゴリについて、実際に被験者が商品を選択した。この際、フェイクレビューのプロキシとして、Amazonに削除されたレビューが表示用いられ、削除されたレビューを表示する介入や、フェイクレビューへの警告表示を行う介入、商品の表示順を変更する介入などが被験者にランダムに割り当てられた。

実験の結果、主に3つの知見が得られた。第一に、削除されたレビューの表示は、デジタルカメラとスマートウォッチにおいて、被験者をより低品質な財に誘導した。消費者が、フェイクレビューに欺かれ、被害が生じていると判断できる。また、有意に安く、レビューの少ない商品に誘導している。

第二に、総合評価での商品表示は、ヘッドホンとスマートウォッチについては、削除レビューの表示の下でも、より品質の高い商品に被験者を誘導した。同時に、上位に表示される商品を選択されやすくしていることから、高評価な商品を上位に表示することで、消費者の探索を早期に終わらせていることが伺える。ただし、デジタルカメラについては、削除されたレビューの下で低品質な財に誘導しており、フェイクレビューの被害を増幅させ

てしまうケースが存在することが示唆される。利便性とのトレードオフが時に生じてしまうといえる一方で、プラットフォームには、フェイクレビューを積極的に削除し、レーティングに基づく商品表示システムを有効に保つインセンティブがあることも指摘できる。

第三に、警告表示は、フェイクレビューの下で被験者に有意な影響を与えなかった。フェイクレビューの存在を警告するという、本実験における教育的介入の効果は限定的であり、教育や啓蒙とは別のアプローチが必要であることが示唆される。

本章にはいくつかの分析上の限界と課題も存在する。第一に、被験者が選択した商品の品質について分析を行っているものの、レビューの不正操作の被害について、金銭に換算された厚生損失を推計しているわけではない。本実験では、抽選の対象として、商品と、商品ごとにランダムに選ばれた金額相当のポイントのどちらかを選択させている。ここで合理的な被験者は、商品への WTP がポイントより高い場合は商品を選び、逆に商品への WTP がポイントより低ければポイントを選ぶ。選択においてポイントは実質的に商品の価格として働き、被験者の WTP を推定することができる。また、これは誘引両立かつ顕示選択の形で示されたものである。この WTP を推定することを通じ、厚生損失を定量化することが求められる。

第二に、本章は、既存の施策と EC サイトのシステムについて評価を行ったものの、レビューの不正操作の被害を抑制するための施策を提案したわけではない。消費者被害を防ぐための有効な施策や、フェイクレビューによる操作が行いにくいメカニズムなどを新たに考案したうえで、評価をおこなうことが必要となる。

第三に、本章では、本稿の他の章と同じく、削除されたレビューをフェイクレビューのプロキシを用いている。今後、実験によるアプローチをとる場合においては⁷⁵、He et al. (2022b) に倣い SNS の調査を行うなど、不正の把握についての精度を向上させることが望ましい。

⁷⁵He et al. (2022b) の手法はコストが高く、カバレッジも保証されない点がデメリットであるが、実験では使用する商品の数が限られるため、適用可能性が大きい。

第 8 章 総括と今後の展望

本稿では、社会問題化しているレビューの不正操作について、1 章と 2 章でリサーチエクシジョンと先行研究のギャップを整理したうえで、4 章から 7 章において様々な角度で実証分析を行い、国内におけるレビューの不正操作の実態とその影響について明らかにした。分析にあたっては、Amazon.co.jp から削除されたレビューを、フェイクレビューのプロキシとして用いた。

4 章では、レビューレベルの分析を通じ、どのようなレビューがフェイクであるかを検証した。分析の結果、高評価なレビューや、一般的に真のレビューのものと考えられる特徴をもつレビューほどフェイクの疑いが強いことが示された。

5 章においては、プロダクトレベルの分析を行い、不正に関与する売り手や商品の属性を明らかにした。低品質な財の売り手や、不正のインセンティブが大きい、マーケットプレイスで販売される商品や非ブランド商品の売り手ほど、不正に関与している疑いが強いことが示された。また、長期間在庫切れの商品や、中古のみの扱いとなっている、通常ない状況にある疑わしい商品ほど、不正に関与しやすいことも推察される。

6 章においてはパネルデータ分析により、不正の時系列上の動向と背景にあるインセンティブを明らかにした。フェイクレビューは販売初期に集中し、その後 Amazon 側のレビュー削除に反応して減少するという、売り逃げを目的とした不正操作の構図が伺える結果となった。更に、フェイクレビューが投稿されて以後、低評価のレビューが増加し、消費者被害が生じていることを示唆された。

7 章においては、オンライン実験データの分析により、レビューの不正操作の消費者行動への影響を明らかにし、施策や Amazon のシステムについて評価を行った。分析の結果、フェイクレビューの下で、消費者は低品質な財に誘導され、教育的介入はフェイクレビューの被害を抑制できなかった。また、レーティングでの商品表示は、時に不正による被害を増幅させてしまうことも示された。

政策的含意

以上の結果から、レビューの不正操作についての施策や規制について、2 点の政策的含意が導かれる。第一に、フェイクレビューは消費者を利するとは考えにくく、実際に憂慮すべき消費者被害が生じている可能性が高いことがいえる。いくつかの理論研究は、質の高い商品の売り手ほど不正を行うために、フェイクレビューが有益なシグナルとなり得ることを指摘する (Dellarocas, 2006; Yasui, 2020) ものの、5 章と 6 章の結果は、低品質な商品の

売り手ほど、不正に関与している可能性が高いことを示す。低品質な商品の売り手が、高評価のレビューの水増しを行っているようなパターンに該当し、レビューの不正操作が消費者の選択を歪め、有害であることを支持する結果といえる。消費者がフェイクレビューをうまく判別できる場合、被害は大きくならないが、4章の結果は、フェイクレビューが、一般的に真のレビューと考えられるような特徴を持つ傾向があることを示す。消費者にとって、フェイクレビューの判別が困難であることが示唆される。また、6章では、フェイクレビューが販売初期の短期間に集中している可能性が示されており、これも判別を困難にすると考えられる。さらに、レビューの不正操作が実際に消費者被害を生じさせているエビデンスも示されている。6章では、フェイクレビューの投入開始後しばらく経過したのちに、低評価のレビューが増加しており、不正操作による被害だと解釈できる。7章での実験結果でも、フェイクレビューの下で、消費者は低品質な商品に誘導されやすいことが示されている。

第二に、今後行うべき施策についての方針が示される。6章の結果は、レビューの削除が始まると、フェイクレビューの投稿が減少することを示唆しており、フェイクレビューを早期に削除できれば、不正操作の被害を緩和することが可能となる。これは、7章で示されたように、フェイクレビューの下でのレーティングでの商品表示順の歪みを正すことにもつながる。一方で、フェイクレビューの存在を強調するような教育的介入については、効果が弱いことが示されている。レビューの不正操作を啓蒙・周知するような教育的介入とは、別のアプローチをとることが推奨される。

今後の展望

本稿では、レビューの不正操作の実態について、一定のエビデンスを提供した。しかしながら、未だ不明な点や限界も多い。今後の研究については、以下の3点の課題の解消が肝要になると考えられる。第一に、レビューがフェイクか否かの判別や、不正に関与している商品や売り手の特定があげられる。本稿や Luca and Zervas (2016) ではプラットフォームによる削除や隔離をプロキシとして用いた分析に留まり、プラットフォームのアルゴリズムを分析しているという懸念を完全に否定することはできない。He et al. (2022b) は不正に関与している商品を特定しているものの、カバレッジについての保証もなく、個別のレビューについてフェイクか否かを特定できてはいない。根本的に解決が難しい課題であるが、より高精度での不正の把握や、異なる角度から分析の信頼性を担保することが求められる。

第二に、消費者被害の定量化が求められる。本稿は実験を用い、フェイクレビューの下

で、消費者が実際に低品質な財に誘導されることを明らかにしたものの、厚生損失について定量的に評価したわけではない。規制や施策の強さを決定するうえで、厚生損失が具体的にどの程度の水準であるのかを推定する必要がある。

第三に、レビューの不正操作に直面する消費者の異質性を調査することも重要性が高い。仮に、所得や学歴の低い、社会的弱者にあたる消費者について、不正操作による被害が大きい場合、不正が総余剰を増加させるとしても、公平性の面で規制の強化は正当化され得る。実際に、5章の結果は非ブランド商品で不正が行われやすい疑いを示しており、非ブランド商品の購入を検討しやすい消費者ほど、不正に直面しやすいことが示唆される。

第四に、新たな施策や制度設計の考案と事前の評価が求められる。本稿は教育的介入や商品表示システムについて評価を行ったに留まる。新たに有効な介入や制度設計を発案したうえでその効果を評価し、提示することが求められる。

これらの課題は、プラットフォームの保有する詳細なデータなくしては解決が困難なものも多い。Amazon は官民連携の姿勢を示しているが、今後は官学民での連携が求められる⁷⁶。

⁷⁶<https://www.aboutamazon.jp/news/innovation/a-blueprint-for-private-and-public-sector-partnership-to-stop-fake-reviews>

Appendix A. 異なる特定化によるパネルデータ分析

6章では、フェイクレビューが販売初期において集中して投下されるか否かを検証するため、発売5週以内のダミー変数を用い、分析を行った(表13)。頑健性を担保するため、より狭い範囲のダミーを用いて推定を行う。

発売4週以内のダミーと、3週以内のダミー変数を用いた推定結果を示したものが、表21である。表13の結果と同様の傾向を示しており、フェイクレビューが初期に集中していることが再確認される。

また、フェイクレビューに欺かれた被害者が、フェイクレビューの集中投入から、しばらく経過してから現れるか否かを検証すべく、削除された高評価レビューの投稿数が最大となる週を基準として、基準週の3週間以後において、低評価レビューが増加するか否かを分析した(表14)。ここでは、異なる基準週と、異なる経過週数を用いて推定する。

表22は、削除された高評価レビューの投稿が始まったタイミングを基準週として、同様の分析を行った結果を示したものである。これも、表14と同じ傾向を示す。

次に、基準週からの経過週を変更して分析した結果を示したものが以下の表22である。基準週から4週以後のダミーを用いても、5週以後のダミーを用いても、表14と同様の傾向を示す。初期にフェイクレビューが集中したのちに低評価のレビューが増加することの頑健性が確認されたといえる。

Appendix B. 実験サイトと質問

7章における実験サイトでは実験の他に、ECサイトの利用経験などについて、被験者への質問を行っており、得られた回答をもとに個人属性についての変数を作成し、分析のコントロール変数として用いている。まず、使用経験のあるECサイトの数と、Amazonの仕様経験の有無について、図24の(a)から変数を作成している。さらに、各カテゴリについての購入経験の有無を示すダミー変数を(b)から作成している。図25と図26の設問からは、5段階中4以上であるダミー変数を作成し、各カテゴリに対しての興味と知識をコントロールしている。また、図27の設問から、ステルスマーケティングに対する認知について、各回答に応じたダミー変数を作成している。

表 21: フェイクレビューのトレンド II

	(1) 削除 ★4-5	(2) 非削除 ★4-5	(3) 削除 ★4-5	(4) 非削除 ★4-5
販売開始 4 週以内	0.072** (0.027)	-0.074** (0.026)		
販売開始 4 週以内 * 非 Amazon	0.054 (0.028)	0.065* (0.027)		
販売開始 3 週以内			0.077** (0.029)	-0.078** (0.027)
販売開始 3 週以内 * 非 Amazon			0.033 (0.029)	0.084** (0.027)
販売からの経過週数	0.000 (0.001)	-0.001* (0.001)	0.000 (0.001)	-0.001* (0.001)
販売からの経過週数 * 非 Amazon	-0.001 (0.001)	0.004*** (0.001)	-0.001 (0.001)	0.004*** (0.001)
削除開始以後	-0.048 (0.043)	0.031 (0.042)	-0.048 (0.043)	0.032 (0.042)
削除開始以後 * 非 Amazon	-0.174*** (0.051)	0.070 (0.050)	-0.180*** (0.052)	0.072 (0.050)
一期ラグ非削除レビュー移動平均低下	-0.014 (0.014)	-0.045** (0.017)	-0.015 (0.014)	-0.043* (0.017)
一期ラグ非削除レビュー移動平均低下 * 非 Amazon	-0.047 (0.026)	-0.016 (0.028)	-0.051 (0.026)	-0.016 (0.028)
レビュー数	0.146*** (0.035)	0.653*** (0.035)	0.146*** (0.035)	0.653*** (0.035)
切片	0.046 (0.044)	-0.121** (0.043)	0.065 (0.044)	-0.129** (0.043)
<i>N</i>	163903	163903	163903	163903

Standard errors in parentheses

* $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$

表 22: 低評価レビューについての推定結果 II

	(1) 非削除 *1-3	(2) 非削除 *4-5	(3) 非削除 *1-3 率
基準週 3 週以後	0.153** (0.056)	-0.063 (0.047)	0.056** (0.021)
基準週 3 週以後 * 非 Amazon 販売	-0.019 (0.058)	0.100 (0.054)	-0.002 (0.022)
販売開始 5 週以内	0.004 (0.018)	-0.065** (0.023)	-0.018* (0.008)
販売開始 5 週以内 * 非 Amazon 販売	-0.082*** (0.020)	0.068* (0.028)	-0.033*** (0.009)
販売からの経過週数	0.001 (0.001)	-0.001 (0.001)	0.000 (0.000)
販売からの経過週数 * 非 Amazon 販売	-0.003*** (0.001)	0.004*** (0.001)	-0.001*** (0.000)
削除開始以後	-0.027 (0.040)	0.061 (0.041)	0.014 (0.018)
削除開始以後 * 非 Amazon 販売	0.066 (0.043)	0.020 (0.055)	-0.014 (0.019)
1 期ラグ非削除レビュー移動平均低下	0.055** (0.017)	-0.043** (0.017)	0.016* (0.008)
1 期ラグ非削除レビュー移動平均低下 * 非 Amazon 販売	0.058** (0.019)	-0.019 (0.028)	0.049*** (0.009)
レビュー数	0.182*** (0.016)	0.653*** (0.035)	0.023*** (0.003)
切片	0.013 (0.015)	-0.134*** (0.038)	0.065*** (0.005)
<i>N</i>	163903	163903	163903

Standard errors in parentheses

* $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$

表 23: 低評価レビューについての推定結果 III

	(1)	(2)	(3)	(4)	(5)	(6)
	非削除 *1-3	非削除 *4-5	非削除 *1-3 率	非削除 *1-3	非削除 *4-5	非削除 *1-3 率
基準週 4 週以後	0.178** (0.059)	-0.148** (0.054)	0.063** (0.020)			
基準週 4 週以後 * 非 Amazon 販売	-0.008 (0.062)	0.594*** (0.073)	-0.008 (0.021)			
基準週 5 週以後				0.157** (0.055)	-0.150** (0.052)	0.059** (0.020)
基準週 5 週以後 * 非 Amazon 販売				-0.026 (0.057)	0.528*** (0.069)	-0.015 (0.020)
販売開始 5 週以内	0.004 (0.018)	-0.067** (0.024)	-0.018* (0.008)	0.001 (0.018)	-0.065** (0.024)	-0.019* (0.008)
販売開始 5 週以内 * 非 Amazon 販売	-0.084*** (0.020)	0.108*** (0.028)	-0.035*** (0.009)	-0.089*** (0.020)	0.089** (0.027)	-0.037*** (0.009)
販売からの経過週数	0.000 (0.000)	-0.001* (0.001)	0.000 (0.000)	0.000 (0.000)	-0.001 (0.001)	0.000 (0.000)
D 販売からの経過週数 * 非 Amazon 販売	-0.003*** (0.001)	0.002** (0.001)	-0.001*** (0.000)	-0.003*** (0.001)	0.002** (0.001)	-0.001*** (0.000)
削除開始以後	-0.040 (0.040)	0.103* (0.053)	0.010 (0.017)	-0.029 (0.041)	0.103 (0.055)	0.012 (0.017)
削除開始以後 * 非 Amazon 販売	0.063 (0.043)	-0.244*** (0.066)	-0.009 (0.018)	0.075 (0.043)	-0.202** (0.066)	-0.005 (0.018)
1 期ラグ非削除レビュー移動平均低下	0.053** (0.017)	-0.039* (0.016)	0.016* (0.008)	0.053** (0.017)	-0.039* (0.016)	0.016* (0.008)
1 期ラグ非削除レビュー移動平均低下 * 非 Amazon 販売	0.053** (0.019)	-0.058* (0.026)	0.048*** (0.009)	0.055** (0.018)	-0.055* (0.026)	0.049*** (0.009)
レビュー数	0.185*** (0.016)	0.661*** (0.035)	0.024*** (0.003)	0.184*** (0.016)	0.660*** (0.035)	0.024*** (0.003)
切片	0.098*** (0.014)	-0.062 (0.040)	0.096*** (0.005)	0.095*** (0.014)	-0.065 (0.039)	0.095*** (0.005)
N	163903	163903	163903	163903	163903	163903

Standard errors in parentheses

* $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$

あなたが2022年に商品を購入したオンラインショッピングサイトをすべてお答えください。

<input type="checkbox"/> Amazon
<input type="checkbox"/> 楽天市場
<input type="checkbox"/> Yahoo!ショッピング(PayPayモール含む)
<input type="checkbox"/> ヨドバシカメラ
<input type="checkbox"/> ZOZOTOWN
<input type="checkbox"/> ビックカメラ
<input type="checkbox"/> ヤマダウェブコム
<input type="checkbox"/> ユニクロ公式オンラインストア
<input type="checkbox"/> au PAYマーケット
<input type="checkbox"/> オイシックス・ラ・大地
<input type="checkbox"/> その他 (自由回答)
こちらに自由回答を入力してください

<1つ前に戻る 次に進む>

(a) EC サイト使用経験についての設問

以下の製品をオンラインショッピングで購入したことがありますか。購入したことがあるもの全てをお選びください。

<input type="checkbox"/> テレビ
<input type="checkbox"/> デジタルカメラ
<input type="checkbox"/> スマートウォッチ
<input type="checkbox"/> イヤホン/ヘッドホン
<input type="checkbox"/> その他の家電
<input type="checkbox"/> 食品、飲料、酒類
<input type="checkbox"/> 化粧品、医薬品
<input type="checkbox"/> 書籍、映像・音楽ソフト
<input type="checkbox"/> 生活雑貨、家具、インテリア
<input type="checkbox"/> 衣類・服装雑貨など
<input type="checkbox"/> 自動車、自動二輪車、パーツなど
<input type="checkbox"/> その他 (自由回答)
こちらに自由回答を入力してください

<1つ前に戻る 次に進む>

(b) EC サイトでの購入経験についての設問

図 24: 設問の抜粋 I

「デジタルカメラ」について、あなたは、どの程度ご存知ですか。次の中から最もよく当てはまるものを1つお選びください。

<input type="radio"/> 01 全く知らない
<input type="radio"/> 02 あまり知らない
<input type="radio"/> 03 どちらともいえない
<input type="radio"/> 04 ある程度知っている
<input type="radio"/> 05 とてもよく知っている

(a) デジタルカメラへの知識についての設問

「イヤホン/ヘッドホン」について、あなたは、どの程度ご存知ですか。次の中から最もよく当てはまるものを1つお選びください。

<input type="radio"/> 01 全く知らない
<input type="radio"/> 02 あまり知らない
<input type="radio"/> 03 どちらともいえない
<input type="radio"/> 04 ある程度知っている
<input type="radio"/> 05 とてもよく知っている

(b) ヘッドホンへの知識についての設問

「スマートウォッチ」について、あなたは、どの程度ご存知ですか。次の中から最もよく当てはまるものを1つお選びください。

<input type="radio"/> 01 全く知らない
<input type="radio"/> 02 あまり知らない
<input type="radio"/> 03 どちらともいえない
<input type="radio"/> 04 ある程度知っている
<input type="radio"/> 05 とてもよく知っている

(c) スマートウォッチへの知識についての設問

図 25: 設問の抜粋 II

「デジタルカメラ」について、あなたは、どの程度興味がありますか。次の中から最もよく当てはまるものを1つお選びください。

<input type="radio"/> 01 全く興味がない
<input type="radio"/> 02 あまり興味がない
<input type="radio"/> 03 どちらともいえない
<input type="radio"/> 04 ある程度興味がある
<input type="radio"/> 05 とても興味がある

(a) デジタルカメラへの知識についての設問

「イヤホン/ヘッドホン」について、あなたは、どの程度興味がありますか。次の中から最もよく当てはまるものを1つお選びください。

<input type="radio"/> 01 全く興味がない
<input type="radio"/> 02 あまり興味がない
<input type="radio"/> 03 どちらともいえない
<input type="radio"/> 04 ある程度興味がある
<input type="radio"/> 05 とても興味がある

(b) ヘッドホンへの知識についての設問

「スマートウォッチ」について、あなたは、どの程度興味がありますか。次の中から最もよく当てはまるものを1つお選びください。

<input type="radio"/> 01 全く興味がない
<input type="radio"/> 02 あまり興味がない
<input type="radio"/> 03 どちらともいえない
<input type="radio"/> 04 ある程度興味がある
<input type="radio"/> 05 とても興味がある

(c) スマートウォッチへの知識についての設問

図 26: 設問の抜粋 III

あなたはインターネット上で、次のどれかに該当する疑わしい情報を見た事がありますか。見たことがあるものを、いくつでもお選びください。

※どれも見たことがないか、全く分からない場合には、どれも選ばずに次へお進みください。

<input type="checkbox"/> 商品について、書くことに対する対価を受け取ってることを隠した記事
<input type="checkbox"/> 商品について、事実よりもより良いものと誤解させるよう依頼された記事
<input type="checkbox"/> 商品について、事実よりもより悪いものと誤解させるよう依頼された記事
<input type="checkbox"/> その商品についてなのか、それとも他の商品についてのことなのか判別しにくい記事

<1つ前に戻る

次に進む>

図 27: ステルスマーケティング認知についての設問

参考文献

- Akesson, J., Hahn, R. W., Metcalfe, R. D., and Monti-Nussbaum, M. (2023). The impact of fake reviews on demand and welfare. Technical report, National Bureau of Economic Research.
- Ananthakrishnan, U. M., Li, B., and Smith, M. D. (2020). A tangled web: Should online review portals display fraudulent reviews? *Information Systems Research*, 31(3):950–971.
- Anderson, E. T. and Simester, D. I. (2014). Reviews without a purchase: Low ratings, loyal customers, and deception. *Journal of Marketing Research*, 51(3):249–269.
- Azimi, S., Chan, K., and Krasnikov, A. (2022). How fakes make it through: the role of review features versus consumer characteristics. *Journal of Consumer Marketing*, (ahead-of-print).
- Becker, G. M., DeGroot, M. H., and Marschak, J. (1964). Measuring utility by a single-response sequential method. *Behavioral science*, 9(3):226–232.
- Bottan, N. L. and Perez-Truglia, R. (2022). Choosing Your Pond: Location Choices and Relative Income. *Review of Economics and Statistics*, 104(5):1010–1027.
- Chevalier, J. A. and Mayzlin, D. (2006). The effect of word of mouth on sales: Online book reviews. *Journal of marketing research*, 43(3):345–354.
- Chintagunta, P. K., Gopinath, S., and Venkataraman, S. (2010). The effects of online user reviews on movie box office performance: Accounting for sequential rollout and aggregation across local markets. *Marketing science*, 29(5):944–957.
- Dellarocas, C. (2006). Strategic manipulation of internet opinion forums: Implications for consumers and firms. *Management science*, 52(10):1577–1593.
- He, S., Hollenbeck, B., Overgoor, G., Proserpio, D., and Tosyali, A. (2022a). Detecting fake-review buyers using network structure: Direct evidence from amazon. *Proceedings of the National Academy of Sciences*, 119(47):e2211932119.
- He, S., Hollenbeck, B., and Proserpio, D. (2022b). The market for fake reviews. *Marketing Science*, 41(5):896–921.

- Hollenbeck, B. (2018). Online reputation mechanisms and the decreasing value of chain affiliation. *Journal of Marketing Research*, 55(5):636–654.
- Li, H., Ji, H., Luo, J. M., and Zhang, Z. (2023). Competition and restaurant online review manipulations: A dynamic panel data analysis. *International Journal of Hospitality Management*, 115:103605.
- Luca, M. and Zervas, G. (2016). Fake it till you make it: Reputation, competition, and yelp review fraud. *Management Science*, 62(12):3412–3427.
- Mayzlin, D. (2006). Promotional chat on the internet. *Marketing science*, 25(2):155–163.
- Mayzlin, D., Dover, Y., and Chevalier, J. (2014). Promotional reviews: An empirical investigation of online review manipulation. *American Economic Review*, 104(8):2421–55.
- Milgrom, P. and Roberts, J. (1986). Price and advertising signals of product quality. *Journal of political economy*, 94(4):796–821.
- Nelson, P. (1970). Information and consumer behavior. *Journal of political economy*, 78(2):311–329.
- Nie, C., Zheng, Z. E., and Sarkar, S. (2022). Competing with the sharing economy: Incumbents’ reaction on review manipulation. *MIS Quarterly*, 46(3).
- Oiso, H., Sakaguchi, H., Kuroda, T., and Ida, T. (2023). Effect of the product order and the product review on the product choice.
- Ott, M., Cardie, C., and Hancock, J. T. (2013). Negative deceptive opinion spam. In *Proceedings of the 2013 conference of the north american chapter of the association for computational linguistics: human language technologies*, pages 497–501.
- Ott, M., Choi, Y., Cardie, C., and Hancock, J. T. (2011). Finding deceptive opinion spam by any stretch of the imagination. *arXiv preprint arXiv:1107.4557*.
- Park, S., Shin, W., and Xie, J. (2023). Disclosure in incentivized reviews: Does it protect consumers? *Management Science*, 69(11):7009–7021.
- Rosenberger, W. F. (2002). *Randomization in clinical trials theory and practice*. Wiley series in probability and statistics. Wiley, New York.

Yasui, Y. (2020). Controlling fake reviews. *Available at SSRN 3693468*.

カライスコス アントニオス (2023). 諸外国におけるステルス・マーケティング規制の実効性確保. *国民生活研究 Journal of research on social and economic life*, 63(1):1-22.

坂口, . (2022). レビューの不正操作に関するサーベイ,
https://www.meti.go.jp/shingikai/mono_info_service/platform_economics/pdf/010_04_02.pdf.

消費者庁 (2020). デジタル・プラットフォーム利用者の意識・行動調査,
https://www.caa.go.jp/notice/assets/consumer_system_cms101_200520_03.pdf.

日本弁護士連合会 (2017). ステルスマーケティングの規制に関する意見書,
https://www.nichibenren.or.jp/library/ja/opinion/report/data/2017/opinion_170216_02.pdf.